

多传感器检测管道缺陷数据融合方法

梁海波^{1*}, 成刚¹, 张志东², 杨海¹, 罗顺³

¹西南石油大学机电工程学院, 四川 成都 610500;

²中国石油集团川庆钻探工程有限公司安全环保质量监督检测研究院, 四川 成都 610056;

³中国石油集团西部钻探工程技术研究院, 新疆 乌鲁木齐 830000

摘要 针对多传感器管道缺陷检测数据融合精度不高的问题,提出了一种改进鸟群算法(IBSN)与加权正则化极限学习机(WRELM)相结合的多传感器检测管道缺陷数据融合方法。首先,利用电磁超声导波、漏磁以及涡流检测设备采集管道缺陷数据,将高斯核函数样本权重矩阵和正则化参数引入极限学习机中,建立 WRELM 数据融合模型;而后,通过引入混沌变量和高斯扰动、优化警惕行为以及改变飞行行为中步长因子来优化鸟群算法,采用 IBSA 优化 WRELM 输入层到隐含层的连接权值和隐含层的偏置;最后,利用多仪器检测管道缺陷数据融合平台进行实验分析。实验结果表明:采用 IBSA-WRELM 的多仪器检测管道缺陷数据融合模型的误差最小,仅为 2.33%,有效提高了多仪器检测管道缺陷数据的融合精度。

关键词 油气管道腐蚀; 多传感器; 改进鸟群算法; 加权极限学习机; 数据融合

中图分类号 TE988.2 文献标志码 A

DOI: 10.3788/LOP212811

Data Fusion Method for Multi-Sensor Detection of Pipeline Defects

Liang Haibo^{1*}, Cheng Gang¹, Zhang Zhidong², Yang Hai¹, Luo Shun³

¹School of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610500, Sichuan, China;

²CNPC Chuanqing Drilling Engineering Co., Ltd. Safety and Environmental Quality Supervision and Testing Institute, Chengdu 610056, Sichuan, China;

³CNPC West Drilling Engineering Technology Research Institute, Urumqi 830000, Xinjiang, China

Abstract Considering the problem of low fusion accuracy of multi-sensor pipeline defect detection data, a data fusion method of multi-instrument pipeline defect detection is proposed, which combines the improved bird swarm algorithm (IBSA) with the weighted regularized extreme learning machine (WRELM). First, pipeline defect data are collected using electromagnetic ultrasonic guided wave testing equipment, magnetic flux leakage testing equipment, and eddy current testing equipment. The Gaussian kernel function sample weight matrix and the regularization parameter are subsequently introduced into the extreme learning machine, and the WRELM data fusion model is established. The bird swarm algorithm is then optimized by introducing chaotic variables and Gaussian perturbations, which optimizes vigilance behavior and changes the step factor in the flight behavior. The IBSA is used to optimize the connection weight between the input layer and the hidden layer and the bias of the hidden layer of WRELM. Finally, the data fusion platform for multi-instrument pipeline defect detection is utilized for experimental analysis. The experimental results show that the error of the multi-instrument pipeline defect data fusion model using the IBSA to optimize the WRELM is the smallest at just 2.33%. The fusion accuracy of multi-instrument pipeline defect data is effectively improved.

Key words oil and gas pipeline corrosion; multiple sensor; improved bird swarm algorithm; weighted extreme learning machine; data fusion

1 引言

近年来,管道运输在油气运输中占据越来越重要

的作用^[1]。但在油气管道运输中,管道会被油气及环境不断腐蚀,产生管壁均匀减薄、蚀损斑、腐蚀点坑等缺陷,一旦腐蚀情况严重,发生油气泄漏事故,将会对

收稿日期: 2021-10-26; 修回日期: 2021-11-26; 录用日期: 2021-12-22; 网络首发日期: 2022-01-04

基金项目: 中石油总公司-西南石油大学创新联合体(2020CX040000)

通信作者: *secondbo@swpu.edu.cn

人们的生命财产安全造成严重威胁^[2]。因此,定期对管道开展腐蚀检测,及时、准确地发现腐蚀缺陷位置及管道损伤情况,并采取相应的控制、维修、更换措施,可有效降低腐蚀事故发生概率。电磁超声导波、漏磁以及涡流无损检测技术是油气管道缺陷检测的常用技术^[3-5]。但油气运输管道腐蚀类型多种多样,单独采用一种无损检测设备难以满足现场生产需求,因此,为提高油气管道缺陷检测精度,采用以上 3 种仪器检测管道存在的缺陷。

多仪器检测管道腐蚀缺陷的关键技术在于检测数据的融合。Song^[6]利用径向基函数网络对多个传感器采集到的信息进行映射,得到缺陷的几何轮廓;Fu 等^[7]设计了改进的条件生成对抗网络,这些网络有效重构多传感器信息,使信息更好地表征缺陷;Ma 等^[8]采用功能链人工神经网络融合多个霍尔传感器的输出数据,有效提高了管道腐蚀检测的精度。以上数据融合算法在一定程度上提高了数据融合的精度,同时也存在一些不能忽略的问题。径向基函数网络、改进的条件生成对抗网络与功能链人工神经网络训练都需要大量样本,且训练速度慢,容易陷入局部最优。

基于以上问题,采用极限学习机对多仪器测量数据进行融合。极限学习机是一种单隐含层前馈型神经网络,具有高效精确处理非线性数据回归问题等优点,克服了一般神经网络学习速度慢、样本需求量大、容易陷入局部最优的问题^[9-11]。但标准极限学习机只考虑了经验风险而未考虑结构风险,容易出现过拟合,导致极限学习机的泛化性能降低,因此引入正则化参数平衡误差矩阵和输出权重,增强极限学习机模型的泛化能力。同时考虑到不同样本对极限学习机网络输出的影响,使用高斯核函数作为样本加权矩阵,利用训练样本与待预测样本的相似性对训练样本加权,避免产生过拟合问题的同时,降低异常点的权重,进而提高了极限学习机的学习能力。

由于极限学习机神经网络输入层到隐含层连接权值以及隐含层阈值均是随机产生,容易造成模型泛化能力不足、稳定较差^[12-13],采用改进鸟群算法(Improved bird swarm algorithm, IBSA)优化极限学习机的连接权重和偏置。IBSA 在继承原有的鸟群算法优点的同时^[14],引入混沌变量和高斯扰动来增强算法跳出局部最优的能力,为增加寻优的靶向性,针对原算法在警戒行为中个体选择时,用当前全局最优个体来替代原来随机选择的个体,同时为了避免步长选择过大导致错过最佳位置而产生误差,采用加权平均之前步长的方式确定新步长。

基于以上情况,本文提出了一种改进鸟群算法与加权正则化极限学习机相结合(IBSA-WRELM)的多仪器检测管道缺陷数据融合方法。首先,利用电磁超声导波、漏磁以及涡流检测设备采集管道缺陷数据,将高斯核函数样本权重矩阵和正则化参数引入极限

学习机中,建立 WRELM 数据融合模型,通过混沌变量、高斯扰动、优化警惕行为以及改变飞行行为中步长因子来优化鸟群算法;然后,采用 IBSA 优化 WRELM 输入层到隐含层的连接权值和隐含层的偏置,最后利用多仪器检测管道缺陷数据融合平台进行实验分析。

2 管道缺陷检测问题分析

金属管道运输是运输油气的重要方式,管道发生腐蚀会影响管道使用寿命,造成环境污染,降低油品质量,影响到油气加工设备的正常运行,同时也会造成设备泄漏、火灾等安全事故^[15]。

金属油气管道腐蚀主要来自 3 个方面:内腐蚀、外腐蚀以及电化学腐蚀^[16-17]。内腐蚀主要来自于油气本身。天然气和石油中通常含有硫化氢、二氧化碳和水,这些成分本身会腐蚀管道,同时这些物质出现化学反应时,又会进一步腐蚀管道,造成均匀腐蚀、点蚀、冲刷腐蚀等。外腐蚀主要来自于油气管道的外部地质环境。裸露的金属管道有时会受到水和土壤的腐蚀,同时各种微生物也会侵蚀管道,腐蚀管道外壁,造成点蚀、均匀减薄、缝隙腐蚀等。电化学腐蚀是油气管道与电解质组成 2 个电极,进而形成腐蚀原电池,造成点蚀、缝隙腐蚀等。

目前对油气管道进行缺陷检测的方法主要有电磁超声导波法、漏磁法、涡流法等^[18-20]。电磁超声导波技术可以利用其垂直纵波对金属管道内部进行探伤,也可以利用水平横波对金属管道进行表面损伤检测,还可以采用激发特定线圈产生斜入射波对被测试件内部的垂直裂缝进行检测,其可以检测到管道表面和内部不同类型的缺陷,但对焊缝等类型缺陷不敏感。涡流缺陷检测方法根据检测时不同的激励方式可以分为单频涡流检测、多频涡流检测、脉冲涡流检测、远场涡流检测等方法,可以对管道中的焊缝、表面裂纹以及近表面缺陷进行高精度的测量,但难以检测金属导体深层的缺陷。漏磁缺陷检测方法是利用基于霍尔效应的漏磁传感器检测整个管道,在缺陷处磁感应曲线会产生变化,由此可确定出缺陷的位置和特征。漏磁检测技术主要检测与磁感应线为非平行方向的缺陷类型,对于厚壁管道及平行于磁感应线的缺陷类型显得乏力。

因此,采用多个传感器检测金属管道腐蚀,结合极限学习机对各种传感器的输出数据进行融合,发挥各种传感器的最佳检测性能,提高分辨率,降低信息的模糊度,从而提升系统工作的容错性。因不同类型的传感器对不同类型的缺陷敏感程度不同,所以对于同一缺陷,某些传感器可能出现漏检或精度低的情况。特别是漏检,不利于数据融合模型的训练和测试,会降低模型的准确性和鲁棒性。为削弱这种情况对融合模型的影响,根据预测样本同训练样本的距离,对预测样本使用加权矩阵,保证了一旦预测样本出现漏检,训练样

本也可以通过加权,削弱这种影响。

3 WRELM

标准极限学习机是基于单隐层前馈神经网络的算法^[21],易发生过拟合问题。为提高极限学习机的泛化能力,采用正则化参数平衡误差矩阵和输出矩阵^[22]。同时考虑到不同样本对极限学习机输出的影响^[23],在其目标函数中引入加权矩阵。利用高斯核函数作为样本加权矩阵,利用训练样本与待预测样本的相似性对待预测样本加权,降低异常点权重,提高极限学习机的学习能力。WRELM的目标函数 L_{WRELM} 为

$$L_{\text{WRELM}} = \min_{\beta} \frac{1}{2} \mathbf{V} \|\mathbf{H}\beta - \mathbf{T}\|_2^2 + \frac{\lambda}{2} \|\beta\|_2^2, \quad (1)$$

式中: β 、 \mathbf{T} 和 \mathbf{H} 分别为输出权值、期望输出以及隐藏层数据矩阵; λ 为正则化参数; $\|\cdot\|_2^2$ 为误差矩阵 $\mathbf{H}\beta - \mathbf{T}$ 的 L_2 范数的平方; \mathbf{V} 为加权矩阵,由高斯核函数组成:

$$\mathbf{V} = \begin{bmatrix} \exp\left[\frac{-\|x - x_1\|_2^2}{2\delta^2}\right] & & & 0 \\ & \ddots & & \\ & & \ddots & \\ 0 & & & \exp\left[\frac{-\|x - x_N\|_2^2}{2\delta^2}\right] \end{bmatrix}, \quad (2)$$

式中: x 为待预测样本; x_i 为训练集样本; δ 为高斯核函数参数。

β 的最优解为

$$\beta = \begin{cases} \mathbf{H}^T (\lambda \mathbf{I} + \mathbf{V}\mathbf{H}\mathbf{H}^T)^{-1} \mathbf{V}\mathbf{T}, & N < L \\ (\lambda \mathbf{I} + \mathbf{H}^T \mathbf{V}\mathbf{H})^{-1} \mathbf{H}^T \mathbf{V}\mathbf{T}, & N \geq L \end{cases}. \quad (3)$$

式中: N 为样本数量; L 为神经元个数; \mathbf{I} 为单位矩阵。

4 改进鸟群算法

使用WRELM作为多传感器数据融合模型时,由于模型的输入层和隐藏层之间的权重和偏置是随机生成的,这易使多传感器数据融合模型出现泛化能力差、稳定性差的问题,因此使用鸟群算法来选取这些参数。

但若使用原始鸟群算法优化加权正则化极限学习机(BSA-WRELM)会导致多传感器数据融合模型收敛速度慢,同时容易使得多传感器数据融合模型求解陷入局部最优,导致融合模型精度低。因此,对鸟群算法进行改进,以提高鸟群算法性能。

4.1 混沌初始化

原始鸟群算法随机初始化鸟群位置,会造成位置分布不均匀进而降低求解精度。基于立方映射混沌变量可以在整个解空间内根据自身特性逐一遍历每一个状态的特性^[24],采用立方混沌映射初始化鸟群,使整个融合算法模型在解空间中更加均匀地初始化,以增强融合模型初始化寻优能力,减少迭代的次数,加速融合模

型收敛:

$$\begin{cases} y(n+1) = 4y(n)^3 - 3y(n) \\ -1 \leq y(n) \leq 1, n = 0, 1, 2, \dots \end{cases}. \quad (4)$$

利用式(4)产生鸟群,而后按照

$$x_i = L_d + (1 + y_i) \times \frac{U_d - L_d}{2} \quad (5)$$

映射到解空间,式中: U_d 、 L_d 为搜索空间的上、下界; y_i 为利用立方混沌映射产生的第 i 只鸟; x_i 为第 i 只鸟在搜索空间的坐标。

4.2 觅食行为优化

为平衡算法全局和局部搜索,同时促进算法跳出局部最优,在鸟群算法的觅食行为中引入混沌惯性权重^[25]、认知加速系数^[26]以及高斯扰动。混沌惯性权重表示为

$$\omega(i+1) = \mu \times \omega(i) \times [1 - \omega(i)], \quad i = 1, 2, \dots, n, \quad (6)$$

式中: $\mu=4$ 时,logistic混沌具有稳定的状态。认知加速系数表示为

$$C = -a \times \left(\frac{t}{t_{\max}}\right)^2 \times \tan\left\{\frac{\pi}{8} \left[1 + \left(\frac{t}{t_{\max}}\right)^2\right]\right\} + \theta + \rho \times z, \quad (7)$$

$$S = -a \times \left(1 - \frac{t}{t_{\max}}\right)^2 \times \tan\left\{\frac{\pi}{8} \times \left[1 + \left(1 - \frac{t}{t_{\max}}\right)^2\right]\right\} + \theta + \rho \times z, \quad (8)$$

式中: a 、 θ 、 ρ 为在 $[0, 2]$ 之间的常数; t 为迭代次数; t_{\max} 为最大迭代次数; z 为满足logistic混沌的映射。

改进后的觅食行为表示为

$$x_{i,j}^{t+1} = x_{i,j}^t \times \mu \times \omega(i) \times (1 - \omega(i)) + (p_{i,j} - x_{i,j}^t) \times \left\{ (-a) \times \left(\frac{t}{t_{\max}}\right)^2 \times \tan\left\{\frac{\pi}{8} \times \left[1 + \left(\frac{t}{t_{\max}}\right)^2\right]\right\} + \theta + \rho \times z \right\} \times \text{rand}(0, 1) + (\text{rand}(0, 1) \times \text{rand}(0, 1) \times \text{Gaussian}(\mu, \sigma^2) + g_j - x_{i,j}^t) \times \left\{ (-a) \times \left(1 - \frac{t}{t_{\max}}\right)^2 \times \tan\left\{\frac{\pi}{8} \times \left[1 + \left(1 - \frac{t}{t_{\max}}\right)^2\right]\right\} + \theta + \rho \times z \right\} \times \text{rand}(0, 1), \quad (9)$$

式中:Gaussian为高斯分布;rand为均匀分布;Gaussian(μ, σ^2)为服从均值为 μ ,方差为 σ^2 的高斯分布随机数。

4.3 警惕行为优化

为增加鸟群算法寻优的靶向性,加速算法收敛,在原算法警戒行为个体选择的问题上,采用当前全局最优个体替代原来的随机个体。改进后的警惕行为表示为

$$x_{i,j}^{t+1} = x_{i,j}^t + \left[a_1 \times \exp\left(-\frac{q_i}{S_{um} + \epsilon} \times N\right) \right] \times (m_j - x_{i,j}^t) \times \text{rand}(0, 1) + \left\{ a_2 \times \exp\left[\frac{q_i - q_g}{|q_g - q_i| + \epsilon}\right] \times \frac{N \times q_g}{S_{um} + \epsilon} \right\} \times (g_j - x_{i,j}^t) \times \text{rand}(-1, 1), \quad (10)$$

式中： q_g 为全局最优个体的适应度； a_1, a_2 为 $[0, 2]$ 之间的正实数； q_i 为第*i*只鸟的适应度值； S_{um} 为群体的最佳适应值之和； ϵ 用于避免零分误差； m_j 为整个鸟群中第*j*个元素的平均值； N 为鸟的数量； g_j 为鸟群共享最佳前位置的第*j*个元素。

4.4 飞行行为优化

针对原算法可能会因步长选择过大而越过最佳位置的问题,采取加权平均的方式确定生产者新步长:

$$x_{i,j}^{t+1} = x_{i,j}^t + \text{rand}(0, 1) \times \frac{\sum_{i=1}^t |x_{i,j}^t - x_{i-1,j}^t| (x_{i,j}^t - x_{i-1,j}^t)}{\sum_{i=1}^t |x_{i,j}^t - x_{i-1,j}^t|}. \quad (11)$$

综上,IBSA流程如图1所示。

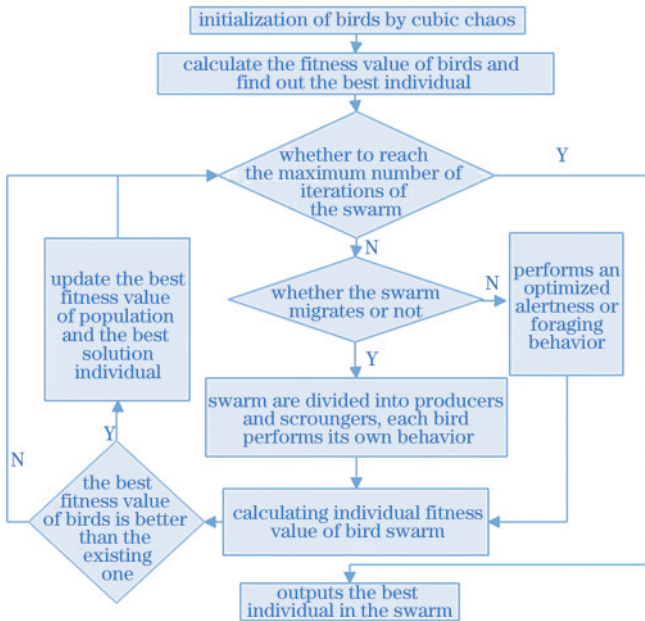


图1 IBSA流程图

Fig. 1 Flow chart of IBSA

5 搭建IBSA-WRELM模型

IBSA-WRELM参数流程图如图2所示。

IBSA-WRELM参数步骤如下:

步骤1 将数据集分为训练集和测试集;

步骤2 混沌初始化鸟群,每只鸟由WRELM的输入权重和偏置构成;

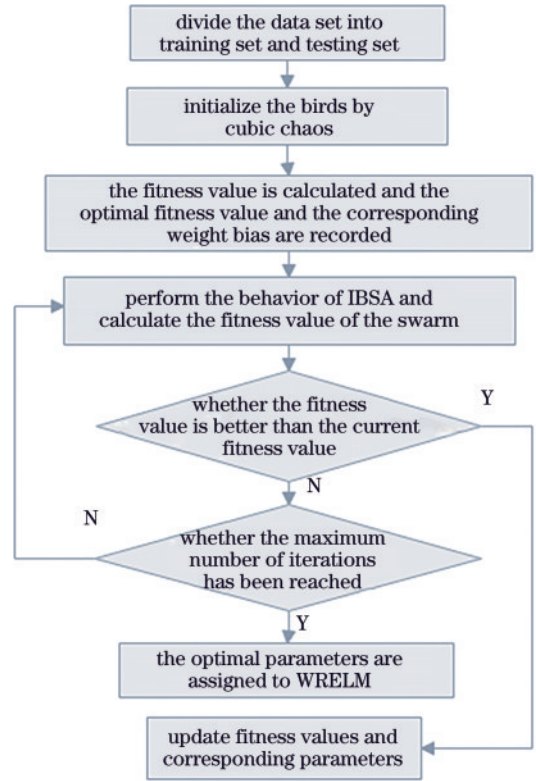


图2 IBSA-WRELM参数流程图

Fig. 2 Flow chart of IBSA-WRELM parameters

步骤3 根据每只鸟的参数计算WRELM的回归误差适应度值,并记录最优的适应度值和对应的权重偏置;

步骤4 执行IBSA行为,而后计算更新适应度值,若优于当前最佳适应度值,则替换最佳适应度值和对应的参数,否则进入下一步;

步骤5 若鸟群进化次数小于最大迭代次数,则返回步骤4;否则将参数赋值给WRELM,完成模型建立。

构建基于IBSA-WRELM的多仪器检测管道缺陷数据融合模型,系统框图如图3所示。

基于IBSA-WRELM的多传感器检测管道缺陷数据融合模型由两部分组成:数据处理部分和训练部分。首先是数据处理部分,也就是IBSA-WRELM模型使用的总数据集,将总数据集分为测试集和训练集后,使用高斯核函数计算训练集对每个测试样本的加权矩阵,使其成为IBSA-WRELM的输入,而后开始训练,IBSA-WRELM的训练流程图如图2所示,最后输出融合算法的预测值。

基于IBSA-WRELM的多仪器检测管道缺陷数据融合方法主要有4个步骤:

步骤1 采集各仪器检测数据,并将数据分为训练集和测试集;

步骤2 根据训练集确定每个测试集样本的权重矩阵;

步骤3 利用每个测试样本和其对应的权重矩阵训练改进鸟群优化的正则化极限学习机,并输出预测值;

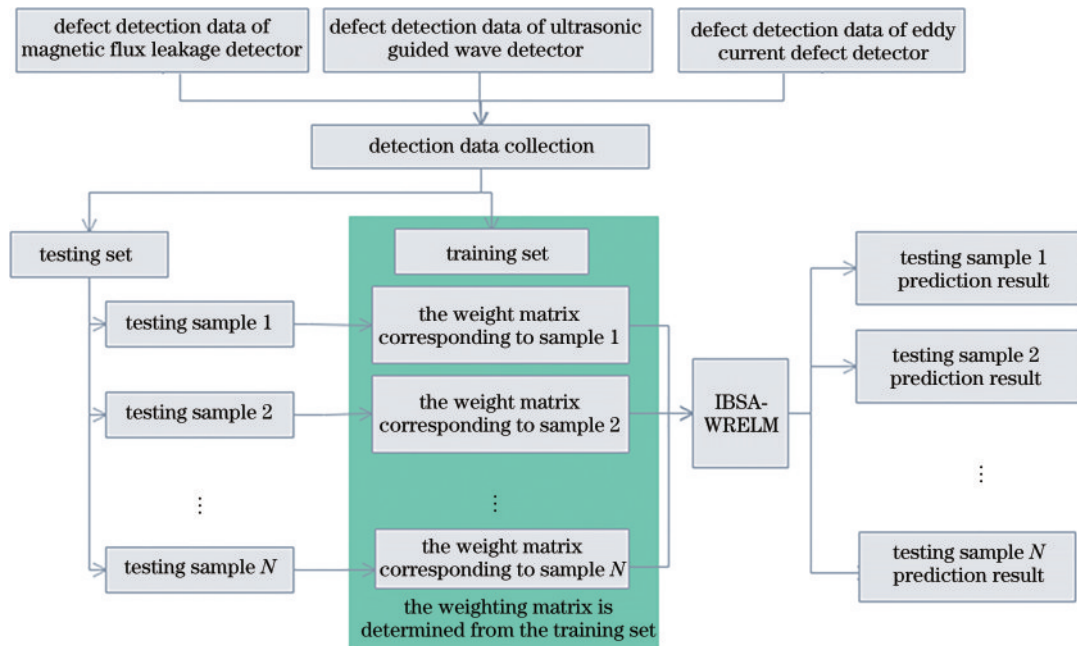


图 3 基于 IBSA-WRELM 的多仪器检测管道缺陷数据融合方法

Fig. 3 Data fusion method for multi-instrument pipeline defect detection based on IBSA-WRELM

步骤 4 按照步骤 3 完成全部测试集预测。

6 实验分析

为了验证所提多仪器检测管道缺陷数据融合模型的正确性,搭建多仪器检测管道缺陷实验平台,并对所提出的模型进行实验验证。

6.1 实验数据采集

选用 Temate PowerBox 电磁超声导波检测仪、Eddyfi 涡流检测仪以及 Pipescan HD 漏磁腐蚀检测仪 3 种仪器来对管道进行缺陷检测。实验装置如图 4 所示。




图 4 Temate PowerBox 电磁超声导波检测仪

Fig. 4 Temate PowerBox electromagnetic ultrasonic guided wave detector

实验样本选择了材料为 304L 的钢管共 30 个样本,每个样本管道外圆直径为 50 mm,内圆直径为 40 mm,壁厚为 5 mm,长度为 500 mm,利用切割刀、车床、电火花等加工设备对管道进行人工缺陷制作,4 种缺陷的标准样本如图 5 所示。

以这 4 个缺陷标准样本为基础,在 30 个样本管道




图 5 裂纹标准缺陷。(a)腐蚀穿孔标准缺陷;(b)点蚀标准缺陷;(c)凹槽标准缺陷;(d)轴向裂纹标准缺陷

Fig. 5 Crack standard defects. (a) Perforation standard defect; (b) pitting standard defect; (c) groove standard defect; (d) axial crack standard defect

上分别制作 30 个缺陷,每个样本管道均制作 11 个穿孔、11 个点蚀缺陷、4 个凹槽和 4 个轴向裂纹。

利用仪器对 30 个样本管道进行检测,从 3 个设备的输出参数中选择出能够表征缺陷位置和尺寸大小的参数:缺陷的几何中心直角坐标 x 轴、 y 轴,缺陷的测量尺寸最大长度 a 、最大宽度 b 以及管道的实时壁厚 c 。利用这 5 种参数的数据对本文的算法模型进行实验验证。部分数据如表 1 所示。

表 1 中有 2 个缺陷样本,表格第 3 列表示缺陷的标准值,该标准值是对管道样本进行标准缺陷加工时确定的,第 4 列表示电磁超声导波无损检测设备的输出值,第 5 列表示漏磁无损检测设备的输出值,第 6 列表示涡流无损检测设备的输出值。算法以电磁超声导波

表 1 检测数据
Table 1 Test data

No.	Parameter	Standard defect /mm	Electromagnetic ultrasonic guided waves output /mm	Magnetic flux leakage output /mm	Eddy current output /mm
1	Location x	35.63	35.63	35.72	35.78
	Location y	-59.47	-59.41	-59.27	-59.45
	Size a	1.64	1.71	1.67	1.60
	Size b	1.12	1.12	1.11	1.22
	Size c	1.34	1.31	1.40	1.34
2	Location x	22.70	22.84	22.86	22.73
	Location y	22.87	22.87	22.89	22.00
	Size a	0.57	0.77	0.75	0.52
	Size b	1.50	1.44	1.54	1.33
	Size c	1.97	1.92	2.01	2.14

无损检测设备的输出值、漏磁无损检测设备的输出值、涡流无损检测设备的输出值共 15 个作为输入, 标准值共 5 个作为输出, 训练基于 IBSA-WRELM 的多仪器检测管道缺陷数据融合模型。

6.2 IBSA-WRELM 的多仪器检测管道缺陷数据融合

利用 IBSA 寻找 WRELM 网络的最佳输入权重和偏置。900 组实验样本中, 选用 630 组样本作为训练集, 剩下 270 组数据作为测试集。

设置 WRELM 的输入权重和偏置范围为 $[0, 1]$, 隐藏层神经元个数为 20, 鸟群数量为 300, 种群最大迭代次数为 25, 输入神经元个数为 15, 分别为 3 种仪器的

输出数据, 设置输出神经元个数为 5, 分别表示融合后的缺陷位置以及缺陷尺寸大小。

用立方混沌初始替代原鸟群的随机初始化, 作为可视化初始化后的鸟群, 采用主成分分析法将初始化数据的维度降为 1, 并将其归一化至 $[-1, 1]$ 区间, 分别绘制立方混沌初始化和随机初始化于 $[-1, 1]$ 的频率分布图。

由图 6 数据可得, 立方混沌初始化数据的方差为 0.5129, 随机初始化数据的方差为 0.3304, 因此, 立方映射混沌初始化的鸟群在空间内比随机初始化分布更加均匀。




图 6 鸟群初始化图。(a)立方混沌初始化;(b)随机初始化

Fig. 6 Bird initialization results. (a) Cubic chaos initialization; (b) random initialization

执行 IBSA-WRELM 和 BSA-WRELM 各 15 次, 并各取二者测试样本平均均方根误差最小的一次鸟群进化过程绘制, 如图 7 所示。

由图 7 可知, BSA-WRELM 测试样本最小平均均方根误差为 0.3001, 而 IBSA-WRELM 得到的测试样本最小平均均方根误差为 0.2276, 寻优效果提升了 24.16%, 同时 IBSA-WRELM 收敛速度快于 BSA-WRELM。

测试样本有 270 组, 若将数据全部绘制, 将导致曲线不清晰, 故选取其中 25 组数据绘制误差曲线。同时将林蔚等^[27]提出的基于 F-CONFIS 和 D-S NN 证据理论的多传感器网络数据融合模型、IBSA-WRELM、

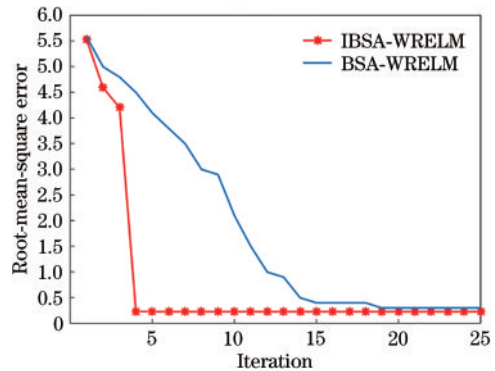


图 7 测试样本平均均方根误差迭代曲线图

Fig. 7 Iterative curves of mean root mean square error of testing samples

BSA-ELM、PSO-ELM、ELM 以及王庆红等^[28]提出的基于神经网络的数据融合算法模型进行误差对比,各模型误差如图 8 所示。

由图 8 可知,IBSA-WRELM 的 5 种参数数据融合相对误差较 BSA-ELM、PSO-ELM、ELM 以及 D-S NN 小,和 F-CONFIS D-S NN 最为接近。

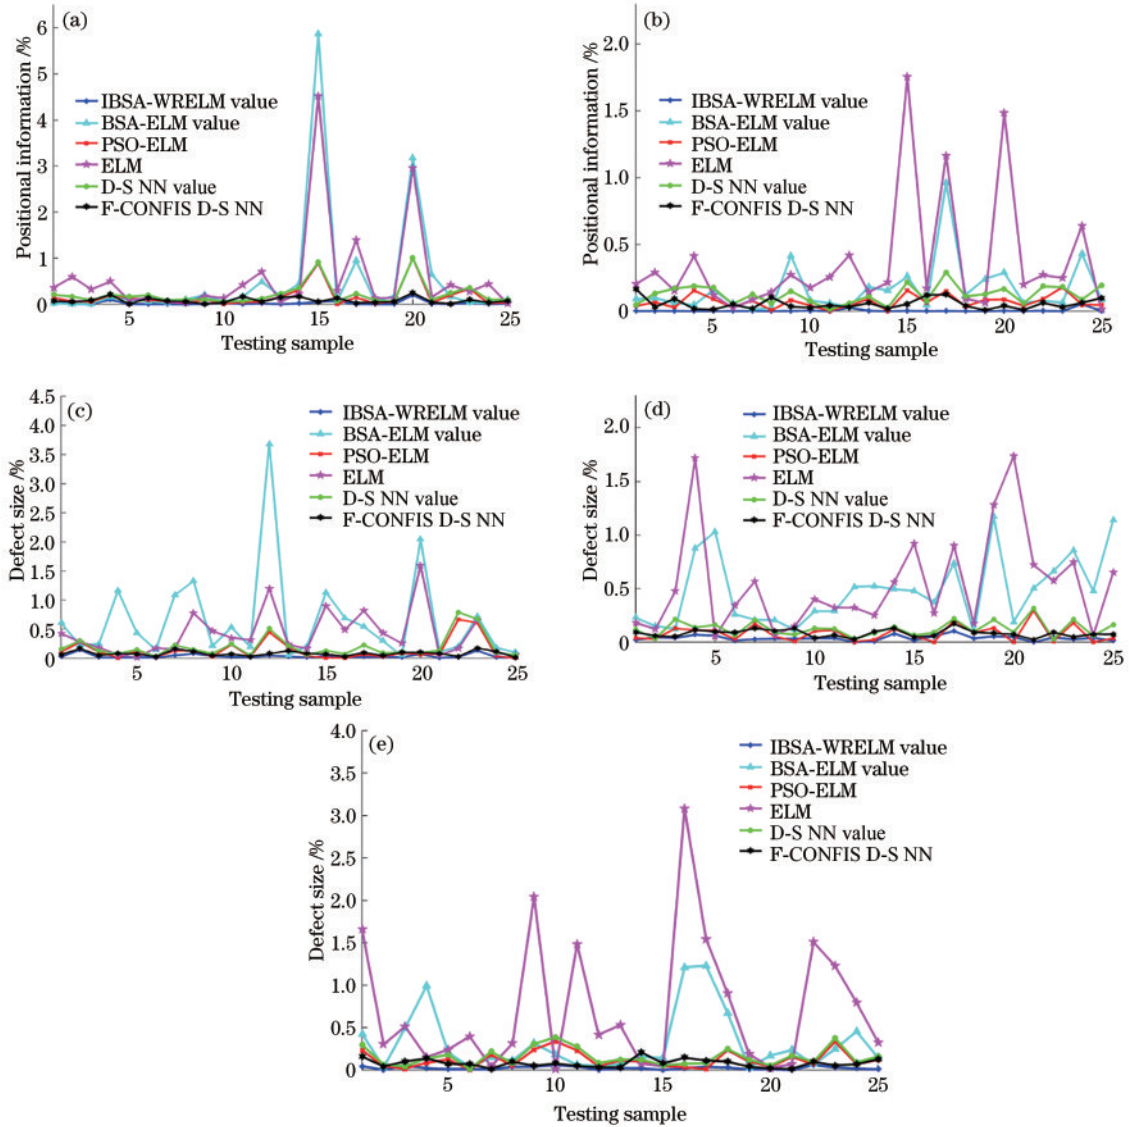


图 8 误差对比图。(a)坐标轴 x 相对误差对比图;(b)坐标轴 y 相对误差对比图;(c)缺陷尺寸 x 相对误差对比图;(d)缺陷尺寸 y 相对误差对比图;(e)缺陷尺寸 z 相对误差对比图

Fig. 8 Error comparison diagrams. (a) Error of coordinate axis x ; (b) error of coordinate axis y ; (c) error of defect size x ; (d) error of defect size y ; (e) error of defect size z

以上仅绘制 25 个样本的样本相对误差,为比较整体测试样本的平均相对误差,表 2 中列出 4 种融合算法

下 270 个测试样本的平均相对误差值,并将每一行平均相对误差值的平均值作为融合算法误差。

表 2 融合数据平均相对误差
Table 2 Average relative error of fusion data

Data fusion	Location x / %	Location y / %	Size x / %	Size y / %	Size z / %	Error of fusion algorithm / %
IBSA-WRELM	1.21	4.10	3.10	4.20	2.72	2.33
BSA-ELM	25.09	13.74	43.75	69.01	34.69	37.26
PSO-ELM	12.32	10.97	18.61	11.42	9.65	12.59
ELM	34.71	22.41	42.87	71.36	70.04	48.28
D-S NN	22.17	12.37	20.76	14.52	18.19	17.60
F-CONFIS D-S NN	8.57	5.82	7.87	10.28	7.61	8.03

由表 2 可知,改进后的融合算法精度远高于普通 ELM 融合算法,其中 IBSA-WRELM 融合算法误差最小,为 2.33%。相较于 BSA-ELM 而言,算法精度提高了 93.75%;相较于 PSO-ELM 而言,算法精度提高了 81.49%;相较于 ELM 而言,算法精度提高了 95.17%;相较于 D-S NN 而言,算法精度提高了 86.76%;相较于 F-CONFIS D-S NN 而言,算法精度提高了 70.98%。

7 结 论

针对多仪器管道缺陷检测存在数据融合精度不高的问题,提出了一种基于 IBSA-WRELM 的多仪器检测管道缺陷数据融合方法。对于 IBSA-WRELM 参数,从实验角度进行验证。首先,利用电磁超声导波、漏磁以及涡流检测设备采集管道缺陷数据,将高斯核函数样本权重矩阵和正则化参数引入极限学习机中,建立 WRELM 数据融合模型,通过引入混沌变量、高斯扰动、优化警惕行为以及改变飞行行为中步长因子来优化鸟群算法,而后采用 IBSA 优化 WRELM 输入层到隐含层的连接权值和隐含层的偏置,最后利用多仪器检测管道缺陷数据融合平台进行实验分析。实验结果表明,采用 IBSA-WRELM 的多仪器检测管道缺陷数据融合模型的误差最小,仅为 2.33%,有效提高了多仪器检测管道缺陷数据的融合精度,为多仪器检测管道缺陷数据融合提供可靠技术支持。

参 考 文 献

- [1] 李雪. 浅析管道完整性管理的重要性[J]. 石化技术, 2017, 24(5): 169.
Li X. Analysis of the importance of pipeline integrity management[J]. Petrochemical Industry Technology, 2017, 24(5): 169.
- [2] 陈学东, 王冰, 关卫和, 等. 我国石化企业在用压力容器与管道使用现状和缺陷状况分析及失效预防对策[J]. 压力容器, 2001, 18(5): 43-53.
Chen X D, Wang B, Guan W H, et al. Present situation of use of in-service pressure vessels and pipelines in Chinese petrochemical enterprises, analysis of defect conditions and failure prevention countermeasures[J]. Pressure Vessel Technology, 2001, 18(5): 43-53.
- [3] Thompson R B. A model for the electromagnetic generation of ultrasonic guided waves in ferromagnetic metal polycrystals[J]. IEEE Transactions on Sonics and Ultrasonics, 1978, 25(1): 7-15.
- [4] 杨连杰, 李阳, 孙俊杰, 等. 激光超声表面波在表面缺陷上的反射与透射[J]. 激光与光电子学进展, 2019, 56(4): 041203.
Yang L J, Li Y, Sun J J, et al. Reflection and transmission of laser ultrasonic waves on surface defects [J]. Laser & Optoelectronics Progress, 2019, 56(4): 041203.
- [5] 谷艳红, 张振振, 高先和, 等. 激光超声结合电磁超声在铝板无损检测中的应用研究[J]. 中国激光, 2020, 47

(5): 0504002.

- Gu Y H, Zhang Z Z, Gao X H, et al. Application of nondestructive detection of aluminum using laser ultrasonic technology and EMAT method[J]. Chinese Journal of Lasers, 2020, 47(5): 0504002.
- [6] Song Q. Data fusion for MFL signal characterization[J]. Applied Mechanics and Materials, 2010, 44/45/46/47: 3519-3523.
- [7] Fu M R, Liu J H, Zhang H G, et al. Multisensor fusion for magnetic flux leakage defect characterization under information incompleteness[J]. IEEE Transactions on Industrial Electronics, 2021, 68(5): 4382-4392.
- [8] Ma Z L, Liu H D. Temperature error compensation new method of MFL sensor to oil-gas pipeline corrosion inspection[J]. Advanced Materials Research, 2011, 204/205/206/207/208/209/210: 1026-1030.
- [9] Lim J, Ayoub A B, Psaltis D. Three-dimensional tomography of red blood cells using deep learning[J]. Advanced Photonics, 2020, 2(2): 026001.
- [10] Zhou T K, Fang L, Yan T, et al. *In situ* optical backpropagation training of diffractive optical neural networks[J]. Photonics Research, 2020, 8(6): 940-953.
- [11] Guo X X, Barrett T D, Wang Z M, et al. Backpropagation through nonlinear units for the all-optical training of neural networks[J]. Photonics Research, 2021, 9(3): B71-B80.
- [12] Chen S W, Shang Y, Wu M H. Application of PSO-ELM in electronic system fault diagnosis[C]//2016 IEEE International Conference on Prognostics and Health Management, June 20-22, 2016, Ottawa, ON, Canada. New York: IEEE Press, 2016.
- [13] Lan Y, Han X H, Zong W W, et al. Two-step fault diagnosis framework for rolling element bearings with imbalanced data based on GSA-WELM and GSA-ELM [J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2018, 232(16): 2937-2947.
- [14] Meng X B, Gao X Z, Lu L H, et al. A new bio-inspired optimisation algorithm: bird swarm algorithm[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2016, 28(4): 673-687.
- [15] 叶海春. 油气管道事故案例分析及腐蚀检测方法发展现状[J]. 清洗世界, 2021, 37(2): 114-115.
Ye H C. Case analysis of oil and gas pipeline accidents and development status of corrosion detection methods [J]. Cleaning World, 2021, 37(2): 114-115.
- [16] 王亚鹏. 油气集输管道的腐蚀机理与防腐技术研究[J]. 全面腐蚀控制, 2021, 35(4): 85-86.
Wang Y P. Research on corrosion mechanism and anti-corrosion technology of oil and gas gathering and transportation pipeline[J]. Total Corrosion Control, 2021, 35(4): 85-86.
- [17] 刘飞. 输气管道防腐控制措施及其应用[J]. 清洗世界, 2021, 37(11): 34-35.
Liu F. Anti-corrosion control measures for gas pipelines and their applications[J]. Cleaning World, 2021, 37(11): 34-35.
- [18] 林俊明, 张开良, 林发炳, 等. 长输油气管道的无损检

- 测[J]. 无损检测, 2019, 41(9): 44-47, 52.
- Lin J M, Zhang K L, Lin F B, et al. Nondestructive testing of long gas and oil pipelines[J]. Nondestructive Testing, 2019, 41(9): 44-47, 52.
- [19] 孙振华, 刘丽, 陈凯, 等. 超声导波在胜利油田埋地管道腐蚀监测中的现场应用与分析[J]. 内江科技, 2019, 40(1): 20-22.
- Sun Z H, Liu L, Chen K, et al. Field application and analysis of ultrasonic guided waves in the corrosion monitoring of buried pipelines in Shengli oilfield[J]. Nei Jiang Science & Technology, 2019, 40(1): 20-22.
- [20] 刘晓青. 国内外埋地管道腐蚀检测技术现状及展望[J]. 广东化工, 2019, 46(8): 138-139.
- Liu X Q. Current status and prospects of corrosion detection technology for buried pipelines at home and abroad [J]. Guangdong Chemical Industry, 2019, 46(8): 138-139.
- [21] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [22] 周孟然, 王锦国, 宋红萍, 等. 核极限学习机和激光诱导荧光技术在食用油识别中的应用[J]. 激光与光电子学进展, 2020, 57(20): 203001.
- Zhou M R, Wang J G, Song H P, et al. Application of kernel extreme learning machine and laser induction fluorescence technique in edible oil identification[J]. Laser & Optoelectronics Progress, 2020, 57(20): 203001.
- [23] Zong W, Huang G B, Chen Y. Weighted extreme learning machine for imbalance learning[J]. Neurocomputing, 2013, 101: 229-242.
- [24] Yu H L, Zhao N N, Wang P J, et al. Chaos-enhanced synchronized bat optimizer[J]. Applied Mathematical Modelling, 2020, 77: 1201-1215.
- [25] Ding H Q, Wu Z Y, Zhao L C. Whale optimization algorithm based on nonlinear convergence factor and chaotic inertial weight[J]. Concurrency and Computation: Practice and Experience, 2020, 32(24): e5949.
- [26] Du Y J, Xu F F. A hybrid multi-step probability selection particle swarm optimization with dynamic chaotic inertial weight and acceleration coefficients for numerical function optimization[J]. Symmetry, 2020, 12(6): 922.
- [27] 林蔚, 褚胜楠. 多传感器输油管道检测数据融合技术[J]. 黑龙江大学自然科学学报, 2015, 32(3): 397-403.
- Lin W, Chu S N. Data fusion research in multi-sensor pipeline detection[J]. Journal of Natural Science of Heilongjiang University, 2015, 32(3): 397-403.
- [28] 王庆红, 车威威, 王子文. 基于神经网络的数据融合算法在管道缺陷损伤识别上的应用[J]. 全面腐蚀控制, 2013, 27(11): 70-74.
- Wang Q H, Che W W, Wang Z W. Based on neural network data fusion algorithm defects in the pipeline damage identification on the application[J]. Total Corrosion Control, 2013, 27(11): 70-74.