

基于改进多目标混沌粒子群优化的 电动汽车充放电调度

曹知奥¹, 马晨硕²

(1. 东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004;
2. 东北大学秦皇岛分校 悉尼智能科技学院, 河北 秦皇岛 066004)

摘要: 针对电动汽车充放电调度问题,提出一种考虑用户综合满意度的有序充放电算法。首先,构建了大规模电动汽车有序充放电模型,并量化用户综合满意度;其次,提出了一种基于改进多目标策略多样性混沌序列扰动粒子群优化(improved multi-objective role partitioning chaotic particle swarm optimization, IMRPC-PSO)算法以解决传统方法中多样性不足和易陷入局部最优的问题。根据粒子性能,给粒子赋予精英粒子、一般粒子和学习粒子的角色,并分别执行保持搜索、发展搜索和学习搜索的多样性策略。每个粒子根据其角色寻优搜索空间;为避免陷入局部最优,在每次迭代初始化后加入混沌序列扰动。最后,通过案例仿真对比所提算法与其余5种多目标优化算法的性能,结果显示IMRPC-PSO在解决电动汽车有序充放电问题上优于其他算法,验证了该算法的有效性和可行性。

关键词: 电动汽车;有序充放电;Tent混沌序列扰动;粒子群优化算法;多目标优化

中图分类号: TP 273 **文献标志码:** A **文章编号:** 1005-3026(2025)09-0001-08

Charging and Discharging Scheduling for Electric Vehicles Based on Improved Multi-objective Chaotic Particle Swarm Optimization

CAO Zhi-ao¹, MA Chen-shuo²

(1. School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China;
2. Sydney Smart Technology College, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China.
Corresponding author: CAO Zhi-ao, E-mail: caozhiao@neuq.edu.cn)

Abstract: To address the issue of charging and discharging scheduling for EVs (electric vehicles), an orderly charging and discharging algorithm that considered users' comprehensive satisfaction was proposed. Firstly, a large-scale orderly charging and discharging model for EVs was constructed, and users' comprehensive satisfaction was quantified. Secondly, an improved multi-objective role partitioning chaotic particle swarm optimization (IMRPC-PSO) algorithm was proposed to solve the problems of insufficient diversity and being trapped in local optimal in traditional methods. According to the performance of particles, the roles of elite particles, general particles, and learning particles were assigned, which respectively implement diversity strategies of maintaining search, developing search, and learning search. Each particle searched the optimization space according to its assigned role. To avoid falling into local optimal, a chaotic sequence perturbation was added after the initialization of each iteration. Finally, the performance of the proposed algorithm was compared with that of the other five multi-objective optimization algorithms through case simulation. The results show that IMRPC-PSO is superior to other algorithms in solving the problem of orderly charging and discharging of EVs, verifying the effectiveness and feasibility of the proposed algorithm.

Key words: electric vehicle (EV); orderly charging and discharging; Tent chaotic sequence perturbation; particle swarm optimization (PSO) algorithm; multi-objective optimization

电动汽车 (electric vehicle, EV) 是一种全新的环境友好型交通工具, 它利用清洁能源作为能量来源, 大大降低了交通领域的碳排放和能源浪费. EV 不仅可以作为出行工具, 还可以作为临时储能设备^[1]. 在 EV 快速发展的背景下, 本文旨在减少能源系统对化石燃料的依赖, 以最大限度提高电网运行的经济性^[2]. 同时, 为了削弱负荷需求的峰谷效应、降低负荷波动, 本文考虑 EV 用户的综合满意度, 通过协调 EV 的有序充放电, 避免因 EV 大规模集中入网导致的电网负荷需求“峰上加峰”情况, 从而保证电网运营的安全性.

EV 用户的有序充放电是降低电网负荷需求的重要手段之一. 文献[3]分析了 EV 作为灵活的储能单元为集中式多能源系统 (integrated energy system, IES) 供电的可能性, 并利用改进的遗传算法求解多目标优化问题. 文献[4]考虑了 EV 入网后可再生能源的调度问题, 并进行了算例分析, 计算其经济效益和可靠性. 尽管上述文献研究了 EV 并网时的调度策略优化, 但并未考虑 EV 用户综合满意度对策略最优性的影响. 因此, 本文旨在量化描述 EV 用户的综合满意度, 并将 EV 作为一种负荷和储能单元接入电网中, 以尽可能协同调度 EV 参与电网调度. 同时, 以用户的综合满意度作为评价指标, 激励用户积极参与有序充放电调度.

本文考虑了 EV 接入后的电网经济性和用户综合满意度作为多个优化目标, 并构建了 EV 并网有序充放电的多目标优化模型. 然而, 传统多目标优化算法往往存在搜索策略单一、种群多样性缩减等问题, 导致算法出现早熟收敛. 为了解决这些问题, 本文在提出的 IMRPC-PSO 算法中引入了改进多目标策略多样性机制, 根据粒子的质量和密度, 为其赋予不同的搜索策略. 具体而言, 多样性和收敛性较好的粒子被分类为精英粒子, 其最接近全局最优解, 因此使用中间值的学习因子和惯性权重. 一般粒子的性能稍差, 但仍需以较快速度向全局最优解靠拢, 应采用较大的全局学习因子, 而自身学习因子与惯性权重则取中间值. 对于性能较差的粒子则采用最大的全局学习因子和较小的自身学习因子及惯性权重, 以改善其搜索能力. 多样性粒子在各自的邻域空间内执行不同的搜索策略, 增强了算法整体的搜索

多样性, 加快了收敛速度. 通过在算法种群初始化中引入 Tent 混沌序列扰动, 利用该扰动在每次迭代时更新种群粒子, 以保持算法迭代过程中粒子的多样性.

1 电动汽车有序充放电调度问题

随着 EV 数量的增加, 用户负荷的峰谷差日益显著, 同时用户对电网效率的不满也逐渐加剧. 有序充放电可以有效缓解电网负荷的峰谷差, 同时使用户有机会通过电量交易获取利润.

在面对有序充放电问题时, 需要满足一系列等式约束和不等式约束, 本文选取电网负荷波动最小和用户综合满意度作为多个优化目标, 并对其模型进行详细构建^[5].

1.1 目标函数

1) 本文以微网负荷波动最小为目标之一, 将每日负载曲线的方差作为目标函数的表现形式, 即

$$J = \text{var}(\text{Loads}) = \sum_{t=1}^T \frac{1}{T} (\text{Loads}(t) - \text{Mean}(\text{Loads}))^2 \quad (1)$$

其中: T 为 24 h; J 为日负载方差; Loads 为某时刻的负载; Mean 为均值; var 为负载方差.

2) 将用户的经济满意度和便利满意度作为量化目标, 经济满意度为

$$R_{1,i} = 1 - e^{-\frac{c_{ex,i}}{c}} \quad (2)$$

其中: $R_{1,i}$ 为第 i 位用户的经济满意度; $c_{ex,i}$ 为第 i 位用户的预期电价; c 为采用有序充放电后的每时段电价^[6].

3) 用户便利满意度目标函数为

$$R_{2,i} = 1 - \frac{\sum_{k=1}^{kT_a} |L_{sch,t,i} - L_{t,i}|}{\sum_{t=1}^T L_{t,i}} \quad (3)$$

其中: T_a 为单位时间间隙时长; $R_{2,i}$ 为第 i 位用户的便利满意度; $L_{sch,t,i}$ 为实行调度后第 i 辆车在该时段的负载值; $L_{t,i}$ 为实行调度前第 i 位用户每时段的负载值.

4) 用户的综合满意度由经济满意度和便利满意度共同描述:

$$R_i = \frac{1}{\alpha R_{1,i} + (1 - \alpha) R_{2,i}} \quad (4)$$

其中, α 为用户对两种满意度的偏好系数. 对满意度值取倒数, 将求最大值转化为求最小值, 并进行优化求解.

由于两个目标相差3个数量级,在求解过程中较难绘制帕累托边界,因此本文对两个目标函数进行归一化,采用将多目标函数转化为单目标函数的仿真方法.

1.2 约束条件

受EV设备和物理规律限制,EV的充放电速率和电池容量应保持在一定范围内以不影响设备寿命;EV的充放电平衡和行驶距离与电荷消耗之间的关系也需要满足现代物理规律.

1) EV行驶时消耗的电荷与其电量平衡关系为

$$\text{SOC}_{t,i} = \text{SOC}_{t-1,i} - \frac{\text{DL}_i}{\text{DL}_{\max}}. \quad (5)$$

其中: $\text{SOC}_{t,i}$ 为 t 时刻电池状态; DL_i 为第 i 辆车的行驶距离; DL_{\max} 为车辆一次行驶的最大距离.

2) EV充放电的电池容量平衡关系为

$$\text{SOC}_{t,i} = (\text{SOC}_{t-1,i} T_a \text{Ch}_{\text{rate}}) \times 100\%. \quad (6)$$

其中: Ch_{rate} 为EV充电速率;当计算EV放电时电池容量时, Ch_{rate} 替换为 Dch_{rate} ,即EV的放电速率.

3) EV接入微网时的总电量公式为

$$E_{\text{agg},i} = \sum_{i=1}^T K_i \varphi_{t,i} \text{SOC}_{t,i}. \quad (7)$$

其中: K_i 为第 i 辆EV的电池容量; $\varphi_{t,i}$ 表示 t 时段EV是否接入微网,如果为1则表明已接入微网,如果为0则表明没有接入微网.

4) EV的电池状态、充放电速率约束为

$$\left. \begin{aligned} \text{SOC}_{\min} &\leq \text{SOC}_i \leq 1, \\ \text{Ch}_{\min,\text{rate}} &\leq \text{Ch}_{\text{rate}} \leq \text{Ch}_{\max,\text{rate}}, \\ \text{Dch}_{\min,\text{rate}} &\leq \text{Dch}_{\text{rate}} \leq \text{Dch}_{\max,\text{rate}} \end{aligned} \right\} \quad (8)$$

其中: SOC_{\min} 是保证用户能够从公司停车场安全回家的最低电量;在住宅停车场,该参数受第二天出行所需的最低电量限制; $\text{Ch}_{\min,\text{rate}}$ 和 $\text{Dch}_{\min,\text{rate}}$ 分别是EV的最小允许充放电速率; $\text{Ch}_{\max,\text{rate}}$ 和 $\text{Dch}_{\max,\text{rate}}$ 分别是EV的最大允许充放电速率.

2 改进多目标粒子群优化算法

2.1 多目标粒子群优化算法

粒子群优化算法是一种基于社会动物集体行为的群体性进化算法^[7].多目标粒子群优化算法则是将粒子群中的非支配解集作为搜索方向,以逼近帕累托边界的最优值^[8].在传统多目标粒子群优化算法中,所有粒子都使用单一的搜索模式,这导致种群过早收敛、多样性差,并且降低了算法的泛化能力^[9].第 i 个粒子的速度和位置可以表示为

$$\left. \begin{aligned} V_i(t+1) &= WV_i(t) + C_1 R_1 (X_{\text{pbest},i} - X_i(t)) + \\ &C_2 R_2 (X_{\text{gbest}} - X_i(t)), \\ X_i(t+1) &= X_i(t) + V_i(t+1). \end{aligned} \right\} \quad (9)$$

其中: $V_i(t)$, $X_i(t)$ 是第 i 个粒子在 t 时刻的速度和位置; W , C_1 , C_2 分别是粒子群的惯性权重、个体最佳学习因子和群体最佳学习因子; R_1 , R_2 是0~1区间内的随机数; $X_{\text{pbest},i}$, X_{gbest} 则是粒子的个体最佳位置和群体最佳位置.

2.2 算法改进

2.2.1 Tent混沌序列扰动

传统的粒子群优化算法在种群初始化方面对初始解的敏感性较高,易陷入局部最优解.为改善多目标粒子群算法的种群初始化质量,本文采用Tent混沌序列扰动改进种群的初始化方法,通过扰动原始解的位置,增强原始解的多样性,有利于算法跳出局部最优,提高初始解的质量,并增强算法的全局搜索能力^[10].Tent映射在 $[0, 0.05]$ 和 $[0.9, 1]$ 2个范围内的取值概率最高.

Tent混沌序列扰动的映射表达式为

$$X_{i+1} = \begin{cases} 2X_i, & X_i \in [0, 0.5]; \\ 2(1-X_i), & X_i \in [0.5, 1]. \end{cases} \quad (10)$$

初始化公式为

$$X_{\text{new}} = (X + X')/2. \quad (11)$$

其中: X' 是产生的扰动量; X_{new} 是混沌扰动后的个体.

扰动量的产生按以下步骤进行:

步骤1 根据式(10)生成混沌变量 X_d .

步骤2 将 X_d 映射到待求解空间,使扰动变量位于 $[-0.4, 0.99]$ 的解空间中.

$$X_{\text{new}} = D_{\min} + (D_{\max} - D_{\min}) X_d. \quad (12)$$

其中, D_{\min} , D_{\max} 分别是 X 每个维度的最小值和最大值.

步骤3 按照式(11)对粒子进行混沌扰动,通过Tent混沌序列扰动使得解在邻域 $[-0.36, 0.3]$ 内波动,从而改善全局搜索能力.

2.2.2 多角色多策略优化

传统的粒子群优化算法中,所有粒子都执行相同的搜索策略,导致搜索策略多样性不足,限制了种群对解空间的搜索.为了提升粒子群的搜索能力,将粒子分为3个群体:精英粒子、一般粒子和学习粒子.划分粒子的指标采用密度指标和质量指标,并使用综合指标评估粒子的性能.

1) 质量指标根据该粒子与最近2个粒子的欧氏距离以及结合非支配排序法解的层级进行

衡量,由公式(15)计算得到.

2) 密度指标用该粒子邻域内粒子的稀疏性表示,由公式(16)计算得出.

3) 综合指标由公式(17)计算,数值越小说明粒子多样性越好,则赋予精英粒子的角色.精英粒子数量占种群总数的20%,超过60%的赋予一般粒子,剩下的赋予学习因子.

针对粒子的决策划分,本文采用多样性的搜索策略:

1) 精英粒子最贴合最优值,其位置最靠近全局最优值,下一步很有可能是非支配解,应减少改变,因此在参数设置上应取中间值.

2) 一般粒子仅次于精英粒子,距离非支配解集有一定距离且多样性较差.在参数上选择全局学习因子的最大值以向全局最优值靠拢,惯性权重和个体学习因子则选择中间值.

3) 学习粒子的收敛性较差,需要调整为较小的惯性权重、个体学习因子以及较大的全局学习因子,以确保其向全局最优值靠拢.

除了上述多样性策略,本文受文献[11]启发,进一步采用离群点思想,通过计算离群因子 Lf_i 来判断粒子是否为极端解.计算公式:

$$\rho_i = \frac{2}{d_{i1} + d_{i2}}, \quad (13)$$

$$Lf_i = \frac{\rho_{j1}/\rho_i + \rho_{j2}/\rho_i}{2}. \quad (14)$$

其中: d_{i1}, d_{i2} 分别表示第 i 个粒子的最近邻和次近邻的欧氏距离; ρ_i 是第 i 个粒子的局部可达密度; ρ_{j1}, ρ_{j2} 分别表示与第 i 个粒子最近邻和次近邻的两个粒子的局部可达密度; 如果离群因子 $Lf_i \leq 1$, 则表示该粒子偏离其他粒子; 如果离群因子 $Lf_i > 1$, 则表示该粒子与其他粒子在同一簇中. Lf_i 值越小, 表明该粒子为极端解的概率越高.

在衡量粒子的质量指标时,非支配排序法是一种常用的方法.该方法对所有粒子进行排序并分配不同的层级,当粒子的解的层级越小,表明该粒子距离最优值越近,质量性能越好.然而,在经过非支配排序后,可得到每个粒子所属的层数 F_i , 层数越小,结果越接近最优值.但在非支配排序中有时会出现收敛性较差的极端解,引入离群因子可以解决此类问题.综合考虑解的层数 F_i 和离群因子 Lf_i 即可得到质量指标 E_i :

$$E_i = \begin{cases} F_i + 1, Lf_i \leq 1; \\ F_i, Lf_i > 1. \end{cases} \quad (15)$$

在进化过程中,位于目标空间稀疏区域的粒

子有利于维持种群多样性^[11].密度指标公式为

$$D_i = \frac{1}{d_{i2} + 2}. \quad (16)$$

其中, D_i 体现了粒子所在区域的稀疏性.若 D_i 越小,表示粒子的邻域越稀疏,反之则越密集.稀疏粒子可以扩大探索空间,而极端解在该层是稀疏的,在种群中可能位于密集区域,也可能位于稀疏区域^[11].考虑质量指标可能会忽视极端解的优势,因此也需要结合密度指标.这里将两个指标综合考虑,计算为

$$R_i = E_i^{\sqrt{N}} + D_i^{\sqrt{N}}. \quad (17)$$

其中, N 为粒子群的种群数量.指标 R_i 越小表示粒子多样性越好,更接近最优值;指标 R_i 越大说明粒子多样性越差,与最优值相差较远.

将粒子按照 R_i 从小到大排序,通过非支配排序获得各粒子的排名 S_i , 将其分为3类粒子:精英粒子、一般粒子和学习粒子.3类粒子的分类指标 R_{0i} :

$$R_{0i} = \begin{cases} 1, S_i \in [0, 0.2N]; \\ 2, S_i \in [0.2N, 0.8N]; \\ 3, S_i \in [0.8N, N]. \end{cases} \quad (18)$$

其中:1表示精英粒子;2表示一般粒子;3表示学习粒子.

对于粒子群优化算法中的3种粒子,通过调整其参数来赋予不同的策略,以实现更全面的解空间搜索.对于精英粒子,保持自身优势继续在解空间中搜索;对于一般粒子,令其充分搜索精英粒子附近的解空间;由于学习粒子远离最优解,因此取最大的全局学习因子向最优解靠拢.通过调整3类粒子的3个参数——惯性权重和两个学习因子的值,进而改变其搜索策略,从而实现更全面的空间搜索.

2.3 IMRPC-PSO 算法流程

在EV有序充放电调度问题中,需要综合考虑负载的不平衡性和用户的综合满意度,因此需要采用多目标优化算法来解决.多目标优化算法可以同时优化多个目标函数,得到一组非支配解;而单目标优化算法仅针对单一目标函数.并且多目标优化求得非支配解后通常需要绘制帕累托边界曲线.本文算法将两个目标函数值进行归一化,并将其组合成单目标函数再进行优化,从而避免了帕累托边界曲线的绘制.算法流程如图1所示.

步骤1 随机生成数量为 N 的粒子群,并对该粒子群进行初始化,然后进行Tent混沌序列扰动.

步骤2 根据约束方程,计算每个粒子的适

应度,并将其作为个体最优解。

步骤 3 根据支配关系获得初始非支配解集,并获得全局最优解;根据多角色划分策略将粒子赋予不同角色。

步骤 4 每个粒子按照参考策略执行对应的更新公式,并根据支配关系更新个体最优值和全局最优值。

步骤 5 更新非支配解集,剔除被支配解。

步骤 6 若达到迭代次数或满足迭代要求,则退出迭代;否则返回步骤 3。

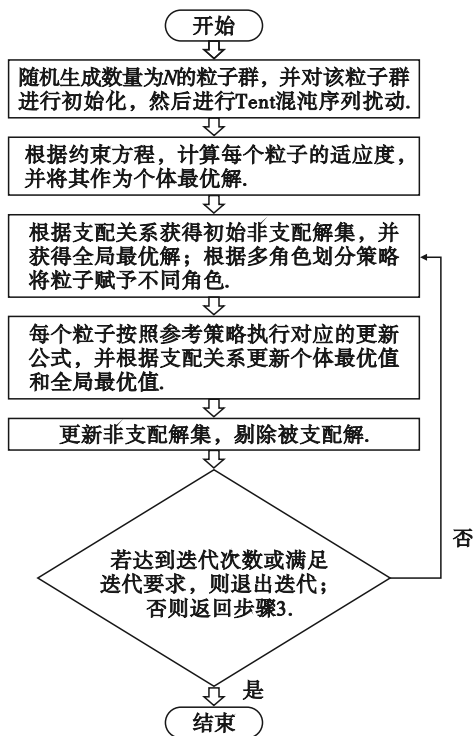


图 1 IMRPC-PSO 算法流程图

Fig. 1 Flowchart of the IMRPC-PSO algorithm

3 仿真实验及结果分析

为了验证 IMRPC-PSO 算法的有效性,对某地存在规模化电动汽车接入的微网进行了仿真分析.根据美国对部分地区电动汽车数量的评估数据,并结合微网可容纳的最大汽车数量,设置电动汽车数量分别为 100, 500 和 1 000 辆时进行案例分析^[12].在配备 Intel Core i7-9750H 和 8 GB RAM 的计算机上进行仿真,操作系统为 Windows 10,使用 Matlab 9.0 进行仿真计算。

3.1 IMRPC-PSO 解决电动汽车调度问题

本案例分别对 100, 500 和 1 000 辆电动汽车进行实验.案例中种群数量为 26,最高迭代 200 次.同时将本文所提出的算法与多目标粒子群优

化算法(MOPSO)^[13]、多目标混沌扰动粒子群优化算法(CMOPSO)^[10]、多目标多角色多策略粒子群优化算法(MMMOPSO)^[7]、遗传算法(NSGA2)^[14]和人工蜂群算法(ABC)^[15]的结果进行比较。

100 辆电动汽车在微网中采取有序充放电策略后的结果,以及微网每日负载和量化后的用户综合满意度指标,如表 1 所示.由表 1 可知,IMRPC-PSO 的负载结果为 210.661 kW,而 CMOPSO 的负载结果为 211.076 kW,IMRPC-PSO 相比于 CMOPSO 减少了 0.19%. IMRPC-PSO 的用户综合满意度最好,结果为 5.23,而 MMMOPSO 的结果为 5.28,IMRPC-PSO 相比 MMMOPSO 降低了 0.94%,综合结果表明 IMRPC-PSO 性能最好。

表 1 不同算法求解 100 辆 EV 问题的结果比较
Table 1 Comparison of results in solving problems with 100 EVs using different algorithms

算法	负载/kW	用户满意度
IMRPC-PSO	210.661	5.23
MOPSO ^[13]	218.723	5.28
CMOPSO ^[10]	211.076	5.27
MMMOPSO ^[7]	218.746	5.26
NSGA2 ^[14]	214.710	5.28
ABC ^[15]	242.603	5.59

500 辆电动汽车在微网中采取有序充放电策略后的结果,以及微网每日负载和量化后的用户综合满意度指标,如表 2 所示.由表 2 可知,大幅度增加电动汽车数量后,微网负载功率值上涨,而且用户满意度大幅下降.这是由于电动汽车入网接口有限导致充放电需要排队,从而便利性满意度大幅降低.表中,ABC 的负载结果为 2 193.556 kW,IMRPC-PSO 的负载结果为 2 434.919 kW,两者相比,ABC 较 IMRPC-PSO 减少了 9.9%.MOPSO 的用户综合满意度为 -29.2,而 MMMOPSO 和 IMRPC-PSO 分别为 -32.2 及 -32.8, MOPSO 相比于 MMMOPSO 和 IMRPC-PSO 结果分别提高了 9.3% 和 11%.由于 ABC 在用户综合满意度优化效果不佳,且 MOPSO 负载优化效果较差,综上所述,IMRPC-PSO 的结果最优。

1 000 辆电动汽车在微网中采取有序充放电策略后的结果,以及微网每日负载和量化后的用户综合满意度指标,如表 3 所示.由表 3 可知,微网负载进一步上升,用户满意度相对保持平稳.这是因为随着更多电动汽车接入微网,负载上升而用户满意度中的便利性造成的影响被经济效益弥合,用户获利也会更多.ABC 的负载结果为 5 413.999 kW,

IMRPC-PSO的负载结果为4 720.114 kW,IMRPC-PSO相比ABC减少了12.8%.NSGA2的用户综合满意度结果为-33.6,MOPSO的结果为-36.4,NSGA2结果相比于MOPSO提高了7.7%.在负载优化方面,IMRPC-PSO结果更好,而在用户满意度优化方面,NSGA2结果更好,综上所述,当电动汽车数量较大时,ABC算法结果更好.

表2 不同算法求解500辆EV问题的结果比较
Table 2 Comparison of results in solving problems with 500 EVs using different algorithms

算法	负载/kW	用户综合满意度
IMRPC-PSO	2 434. 919	-32. 8
MOPSO ^[13]	4 322. 687	-29. 2
CMOPSO ^[10]	3 594. 713	-33. 1
MMMOPSO ^[7]	2 961. 451	-32. 2
NSGA2 ^[14]	4 103. 258	-34. 0
ABC ^[15]	2 193. 556	-40. 7

表3 不同算法求解1 000辆EV问题的结果比较
Table 3 Comparison of results in solving problems with 1 000 EVs using different algorithms

算法	负载/kW	用户综合满意度
IMRPC-PSO	4 720. 144	-52. 2
MOPSO ^[13]	8 182. 282	-36. 4
CMOPSO ^[10]	5 657. 921	-51. 2
MMMOPSO ^[7]	7 753. 242	-37. 1
NSGA2 ^[14]	8 591. 319	-33. 6
ABC ^[15]	5 413. 999	-36. 5

由IMRPC-PSO算法在3个案例中的负载结果可知,100辆电动汽车的结果为210.661 kW;500辆电动汽车的结果为2 434.919 kW;1 000辆电动汽车的结果为4 720.114 kW.可以看出,在100辆电动汽车参与优化时,有序充放电的结果最好.而IMRPC-PSO算法中各案例的用户综合满意度分别为5.23,-32.8和-52.2.由上述数据可以得出,IMRPC-PSO适合接入电网的EV数量较少的情况.考虑到在参与优化的EV数量较少时充电会更方便,然而电价会相对较高;若EV参与的数量较多时,充电机会减少,相对价格增多,即便利满意度上升而经济满意度下降.同时对于一个中小型规模的社区而言,微网可承担EV数量一般在100辆左右,因此下文在优化时采取110辆.

3.2 负载优化和用户满意度优化

3.2.1 负载优化

分别求解110辆EV在不同算法优化后的负

载值 and 用户满意度.粒子数量为26,迭代次数为200.然后对比不同算法的优化结果.6种算法的优化结果如图2a所示,IMRPC-PSO算法优化后的负载最小且平稳.从表2和图2a可以看出,NSGA2算法虽然部分迭代次数的负载值优于IMRPC-PSO算法,但是该算法并不稳定,在迭代40次后始终在某个范围内波动,这说明NSGA2算法稳定性较差,在实际应用中,IMRPC-PSO和CMOPSO更为合适.由图2b可知,在迭代次数90~130之间,MOPSO的优化效果优于MMMOPSO和CMOPSO.

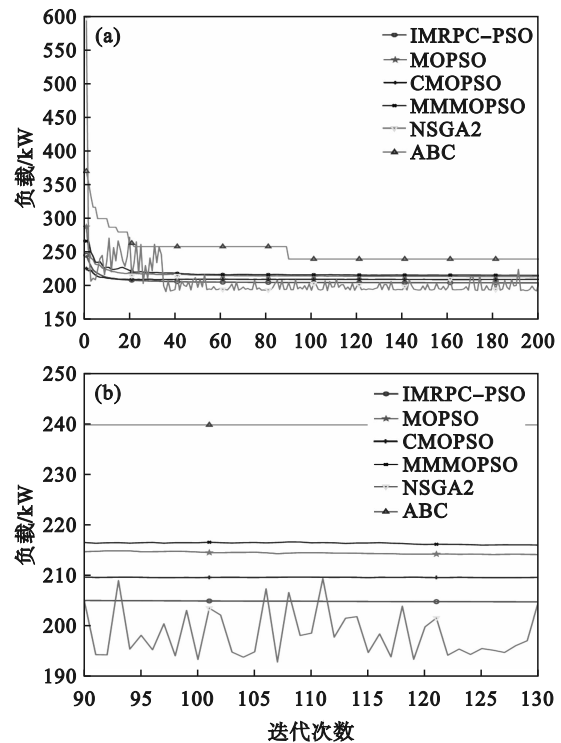


图2 110辆EV负载仿真结果图

Fig. 2 Load simulation results of 110 EVs

(a)—200次迭代图像;(b)—90~130次迭代图像.

3.2.2 用户满意度优化

本文将用户对EV有序充放电策略的综合满意度进行量化,并作为目标函数进行优化.结果显示,IMRPC-PSO的结果最优,ABC算法结果较差.NSGA2算法在迭代初期时结果不稳定,在20次之前基本不收敛,在20到40次之间波动范围逐渐收缩,在40次之后才趋向于局部收敛.然而由图3a可知,NSGA2算法仍不稳定,在5.25与5.3之间波动,这是因为NSGA2算法容易陷入局部收敛,导致最终结果不收敛.在90~130次迭代过程中,由图3b可知,MOPSO,MMMOPSO以及CMOPSO结果类似,均弱于IMRPC-PSO.




图3 110辆EV用户满意度仿真结果图

Fig. 3 Simulation results of user's satisfaction for 110 EVs

(a)—200次迭代图像; (b)—90~130次迭代图像.

3.2.3 综合优化

本文将两个变量转化为一个变量,即多目标转化为单目标进行优化.由于负载指标数量级远大于用户综合满意度指标数量级,因此首先将两个指标转化为同一数量级,然后分别乘以0.5获得最终的结果.最终结果如图4a所示,迭代90~130次的详细结果如图4b所示.由图4a可知,

IMRPC-PSO的结果略优于CMOPSO,二者性能相近;而MOPSO和MMMOPSO结果基本类似,其优化结果均弱于IMRPC-PSO以及CMOPSO;ABC算法搜索能力较弱,在最终结果上不及其他4种粒子群优化算法;NSGA2算法虽然在部分迭代次数结果较优,但其收敛能力较差,始终在一个区间内波动,无法达到最终收敛.




图4 110辆EV BestCost仿真结果图

Fig. 4 BestCost simulation results for 110 EVs

(a)—200次迭代图像; (b)—90~130次迭代图像.

MOPSO, MMMOPSO, CMOPSO 和 IMRPC-PSO 收敛速度快,在迭代20次后基本达到稳定,ABC算法在90次后达到稳定;NSGA2算法在40次后在区间内波动,但始终不能收敛.算法之间的具体差异可由图4b(迭代次数90~130之间)的详细结果查看.

NSGA2的迭代初期结果分别为16.1和22.9.由表4和图4b可知,NSGA2算法的稳定性与收敛性较差,而ABC算法的搜索能力较弱.

将两个变量转化为一个变量后,用BestCost表示.在迭代次数早期,由表4可见,IMRPC-PSO和CMOPSO的迭代初期结果分别为10.8和11.0.这两个算法均使用了Tent混沌序列扰动,加快了算法初期的搜索能力,因此迭代初期结果较好,同时也使算法收敛速度加快,收敛结果更优.而MMMOPSO和MOPSO的迭代初期结果分别为11.7和11.4,说明两算法在迭代初期的收敛速度较慢.ABC和

表4 不同算法求解110辆EV问题的结果比较
Table 4 Comparison of results in solving problems with 110 EVs using different algorithms

算法	Tent	BestCost
IMRPC-PSO	是	10.8
MOPSO ^[13]	否	11.4
CMOPSO ^[10]	是	11.0
MMMOPSO ^[7]	否	11.7
NSGA2 ^[14]	否	22.9
ABC ^[15]	否	16.1

4 结 论

本文针对电动汽车接入电网时所面临的物理和设备约束问题进行了研究,并提出了改进的多目标策略多样性混沌序列扰动粒子群优化(IMRPC-PSO)算法来解决这一问题.该算法考虑了用户综合满意度对电动汽车并网调度策略的影响.为了应对模型难以求解的非线性和多目标等问题,本文采用了IMRPC-PSO算法,该算法结合多角色划分和Tent混沌序列扰动的思想,能够有效解决电动汽车有序充放电问题.通过仿真实验,与其他5种算法进行对比,结果表明该算法在收敛速度、降低成本和稳定性等方面具有优势,验证了算法的有效性,为解决电动汽车有序充放电调度问题提供了一种行之有效的方法.

参考文献:

- [1] He Y F, Venkatesh B, Guan L. Optimal scheduling for charging and discharging of electric vehicles [J]. *IEEE Transactions on Smart Grid*, 2012, 3(3): 1095-1105.
- [2] Dang S P, Odonde A, Mirza T, et al. Sustainable energy management: an analysis report of the impacts of electric vehicles [C]//2014 14th International Conference on Environment and Electrical Engineering. Krakow, 2014: 318-322.
- [3] Wei H Q, Zhang Y T, Wang Y Z, et al. Planning integrated energy systems coupling V2G as a flexible storage [J]. *Energy*, 2022, 239: 122215.
- [4] Shafiq S, Al-Awami A T. Reliability and economic assessment of renewable micro-grid with V2G electric vehicles coordination [C]//2015 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT). Amman, 2015: 1-6.
- [5] Ahmadi S, Arabani H P, Haghghi D A, et al. Optimal use of vehicle-to-grid technology to modify the load profile of the distribution system [J]. *Journal of Energy Storage*, 2020, 31: 101627.
- [6] Zhang Q, Hu Y, Tan W Y, et al. Dynamic time-of-use pricing strategy for electric vehicle charging considering user satisfaction degree [J]. *Applied Sciences*, 2020, 10(9): 3247.
- [7] Marini F, Walczak B. Particle swarm optimization (PSO): a tutorial [J]. *Chemometrics and Intelligent Laboratory Systems*, 2015, 149: 153-165.
- [8] Coello C A, Lechuga M S. MOPSO: a proposal for multiple objective particle swarm optimization [C]//Proceedings of the 2002 Congress on Evolutionary Computation. Honolulu, 2002: 1051-1056.
- [9] Breunig M M, Kriegel H P, Ng R T, et al. LOF: identifying density-based local outliers [C]//Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data. Dallas, 2000: 93-104.
- [10] 吕鑫, 慕晓冬, 张钧, 等. 混沌麻雀搜索优化算法 [J]. 北京航空航天大学学报, 2021, 47(8): 1712-1720. (Lyu Xin, Mu Xiao-dong, Zhang Jun, et al. Chaos sparrow search optimization algorithm [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2021, 47(8): 1712-1720.)
- [11] 王万良, 金雅文, 陈嘉诚, 等. 多角色多策略多目标粒子群优化算法 [J]. 浙江大学学报(工学版), 2022, 56(3): 531-541. (Wang Wan-liang, Jin Ya-wen, Chen Jia-cheng, et al. Multi-objective particle swarm optimization algorithm with multi-role and multi-strategy [J]. *Journal of Zhejiang University (Engineering Science)*, 2022, 56(3): 531-541.)
- [12] Becker T A, Sidhu I, Tenderich B. Electric vehicles in the United States: a new model with forecasts to 2030 [M]. Berkeley: University of California, 2009.
- [13] Borhanazad H, Mekhilef S, Gounder-Ganapathy V, et al. Optimization of micro-grid system using MOPSO [J]. *Renewable Energy*, 2014, 71: 295-306.
- [14] Adham A M, Mohd-Ghazali N, Ahmad R. Optimization of an ammonia-cooled rectangular microchannel heat sink using multi-objective non-dominated sorting genetic algorithm (NSGA2) [J]. *Heat and Mass Transfer*, 2012, 48(10): 1723-1733.
- [15] Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm [J]. *Journal of Global Optimization*, 2007, 39(3): 459-471.