

目 次

人工智能

基于深度学习的加油站销量预测与营销策略应用研究	卢晨辉,冯 硕,易爱华,叶晓俊(1)
基于宽度 & 深度学习的基站网络流量预测方法	陈浩杰,黄 锦,左兴权,韩 静,张百胜(7)
改进的协同训练半监督 SVM 在油层识别中的应用	潘用科,贺紫平,夏克文,牛文佳(14)
基于特征蒸馏的改进 Ghost-YOLOv5 红外目标检测算法	李北明,金荣璐,徐召飞,刘 晴,王水根(20)
改进 PSO-BPNN 算法在管道腐蚀预测中的应用	肖 斌,张恒宾,刘宏伟(27)
基于 YOLOv3 和注意力机制的野外蝴蝶种类识别	周文进,李 凡,薛 峰(34)
一种基于自适应信息素蒸发系数的 WSN 蚁群路由算法	王 恭,孙铭阳,孙汇阳,滕子铭(41)

机械工程

基于立方型转矩分配函数的 SRM 直接转矩控制	白国长,吴贺松,郑 鹏(48)
对称 Y 型分岔微通道微滴分裂数值模拟与实验探究	郑艳萍,张瑞根,梁 帅,李 洋,徐 刚,舒海涛(55)
弯曲气动肌肉驱动手腕康复装置的设计与研究	韩坤峰,刘艳红,毛晓波,张季冬,王 葳,逯 鹏(62)

土木工程

基于熵权法-云模型的石拱桥技术状况评定	张 鹏,钟 山,朱 锐,焦美菊(69)
隧道 Park 收敛模式正交下穿既有隧道影响分析	靳军伟,付柏毅,陈允斌,刘钢立,李明宇(76)
再生混凝土抗氯离子渗透的五相细观数值模拟	金立兵,余化龙,王振清,薛鹏飞,吴 强(83)

网络安全及其他

基于非零和信号博弈的主动防御模型	黄万伟,袁 博,王苏南,张校辉(90)
LCL 型并网逆变器电流谐波抑制策略研究	刘海洋,董亮辉,高金峰,王要强,黄文剑(97)
基于区块链的车联网安全信息共享机制设计	李永强,刘兆伟(103)

文章编号:1671-6833(2022)01-0027-07

改进 PSO-BPNN 算法在管道腐蚀预测中的应用

肖斌, 张恒宾, 刘宏伟

(西南石油大学 计算机科学学院, 四川 成都 610500)

摘要: 输油管道由于埋藏环境、运输介质等影响,随着使用年限增加,管道会逐渐出现腐蚀,常规的腐蚀管道剩余强度计算方法有公式计算和有限元分析(FEA)等。针对常规方法中公式计算准确性较低和有限元分析过于复杂的问题,提出了一种改进的粒子群算法优化的神经网络模型(IPSO-BPNN)来预测腐蚀管道剩余强度。首先,在传统粒子群算法的基础上,提出了一种新的非线性递减惯性权重用于快速更新粒子速度和位置,并引入了遗传交叉算子增加粒子的多样性,形成了改进的粒子群算法(IPSO);其次,采用 IPSO 算法对神经网络的权重和阈值进行优化,并使用优化后的权重和阈值初始化神经网络,建立了 IPSO-BPNN 模型;最后,在 2 个真实的管道测试爆破数据集上进行实验,分别使用线性回归(LR)、FEA、前馈神经网络(BPNN)、粒子群算法前馈神经网络(PSO-BPNN)以及 IPSO-BPNN 模型对腐蚀管道剩余强度进行预测,使用平均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)作为评估模型预测性的指标。在 2 个数据集的测试集上的结果表明:IPSO-BPNN 模型的 MAE 分别为 0.525 4、0.718 5,MAPE 分别为 3.77%、2.68%,RMSE 分别为 0.672 6、0.947 2,3 项指标较 LR、FEA、BPNN 和 PSO-BPNN 有明显提升。改进 PSO-BPNN 算法可以提高腐蚀管道剩余强度预测的准确性,可以为管道检查提供较为准确的依据。

关键词: 粒子群优化算法;非线性递减惯性权重;神经网络;腐蚀管道;剩余强度

中图分类号: TE973.6; TP183 **文献标志码:** A **doi:**10.13705/j.issn.1671-6833.2022.01.008

0 引言

管道输送在石油和天然气的运输中起着重要的作用,但随着管道服役时间的增长,管道会出现不同程度的腐蚀缺陷,在腐蚀严重的情况下,会引起管道泄漏或爆炸,不仅影响油气管道正常运输,甚至会危害人民生命财产安全和生态环境。因此,研究腐蚀管道的剩余强度具有重要意义。

目前,许多专家已经采用实验、数值分析或经验方法对腐蚀管道的剩余强度进行了深入研究。Abdalla 等^[1]分析了孤立点腐蚀缺陷的应力分布;Wang 等^[2]考虑管道几何形状等因素分析了管道强度极限状态;臧雪瑞等^[3]分析了 X100 等级输气管道的失效压力模型。通过相关研究结果可以发现,腐蚀管道剩余强度预测的最常用方法是公式计算和有限元分析。但是公式计算方法的准确率较低,且无法适用于所有管道,而有限元分析过程又较为复杂^[4],比如常规的有限分析过程包括

确定边界条件,建立模型,设计变量、公式和求解方程,整个过程需要进行大量假设,并且需要耗费大量时间。

近年来,由人工神经网络建立的非线性映射关系预测模型受到众多学者的关注,三层的神经网络理论上可以拟合任意的非线性函数,相比起有限元分析和回归模型可以更加精确地拟合实验数据,实现更高质量的预测,具有非常广阔的应用前景。但传统的神经网络仍然存在容易陷入局部最优等问题,而启发式搜索算法不要求目标函数连续、可微等信息,具有较好的全局寻优能力^[5],所以启发式搜索算法可对神经网络参数进行初始化。

本文提出了一种新的非线性递减惯性权重粒子群算法,以解决其存在的局部最优和易早熟问题;然后使用改进的粒子群算法对神经网络的初始权重和阈值进行优化,以解决神经网络本身的局限性,从而建立了预测模型;最后使用模型在 2

收稿日期:2021-05-15;修订日期:2021-08-27

基金项目:国家自然科学基金资助项目(62006200)

作者简介:肖斌(1978—),男,四川成都人,西南石油大学副教授,主要从事数据挖掘研究,E-mail:xiaobin@swpu.edu.cn。

个真实的管道爆破数据集上进行实验,结果表明,相比其他模型,所提算法可以更准确地预测腐蚀管道的剩余强度。

1 相关工作

粒子群优化算法(PSO)是一种群体智能优化算法^[6],粒子群优化算法的数学描述如下。

假设在一个 D 维的目标搜索空间中,有 m 个代表问题潜在解的粒子组成一个种群。第 i 个粒子的位置记为 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{iD}]^T$,其速度记为 $\mathbf{V}_i = [v_{i1}, v_{i2}, \dots, v_{iD}]^T$ 。首先随机初始化 m 个粒子,然后迭代找到最优解。每一次迭代中,粒子通过跟踪 2 个极值 $\mathbf{P}_i = [p_{i1}, p_{i2}, \dots, p_{iD}]^T$ 、 $\mathbf{P}_g = [p_{g1}, p_{g2}, \dots, p_{gD}]^T$ 进行信息交流。即根据式(1)和式(2)更新自己的速度和位置:

$$\mathbf{V}_i^{t+1} = \mathbf{V}_i^t + c_1 r_1 (\mathbf{P}_i^t - \mathbf{X}_i^t) + c_2 r_2 (\mathbf{P}_g^t - \mathbf{X}_i^t); \quad (1)$$

$$\mathbf{X}_i^{t+1} = \mathbf{X}_i^t + \mathbf{V}_i^{t+1}. \quad (2)$$

式中: t 为当前迭代次数; c_1 、 c_2 为学习因子; r_1 、 r_2 为 $[0, 1]$ 的随机数; \mathbf{V}_i^t 为第 t 次迭代时粒子 i 的速度; \mathbf{X}_i^t 为第 t 次迭代时粒子 i 的位置; \mathbf{P}_i^t 为到第 t 次迭代时粒子 i 自身经历的最优值; \mathbf{P}_g^t 为到第 t 次迭代时整个种群的最优值。

为了提高原始粒子群算法的收敛性能, Shi 等^[7]提出了一种改进的粒子群算法:在速度更新过程中引入惯性权重,新的速度迭代式如下所示: $\mathbf{V}_i^{t+1} = w \mathbf{V}_i^t + c_1 r_1 (\mathbf{P}_i^t - \mathbf{X}_i^t) + c_2 r_2 (\mathbf{P}_g^t - \mathbf{X}_i^t)$ 。(3) 式中: w 为惯性权重,决定了粒子当前速度对下次迭代时速度的影响。

多年来,文献中报道了自适应惯性权重^[8]、随机惯性权重^[9]、线性减少惯性权重^[10]、非线性减少惯性权重^[11]等多种权重变化策略。

交叉主要用于遗传算法中增加后代种群多样性,随着研究深入,已有很多学者将交叉思想引入粒子群算法来增加粒子的多样性^[12]。

2 神经网络优化预测模型

2.1 改进的粒子群算法

在标准粒子群优化算法中,惯性权重为固定值,后来发现动态变化的惯性权重寻优结果比固定值好。在许多研究中,通常选择线性递减惯性权重^[7],其算法如式(4)所示:

$$w = w_{\max} - (w_{\max} - w_{\min}) \frac{t}{t_{\max}}. \quad (4)$$

式中: t 为当前迭代次数; t_{\max} 为粒子的最大迭代

次数; w_{\max} 为惯性权重的最大值, w_{\min} 为惯性权重的最小值,通常取值为 $w_{\max} = 0.9$, $w_{\min} = 0.4$ 。

为了更好地保持全局和局部搜索能力之间的平衡, Saxena 等^[13]提出了一种非线性递减惯性权重,但是使用时惯性权重会长时间保持在 0.7,从而使粒子丧失局部寻优能力。本文在文献[13]的基础上提出了一种新的非线性递减惯性权重,如式(5)、(6)所示:

$$\Delta = (w_{\text{start}})^2 - (w_{\text{end}})^2. \quad (5)$$

$$w =$$

$$\begin{cases} (w_{\max} - w_{\min}) \left[1 - \Delta \left(\frac{t}{t_{\max}} \right)^5 \right]^{\frac{1}{2}}, & 0 < t < 0.4t_{\max}; \\ w_{\max} \left[1 - \Delta \left(\frac{t}{t_{\max}} \right)^{\frac{1}{2}} \right]^2, & 0.4t_{\max} \leq t \leq t_{\max}. \end{cases} \quad (6)$$

式中: w_{start} 为惯性权重的迭代的初始值, w_{end} 为惯性权重的迭代的结束值,通常取值为 $w_{\text{start}} = 0.7$, $w_{\text{end}} = 0.4$ 。

该权重在迭代的前期能快速下降,使得粒子能够快速拉近与最低点之间的距离,同时避免陷入局部最优解,在后期下降较为缓慢从而得到最优解。如图 1 所示,权重的递减速度在迭代过程中呈现出先快后慢的非线性模式。




图 1 非惯性权重值下降曲线

Figure 1 Non-linear inertia weight value decreasing curve

同时,基于引入的交叉思想^[12],在每次迭代中,根据杂交概率选择一定数量的粒子,放入杂交池中,然后池中的粒子成对随机交叉生成相同数量的后代粒子,最后使用子粒子替换父粒子以增强粒子多样性。子粒子的位置和速度通过父粒子的位置和速度交叉获得。位置交叉公式如下:

$$\mathbf{q}_x = \lambda \mathbf{p}_x^{(1)} + (1 - \lambda) \mathbf{p}_x^{(2)}. \quad (7)$$

式中: \mathbf{p}_x 为父粒子的位置; \mathbf{q}_x 为子粒子的位置; λ

为 0 到 1 之间的随机数。

子粒子的速度计算式如下：

$$\boldsymbol{q}_v = \frac{\boldsymbol{p}_v^{(1)} + \boldsymbol{p}_v^{(2)}}{\left| \boldsymbol{p}_v^{(1)} + \boldsymbol{p}_v^{(2)} \right|} \left| \boldsymbol{p}_v \right|。$$

(8)

式中： \boldsymbol{p}_v 为父粒子速度； \boldsymbol{q}_v 为子粒子速度。

2.2 IPSO-BPNN 算法

针对神经网络收敛缓慢且容易陷入局部最优问题,本文使用改进的 PSO 算法 (IPSO) 对神经网络进行优化,提高神经网络寻找全局最优解的能力。IPSO-BPNN 算法步骤如下。

Step 1 建立 3 层网络拓扑结构,确定输入层、隐藏层和输出层的节点个数。

Step 2 初始化粒子群参数。

Step 3 进行 IPSO 算法训练,计算每个粒子适应度值,根据式 (3)、(2) 更新粒子的速度和位置,根据式 (6) 更新粒子权重,更新 \boldsymbol{P}_i 和 \boldsymbol{P}_g 。

Step 4 进行交叉。根据杂交的概率选择一定数量的颗粒进行杂交,根据式 (7) 和 (8) 计算子粒子的位置和速度。

Step 5 重复 Step 3 和 Step 4,直到算法误差满足要求或训练次数达到最大迭代次数。

Step 6 使用 Step 5 得到的全局最优值优化神经网络的初始权重和阈值。训练神经网络,输出网络的预测值,计算网络误差,将误差传播回输出层并调整权重和阈值。重复上述过程,直到满足算法的终止条件或达到最大迭代次数为止。

2.3 时间复杂度对比

在 IPSO 算法中,对于 n 个样本,使用两层循环寻优,第 1 层循环为最大迭代次数 j ,第 2 层循环为种群粒子数 k ,由于 k 和 j 都是常量,因此得到粒子群算法的时间复杂度为 $O(1)$ 。而对于一个 l 层的全连接神经网络,如果在输出层通过激活函数输出最后结果,则 P 轮训练进行了 $2(l-1)mn$

次计算,由于 l 和 m 为常量,因此整个算法的时间复杂度可以近似为 $O(n)$ 。

在有限元分析中重要的步骤是联立方程组求解,其主要方法包括 Gauss 消元法、共轭梯度法等。Gauss 消元法的时间复杂度为 $O(n^3)$,共轭梯度法和其他迭代法的时间复杂度为 $O(n^2)$ 。而且在实际应用中,FEA 方法通常还需要花费大量的时间来建模,此步骤花费的时间通常多于求解计算的时间。因此 IPSO-BPNN 算法能有效提高预测效率,节省时间。

3 实验与分析

3.1 IPSO 算法对比实验

实验选择了如表 1 所示的 4 个基准函数作为测试函数。其中 F1, F2 是单峰函数编号,只有一个最优值, F3 和 F4 则是多峰函数编号,具有多个局部最优值。同时,还对 IPSO 算法与标准粒子群算法 (PSO)、线性递减惯性权重粒子群算法 (LPSO)、自适应权重粒子群算法 (APSO) 和随机权重粒子群算法 (RPSO) [14] 进行了对比分析。

3.1.1 实验设置

为了对 5 种使用不同权重策略的粒子群算法进行公正和客观的比较,惯性权重的最小值和最大值分别设为 0.4 和 0.9,算法最大迭代次数设为 1 000,学习因子 c_1 和 c_2 的取值均为 2,粒子种群规模大小为 40,交叉池大小比例为 0.1,交叉概率为 0.8,对每个基准函数进行了 30 次重复实验,并记录了实验过程中的最优值、平均值用于评估算法的优化精度,使用标准差 (SD) 评估优化稳定性。

3.1.2 结果分析

仿真结果如表 2 所示。从表 2 中可以看出,IPSO 在前 2 个测试函数中的平均值、标准差优于 PSO、LPSO、APSO 和 RPSO,而在后 2 个函数中也表现出了较好的效果。

表 1 4 个基准测试函数
Table 1 Four benchmark test functions

函数编号	名称	表达式	取值	维度
F1	Sphere	$\min f(x) = \sum_{i=1}^D x_i^2$	$[-100, 100]$	10 和 30
F2	Rosenbrock	$\min f(x) = \sum_{i=1}^D [100 (x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$[-10, 10]$	10 和 30
F3	Ackley	$\min f(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2} \right) - \exp \left(\frac{1}{D} \sum_{i=1}^D \cos 2\pi x_i \right) + 20 + e$	$[-32, 32]$	10 和 30
F4	Griewank	$\min f(x) = \frac{1}{4\,000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos \frac{x_i}{\sqrt{i}} + 1$	$[-600, 600]$	10 和 30

图 2 是 5 种算法对 30 维的 4 个测试函数的平均适应度曲线,纵轴为每一次迭代中适应度函数值的平均值,横轴为迭代次数,因为函数值波动较大,对函数的适应度值取对数^[15]。从图 2 中可

表 2 4 种算法仿真结果

Table 2 Simulation results of five algorithms

函数	算法	最优值		平均值		标准差	
		10 维	30 维	10 维	30 维	10 维	30 维
Sphere	PSO	0. 018 478	6. 990 167	0. 073 771	13. 014 24	0. 042 782	5. 180 994
	LPSO	6. 41E-05	5. 696 458	0. 144 626	204. 126 4	0. 350 239	114. 521 6
	APSO	0. 000 285	33. 137 06	0. 017 199	75. 688 33	0. 024 996	31. 325 95
	RPSO	1. 18E-18	3. 513 912	7. 95E-06	11. 903 11	3. 04E-05	6. 873 913
	IPSO	4. 75E-15	0. 545 052	3. 68E-09	1. 960 469	9. 22E-09	0. 935 945
Rosenbrock	PSO	0. 758 358	44. 038 63	6. 984 691	101. 227	2. 683 208	40. 614 16
	LPSO	4. 123 622	46. 605 09	7. 975 662	274. 387	1. 582 365	152. 319 8
	APSO	2. 554 999	91. 612 42	6. 955 081	205. 460 5	2. 019 491	79. 555 54
	RPSO	0. 010 707	33. 178 54	3. 034 056	74. 861 03	2. 011 781	44. 792 79
	IPSO	7. 67E-08	26. 963 86	0. 832 613	45. 868 63	1. 569 411	27. 075 83
Ackley	PSO	0. 061 429	2. 134 473	0. 272 524	2. 788 05	0. 341 00	0. 418 426
	LPSO	0. 012 163	5. 652 594	2. 182 753	6. 513 758	1. 235 00	0. 444 341
	APSO	0. 003 774	3. 148 742	1. 346 02	4. 447 982	0. 740 011	0. 746 712
	RPSO	1. 00E-08	3. 765 844	1. 794 006	5. 548 936	0. 954 170	1. 030 509
	IPSO	2. 26E-07	0. 931 227	0. 208 927	2. 603 313	0. 473 920	0. 655 174
Griewank	PSO	0. 210 821	1. 047 799	0. 475 176	1. 115 343	0. 169 468	0. 038 914
	LPSO	0. 041 852	1. 258 772	0. 236 686	2. 946 855	0. 140 712	1. 036 665
	APSO	0. 054 27	1. 211 187	0. 221 286	1. 620 376	0. 120 452	0. 283 052
	RPSO	0. 007 396	1. 047 08	0. 179 603	1. 112 132	0. 107 452	0. 043 762
	IPSO	0. 022 128	0. 399 075	0. 111 306	0. 849 327	0. 078 020	0. 149 696

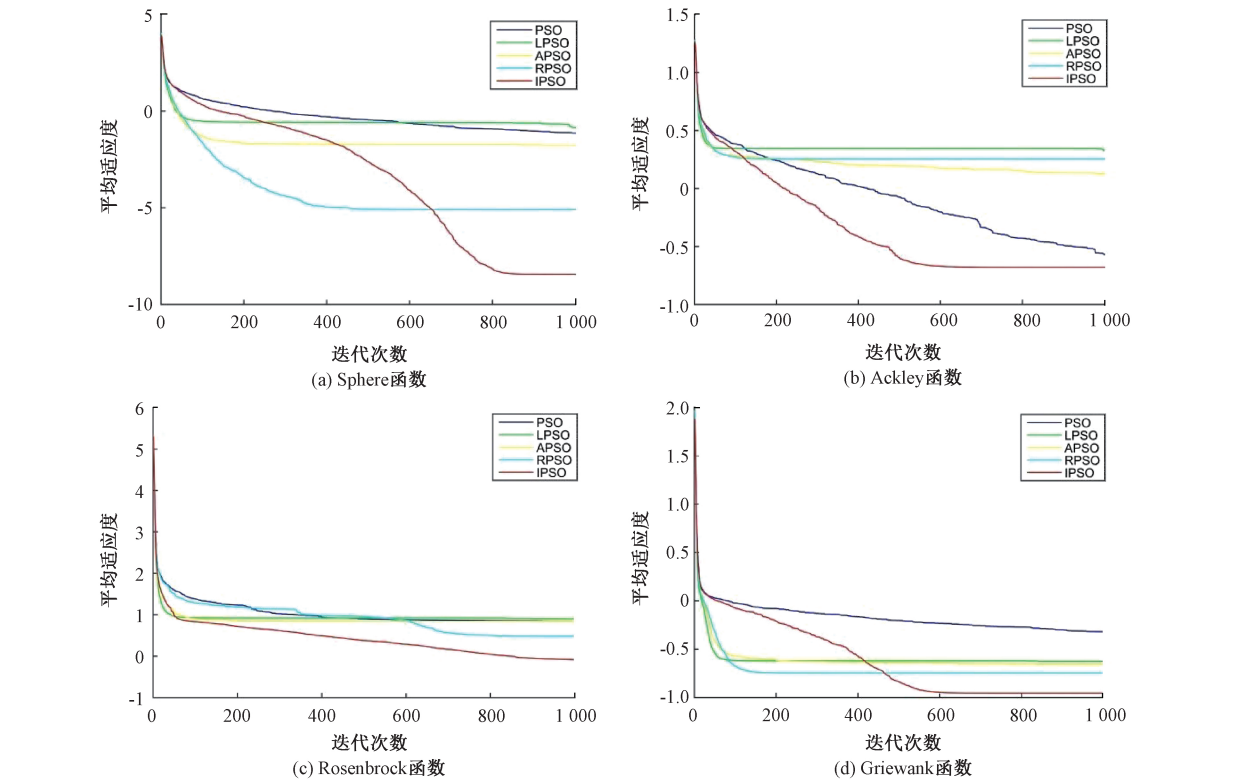


图 2 5 种算法在 4 个测试函数上的平均适应度曲线 (30 维)

Figure 2 Average fitness curve of five algorithms for four test functions (30D)

以看出,相比其他几种算法,IPSO 具有更快的收敛速度和更好的平均适应度,表明该算法有更好的鲁棒性和适用性。

3.2 IPSO-BPNN 预测腐蚀管道剩余强度实验

3.2.1 数据来源

为了验证本文提出的 IPSO-BPNN 模型的预测性能,从文献[16-21]中收集了 161 组真实管道爆破数据用于管道剩余强度预测。数据集 1 有 79 组数据,其中 66 组数据参与训练,13 组数据用于验证;数据集 2 有 82 组数据,其中 66 组数据参与训练,16 组数据用于验证。本文选择了 5 个因素作为输入变量,分别为管线钢级(取值 X42~X100,包含了常用的高等级管线的主要钢级)、管道直径(取值 323~1 320 mm)、管道壁厚(取值 4.67~22.9 mm)、缺陷深度(取值 0~15 mm)、缺陷长度(取值 0~1 110 mm)。爆破压力是输出变量,单位为 MPa。

3.2.2 数据预处理

首先对数据里的非数值数据如管线钢级进行处理,转换成数值类型。由于数据集中的 5 个变量分别对应于不同的纲度和数量范围,有必要对数据进行规范化处理。这里采用归一化操作,归一化表示如式(9)所示:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}。 \tag{9}$$

3.2.3 评估标准

评估该模型预测性能的指标是平均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)^[22],其定义为

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)|; \tag{10}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i^r - y_i^p)^2}; \tag{11}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i^r - y_i^p|}{y_i^r} \times 100\%。 \tag{12}$$

式中: y_i^r 为第 i 个样本的真实值; y_i^p 为第 i 个样

本的预测值; n 为样本数量。

3.2.4 参数设置

本文选择 3 层神经网络,包括 5 个输入层节点和 1 个输出层节点。隐藏层中的节点数根据式(13)为 3~13 个:

$$n_{\text{hid}} = \sqrt{n_{\text{in}} + n_{\text{out}}} + \alpha。 \tag{13}$$

式中: n_{in} 为输入层节点的个数; n_{out} 为输出层节点的个数; α 为 0~10 的常数。

根据计算得到的节点范围进行测试,选择均方根误差最小的节点数作为隐藏层节点的最终数目。由图 3 可知,当隐藏层中的节点数为 9 时,神经网络预测的均方根误差最小。




图 3 均方根误差与隐藏层节点之间的关系

Figure 3 Relationship between root mean square error and hidden layer notes

IPSO 参数设置:种群大小为 40,粒子维度为 64,学习因子 c_1 和 c_2 均为 2;惯性权重的最小值和最大值分别为 0.4 和 0.9;粒子速度值为 $[-1,1]$;粒子位置值为 $[-4,4]$;杂交池的大小比为 0.1,杂交的概率为 0.8。

3.2.5 结果分析

为了更好地对比和评价模型的准确性,将 IPSO-BPNN 与线性回归(LR)、有限元分析(FEA)、前馈神经网络(BPNN)和粒子群算法优化神经网络(PSO-BPNN)在 2 个数据集上的预测结果进行了对比,各项指标如表 3 所示,预测结果的相对误差对比如图 4 所示。

表 3 5 种模型测试结果

Table 3 Test result of five models

数据集 1 ^[16] (共 79 组数据)				数据集 2 ^[17-21] (共 82 组数据)			
模型	MAE	MAPE/%	RMSE	模型	MAE	MAPE/%	RMSE
LR	1.969 9	14.59	2.419 9	LR	3.900 8	42.90	5.611 5
FEA	1.911 5	14.41	2.434 2	FEA	0.986 1	3.12	1.117 4
BPNN	1.070 0	8.51	1.284 1	BPNN	1.331 7	4.93	1.361 3
PSO-BPNN	0.639 2	4.83	0.803 8	PSO-BPNN	0.828 2	2.78	0.978 8
IPSO-BPNN	0.525 4	3.77	0.672 6	IPSO-BPNN	0.718 5	2.68	0.947 2

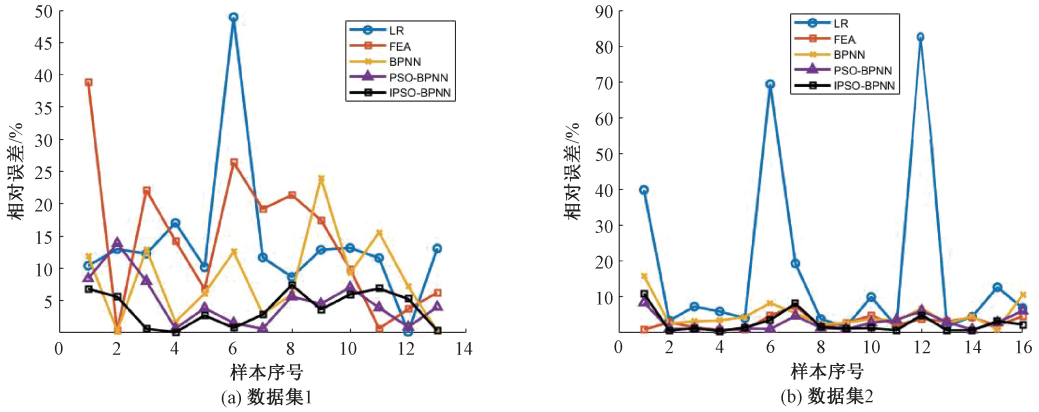


图 4 数据集相对误差变化曲线

Figure 4 Relative error curve of the dataset

从表 3 可以看出,在 2 个数据集中,本文提出的 IPSO-BPNN 预测模型的各项指标均优于其他对比模型,显示出了更高的准确性。从图 4 可以看出,IPSO-BPNN 在测试集中的相对误差都保持在 10% 以内,表明该模型对数据的整体拟合效果较好,显示出了较高的稳定性。

4 结论

传统的神经网络在预测腐蚀管道的剩余强度时波动很大,很容易陷入局部最优状态。本文使用 PSO-BPNN 算法来预测腐蚀管道的残余强度,通过非线性递减惯性权重和杂交增加粒子的多样性,克服了神经网络容易陷入局部最优的缺点。与 LR、FEA、BPNN 和 PSO-BPNN 模型相比,IPSO-BPNN 模型可以提高腐蚀管道残余强度的预测精度。所提算法适用于各个钢级的单腐蚀输油管线的剩余强度预测,可以为管道检查提供较为准确的依据。本文只考虑了单一腐蚀缺陷管道的剩余强度情况,下一步的研究重点是对复合型腐蚀缺陷管道进行分析和评价。

参考文献:

[1] ABDALLA F J E, MACHADO R D, BERTIN R J, et al. On the failure pressure of pipelines containing wall reduction and isolated pit corrosion defects [J]. Computers & structures, 2014, 132: 22-33.

[2] WANG N Y, ZARGHAMEE M S. Evaluating fitness-for-service of corroded metal pipelines: structural reliability bases [J]. Journal of pipeline systems engineering and practice, 2014, 5(1): 04013012.

[3] 臧雪瑞, 顾晓婷, 王秋妍, 等. 含腐蚀缺陷高钢级输气管道的失效压力模型 [J]. 油气储运, 2019, 38(3): 285-290, 296.

[4] 马钢, 李俊飞, 白瑞, 等. 基于 PCA-SVR 模型的油气管道剩余强度预测 [J]. 油气储运, 2019, 38(10): 1119-1124.

[5] 梁静, 刘睿, 瞿博阳, 等. 进化算法在大规模优化问题中的应用综述 [J]. 郑州大学学报(工学版), 2018, 39(3): 15-21.

[6] KENNEDY J, EBERHART R. Particle swarm optimization [C]//Proceedings of ICNN' 95-International Conference on Neural Networks. Piscataway: IEEE, 1995: 1942-1948.

[7] SHI Y, EBERHART R. A modified particle swarm optimizer [C]//1998 IEEE International Conference on Evolutionary Computation Proceedings. Piscataway: IEEE, 1998: 69-73.

[8] SHI Y B. Optimization of PID parameters of hydroelectric generator based on adaptive inertia weight PSO [C]//2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). Piscataway: IEEE, 2019: 1854-1857.

[9] LIANG M Y, CAI X H, CAO B Y. Random inertia weight PSO based MPPT for solar PV under partial shaded condition [J]. IOP conference series: earth and environmental science, 2020, 585: 012028.

[10] NKWANYANA T B, WANG Z H. Improved particle swarm optimization base on the combination of linear decreasing and chaotic inertia weights [C]//2020 12th International Conference on Computational Intelligence and Communication Networks (CICN). Piscataway: IEEE, 2020: 460-465.

[11] CHANG J, HU Z G, TAO Y, et al. Task scheduling based on dynamic non-linear PSO in cloud environment [C]//2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS). Piscataway: IEEE, 2018: 877-880.

[12] 丁承君, 王鑫, 冯玉伯, 等. 基于粒子群优化算法的

- AGV 路径规划[J].传感器与微系统,2020,39(8):123-126.
- [13] SAXENA S,POHIT M.A new non linear inertia weight approach in PSO for faster rigid image registration [C]//2019 6th International Conference on Signal Processing and Integrated Networks (SPIN). Piscataway:IEEE,2019:607-612.
- [14] 高飞.MATLAB 智能算法超级学习手册[M].北京:人民邮电出版社,2014:259-260.
- [15] YUAN X F,LIU Z A,MIAO Z M,et al.Fault diagnosis of analog circuits based on IH-PSO optimized support vector machine [J]. IEEE access, 2019, 7: 137945-137958.
- [16] MA B,SHUAI J,LIU D X,et al.Assessment on failure pressure of high strength pipeline with corrosion defects [J].Engineering failure analysis,2013,32:209-219.
- [17] 崔铭伟,曹学文.腐蚀缺陷对中高强度油气管道失效压力的影响[J].石油学报,2012,33(6):1086-1092.
- [18] 武琳,方清,粟紫葳,等.中高强度压力管道腐蚀缺陷剩余强度评估方法的对比研究[J].内蒙古石油化工,2014,40(23):10-11.
- [19] FREIRE J L F,VIEIRA R D,CASTRO J T P,et al. Part 3: burst tests of pipeline with extensive longitudinal metal loss [J]. Experimental techniques, 2006,30(6):60-65.
- [20] 王战辉,马向荣,李瑞瑞.高钢级油气管道剩余强度评价方法研究[J].当代化工,2019,48(8):1853-1857.
- [21] 杨燕华,顾晓婷,张旭,等.高级 X100 输气管道含双点腐蚀缺陷的剩余强度研究[J].腐蚀与防护,2021,42(4):48-53.
- [22] 贾俊平.统计学概论[M].北京:中国人民大学出版社,2011.

Application of Improved PSO-BPNN Algorithm in Corroded Pipelines Prediction

XIAO Bin, ZHANG Hengbin, LIU Hongwei

(School of Computer Science, Southwest Petroleum University, Chengdu 610500, China)

Abstract: Due to the impact of buried environment and medium transported, oil pipelines will be gradually corroded with the increasing of service life. Traditional methods for calculating the residual strength of corroded pipelines included formula calculation and finite element analysis, etc. Aiming at the problems of low calculation accuracy of formulas and too complicated finite element analysis (FEA) in the prediction of the residual strength of corroded pipelines, an improved particle swarm optimization neural network model (IPSO-BPNN) was proposed to predict the residual strength of corroded pipelines. Firstly, based on the traditional particle swarm optimization, a new nonlinear decreasing inertia weight was proposed to update the velocity and location of elements quickly, and the genetic crossover operator was introduced to increase the diversity of particles, then form an improved particle swarm optimization algorithm (IPSO). Secondly, the IPSO algorithm was used to optimize the weights and thresholds of the neural network, and initialize the neural network with optimized weights and thresholds to establish the IPSO-BPNN model. Finally, the linear regression(LR),FEA, back-propagation neural network (BPNN), particle swarm optimization back-propagation neural network (PSO-BPNN) and IPSO-BPNN model were experimented on real pipelines test blasting data sets to predict the residual strength of the corroded pipelines. *MAE*, *RMSE* and *MAPE* were used as indicators to evaluate the predictability of the models. The results on the test set of two data sets showed that the *MAE* of the IPSO-BPNN model was 0.525 4, 0.718 5; the *MAPE* was 3.77%, 2.68%; the *RMSE* was 0.672 6, 0.947 2, respectively. The three indicators were significantly improved compared to LR, FEA, BPNN and PSO-BPNN. It showed that this method could improve the accuracy of predicting the residual strength of corroded pipelines, and could provide a more accurate basis for pipeline inspection.

Keywords: particle swarm optimization; nonlinear decreasing inertia weight; neural network; corroded pipelines; residual strength