

DOI: 10.19783/j.cnki.pspc.230761

电网故障诊断解析模型的改进二进制增益共享知识算法求解

袁泉^{1,2}, 周海峰^{1,2}, 黄金满³, 宋阜⁴

(1. 集美大学轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室, 福建 厦门 361021;
3. 厦门安麦信自动化科技有限公司, 福建 厦门 361026; 4. 赣州赛可韦尔科技有限公司, 江西 赣州 341000)

摘要: 针对现有智能优化算法在求解电网故障诊断解析模型时存在的易于陷入局部最优和种群质量低等问题, 提出一种改进二进制增益共享知识算法(improved binary gaining-sharing knowledge-based algorithm, IBGSK)。首先, 根据故障诊断规则, 构建一种包含完备故障信息的完全解析模型。其次, 将离散工作机制融入改进算法的种群更迭中, 以避免发生空间脱节。然后, 结合进化种群动力学思想(evolutionary population dynamics, EPD), 引入一种自适应交叉算子, 以提高种群质量和增强算法的全局寻优能力。最后, 通过特征选择和故障诊断仿真实验对算法性能进行评估。结果表明: IBGSK 算法相较于其他优化算法, 在特征选择问题上具有更高的计算效率、更强的全局寻优能力和泛化能力; 在求解电网故障诊断解析模型上具有更优的诊断可靠性、时效性和收敛性。

关键词: 故障诊断; 二进制; 增益共享知识算法; 离散工作机制; 进化种群动力学; 自适应交叉算子

An improved binary gaining-sharing knowledge-based algorithm for solving the analytic model of power grid fault diagnosis

YUAN Quan^{1,2}, ZHOU Haifeng^{1,2}, HUANG Jinman³, SONG Fu⁴

(1. School of Marine Engineering, Jimei University, Xiamen 361021, China; 2. Fujian Province Key Laboratory of Naval Architecture and Marine Engineering, Xiamen 361021, China; 3. Xiamen Anmaixin Automation Technology Co., Ltd., Xiamen 361026, China; 4. Ganzhou Cyclewell Technology Co., Ltd., Ganzhou 341000, China)

Abstract: There is a problem that existing intelligent optimization algorithms tend to fall into local optima and low population quality when solving power grid fault diagnosis analytical models. Thus an improved binary gain-sharing knowledge-based algorithm (IBGSK) is proposed. First, a complete analytical model considering complete fault information is constructed from the fault diagnosis rules. Second, a discrete working mechanism is integrated into the population replacement of the improved algorithm to avoid spatial disconnection. Then, combined with the idea of evolutionary population dynamics (EPD), an adaptive crossover operator is proposed to improve the population quality, thereby enhancing the global optimization ability of the improved algorithm. Finally, the performance of algorithms is evaluated by feature selection and fault diagnosis simulation experiments. The results show that the IBGSK algorithm has higher computational efficiency, stronger global optimization ability, and generalizability in feature selection problems than other optimization algorithms. It has better diagnostic reliability, timeliness, and convergence in solving the analytic model of power grid fault diagnosis.

This work is supported by the General Program of National Natural Science Foundation of China (No. 51179074).

Key words: fault diagnosis; binary; gaining-sharing knowledge-based algorithm; discrete working mechanism; evolutionary population dynamics; adaptive crossover operator

0 引言

智慧电网的故障诊断主要依赖监控和数据采集

基金项目: 国家自然科学基金面上项目资助(51179074); 福建省自然科学基金项目资助(2021J01839); 集美大学安麦信产学研项目资助(S20127)

系统(the supervisory control and data acquisition system, SCADA)提供的激活保护和断路器告警信息, 通过应用不同的诊断方法来准确获取相应的故障信息^[1-2]。当电网发生故障时, 快速且可靠的诊断对于快速恢复供电、减少事故扩大、维护电网的安全和稳定运行至关重要^[3-4]。

目前, 电网故障诊断方法主要涵盖 Petri 网^[5]、

模糊集理论^[6]、神经网络和解析模型等。这些方法在技术路线和建模思想上存在显著差异,各具特色。其中,基于解析模型的诊断方法是通过建立数学解析模型来表达部件或区段、保护和断路器之间的逻辑关系,并利用优化算法求解来识别故障部件或区段。该方法具有严格的逻辑解释、严密的数学推导和易于实现的特点,因此在实践中具有广泛的应用前景。

近年来,学者和专家们提出多种解析模型和优化算法来应对电网故障诊断问题,并取得卓越成就^[7]。但随着电网的规模和复杂性日益增加,正确地诊断出故障仍然是一个挑战。在基于解析模型的故障诊断方法中,优化算法的优劣是影响诊断结果和结论的重要因素。因此,本文考虑到在故障情况下不同不确定事件发生概率具有差异性的基础上,选用一种包含完备故障信息的解析模型作为待优化的目标函数。针对现有求解优化算法存在的问题,提出了改进二进制增益共享知识算法(improved binary gaining-sharing knowledge-based algorithm, IBGSK)。

增益共享知识算法(gaining-sharing knowledge-based algorithm, GSK)作为一种群智能算法^[8],文献^[9]证明了 GSK 算法在解决基准优化问题和实际工程问题上的强大竞争力。

二进制增益共享知识算法^[10]作为 GSK 算法的二进制版本,虽然能够解决一些离散优化问题,但依然存在着空间脱节、易于陷入局部最优和种群质量低的缺陷。因此,本文首先将文献^[11]提出的离散工作机制融入 IBGSK 算法中的种群更新过程中,以避免发生空间脱节并防止错失优秀个体。其次,结合进化种群动力学思想(evolutionary population dynamics, EPD)思想,通过自适应交叉算子来重新定义最差子种群中的个体,以达到提高算法搜索性能和种群质量的目的。随后,将文献^[12]提出的基于逻辑运算的二进制增益共享知识算法(logical operations binary gaining-sharing knowledge-based algorithm, LOBGSK)、文献^[13]提出的具有突变策略的改进二进制增益共享知识算法(improved binary gaining-sharing knowledge-based algorithm with mutation, IBGSKM)和文献^[14]提出的动态粘度粒子群算法(dynamic sticky binary particle swarm optimization, DSBPSO)作为对比算法,通过特征选择问题来验证 IBGSK 算法的求解优势。最后,对多种故障场景进行仿真诊断的实验结果证明了 IBGSK 算法在解决电网故障诊断问题上具有更好的综合诊断性能。

1 电网故障诊断解析模型

电网保护主要包括主保护、近后备保护、远后

备保护和断路器失灵保护。当元件发生故障时,相关的主保护应该动作,触发相应的断路器跳闸来隔离故障。若主保护无法使对应的断路器跳闸,备用保护将依次启动,确保故障得到隔离,并上报保护动作和断路器跳闸的告警信息。故障诊断解析模型就是把上述保护原理和规则用逻辑方程组的形式进行表达,进而全面描述故障场景^[15]。

保护和断路器的期望状态是指保护和断路器根据继电保护原理所做出的响应激励,而实际状态指的是保护和断路器在当前时刻下的真实工作状态^[16]。本文将 f_{r_m} 设为可疑故障元件 s 的主保护 r_m 的期望状态。若元件 s 发生故障, r_m 应当响应,此时 $f_{r_m} = 1$ 。当元件 s 正常工作时, r_m 则保持沉默状态,此时 $f_{r_m} = 0$ 。因此, f_{r_m} 的数学表达式如式(1)所示。

$$f_{r_m} = d \quad (1)$$

式中, d 表示元件 s 的状态,当 $d=1$ 时,表示元件 s 发生故障,当 $d=0$ 时,则表示元件 s 正常工作。

当元件 s 故障且主保护拒动时,近后备保护 r_p 将被激活,此时 r_p 的期望状态 $f_{r_p} = 1$ 。若主保护 r_m 正常动作或者元件 s 未发生故障,此时 $f_{r_p} = 0$ 。综上所述, f_{r_p} 的数学表达式为

$$f_{r_p} = d \overline{g_m} \quad (2)$$

式中: g_m 表示 r_m 的实际状态, $g_m = 1$ 表示 r_m 的实际状态为动作, $g_m = 0$ 表示 r_m 未动作;符号“ $\overline{\quad}$ ”表示“逻辑非”运算。

设 r_s 为元件 s 的远后备保护,其在两种情况应该动作:元件 s 故障且 r_m 和 r_p 均未动作;元件 s 的相邻元件 s_x 发生故障($d_x = 1$,表明元件 s_x 出现故障; $d_x = 0$,则 s_x 未发生故障)且关联路径上的断路器均未动作。因此,远后备保护 r_s 的期望状态 f_{r_s} 的数学表达式如式(3)所示。

$$f_{r_s} = d \overline{g_m g_p} \oplus \sum_{s_x \in Z(r_s, s)} \left(d_x \prod_{c_t \in p(r_s, s_x)} \overline{c_t} \right) \quad (3)$$

式中: g_p 表示 r_p 的实际状态, $g_p = 1$ 表示 r_p 的实际状态为动作,而 $g_p = 0$ 表示 r_p 未动作;集合 $Z(r_s, s)$ 表示在远后备保护 r_s 的保护范围内,元件 s 的所有相邻元件;集合 $p(r_s, s_x)$ 表示沿关联路径从保护 r_s 安装处到元件 s_x 处的所有断路器期望状态; c_t 为集合 $p(r_s, s_x)$ 中的元素, $c_t = 1$ 表明该集合中的第 t 个断路器发生跳闸,若 $c_t = 0$,说明该断路器处于闭合状

态; 符号“ Σ ”为连加运算; 符号“ Π ”为连乘运算; 符号“ \oplus ”为“逻辑与”运算。

220 kV 及其以上电网中的断路器会配置失灵保护 r_n 。当有保护动作并驱动断路器 c_b 跳闸, 若 c_b 未能跳闸, 此时 r_n 应当动作, 此时, 失灵保护 r_n 的期望状态 $f_{r_n} = 1$ 。若 f_{r_n} 取值为 0, 则说明 r_n 处于沉默状态。 f_{r_n} 的数学表达式如式(4)所示。

$$f_{r_n} = \overline{c_k} \sum_{r_x \in R(c_b)} r_x \quad (4)$$

式中: $R(c_b)$ 为所有能够驱动断路器 c_b 跳闸的保护集合; r_x 为集合 $R(c_b)$ 中的第 x 个元素; $c_k = 1$ 表示断路器 c_b 发生跳闸, $c_k = 0$ 则表示断路器 c_b 处于闭合状态。

任何能够驱动断路器 c_b 跳闸的保护动作, 都会触发 c_b 跳闸。断路器 c_b 的期望状态 f_{c_b} 为

$$f_{c_b} = \sum_{r_x \in R(c_b)} r_x \quad (5)$$

式中, $f_{c_b} = 1$ 表示断路器 c_b 的期望状态为跳闸, $f_{c_b} = 0$ 则断路器 c_b 的期望状态为闭合。

当电网发生故障时, 保护和断路器有可能发生拒动或误动, 同时上传到 SCADA 系统中的告警信息也可能存在着误报或漏报。虽然这些小概率的不确定事件不能确定具体的故障场景, 但在一定程度上能够反映某种故障场景发生的可能性。本文从这个角度出发, 基于故障诊断规则, 构建包含完备故障信息的解析模型。

考虑到各逻辑变量之间的关联性, 本文用 e_r 和 e_c 来分别表示保护 r 和断路器 c 的告警信息错误(漏报和误报)合集。其中, $e_r = 1(e_c = 1)$ 和 $e_r = 0(e_c = 0)$ 分别表示保护 r (断路器 c)的告警信息出现错误和无错误。电网的完备故障信息表达式如式(6)所示。

$$\begin{cases} m_r = g_r \overline{f_r}, d_r = \overline{g_r} f_r \\ m_c = g_c \overline{f_c}, d_c = \overline{g_c} f_c \\ g_r = e_r \overline{r'} \oplus \overline{e_r} r', g_c = e_c \overline{c'} \oplus \overline{e_c} c' \\ e_r = w_r \oplus l_r, e_c = w_c \oplus l_c \end{cases} \quad (6)$$

式中: g_r 和 g_c 分别表示保护 r 和断路器 c 的实际状态, $g_r = 1(g_c = 1)$ 和 $g_r = 0(g_c = 0)$ 分别表示 $r(c)$ 的实际状态为动作(跳闸)和未动作(闭合); f_r 和 f_c 分别表示保护 r 和断路器 c 的期望状态, $f_r = 1(f_c = 1)$ 和 $f_r = 0(f_c = 0)$ 分别表示保护 $r(c)$ 的期望状态为动作(跳闸)和不动作(闭合); r' 和 c' 分别表示保护 r 和断路器 c 的实际告警信息, $r' = 1(c' = 1)$ 和 $r' = 0(c' = 0)$

分别表示 $r(c)$ 的告警状态为动作(跳闸)和不动作(闭合); l_r 和 l_c 分别表示保护 r 和断路器 c 的告警信息是否漏报, $l_r = 1$ 和 $l_c = 1$ 分别表示 r 和 c 的告警信息存在漏报, 而 $l_r = 0$ 和 $l_c = 0$ 则分别表示 r 和 c 的告警信息不存在漏报的情况; w_r 和 w_c 分别表示 r 和 c 的告警信息是否误报, $w_r = 1$ 和 $w_c = 1$ 分别表示 r 和 c 的告警信息存在误报, $w_r = 0$ 和 $w_c = 0$ 则分别表示 r 和 c 的告警信息没有发生畸变; m_r 和 m_c 分别表示 r 和 c 是否误动, $m_r = 1$ 和 $m_c = 1$ 分别表示 r 的动作和 c 的跳闸存在错误, $m_r = 0$ 和 $m_c = 0$ 分别表示 r 的动作和 c 的跳闸是符合动作逻辑的; d_r 和 d_c 分别表示 r 和 c 是否拒动, 其中, $d_r = 1$ 和 $d_c = 1$ 分别表示 r 和 c 拒动, $d_r = 0$ 和 $d_c = 0$ 分别表示 r 和 c 正常动作。

根据式(6), 构建了计及完备故障信息的目标函数, 其表达式如式(7)所示。

$$\begin{aligned} I = & \sum_{i=1}^Z \|e_{r_i}\| + \sum_{i=1}^Y \|e_{c_i}\| + \omega_{11} \sum_{i=1}^{\alpha_1} \|m_{r_i}\| + \\ & \omega_{12} \sum_{i=1}^{\alpha_2} \|m_{r_i}\| + \omega_{13} \sum_{i=1}^{\alpha_3} \|m_{r_i}\| + \omega_{21} \sum_{i=1}^{\alpha_1} \|d_{r_i}\| + \\ & \omega_{22} \sum_{i=1}^{\alpha_2} \|d_{r_i}\| + \omega_{23} \sum_{i=1}^{\alpha_3} \|d_{r_i}\| + \\ & \omega_3 \sum_{i=1}^{\alpha_4} (\|m_{r_i}\| + \|d_{r_i}\|) + \omega_4 \sum_{i=1}^Y (\|m_{c_i}\| + \|d_{c_i}\|) \end{aligned} \quad (7)$$

式中: Z 、 Y 分别为保护和断路器的总数; α_1 、 α_2 、 α_3 和 α_4 分别表示线路保护、母线保护、变压器保护和失灵保护的数量, 并满足等式 $\alpha_1 + \alpha_2 + \alpha_3 = Z$ 和 $\alpha_4 = Y$; ω_{11} 、 ω_{12} 、 ω_{13} 、 ω_3 、 ω_4 、 ω_{21} 、 ω_{22} 和 ω_{23} 均为权值; 符号“ $\|\cdot\|$ ”表示向量中的元素进行绝对值求和运算。

考虑到保护和断路器拒动和误动以及告警信息误报和漏报的实际发生概率, 并结合 2000—2004 年中国电网继电保护与安全自动装置运行情况的统计数据^[17-18], 式(7)中的权值取值如下: ω_{11} 、 ω_{12} 和 ω_{13} 分别为 1.16、12.59 和 5.32; ω_{21} 、 ω_{22} 和 ω_{23} 分别为 0.09、3.46 和 0.46; ω_3 为 0.8; ω_4 为 0.5。

2 基于改进算法的故障诊断

2.1 增益共享知识算法

GSK 算法的灵感来源于人类一生中知识获取和共享过程。在 GSK 算法中, 第 t 次迭代时规模为 N 、总维数为 W 的群体 P_{op} 被描述为

$$\begin{cases} P_{op} = \{x'_1, x'_2, \dots, x'_N\} \\ x'_i = [x'_{i,1}, x'_{i,2}, \dots, x'_{i,W}], i = 1, 2, \dots, N \end{cases} \quad (8)$$

GSK 算法的知识获取和共享具体分为初级阶段和高级阶段。在初级阶段中,个体首先根据目标函数值按升序排列。之后,对于目标个体 x'_i ,一方面,它从距离其最近的两个个体 x'_{i-1} 和 x'_{i+1} 中获得知识,另一方面,将从群体中随机选择个体 x'_r 作为共享知识的来源。个体 x'_i 中在该阶段中的数值更新如式(9)所示。

$$x'_i = \begin{cases} x'_i + k_f \times [(x'_{i-1} - x'_{i+1}) + (x'_r - x'_i)], & \text{if } f(x'_r) < f(x'_i) \\ x'_i + k_f \times [(x'_{i-1} - x'_{i+1}) + (x'_i - x'_r)], & \text{if } f(x'_r) \geq f(x'_i) \end{cases} \quad (9)$$

式中: k_f 为知识系数; $f(\cdot)$ 为单一个体所对应的目标函数值。

种群中的个体按照相应目标函数值的大小进行排列(目标函数值越小,相应的个体越优),因此,当目标个体为群体中的最优个体 x'_1 时,种群中排名第二的个体 x'_2 等同于 x'_{i-1} ,排名第三的个体 x'_3 等同于 x'_{i+1} 。若目标个体为最差个体 x'_N 时,排名倒数第二的个体 x'_{N-1} 和排名倒数第三的个体 x'_{N-2} 被选为距离其最近的个体。

在高级阶段中,按升序对所有个体进行排序后,将种群划分为 3 个层次,即最优、中间和最差。其中,最优和最差层次均包含 $p \times N$ ($p \in [0,1]$) 个个体,其余 $(1-2p) \times N$ 个个体属于中间层次。对于个体 x'_i ,它从属于不同层次的 3 个随机个体中获得知识,表达式如式(10)所示。

$$x'_i = \begin{cases} x'_i + k_f \times [(x'_b - x'_w) + (x'_m - x'_i)], & \text{if } f(x'_m) < f(x'_i) \\ x'_i + k_f \times [(x'_b - x'_w) + (x'_i - x'_m)], & \text{if } f(x'_m) \geq f(x'_i) \end{cases} \quad (10)$$

式中, x'_b 、 x'_w 和 x'_m 分别表示算法从最优层次、最差层次和中间层次中选择的个体。

在 GSK 算法中,个体中的一些维度 (W_{jp}) 在初级阶段进行更新,而其余维度 (W_{sp}) 选择在高级阶段中进行更新,计算公式如式(11)和式(12)所示。

$$W_{jp} = \left(1 - \frac{g_{en}}{G_{en}}\right)^K \times W \quad (11)$$

$$W_{sp} = W - W_{jp} \quad (12)$$

式中: W 为单一个体的总维数; K 为知识率; g_{en} 为当前迭代次数; G_{en} 为最大迭代次数。

GSK 算法的流程步骤如下。其中, r_{and} 为均匀分布在 $[0,1]$ 中的随机数, k_r 作为知识比率,用于保

留从目标个体中所继承到的知识量, $k_r \in [0,1]$ 。

Step1: 初始化种群 P_{op} 和参数。

Step2: 计算个体的目标函数值,按升序排列。

Step3: 分别使用式(11)和式(12)计算出初级阶段和高级阶段中的维度 W_{jp} 和 W_{sp} 。

Step4: 若 r_{and} 小于 k_r , 则进入 Step5, 反之, 进入 Step6。

Step5: 若 r_{and} 小于 W_{jp}/W , 则代入式(9)生成 $x'_{new,i}$, 反之, $x'_{new,i}$ 的生成将依赖于式(10)。完成更新之后进入 Step7。

Step6: 令 $x'_{new,i} = x'_i$ 。

Step7: 计算新个体的目标函数值,根据精英选择策略保留 x'_i 与 $x'_{new,i}$ 之间的优胜者。

Step8: 计算个体的目标函数值,按升序排列。

Step9: 若达到最大迭代次数,则输出最优个体,反之,返回 Step2, 进入下一迭代。

2.2 改进算法

GSK 算法虽然能够解决连续空间上的优化问题,但不能直接应用于离散空间。因此,为了更有效地解决离散优化问题,本文提出 IBGSK 算法。

在 IBGSK 算法中,将知识系数 k_f 设为 1,从而使得个体直接在二进制空间中进行更新,避免了使用传递函数可能带来的空间脱节风险,以免错失重要信息。由于个体在不同阶段获取和共享知识的途径不同,因此根据不同个体的目标函数值大小,离散工作机制可以具体分为以下 4 种情况。

在初级阶段中,基于式(9),对个体 x'_i 与 x'_r 的目标函数值 $f(x'_i)$ 和 $f(x'_r)$ 进行数值大小比较。

情况 1: 当 $f(x'_r)$ 小于 $f(x'_i)$ 时,算法中共有 3 个变量 ($x'_{i-1,j}$, $x'_{i+1,j}$, $x'_{r,j}$), 其中,变量 j 的取值范围为 $[1,W]$ 。由于这些变量只能取值为 1 或 0,所以会有 2^3 种组合可以实现。将这些组合代入式(9)中的第一个子式中,得到相应的数值结果。本文对所得到的数值结果进行修正处理(数值结果大于 1,将其等价于 1;数值结果小于 0,将其等价于 0),进而完成个体元素的数值更新。具体信息如表 1 所示。

由表 1 可知,当 $x'_{i-1,j} = x'_{i+1,j}$ 时,最终的修正结果等于 $x'_{r,j}$ 。当 $x'_{i-1,j}$ 与 $x'_{i+1,j}$ 相异时,经过修正后的结果与 $x'_{i-1,j}$ 相等。因此,在情况 1 下的单一元素数值更新表达式如式(13)所示。

$$x'_{new,i,j} = \begin{cases} x'_{r,j}, & \text{if } x'_{i-1,j} = x'_{i+1,j} \\ x'_{i-1,j}, & \text{if } x'_{i-1,j} \neq x'_{i+1,j} \end{cases} \quad (13)$$

表 1 情况 1 的组合结果

Table 1 Combination results for case 1

$x'_{i-1,j}$	$x'_{i+1,j}$	$x'_{r,j}$	数值结果	修正结果
0	0	0	0	0
0	0	1	1	1
1	1	0	0	0
1	1	1	1	1
1	0	0	1	1
1	0	1	2	1
0	1	0	-1	0
0	1	1	0	0

情况 2: 当 $f(\mathbf{x}'_r)$ 大于或等于 $f(\mathbf{x}'_i)$ 时, 由于有 4 个变量 ($x'_{i-1,j}, x'_{i,j}, x'_{i+1,j}, x'_{r,j}$), 所以会有 2^4 种组合可以实现。将这些组合代入式(9)中的第二个子式中, 所得到的数据信息具体如表 2 所示。

表 2 情况 2 的组合结果

Table 2 Combination results for case 2

$x'_{i-1,j}$	$x'_{i,j}$	$x'_{i+1,j}$	$x'_{r,j}$	数值结果	修正结果
1	1	0	0	3	1
1	0	0	0	1	1
0	1	1	1	0	0
0	0	1	1	-2	0
0	0	0	0	0	0
0	1	0	0	2	1
0	0	1	0	-1	0
0	0	0	1	-1	0
1	0	1	0	0	0
1	0	0	1	0	0
0	1	1	0	1	1
0	1	0	1	1	1
1	1	1	0	2	1
1	0	1	1	-1	0
1	1	0	1	2	1
1	1	1	1	1	1

由表 2 可知, 当 $x'_{i-1,j}$ 不等于 $x'_{i+1,j}$ 且 $x'_{i+1,j}$ 等于 $x'_{r,j}$ 时, 新个体中的单一元素 $x'_{\text{new},i,j} = x'_{i-1,j}$ 。在其余情况下, $x'_{\text{new},i,j} = x'_{i,j}$ 。因此, 在该情况下的单一元素数值更新表达式如式(14)所示。

$$x'_{\text{new},i,j} = \begin{cases} x'_{i-1,j}, & \text{if } x'_{i-1,j} \neq x'_{i+1,j} \text{ 且 } x'_{i+1,j} = x'_{r,j} \\ x'_{i,j}, & \text{otherwise} \end{cases} \quad (14)$$

在高级阶段中, 将基于式(10), 比较个体 \mathbf{x}'_i 与 \mathbf{x}'_m 的目标函数值 $f(\mathbf{x}'_i)$ 和 $f(\mathbf{x}'_m)$ 的数值大小。

情况 3: 当 $f(\mathbf{x}'_m)$ 小于 $f(\mathbf{x}'_i)$ 时, ($x'_{b,j}, x'_{m,j}, x'_{w,j}$) 作为算法中的变量, 其有 2^3 种组合可以实现。将这些组合代入式(10)中的第一个子式中, 所得到的数据信息具体如表 3 所示。

表 3 情况 3 的组合结果

Table 3 Combination results for case 3

$x'_{b,j}$	$x'_{w,j}$	$x'_{m,j}$	数值结果	修正结果
0	0	0	0	0
0	0	1	1	1
1	1	0	0	0
1	1	1	1	1
1	0	0	1	1
1	0	1	2	1
0	1	0	-1	0
0	1	1	0	0

由表 3 可知, 当 $x'_{b,j} = x'_{w,j}$ 时, 新个体中的单一元素 $x'_{\text{new},i,j} = x'_{m,j}$ 。当 $x'_{b,j}$ 与 $x'_{w,j}$ 相异时, 经过修正后的结果与 $x'_{b,j}$ 相等。该情况所对应的元素更新数学表达式如式(15)所示。

$$x'_{\text{new},i,j} = \begin{cases} x'_{m,j}, & \text{if } x'_{b,j} = x'_{w,j} \\ x'_{b,j}, & \text{if } x'_{b,j} \neq x'_{w,j} \end{cases} \quad (15)$$

情况 4: 当 $f(\mathbf{x}'_m)$ 大于或等于 $f(\mathbf{x}'_i)$ 时, 会有 4 个变量 ($x'_{b,j}, x'_{m,j}, x'_{w,j}, x'_{i,j}$), 一共包含了 2^4 种组合, 将这些组合代入式(10)中的第二个子式中, 所得到的数据信息具体如表 4 所示。

表 4 情况 4 的组合结果

Table 4 Combination results for case 4

$x'_{b,j}$	$x'_{i,j}$	$x'_{w,j}$	$x'_{m,j}$	数值结果	修正结果
1	1	0	0	3	1
1	0	0	0	1	1
0	1	1	1	0	0
0	0	1	1	-2	0
0	0	0	0	0	0
0	1	0	0	2	1
0	0	1	0	-1	0
0	0	0	1	-1	0
1	0	1	0	0	0
1	0	0	1	0	0
0	1	1	0	1	1
0	1	0	1	1	1
1	1	1	0	2	1
1	0	1	1	-1	0
1	1	0	1	2	1
1	1	1	1	1	1

由表 4 可知, 当 $x'_{b,j}$ 不等于 $x'_{w,j}$ 且 $x'_{m,j}$ 等于 $x'_{w,j}$ 时, 新个体中单一元素 $x'_{\text{new},i,j}$ 的取值等同于 $x'_{b,j}$ 。在其余情况下, $x'_{\text{new},i,j}$ 的取值与 $x'_{i,j}$ 相等。此情况下的更新如式(16)所示。

$$x'_{\text{new},i,j} = \begin{cases} x'_{b,j}, & \text{if } x'_{b,j} \neq x'_{w,j} \text{ 且 } x'_{w,j} = x'_{m,j} \\ x'_{i,j}, & \text{otherwise} \end{cases} \quad (16)$$

EPD 作为一种优化思想,其首先根据个体的目标函数值将种群平均地划分为最优子种群和最差子种群。之后,基于最优子种群中的个体,采用不同的策略来重新定义最差子种群,以达到加快收敛速度的目的^[19]。文献[20]共提出 4 种基于 EPD 的优化策略来缓解传统算法的过早收敛问题。由于这些策略过分依赖于最优子种群的领导能力,导致算法在问题空间中无法进行高效的搜索。为了克服这一不足,本文首先随机选取最优子种群中的优秀个体。随后,将该个体与最差子种群中的个体进行自适应交叉来生成新个体。

在迭代初期,倾向于保留优秀个体中的元素有助于算法进行全局勘探。当处于迭代后期时,原始个体中的元素被更多地保留下来有利于算法进行局部开发,以期寻到最优解。更新公式如式(17)所示。

$$x_j = \begin{cases} x_j, & \text{if } r_{\text{and}} \leq \varepsilon \\ x_j^{\text{nice}}, & \text{otherwise} \end{cases} \quad (17)$$

式中: x_j 和 x_j^{nice} 分别为原始个体和优秀个体中第 j 维度的数值; ε 为交叉率,如式(18)所示。

$$\varepsilon = (0.5 + \theta) - \frac{2\theta}{1 - e^{-\frac{5 \cdot 10 \text{gen}}{G_{\text{en}}}}} \quad (18)$$

式中, θ 为控制参数,控制着交叉率的变化趋势。

图 1 给出了 3 种不同控制参数下的交叉率变化曲线。

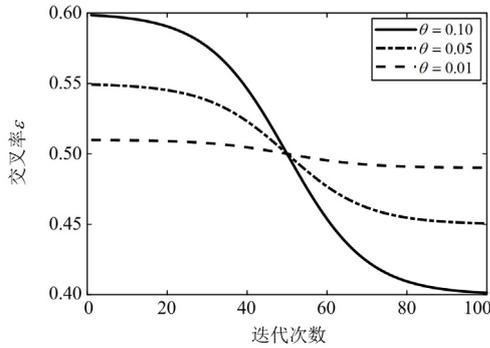


图 1 不同控制参数下的交叉率

Fig. 1 Crossover rate under different control parameters

2.3 改进算法的性能评估

为了综合评估改进算法的性能和求解优势,本文采用特征选择问题作为测试和比较分析的基准。特征选择问题是指在给定数据集的情况下,通过选择出与目标类别具有最低内部相似性和最高相关性的特征子集,来提高分类精度并最大限度地降低错误率。其目标是通过去除无用、不相关或者冗余的特征,为后续的建模和预测提供更好的输入。

假设 A 是具有 m 个实例和 l 个特征的原始数据集, L 为包含 l 个特征的向量。特征选择的工作机制是从 L 中选择最优特征子集,以优化特定的指标函数 $F(X)$, 特征选择问题的数学表达式如式(19)所示。

$$\begin{aligned} & \max \text{ or } \min F(X) \\ & \text{s.t. } X = (x_{i,1}, \dots, x_{i,j}, \dots, x_{i,l}); \text{ where } x_{i,j} \in \{0,1\} \end{aligned} \quad (19)$$

式中, $x_{i,j} = 1$ 或 $x_{i,j} = 0$ 分别意味着第 i 个实例中的第 j 个特征被选中或者未被选中。

本研究将 LOBGSK 算法、IBGSKM 算法、DSBPSO 算法和 IBGSK 算法作为搜索算法,并使用 K-最近邻(k-nearest neighbor, KNN)算法^[21-22]进行特征评估和分类预测。为了从给定数据集中挑选出最佳的特征子集,使用评价标准 Z 来对不同的子集进行评价,其数学表达式为

$$\min Z = \gamma_1 E_{\text{Rate}} + \gamma_2 \frac{n_{\text{selected}}}{n_{\text{total}}} \quad (20)$$

式中: E_{Rate} 为使用 KNN 算法计算时的分类错误率; γ_1 和 γ_2 是对应于评价标准的两个参数,并且满足 $\gamma_1 \in [0,1]$ 和 $\gamma_2 = 1 - \gamma_1$, 本文将 γ_1 取为 0.99; n_{selected} 为被选择特征数; n_{total} 为特征总数。

算法对取自 UCI 机器学习库中的 3 个数据集进行特征选择。各数据集的信息如表 5 所示。

表 5 基准数据集的基本信息

Table 5 Basic information about the baseline dataset		
数据集	样本数	特征数
zoo	101	16
ionosphere	351	34
M-of-n	1000	13

在本文研究中,各搜索算法均独立运行 30 次,并通过计算以下指标来评估算法的性能和优势。

1) 平均目标函数值:表示算法独立运行 M 次所获得最佳目标函数值的平均值 a_{value} ,如式(21)所示。

$$a_{\text{value}} = \frac{1}{M} \sum_{i=1}^M Z_i^* \quad (21)$$

式中, Z_i^* 表示在第 i 次运行下的最佳目标函数值。

2) 平均分类精度:表示算法独立运行 M 次所获得最佳分类精度的平均值。设在第 i 次运行中,算法所得到的最佳分类精度为 A_{cct}^* ,则平均分类精度 a_{accuracy} 的计算如式(22)所示。

$$a_{\text{accuracy}} = \frac{1}{M} \sum_{i=1}^M A_{\text{cct}}^* \quad (22)$$

3) 平均选择特征数:表示算法独立运行 M 次所获得选择特征数的平均值。设在第 i 次运行中,算法所得到的最优解为 x_i^* ,则平均选择特征数 a_{feature} 的计算如式(23)所示。

$$a_{\text{feature}} = \frac{1}{M} \sum_{i=1}^M \frac{\text{sum}(x_i^*)}{l} \quad (23)$$

算法的基本参数设置：群体规模 N 为 5；最大迭代次数 G 为 70；知识率 K 为 10；知识比率 k_r 为 0.1； p 为 0.1。此外，IBGSKM 算法、DSBPSO 算法和 IBGSK 算法中的特有参数取值如表 6 所示。

表 6 各个算法的特有参数

算法	参数	数值
IBGSKM	突变概率 ϕ	0.01
DSBPSO	粘度 S	从 $T/10$ 线性递减至 0
	粘度因子 i_s	从 $10/W$ 线性递减至 0
IBGSK	控制参数 θ	0.05

表 6 中， T 表示最大迭代次数。

算法的测试环境为：Windows11 操作系统；Intel(R) AMD Ryzen 7 4800H 处理器；16 GB 内存；Matlab 编程语言；Matlab 2020b 开发环境。

表 7 给出了 4 种算法在不同数据集上所得到的平均目标函数值。

表 7 平均目标函数值的比较

数据集	LOBGSK	IBGSKM	DSBPSO	IBGSK
zoo	0.0715	0.0922	0.0827	0.0620
ionosphere	0.0614	0.0671	0.0604	0.0469
M-of-n	0.0358	0.0614	0.0165	0.0094

由表 7 可知，相较于对比算法，IBGSK 算法在 3 种数据集上均取得了最小的平均目标函数值，从而说明 IBGSK 算法具有更强的寻优能力。

表 8 给出了 4 种算法在不同数据集上获得的平均分类精度。

表 8 平均分类精度的比较

数据集	LOBGSK	IBGSKM	DSBPSO	IBGSK
zoo	0.9320	0.9111	0.9203	0.9412
ionosphere	0.9410	0.9348	0.9414	0.9548
M-of-n	0.9689	0.9434	0.9883	0.9953

由表 8 可知，相较于其余 3 种算法，IBGSK 算法在 3 种数据集上始终保持着更高的平均分类精度，这意味着它能够在测试子集上产生更准确的分类预测结果，具有更强的泛化能力。

表 9 给出了 4 种算法在 3 种不同数据集上所得到的平均选择特征数。

由于进行特征选择实验所需的计算时间和资源与选择的特征数量相关，所以平均选择特征数能够

较好地反映出算法的计算效率。根据表 9 的数据可知，相较于其余 3 种对比算法，IBGSK 算法在 3 种数据集上具有最小的平均选择特征数和最高的计算效率。

表 9 平均选择特征数的比较

数据集	LOBGSK	IBGSKM	DSBPSO	IBGSK
zoo	6.6880	6.7024	6.0752	6.0608
ionosphere	9.8670	8.4216	7.8738	7.1016
M-of-n	7.0154	7.5124	6.8838	6.6458

2.4 故障诊断流程

基于 IBGSK 算法的故障诊断流程如下所示。

Step1: 根据上传到 SCADA 系统中的告警信息，以确定可疑故障元件集以及相关保护的和断路器，进而构建出计及完备故障信息的解析模型。

Step2: 初始化二进制种群 P_{op} ，每个个体对应一种故障场景，并设置算法中的相关参数。

Step3: 计算所有个体的目标函数值，并按升序排列。

Step4: 根据式(11)和式(12)分别计算 W_{jp} 和 W_{sp} 。

Step5: 若 $r_{and} < k_r$ ，则进入 Step6，反之，进入 Step7。

Step6: 若 $r_{and} < W_{jp}/W$ ，将比较 $f(x'_i)$ 和 $f(x'_r)$ ，并根据式(13)和式(14)来生成 $x'_{new,i,j}$ ，反之，比较 $f(x'_i)$ 和 $f(x'_m)$ ，根据式(15)和式(16)来更新个体。完成更新之后进入 Step8。

Step7: 令 $x'_{new,i} = x'_i$ 。

Step8: 计算新个体的目标函数值，根据精英保留策略选出 x'_i 和 $x'_{new,i}$ 之间的优胜者。

Step9: 计算所有个体的目标函数值，按升序排列，并根据 EPD 思想，通过自适应交叉算子来重新定义最差子种群。

Step10: 若达到最大迭代次数，则输出最优个体，反之，返回 Step3，进入下一代周期。

Step11: 对输出的最优解进行动作逻辑分析，在得到故障元件的同时，也对保护和断路器的动作和告警信息进行了评判。

3 系统仿真

3.1 参数设置

本文利用 LOBGSK 算法、IBGSKM 算法、IBGSK 算法和 DSBPSO 算法，在测试电网和实际电网的不同故障场景下，进行诊断对比仿真实验。以故障诊断结果和结论、目标函数值、达到收敛的

最小迭代次数以及平均诊断运行时间作为算法诊断性能的评估指标。参数设置如下： N 和 G 分别为30和500,其余参数的取值和测试环境与2.3节中设置的相同。

3.2 测试电网

测试电网由12条母线(A1—A4和B1—B8)、8条输电线路(L1—L8)、8台变压器(T1—T8)和40个断路器(CB1—CB40)组成。并配置了相应的保护。此外,本文用下标“m”、“p”、“s”和“f”来分别代表主保护、近后备保护、远后备保护和断路器失灵保护,S和R分别表示线路的送端和受端。该电网的拓扑结构如图2所示。

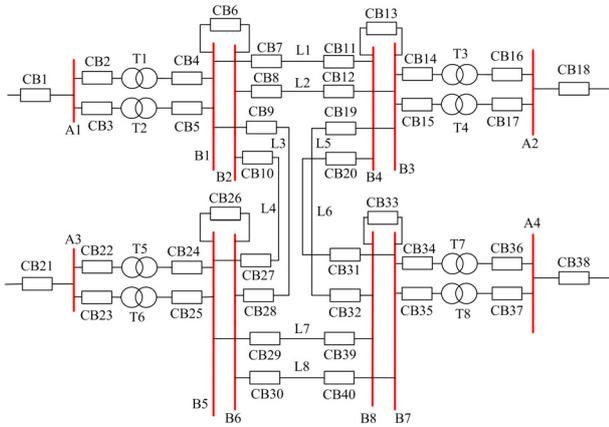


图2 测试电网
Fig. 2 Test grid

本文给出了在该测试电网下考虑到故障发生时可能会出现故障场景,具体信息如表10所示。

表10 测试电网的故障场景

Table 10 Fault scenarios of test grid

故障场景	告警信息	实际故障情况
1-1	B2 _m , T3 _m , T3 _p , CB4, CB6, CB8, CB10, CB12, CB13, CB16, CB19, CB27	B2、T3故障; T3 _p 误报; CB27误动; CB14 _f 漏报; CB14拒动
1-2	A3 _m , B6 _m , CB21, CB22, CB23, CB24, CB25, CB27, CB28, CB29, CB30	A3、B6故障; CB26拒动; CB26 _f 漏报

利用4种算法多次独立求解不同故障场景对应的目标函数式(7),然后根据故障诊断规则,分析所得到的解,并将相应的诊断结果和结论整理如表11所示。

由表11可知,4种诊断算法在诊断出故障部件的同时,也对保护和断路器的状态进行了评价。

在故障场景1-1下,4种诊断算法均取得了与实际相符且目标函数值为3的诊断结果和结论。

表11 测试电网的诊断结果和结论

Table 11 Diagnosis results and conclusions of the test grid

场景	诊断结果和结论			
	LOBGSK	IBGSKM	IBGSK	DSBPSO
1-1	B2,T3故障; T3 _p 误报; CB27误动; CB14 _f 漏报; CB14拒动			
1-2	A3,B6故障; CB26拒动; CB26 _f 漏报	A3,B6故障; CB26拒动; CB26 _f 漏报	A3,B6故障; CB26拒动; CB26 _f 漏报	①A3,B6故障; CB26拒动; CB26 _f 漏报 ②A3,B5,B6故障; B5 _m 漏报; CB26漏报

在故障场景1-2下,4种诊断算法通过式(7)均可以寻到诊断结果、结论与实际故障情况相符的对应解,其目标函数值 I 为1.5。此外,在该故障场景进行单次诊断时,DSBPSO算法还有可能得到符合动作逻辑且目标函数值为2的额外诊断结果和结论。这一方面说明DSBPSO算法在寻优能力方面相对于其他3种算法存在不足,在相同解析模型的前提下,其有可能得到对应的目标函数值大于其余3种算法的诊断结果和结论;另一方面说明目标函数式(7)在进行诊断时存在着缺陷,即相对权值大小影响算法的寻优结果。通过DSBPSO算法诊断所得到的两种故障场景,它们对应的目标函数值表达式如式(24)所示。

$$\begin{cases} I_1 = 1 + \omega_4 \\ I_2 = 1 + 1 = 2 \end{cases} \quad (24)$$

由式(24)可知,当与断路器误动和拒动相关联的权值 ω_4 取0.5时, I_1 小于 I_2 。因此,优化算法趋向于输出 I_1 所对应的诊断结果和结论。

诊断运行时间和达到收敛所需的最小迭代次数分别反映了算法的时效性和收敛性,及时地诊断出故障,可以避免发生更大的电力损失。因此,本文也将它们作为评估诊断性能的指标。表12记录了各算法独立运行多次实验所对应的平均诊断运行时间。

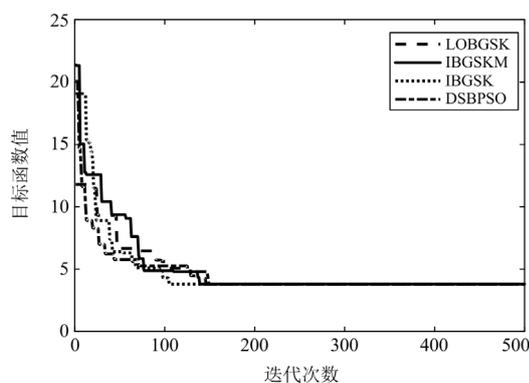
表12 测试电网的平均诊断运行时间

Table 12 Average diagnostic run times of test grid

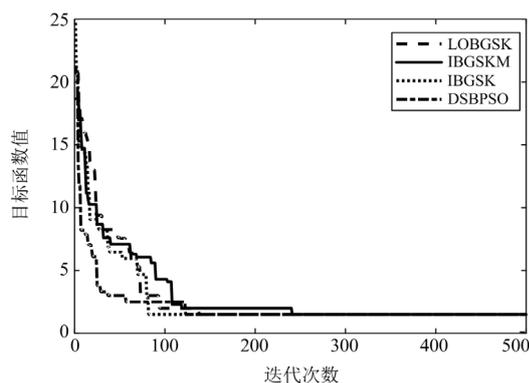
故障场景	s			
	LOBGSK	IBGSKM	IBGSK	DSBPSO
1-1	5.724	5.905	0.886	3.520
1-2	5.665	5.947	0.818	3.603

由表 12 可知, 在两种故障场景中, IBGSK 算法的平均诊断运行时间最短。DSBPSO 算法、LOBGSK 算法和 IBGSKM 算法所需的时间依次增加, 因此, IBGSK 算法具有更好的时效性。

图 3 给出了各算法所得诊断结果和结论与实际故障情况相符的目标函数值收敛曲线。



(a) 故障场景1-1



(b) 故障场景1-2

图 3 测试电网收敛曲线

Fig. 3 Convergence curves of the test grid

由图 3 可知, IBGSK 算法在两种故障场景下, 均需要进行 100 次左右的迭代即可达到收敛。LOBGSK 算法和 DSBPSO 算法对应的最小收敛迭代次数均介于 100~200 之间。而 IBGSKM 算法在故障场景 1-2 下的最小迭代次数明显大于 200。这证明了相较于传统算法, 本文所提出的改进算法具有更显著的问题空间搜索效率。

为了进一步验证算法在测试电网中的诊断性能, 本文将故障场景 1-2 下 DSBPSO 算法所诊断出的额外故障场景预设为一故障场景, 并将式(7)中的权值 ω_4 特定取值为 1.2, 再次进行求解, 进而分析各算法的诊断表现。

表 13 统计了各诊断算法对该故障场景进行多

次独立诊断时, 诊断正确的概率以及相应的平均目标函数值。由表可知, IBGSK 算法在问题空间中的寻优能力强于对比算法, 其他算法均有可能找到目标函数值大于预设的额外故障场景。

表 13 概率和平均目标函数值

Table 13 Probability and average objective function values

	LOBGSK	IBGSKM	IBGSK	DSBPSO
概率	0.99	0.97	1.00	0.63
平均目标函数值	2.0020	2.0180	2.0000	2.0700

表 14 为各个诊断算法对预设故障场景独立实验, 所得到的诊断运行时间。由表可知, IBGSK 算法的所需诊断时间最短, 因此具有更高的问题解决效率。

表 14 平均诊断运行时间

Table 14 Average diagnostic run time

	LOBGSK	IBGSKM	IBGSK	DSBPSO
时间/s	5.747	5.910	0.879	3.587

图 4 给出了各个诊断算法在预设故障场景下, 取得诊断结果、结论与预设相一致的目标函数值收敛曲线。由图可知, 相较于对比算法, IBGSK 算法达到收敛所需的最小迭代次数为最少, 具有更快的收敛速度。

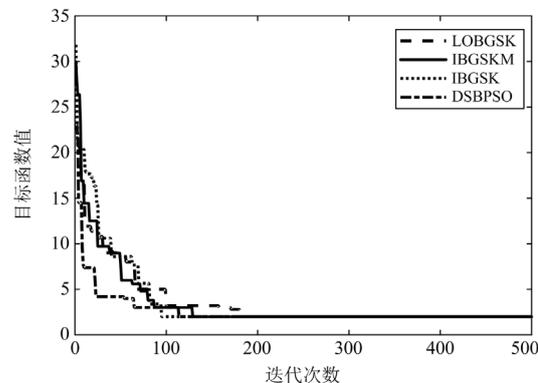


图 4 额外故障场景的收敛曲线

Fig. 4 Convergence curve for additional fault scenarios

3.3 实际电网

为了进一步验证算法在解决电网故障诊断问题上的有效性, 本文分析了在实际电网中出现的两种故障场景, 并进行多次独立诊断实验。该电网的拓扑结构如图 5 所示。

该电网由 11 条母线、16 条输电线路、4 台变压器和 40 个断路器组成, 并配备相应的主保护、后备保护和断路器失灵保护。

在该实际电网中, 两种故障场景中的具体告警

信息如表 15 所示。

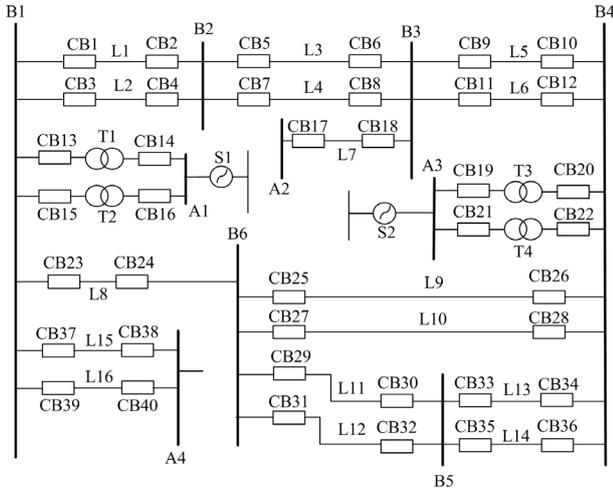


图 5 实际电网
Fig. 5 Physical grid

表 15 实际电网的故障场景

Table 15 Fault scenarios of the physical grid

故障场景	告警信息	实际故障情况
2-1	L1 _{sm} , L1 _{rp} , L5 _{rs} , L6 _{sp} , L6 _{rm} , L7 _{ss} , B3 _m , CB1, CB4, CB5, CB6, CB7, CB8, CB10, CB11, CB12, CB17	B2, B3, L1, L6 故障; L1 _{rm} 、L6 _{rm} 拒动; B2 _m 漏报; CB2、 CB9 和 CB18 拒动
2-2	L8 _{ss} , B6 _m , L9 _{sm} , L9 _{rp} , L10 _{sm} , L10 _{rm} , CB23, CB25, CB26, CB27, CB28	B6, L9, L10 故障; CB24 拒动; L9 _{rm} 拒动; CB24 _r 拒动

表 16 具体给出了 4 种算法的诊断结果和结论。由表可知，在故障场景 2-1 下，4 种诊断算法通过目标函数式(7)均可以寻得诊断结果、结论与实际故障情况相符的对应解，其目标函数值为 2.68。此外，在对该故障场景进行单次诊断时，LOBGSK 算法还可能得到多种目标函数值大于 2.68 的额外故障场景。由于调度中心未收到与额外故障元件(L2、L3、L4、L5、L7 其中的任意一个元件)相关联的任何保护告警信息，因此在理论上，这些保护信息存在动作过程中发生拒动或者正常动作但在信息传输过程中发生漏报的可能性。

随着失效检测和检修技术的不断进步，继电保护的正確动作率也在不断提高^[23]。以 2007 年为例，国家电网公司 220 kV 及以上系统继电保护装置正确动作率已经达到了 99.88%^[24]。所以若某元件发生故障，其主保护和后备保护均拒动的可能性非常低。另一方面，在这些额外故障场景所生成的对应解中，相关保护所对应的告警信息错误合集 e_i 没有发出警告 ($e_i = 0$)，这与漏报相矛盾，存在逻辑错误。

因此，LOBGSK 算法得出的额外故障场景均不符合实际情况，具有较低的诊断可靠性。

表 16 实际电网的诊断结果和结论

Table 16 Diagnosis results and conclusions of the actual grid

场 景	诊断结果和结论			
	LOBGSK	IBGSKM	IBGSK	DSBPSO
2-1	① B2, B3, L1, L6 故障; L1 _{rm} , L6 _{rm} 拒动; B2 _m 漏报; CB2, CB9 和 CB18 拒动	B2, B3, L1, L6 故障; L1 _{rm} , L6 _{rm} 拒动; B2 _m 漏报; CB2, CB9 和 CB18 拒动	B2, B3, L1, L6 故障; L1 _{rm} , L6 _{rm} 拒动; B2 _m 漏报; CB2, CB9, CB18 拒动	① B2, B3, L1, L6 故障; L1 _{rm} , L6 _{rm} 拒动; B2 _m 漏报; CB2, CB9 和 CB18 拒动
	② B2, B3, L1, L6 以及 L2, L3, L4, L5, L7 其中的一个元件故障; L1 _{rm} , L6 _{rm} 拒动; B2 _m 漏报; CB2, CB9 和 CB18 拒动	① B5, L9, L10 故障; CB24 拒动; L9 _{rm} , CB24 _r 拒动	② B5, L8, L9, L10 故障; CB24 拒动; L9 _{rm} , CB24 _r 拒动	② B3, L1, L6 故障; L1 _{rm} , L6 _{rm} 拒动; L1 _{rm} , L6 _{rm} 拒动; CB2, CB9 和 CB18 拒动
2-2	① B5, L9, L10 故障; CB24 拒动; L9 _{rm} , CB24 _r 拒动	② B5, L8, L9, L10 故障; CB24 拒动; L9 _{rm} , CB24 _r 拒动	① B5, L9, L10 故障; CB24 拒动; L9 _{rm} , CB24 _r 拒动	① B5, L9, L10 故障; CB24 拒动; L9 _{rm} , CB24 _r 拒动

DSBPSO 算法能够获得目标函数值为 3.18，同时符合动作逻辑的额外诊断结果和结论。这一方面说明了在相同诊断模型的前提下，DSBPSO 算法的寻优能力弱于 IBGSK 算法。另一方面也再次证实了目标函数式(7)存在缺陷。目标函数值分别为 2.68 和 3.18 所对应的数值表达式，如式(25)所示。

$$\begin{cases} I_1 = 1 + 2\omega_{21} + 2\omega_4 \\ I_2 = 2\omega_{21} + 6\omega_4 \end{cases} \quad (25)$$

由式(25)可知，当与断路器误动和拒动相关联的权重 ω_4 取 0.5 时， $I_1 < I_2$ ，优化算法更倾向于得出与 I_1 相对应的诊断结果和结论。若 ω_4 小于 0.25，此时 $I_1 > I_2$ ，算法更倾向于得到元件 B3、L1 和 L6 发生故障的结论。

在故障场景 2-2 下，LOBGSK 算法和 IBGSKM 算法均有可能得到相同的额外故障场景(实际故障元件以及 L8)。调度中心没有收到关于 L8 送端的任何保护告警信息，考虑到主保护和后备保护均拒动的可能性非常小以及告警信息错误合集(误报和漏报)也没有发出警告，所以认定该故障场景也不符合

实际情况, 算法的诊断可靠性较低。

表 17 给出了 4 种算法运行多次所得到的平均诊断运行时间。

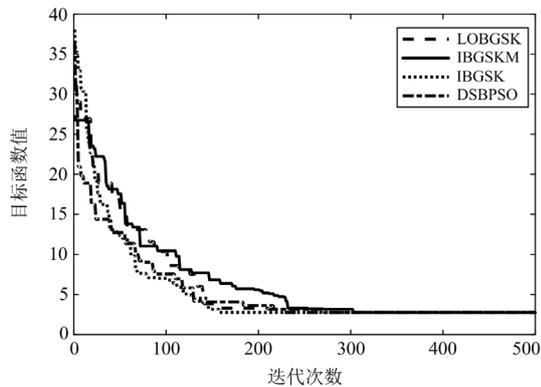
表 17 实际电网的平均诊断运行时间

Table 17 Average diagnostic running time of physical grid

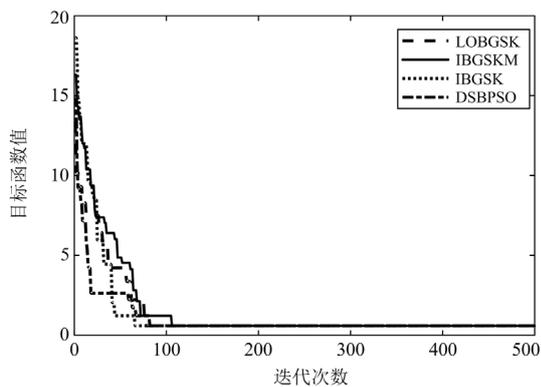
故障场景	LOBGSK	IBGSKM	IBGSK	DSBPSO
2-1	5.965	6.263	0.991	3.989
2-2	5.808	5.833	0.792	3.175

由表 17 可知, IBGSK 算法在实际电网的故障诊断中, 也能够保持良好的时效性。

图 6 给出了算法所得诊断结果、结论与实际故障场景相一致的目标函数值收敛曲线。通过分析可知, IBGSK 算法达到收敛的迭代次数为最小。



(a) 故障场景 2-1



(a) 故障场景 2-2

图 6 实际电网收敛曲线

Fig. 6 Convergence curves for the physical grid

为了进一步验证 IBGSK 算法在实际电网中的诊断性能, 本文将 DSBPSO 算法在故障场景 2-1 中所得到的额外故障场景单独作为预设定的故障场景, ω_4 特定更改为 0.2, 4 种算法再次进行诊断。

表 18 再次统计了在改进目标函数的前提下, 算

法诊断运行多次, 诊断正确的概率以及对应的平均目标函数值。

表 18 诊断正确概率和平均目标函数值

Table 18 Diagnostic correctness probability and average objective function values

	LOBGSK	IBGSKM	IBGSK	DSBPSO
概率	0.94	0.98	1.00	0.98
平均目标函数值	1.4250	1.3849	1.3800	1.3849

由表 18 可知, 在使用改进目标函数的前提下, IBGSK 算法具有更优的寻优能力。

表 19 给出了 4 种诊断算法在该故障场景下, 独立运行多次所得到的平均诊断运行时间。

表 19 平均诊断运行时间

Table 19 Average diagnostic running time

	LOBGSK	IBGSKM	IBGSK	DSBPSO
时间/s	6.794	7.017	1.320	4.216

通过表 19 可知, IBGSK 算法的诊断效率依然优于对比算法。

图 7 给出了各诊断算法所得的诊断结果和结论与预设故障情况相符的目标函数值收敛曲线。

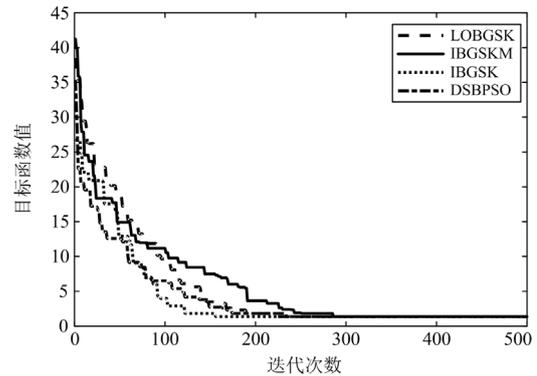


图 7 额外故障场景的收敛曲线

Fig. 7 Convergence curve for additional fault scenarios

通过分析图 7 中的收敛曲线可知, IBGSK 算法达到收敛所需要的最小迭代次数介于 100~200 之间, 而 LOBGSK 算法、IBGSKM 算法和 DSBPSO 算法达到收敛所需要的最小迭代次数均大于 200, 其中, IBGSKM 算法对应的最小迭代次数为最大。因此, 相比于对比算法, IBGSK 算法具有更快的收敛速度。

4 结论

本文提出一种改进的二进制增益共享知识算法, 用于求解电网故障诊断解析模型。首先将离散工作机制融入种群更新过程, 实现了个体在二进制

搜索空间中的直接更新,再结合 EPD 思想,集成一种自适应交叉算子,达到提高种群质量和强化算法全局搜索能力的目的。通过对 UCI 数据库进行特征选择实验,并与 LOBGSK、IBGSKM 和 DSBPSO 算法进行比较,结果表明,IBGSK 算法在寻优能力、分类精度和计算效率方面具备显著求解优势。此外,通过对比多种故障场景下的实验数据,表明了 IBGSK 算法在求解故障诊断解析模型时,具有更高的诊断准确率和效率,有效缩短了故障检查和恢复的时间,同时也指出本文所用解析模型存在权值大小影响诊断结果和结论的缺陷。

本文计划在以下几个工作方向上做进一步探究。首先,针对解析模型存在权值大小影响最终诊断结果和结论的问题,通过引入自适应参数,降低人工权值分配的影响。然后,将其他算法混合到 IBGSK 算法中,增强对问题空间的搜索强度。最后,扩展该算法的应用领域,以期有效解决更多类型的离散优化问题。

参考文献

- [1] 李亚光, 李蒙. 基于深度小世界神经网络的风电机组异常检测[J]. 发电技术, 2021, 42(3): 313-321.
LI Yaguang, LI Meng. Anomaly detection of wind turbines based on deep small-world neural network[J]. Power Generation Technology, 2021, 42(3): 313-321.
- [2] 青灿, 行舟, 智勇, 等. 基于 SVM 的变电站母线日净负荷曲线大数据识别方法[J]. 电力科学与技术学报, 2022, 37(6): 125-131.
QING Can, XING Zhou, ZHI Yong, et al. Big data recognition method for daily net load curve of substation bus based on SVM[J]. Journal of Electric Power Science and Technology, 2022, 37(6): 125-131.
- [3] 徐艳春, 赵彩彩, 孙思涵, 等. 基于改进 LMD 和能量相对熵的主动配电网故障定位方法[J]. 中国电力, 2021, 54(11): 133-143.
XU Yanchun, ZHAO Caicai, SUN Sihan, et al. Fault location for active distribution network based on improved LMD and energy relative entropy[J]. Electric Power, 2021, 54(11): 133-143.
- [4] 梅飞, 陈子平, 裴鑫, 等. 基于矩阵算法的有源配电网故障定位容错方法[J]. 电力工程技术, 2022, 41(6): 109-115.
MEI Fei, CHEN Ziping, PEI Xin, et al. Fault-tolerant method for fault location of active distribution network based on matrix algorithm[J]. Electric Power Engineering Technology, 2022, 41(6): 109-115.
- [5] 于昊正, 潘肇伦, 李科, 等. 基于模糊 Petri 网的配电网工程偏差指标诊断[J]. 中国电力, 2022, 55(7): 67-73.
YU Haozheng, PAN Zhaolun, LI Ke, et al. Diagnosis of deviation indicators of distribution network engineering based on fuzzy petri net[J]. Electric Power, 2022, 55(7): 67-73.
- [6] 段穰达. 有源配网后评价指标体系及其综合评价方法[J]. 发电技术, 2021, 42(1): 86-93.
DUAN Rangda. A post-evaluation index system of active distribution network project and its comprehensive evaluation method[J]. Power Generation Technology, 2021, 42(1): 86-93.
- [7] 李卫彬, 童欣, 黄超, 等. 基于分层定位模型的含 DG 配电网故障定位方法研究[J]. 电力系统保护与控制, 2022, 50(24): 160-166.
LI Weibin, TONG Xin, HUANG Chao, et al. A fault location method for a distribution network with DG based on a hierarchical location model[J]. Power System Protection and Control, 2022, 50(24): 160-166.
- [8] MOHAMED A W, HADI A A, MOHAMED A K. Gaining-sharing knowledge-based algorithm for solving optimization problems: a novel nature-inspired algorithm[J]. International Journal of Machine Learning and Cybernetics, 2020, 11(7): 1501-1529.
- [9] MOHAMED A W, HADI A A, MOHAMED A K, et al. Evaluating the performance of the adaptive gaining-sharing knowledge-based algorithm on CEC 2020 benchmark problems[C] // 2020 IEEE Congress on Evolutionary Computation (CEC), July 19-24, 2020, Glasgow, United Kingdom: 1-8.
- [10] AGRAWAL P, GANESH T, OLIVA D, et al. S-shaped and V-shaped gaining-sharing knowledge-based algorithm for feature selection[J]. Applied Intelligence, 2022, 52(1): 81-112.
- [11] AGRAWAL P, GANESH T, MOHAMED A W. A novel binary gaining-sharing knowledge-based optimization algorithm for feature selection[J]. Neural Computing & Applications, 2021, 33(11): 5989-6008.
- [12] XIONG G J, YUAN X, MOHAMED A W, et al. Fault section diagnosis of power systems with logical operation binary gaining-sharing knowledge-based algorithm[J]. International Journal of Intelligent Systems, 2022, 37(2): 1057-1080.
- [13] XIONG G J, YUAN X, MOHAMED A W, et al. Improved binary gaining-sharing knowledge-based algorithm with mutation for fault section location in distribution networks[J]. Journal of Computational Design and Engineering, 2022, 9(2): 393-405.
- [14] NGUYEN B H, XUB B, ANDREA P, et al. A new binary particle swarm optimization approach: momentum and dynamic balance between exploration and exploitation[J]. IEEE Transactions on Cybernetics, 2019, 51(2): 589-603.

- [15] 陈家超, 张勇军, 黄国权, 等. 计及保护和断路器告警信息可信度的电网故障诊断优化模型[J]. 电力系统保护与控制, 2021, 49(4): 28-36.
CHEN Jiachao, ZHANG Yongjun, HUANG Guoquan, et al. The optimal model of power grid fault diagnosis considering the reliability of protection and circuit breaker alarm information[J]. Power System Protection Control, 2021, 49(4): 28-36.
- [16] 刘道兵, 顾雪平, 李海鹏. 电网故障诊断的一种完全解析模型[J]. 中国电机工程学报, 2011, 31(34): 85-92.
LIU Daobing, GU Xueping, LI Haipeng. A complete analytic model for fault diagnosis of power systems[J]. Proceedings of the CSEE, 2011, 31(34): 85-92.
- [17] 周玉兰, 王玉玲, 赵曼勇. 2004 年全国电网继电保护与安全自动装置运行情况[J]. 电网技术, 2005, 29(16): 42-48.
ZHOU Yulan, WANG Yuling, ZHAO Manyong. Statistics of operation situation of protective relaying and automation devices of power systems of China in 2004[J]. Power System Technology, 2005, 29(16): 5-8.
- [18] 刘道兵, 顾雪平, 梁海平, 等. 电网故障诊断完全解析模型的解集评价与最优解求取[J]. 中国电机工程学报, 2014, 34(31): 5668-5676.
LIU Daobing, GU Xueping, LIANG Haiping, et al. Solution evaluation and optimal solution discrimination of a complete analytical model for power system fault diagnosis[J]. Proceedings of the CSEE, 2014, 34(31): 5668-5676.
- [19] THAER T, HAMOUDA C, JINGWEI T, et al. Boolean particle swarm optimization with various evolutionary population dynamics approaches for feature selection problems[J]. Expert Systems with Applications, 2022, 195(6): 1-30.
- [20] MAFARJA M, ALJARAHI I, HEIDARI A A, et al. Evolutionary population dynamics and grasshopper optimization approaches for feature selection problems[J]. Knowledge-Based Systems, 2018, 145(4): 25-45.
- [21] 唐登平, 蔡文嘉, 周翔宇, 等. 基于 VMD 和样本熵的电磁式电流互感器故障诊断[J]. 电力科学与技术学报, 2021, 36(6): 144-150.
TANG Dengping, CAI Wenjia, ZHOU Xiangyu, et al. Fault diagnosis of current transformer based on VMD and sample entropy[J]. Journal of Electric Power Science and Technology, 2021, 36(6): 144-150.
- [22] 陈茜, 李录平, 刘瑞, 等. 基于 PCA-KNN 融合算法的风力机变桨角度故障诊断方法[J]. 中国电力, 2021, 54(11): 190-198.
CHEN Xi, LI Luping, LIU Rui, et al. Fault diagnosis method of wind turbine pitch angle based on PCA-KNN fusion algorithm[J]. Electric Power, 2021, 54(11): 190-198.
- [23] 叶远波, 谢民, 陈晓东, 等. 基于故障率分析的继电保护系统状态检修策略[J]. 电力系统保护与控制, 2021, 49(7): 167-173.
YE Yuanbo, XIE Min, CHEN Xiaodong, et al. A condition-based maintenance strategy for a relay protection system based on failure probability analysis[J]. Power System Protection and Control, 2021, 49(7): 163-173.
- [24] 沈晓凡, 舒治淮, 刘宇, 等. 2007 年国家电网公司继电保护装置运行情况[J]. 电网技术, 2008, 32(16): 5-8.
SHEN Xiaofan, SHU Zhihuai, LIU Yu, et al. Operation situation of protective relaying of State Grid Corporation of China in 2007[J]. Power System Technology, 2008, 32(16): 5-8.

收稿日期: 2023-06-20; 修回日期: 2023-09-02

作者简介:

袁 泉(1998—), 男, 硕士研究生, 研究方向为电力系统故障诊断; E-mail: 3472645534@qq.com

周海峰(1970—), 男, 通信作者, 博士, 教授, 硕士生导师, 研究方向为智能信息处理、电力系统故障诊断等; E-mail: zhfeng216@163.com

黄金满(1982—), 男, 硕士, 高级工程师, 硕士生导师, 研究方向为新能源电力系统智能控制与应用及自动化系统。E-mail: anmaixin@163.com

(编辑 张颖)