

屈新东, 朱绍柯, 潘叶, 等. 基于改进极限学习机的通信网络故障诊断[J]. 智能计算机与应用, 2024, 14(9): 131-135. DOI: 10.20169/j.issn.2095-2163.240920

基于改进极限学习机的通信网络故障诊断

屈新东, 朱绍柯, 潘叶, 张郭

(中国移动通信集团广东有限公司, 广州 510000)

摘要: 为了提高通信网络故障诊断精度, 提出了一种基于改进极限学习机的通信网络故障诊断方法。采用 CS 算法对 ELM 进行优化, 建立了基于 CS-ELM 的通信网络故障诊断模型。采用通信网络故障数据进行仿真分析, 并与其他模型进行了对比分析。结果表明, CS-ELM 模型在对测试集进行诊断时的正确率高达 98.57%, 诊断精度高于其他几种对比模型, 验证了所提通信网络故障诊断方法的正确性。

关键词: 通信网络; 故障诊断; 极限学习机; 布谷鸟搜索算法

中图分类号: TP181

文献标志码: A

文章编号: 2095-2163(2024)09-0131-05

Communication network fault diagnosis based on improved extreme learning machine

QU Xindong, ZHU Shaoke, PAN Ye, ZHANG Guo

(China Mobile Communications Group Guangdong Co., LTD, Guangzhou 510000, China)

Abstract: In order to improve the accuracy of communication network fault diagnosis, a communication network fault diagnosis method based on an improved extreme learning machine is proposed. We optimized ELM using CS algorithm and established a communication network fault diagnosis model based on CS-ELM. Using communication network fault data for simulation analysis and comparing it with other models, the results show that the CS-ELM model has a high accuracy rate of 98.57% in diagnosing the test set, with higher diagnostic accuracy than other comparative models, verifying the correctness of the proposed communication network fault diagnosis method.

Key words: communication network; fault diagnosis; extreme learning machine; cuckoo search algorithm

0 引言

随着移动通信技术的发展, 未来通信网络将不再使用单一技术, 而是朝着多种技术融合的方向发展^[1]。在网络结构日趋复杂的背景下, 如何实现通信网络的快速诊断和提高通信网络故障诊断准确率是目前亟待解决的问题。因此, 对通信网络故障诊断方法进行研究具有十分重要的现实意义。

为了实现通信网络故障的准确诊断, 专家学者们进行了大量研究。如: 文献[2]为了解决电力通信网络故障诊断过程中的噪声问题, 利用卷积模块对故障信息的多尺度特征进行了提取, 在此基础上提出了一种基于卷积神经网络的电力通信网络故障诊断方法, 并在诊断过程中引入了注意力机制, 以提高诊断结果的准确性, 采用实际故障数据进行仿真分析。结果表明, 该方法的抗噪声效果消耗, 诊断结

果的准确性和稳定性均较高。文献[3]首先对通信网络数据进行了筛选, 然后采用 BP 神经网络对故障特征进行了提取, 最后建立了基于 BP 神经网络的移动通信网络故障诊断模型。算例分析结果表明, 该模型既能缩短移动通信网络的故障诊断时间, 也能够提高其诊断精度。文献[4]对卷积神经网络的激活函数进行了改进, 使其稀疏性和光滑性更好, 并利用小波神经网络得到了告警信号对电力通信网故障类型的影响权重, 提出了一种基于改进卷积神经网络的通信网络故障诊断方法, 将该方法的诊断效果与卷积神经网络和贝叶斯算法进行对比, 验证了所提通信网络故障诊断方法的有效性, 该方法为通信网络故障诊断研究提供了新思路。

本文采用布谷鸟搜索 (Cuckoo Search, CS) 算法对极限学习机 (Extreme Learning Machine, ELM) 进行优化, 解决了极限学习机参数选择盲目性问题, 在

此基础上建立了基于CS算法优化ELM的通信网络故障诊断模型,通过算例分析对所提通信网络故障诊断模型的实用性进行验证。

1 布谷鸟搜索算法

2009年,英国学者YANG X S等^[5]在对布谷鸟繁殖行为研究的基础上提出了CS算法。同大多数优化算法一样,CS算法也是一种基于群体的智能算法,由于CS算法具有良好的优化性能,目前在通信、航天和医疗等领域得到了广泛应用。

1.1 CS算法机理介绍

布谷鸟通过寄生行为繁殖产生下一代,并在产卵过程中遵循莱维飞行搜索机制,因此CS算法的基本机理是布谷鸟的借窝产卵行为和莱维飞行轨迹^[6-8]。

1) 布谷鸟借窝产卵行为

布谷鸟是一种非常聪明的鸟类,借窝产卵是其特有的繁殖方式。当繁殖期到来时,布谷鸟四处寻找其他鸟类的鸟窝(宿主鸟),进行借窝繁殖。其在宿主鸟的鸟窝里面下蛋,宿主鸟以为是自己的鸟蛋,就会代为孵化。当然不是所有的鸟类都会帮助布谷鸟孵化后代,有的宿主鸟发现鸟窝的蛋不是自己的,就会将布谷鸟的鸟蛋丢弃。为了提高后代的孵化率,布谷鸟选择宿主鸟时尽量选择鸟蛋颜色相同的鸟类作为宿主鸟,并且选择与宿主鸟相同的时间产卵,另外布谷鸟鸟蛋在短期内即可完成孵化,得到布谷鸟幼鸟。这些幼鸟非常聪明,会将宿主鸟的鸟蛋踢出去,以提高自身存活率。因此布谷鸟虽然不自己做窝哺育幼鸟,凭借这一行为也能不断繁衍后代。

2) 莱维飞行

20世纪中叶,法国学者莱维根据自然界中的随机分布行为提出了一种新型飞行轨迹,被命名为莱维飞行。莱维飞行的特点是飞行轨迹满足莱维分布,该飞行轨迹的提出很好地解释了自然界中一些随机现象,莱维飞行轨迹示意如图1所示。




图1 二维平面的莱维飞行示意图

Fig. 1 Schematic diagram of Levy flight in a two-dimensional plane

莱维飞行轨迹的特点是大小步长相结合,且小步出现的频率更高。基于上述特点,优化算法中引入莱维飞行轨迹后,能够很好地增加种群多样性,扩大搜索范围,提高其搜索性能,从而避免算法陷入局部最优。

1.2 CS算法基本原理

CS算法在使用过程中,应满足下列条件:

(1) 布谷鸟在产卵时,单只布谷鸟个体只能产生一枚鸟蛋,该鸟蛋以随机方式选择其宿主鸟的鸟窝进行孵化;

(2) 孵化过程中,满足精英进化策略,即选择适应度值最优的鸟巢下一代;

(3) 鸟窝的数量保持不变,但由于布谷鸟属于寄生繁殖,宿主鸟如果发现鸟蛋不是自己生产的,将会放弃该鸟窝,此时布谷鸟只能寻找新的鸟窝。若令发现概率为 $p_a \in [0, 1]$,可见 p_a 的值越大,鸟窝被放弃的可能性就越大。

与其他寻优算法的实施过程一样,CS算法首先需要产生初始鸟窝种群,然后根据鸟窝位置的更新公式更新鸟窝位置,产生新的鸟窝种群;再根据算法终止迭代的条件判断迭代是否继续;最后获得全局最优解,即最优鸟窝的位置^[9-10]。

CS算法的寻优原理^[11]为:令 d 维搜索空间中,存在一个布谷鸟种群 X ,且有:

$$X = [x_1, x_2, x_3, \dots, x_d] \quad (1)$$

鸟窝位置的更新遵循莱维飞行搜索机制,则鸟窝位置的更新如下:

$$X_i^{(t+1)} = X_i^{(t)} + \alpha \oplus L(\lambda), \quad (2)$$

$$i = 1, 2, \dots, N_{pop}, t = 1, 2, \dots, T_{max}$$

式中: t 为算法当前迭代次数, $X_i^{(t)}$ 为第 i 个鸟窝在当前迭代时的位置, $X_i^{(t+1)}$ 为第 i 个鸟窝在下次迭代时的位置, T_{max} 为算法设置的最大迭代次数, α 为步长调整系数,一般取值为1, $L(\lambda)$ 为布谷鸟飞行步长,该值符合莱维分布,具体如下:

$$L(\lambda) \sim u = t^{-\lambda}, 1 < \lambda \leq 3 \quad (3)$$

综合式(2)和式(3)可以得到:

$$X_i^{(t+1)} = X_i^{(t)} + \alpha \frac{u}{|v|^{\frac{1}{\beta}}} (X_i^{(t)} - X_{best}^{(t)}), \beta \in [1, 2] \quad (4)$$

式中: $X_{best}^{(t)}$ 为当前迭代时的最优鸟窝位置, β 为常数,取值为1.5, u, v 均为位置变化系数,均为服从正态分布的参数,即 $u \sim N(0, \sigma_u^2)$, $v \sim N(0, \sigma_v^2)$,其中 σ_u^2 和 σ_v^2 存在下列关系:

$$\sigma_u^2 = \left\{ \frac{\Gamma(1 + \beta) \sin(\pi\beta/2)}{\Gamma[(1 + \beta)/2] \beta_2^{(\beta-1)/2}} \right\}, \sigma_v^2 = 1 \quad (5)$$

式中: Γ 表示 Gamma 函数。

2 极限学习机

2.1 SLFN

单隐层前馈神经网络^[12] (Single-hidden Layer Feed-forward Neural Network, SLFN) 是一种常用的神经网络,其结构简单、自学习能力强、函数逼近效果好,常被用于解决一些简单的分类、回归问题,SLFN 的网络结构如图 2 所示。




图 2 SLFN 的网络结构

Fig. 2 Network structure of SLFN

由图 2 可见,SLFN 网络结构主要由输入层、隐含层和输出层组成。若令输入层、隐含层和输出层的节点数依次为 n, l 和 m , 则对于样本 (x_i, t_i) 中, $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n, t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$, 则有:

$$\sum_{j=1}^l \beta_j g(w_j \cdot x_i + b_j) = t_i, j = 1, 2, \dots, N \quad (6)$$

式中: $w_j = [w_{1j}, w_{2j}, \dots, w_{nj}]^T$, 表示隐含层节点与输入层中第 j 个节点的连接权值, b_j 为第 j 个节点的偏置量, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T$, 表示输出层节点与隐含层中第 j 个节点的连接权值, $g(x)$ 为激励函数, 常用的激励函数有 S 型函数、正弦函数和余弦函数。

SLFN 在进行回归或分类计算时,其迭代过程中的网络参数需要不断调整,由此使 SLFN 内部各层之间的偏置量和连接权值参数互相影响,造成 SLFN 的输出结果不稳定。大量实践应用证明,SLFN 存在下列不足:

(1) 梯度下降法修正权值和阈值时需要进行多次迭代,造成模型在训练过程中消耗大量时间,导致其训练速度缓慢;

(2) SLFN 的输出结果受其网络参数影响较大,网络参数取值不当易陷入局部最优,从而造成算法收敛较慢或者出现无法收敛的现象;

(3) 学习率 η 对 SLFN 的输出效果影响很大,学习率 η 取值过大,易造成算法不收敛,学习率 η 取值过小,算法收敛慢。

2.2 ELM 基本原理

针对 SLFN 的不足, Huang 等对 SLFN 进行了改进,将 SLFN 的偏置量和连接权值参数作为线性系统进行处理,通过矩阵求逆运算确定其网络参数,并提出了 ELM^[13]。ELM 具有较快的学习速度和更强的泛化性能,且在训练过程中不易陷入局部最优,目前在分类、回归领域得到了广泛应用。ELM 的基本原理为:设样本数据为 $\{x_i, t_i | x_i \in R^n, t_i \in R^m, i = 1, 2, \dots, N\}$, 激励函数为 $g(x)$, 将式(6)中的 N 个方程写成矩阵形式可以得到:

$$H\beta = T \quad (7)$$

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_l \cdot x_1 + b_l) \\ \vdots & & \vdots \\ g(w_1 \cdot x_n + b_1) & \dots & g(w_l \cdot x_n + b_l) \end{bmatrix}_{n \times l}, \quad \beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_l^T \end{bmatrix}_{l \times m}, \quad T = \begin{bmatrix} t_1^T \\ t_2^T \\ \vdots \\ t_n^T \end{bmatrix}_{n \times m} \quad (8)$$

式中 H 为隐含层的矩阵。

由于隐含层矩阵中的激励函数能够进行无限微分,则 ELM 偏置量和连接权值等参数不需要再进行调整。求解公式(7)中的最小二乘范数解 $\tilde{\beta}$, 得到:

$$\|H\tilde{\beta} - T\| = \min_{\beta} \|H\beta - T\| \quad (9)$$

进而可以得到:

$$\tilde{\beta} = H^+ T \quad (10)$$

式中 H^+ 为矩阵 H 的摩尔-彭罗斯逆。

从极限学习机的基本原理可以看出,ELM 的模型训练实际上就是选取合适的权值矩阵,使 ELM 的输出值与实际值更接近,从而减小模型训练误差。由于 ELM 结构简单、不需要调整太多参数,且在训练过程中不易陷入局部最优^[14-15], 因此本文利用 ELM 对通信网络进行故障诊断。

3 基于 CS-ELM 的通信网络故障模型

由于通信网络结构复杂,引起通信网络故障的因素较多,这些影响因素与通信网络故障类型之间并非线性关系,由此可以将通信网络故障诊断问题看作是一个非线性分类问题^[16-17]。本文采用 CS 算法对 ELM 的参数进行优化,建立基于 CS-ELM 的通信网络故障诊断模型,CS-ELM 模型的建模步骤如下:

(1) 获取通信网络故障样本数据,将样本数据划分为训练集和测试集,分别用于 CS-ELM 模型的

训练和精度检验;

(2) 确定 ELM 的网络结构, 主要包括 ELM 输入层、隐含层和输出层神经元的数量;

(3) 初始化 CS 算法并设置相关参数, 主要包括算法最大迭代次数、发现概率等;

(4) 利用 CS 算法进行搜索, 将 CS 算法初始解赋值给 ELM, 利用 ELM 输出通信网络故障类型, 计算函数适应度值。本文将通信网络故障诊断正确率作为适应度函数, 其计算公式为

$$\chi = \frac{p - q}{p} \times 100\% \quad (11)$$

式中: χ 为正确率, p 为训练样本数据的总容量, q 为通信网络故障诊断错误的数量。

(5) 采用式(4)对鸟窝位置进行更新, 生成一组新解, 利用式(11)计算所有鸟窝位置的适应度值, 确定最优鸟窝位置, 并与最优值比较, 保留其中的最优值;

(6) 随机生成某一概率值, 将该值与发现概率值进行比较。若随机概率值大于发现概率的值, 则随机淘汰一组鸟窝位置, 并生成一组新解; 否则当前鸟窝种群保持不变;

(7) 判断当前迭代是否已经达到算法设置的最大迭代次数; 若是, 则将最优参数赋值给 ELM, 否则继续执行迭代;

(8) 利用 CS-ELM 模型对通信网络进行故障诊断, 输出诊断结果。

4 算例分析

4.1 实验数据

本文采用移动通信网络实验数据进行仿真分析, 利用移动通信网络测试系统获取通信网络的 7 种常见故障类型数据组成样本数据。移动通信网络常见的故障类型主要包括正常、链路宽带不足、接口信号丢失、接口负载过大、以太网未连接、接口速率不匹配和双工模式不匹配等。为了方便建模计算, 对上述 7 种通信网络故障类型进行编码, 详见表 1。

表 1 故障编码
Table 1 Fault codes

故障类型	程序编码	故障编码
正常	0000001	1
链路宽带不足	0000010	2
接口信号丢失	0000100	3
接口负载过大	0001000	4
以太网未连接	0010000	5
接口速率不匹配	0100000	6
双工模式不匹配	1000000	7

表 1 中, 每种故障类型的实验数据为 100 组, 则

样本数据的总容量为 700, 在每种故障实验数据中任意选取的 90 组数据作为训练集, 用于模型训练, 剩余数据作为测试集, 用于检验精度, 由此可以得到训练集样本容量和测试集样本容量分别为 630 和 70。

CS 算法的主要参数设置为: 鸟窝数量为 30、算法最大迭代次数为 100、发现概率为 0.4。利用 630 组训练集样本对模型进行训练, 根据 CS-ELM 模型的建模步骤, 采用 CS 算法对 ELM 进行优化, 在 MATLAB 中建立 CS-ELM 模型, 采用试凑法确定 ELM 隐含层神经元的数量, 即根据经验公式确定隐含层神经元的数量为 5~15, 依次选取不同数量的隐含层神经元进行仿真测试, 实验结果见表 2。由表 2 可知, 当隐含层神经元数量为 8 时, 测试误差最小为 3.61×10^{-4} , 由此可以确定 CS-ELM 模型隐含层神经元数量为 8。

表 2 测试误差对比

Table 2 Comparison of Testing Errors

隐含层神经元数量	测试误差
5	8.12×10^{-4}
6	7.66×10^{-4}
7	6.85×10^{-4}
8	3.61×10^{-4}
9	7.63×10^{-4}
10	1.05×10^{-3}
11	1.35×10^{-3}
12	1.12×10^{-3}
13	8.42×10^{-4}
14	5.5×10^{-4}
15	8.2×10^{-4}

4.2 结果分析

采用训练好的 CS-ELM 模型对测试集中的 70 组样本进行诊断, 诊断结果如图 3 所示。为了对比 CS-ELM 模型在通信网络故障诊断的效果, 采用遗传优化反向传播神经网络 (Genetic Algorithm Optimization of Backpropagation Neural Networks, GA-BPNN)、粒子群优化支持向量机 (Particle Swarm Optimization Support Vector Machine, PSO-SVM) 和 ELM 分别建立通信网络故障模型进行对比分析, GA-BPNN 模型、PSO-SVM 模型和 ELM 模型的诊断结果分别如图 4~图 6 所示。从图 3~图 6 可以看出, 相比 GA-BPNN 模型、PSO-SVM 模型和 ELM 模型, CS-ELM 模型输出结果与实际值的差异个数更少, 诊断效果更好。

表 3 给出了 CS-ELM 模型、GA-BPNN 模型、PSO-SVM 模型和 ELM 模型在本次通信网络故障诊断实验中出现误诊断的个数及各模型的正确率。对比表 3 中的数据可以发现, 本文所提 CS-ELM 模型出现误诊断的个数仅为 1 个, 其正确率为 98.57%,

高于其他几种对比模型,可见基于 CS-ELM 的通信网络故障诊断模型具有更高的诊断精度。

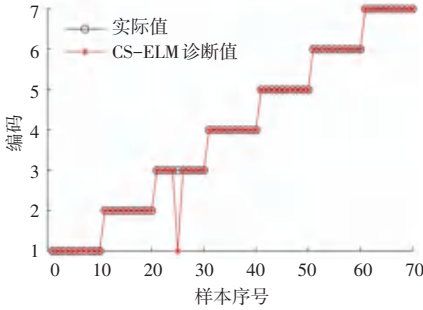


图 3 CS-ELM 模型诊断结果

Fig. 3 Diagnosis results of CS-ELM model




图 4 GA-BP 模型诊断结果

Fig. 4 Diagnosis results of GA-BP model

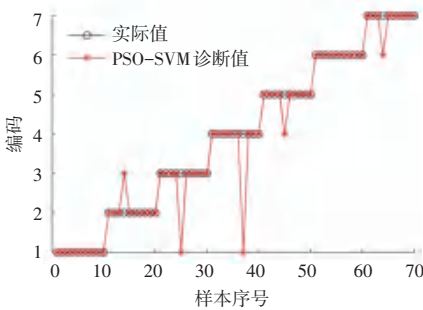


图 5 PSO-SVM 模型诊断结果

Fig. 5 Diagnosis results of PSO-SVM model

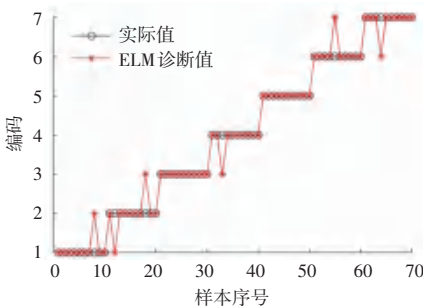


图 6 ELM 模型诊断结果

Fig. 6 Diagnosis results of ELM model

表 3 各模型误诊断个数及正确率

Table 3 Number of misdiagnoses and accuracy of each model

模型	误诊断个数/个	正确率/%
CS-ELM	1	98.57
GA-BP	3	95.71
PSO-SVM	5	92.86
ELM	6	91.43

5 结束语

本文采用布谷鸟算法对极限学习机进行了参数寻优,建立基于 CS-ELM 的通信网络故障诊断模型,将本文所提 CS-ELM 模型与其他几种模型进行对比结果表明,该 CS-ELM 模型在进行通信网络故障诊断时的误诊断个数更少,诊断精度更高,验证了 CS-ELM 模型在通信网络故障诊断方面的正确性和优越性。

参考文献

- [1] 马璐璐,黄亚蒙,徐源音. 基于大数据技术的通信网络故障检测方法[J]. 长江信息通信, 2023, 36 (5): 96-98.
- [2] 齐放,姚渭箐,张成,等. 基于卷积神经网络的电力通信网络故障诊断[J]. 信息技术,2023(6):119-123,128.
- [3] 常瑞莉. 一种基于 BP 神经网络的移动通信网络故障检测方法[J]. 自动化技术与应用, 2023, 42 (6): 123-126.
- [4] 郭瑜,童丽娜,倪旭明. 基于改进卷积神经网络的移动通信网络故障诊断研究[J]. 计算机测量与控制, 2022, 30 (2): 24-30.
- [5] YANG X S, DEB S. Comuckoo search via levy flights [C]// Proceedings of World Congress on Nature and Biologically Inspired Computing (NaBIC2009). India: IEEE, 2009:210-214.
- [6] 李艳波,王笑寒,陈俊硕,等. 基于改进布谷鸟搜索算法的光伏 MPPT 控制[J]. 计算机仿真, 2024, 41 (4): 85-91.
- [7] 康晓华. 基于改进布谷鸟搜索算法的电力系统多目标运行优化研究[J]. 微型电脑应用, 2024, 40 (4): 218-220,225.
- [8] 全世超,高飞翔,朱晓杰,等. 基于改进布谷鸟算法的电网静态选址定容策略[J]. 电气开关, 2024, 62 (3): 1-7,11.
- [9] 兰添贺,曲大义,陈昆,等. 基于 CS 算法优化的 SVM 短时交通流预测模型[J]. 青岛理工大学学报, 2024, 45 (1): 134-140.
- [10] 曲昕. 基于布谷鸟搜索算法的火力发电厂机组调峰运行优化方法[J]. 电工技术, 2023(12): 34-36,39.
- [11] 毛涵申. 基于 CS-BP 神经网络模型的碳排放权价格预测[J]. 信息技术与信息化, 2023(9): 52-55.
- [12] 郭亚鹏,于磊,田海川,等. 基于 GWO-ELM 模型的深基坑开挖变形预测研究[J]. 山西建筑, 2024, 50 (3): 114-118.
- [13] 洪梅,艾春. 基于 FS 算法和极限学习机的通信网络入侵检测方法[J]. 长江信息通信,2022,35(6):51-53.
- [14] 张宇,刘珊. 蚁群算法优化极限学习机的通信网络流量建模分析[J]. 甘肃科学学报,2021,33(6):29-33.
- [15] 高静. 基于极限学习机的舰船网络入侵检测算法[J]. 舰船科学技术,2021,43(10):139-141.
- [16] 谭武坤,杨秋辉,陈伟. 基于贝叶斯网络的通信网络故障定位方法[J]. 计算机应用, 2018, 38 (S2): 217-220,235.
- [17] 彭波涛,戈伟. 基于蚁群算法的电力通信网络节点故障检测系统[J]. 机电工程技术, 2022, 51 (9): 273-275.