



研究与开发

面向 SDWSN 的分布式高效熵节能分簇路由算法

马巧巧, 董黎刚, 蒋献

(浙江工商大学信息与电子工程学院(萨塞克斯人工智能学院), 浙江 杭州 310018)

摘要: 为提高软件定义无线传感器网络 (software defined wireless sensor network, SDWSN) 的寿命并降低数据传输能耗, 设计一种基于萤火虫算法 (firefly algorithm, FA) 和生物地理学优化 (biogeography-based optimization, BBO) 的混合优化算法, 并基于该混合优化算法, 设计一种分布式高效熵节能分簇路由算法 (distributed high-efficiency entropy energy-saving cluster routing algorithm, DHEEC), 将能量熵和混合优化算法用于簇头选择。仿真结果表明, 混合优化算法在标准函数上的表现优于其他算法, DHEEC 的 10% 节点死亡轮数比 IFCEER 提高了约 41.05%, 比 DEEC-FA 提高了约 13.89%, 并提高了能量利用率。

关键词: 分簇路由; 萤火虫算法; 生物地理学优化; 能量效率

中图分类号: TP393.0

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023024

Distributed high-efficiency entropy energy-saving clustering routing algorithm for SDWSN

MA Qiaoqiao, DONG Ligang, JIANG Xian

School of Information and Electronic Engineering (Sussex Artificial Intelligence Institute),
Zhejiang Gongshang University, Hangzhou 310018, China

Abstract: In order to improve the life of software defined wireless sensor network (SDWSN) and reduce the energy consumption of data transmission, a hybrid optimization algorithm based on firefly algorithm (FA) and biogeography-based optimization (BBO) were designed, and based on the hybrid optimization algorithm, a distributed high-efficiency entropy energy-saving clustering routing algorithm (DHEEC) was designed, using energy entropy and hybrid optimization algorithm for cluster head selection. The simulation results show that the hybrid optimization algorithm outperforms other algorithms on standard functions. The number of death rounds of 10% nodes of DHEEC is about 13.89% higher than that of IFCEER, and about 41.05% higher than that of DEEC-FA, and the energy utilization is improved.

Key words: cluster routing, firefly algorithm, biogeographic-based optimization, energy efficiency

收稿日期: 2022-12-17; 修回日期: 2023-02-02

通信作者: 董黎刚, donglg@zjgsu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61871468); 浙江省重点研发计划项目 (No.2021C01036); 浙江省自然科学基金资助项目 (No.LY18F010006); 浙江省新型网络标准与应用技术重点实验室基金资助项目 (No.2013E10012)

Foundation Items: The National Natural Science Foundation of China (No.61871468), Zhejiang Province Key Research and Development Program (No.2021C01036), Zhejiang Provincial Natural Science Foundation of China (No.LY18F010006), Zhejiang Provincial Key Laboratory of New Network Standards and Application Technology (No.2013E10012)

0 引言

无线传感器网络(wireless sensor network, WSN)^[1]通常部署一个基站和大量传感器节点。由于部署成本低、效益高, WSN 获得快速发展和广泛普及。然而 WSN 存在网络资源受限、网络管理不灵活和路由算法局部有效等问题^[2]。为了解决上述问题, 软件定义无线传感器网络(software defined wireless sensor network, SDWSN)^[3]将软件定义技术应用在 WSN 中, 将数据平面和控制平面解耦。SDWSN 通过集中式管理和可编程性, 提高了网络的灵活性, 并支持异构快速互联、灵活高效传感并动态可靠路由^[4], 提高了 WSN 的利用率。

在 SDWSN 中, 网络能量效率仍然是制约 WSN 应用的重要因素, WSN 原有的路由方法不再完全适用, 设计一种适应 SDWSN 特点的路由方法显得极为重要。分簇路由算法被用于 SDWSN, 主要包括低功耗自适应聚类层次(low energy adaptive clustering hierarchy, LEACH)算法^[5]、异构无线传感器网络分布式节能分簇(distribute energy-efficient clustering, DEEC)算法^[6]和稳定选举协议(stable election protocol, SEP)^[7]等。分簇路由算法将传感器节点分为不同的簇, 每个簇都有一个簇头收集簇成员信息并传输给基站, 这种方式使 SDWSN 具有良好的拓展性和稳健性。LEACH 随机选取簇头, 使得网络负载比较均衡, 但频繁进行簇头选择, 会导致能量浪费; DEEC 选取簇头时考虑了节点的剩余能量, 增加了网络生存周期, 但会给数据传输带来时延。

近年来, 许多智能优化算法被用于改进分簇路由算法的分簇阶段, 它通过模拟动物的群体行为来近似求解复杂的优化问题。智能优化算法包括遗传算法(genetic algorithm, GA)^[8]、萤火虫算法(firefly algorithm, FA)^[9]、人工蜂群(artificial bee colony, ABC)算法^[10]等。GA 收敛速度快, 但不擅长局部搜索; FA 的参数比 GA 少; ABC

算法在全局搜索和收敛速度方面具有优势。其中, FA 和 ABC 算法更易于在分簇路由算法中实现。智能优化算法存在求解精度低、收敛于局部最优解和搜索空间范围小等问题。

本文的主要研究工作如下。

(1) 建立 SDWSN 的网络模型和能耗模型。

(2) 设计了一种混合优化算法(optimized algorithm based on firefly algorithm, gravity search algorithm and biogeography optimization, FGB)。首先, 基于 FA 引入基于种群多样性的位置更新策略, 优化全局搜索最优解的能力; 然后, 基于引力搜索算法(gravitational search algorithm, GSA)和生物地理学优化(biogeography-based optimization, BBO)杂交算法, 优化局部搜索最优解能力。该算法提高寻找近似全局解的优化过程的性能。

(3) 设计了一种面向 SDWSN 的分布式高效熵节能分簇路由算法(distributed high-efficiency entropy energy-saving cluster routing algorithm, DHEEC)。该算法在选取簇头时考虑能量熵, 更加适合 SDWSN 中的能量更新, 同时将 FGB 用于簇头选择, 加快簇头轮换的速度。

(4) 通过实验仿真与分析, 将 FGB 与其他算法进行对比, 验证其在标准函数上的表现; 将 DHEEC 与其他算法进行对比, 其延长了网络生存周期, 提高了能量利用率。

1 相关工作

本节主要围绕网络分簇路由算法和智能优化算法两个方面进行研究。

Singh 等^[11]提出了一个用于 WSN 的三级异构网络模型, 用来描述网络的异质性, 并通过加权选举概率和阈值函数选取簇头。基于优化 LEACH 协议的遗传算法(genetic algorithm based optimized LEACH protocol, LEACH-O)^[12], 提高了能量效率, 并延长了 WSN 的寿命。增强型自适应分布式节能集群(enhanced adaptive distributed



energy-efficient clustering, EADEEC) 算法^[13]基于 DEEC, 对簇的数据传输、节点生存时间和稳定性进行改进。Lu 等^[14]面向 SDWSN, 采用粒子群优化 (particle swarm optimization, PSO) 计算簇头和基站的相对位置, 基于 ABC 的遍历路径算法设计基站的移动路径, 减少了传感器节点的能量开销。

种群优化算法被用于分簇路由算法中的分簇阶段。罗剑等^[15]提出了基于改进萤火虫聚类的能耗优化异构 WSN 路由算法 (optimized energy efficient routing algorithm based on improved firefly clustering, IFCEER), 该算法将 FA 用于高能节点分簇中, 降低了多次聚类消耗的能量, 但存在收敛速度慢、求解精度低等问题。余修武等^[16]提出了基于萤火虫算法优化模糊 C 均值的 WSN 路由算法 (firefly algorithm to optimize fuzzy C-means, FFACM), 避免算法陷入局部最优值, 然而存在初始聚类中心设置不精确问题。Zhang 等^[17]研究了基于贝叶斯的 PSO 算法, 该算法基于贝叶斯原理的概率强度函数进行参数设置, 然而面临局部最优问题, 尤其是在复杂的多重极小问题上表现得极为明显。萤火虫和粒子群混合优化 (hybrid firefly and particle swarm optimization, HFPSO) 算法^[18]通过检查当前全局最佳适应度的值确定搜索过程的开始。Pitchaimanickam 等^[19]提出了基于粒子群优化的混合萤火虫算法 (hybrid firefly algorithm with particle swarm optimization, HFAPSO), 该算法将 HFPSO 用于 LEACH-C 中的最优簇头选择, 增强了萤火虫的全局搜索能力。Basith 等^[20]将 FA 应用于具有能量参数的混合状态逻辑模型, 用于检测分布式拒绝服务 (distributed denial of service, DDoS) 攻击。Kumari 等^[21]使用 FA 和 BBO 在软件产品线进行特征选择。Shrivastava 等^[22]将灰狼优化 (grey wolf optimizer, GWO) 算法与 PSO 混合, 大幅减少了实现算法所需的计算时间。

2 系统模型

本节介绍了 SDWSN 的网络模型以及采用的能耗模型。

2.1 网络模型

在 SDWSN 的体系架构中, 基站位于控制层, 包含计算整个网络的路由的控制器模块; 传感器节点位于数据层, 实现按流表转发数据的功能^[23]。根据 SDWSN 的体系架构, SDWSN 模型如图 1 所示, 控制层具有如下功能: 获取网络拓扑、传感器节点的剩余能量、位置等信息; 按照能量计算簇头轮换表; 计算满足需求的最优路径; 将 DHEEC 和簇头轮换表载入流表信息。位于数据层的簇头仅完成接收、融合和转发数据。




图 1 SDWSN 模型

该网络模型基于如下假设:

- (1) 传感器节点 $s_i (i=1, 2, \dots, N)$ 随机部署在 $M \times M$ 区域内, 基站位于区域中心;
- (2) 基站与簇头之间根据 OpenFlow 协议进行数据信息交互;
- (3) 节点软硬件配置相同, 都有唯一的 ID, 位置固定;
- (4) 网络的链路是对称的;
- (5) 基站的计算速度和数据传输能力强于传感器节点。

2.2 能耗模型

无线电网能耗模型如图2所示^[24]。




图2 无线电网能耗模型

根据该能耗模型，发射一个 l bit 数据包的能量 En_{Tx} 为：

$$En_{Tx} = \begin{cases} IEn_{elec} + dis^2 l \varepsilon_{fs}, & dis < dis_{break} \\ IEn_{elec} + dis^4 l \varepsilon_{mp}, & dis \geq dis_{break} \end{cases} \quad (1)$$

其中， En_{elec} 为单位能耗， ε_{fs} 和 ε_{mp} 为功率放大损耗， dis 为距离， dis_{break} 是阈值距离。

接收一个 l bit 数据包所需能量 En_{Rx} 为：

$$En_{Rx} = IEn_{elec} \quad (2)$$

因此，一轮迭代中消耗的总能量为：

$$En_{Round} = En_{Tx} + En_{Rx} = l_D (2NEn_{elec} + NEn_{DA} + k\varepsilon_{mp} dis_{HB}^4 + k\varepsilon_{fs} dis_{MH}^2) \quad (3)$$

其中， k 为簇数， dis_{HB} 为簇头和基站之间的平均距离， dis_{MH} 为簇成员节点和簇头节点之间的平均距离：

$$\begin{aligned} dis_{HB} &= 0.765 \frac{M}{2} \\ dis_{MH} &= \frac{M}{\sqrt{2\pi k}} \end{aligned} \quad (4)$$

3 混合优化算法

选择簇头对路由算法的性能影响重大，为了节省传感器节点的能量，本节设计了一种混合优化算法，用于优化簇头的选择过程。

3.1 改进的萤火虫算法

FA 是一种启发自萤火虫闪烁行为的算法，萤火虫根据亮度进行位置迭代寻找最优解。使用了如下规则：

(1) 萤火虫根据亮度单向吸引；

(2) 萤火虫的吸引力与亮度成正比；

(3) 亮度低的萤火虫被亮度高的萤火虫吸引；

(4) 具有最高亮度的萤火虫随机移动。

定义1 萤火虫 i 和 j 的相对荧光亮度 I 为：

$$I = I_0 e^{-\beta r_{ij}} \quad (5)$$

其中， I_0 为萤火虫的最大荧光亮度， β 为光强吸收系数， r_{ij} 为欧几里得距离，计算式为：

$$r_{ij} = \|c_i - c_j\| = \sqrt{\sum_{w=1}^D (c_{iw} - c_{jw})^2} \quad (6)$$

其中， c_i 和 c_j 代表萤火虫 i 和 j 所处的空间位置， c_{iw} 和 c_{jw} 为萤火虫 i 和 j 在第 w 维的坐标。

定义2 萤火虫之间的相互吸引度 γ 。 γ 与萤火虫之间的相对荧光亮度对应：

$$\gamma = \gamma_0 e^{-\beta r_{ij}^2} \quad (7)$$

其中， γ_0 为最大吸引度。

然而 FA 收敛速度慢，全局搜索缺乏随机性，可能导致收敛到局部最优解。这里提出了一种基于种群多样性的位置更新策略，该位置更新策略使用萤火虫个体到最优萤火虫个体的平均距离来衡量群体多样性。

定义3 多样性指数 β^n 。反映了第 n 代种群的多样性：

$$\beta^n = \frac{1}{|s|} \sum_{i=1}^{|s|} \sqrt{\sum_{j=1}^N (C_{ij} - \overline{C_Y})^2} \quad (8)$$

其中， $|s|$ 表示种群大小， $\overline{C_Y}$ 表示种群平均中心。

进一步调整萤火虫的位置更新策略，如式(9)所示：

$$\begin{aligned} c_i^{n+1} &= c_i^n + \gamma_0 e^{-\beta r_{ij}^2} \times (c_j - c_i) + \alpha \times \text{rand} = \\ c_i^n &+ \gamma_0 e^{-\beta r_{ij}^2} \times (c_j - c_i) + \rho \times (c_i^n - C_{best}^n) + \alpha \times \text{rand} \end{aligned} \quad (9)$$

其中， c_i^n 表示萤火虫 i 所处的空间位置； $\alpha \in [0,1]$ 表示步长因子；随机参数 $\text{rand} \in [0,1]$ ； C_{best}^n 表示当前迭代次数 n 轮中最亮萤火虫个体的位置； ρ



是一个根据 β^n 和迭代次数变化的权重, 其计算式为:

$$\rho = \begin{cases} -k \times \sigma, \beta^n \leq \sigma \times \beta^0 \\ 0, \beta^n > \sigma \times \beta^0 \end{cases} \quad (10)$$

其中, β^0 为初始种群多样性指数, k 为当前迭代次数, σ 是线性递减函数, 其计算式为:

$$\sigma = \frac{\maxIterate - k}{\maxIterate} \quad (11)$$

其中, $\maxIterate$ 为最大迭代次数。

根据式 (11) 得知, σ 的初始值为 1, 在首轮迭代即 $k=1$ 时, 式 (10) 得到的 ρ 是负值, 因此, 在算法的初始阶段, 萤火虫个体大概率朝着远离最优解的随机方向移动, 从而保证更大范围内的搜索。随着迭代次数增加, 多样性指数降低, 萤火虫会围绕最优解做局部随机搜索, 从而实现更精细的局部搜索。这样的动态调整机制可以平衡算法前期全局优化和后期局部优化的问题, 从而避免算法收敛于局部最优解。

在 FA 中, α 是一个固定值, 随着迭代次数的增加, 大部分萤火虫会围绕最佳点做局部最优搜索, 固定步长可能导致无法精确收敛到最佳点。因此, 步长因子 α 根据迭代次数做如下动态调整:

$$\alpha = \alpha_0 \times \sigma \quad (12)$$

其中, α_0 表示初始步长因子。

改进的萤火虫算法的伪代码如算法 1 所示, 其步骤描述如下。

步骤 1 初始化参数, 种群规模 N 、初始步长因子 α 、初始种群多样性指数 β^0 、最大迭代次数 $\maxIterate$ 等。

步骤 2 构建初始种群 C_0 , 并进行亮度计算, 根据亮度进行排序, 根据最大荧光亮度 I_0 计算适应度 I 以及当前全局最优解 C_{best} 。

步骤 3 根据式 (9) 更新萤火虫之间的距离, 根据式 (7) 更新萤火虫之间的吸引度, 同时更新全局最优解 C_{best} 。

步骤 4 迭代次数加 1, 根据式 (12) 更新步长因子。

步骤 5 若迭代次数达到 $\maxIterate$, 算法停止并输出当前全局最优解 C_{best} , 否则循环执行步骤 2~步骤 4。

算法 1 改进的萤火虫算法

输入: 种群规模 N 、初始步长因子 α 、初始种群多样性指数 β^0 、最大迭代次数 $\maxIterate$

输出: 最优解 C_{best}

objective function $f(x)$

generate initial population C_0

create light intensity

while $k < \maxIterate$ **do**

calculate attraction γ

for each $i \in [1, N]$ **do**

for each $j \in [1, N]$ **do**

calculate the parameters β, σ

if $I_j > I_i$ **then**

move fly i to towards j

$$c_i^{n+1} = c_i^n + \gamma_0 e^{-\beta r_{ij}^2} \times (c_j - c_i) +$$

$$\rho \times (c_i^n - C_{best}^n) + \alpha \times \text{rand}$$

end if

change attraction

search again and modify light intensity

end for

end for

sort the attraction and find the best solution C_{best}

end while

3.2 引力搜索算法和生物地理学杂交算法

BBO 将种群中的解看成栖息地, 并为每个栖息地分配一个栖息地适宜指数 (habitants suitability index, HSI) 反映整体适宜性, 并通过种群迁移操作更新最优解。栖息地类似于 FA 中的萤火虫个体位置, BBO 使用的一般规则如下:

(1) 亮度与栖息地的 HSI 值成正比;

(2) 高 HSI 值的栖息地的个体往低 HSI 值的栖息地迁移;

(3) 低 HSI 值的栖息地吸引高 HSI 值的栖息地的个体;

(4) 栖息地面临个体的随机变化。

定义 4 栖息地 H 。栖息地在数值优化问题的搜索空间内提供一种解决方案。

定义 5 栖息地适宜指数 HSI。反映栖息地的整体适宜性。

定义 6 适宜性指数变量 SIV。通过附加系数对 HSI 产生影响,例如降雨量、植被多样性和温度等。

定义 7 迁出移民指数 μ 。控制栖息地的移民,物种离开栖息地的概率与栖息地物种数量成正比。

定义 8 迁入移民指数 λ 。控制栖息地的移民,当栖息地没有物种时,迁入移民指数达到最大。

BBO 从种群规模 N 、维度为 D 的随机种群开始,每个个体 H_{ij} 按式 (13) 生成。

$$H_{ij} = a_j + \text{rand} \times (b_j - a_j) \quad (13)$$

其中, $i = \{1, 2, \dots, N\}$, $j = \{1, 2, \dots, D\}$, a_j 和 b_j 分别是解向量在第 j 维的上下界。

计算 HSI, 按照从好到坏的顺序排序种群个体 H_k , 并根据式 (14) 计算迁出移民指数 μ_k 和迁入移民指数 λ_k 。

$$\begin{aligned} \mu_k &= \frac{E \times S_k}{S_{\max}} \\ \lambda_k &= \left(\frac{1 - S_k}{S_{\max}} \right) \cdot I \end{aligned} \quad (14)$$

其中, S_k 表示目前种群个体的数量, $S_{\max}$ 表示最大种群个体的数量, E 表示最大移民迁出率, I 表示最大移民迁入率。 μ_k 越大, λ_k 越小, HSI 越高; μ_k 越小, λ_k 越大, HSI 越低。每次迭代, 较优解传播给较差解; 较差解大概率向较优解学习。总体来说, 随着迭代次数的增加, 所有解向着最优解靠近。

HSI 较高和较低的栖息地容易发生变异, 中间的解则保持原样。变异率为:

$$m_i = M \times \left(\frac{1 - P_i}{P_{\max}} \right) \quad (15)$$

其中, M 为最大变异率, P_i 为物种概率, $P_{\max}$ 为最大物种概率, 此处 $P_{\max} = N$ 。

变异是突发事件导致栖息地的物种数量和 HSI 改变引起的, 物种的变异率取决于物种概率。当物种数量较多或者较少时, 物种概率较低, 变异率较高; 当物种数量适中时, 物种概率较高, 变异率较低。变异的目的是提高种群多样性, 使得低 HSI 值的栖息地得到改进, 较高 HSI 值的栖息地得到提升, 高 HSI 值的栖息地可能向低 HSI 变化。变异有利于扩大搜索空间、跳出局部最优。

物体之间的引力 F 和个体的加速度 a 分别为:

$$\begin{aligned} F &= G \frac{M_1 \times M_2}{R^2} \\ a &= \frac{F}{M} \end{aligned} \quad (16)$$

其中, M_1 和 M_2 为物体质量, G 为引力常量, R 是欧氏距离, M 是质量。

根据 GSA, 种群个体 i 和 j 之间的引力 f_{ij} 和个体的加速度 a_i 分别为:

$$a_i = \frac{F_{ij}}{M_{ii}} \quad (17)$$

其中, M_{aj} 和 M_{pi} 分别表示种群个体 i 的主动引力质量和种群个体 j 的被动引力质量, M_{ii} 是种群个体 i 的惯性质量。

种群个体的惯性质量与适应度相关。惯性质量越大, 产生最优解的概率越大。种群在 t 时刻的质量 $M_i(t)$ 计算式如下:

$$M_{ai} = M_{pi} = M_{ii} = M_i, \quad i = 1, 2, \dots, N$$

$$m_i(t) = \frac{\text{fit}_i(t) - \text{worst}(t)}{\text{best}(t) - \text{worst}(t)}$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^n m_j(t)} \quad (18)$$



其中, $\text{fit}_i(t)$ 为适应度值, $\text{best}(t)$ 为最优解, $\text{worst}(t)$ 为最差解, 计算式为:

$$\begin{aligned}\text{best}(t) &= \max_{i \in \{1, \dots, N\}} \text{fit}_i(t) \\ \text{worst}(t) &= \max_{i \in \{1, \dots, N\}} \text{fit}_i(t)\end{aligned}\quad (19)$$

BBO 算法的解集合为:

$$m_{ti} = [(I_{i1} + E_{i1}), (I_{i2} + E_{i2}), \dots, (I_{iD} + E_{iD})] \quad (20)$$

BBO 通过迁移和变异操作避免陷入局部最优解和算法早熟的问题, 并改善种群的整体稳定性, 也就是改善 HSI 的值。根据 HSI, 创建适应度函数为:

$$\begin{aligned}\text{fit}_i(t) &= \text{HSI} = \\ &= \text{SIV}_i + N + \lambda_k - \mu_k = \\ &= \text{SIV}_i + N + \left(\frac{1 - S_k}{S_{\max}} \right) \cdot I - \frac{E \times S_k}{S_{\max}} = \\ &= \text{SIV}_i + N + \left[\frac{I - S_k(I + E)}{S_{\max}} \right] = \\ &= \text{SIV}_i + N + \left[\frac{I - S_k M_t}{S_{\max}} \right]\end{aligned}\quad (21)$$

更新式 (18) 得到:

$$m_i(t) = \frac{S_{\max} [\text{SIV}_i + N + I - S_k M_t - \text{worst}(t)]}{S_{\max} [\text{best}(t) - \text{worst}(t)]} \quad (22)$$

根据式 (17) 更新个体的速度和位置:

$$v_i^d(t+1) = \text{rand}_i \times v_i^d(t) + a_i^d(t) \quad (23)$$

$$x_i^d(t+1) = v_i^d(t) + v_i^d(t+1) \quad (24)$$

GSA-BBO 的伪代码如算法 2 所示, 其步骤描述如下。

算法 2 GSA-BBO 算法

输入: 种群规模 N 、维度 D 、最大移民迁出率 E 、最大移民迁入率 I 、最大变异率 M 、最大迭代次数 $r_{\max}$

输出: 最优解 G_{best}

objective function $f(x) = C_{\text{best}}$

generate initial population C_0

while $k < r_{\max}$ **do**

calculate HSI

for each $i \in [1, N]$ **do**

for each $j \in [1, N]$ **do**

calculate the parameters μ_k , λ_k , M

if $M_j > M_i$ **then**

move habitat i to towards j

$$\text{HSI} = \text{SIV}_i + N + \left[\frac{I - S_k M_t}{S_{\max}} \right]$$

end if

change HSI

search again and modify gravitational

end for

end for

sort the HSI and find the best solution G_{best}

end while

步骤 1 设置初始化种群规模 N 、维度 D 、最大移民迁出率 E 、最大移民迁入率 I 、最大变异率 M 、最大迭代次数 $r_{\max}$ 等参数。

步骤 2 构建初始种群 C_0 , 计算适宜指数 HSI, 并进行排序, 更新当前全局最优解 G_{best} 。

步骤 3 根据式 (14) 计算栖息地的迁出移民指数 μ_k 和迁入移民指数 λ_k , 并进行迁移操作, 根据式 (15) 进行变异操作。

步骤 4 根据式 (22) 计算每一个种群的惯性质量, 根据式 (24) 更新个体位置。

步骤 5 若迭代次数达到 $r_{\max}$, 算法停止并输出 G_{best} , 否则循环执行步骤 2~步骤 4。

3.3 混合优化算法设计

FA 在最终迭代中易收敛到局部最优解, 导致其不能进行适当的局部搜索, GSA-BBO 的局部搜索能力弥补了 FA 的缺陷。因此, 设计了 FGB, 该算法混合了 FA 的全局搜索能力和 GSA-BBO 的局部搜索能力, 用来提高寻找近似全局解的优化过程的性能。

FGB 有两个阶段。在第一个阶段, 改进的 FA 执行初步优化, 通过执行有限的迭代次数来搜索设计搜索空间, 该阶段找到的最优解为 C_{best} ; 在

第二个阶段, 使用 GSA-BBO 执行有限的迭代次数, 对 C_{best} 进行更加精细的搜索。

改进的 FA 构建的初始种群随机分布在整个空间, 而在 GSA-BBO 中, C_{best} 直接转化为最优初始种群。

FGB 流程如图 3 所示。




图 3 FGB 流程

FGB 的伪代码如算法 3 所示。

算法 3 FGB

输入: L 、 N 、 α 、 β^0 、 $\max\text{Iterate}$ 、 D 、 E 、

I 、 $r_{\max}$

输出: 最优解 G_{best}

objective function $f(x)$

generate initial population C_0

create light intensity

while $k < \max\text{Iterate}$ **do**

calculate attraction γ

for each $i \in [1, N]$ **do**

for each $j \in [1, N]$ **do**

calculate the parameters β , σ

if $I_j > I_i$ **then**

move fierfly i to towards j

$$c_i^{n+1} = c_i^n + \gamma_0 e^{-\beta r_{ij}^2} \times (c_j - c_i) +$$

$$\rho \times (c_i^n - C_{\text{best}}^n) + \alpha \times \text{rand}$$

end if

change attraction

search again and modify light intensity

end for

end for

sort the attraction and find the best solution

C_{best}

end while

objective function $f(x) = C_{\text{best}}$

generate initial population C_0

while $k < r_{\max}$ **do**

calculate HSI

for each $i \in [1, L]$ **do**

for each $j \in [1, L]$ **do**

calculate the parameters μ_k , λ_k , M

if $M_j > M_i$ **then**

move habitat i to towards j

$$\text{HSI} = \text{SIV}_i + N + \left[\frac{I - S_k M_t}{S_{\max}} \right]$$

end if

change HSI

search again and modify gravitational

end for

end for

sort the HSI and find the best solution G_{best}

end while

4 高效熵节能分簇路由算法

DHEEC 的运行时序如图 4 所示, 以轮为执行周期, 包括启动状态和稳定状态。在首轮迭代之前, 基站通过下发流表信息并转发给所有的传感器节点, 同时指示开始。在启动的初始



阶段, SDWSN 有两个重要的功能: (1) 选取簇头; (2) 建立簇。在 (1) 中, 基于阈值计算式选取临时簇头, 节点信息通过簇头发送给基站, 然后, 基于 FGB 临时簇头与簇内成员进行交换, 这样, 具有高能量的节点成为簇头。簇头向邻近节点发送消息, 普通节点选择簇头加入簇中成为簇内成员节点, 簇正式建立。SDWSN 进入稳定阶段, 按照簇间路由进行数据传输。




图4 DHEEC 的运行时序

4.1 阈值公式

基于系统模型的假设, 传感器节点的初始能量在区间 $[En_0, (1+a_{\max})En_0]$ 内随机分布, 因此传感器节点 $s_i (i=1, 2 \dots N)$ 具有 $(1+a_i)En_0$ 的初始能量, 其中 $a_i \in [0, a_{\max}]$ 。网络的初始总能量 En_{total} 如式 (25) 所示:

$$En_{\text{total}} = \sum_{i=1}^N (1+a_i)En_0 = En_0 \left(N + \sum_{i=1}^N a_i \right) = En_0 (N+A) \quad (25)$$

在 DHEEC 中, 利用熵来描述节点预测成为簇头的概率、节点初始能量和剩余能量的携带信息不确定性, 熵越小, 节点的剩余能量越大。每个传感器节点通过获取初始能量和剩余能量水平自动完成自身的熵选择。

定义 14 节点的相对能量熵 $H(En_i)$ 为:

$$H(En_i) = - \sum_{i=1}^n k \times En_i(r) \ln \bar{E}(r) \quad (26)$$

其中, $En_i(r)$ 是传感器节点 s_i 在 r 轮的剩余能量, $\bar{E}(r)$ 代表 r 轮网络的平均能量为:

$$\bar{E}(r) = \frac{1}{N} \sum_{i=1}^N En_i(r) \quad (27)$$

相对能量熵由 3 个部分组成: 可预测的簇头数量、剩余能量和平均能量, 并在两个相对能量的方向围绕 k 四处振荡, 因此单个节点可以自动管理其熵。在每一轮的选择临时簇头阶段, 每个节点评估自己成为簇头的概率, 在 0 与 1 之间提取一个随机数作为条件概率, 若小于该条件概率, 节点将选择本身作为临时簇头。

簇头选取阈值计算式为:

$$T(n) = \begin{cases} \frac{H(En_i)}{1 - H(En_i) \left(r \bmod \left[\frac{1}{H(En_i)} \right] \right)}, & s_i \in C \\ 0, & \text{其他} \end{cases} \quad (28)$$

其中, C 表示没有成为簇头的节点组, 根据阈值 $T(n)$ 参与第 r 轮簇头的选择。在算法迭代的最后一轮中, 若 s_i 没有成为簇头, 则 $s_i \in C$ 。这样基于节点能量和初始能量的相对能量熵的条件运算更加适合 SDWSN 中的能量更新。

4.2 FGB 用于簇头选举

FGB 用于识别式 (24) 中的相对能量熵, 使用了如下规则:

- (1) 萤火虫根据亮度即节点能量单向吸引;
- (2) 萤火虫的吸引力与节点能量成正比;
- (3) 能量低的萤火虫被能量高的萤火虫吸引;
- (4) 具有最高能量的萤火虫随机移动。

在 DHEEC 中, 结合熵小、吸引力高和位置佳的萤火虫会吸引大量萤火虫, 通过目标函数即相对能量熵可以预测萤火虫的吸引力。如果吸引力平衡, 萤火虫将任意移动。

在算法中, FGB 用于簇头选择, 并分为两个阶段。在第一个阶段, 改进的 FA 执行初步优化, 该阶段找到的最优解为 C_{best} ; 在第二个阶段, 使用 GSA-BBO 对 C_{best} 进行更加精细的搜索, 找到的最优解为 G_{best} 。该最优解即当前迭代次数中能量最大的节点。

4.3 簇间路由

传感器节点将节点位置信息、剩余能量信息和拓扑信息发送给基站。节点数据传输方式见表 1，其中， d 为节点与基站之间的距离， dis 为距离阈值即节点到簇头的距离。基站计算网络路由，控制传感器节点。该方法降低了能量消耗和计算开销。DHEEC 算法流程如图 5 所示。

表 1 节点数据传输方式

数据传输方式	条件
直接传输	$d < \text{dis}$
簇头传输	$d \geq \text{dis}$




图 5 DHEEC 算法流程

5 实验仿真与分析

本节使用的软件是 MATLAB 2018a。首先，通过对比 PSOGWO^[22]、HFPSO^[17]和 FGB 3 种算法在不同测试函数上的表现，验证 FGB 的收敛性能；其次，通过对比 IFCEER^[15]、DEEC-FA^[20]和 DHEEC 的网络生存周期和数据传输量，验证 DHEEC 的网络性能。

5.1 标准函数测试实验

用来测试的标准函数见表 2， f_1 是单峰函数，考查优化算法的收敛速度和精度； f_2 、 f_3 和 f_4 是多峰函数，考查优化算法的全局搜索能力； f_5 是不连续的阶梯函数，考查优化算法的有效性，问题维度为 30，它们的最优值都为 0。

表 2 用来测试的标准函数

函数名称	数学表达式	范围
Sphere	$f_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$
Schwefel	$f_2(X) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$
Rastrigin	$f_3(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$
Ackley	$f_4(x) = -20 \exp \left[-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right] - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e$	$[-32, 32]$
Step	$f_5(x) = \sum_{i=1}^n (x_i + 0.5)^2$	$[-100, 100]$

标准函数图像如图 6 所示。

5.1.1 参数设置

测试标准函数实验的部分参数设置如下： $N=30$ ， $\alpha=0.2$ ， $\beta^0=1$ ， $D=3$ ， $E=1$ ， $I=1$ 。

不同最大变异率和种群多样性指数下 FGB 的适应度变化如图 7 所示。图 7 (a) 显示了最大迭代次数为 20 轮，最大变异率 M 分别为 0.05、0.1、0.2、0.5 和 1 时 FGB 的适应度变化。变异率增加了种群个体的多样性，适中的变异率促进算法快




图6 标准函数图像




图7 不同最大变异率和种群多样性指数下FGB的适应度变化

速收敛到最优值附近, 这里取最大变异率为 0.1。

图 7 (b) 显示了种群多样性指数 β 分别为 0.1、0.2 和 0.5 时 FGB 的适应度变化。种群多样性适中时, 物种概率较高, 算法越稳定, 此时取种群多样性指数为 0.2。

5.1.2 仿真结果与分析

3 种算法在 5 种标准函数下的结果对比见表 3, PSOGWO、HFPSO 和 FGB 在不同标准函数下的适应度变化如图 8 所示, 显示了最大迭代次数为 1 000 轮、 $M=0.1$ 、 $\beta=0.2$ 时, PSOGWO、HFPSO

表 3 3 种算法在 5 种标准函数下的结果对比

函数	PSOGWO		HFPSO		FGB	
	最优值	运行时间/s	最优值	运行时间/s	最优值	运行时间/s
f_1	$1.433\ 5 \times 10^{-26}$	2.21	$4.779\ 5 \times 10^{-9}$	2.39	$9.082\ 4 \times 10^{-17}$	1.94
f_2	$9.465\ 3 \times 10^{-9}$	2.05	$5.632\ 9 \times 10^{-5}$	2.30	$3.715\ 4 \times 10^{-8}$	1.97
f_3	23.624 7	1.98	36.813 5	2.11	20.894 1	1.91
f_4	$1.333\ 4 \times 10^{-7}$	1.85	$2.852\ 2 \times 10^{-5}$	1.86	$7.876\ 9 \times 10^{-9}$	2.27
f_5	374.867	1.19	0	1.47	0	2.08




图 8 PSOGWO、HFPSO 和 FGB 在不同标准函数下的适应度变化



和 FGB 3 种算法在标准函数上的表现。从结果可以看出, FGB 在 f_1 上略差于 PSOGWO, 但收敛速度快于 PSOGWO; FGB 在 f_2 上的表现说明其搜索解范围大; FGB 在 f_3 、 f_4 和 f_5 上表现良好, 说明其实用性、收敛速度和搜索能力强于其他两种算法。

5.2 网络仿真实验

5.2.1 仿真参数设置

网络仿真实验的部分参数见表 4。

表 4 网络仿真实验的部分参数

参数	参数值
网络区域	100 m×100 m
传感器节点个数	100
基站位置	(50,50)
传输数据包/bit	4 000
E_0 / J	0.5
$E_{\text{elec}} / (\text{nJ} \cdot \text{bit}^{-1})$	50
$\varepsilon_{\text{fs}} / (\text{nJ} \cdot \text{bit}^{-1} \cdot \text{m}^{-2})$	10
$\varepsilon_{\text{mp}} / (\text{pJ} \cdot \text{bit}^{-1} \cdot \text{m}^{-4})$	0.001 3
$E_{\text{DA}} / (\text{nJ} \cdot \text{bit}^{-1} \cdot \text{signal}^{-1})$	5

5.2.2 网络生存周期

网络节点的能量随着算法的迭代次数增加而减少, 在一定的迭代次数后耗尽, 导致节点死亡。网络中节点死亡数代表了网络的生存周期。

IFCEER、DEEC-FA 和 DHEEC 的网络节点生存周期对比如图 9 所示, 显示了 IFCEER、DEEC-FA 和 DHEEC 3 种算法对网络生存周期的影响。其中图 9 (a) 显示了最大迭代次数为 5 000 轮时, IFCEER、DEEC-FA 和 DHEEC 3 种算法节点死亡数的变化。可以看出 IFCEER、DEEC-FA 和 DHEEC 3 种算法全部节点的死亡轮数分别为 2 000、3 754 和 3 568。

网络第一个节点死亡, 基站收集的信息不再全面, 而随着算法的运行, 死亡节点数量增多, 在后期存活的少部分节点剩余能量较低, 并丧失了通信能力。因此, 为了更加全面地衡量网络的

生存周期, 图 9 (b) 对比了 IFCEER、DEEC-FA 和 DHEEC 3 种算法首个节点死亡的轮数 (first node died, FND)、10%节点死亡的轮数 (10% node died, TND) 和节点全部死亡的轮数 (last node died, LND)。可以看出, IFCEER 只允许高能节点参与竞选簇头, 导致 FND 和 LND 非常接近, DEEC-FA 的 FND 远小于其他两个算法, 在算法初期网络性能下降严重。考虑网络整体能耗的均衡, 定义 TND 为网络生命周期, DHEEC 的 TND 比 IFCEER 提高约 41.05%, 比 DEEC-FA 提高约 13.89%。





图 9 IFCEER、DEEC-FA 和 DHEEC 的网络节点生存周期对比

5.2.3 网络数据传输量

算法运行过程中, 存活的成员节点将收集到的数据传输到簇头, 簇头再传输给基站, 在所有节点传输完成后, 基站统计本轮接收的数据包的数量。因此基站接收到的数据包总数用来评估能量利用率, 基站接收的数据包越多, 能量分布越平衡。

基站接收的数据包总数如图 10 所示,显示了 IFCEER、DEEC-FA 和 DHEEC 3 种算法在迭代了 5 000 轮后基站接收的数据包总数的变化。由此得出结论, DHEEC 在能量利用率方面比 IFCEER 提高约 31.58%, 比 DEEC-FA 提高约 31.06%。




图 10 基站接收的数据包总数

6 结束语

本文面向 SDWSN 的分簇路由算法进行研究。考虑提高寻找近似全局解的优化过程的性能, 设计了一种混合优化算法, 混合 FA 的全局优化能力和 GSA-BBO 的局部优化能力; 设计一种分布式高效节能分簇路由算法, 加快簇头轮换的速度。通过实验仿真与分析, 将混合优化算法与相关算法进行收敛精度、运行时间和稳定性等性能的对比, 证明其优化性能; 将分布式高效节能分簇路由算法与相关算法进行对比, 证明其延长网络寿命、降低数据传输能耗能力。

下个阶段工作将考虑建立 DDoS 攻击检测与防御机制, 以提高 SDWSN 的安全性。

参考文献:

- [1] 丁铖, 陈锦荣, 曹小冬, 等. 基于服务质量的层次化结构资源分配算法[J]. 电信科学, 2022, 38(1): 102-111.
DING C, CHEN J R, CAO X D, et al. Hierarchical structure resource allocation algorithm based on quality of service[J]. Telecommunication Science, 2022, 38(1): 102-111.
- [2] 汤季, 谭小波, 朱腾. SNDQ-WISE: 一种新的基于 SDWSN 的 QoS 路由协议[J]. 沈阳理工大学学报, 2019, 38(4): 18-24, 51.
TANG J, TAN X B, ZHU T. SNDQ-WISE: a new QoS routing

- protocol based on SDWSN[J]. Journal of Shenyang Ligong University, 2019, 38(4): 18-24, 51.
- [3] HAWBANI A, WANG X F, ZHAO L, et al. Novel architecture and heuristic algorithms for software-defined wireless sensor networks[J]. IEEE/ACM Transactions on Networking, 2020, 28(6): 2809-2822.
- [4] 黄美根, 黄一才, 郁滨, 等. 软件定义无线传感器网络研究综述[J]. 软件学报, 2018, 29(9): 2733-2752.
HUANG M G, HUANG Y C, YU B, et al. Software-defined wireless sensor networks: a research survey[J]. Journal of Software, 2018, 29(9): 2733-2752.
- [5] MAHMUDDIN M, ALABADLEH W A, KAMARUDIN L M. A comparative study on hopping mechanism of LEACH protocol in wireless sensor networks: a survey[J]. IOP Conference Series: Materials Science and Engineering, 2019, 551(1): 012056.
- [6] GHOSH R, MOHANTY S, PATTNAIK P K, et al. A performance assessment of power-efficient variants of distributed energy-efficient clustering protocols in WSN[J]. International Journal of Interactive Communication Systems and Technologies, 2020, 10(2): 1-14.
- [7] 曹宇. 基于改进 SEP 协议的 WSN 能量优化方案研究[D]. 南京: 南京邮电大学, 2019.
CAO Y. Research on WSN energy optimization scheme based on improved SEP protocol[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019.
- [8] 刘奕岑, 徐蔚鸿, 陈沅涛, 等. 具有适应度选择调整策略的混沌遗传算法及其应用[J]. 计算技术与自动化, 2019, 38(2): 8-14.
LIU Y C, XU W H, CHEN Y T, et al. Chaos genetic algorithm with fitness selection adjustment strategy and its application[J]. Computing Technology and Automation, 2019, 38(2): 8-14.
- [9] RAYENIZADEH M, RAFSANJANI M K, SAEID A B. Cluster head selection using hesitant fuzzy and firefly algorithm in wireless sensor networks[J]. Evolving Systems, 2022, 13(1): 65-84.
- [10] REN Z C, ZHANG L Y, TANG J Y, et al. Improved artificial bee colony algorithm based on cauchy OBL[J]. Journal of Physics: Conference Series, 2021, 1920(1): 012108.
- [11] SINGH S, MALIK A, KUMAR R. Energy efficient heterogeneous DEEC protocol for enhancing lifetime in WSNs[J]. Engineering Science and Technology, an International Journal, 2017, 20(1): 345-353.
- [12] BHOLA J, SONI S, CHEEMA G K. Genetic algorithm based optimized leach protocol for energy efficient wireless sensor networks[J]. Journal of Ambient Intelligence and Humanized Computing, 2020, 11(3): 1281-1288.
- [13] POLURU R K, REDDY P K M, BASHA S M, et al. Enhanced adaptive distributed energy-efficient clustering (EADEEC) for wireless sensor networks[J]. Recent Advances in Computer Science and Communications, 2020, 13(2): 190-194.



- [14] LU S X, WU M Q, ZHAO M. Particle swarm optimization and artificial bee colony algorithm for clustering and mobile based software-defined wireless sensor networks[J]. *Wireless Networks*, 2022, 28(4): 1671-1688.
- [15] 罗剑, 毕晓东. 基于改进萤火虫聚类的异构 WSN 能耗优化路由算法[J]. *传感技术学报*, 2018, 31(10): 1584-1591.
- LUO J, BI X D. Optimized energy efficient routing algorithm based on improved firefly clustering for heterogeneous WSN[J]. *Chinese Journal of Sensors and Actuators*, 2018, 31(10): 1584-1591.
- [16] 余修武, 秦晓坤, 刘永. 基于萤火虫算法优化 FCM 的 WSN 路由算法[J]. *北京邮电大学学报*, 2022, 45(2): 50-56.
- YU X W, QIN X K, LIU Y. WSN routing algorithm based on firefly algorithm to optimize FCM[J]. *Journal of Beijing University of Posts and Telecommunications*, 2022, 45(2): 50-56.
- [17] ZHANG L M, TANG Y G, HUA C C, et al. A new particle swarm optimization algorithm with adaptive inertia weight based on Bayesian techniques[J]. *Applied Soft Computing*, 2015(28): 138-149.
- [18] AYDILEK İ B. A hybrid firefly and particle swarm optimization algorithm for computationally expensive numerical problems[J]. *Applied Soft Computing*, 2018(66): 232-249.
- [19] PITCHAIMANICKAM B, MURUGABOOPATHI G. A hybrid firefly algorithm with particle swarm optimization for energy efficient optimal cluster head selection in wireless sensor networks[J]. *Neural Computing and Applications*, 2020, 32(12): 7709-7723.
- [20] BASITH K A, SHANKAR T N. Hybrid state analysis with improved firefly optimized linear congestion models of WSN for DDoS & CRA attacks[J]. *PeerJ Computer Science*, 2022(8): e845.
- [21] KUMARI C, YADAV H, CHHIKARA R. Hybrid model using firefly and BBO for feature selection in software product line[J]. *Recent Advances in Computer Science and Communications*, 2021, 14(9): 2754-2760.
- [22] SHRIVASTAVA A, SHARMA A, PANDIT M, et al. Hybrid protection scheme based optimal overcurrent relay coordination strategy for RE integrated power distribution grid[J]. *Energies*, 2021, 14(21): 7192.
- [23] 张芬. 基于软件定义的 WSN 分簇路由算法研究[D]. 兰州: 西北师范大学, 2021.
- ZHANG F. Research on clustering routing algorithm based on software-defined in WSN[D]. Lanzhou: Northwest Normal University, 2021.
- [24] 尚静, 董增寿, 康琳. 异构网络中基于 DEEC 的非均匀分簇路由算法[J]. *太原科技大学学报*, 2018, 39(2): 90-94.
- SHANG J, DONG Z S, KANG L. An non-uniform clustering routing algorithm based on DEEC in heterogeneous networks[J]. *Journal of Taiyuan University of Science and Technology*, 2018, 39(2): 90-94.


[作者简介]



马巧巧(1998-), 女, 浙江工商大学硕士生, 主要研究方向为软件定义网络。



董黎刚(1973-), 男, 博士, 浙江工商大学信息与工程学院院长、教授、硕士生导师, 中国电子学会高级会员, 浙江省计算机学会理事, 浙江省高校学科带头人, 主要研究方向为新一代网络和分布式系统。



蒋献(1988-), 男, 浙江工商大学实验师, 主要从事数字电路实验和模拟电路实验、电子设计竞赛指导方面的工作。