

关于系统级故障诊断的烟花-反向传播神经网络算法

归伟夏 陆 倩* 苏美力

(广西大学计算机与电子信息学院 南宁 530004)

摘 要: 为了更快速且精确地诊断出大规模多处理器系统中的故障单元, 该文首次将改进的烟花算法和反向传播(BP)神经网络相结合, 提出一种新的系统级故障诊断算法——烟花-反向传播神经网络故障诊断算法(FWA-BPFD)。首先, 在烟花算法中引入双种群策略、协作算子以及最优算子, 设计新的适应度函数, 优化变异算子、映射规则和选择策略。然后, 利用烟花算法全局搜索能力和局部搜索能力的自调节机制, 优化BP神经网络中的权值和阈值的寻优过程。仿真实验结果表明, 该文算法相较于其他算法不仅有效地降低了迭代次数和训练时间, 而且还进一步提高了诊断精度。

关键词: 系统级故障诊断; 烟花算法; 反向传播神经网络; PMC模型; 烟花-反向传播神经网络算法

中图分类号: TP306

文献标识码: A

文章编号: 1009-5896(2020)05-1102-08

DOI: 10.11999/JEIT190484

A Fireworks Algorithm-Back Propagation Fault Diagnosis Algorithm for System-level Fault Diagnosis

GUI Weixia LU Qian SU Meili

(School of Computer and Electronics Information, Guangxi University, Nanning 530004, China)

Abstract: In order to diagnose fault units in the large-scale multiprocessor systems more quickly and accurately, a system-level fault diagnosis algorithm—FireWorks Algorithm-Back Propagation Fault Diagnosis (FWA-BPFD) based on fireworks algorithm and Back Propagation(BP) neural network is proposed. Firstly, two population strategy, cooperative operator and optimal operator are introduced into fireworks algorithm. A new fitness function is designed, and the mutation operator, mapping rule and selection strategy are optimized. Then, the optimization process of weight and threshold value in BP neural network is optimized by the self-regulating mechanism of global and local searching ability of fireworks algorithm. Simulation results show that compared with other algorithms, this algorithm not only reduces the number of iterations and training time, but also improves the accuracy of diagnosis.

Key words: System-level fault diagnosis; Fireworks algorithm; Back Propagation (BP) neural network; Preparata Metze Chien (PMC) model; FireWorks Algorithm-Back Propagation Fault Diagnosis (FWA-BPFD) algorithm

1 引言

随着大数据时代的到来, 大规模多处理器系统越来越普及。由于这类系统集成了许多个处理器, 其中的每一台处理器相当于系统的一个主机, 需要各个处理器之间进行通信以实现资源共享。这类系统要处理的实时任务非常多, 处理器之间的实时通

信会很繁重, 一旦系统中的某些处理器发生故障而未能及时得到有效处理时往往会造成巨大的损失, 甚至带来灾难性的后果。因此, 寻求一种有效的诊断技术快速、准确地定位系统中的故障处理器并修复或替换掉, 具有非常重要的意义。

作为保证多处理器系统具有高可靠性和高稳定性的一种常用途径和方法, 系统级故障诊断一直备受众多研究学者的关注。1967年, Preparata, Metze和Chien^[1]首次提出并利用图论的思想来解决故障诊断问题, 提出了至今仍被广泛研究的Preparata Metze Chien (PMC)模型, 随后, BGM^[2], Chwa & Hakimi^[3], Malek^[4], MM以及MM*^[5]等诊断模型被相继提出。文献[6–8]中, 分别提出了条件诊

收稿日期: 2019-06-28; 改回日期: 2020-01-19; 网络出版: 2020-02-13

*通信作者: 陆倩 563766390@qq.com

基金项目: 国家自然科学基金(61862003, 61862004), 广西研究生教育创新计划资助项目(YCSW2019036)

Foundation Items: The National Natural Science Foundation of China (61862003, 61862004), The Innovation Project of Guangxi Graduate Education (YCSW2019036)

断算法、概率型矩阵诊断算法以及自适应诊断算法。现代智能算法一般都具有鲁棒性好、自适应能力强、迭代求解速度快等特点，故近年来，各种各样的智能诊断算法也应运而生，如反向传播(Back Propagation, BP)神经网络^[9]、遗传算法^[10]、蚁群算法^[11]、贝壳漫步算法^[12]和烟花算法^[13]等智能算法被应用于系统级故障诊断领域中，并取得不错的效果。对于上述的几种诊断算法，虽然基于BP神经网络的诊断算法(Back Propagation Fault Diagnosis, BPFDD)在时间复杂度方面比其他智能诊断算法要高，但是相比于其他智能诊断算法，它拥有相对较高的诊断精度。因此，在越来越侧重诊断精度的当下，BPFDD算法具有非常大的优势。

烟花算法(FireWorks Algorithm, FWA)^[14]拥有非常强的运行并行性和种群多样性，这使得它能在现有的众多智能算法中崭露头角，并得到了广大学者的青睐。本文针对基于PMC模型的系统级故障诊断的特点，首先，在传统烟花算法中引入双种群策略、协作算子和最优算子，并优化了适应度函数、映射规则 and 选择策略；然后再结合BPFDD算法处理PMC模型下的系统级故障诊断问题，提出了一个新的故障诊断算法——烟花-反向传播神经网络算法(FireWorks Algorithm-BP Fault Diagnosis, FWA-BPFDD)。最后在具体实例数据的基础上，使用该诊断算法进行仿真验证和分析。

2 PMC模型

在PMC模型中，无故障结点表示为0，故障结点表示为1，处理器结点之间可以相互测试，其测试结果描述如表1所示。如果结点之间不存在测试关系(没有边相连)，则测试结果 $u_{ij} = -1$ 。所有的测试结果 u_{ij} 构成这个系统的一个测试症候，用 S 表示，所有的结点状态称为系统的故障模式，用 F 表示。

3 基于烟花算法改进的BP神经网络算法

3.1 BP神经网络

BP神经网络^[15]是一种按误差逆向传播反复调节权值和阈值进行学习训练的多层前向网络，它包括3个层级，分别为输入层、隐含层和输出层。输入层接收外界的数据，通过传递函数传递到隐含

层，其中隐含层可以是单层或多层的，如图1是一个3层(单隐含层)BP神经网络的结构图。隐含层将变换处理过的数据通过传递函数传递到输出层进行下一步处理。

3.2 烟花算法改进

3.2.1 初始种群

烟花算法优化的对象是神经网络随机产生的权值和阈值，所以对于一个给定的神经网络结构，将其连接的权值和阈值直接排列，构成一个烟花个体。若某神经网络为3层结构，输入层到隐含层的权值和阈值分别为 $[W_1, W_2, \dots, W_{n1}]$ 和 $[\theta_1, \theta_2, \dots, \theta_{n2}]^T$ ，隐含层到输出层的权值和阈值分别为 $[V_1, V_2, \dots, V_{n2}]$ 和 $[r_1, r_2, \dots, r_{n3}]^T$ 。其中， W_i 是由输入层到隐含层的权值矩阵转换成 n_2 维的行向量， V_i 是由隐含层到输出层的权值矩阵转换成 n_3 维的行向量。种群中的一个烟花个体可以表示为 $[W_1, W_2, \dots, W_{n1}, \theta_1, \theta_2, \dots, \theta_{n2}, V_1, V_2, \dots, V_{n2}, r_1, r_2, \dots, r_{n3}]$ 。

3.2.2 适应度函数

算法模型训练的目的是通过不断地迭代计算，使得网络输出层结果与期望结果尽可能地接近，从而得到网络输出结果最优时各神经元节点之间的权值和阈值。由于烟花算法的适应度函数和神经网络的总误差函数有关，故本文引入总误差函数，来计算烟花个体的适应度值，因此适应度函数fit的表达式为

$$\text{fit} = \frac{1}{1 + E} \quad (1)$$

$$E = \frac{1}{2} \sum_{k=1}^K \sum_{j=1}^q (d_{kj} - y_{kj})^2 \quad (2)$$

其中， E 表示神经网络的总误差， K 为数据样本的个数， q 为隐含层神经元个数， d 为网络的期望输出， y 为网络的实际输出。

该适应度函数可直观地反映出实际输出和期望输出的误差大小，若误差越小，表示适应度越好。

3.2.3 爆炸算子

在传统烟花算法中，在计算烟花的爆炸半径和




图1 3层BP神经网络结构图

表1 PMC诊断模型

测试结点 u_i	被测试结点 u_j	测试结果 u_{ij}
0	0	0
0	1	1
1	0	0/1
1	1	0/1

爆炸火花数时存在如下情况：最好的烟花爆炸半径接近于0，起不到任何搜索作用；适应度好的烟花个体爆炸产生的火花数量过多，同时适应度值差的烟花个体爆炸产生的火花数量过少。针对这一缺陷，本文对烟花算法的爆炸半径 A_i 和爆炸火花数 S_i 改进为

$$A_i = \begin{cases} \hat{A} \cdot \frac{f(x_i) - Y_{\text{best}} + \varepsilon}{\sum_{i=1}^N (f(x_i) - Y_{\text{best}}) + \varepsilon}, & A_i \geq A_{\min} \\ A_{\min}, & \text{其他} \end{cases} \quad (3)$$

$$S_i = \hat{S} \cdot \frac{Y_{\text{worst}} - f(x_i) + \varepsilon}{\sum_{i=1}^N (Y_{\text{worst}} - f(x_i)) + \varepsilon} \quad (4)$$

其中， $\hat{A}$ 和 $\hat{S}$ 都是常数，分别用来限制最大的爆炸半径和爆炸产生的最大火花数； Y_{best} 和 Y_{worst} 分别表示最好烟花和最差烟花； $f(x_i)$ 为烟花个体 x_i 的适应度值； ε 为一个极小的常数，用来避免除0操作； $A_{\min}$ 为最小的爆炸半径； $\text{round}(\cdot)$ 是根据四舍五入规则的取整函数。

为能避免出现最优烟花产生大量的火花却没有进行任何搜索的情况，在式(3)中增加了一个最小爆炸半径 $A_{\min}$ 来对最优烟花的爆炸半径进行有效的控制；为了避免式(4)中爆炸火花数量出现过或过小的情况，定义

$$S_i = \begin{cases} \text{round}(a\hat{S}), & S_i < am \\ \text{round}(b\hat{S}), & S_i > bm, a < b < 1 \\ \text{round}(S_i), & \text{其他} \end{cases} \quad (5)$$

其中， a 和 b 是根据经验设置的两个系数。

根据计算出的爆炸半径和爆炸火花数量，采取以不同大小的偏移量来进行位移操作，以产生爆炸火花，即

$$\dot{X}_i^k = \dot{X}_i^k + \text{random}(0, A_i) \quad (6)$$

其中， $\dot{X}_i^k$ 表示第 i 个爆炸火花在第 k 维上的位置； A_i 为第 i 个烟花的爆炸半径； $\text{random}(0, A_i)$ 表示在爆炸半径 A_i 内生成的均匀随机数。

3.2.4 变异算子

烟花爆炸完成后，为了进一步提高种群的多样性，避免陷入局部极值，在求解过程中引入高斯变异

$$\tilde{X}_i^k = X_i^k + (X_B^k - X_i^k) \times \text{Gaussian}(1, 1) \quad (7)$$

其中， $\tilde{X}_i^k$ 表示烟花变异后产生的高斯变异火花； X_i^k 表示第 i 个烟花 X_i 在第 k 维上的位置； X_B^k 是当前

种群中最优个体 X_B 在第 k 维上的位置； $\text{Gaussian}(1, 1)$ 是均值和方差均为1的高斯分布随机数。

3.2.5 协作算子

传统烟花算法中爆炸点规模较大，且爆炸的炸点之间存在缺乏有效交互的缺陷，为解决该问题，本文引入了协作算子对烟花算法进行改进。协作算子分为均匀交叉算子和算术交叉算子两种，具体执行哪一种算子可由交叉概率 p_c 决定，如果满足 $\text{rand}(0, 1) > p_c$ ，则烟花个体执行均匀交叉算子，否则执行算术交叉算子。

(1) 均匀交叉算子：均匀交叉也叫做一致交叉，它是指两个配对个体的每个维度都以相同的交叉概率进行交换，从而形成两个新的个体。在双种群烟花算法中，如果种群1中的烟花个体 X_i 执行均匀交叉算子，则将 X_i 与种群2中的最优烟花个体 X_j 进行均匀交叉操作，得到两个新的烟花个体 X'_i 和 X''_i ，均匀交叉的示意图如图2所示。




图2 均匀交叉运算示意图

(2) 算术交叉算子：算术交叉是指由两个个体的线性组合而产生出两个新的个体。在双种群烟花算法中，如果种群1中的烟花个体 X_i 执行算术交叉算子操作，则将 X_i 与种群2中的最优烟花个体 X_j 按式(8)、式(9)生成两个新的烟花个体 X'_i 和 X''_i

$$X'_i = a \cdot X_i + (1 - a) \cdot X_j \quad (8)$$

$$X''_i = (1 - a) \cdot X_i + a \cdot X_j \quad (9)$$

其中， a 表示算数交叉因子。

对经过协作算子操作之后生成的新个体 X'_i 和 X''_i 进行评价，如果新个体优于 X_i ，则将新个体中最优的那个个体替换掉 X_i 。通过协作算子，两个种群之间可以进行很好的信息交换，实现了种群之间的协同进化。

3.2.6 最优算子

为了进一步提高算法的寻优能力，本文在烟花算法中引入了最优算子，利用种群中最优烟花的信息进入当前烟花个体区域进行搜索以优化当前烟花个体信息。该种策略主要是综合了最优烟花个体的

信息，对当前的爆炸点进行适当的扰动，从而提高算法的效率

$$X_i^k = X_B^k \quad (10)$$

其中， X_i^k 表示第 i 个烟花 X_i 在第 k 维上的位置； X_B^k 表示当前种群中最优个体 X_B 在第 k 维上的位置。

3.2.7 映射规则

经过以上操作之后产生的火花有可能会超出可行域，这种火花对于该算法是无用的，因此需要通过某种映射规则将其拉回到可行域范围内。为了解决这个问题，本文主要采用模运算映射规则来处理超出边界的火花

$$X_i^k = X_{LB}^k + U(0,1) \times (X_{UB}^k - X_{LB}^k) \quad (11)$$

其中， X_i^k 表示超出边界的第 i 个烟花个体 X_i 在第 k 维上的位置； X_{LB}^k 和 X_{UB}^k 分别表示烟花在第 k 维上的下边界和上边界； $U(0,1)$ 表示在区间 $[0,1]$ 上均匀分布的随机数。

3.2.8 选择策略

为使烟花种群中优秀的信息能够传递到下一代种群中，本文算法采用的是最优适应度值选择策略。在双种群烟花算法中，两个种群分别独立地选择并生成下一代种群，即从各自的烟花种群中选择适应度值较优的前 N 个烟花个体。

3.3 烟花算法优化BP神经网络的原理

一般的BP神经网络由于随机生成的初始权值和阈值具有非常大的随机性，因此网络的稳定性和误差均存在一定的偶然性，导致网络的泛化能力不强，而利用烟花算法局部搜索能力和全局搜索能力的自调节机制可以很好地解决这个问题。图3为利用烟花算法优化BP神经网络后的流程图，FWA-BPFD算法比普通BP神经网络流程图多出了虚线框内的烟花算法部分。

3.4 算法时间复杂度分析

假设在某次诊断中，初始烟花种群的规模为 N ，而在每一次迭代中，烟花爆炸产生的火花总数为 s ，高斯变异的烟花数量为 g ，下面就本文3.3节给出的算法流程，分析本文算法的时间复杂度。第一，采用随机初始化的方法生成初始种群，种群规模为 N ，时间复杂度为 $O(N)$ ；第二，两个种群并行计算初始种群中每个个体的适应度值，这需要遍历整个种群，时间复杂度为 $O(N)$ ；第三，两个种群中的每一个烟花分别通过爆炸算子和变异算子生成爆炸火花和变异火花，时间复杂度分别为 $O(s)$ 和 $O(g)$ ；第四，两个种群交替执行协作算子和最优算子，时间复杂度为 $O(N+s+g)$ ；第五，对现有的烟花个体进行越界检测，时间复杂度为 $O(N+s+g)$ ；




图3 烟花算法优化BP神经网络的流程图

第六，种群1和种群2通过选择策略独立地选择生成下一代种群，时间复杂度为 $O(N+s+g)$ ；第七，神经网络训练，时间复杂度为 $O(N^2)$ 。

综上，算法每一次迭代的时间复杂度为 $O(N) + O(N) + O(s) + O(g) + O(N+s+g) + O(N+s+g) + O(N+s+g) + O(N^2) = O(N^2)$ ，若算法迭代 l 次，则算法总的时间复杂度为 $O(lN^2)$ 。而文献[9]中所提出的BPFD算法的时间复杂度为 $O(lN^3)$ ，相比之下，本文的FWA-BPFD算法有效降低了诊断的时间复杂度。

4 基于FWA-BPFD的系统级故障诊断

本文的算法设计平台为MATLAB R2014a，并且在一台内存为4.00 GB，CPU为Intel(R) Core(TM) i5-3230M 2.60 GHz的计算机上进行仿真实验。

4.1 神经网络结构关键参数的设置

BP神经网络模型的关键参数主要有：隐含层层数 e ，隐含层神经元个数 s ，激活函数 f ，网络节点的权值 w_{ij} 以及网络节点的阈值 θ 等。其具体参数设置如下：

(1) 隐含层层数 e ：采用单层隐含层结构的网络即可解决简单问题，但对于映射关系比较复杂的问题需要采用两个或两个以上隐含层结构的网络来解决。先后有人证明了一个3层结构的神经网络就可以实现任意 n 维空间到 m 维空间的映射^[16]，所以现设定：当系统规模 $n \leq 100$ 的时候，神经网络隐含层个数设置为1，而当系统规模 $n > 100$ 的时候，神经网络隐含层个数设置为2。

(2) 隐含层神经元个数 s : 神经网络隐含层神经元个数的设置是一个比较困难和复杂的问题, 目前还没有很好的理论公式来确定。对于隐含层神经元个数的确定, 本文算法根据Komgorov定理, 由式(12)计算出隐含层的神经元个数

$$s = \sqrt{0.43mn + 0.12n^2 + 2.54m + 0.77n + 0.35} + 0.51 \quad (12)$$

其中, s 表示隐含层节点个数, m 表示输入层节点个数, n 表示输出层节点个数。

(3) 激活函数 f : 在神经网络的预测模型中, 输入层的激活函数 f_1 采用tansing函数, 而输出层的激活函数 f_2 采用purelin函数。

(4) 网络的权值 w_{ij} 和阈值 θ : 对于网络节点间的权值和阈值, 基于传统BP神经网络的系统级故障诊断算法采用的是随机初始化的方式, 这导致算法在训练过程中不易收敛, 且易陷入局部极值。针对这个缺陷, 本文采用经过烟花算法迭代选择得到的最优烟花个体对BP神经网络的权值和阈值进行初始化。

4.2 烟花算法主要参数的设置

(1) 关键参数设置: 根据4.1节给出的待优化网络的参数, 以对权值 w_{ij} 和阈值 θ 进行优化为目标, 采用控制变量法, 逐一对烟花算法的关键参数进行实验分析, 实验结果如图4所示。根据实验结果对烟花算法的关键参数进行设置: 烟花种群大小

$N=15$, 最大火花数 $\hat{S}=30$, 最大爆炸半径 $\hat{A}=5$, 高斯变异火花数 $g=4$ 。

(2) 其它参数: 在文献[17,18]中相关实验结果的基础上, 对烟花算法中的其它参数设置如表2所示。

4.3 模型训练与测试

根据PMC模型, 首先设置处理器结点数以及连接边数, 以此随机生成不同规模的网络拓扑结构图, 然后根据 t -可诊断性, 随机产生故障结点, 得出相应的系统测试症候 S 和故障模式 F , 即系统测试报告。将这份系统测试报告来对基于FWA-BPFD算法的神经网络模型进行训练和测试, 选取测试报告中的前80%数据作为训练数据, 用于对模型进行训练, 选取测试报告中的后20%数据作为测试数据, 用于对模型进行测试。由于在PMC模型下生成的测试症候和故障模式都是-1, 0或者1, 数据本身已经归一化, 所以在之后的诊断实验中不需要再另作数据的归一化处理。

对比实验中, 为了保证实验对比分析结果的有效性, 对所有模型中神经网络训练的关键参数进行相同的设置, 如表3所示。

以规模为50的系统为例, 使用本文算法进行训练和测试, 如图5所示, 在训练到305次时, 能够得到最小的误差值, 为6.8804e-07, 表明本文算法能够在训练过程中快速搜索, 而没有陷入局部最优解。




图4 各关键参数对算法CPU运行时间的影响

表 2 烟花算法的其它参数设置

参数名称	参数说明	参数值
$A_{\min}$	烟花的最小爆炸半径	2
p_c	协作算子交叉概率	0.5
X_{LB}	烟花位置下界值	0
X_{UB}	烟花位置上界值	1
T	最大迭代次数	1000

表 3 神经网络训练关键参数设置

参数名称	参数说明	参数值
show	设置数据显示刷新频率	30
lr	网络的学习率	0.01
goal	网络输出误差最小值	7e-07
epochs	最大迭代次数	10000




图 5 算法训练性能图




图 6 不同系统规模中4种算法诊断正确率的比较

表 4 4种算法在不同系统规模中的性能比较

算法名称	$n = 50$		$n = 100$	
	训练时间(s)	迭代次数	训练时间(s)	迭代次数
BPFD	412	685	34163	5937
CS-BPFD	233	327	17810	2134
GA-BPFD	310	365	27890	3978
本文FWA-BPFD	212	305	16755	1998

4.4 算法比较

为了验证FWA-BP算法的系统级故障诊断性能，在选取相同的训练参数条件下，采用相同的测试报告(数据集)，分别对BPFD算法^[9]、布谷鸟搜索-BP神经网络(Cuckoo Search-Back Propagation Fault Diagnosis, CS-BPFD)算法^[12]、遗传-BP神经网络(Genetic Algorithm-Back Propagation Fault Diagnosis, GA-BPFD)算法^[19]以及本文的FWA-BPFD算法进行故障诊断的训练和测试。

诊断准确率是指在测试过程中，被正确诊断的测试样本数占总测试样本数的百分比，即诊断准确率=被正确诊断的测试样本数/总测试样本数 $\times 100\%$ 。分别对规模 n 等于50和100的多处理器系统进行诊断实验，其中，故障机个数按照系统的 t -可诊断性从1逐一递增到 $(n/2) - 1$ 。为了保证结果的稳定性，减小其随机性，在相同条件下，重复进行100次实验，取诊断正确率的平均值。图6为BPFD算法、CS-BPFD算法、GA-BPFD算法以及FWA-BPFD算法在不同系统规模中诊断正确率的比较。表4给出了这4种算法在不同系统规模中的性能比较。

由图6看出，在系统规模相同的情况下，随着故障结点个数的增加，虽然4个算法的诊断准确率都呈下降趋势，但是FWA-BPFD算法的诊断准确率略高于其它3个算法，在规模为50的情况下，FWA-BPFD算法的诊断准确率基本保持在100%，在规模为100的情况下，FWA-BPFD算法的诊断准

确率一直保持在98%以上。此外,在不同故障结点个数下准确率波动较小,体现了FWA-BPFD算法在诊断精度方面的优越性。

由表4可以看出,在系统规模相同的情况下,对于训练时间和迭代次数方面,FWA-BPFD算法明显少于其他3种算法,表明了FWA-BPFD算法在诊断时间方面的优越性。

5 结束语

BP神经网络非线性映射能力极强,具有联想、推测和记忆的功能,这使其非常适用于系统级故障诊断。烟花算法是一种拥有全局搜索能力和局部搜索能力自调节机制的群体智能算法,通过将烟花算法和BP神经网络进行结合,不仅可以克服一般BP算法收敛速度慢、易陷入局部极小值的问题,同时又能兼备BP和烟花算法本身的优点,在提升诊断的准确率的同时,缩短了诊断的时间,能更好地解决系统级故障诊断问题。烟花算法中各算子和各参数均存在一定的缺陷和性能不足的情况,在此基础上,本文提出了相应的改进策略和方法,同时还引入了一些新的算子,最后结合BPFD算法,提出了基于PMC模型的FWA-BPFD算法。与BPFD等算法相比,FWA-BPFD不仅有效地降低了迭代次数和训练时间,还进一步提高了诊断的准确率。后续工作将会对烟花算法本身和BP神经网络本身继续研究和优化,使得FWA-BPFD算法能运用于更大规模的多处理器系统中。

参 考 文 献

- [1] PREPARATA F P, METZE G, and CHIEN R T. On the connection assignment problem of diagnosable systems[J]. *IEEE Transactions on Electronic Computers*, 1967, EC-16(6): 848–854. doi: 10.1109/PGEC.1967.264748.
- [2] BARSİ F, GRANDONI F, and MAESTRINI P. A theory of diagnosability of digital systems[J]. *IEEE Transactions on Computers*, 1976, C-25(6): 585–593. doi: 10.1109/tc.1976.1674658.
- [3] CHWA K Y and HAKIMI S L. Schemes for fault-tolerant computing: a comparison of modularly redundant and t -diagnosable systems[J]. *Information and Control*, 1981, 49(3): 212–238. doi: 10.1016/S0019-9958(81)90388-0.
- [4] MALEK M. A comparison connection assignment for diagnosis of multiprocessor systems[C]. The 7th Annual Symposium on Computer Architecture. New York, USA, 1980: 31–36. doi: 10.1145/800053.801906.
- [5] MAENG J and MALEK M. A comparison connection assignment for self-diagnosis of multiprocessor systems[C]. The 11th International Symposium on Fault-Tolerant Computing, Portland, USA, 1981: 173–175.
- [6] XIE Min, YE Liangcheng, and LIANG Jiarong. A t/k diagnosis algorithm on hypercube-like networks[J]. *Concurrency and Computation: Practice and Experience*, 2018, 30(6): e4358. doi: 10.1002/cpe.4358.
- [7] 冯海林, 雷花, 梁伦. 一种基于PMC模型下的概率性矩阵诊断算法[J]. 南京理工大学学报: 自然科学版, 2017, 41(4): 479–485. doi: 10.14177/j.cnki.32-1397n.2017.41.04.013.
- [8] FENG Hailin, LEI Hua, and LIANG Lun. Probability matrix diagnosis algorithm based on PMC model[J]. *Journal of Nanjing University of Science and Technology*, 2017, 41(4): 479–485. doi: 10.14177/j.cnki.32-1397n.2017.41.04.013.
- [8] 云龙, 梁家荣, 周宁. 基于互连网络系统故障的新型自适应诊断算法[J]. 计算机应用研究, 2017, 34(9): 2638–2641, 2650. doi: 10.3969/j.issn.1001-3695.2017.09.016.
- [9] YUN Long, LIANG Jiarong, and ZHOU Ning. Novel adapted algorithm for interconnection network[J]. *Application Research of Computers*, 2017, 34(9): 2638–2641, 2650. doi: 10.3969/j.issn.1001-3695.2017.09.016.
- [9] MOURAD E and NAYAK A. Comparison-based system-level fault diagnosis: A neural network approach[J]. *IEEE Transactions on Parallel and Distributed Systems*, 2012, 23(6): 1047–1059. doi: 10.1109/TPDS.2011.248.
- [10] 归伟夏, 刘翠. 一种Malek模型下的系统故障诊断算法[J]. 计算机工程与应用, 2017, 53(13): 78–82, 145. doi: 10.3778/j.issn.1002-8331.1607-0130.
- [11] GUI Weixia and LIU Cui. System-level diagnosis algorithm based on Malek model[J]. *Computer Engineering and Applications*, 2017, 53(13): 78–82, 145. doi: 10.3778/j.issn.1002-8331.1607-0130.
- [11] WANG Yuxi, LI Zhan, XU Minghui, et al. An evolutionary approach based on ant colony system to system-level fault diagnosis[C]. The 8th IEEE International Power Electronics and Motion Control Conference (IPEMC-ECCE Asia), Hefei, China, 2016: 2493–2497. doi: 10.1109/IPEMC.2016.7512690.
- [12] 赵冬. 关于系统级故障诊断的两种高效算法[D]. [硕士学位论文], 南京财经大学, 2016.
- [13] ZHAO Dong. Two efficient algorithms about system-level fault diagnosis[D]. [Master's dissertation], Nanjing University of Finance and Economics, 2016.
- [13] LU Qian, GUI Weixia, and SU Meili. A fireworks algorithm for the system-level fault diagnosis based on MM* model[J]. *IEEE Access*, 2019, 7: 136975–136985. doi: 10.1109/ACCESS.2019.2942336.
- [14] 韩树楠, 张旻, 李歆昊. 基于构造代价函数求解的自同步扰码盲识别方法[J]. 电子与信息学报, 2018, 40(8): 1971–1977. doi: 10.11999/JEIT171026.

- HAN Shunan, ZHANG Min, and LI Xinhao. A blind identification method of self-synchronous scramblers based on optimization of established cost function[J]. *Journal of Electronics & Information Technology*, 2018, 40(8): 1971–1977. doi: 10.11999/JEIT171026.
- [15] 梁晓萍, 郭振军, 朱昌洪. 基于头脑风暴优化算法的BP神经网络模糊图像复原[J]. 电子与信息学报, 2019, 41(12): 2980–2986. doi: 10.11999/JEIT190261.
- LIANG Xiaoping, GUO Zhenjun, and ZHU Changhong. BP neural network fuzzy image restoration based on brain storming optimization algorithm[J]. *Journal of Electronics & Information Technology*, 2019, 41(12): 2980–2986. doi: 10.11999/JEIT190261.
- [16] CUI Jiefen, LI Yinping, WANG Shixin, *et al.* Directional preparation of anticoagulant-active sulfated polysaccharides from *Enteromorpha prolifera* using artificial neural networks[J]. *Scientific Reports*, 2018, 8(1): No. 3062. doi: 10.1038/s41598-018-21556-x.
- [17] LI Jingmei, TIAN Qiao, ZHANG Guoyin, *et al.* Task scheduling algorithm based on fireworks algorithm[J]. *EURASIP Journal on Wireless Communications and Networking*, 2018, 2018(1): No. 256. doi: 10.1186/s13638-018-1259-2.
- [18] XUE Yu, ZHAO Binping, MA Tinghui, *et al.* A self-adaptive fireworks algorithm for classification problems[J]. *IEEE Access*, 2018, 6: 44406–44416. doi: 10.1109/ACCESS.2018.2858441.
- [19] 刘田田. 基于BP神经网络的系统级故障诊断算法研究[D]. [硕士论文], 南京财经大学, 2015.
- LIU Tiantian. System level fault diagnosis algorithm research based on BP neural network[D]. [Master's dissertation], Nanjing University of Finance and Economics, 2015.
- 归伟夏: 女, 1974年生, 副教授, 博士, 研究方向为智能计算、网络与并行分布式计算.
- 陆倩: 女, 1994年生, 硕士生, 研究方向为智能算法、并行计算.
- 苏美力: 女, 1989年生, 硕士生, 研究方向为智能算法、并行计算.