

BPSO 优化算法在含 DG 配电网中的故障诊断研究

郭 兴, 徐 武, 唐文权, 文 聪
(云南民族大学 电气信息工程学院, 昆明 650500)

摘要: 针对含分布式电源 (distributed generation, DG) 的配电网故障检测, 传统的故障检测方法容易出现检测精度低、适用性差、容错力低等问题; 为此, 提出了一种改进的二进制粒子群算法 (binary particle swarm optimization, BPSO) 进行故障检测, 该算法是在 BPSO 算法的基础上, 重新对自适应度值进行定义确保种群寻找到最为准确的最优解, 解决 BPSO 算法容易陷入“早熟”的情况; 通过 IEEE33 节点进行仿真分析, 实验结果表明: 采用改进的 BPSO 算法可以有效对故障区段进行定位, 验证了改进的 BPSO 算法的有效性和正确性; 同时, 当存在信息畸变时, 改进的 BPSO 算法比一般算法具有更强的容错能力。

关键词: 故障检测; 改进的 BPSO 算法; 检测率; 容错力

BPSO Optimization Algorithm in Distribution Network With DG Fault Diagnosis Research

Guo Xing, Xu Wu, Tang Wenquan, Wen Cong

(Institute of electrical and Information Engineering, Yunnan Minzu University, Kunming 650500, China)

Abstract: For fault detection of distribution network including distributed generation (DG), traditional fault detection methods are prone to problems such as low detection accuracy, poor applicability and low fault tolerance. An improved binary particle swarm optimization (BPSO) was proposed for fault detection. Based on BPSO algorithm, the self-adaptive value was redefined to ensure that the population could find the most accurate optimal solution and solve the problem that BPSO algorithm was prone to "premature". Through the simulation analysis of IEEE33 nodes, the experimental results show that the improved BPSO algorithm can effectively locate fault sections, which verifies the effectiveness and correctness of the improved BPSO algorithm. At the same time, when there is information distortion, the improved BPSO algorithm is more fault-tolerant than the general algorithm.

Keywords: fault detection; improved BPSO algorithm; detection rate; fault tolerance

0 引言

随着城市的扩张, 社会各界对电能的需求量快速增加, 人类对电能质量的要求也越来越高^[1]。如今, 随着我国配电网的规模日益扩大, 特别是分布式电源的接入, 导致配电网系统从以往的单向潮流系统转变为多向潮流系统, 配电网变得不稳定, 发生故障的风险也随之提高; 其次, 分布式电源的接入, 也将会导致传统配电网的故障定位方法不再适用^[2]。

目前, 用于配电网故障定位的方法主要分为两类, 第一类是通过重合闸装置和分段器共同作用的检测方法^[3]。其原理是当配电网馈线网络发生故障时, 首先利用重合器完成跳闸操作, 当线路失压后再断开分段开关, 该方法的优势在于速度快, 精度高, 缺点是容错能力差; 另外一类是利用 FTU 终端设备进行故障检测, 其原理是利用 FTU 终端设备进行电流、电压等信息采集并上传至 SCADA 系统, 由 SCADA 系统结合智能算法完成故障区段定位。该方法的参数设定较

为复杂, 难以满足故障定位对实时性的要求^[4]。

粒子群算法最开始是对鸟类获取食物的行为进行研究, 鸟类找到食物最简单的方法就是寻找距离食物最近的鸟。但是, 单纯采用 PSO 算法进行寻优时, 粒子容易陷入局部最优的情况。为此, 本文提出了一种改进的二进制粒子群算法 (BPSO) 运用于配电网的故障检测中, 通过大量的仿真实验验证, 改进的 BPSO 算法能够有效改善含 DG 电源的检测精度。

1 二进制粒子群算法 (BPSO) 的基本原理

二进制粒子群算法作为计算机领域的一种生物启发式算法^[5], 二进制粒子群算法中的某一个粒子都代表其中一个解, 一个粒子表示一个适应度值; 粒子的方向、距离与粒子的速度相关, 粒子会根据周围粒子的速度进行相应调整, 以便在空间中找到最优解^[6]。

二进制粒子群算法 (BPSO) 则是将粒子的最优解以及粒子的任意位置 x_{ij} 记为 0 或者 1, v_{ij} 代表 x_{ij} 取值为 1 时的

收稿日期: 2020-08-10; 修回日期: 2020-09-14。

基金项目: 国家自然科学基金项目 (61761049)。

作者简介: 郭 兴 (1995-), 女, 云南曲靖人, 在校研究生, 主要从事配电网故障检测方向的研究。

通讯作者: 徐 武 (1974-), 男, 新疆克拉玛依族人, 教授, 研究生导师, 主要从事电力系统运行分析方向的研究。

引用格式: 郭 兴, 徐 武, 唐文权, 等. BPSO 优化算法在含 DG 配电网中的故障诊断研究[J]. 计算机测量与控制, 2021, 29(3): 88-92.

概率^[7]。假定搜索空间的维度是 W , 粒子 i 的位置标记为 $x_i = (x_{i1}, x_{i2}, \dots, x_{iw})$, 速度标记为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iw})$ 。BP-SO 算法表示粒子速度的公式可以定义为:

$$v_i^{k+1} = \delta v_{ij}^k + c_1 r_1 (pb_{ij}^k - x_{ij}^k) + c_2 r_2 (gb_{ij}^k - x_{ij}^k) \quad (1)$$

其中: x_{ij}^k 代表粒子 i 进行 k 次迭代以后处于第 j 维位置空间; v_i^{k+1} 代表粒子 i 进行 $k+1$ 次迭代以后处于第 j 维位置空间; c_1, c_2 代表学习因素; r_1, r_2 表示 $[0, 1]$ 之间的任意数; δ 表示权重系数; pb_{ij}^k, gb_{ij}^k 表示粒子 i 迭代至第 k 代时停止, 分别表示处于第 j 维空间位置中的个体最优位置以及种群最优位置^[8]。

可将位置更新式子定义为:

$$x_{ij} = \begin{cases} 1, & rand() < S(v_{ij}) \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中: $rand()$ 表示 $[0, 1]$ 之间的任意值, $S(v_{ij})$ 表示 sigmoid 函数; sigmoid 函数可将 v_{ij} 限定在 $[-4.0, 0, 4.0]$ 范围内^[9]。sigmoid 函数可定义为:

$$sigmoid(v_{ij}^k) = \begin{cases} 0.98, & v_{ij}^k > 4 \\ \frac{1}{1 + \exp(-v_{ij}^k)}, & -4 \leq v_{ij}^k \leq 4 \\ -0.98, & \end{cases} \quad (3)$$

2 二进制粒子群算法在含 DG 配电网故障检测的模型构建

2.1 含 DG 配电网的故障编码

在传统配电网中, 装设在各联络开关上的 FTU 设备根据配电网系统正常工作状态下的电流值自动设定监测阈值^[10]。当 FTU 检测到的电流值超过系统预先设定的阈值时, 表明该联络开关处有故障电流流过, 此时记为“1”; 反之, 当 FTU 检测到的电流值小于系统预先设定的阈值时, 表明该联络开关处没有故障电流流过, 此时记为“0”。采用这样的方式可以形成一系列的离散信息, 将这些离散信息传送至 SCADA 系统, 系统利用采集到的故障信息完成故障区段的求解^[11]。

当分布式电源接入配电网以后, 导致原有配电网的潮流系统从单相潮流系统变为多向潮流系统^[12]。为此, 需要对 FTU 终端设备的编码方式重新定义。主电源按照距离其中任意一个 FTU 设备“最短距离”的原则进行选取, 当存在多个电源与 FTU 终端设备之间的距离相等的情况下, 任意选择其中一个电源作为系统的主电源。规定某一主电源单独作用时流过 FTU 设备的电流标记为正参考方向, 当存在故障电流流经 FTU 设备时, 若方向与规定方向相同, 标记为“1”; 反之, 当存在故障电流流经 FTU 设备时, 若方向与规定方向相反, 标记为“0”^[13]。故障电流 I 的定义为:

$$I = \begin{cases} 1, & \text{故障电流方向与规定的正方向一致} \\ 0, & \text{不存在故障电流} \\ -1, & \text{故障电流方向与规定的正方向相反} \end{cases}$$

2.2 开关函数的构建

为实现配电网故障区段定位, 需要明确联络开关与故障区段的关系, 见公式 (4) 所示:

$$I_j^*(x) = \prod_{i=1}^{N_j} x_{j,i} \quad (4)$$

式中, $I_j^*(x)$ 表示联络开关 j 的工作运行状态, 主要有“0”和“1”两种状态, “0”表示正常运行状态, “1”表示故障状态。




图1 IEEE9 配电网图

在图 1 中所示的 IEEE9 节点配电网图中, S1~S9 表示开关编号, L1~L9 表示每一段馈线的馈线编号。由上述定义规则可知, S1~S5 的主电源是系统电源 S, 且 S1~S5 上的联络开关上装设的 FTU 设备的电流正方向为图中实线箭头方向所指; S6~S9 的主电源是分布式电源 DG, 且 S6~S9 上联络开关上装设的 FTU 设备的电流正方向为图中虚线箭头方向所指。当线路 L4 发生故障时, SCADA 接收到的编码信息为 $[1, 1, 1, 1, -1, 1, 1, 1, 1]$ 。为避免故障信息传送过程中信息丢失, 导致故障诊断算法出现误判, 可将丢失的故障信息数据全部设定为“1”。

2.3 评价函数的构建

针对辐射性配电网可构建如式 5 所示的评价函数:

$$F(S_c) = \sum_{j=1}^{N_1} |I_j - I^*(S_c)| + \omega \sum_{j=1}^{N_2} |L_j| \quad (5)$$

式中, I_j 表示第 J 个联络开关上对应的 FTU 设备检测到的电流信息; $I^*(S_c)$ 表示联络开关的期望函数, 该期望函数主要用于表示故障电流信息与故障馈线区间之间的关系; N_1 表示配电网中装设的 FTU 终端设备的总个数; N_2 表示馈线故障区段的总数量; $\omega \sum_{j=1}^{N_2} |L_j|$ 表示为有效防止 SCADA 系统误判而特意增加的一项; ω 为常量, 通常取值为 0.5 ^[14]。

当 DG 电源接入到配电网中, 造成配电网中原有的单相潮流系统变为多向潮流系统, 如果继续使用 -1, 1 两种状态对故障信息进行描述, 可能导致 SCADA 系统无法进行判断。为此, 提出一种以 1, -1, 0 三种方式进行故障电流信息编码。为保证评价函数能够快速适应新的编码方式, 本文对评价函数中涉及到的联络开关期望函数进行改进处理, 见公式 (6) 所示:

$$I^*(S_c) = (0 - g^*(S_c)) + S^*(S_c) \quad (6)$$

式中, $S^*(S_c)$ 表示在联络开关 S_c 处装设的 FTU 设备检测到的故障电流信息为 1 时, 对所有联络开关上安装的 FTU 设备可以检测到故障信息为 1 的馈线区段进行“或逻辑”运算; $g^*(S_c)$ 表示在联络开关 S_c 处装设的 FTU 设备检测到的故障电流信息为 -1 时, 对所有联络开关上安装的 FTU 设备可以检测到故障信息为 -1 的馈线区段进行“或逻辑”运算^[15]。

3 BPSO 算法的改进

种群在不断迭代过程中, 当其中某一粒子出现“局部最

优”的情况时, 周围的其他粒子将会逐渐向其靠近, 最终导致粒子群失去原本的多样性特征, 发生“早熟”现象。因此, 需要对二进制粒子群中的自适应变化率进行改进处理, 改进公式如下:

$$g = \frac{|f(k) - f(k-6)|}{|f(k-s)|} \quad (7)$$

式中, g 表示种群迭代至第 6 代时的变化率, $f(k)$ 表示迭代次数为 k 代时的适应度值。

假定 ω 的值会随着 g 的变化而自适应取值, 定义公式如下:

$$\omega = \begin{cases} \alpha_1 + \frac{r}{2}, & g \geq 0.05 \\ \alpha_2 + \frac{r}{2}, & g < 0.05 \end{cases} \quad (8)$$

式中, r 的取值范围为 $[0, 1]$, $\alpha_1 < \alpha_2$, α_1 一般取值为 0.5, α_2 一般取值为 0.3。当 $g \geq 0.05$ 时, 此时种群的最优适应度值波动较大, 且种群暂未发现聚拢方向。此时, 令 $\omega = \alpha_1 + \frac{r}{2}$ 可确保算法快速收敛; $g < 0.05$ 时, 此时种群的最优适应度值是某一确定值, 种群处于开发阶段, 令 $\omega = \alpha_2 + \frac{r}{2}$ 促使种群找到最优解。

3.1 改进的 BPSO 算法的应用流程

基于智能终端设备的故障定位的本质就是找到最符合真实故障情况的故障场景。由于故障电流信息是由“0”和“1”组成的离散信息, 当使用改进的 BPSO 算法进行优化时, 需要把三维连续空间里的寻优问题转变为对多维离散空间中的粒子群进行寻优。选用粒子所处的空间位置表示馈线状态信息, 每一次迭代结束以后都利用评价函数对对粒子所处的空间位置进行优劣判断, 再对新一代粒子所处的空间位置进行更新, 直到满足收敛条件时结束, 此时获得粒子所处空间位置。具体操作流程如下:

1) 初始化操作, 设定粒子群的规模大小 Q , 迭代次数为 N , 随机产生粒子群体的 x 维离散空间, 记为 $(L_1, L_2, L_3, \dots, L_j, \dots, L_x)$, 联络开关信息记为 S , 电流信息序列为 (I_1, I_2, \dots, I_s) , 由配电网的拓扑结构明确 S 与 L 的对应关系;

2) 选择序列 I 为参考点, 计算第 j 个粒子与参考点之间的欧氏距离, 记为 D_j ;

3) 评价函数中的 $\omega \sum_{j=1}^N |L_j|$ 项, 有效防止 SCADA 系统误判, 提高算法的的容错性;

4) 算法迭代过程中, 赋予每一个粒子的运动方向以及一个随机数 $rand$, $rand \in (0, 1)$, 并作为下一代粒子空间位置更新的依据。依照公式 (9) 进行操作:

$$L_j = \begin{cases} 0, & rand \leq 0.5 \\ 1, & rang > 0.5 \end{cases} \quad (9)$$

5) 对迭代次数 N 以及评价函数 $F(S_j)$ 进行判断, 如果满足条件则停止迭代, 否则继续进行迭代直到满足终止条件;

6) 输出 $F(S_j)$ 对应的粒子所处的空间位置, 得到馈线

区段的状态信息。

图 2 为采用改进的 BPSO 算法的流程图。

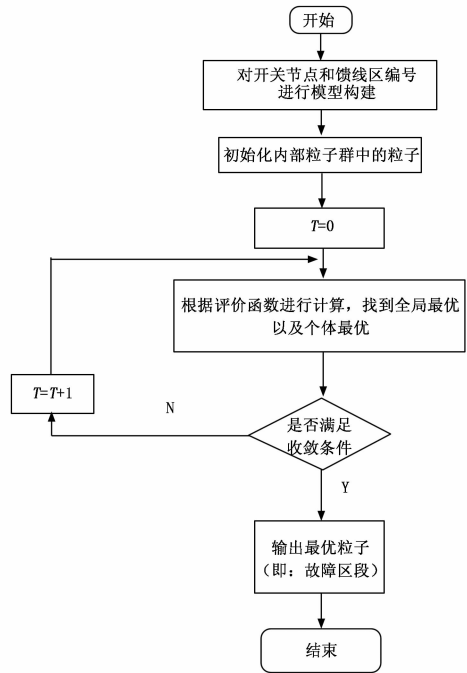


图 2 算法流程图

3.2 仿真分析

本文选用含 DG 电源的 33 节点进行讨论分析, 见图 3 所示, 针对不同的故障点特征信息, 均采用本文改进的 BPSO 算法以及传统的 BPSO 算法进行仿真。本文的所有实验均利用 MATLAB 软件完成。




图 3 IEEE33 节点配电网图

3.3 两种算法的仿真对比

分别对表 1 中的 4 种状态进行仿真分析, 见图 4 所示。

3.4 节点数对配电网故障检测精度的影响

为保证实验数据的准确性, 选用表 1 中的第 2 种故障状态以及第 4 种故障且分别进行 100 次的仿真实验。

通过利用 IEEE33 节点的仿真分析可知, 改进的 BPSO 算法完全适用于含 DG 配电网的故障检测, 并且改进算法的收敛速度比传统算法的收敛速度更快。从仿真的结果图来看, 改进的 BPSO 算法可以对单重故障、或者多重故障进行准确定位, 与传统的 BPSO 算法相比较, 本文改进算法的迭代次数减小, 检测精度也明显提高。

表 1 两种算法的仿真对比图

采用算法	故障区段	信息畸变位数	最多迭代次数	最少迭代次数	平均迭代次数	实际输出	结论
BPSO 算法	L5 单重故障	0	95	36	87.3	L5	正确
改进的 BPSO 算法			60	38	63.6	L5	正确
BPSO 算法	L5 单重故障	1	96	74	88.5	L5	正确
改进的 BPSO 算法			76	61	60.4	L5	正确
BPSO 算法	L9、L29 多重故障	0	95	71	84.3	L9、L29	正确
改进的 BPSO 算法			75	43	62.6	L9、L29	正确
BPSO 算法	L9、L29 多重故障	2	97	79	87.5	L9、L29	正确
改进的 BPSO 算法			85	61	65.7	L9、L29	正确

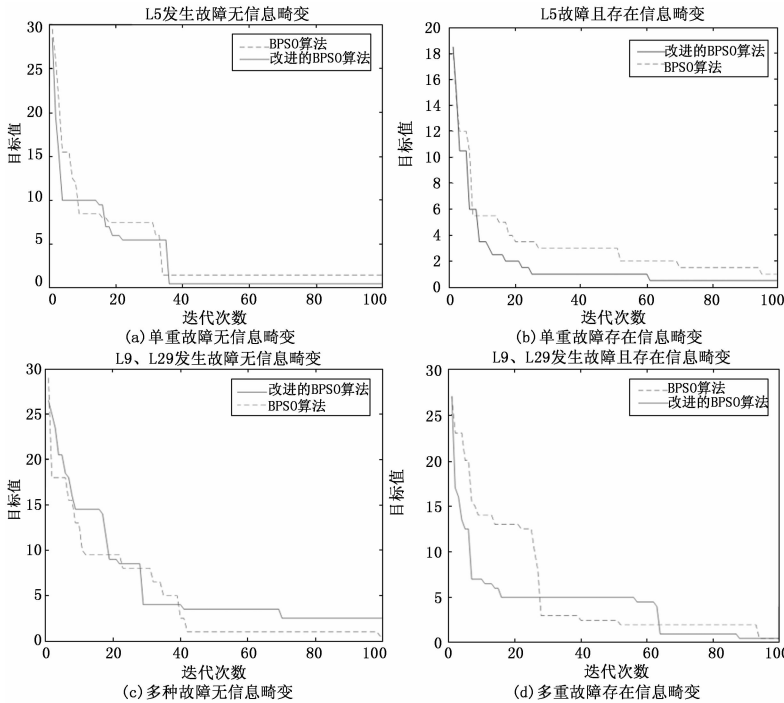


图 4 两种算法的仿真分析图

表 2 3 种不同节点的精确度对比


故障类型	配电网节点数	实验次数/次	BPSO 算法的精确度	改进的 BPSO 算法的精确度
L9、L29 发生故障存在信息畸变	31 节点	100	83.4%	96.7%
	33 节点	100	80.6%	94.2%
	69 节点	100	74.6%	93.4%
L5 发生故障存在信息畸变	31 节点	100	84.3%	97.8%
	33 节点	100	82.5%	96.3%
	69 节点	100	77.7%	95.5%

从表 2 中的数据可以看出, 不论是发生单重故障还是多重故障情况, 当节点数增加时, 采用智能算法的检测率都会随着节点数的增加而减小。这也就验证了节点数对配电网故障检测存在一定影响。从表 2 中的整体数据来看, 不论节点选用哪一类节点进行仿真分析, 改进后的 BPSO 算法的检测精度都优于未改进的 BPSO 算法。

3.5 容错性分析

考虑到 FTU 终端设备一般安装与户外, 受天气、地理

因素影响较大, 导致出现故障信息传送到 SCADA 信息时存在漏报、误报等情况。本文选用图 5 所示的配电网图进行仿真分析。



(a) L5 故障区段检测图

(b) L9、L29 故障区段检测图

图 5 故障区段检测仿真

从表 3 中的数据可以看出, 当 FTU 终端设备出现漏报或者误报情况时, 当未接入 DG 电源时, 采用改进的 BPSO 算法的迭代次数最小; 不论是否接入 DG 电源, 采用改进的 BPSO 算法都能进行准确定位, 都能够在 60 代以前检测到故障区段, 验证了本文选用算法的容错性好于传统算法。

4 结束语

本文采用一种改进的 BPSO 算法, 通过对自适应值得改进来防止算法“早熟”, 更大概率的找寻到最优解; 通过 IEEE33 节点配电网的仿真结果可知, 改进的 BPSO 算法能够进行准确定位; 其次, 伴随着节点数的增加, 配电网的检测精度也会随之降低; 最后, 对改进的 BPSO 算法与 BPSO 算法的容错性进行了分析, 改进的 BPSO 算法容错性明显优于 BPSO 算法, 再次验证了本文改进算法的可行性和有效性。

表 3 容错性分析记录表

DG 电源加入情况	故障馈线编号	信息畸变位数	最多迭代次数	最小迭代次数	平均迭代次数	输出结果	判断
未投入 DG 电源	L5	1	75	43	47.3	L6	正确
投入一个 DG 电源	L9、L29	2	79	51	51.6	L9、L23	正确
投入两个 DG 电源	L9	1	78	59	54.3	L9	正确
投入 3 个 DG 电源	L5、L9	2	81	55	55.1	L10、L30	正确

参考文献:

[1] 康文文, 赵建国, 丛伟, 等. 含分布式电源的配电网故障检测与隔离算法 [J]. 电力系统自动化, 2011, 35 (9): 25 - 29.

[2] 罗 蛟. 配电网故障检测与定位方法的研究 [D]. 长沙: 湖南大学, 2013.

[3] 丛 伟, 路庆东, 田崇稳, 等. 智能配电终端及其标准化建模 [J]. 电力系统自动化, 2013, 37 (10): 6 - 12.

[4] 王占宇. 配电网故障检测、隔离与恢复系统的算法研究及应用 [D]. 保定: 华北电力大学 (保定), 2013.

[5] 吴乐鹏, 黄 纯, 曾照新. 分布式发电配电网故障区间定位的自适应矩阵算法 [J]. 电工电能新技术, 2012, 31 (4): 52 - 57.

[6] 房凡秀. 智能配电网分布式区域纵联保护与故障恢复系统研究 [D]. 长沙: 湖南大学, 2016.

[7] 何宏杰. 基于二进制粒子群优化算法的配电网重构研究 [D]. 杭州: 浙江大学, 2006.

[8] 潘文明. 基于改进二进制粒子群算法的配电网重构 [D]. 吉林: 东北电力大学, 2009.

[9] 卢志刚, 董玉香. 基于改进二进制粒子群算法的配电网故障恢复 [J]. 电力系统自动化, 2006, 30 (24): 39 - 43.

[10] 马天祥, 王春英, 贾静然, 等. 基于二进制粒子群算法的交直流混合配电网故障恢复方法 [J]. 电力系统保护与控制, 2019, 47 (9): 112 - 119.

[11] 魏声云, 张 静, 郭 虹, 等. 改进二进制粒子群优化的节点选择算法 [J]. 西安电子科技大学学报, 2016, 43 (2): 150 - 156.

[12] 李超文. 基于改进模型和二进制粒子群算法的电网故障诊断研究 [D]. 成都: 西南交通大学, 2009.

[13] 钟建伟, 朱润枫, 黄秀超, 等. 基于双态二进制粒子群优化算法的配电网故障定位 [J]. 电力系统及其自动化学报, 2019, 31 (3): 29 - 34.

[14] 於益军, 张建明, 叶 周, 等. 配电网故障自动处理方法及其应用 [J]. 电力系统自动化, 2001 (17): 63 - 64.

[15] 蔡 乐, 邓佑满, 朱小平. 改进的配电网故障定位、隔离与恢复算法 [J]. 电力系统自动化, 2001, 25 (16): 48 - 50.

(上接第 87 页)

[18] Schlegl T, Seeböck P, Waldstein S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery [C]. In: Niethammer, M., et al. (eds.) IPMI 2017. LNCS, 10265, 146 - 157.

[19] Chen T W, Chen Y L, Chien S Y. Fast image segmentation based on K - Means clustering with histograms in HSV color space [A]. 2008 IEEE 10th Workshop on Multimedia Signal Processing [C]. IEEE, 2008.

[20] Guo Y H. Image Segmentation Based on HSV Color Space [J]. heilongjiang metallurgy, 2011, 031 (002): 35 - 37

[21] Jau U L, Teh C S, Ng G W. A comparison of RGB and HSI color segmentation in real - time video images; A preliminary study on road sign detection [A]. International Symposium on Information Technology [C]. IEEE, 2008.

[22] Moreno R, Grana M, Ramik D M, et al. Image segmentation on spherical coordinate representation of RGB colour space [J]. Image Processing Iet, 2012, 6 (9): 1275 - 1283.

[23] Chen L C, Zhu Y, Papandreou G, et al. Encoder - decoder with atrous separable convolution for semantic image segmentation [A]. Proceedings of the European conference on computer vision (ECCV) [C]. 2018: 801 - 818.

[24] Tsai Y H, Hung W C, Schuller S, et al. Learning to adapt structured output space for semantic segmentation [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. 2018: 7472 - 7481.

[25] Yu C, Wang J, Peng C, et al. Learning a discriminative feature network for semantic segmentation [A]. Proceedings of

the IEEE conference on computer vision and pattern recognition [C]. 2018: 1857 - 1866.

[26] He K M, Georgia G, Piotr D, et al. Mask R - CNN [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, PP: 1 - 1.

[27] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [A]. Proceedings of the IEEE conference on computer vision and pattern recognition [C]. 2015: 3431 - 3440.

[28] Ronneberger O, Fischer P, Brox T U. Convolutional networks for biomedical image segmentation [A]. Paper presented at: International Conference on Medical Image Computing and Computer - Assisted Intervention [C]. 2015.

[29] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770 - 778.

[30] Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift [C]. international conference on machine learning, 2015: 448 - 456.

[31] Ruseckaite A, Fok D, Goos P. Flexible Mixture - Amount Models Using Multivariate Gaussian Processes [J]. Journal of Business and Economic Stats, 2018: 1 - 15.

[32] Seeger M. Gaussian processes for machine learning [J]. International journal of neural systems, 2004, 14 (2): 69.

[33] Seeger, Matthias. Gaussian Processes for Machine Learning [J]. International Journal of Neural Systems, 2008, 14 (2): 69 - 106.