

基于 IFA-BPNN 的长输管道外腐蚀速率预测

凌晓^{1a}, 徐鲁帅^{1a}, 高甲程², 马娟娟^{1a}, 马贺清^{1a}, 付小华^{1b}

(1.兰州理工大学 a.石油化工学院 b.理学院, 兰州 730050;
2.中国石油天然气股份有限公司 甘肃兰州销售分公司, 兰州 730050)

摘要: **目的** 构建陆地长输管道外腐蚀速率的预测模型, 提升管道外腐蚀速率预测的精度, 对长输管道外腐蚀状态进行准确把控。**方法** 深入解析了萤火虫算法 (FA) 的工作原理, 针对 FA 易出现陷入局部最优或因控制参数设置不合适而导致函数无法收敛等问题, 提出了 FA 的改进方案: 采用 Logistics 混沌映射的方法初始化萤火虫的位置, 提升萤火虫种群的所养性; 引入一种新的惯性权重计算方法来改进萤火虫位置移动公式, 提升 FA 全局寻优能力。利用改进的萤火虫算法 (IFA) 对误差反向传播神经网络 (BPNN) 初始权值和阈值进行优化, 建立基于 IFA-BPNN 的长输管道外腐蚀速率预测模型。以 111 组长输管道外腐蚀检测数据为例, 在 MATLAB 中进行模拟仿真计算, 使用粒子群算法优化的 BPNN (PSO-BPNN)、遗传算法优化的 BPNN (GA-BPNN) 以及未进行优化的 BPNN 作为对比模型进行对比分析。**结果** 使用 IFA 优化 BPNN, 大幅提升了 BPNN 模型的预测精度。使用 IFA-BPNN 模型预测 12 组管道腐蚀速率, 平均相对误差仅为 5.94%, 预测结果的 R^2 为 0.995 95, 均优于 BPNN、PSO-BPNN 以及 GA-BPNN 模型的预测结果。**结论** IFA-BPNN 作为预测管道腐蚀速率工具具有较好的预测精度和鲁棒性。

关键词: 萤火虫算法; BP 神经网络; 混沌初始化; 惯性权重; 管道; 腐蚀速率预测

中图分类号: TG172 **文献标识码:** A **文章编号:** 1001-3660(2021)04-0285-09

DOI: 10.16490/j.cnki.issn.1001-3660.2021.04.029

Prediction of External Corrosion Rate of Oil Pipeline Based on Improved IFA-BPNN

LING Xiao^{1a}, XU Lu-shuai^{1a}, GAO Jia-cheng², MA Juan-juan^{1a}, MA He-qing^{1a}, FU Xiao-hua^{1b}

(1.a.College of Petroleum and Chemical Engineering, b.College of Sciences, Lanzhou University of Technology, Lanzhou 730050, China; 2.PetroChina Gansu Lanzhou Marketing Company, Lanzhou 730050, China)

ABSTRACT: In order to establish a machine learning model for predicting the external corrosion rate of long land transport pipelines, improve the prediction accuracy of the external corrosion rate of the pipeline, and accurately grasp the external corrosion status of the long-distance pipeline, this paper analyzes the working principle of FA, to solve the problems of FA, such as local optimization or function convergence failure due to initial parameter setting, and an improved FA algorithm is proposed:

收稿日期: 2020-07-30; 修订日期: 2020-11-27

Received: 2020-07-30; Revised: 2020-11-27

基金项目: 国家自然科学基金青年项目 (51904138); 甘肃省自然科学基金 (20JR5RA451); 甘肃省高等学校创新能力提升项目 (2020A-019)

Fund: Supported by the Youth Program of National Natural Science Foundation of China (51904138); the Natural Science Foundation of Gansu Province (20JR5RA451); Innovation Ability Improvement Project of Colleges and Universities in Gansu Province (2020A-019)

作者简介: 凌晓 (1982—), 男, 博士, 副教授, 主要研究方向为油气管道完整性管理。邮箱: lingxiao_lut@163.com

Biography: LING Xiao (1982—), Male, Doctor, Associate professor, Research focus: oil and gas pipeline integrity management. E-mail: lingxiao_lut@163.com

引文格式: 凌晓, 徐鲁帅, 高甲程, 等. 基于 IFA-BPNN 的长输管道外腐蚀速率预测[J]. 表面技术, 2021, 50(4): 285-293.

LING Xiao, XU Lu-shuai, GAO Jia-cheng, et al. Prediction of external corrosion rate of oil pipeline based on improved IFA-BPNN[J]. Surface technology, 2021, 50(4): 285-293.

This paper uses the method of Logistics chaotic mapping to initialize the position of the firefly, and improve the cultivability of the firefly population; this paper introduces a new inertia weight calculation method to improve the formula of the firefly position movement and enhance the FA global optimization ability. The improved FA (IFA) was used to optimize the initial weights and thresholds of BPNN, and a long-distance pipeline external corrosion rate prediction model based on IFA-BPNN was established. Taking 111 sets of long-distance pipeline external corrosion detection data as an example, the simulation calculation is carried out in MATLAB, and PSO-BPNN, GA-BPNN and unoptimized BPNN are used as comparative models for comparative analysis. The IFA model is used to initialize the BPNN model, which greatly improves the prediction accuracy of the BPNN model. The IFA-BPNN model was used to predict and analyze the external corrosion rates of 12 groups of pipelines, the average relative error was only 5.94%, and the R^2 of the prediction results was 0.995 95. The prediction results of IFA-BPNN model are superior to those of BPNN model, PSO-BPNN model and GA-BPNN model in all aspects. IFA-BPNN has good accuracy and robustness as a tool to predict pipeline corrosion rate.

KEY WORDS: firefly algorithm; BP neural network; chaos initialization; inertia weight; oil pipelines; corrosion rate prediction

管道作为最快速、最安全的石油和天然气运输方式,建设规模不断扩大。2019 年末,我国长输管道总里程已达 13.9×10^4 km^[1],管道失效将直接影响企业的经济效益和居民的安全^[2-3]。近年来,国内外研究人员对管道失效模式进行了大量研究,发现腐蚀是造成油气长输管道失效的主要原因之一^[4-6]。管道开挖检测费时费力,易造成资源浪费。因此,基于算法模型以及影响管道腐蚀的各项数据,对管道腐蚀状态进行准确预测,可为管道检修提供决策支持,对保障管道安全运行具有重大意义^[7-11]。

张河苇等^[12]使用互信息理论确定了管道腐蚀的主要影响因素,为选取预测管道腐蚀速率的数据提供了决策支持。毕傲睿等^[13]利用主成分分析法对输油管道内腐蚀因素进行优选,选出了影响管道腐蚀的主要因素,并结合改进的支持向量机模型对管道内腐蚀情况进行预测,且结果较为理想,但支持向量机由于算法本体缺陷,针对大规模训练样本难以实施。陈迪等^[14]研究发现了影响含硫管道腐蚀情况的四大因素,并结合实验结论建立了一套预测含硫管道腐蚀状态模型,预测效果较优,但该模型仅针对管道内腐蚀有效,不适用于管道外腐蚀速率预测。章玉婷等^[15]使用单一的 BP 神经网络(BP Neural Network, BPNN)对管道腐蚀速率进行分析预测,由于未经优化的 BPNN 易陷入局部最优,因此预测值相对真实数据误差较大。董绍华等提出中国管道的发展目标是建立基于管道全生命周期大数据的智慧管网^[16],而基于机器学习的管道大数据分析处理是构建智慧管网的重要内容之一。近年来, Yang 等^[17-19]提出了萤火虫算法(Firefly Algorithm, FA),并通过仿真证实了 FA 要优于粒子群优化算法(Particle Swarm Optimization, PSO)和遗传算法(Genetic Algorithm, GA)。NANDY 等^[20]使用 FA 优化 BPNN 的初始权值和阈值,并通过仿真证实了其可行性。

综上所述,目前研究工作着重于管道腐蚀小样本数据预测研究,或因算法本体缺陷而导致腐蚀速率的

预测误差较大。随着智慧管网的发展,管道数据采集量将会增大,而 BPNN 可应对数据量较大的问题。因此,本文对 FA 算法进行了改进,增强其全局寻优能力,并利用 IFA 对 BPNN 初始权值和阈值进行优化,建立了基于 IFA-BPNN 的长输管道外腐蚀速率预测模型,并对该模型进行实例应用,验证了该模型的适应性和鲁棒性。

1 BPNN 及其优化模型介绍

BPNN 模型具有较强的非线性函数拟合能力,但该模型常因初始权值和阈值的设置不当而陷入局部最优,从而使模型预测结果不理想。为改进 BPNN 本体存在的不足,本文提出使用 IFA 对 BPNN 初始值进行优化,并以 GA 和 PSO 作为对比优化模型进行测试分析,以验证 IFA-BPNN 模型的使用效果。

1.1 BPNN 模型概述

BPNN 于 1986 年提出,是现阶段应用较广泛的神经网络模型之一。BPNN 一般采用 3 层网络结构便可达到良好的非线性逼近效果^[21-22]。BPNN 输入和输出的节点数量分别根据数据输入类别和预期输出类别确定,隐藏层中的节点数量可根据经验公式确定,各层通过权值相连,隐藏层和输出层各节点设有阈值。BPNN 网络拓扑图如图 1 所示。

BPNN 模型正向传递过程按式(1)~(4)进行运算^[9]。

$$s_j = \sum_{i=1}^L w_{ij} x_i + b_j \quad (1)$$

$$a_j = f(s_j) \quad (2)$$

$$p_k = \sum_{j=1}^N w_{jk} a_j + b_k \quad (3)$$

$$t_k = f(p_k) \quad (4)$$

式中: x_i 为 BPNN 输入值; w_{ij} 为输入层到隐藏




图 1 BPNN 模型示意图

Fig.1 Schematic diagram of BPNN model

层的权重值; b_j 、 b_k 分别为隐藏层和输出层的阈值; s_j 、 a_j 分别为隐藏层的输入值和输出值; w_{jk} 为隐藏层到输出层之间的权值; p_k 、 t_k 分别为输出层的输入值和输出值; $f(x)$ 为神经网络传递函数。

误差反向传播的误差函数公式及权值阈值修正系数的公式为^[9]:

$$f_i = \sum_{k=1}^N (y_k - \bar{y}_k)^2 \quad (5)$$

$$\Delta w_{jk} = -\eta \frac{\partial E_p}{\partial w_{jk}} \quad (6)$$

$$\Delta w_{ij} = -\eta \frac{\partial E_p}{\partial w_{ij}} \quad (7)$$

$$\Delta b_k = -\eta \frac{\partial E_p}{\partial b_k} \quad (8)$$

$$\Delta b_j = -\eta \frac{\partial E_p}{\partial b_j} \quad (9)$$

式中: f_i 是误差函数公式; N 为样本组数; y_k 为真实值; \bar{y}_k 为 BPNN 输出值; η 为学习速率; Δw_{ij} 、 Δw_{jk} 为修正系数; Δb_j 、 Δb_k 为阈值修正系数; E_p 为节点误差。

1.2 GA 模型

GA 由 Holland 及其学生于 1975 年创建, 其思想是基于达尔文的进化论和 Mendel 的遗传学说, 其主体分为选择、交叉和变异三部分^[23-24]:

1) 选择。文内采用轮盘赌方法进行选择操作, 其公式为式 (10), 其中 f_i 计算公式与式 (5) 相同。

$$P_i = f_i / \sum_{i=1}^m f_i \quad (10)$$

式中: m 为染色体总数; f_i 是第 i 个个体的适应度; N 为样本总数; P_i 是第 i 个个体被选中的几率。

2) 交叉。文中采用实数交叉法, 公式见式 (11)。

$$\begin{cases} x_A^{t+1} = ax_B^t + (1-a)x_A^t \\ x_B^{t+1} = ax_A^t + (1-a)x_B^t \end{cases} \quad (11)$$

式中: x_A^t 、 x_B^t 表示 A、B 两个染色体在第 t 位的交叉; a 是 $[0,1]$ 间的随机数。

3) 变异。变异操作的公式见式 (12)。

$$x_k = x_{\min} + \beta(x_{\max} - x_{\min}) \quad (12)$$

式中: x_{\min} 、 x_{\max} 分别为基因下界值和上界值; β 为 $[0,1]$ 间的随机数; x_k 是变异后的新基因。

1.3 PSO 模型

PSO 算法原理是随机初始化一组粒子, 通过跟踪个体极值和群体极值来更新粒子群, 粒子的速度和位置分别根据式 (13) 和式 (14) 更新^[25]。

$$v_{i,j}(t+1) = wv_{i,j}(t) + c_1r_1[p_{i,j} - x_{i,j}(t)] + c_2r_2[p_{g,j} - x_{i,j}(t)] \quad (13)$$

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1) \quad (14)$$

式中: $v_{i,j}(t+1)$ 为粒子的速度; $x_{i,j}(t+1)$ 为粒子的位置; c_1 和 c_2 是学习因子; r_1 和 r_2 是 $[0,1]$ 间的两个随机数; w 为惯性权重。

惯性权重采用线性递减的方式^[26], 其计算公式见式 (15)。

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{t_{\max}} \times t \quad (15)$$

式中: t 、 t_{\max} 分别为当前迭代数和初始设置的最大迭代数; w_{\max} 、 w_{\min} 分别为惯性权重的最大值和最小值。

1.4 FA 模型及改进

1.4.1 FA 模型

YANG Xin-she^[17]提出的 FA 模型的基本思想是: 萤火虫种群中每个萤火虫代表一个潜在解, 根据萤火虫相对亮度 I_0 也就是适应度值 f_i (f_i 计算公式与式 (5) 相同) 确定萤火虫的移动方向, 其中亮度值小的萤火虫向亮度值大的萤火虫移动, 最亮的个体随机移动。流程如下:

1) 初始化各参数以及随机初始化萤火虫个体位置, 计算各萤火虫所对应的 I_0 。

2) 根据式 (16) — (18) 计算 I 、 β 。

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2} \quad (16)$$

$$I = I_0 \times e^{-\gamma r_{ij}^2} \quad (17)$$

$$\beta = \beta_0 \times e^{-\gamma r_{ij}^2} \quad (18)$$

式中: β 、 β_0 分别为吸引力值和最大吸引力值; I 和 I_0 分别代表相对亮度和初始相对亮度; γ 是光吸收系数; r_{ij} 代表萤火虫 i 、 j 之间的空间距离; d 为萤火虫所在空间的维数, 由待优化目标确定; $x_{i,k}$ 是萤火虫 i 在空间 d 的第 k 个的值。

3) 得出 I 和 β 后, 根据式 (19) 更新萤火虫位置。

$$x_i(t+1) = x_i(t) + \beta(x_j(t) - x_i(t)) + \alpha(rand - 0.5) \quad (19)$$

式中: x_i 、 x_j 为萤火虫所处的位置; α 是随机步长, 取值区间为 $[0,1]$; $rand$ 是 $[0,1]$ 间的随机数。

4) 计算更新位置后萤火虫的亮度。

5) 满足结束条件后输出全局极值和最优个体值; 若不满足, 转步骤 2 继续迭代搜索, 迭代次数加 1。

1.4.2 FA 模型改进策略

FA 作为新型优化算法, 易出现陷入局部最优或因控制参数设置不合适而导致函数无法收敛等问题^[27-29]。鉴于上述问题, 对 FA 进行改进, 表 1 为 IFA 的伪代码。

表 1 IFA 伪代码
Tab.1 IFA pseudocode

Objective function fitness(\mathbf{x}), $\mathbf{x} = (x_1, \dots, x_d)^T$	
Logistics chaos initialize the position of fireflies x_i ($i = 1, 2, \dots, n$)	
Initializes the basic parameters	
$\gamma = a$	% Absorption coefficient of light intensity
$\alpha = b$	% Step length factor
$\beta_0 = c$	% Maximum attraction
Max T = d	% Maximum iteration number
while (The termination condition is not met)	
for $i = 1 : n$	
for $j = 1 : i$	
Calculate the light intensity of fireflies	
if ($I_j > I_i$)	
Firefly x_i towards x_j in all d dimensions	
end if	
Calculate the relative attractiveness	
New solution = $\omega x + \beta * (x_j - x_i) + \alpha * (rand - 0.5)$	
Calculate the new light intensity	
end for j	
end for i	
Determine the optimal firefly location	
end while	
Output the optimal solution	

处理流程如下所述。

1) 对萤火虫位置进行 Logistics 混沌初始化, 提升了萤火虫初始种群的多样性和萤火虫搜索的全局遍历性, 又与萤火虫随机初始化位置本质相匹配。Logistics 混沌映射公式见式 (20)^[30]。

$$z_{n+1} = rz_n(1 - z_n) \quad (20)$$

式中: r 为混沌吸引子, 取 4 时可完全混沌, 此时 $z_n + 1 \in (1 - z_n)$ 。

2) 线性递减惯性权重 w 的变化依赖当前迭代次数 T 和最大迭代次数 T_{\max} , 在迭代后期, 收敛速度变慢, 难以跳出局部最优^[31]。本文引入一种基于萤火虫个体和群体适应度值的惯性权重计算方法, 其表达式见式 (21) 和式 (22), 式 (21) 中 f_i 的计算方法与

式 (5) 相同, 改进后的萤火虫位置的计算公式更新为式 (23)。

$$w(t) = w_0 + k \times \ln\left(\frac{f_i}{f_{\text{avg}}}\right) \quad (21)$$

$$f_{\text{avg}} = \frac{1}{m} \left(\sum_{k=1}^N \sum_{j=1}^m (y_{kj} - \bar{y}_{kj})^2 \right) \quad (22)$$

$$x_i(t+1) = w(t)x_i(t) + \beta(x_j(t) - x_i(t)) + \alpha(rand - 0.5) \quad (23)$$

式中: $w(t)$ 是每次迭代的惯性权重; w_0 是惯性权重初值 (常量); k 是系数常量; f_{avg} 是第 t 代的所有萤火虫的适应度平均值; m 为群体总数; N 为样本总数; y_k 为真实值; \bar{y}_k 为输出值。位置更新公式 (23) 与式 (19) 各参数含义相同。

针对惯性权重的计算, 当 $f_i > f_{\text{avg}}$ 时, 萤火虫个体较差, 惯性权重增大, 增强萤火虫的全局搜索能力, 有利于萤火虫跳出局部最优; 当 $f_i < f_{\text{avg}}$ 时, 萤火虫个体较好, 惯性权重减小, 增强萤火虫的局部搜索能力, 使函数快速收敛。

2 管道外腐蚀速率预测模型构建

分别使用 GA、PSO 以及 IFA 3 种优化算法对 BPNN 的初始权值和阈值进行优化, 结合第 1 节各算法的理论基础, 构建长输管道外腐蚀速率预测模型 GA-BPNN、PSO-BPNN 和 IFA-BPNN, 具体的模型构建流程如图 2 所示。

3 模型评价指标

为验证 GA-BPNN、PSO-BPNN、IFA-BPNN 模型的实际应用效果, 本文选用相对误差 (RE)、平均相对误差 (MRE) 以及决定系数 R^2 来评价模型的预测效果。其中, RE 和 MRE 的数值越小越好, 都为 0 时证明预测值与真实值相等; R^2 的最大值为 1, 其值越接近 1, 表面拟合效果越好。RE、MRE、 R^2 的公式见式 (24) — (26)。

$$RE = \frac{|y_i - y_i^0|}{y_i^0} \quad (24)$$

$$MRE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - y_i^0|}{y_i^0} \times 100\% \quad (25)$$

$$R^2 = \frac{\left(N \sum_{i=1}^N y_i y_i^0 - \sum_{i=1}^N y_i \sum_{i=1}^N y_i^0 \right)^2}{\left[N \sum_{i=1}^N (y_i^0)^2 - \left(\sum_{i=1}^N y_i^0 \right)^2 \right] \left[N \sum_{i=1}^N y_i^2 - \left(\sum_{i=1}^N y_i \right)^2 \right]} \quad (26)$$

式中: y_i 为样本准确数据; y_i^0 为模型预测数据; N 为测试样本总数。

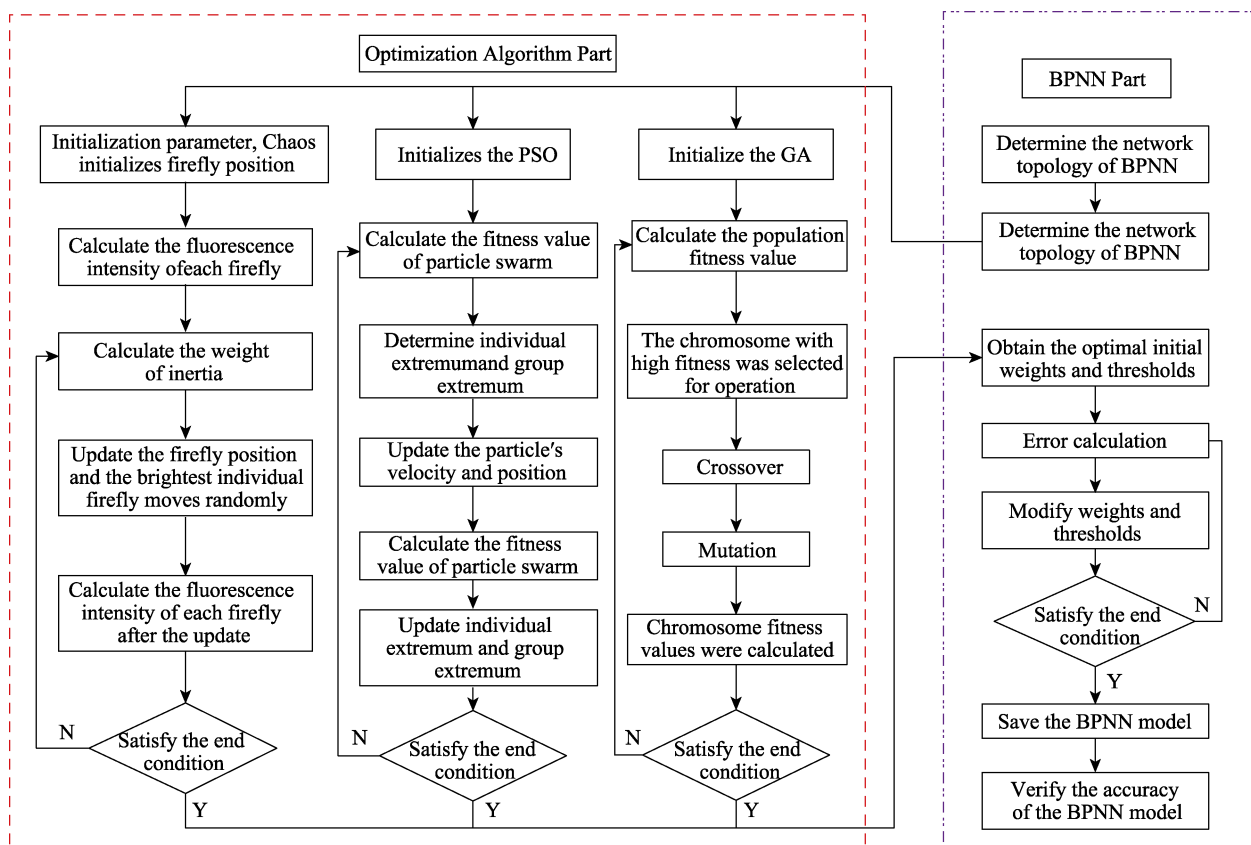


图 2 混合模型流程图
Fig.2 Flow chart of mixed model

4 实例分析

4.1 数据采集

选用文献[32]的 111 组管道外腐蚀数据, 这 111 组数据的管道防腐层均为煤焦油瓷漆涂层。因数据组数较多, 文内仅展示 20 组检测数据, 如表 2 所示。每组数据包含 11 项检测数据, 其中 Corrosion rate 为管道外腐蚀速率, TT 为管道运行总时长, PP 为氧化还原电位, pH 为管道外界土壤的 pH 值, RP 为管地电位, RE 为土壤电阻率。此数据集包括对现场开挖点的土壤成分分析数据, 该数据集采用标准实验室方法进行分析检测, 所测数据类型包括含水量 (WC)、容重 (BD) 及溶解氯化物 (CC)、碳酸氢盐 (BC)、硫酸盐 (SC) 的离子浓度。随机选取 99 组数据让各模型进行学习训练, 利用剩余的 12 组数据对各模型进行测试分析。

4.2 模型参数设置

分别使用未经优化的 BPNN 模型、GA-BPNN 模型、PSO-BPNN 模型、IFA-BPNN 模型进行管道数据的学习预测。

4.2.1 BPNN 网络设置

BPNN 采用 3 层网络结构, 各层节点数的设置方法如下所述。

BPNN 输入数据类型包括管道运行总时长, 氧化还原电位, 管道外界土壤的 pH 值, 管地电位, 土壤电阻率, 土壤含水量, 容重, 土壤中溶解氯化物、碳酸氢盐以及硫酸盐离子浓度。BPNN 输出数据为管道外腐蚀速率。因此, 将 BPNN 输入层节点数设为 10, 输出层节点数设为 1。隐含层神经元节点数根据经验公式 (27) 计算选取^[33], 因为 $\log_2(99) \approx 7$, 所以 BPNN 隐含层神经元节点数设置为 7。

$$l = \log_2 Q \quad (27)$$

式中: l 为 BPNN 隐含层节点数; Q 为 BPNN 训练集样本总数。

隐含层选用 logsig 函数作为传递函数, 其表达式见式 (28)。选用 pureline 型函数作为输出层的传递函数, 表达式见式 (29)。

$$y = \frac{1}{1 + e^{-x}} \quad (28)$$

$$y = x \quad (29)$$

式中: x 、 y 分别为节点的输入量和输出量。

4.2.2 模型初始化设置

GA-BPNN、PSO-BPNN 以及 IFA-BPNN 的神经网络部分采用 3.2.1 节的方法设置, 其网络拓扑结构均为 10-7-1, 步长为 0.2, MaxT 为 2000, 误差目标 10^{-6} 。表 3、表 4、表 5 分别为 GA、PSO、IFA 模型的初始参数设定值。

表 2 长输管道外腐蚀数据集

Tab.2 External corrosion data set of long-distance pipeline

Entry	Corrosion rate/(mm·a ⁻¹)	TT/a	pH	PP/V	RE/(Ω·m)	WC/%	BD/(g·mL ⁻¹)	CC/(×10 ⁻⁴ %)	BC/(×10 ⁻⁴ %)	SC/(×10 ⁻⁴ %)	RP/mV
1	0.055	26	7.5	-0.65	15.7	20.3	1.28	8.27	12.65	136.4	235
2	0.163	26	6.01	-0.67	13.3	29.4	1.3	69.05	5.55	40.43	96
3	0.100	26	7.04	-0.71	10	34.1	1.21	38.26	12.87	106.8	93
4	0.100	25	5.8	-0.88	8.8	33.9	1.15	11.58	8.32	321.1	263
5	0.103	26	6.22	-0.77	10.8	27.4	1.17	27.99	5.1	143.2	92
6	0.038	25	6.37	-0.85	46.8	30.4	1.16	14.06	11.1	284.3	88
7	0.043	25	5.73	-1.36	18.7	29.8	1.19	17.09	27.74	83.6	309
8	0.047	25	5.29	-0.75	86.3	29.1	1.12	6.62	5.55	60.47	275
9	0.055	23	4.6	-0.8	129.3	20.8	1.27	8.8	9.71	98.1	130
10	0.031	29	6.61	-1.11	9.1	30.8	1.28	18.49	5.55	30.97	59
11	0.076	29	5.35	-1.05	34.5	21.7	1.26	13.33	13.87	308.4	190
12	0.059	20	6.11	-0.8	87.8	20.1	1.22	12.33	16.65	54.85	150
13	0.046	22	5.28	-0.77	17.6	23.9	1.25	19.06	8.32	158	339
14	0.144	27	5.3	-0.62	36.5	25.3	1.23	109.8	10.65	374.3	17.3
15	0.151	28	5.16	-0.79	60	23.9	1.36	109.8	11.87	95.57	108
16	0.198	42	6.13	-0.47	6.8	32.4	1.21	104	15.01	379.1	117
17	0.200	42	6.5	-0.47	10.4	31.3	1.2	128.5	28.99	288.2	98
18	0.019	42	7.09	-0.48	107.1	16.8	1.34	30.96	29.65	101.2	138
19	0.197	42	6.2	-0.49	10.3	38.9	1.22	56.14	33.47	146.8	98
20	0.037	42	7.79	-0.47	7.3	39.3	1.3	18.41	29.55	399.9	99

表 3 GA 初始化参数

Tab.3 GA initialization parameters

Parameter	Value	Parameter	Value
Population size	80	Crossover probability	0.6
Max T	100	Mutation probability	0.05
Training accuracy	10 ⁻⁶		

表 4 PSO 初始化参数

Tab.4 PSO initialization parameters

Parameter	Value	Parameter	Value
Population size	80	w_{\max}	0.2
Max T	100	w_{\min}	1
Learning factor c_1	2	Training accuracy	10 ⁻⁶
Learning factor c_1	2		

表 5 IFA 初始化参数

Tab.5 IFA initialization parameters

Parameter	Value	Parameter	Value
Population size	80	Minimum attraction	0.2
Max T	100	γ	1
Step length a	0.1	w_0	0.7
β_0	1	k	0.4
Training accuracy	10 ⁻⁶	Range of w	[0.2,1]

5 结果分析

为避免数值问题, 加快 BPNN 的收敛速度, 在进行训练之前, 对所有数据进行归一化操作, 归一化公式见式 (30)。

$$x_{\text{normalization}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (30)$$

式中: $x_{\text{normalization}}$ 为归一化结果, x_{\min} 、 x_{\max} 为归一化区间临界值。

模型训练后的测试结果如表 6、图 3 和图 4 所示。由表 6 可知, 使用未经优化的 BPNN 预测管道腐蚀速率的效果最差, 最大相对误差 (Max RE) 达到了 30.88%, 最小相对误差 (Min RE) 为 14.17%; 预测效果最好的是 IFA-BPNN 模型, 其预测结果的 Max RE 为 8.82%, Min RE 仅为 1.47%, 也就是其误差区间为 [1.47%, 8.82%]; 相较于 PSO-BPNN 和 GA-BPNN 模型的误差区间, IFA-BPNN 模型的 [Min RE, Max RE] 的取值最小, 跨度最小, 证明了 IFA-BPNN 的预测精度要优于 BPNN、PSO-BPNN 以及 GA-BPNN。为进一步分析验证 IFA-BPNN 的使用效果, 对 BPNN、PSO-BPNN、GA-BPNN、IFA-BPNN 的预测结果进行 MAE 计算, 结果分别为 22.26%、15.03%、10.74%、5.94%。相较于 BPNN、PSO-BPNN、GA-BPNN 预测

结果的平均相对误差, IFA-BPNN 分别提升了 16.32%、9.09%、4.8%。使用训练好的模型 BPNN、PSO-BPNN、GA-BPNN、IFA-BPNN 对训练集的 99 组数据进行测试, 其平均相对误差分别为 18.11%、12.54%、9.12%、5.66%, 进一步验证了利用 IFA 优化 BPNN 后可有效提升其预测精度。

表 6 模型预测误差统计表
Tab.6 Model prediction error statistics table

Entry	Measured corrosion rate/(mm·a ⁻¹)	BPNN		PSO-BPNN		GA-BPNN		IFA-BPNN	
		Prediction value/(mm·a ⁻¹)	Relative error/%	Prediction value/(mm·a ⁻¹)	Relative error/%	Prediction value/(mm·a ⁻¹)	Relative error/%	Prediction value/(mm·a ⁻¹)	Relative error/%
1	0.073	0.053	27.40	0.065	10.96	0.085	16.44	0.076	4.11
2	0.023	0.029	26.09	0.018	21.74	0.027	17.39	0.025	8.70
3	0.124	0.101	18.55	0.113	8.87	0.134	8.06	0.128	3.23
4	0.074	0.086	16.22	0.089	20.27	0.071	4.05	0.069	6.76
5	0.046	0.038	17.39	0.053	15.22	0.041	10.87	0.043	6.52
6	0.204	0.141	30.88	0.228	11.76	0.231	13.24	0.201	1.47
7	0.038	0.047	23.68	0.033	13.16	0.04	5.26	0.035	7.89
8	0.034	0.044	29.41	0.029	14.71	0.038	11.76	0.037	8.82
9	0.031	0.039	25.81	0.024	22.58	0.036	16.13	0.033	6.45
10	0.24	0.274	14.17	0.208	13.33	0.225	6.25	0.255	6.25
11	0.048	0.036	25.00	0.054	12.50	0.042	12.50	0.044	8.33
12	0.072	0.081	12.50	0.061	15.28	0.077	6.94	0.074	2.78




图 3 模型预测结果对比图
Fig.3 Comparison of model prediction results




图 4 模型预测误差曲线图
Fig.4 Model prediction error curve

由图 3 可见, IFA-BPNN 预测的管道外腐蚀速率与实测值最接近, 相较于未经优化的 BPNN, 其预测精

度有了较大幅度的提升, 且 IFA-BPNN 的预测精度也优于 PSO-BPNN 和 GA-BPNN。图 4 为预测结果的误差对比图。由图 4 可见, BPNN 预测结果的误差最大, PSO-BPNN 次之, GA-BPNN 优于 BPNN 和 PSO-BPNN, IFA-BPNN 预测结果的相对误差最小, 且相对误差曲线最为平缓, 这不仅体现出 IFA-BPNN 模型预测结果的准确率较高, 也体现出该模型具有较强的鲁棒性。

分别把 BPNN、PSO-BPNN、GA-BPNN、IFA-BPNN 预测的管道腐蚀速率与实际检测的管道外腐蚀速率进行相关性分析, 其结果如图 5—8 所示, 图中黑色线公式为 $Y=X$, 红色线为预测结果拟合线。可知 BPNN 模型的 R^2 为 0.88037, PSO-BPNN 的 R^2 为 0.95876, GA-BPNN 的 R^2 为 0.97888, IFA-BPNN 的 R^2 为 0.99595。IFA-BPNN 的 R^2 最接近 1, 这进一步验证了 IFA-BPNN 作为预测管道腐蚀速率工具的准确性和鲁棒性。




图 5 BPNN 预测结果线性拟合图
Fig.5 Linear fitting diagram of BPNN prediction results




图6 PSO-BPNN 预测结果线性拟合图

Fig.6 Linear fitting diagram of PSO-BPNN prediction results




图7 GA-BPNN 预测结果线性拟合图

Fig.7 Linear fitting diagram of GA-BPNN prediction results




图8 IFA-BPNN 预测结果线性拟合图

Fig.8 Linear fitting diagram of IFA-BPNN prediction results

6 结论

1) 对 FA 进行改进, 一是对萤火虫初始位置进行 Logistics 混沌初始化, 二是引入了新的惯性权重计算公式, 有利于函数跳出局部最优寻找全局最优。利用改进的萤火虫算法优化 BPNN 的初始权值和阈值, 建立了 IFA-BPNN 管道外腐蚀速率预测模型。

2) 分别使用 BPNN、PSO-BPNN、GA-BPNN 以

及 IFA-BPNN 模型对长输管道外腐蚀速率数据进行训练、预测。IFA-BPNN 模型预测结果的 MRE 为 5.94%, R^2 为 0.99595, 均优于 BPNN、PSO-BPNN、GA-BPNN 的预测结果, 验证了 IFA-BPNN 作为预测管道腐蚀速率工具的准确性和鲁棒性。应用 IFA-BPNN 模型预测管道外腐蚀速率可为长输管道的检维修提供决策支持。

3) 由于管道外腐蚀因素较多, 且工程上难以获取较为整齐的数据, 后期研究可在数据集中添加随机变量以及噪音数据进行深入研究。

参考文献:

- [1] 高鹏, 高振宇, 王峰, 等. 2018 年中国油气管道建设新进展[J]. 国际石油经济, 2019, 27(3): 62-67.
GAO Peng, GAO Zhen-yu, WANG Feng. New progress in China's oil and gas pipeline construction in 2019[J]. International petroleum economics, 2019, 27(3): 62-67.
- [2] 王大庆, 张鹏. 油气输送管线失效后果模糊事件树分析[J]. 安全与环境学报, 2014, 14(3): 88-92.
WANG Da-qing, ZHANG Peng. Analysis of failure consequences of oil and gas transmission pipelines by using a fuzzy event tree[J]. Journal of safety and environment, 2014, 14(3): 88-92.
- [3] 黄坤, 吴佳丽, 全恺, 等. 含腐蚀缺陷油气管道评价技术研究进展[J]. 表面技术, 2018, 47(1): 116-122.
HUANG Kun, WU Jia-li, QUAN Kai, et al. A review on evaluation technology of oil-gas pipelines with corrosion defect[J]. Surface technology, 2018, 47(1): 116-122.
- [4] 单克, 帅健, 杨光, 等. 美国油气管道基本失效概率评估方法及启示[J]. 油气储运, 2020, 39(5): 530-535.
SHAN Ke, SHUAI Jian, YANG Guang, et al. Evaluation method for basic failure probability of oil and gas pipeline based on accident statistics in the United States and enlightenments[J]. Oil & gas storage and transportation, 2020, 39(5): 530-535.
- [5] CHIO Lam, ZHOU Wen-xing. Statistical analyses of incidents on onshore gas transmission pipelines based on PHMSA database[J]. International journal of pressure vessels and piping, 2016, 145: 29-40.
- [6] 张英, 吕佳慧, 王卫泽, 等. 失效数据库的建立和近年国内失效案例的统计分析[J]. 金属热处理, 2019, 44(1): 668-675.
ZHANG Ying, LYU Jia-hui, WANG Wei-ze, et al. Establishment of failure database and statistical analysis of domestic failure cases based in recent years[J]. Heat treatment of metals, 2019, 44(1): 668-675.
- [7] MOHAMMED S, ABBASY E, AHMED S, et al. Artificial neural network models for predicting condition of offshore oil and gas pipelines[J]. Automation in construction, 2014, 45: 50-65.
- [8] 曲志豪, 唐德志, 胡丽华, 等. 基于优化随机森林的 H_2S 腐蚀产物类型及腐蚀速率预测[J]. 表面技术, 2020, 49(3): 42-49.
QU Zhi-hao, TANG De-zhi, HU Li-hua, et al. Prediction of H_2S corrosion products and corrosion rate based on

- optimized random forest[J]. Surface technology, 2020, 49(3): 42-49.
- [9] 凌晓, 徐鲁帅, 梁瑞, 等. 基于改进 PSO-BPNN 的输油管道内腐蚀速率研究[J]. 中国安全生产科学技术, 2019, 15(10): 63-68.
LING Xiao, XU Lu-shuai, LIANG Rui, et al. Study on internal corrosion rate of oil pipeline based on improved PSO-BPNN[J]. Journal of safety science and technology, 2019, 15(10): 63-68.
- [10] 马钢, 李俊飞, 白瑞, 等. 基于 PSO-SVM 模型的油气管道内腐蚀速率预测[J]. 表面技术, 2019, 48(5): 43-48.
MA Gang, LI Jun-fei, BAI Rui, et al. Prediction of corrosion rate in oil and gas pipelines based on PSO-SVM model[J]. Surface technology, 2019, 48(5): 43-48.
- [11] 王文辉, 骆正山, 张新生. 基于 PSO-GRNN 模型的埋地管道腐蚀剩余寿命预测[J]. 表面技术, 2019, 48(10): 267-275.
WANG Wen-hui, LUO Zheng-shan, ZHANG Xin-sheng. Prediction on remaining service life of buried pipeline after corrosion based on PSO-GRNN model[J]. Surface technology, 2019, 48(10): 267-275.
- [12] 张河苇, 金剑, 董绍华, 等. 一种基于管道大数据的腐蚀因素相关性分析方法[J]. 科学通报, 2018, 63(8): 777-783.
ZHAN He-wei, JIN Jian, DONG Shao-hua, et al. A corrosion correlation analysis method based on pipeline big data[J]. Chinese science bulletin, 2018, 63(8): 777-783.
- [13] 毕傲睿, 骆正山, 乔伟, 等. 基于主成分和粒子群优化支持向量机的管道内腐蚀预测[J]. 表面技术, 2018, 47(9): 133-140.
BI Ao-rui, LUO Zheng-shan, QIAO Wei, et al. Prediction of pipeline inner-corrosion based on principal component analysis and particle swarm optimization-support vector machine[J]. Surface technology, 2018, 47(9): 133-140.
- [14] 陈迪, 廖柯熹, 何国玺, 等. 基于 EWM-GRA 的腐蚀主控因素分析与腐蚀模型建立[J]. 表面技术, 2019, 48(6): 268-273.
CHEN Di, LIAO Ke-xi, HE Guo-xi, et al. Analysis of corrosion main influencing factors based on EWM-GRA and corrosion model establishment[J]. Surface technology, 2019, 48(6): 268-273.
- [15] 章玉婷, 杨剑锋. 基于 BP 神经网络的管道腐蚀速率预测[J]. 全面腐蚀控制, 2013, 27(9): 67-71.
ZHANG Yu-ting, YANG Jian-feng. Corrosion rate prediction of pipeline based on BP artificial neural network[J]. Total corrosion control, 2013, 27(9): 67-71.
- [16] 董绍华. 中国油气管道完整性管理 20 年回顾与发展建议[J]. 油气储运, 2020, 39(3): 241-261.
DONG Shao-hua. Review of China's oil and gas pipeline integrity management in the past 20 years and development suggestions[J]. Oil & gas storage and transportation, 2020, 39(3): 241-261.
- [17] YANG X S. Firefly algorithms for multimodal optimization[J]. Lecture notes in computer science, 2009, 5792: 169-178.
- [18] YANG, X S. Firefly algorithm, stochastic test functions and design optimisation[J]. International journal of bio inspired computation, 2010, 2(2): 78-84.
- [19] YANG X S, HE X. Firefly algorithm: recent advances and applications[J]. International journal of swarm intelligence, 2013, 1(1): 36-50.
- [20] NANDY S, SARKAR P P, DAS A. Analysis of a nature inspired firefly algorithm based back-propagation neural network training[J]. Computer science, 2012, 8(22): 207-220.
- [21] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators[J]. Neural networks, 1989, 2(5): 359-366.
- [22] HOLLAND J H. Adaptation in natural and artificial systems[M]. Ann Arbor: University of Michigan Press, 1975.
- [23] 许宏良, 殷苏民. 基于改进 BP 神经网络优化的管道腐蚀速率预测模型研究[J]. 表面技术, 2018, 47(2): 177-181.
XU Hong-liang, YIN Su-min. Prediction model of pipeline corrosion rate based on improved BP neural network[J]. Surface technology, 2018, 47(2): 177-181.
- [24] 吉根林. 遗传算法研究综述[J]. 计算机应用与软件, 2004, 21(2): 69-73.
JI Gen-lin. Survey on genetic algorithm[J]. Computer applications and software, 2004, 21(2): 69-73.
- [25] SHI Y H, EBERHART R C. A modified particle swarm optimizer[C]//Proc of the IEEE international conference on evolutionary computation. Piscataway: IEEE Service Center, 1998: 69-73.
- [26] CHATTERJEE A, SIARRY P. Nonlinear inertia weight variation for dynamic adaptation in particle swarm optimization[J]. Computers and operations research, 2006, 33(3): 859-871.
- [27] 程美英, 倪志伟, 朱旭辉. 萤火虫优化算法理论研究综述[J]. 计算机科学, 2015(4): 24-29.
CHENG Mei-ying, NI Zhi-wei, ZHU Xu-hui. Overview on glowworm swarm optimization or firefly algorithm[J]. Computer science, 2015(4): 24-29.
- [28] 杨雁莹, 徐仙伟, 曹霖. 基于仿生理论的新型优化算法综述[J]. 计算机仿真, 2016, 33(6): 233-237.
YANG Yan-ying, XU Xian-wei, CAO Ji. Overview of new optimization algorithms based on bionic theory[J]. Computer simulation, 2016, 33(6): 233-237.
- [29] 李巍华, 翁胜龙, 张绍辉. 一种萤火虫神经网络及在轴承故障诊断中的应用[J]. 机械工程学报, 2015(7): 99-106.
LI Wei-hua, WENG Sheng-long, ZHANG Shao-hui. A firefly neural network and its application in bearing fault diagnosis[J]. Journal of mechanical engineering, 2015(7): 99-106.
- [30] ROBERT M. On the derivation of a "Chaotic" encryption algorithm[J]. Cryptologia, 1989, 13(1): 29-42.
- [31] 李丹丹. 基于改进粒子群算法的混沌时间序列预测[D]. 秦皇岛: 燕山大学, 2014.
LI Dan-dan. Chaotic time series prediction based on improved particle swarm algorithm[D]. Qinhuangdao: Yanshan University, 2014.
- [32] VELAZQUEZ J C, CALEYO F, VALOR A, et al. Technical note: Field study-pitting corrosion of underground pipelines related to local soil and pipe characteristics[J]. Corrosion, 2010, 66(1): 0160011-0160015.
- [33] WANAS N, AUDA G, KAMEL M S, et al. On the optimal number of hidden nodes in a neural network[C]//Proceeding of 1998 IEEE canadian conference on electrical and computer engineering. Toronto: IEEE, 2002: 918-921.