文章编号：1003-1421(2026)11-0118-10
引用格式：潘福全，黎文正，张丽霞，等. 基于APSO-SA算法的地铁列车复杂线路区间运行工况优化研究[J]. 铁道运输与经济，2026，48(11)：118-127.
PAN Fuquan，LI Wenzheng，ZHANG Lixia，et al. Operation Condition Optimization of Metro Trains in Complex Line Sections Based on APSO-SA Algorithm[J]. Railway Transport and Economy，2026，48(11)：118-127.

基于APSO-SA算法的地铁列车复杂线路区间运行工况优化研究

潘福全[1]，黎文正[1]，张丽霞[1]，杨晓霞[1]，宋夫才[2]，魏金丽[1]

(1.青岛理工大学 城市建设学院，山东 青岛 266520；2.青岛市交通规划设计院有限公司，山东 青岛 266101)

摘 要：针对地铁列车在复杂线路区间运行过程中工况优化的问题，提出了一种融合自适应参数调节与模拟退火接受机制的改进粒子群优化算法(APSO-SA)；在传统PSO框架基础上，对惯性权重与学习因子实行自适应调节，引入模拟退火接受准则与速度随机扰动机制，使粒子以一定概率接受劣解，避免陷入局部最优，通过4种经典测试函数，验证了该算法收敛速度快，不易陷入局部最优。将算法应用于列车运行工况优化中，经验证结果表明，相比于传统PSO优化算法，所提改进算法在保证列车运行准点性与乘坐舒适性的前提下，将能耗降低了10.86%，同时获得了最优工况转换点与对应的速度曲线，验证了算法的可行性与优越性。

关键词：地铁列车；运行工况；自适应调节；模拟退火；改进粒子群算法
中图分类号：U231.9 **文献标识码**：A **DOI**：10.16668/j.cnki.issn.1003-1421.20250708003

Operation Condition Optimization of Metro Trains in Complex Line Sections Based on APSO-SA Algorithm

PAN Fuquan[1]，LI Wenzheng[1]，ZHANG Lixia[1]，YANG Xiaoxia[1]，SONG Fucai[2]，WEI Jinli[1]

(1. School of Urban Construction, Qingdao University of Technology, Qingdao 266520, Shandong, China; 2. Qingdao Transportation Planning and Design Institute Co., Ltd., Qingdao 266101, Shandong, China)

Abstract: To address the problem in operation condition optimization of subway trains in complex line sections, an improved Particle Swarm Optimization (PSO) algorithm that integrates adaptive parameter adjustment and a simulated annealing acceptance mechanism (APSO-SA) was proposed. Based on the traditional PSO framework, an adaptive adjustment strategy was implemented for the inertia weight and learning factors. A simulated annealing acceptance criterion and a stochastic velocity perturbation mechanism were introduced to enable particles to accept inferior solutions with a certain probability and avoid getting trapped in a local optimum. The four classical test functions were employed to validate the fast convergence velocity and strong resistance to local optima of the algorithm. When applied to the train operation condition optimization, the

收稿日期：2025-07-08
通信作者：张丽霞(1978—)，女，湖北天门人，青岛理工大学城市建设学院教授。
基金项目：山东省自然科学基金创新发展联合基金项目(ZR2024LZN012)；国家自然科学基金项目(62373209)

verification results show that, compared with the traditional PSO optimization algorithm, the proposed improved algorithm reduces energy consumption by 10.86% while ensuring the punctuality of train operation and passenger riding comfort. Additionally, it obtains the optimal operation condition conversion points and corresponding velocity curves, validating the feasibility and superiority of the algorithm.

Keywords: Metro Train; Operation Condition; Adaptive Adjustment; Simulated Annealing; Improved Particle Swarm Algorithm

0　引言

地铁列车运行能耗问题与列车运行特性、线路条件、运行策略有关[1]，如何在运行区间寻找最优运行工况转换点，减少列车运行过程中的能源消耗，对推动城市轨道交通的可持续发展意义深远。国内外学者在列车节能运行优化领域展开了研究，Song等[2]以高速列车节能运行优化为目标，提出一种双速度曲线优化的方法，对列车的实际运行速度曲线进行优化；Liu等[3]进一步引入坡段识别与分段优化策略，在保持运行时间约束下，实现了多坡度区间的局部节能控制；Chen等[4]对列车典型工况进行分析，以列车运行时间、能耗、停车精度为目标进行分析；Wang等[5]基于遗传算法原理对其优化改进，提高遗传算法在解决复杂非线性列车自动驾驶(ATO)速度曲线优化问题的性能；Gao等[6]使用灰色模型改进遗传算法对列车自动控制策略进行研究；Ning等[7]提出了一种深度确定性策略梯度的高速铁路列车轨迹优化方法，通过离线训练生成最优列车轨迹，确保列车的准点性和能源效率；徐凯等[8]融合了传统的粒子群优化(PSO)算法与改进布谷鸟算法，构建了一种混合算法用于地铁列车多目标优化；Wei等[9]针对速度构建多目标优化模型，并将差分进化算法与模拟退火算法相结合，构建了混合进化算法对目标进行求解。虽然上述研究进行了部分改进，但在算法优化过程中，对惯性权重、学习因子的调节策略单一，未充分考虑粒子迭代过程中个体探索、全局收敛的需求，部分研究引入模拟退火算法仅作为全局搜索补充，未与粒子群算法的速度更新、工况约束深度耦合，现有研究多聚焦单一坡度区间或理想化线路条件，对实际复杂坡度场景的适配性不足，难以在多工况动态转换中稳定寻优，容易出现收敛速度慢、陷入局部最优解等问题。

因此针对复杂坡度场景下的地铁列车运行工况优化问题进行研究，采用改进的自适应粒子群-模拟退火(APSO-SA)算法对地铁列车运行中工况转换点的优化进行求解，该算法将PSO算法中学习因子与权重进行改进，同时融合模拟退火(SA)算法的接受机制和速度随机扰动机制，增强算法的收敛速度，加强全局搜索能力，避免陷入局部最优，并结合实际线路条件验证算法的可行性。

1　列车运行工况描述与分析

地铁列车在连续坡道与曲线线路耦合作用下，牵引能耗呈显著非线性特征。在复杂坡度区间运行时，列车除受基本阻力、附加阻力和势能变化影响外，还需满足线路限速与运行时间的要求。高豪等[10]研究表明不同工况组合及转换点位置会显著影响速度曲线和能耗，因此需在保证安全、准点、停车精度和舒适度的前提下，优化求解各坡度曲率下的最佳工况转换点及其对应的速度曲线与能耗水平。

地铁列车运行时包含4种基本工况[11]：牵引、巡航、惰行、制动。列车运行工况是指列车在特定运行条件下，由工作环境、负载特性及性能指标等要素共同构成的综合运行状态。不同的运行工况组合会直接影响行程耗时与动力消耗，在确定行程时间要求的情况下，总能找到至少一种最优控制方法，能满足时间约束的同时实现最低能量消耗，称之为该运行时段内的最优运行组合工况[12]。不同运行工况速度曲线示意图如图1所示，描述了复杂坡度区间内不同运行工况组合下的速度-位移曲线，L_1，L_0，L_{-1}分别表示首次进入巡航、惰行和制动工况的位置。若线路区间较短时，可采用“牵引-惰行-制动”的组合运行工况，若线路区间较长时，通常采用“牵引-巡航-惰行-制动”的4阶段组合运行工况，以降低运行能耗；由于实际线路区间的

坡度、曲率与限速的不同，实际线路运行中可能会采用多次“牵引-巡航-惰行”或“巡航-惰行”组合工况。因此，在满足各种约束条件与实际线路区间运行的条件下，需要优化工况转换点的位置，获得最优驾驶曲线，求解最优运行能耗。

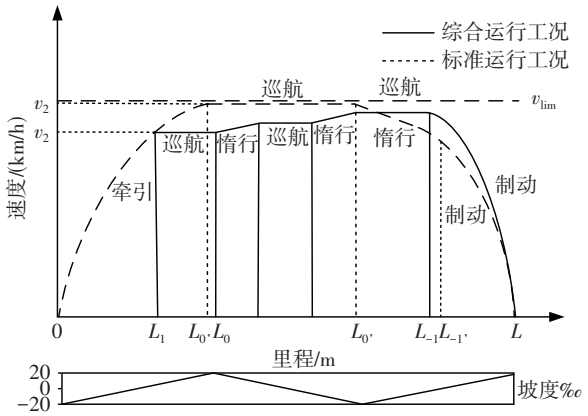


图1　不同运行工况速度曲线示意图

Fig.1　Velocity curves under different operation conditions

根据列车运行工况的转换特性，假设长度L的区间内有k个转换点，令列车在第k个转换点处的位置为x_k，控制模式$U_k \in \{-1, 0, 1, 2\}$，分别对应制动、惰行、巡航和牵引工况，同时引入对应位置处的速度变量v_k，则模型决策变量如式(1)所示。

$$x = \{x_1, x_2, \cdots, x_k, U_1, U_2, \cdots, U_k, v_1, v_2, \cdots, v_k\} \tag{1}$$

在给定线路长度L内，需确定一组工况转换点x_k，并在每个转换点处给出对应的运行工况U_k与速度v_k，求解运行能耗，模型约束条件如式(2)所示。

$$\begin{cases} 0 = x_0 < x_1 < \cdots < x_k = L \\ u_k \in [-1, 0, 1, 2] \quad k = 1, 2, \cdots, k \\ 0 \leqslant v_k \leqslant v_{\lim}(x_k) \\ v_0 = v_L = 0 \\ |a_k| = \left| \dfrac{v_{k+1}^2 - v_k^2}{2(x_{k+1} - x_k)} \right| \leqslant a_{\max} \end{cases} \tag{2}$$

式中：L为线路长度，m；$v_{\lim}(x_k)$为最大限速，km/h；$a_{\max}$为最大加速度，m/s^2。

当列车在长度为L的区间运行时，驾驶工况转换原则如表1所示。

表1　驾驶工况转换原则

Tab.1　Principles for switching driving conditions

转换后工况	转换前工况			
	牵引	巡航	惰行	制动
牵引	/	Y	Y	N
巡航	Y	/	Y	Y
惰行	Y	Y	/	Y
制动	N	Y	Y	/

注：Y表示允许工况转换；N表示不允许工况转换；/表示同一阶段，不存在转换。

2　列车模型建立

2.1　列车动力学模型

一般情况下，将列车看作均质的刚性质点，即单质点模型，不考虑各车厢间的相互作用力。对列车运行时的受力进行分析，则列车受力可表示为

$$\begin{cases} a(t) = \dfrac{\mathrm{d}v}{\mathrm{d}t} = \dfrac{F_{\text{total}}}{(1+\gamma)M} \\ v(t) = \dfrac{\mathrm{d}x}{\mathrm{d}t} \end{cases} \tag{3}$$

式中：$a(t)$为t时刻的加速度，m/s^2；M为列车的质量，kg；F_{total}为列车所受合力，N/kN；$v(t)$为列车运行速度，km/h；t为列车运行时间，s；γ为列车旋转质量系数，通常取传统经验值0.06。列车所受合力可表示为

$$F_{\text{total}} = F_q(v) - F_b(v) - F_y(v) - F_{\text{add}}(\theta) \tag{4}$$

式中：θ为坡度角，°；$F_q(v)$为列车在速度v下的牵引力，N/kN；$F_b(v)$为列车在速度v下的制动力，N/kN；$F_y(v)$为列车在速度v下运行的基本阻力，N/kN；$F_{\text{add}}(\theta)$为线路坡度为θ时的列车附加阻力，N/kN。列车运行基本阻力$F_y(v)$可表示为

$$\begin{cases} F_y(v) = \dfrac{F_y \cdot M \cdot g}{1\,000} \\ F_y = a + bv + cv^2 \end{cases} \tag{5}$$

式中：a，b，c为基本阻力系数；F_y为单位基本阻力，N/kN。列车附加阻力$F_{\text{add}}(\theta)$由坡度阻力$F_g(\theta)$、曲线阻力F_{curve}和隧道阻力F_{tunnel}构成，各分量计算公式如式(6)所示。

$$\begin{cases} F_{\text{add}}(\theta) = \dfrac{(F_g(\theta) + F_{\text{curve}} + F_{\text{tunnel}}) \cdot M \cdot g}{1\,000} \\ F_g(\theta) = 1\,000\sin\theta \\ F_{\text{curve}} = \dfrac{K_a}{R} \\ F_{\text{tunnel}} = 0.000\,13L_t \end{cases} \tag{6}$$

式中：R为曲线半径，m；K_a为曲线阻力常数，通常取值为600；L_t为隧道长度，m；$F_g(\theta)$为单位坡道附加阻力，N/kN；F_{curve}为单位曲线附加阻力，N/kN；

F_{tunnel}单位隧道附加阻力，N/kN，通常取经验公式。

列车运行的受力特性随工况动态变化，当列车运行速度为v时，牵引力$F_q(v)$与制动力$F_b(v)$可通过牵引/制动特性曲线实时获取。各工况动力学模型如式(7)—(10)所示。

处于牵引工况时(U_k=2)

$$F_{\text{total}} = F_q(v) - F_y(v) - F_{\text{add}}(\theta) \tag{7}$$

处于巡航工况时(U_k=1)

$$F_q(v) = F_y(v) + F_{\text{add}}(\theta),\ F_{\text{total}} = 0,\ F_b(v) = 0 \tag{8}$$

处于惰行工况时(U_k=0)

$$F_q(v) = 0,\ F_b(v) = 0,\ F_{\text{total}} = -\left(F_y(v) + F_{\text{add}}(\theta)\right) \tag{9}$$

处于制动工况时(U_k=−1)

$$F_q(v) = 0,\ F_b(v) = -F_b(v),\ F_{\text{total}} = -\left(F_b(v) + F_y(v) + F_{\text{add}}(\theta)\right) \tag{10}$$

式中：$F_q(v)$为速度v时的牵引力，N/kN；$F_b(v)$为速度v时的制动力，N/kN；$F_y(v)$为速度v时的列车基本运行阻力，N/kN；$F_{\text{add}}(\theta)$为坡度θ时的列车附加阻力，包含坡度阻力、曲线阻力、隧道阻力，N/kN；F_{total}为列车所受合力，N/kN，决定列车的加速度状态。

为便于数值仿真，采用离散时间方法处理列车站间运行的连续过程，设定时间步长为Δt，假设每个离散区间内列车受力恒定，作匀变速运动，可迭代求解各时间步长内的加速度、速度、位移及单位步长瞬时能耗，则数值关系可表示为

$$\begin{cases} a_{i+1} = \dfrac{F_{\text{total}}}{(1+\gamma)M} \\ v_{i+1} = v_i + a_i \cdot \Delta t \\ L_{i+1} = L_i + v_i \cdot \Delta t + \dfrac{1}{2} a_i \cdot \Delta t^2 \\ \Delta E_i = F_q \cdot v_{i+1} \cdot \Delta t \end{cases} \tag{11}$$

式中：a_{i+1}，a_i分别为t_{i+1}，t_i时刻列车的加速度，m/s^2；v_{i+1}，v_i分别为t_{i+1}，t_i时刻列车的运行速度，km/h；L_{i+1}，L_i分别为t_{i+1}，t_i时刻列车的运行距离，m；ΔE_i为列车在(t_i，t_{i+1})时间内的能耗，kW·h；F_q为列车在(t_i，t_{i+1})时间内的牵引力，N/kN；Δt为一个单位时间步长，s。

2.2　列车能耗与约束模型

列车牵引能耗仅存在于牵引(U_k=2)与巡航(U_k=1)工况，处于惰行(U_k=0)与制动(U_k=−1)工况时，列车无牵引力做功。因此，列车运行总能耗可由牵引力做功的时域积分离散化求得

$$E_{\text{总}} = \sum_{i=1}^{N} \delta_i \cdot F_q(i) \cdot v_i \cdot \Delta t \tag{12}$$

式中：$E_{\text{总}}$表示累计运行能耗，kW·h；δ_i为工况指示函数，牵引/巡航工况δ_i取1，制动/惰行工况δ_i取0；$F_q(i)$为t_i时刻的牵引力，N/kN；v_i为t_i时刻的速度，km/h。

列车运行过程中各约束条件如式(13)—(16)所示。

（1）运行安全约束。

$$0 \leqslant v(i) \leqslant v_{\text{lim}} \tag{13}$$

式中：v_{lim}为列车站间运行的最大限制速度，km/h。

（2）准时性约束。

$$\begin{cases} T_{\min} \leqslant T \leqslant T_{\max} \\ |T - T_P| \leqslant \varepsilon(\text{t}) \end{cases} \tag{14}$$

式中：$\varepsilon(t)$为允许的运行时间差，s，通常不超所计划运行时间的5%；T_P表示计划运行时间，s；T表示实际运行时间，s。

（3）停车精度约束。

$$\varepsilon(L) = |L - L_n| \tag{15}$$

式中：$\varepsilon(L)$表示精确停车误差，一般为±30 cm；L为列车在相邻两站之间实际运行的距离，m；L_n为相邻两站之间的距离，m。

（4）舒适度约束。舒适度通常通过冲击率$Jerk$来表示，如式(16)所示。

$$Jerk = \int \left| \frac{\text{d}a(t)}{\text{d}t} \right| \text{d}t \tag{16}$$

式中：$a(t)$为列车的加速度，m/s^2。

舒适度等级判定如表2所示。

表2　舒适度等级判定

Tab.2　Judgment of comfort levels

舒适度等级	加速度/(m/s^2)	评价等级
等级1	<0.315	很舒适
等级2	0.315~0.63	舒适
等级3	0.63~1.0	一般舒适
等级4	1.0~1.6	不舒适
等级5	1.6~2.5	很不舒适
等级6	>2.5	极不舒适

综合上述分析，构建了地铁列车节能运行优化模型，如式(17)所示。

$$\begin{cases} \min E_{总}=\sum_{i=1}^{N}\delta_i\cdot F_q(i)\cdot v_i\cdot\Delta t \\ \dfrac{\mathrm{d}v}{\mathrm{d}t}=\dfrac{F_q(v)-F_b(v)-F_y(v)-F_{\mathrm{add}}(\theta)}{(1+\gamma)M} \\ \dfrac{\mathrm{d}x}{\mathrm{d}t}=v \\ T_{\min}\leqslant T\leqslant T_{\max} \quad |T-T_p|\leqslant\varepsilon T_p \\ |L-L_n|\leqslant 30\ \mathrm{cm} \quad l_1=0,\ l_n=L \\ 0\leqslant v_i\leqslant v_{\lim}(v_k) \quad v_1=0,\ v_L=0 \\ \left|\dfrac{\mathrm{d}v}{\mathrm{d}t}\right|\leqslant a_{\max} \\ K_j=\int\left|\dfrac{\mathrm{d}a(t)}{\mathrm{d}t}\right|\mathrm{d}t \end{cases} \tag{17}$$

式中：$E_{总}$为列车运行能耗，kW·h；T为列车站间运行总时间，s；$v_{\lim}$为列车运行最大限速，km/h；K_j为加速度变化率，即舒适度指标，其值越小，乘客的舒适度越高；$a_{\max}$为列车运行允许的最大加(减)速度，m/s²；v_1，v_L为列车在起点与终点的速度，km/h；l_1，l_n为列车初始位置和列车终点位置，m。

3　算法设计

传统粒子群优化算法在保持种群多样性方面效果欠佳，算法迭代时易出现早熟收敛，陷入局部最优解，难以实现全局范围内的高效寻优。而模拟退火算法则构建了一个基于概率突跳特性的全局搜索框架，初始阶段设置较高温度参数，随着迭代次数的增加，系统温度按预定策略递减，从而改善解的质量。其中，Metropolis接受准则作为算法的核心决策机制，允许在特定条件下接受适度劣化解，提升获得全局最优解的能力。因此，研究提出了一种改进的粒子群优化算法用于求解该优化问题，该算法在传统PSO的基础上，对惯性权重与学习因子实行自适应调节；并且引入模拟退火接受机制与速度随机扰动机制，以一定概率接受劣质解，增强收敛速度与全局寻优性能，避免陷入局部最优。

3.1　双因子改进PSO

PSO算法中的粒子模拟鸟群飞行的行为，互相进行信息交流，来搜索目标函数最优解，计算模型如式(18)所示。

$$\begin{cases} v_{i,j}(k+1)=\omega v_{i,j}(k)+c_1r_1\left(p_{i,j}(k)-x_{i,j}(k)\right)+c_2r_2\left(g_{i,j}(k)-x_{i,j}(k)\right) \\ x_{i,j}(k+1)=x_{i,j}(k)+v_{i,j}(k+1) \end{cases} \tag{18}$$

式中：ω为惯性权重，用于描述粒子过往的速度对该时刻的速度影响程度；$v_{i,j}(k)$为第i个粒子在第k次迭代中的速度；$x_{i,j}(k)$为该粒子当前位置的第j个维度；学习因子c_1，c_2分别为个体与群体对速度调整的影响系数；r_1，r_2是[0，1]区间内的随机变量；$p_{i,j}(k)$是个体当前搜索过程中的最优位置；$g_{i,j}(k)$为种群在第k代中的全局最优解。

根据适应度数值对惯性权重实施动态自适应调节[13]，构建了基于个体适应度动态调整惯性权重的模型，以提升算法的搜索性能，如式(19)所示。

$$\omega=\begin{cases} \omega_{\min}+\dfrac{(\omega_{\max}-\omega_{\min})(f-f_{\min})}{f_{\mathrm{average}}-f_{\min}} & f\leqslant f_{\mathrm{average}} \\ \omega_{\max} & f>f_{\mathrm{average}} \end{cases} \tag{19}$$

式中：f为当前粒子的适应度值；f_{average}为适应度值的平均值，即所有粒子适应度值的算术平均，$f_{\mathrm{average}}=\dfrac{1}{n}\sum_{i=1}^{n}f_i$；$f_{\min}$为适应度最小值，遍历当前迭代所有粒子的适应度值$f_i$($i$=1，2，…，$n$，$n$为粒子总数)，取其中最小数值，即$f_{\min}=\min\{f_1,f_2,\cdots,f_n\}$，反之取最大值；$\omega_{\max}$，$\omega_{\min}$分别为惯性权重系数的最大值和最小值，取0.95和0.4。

在粒子群优化算法中，学习因子c_1，c_2分别用于调控粒子向个体最优解和全局最优解方向的引导[14]。随着迭代次数的增加，惯性权重ω逐步减小，同时c_1逐渐降低、c_2逐步增大，以增强算法后期的全局引导能力，改进后的学习因子可表示为

$$\begin{cases} c_1=c_{1\mathrm{s}}-(c_{1\mathrm{s}}-c_{1\mathrm{e}})\dfrac{k}{k_{\max}} \\ c_2=c_{2\mathrm{e}}+(c_{2\mathrm{s}}-c_{2\mathrm{e}})\dfrac{k}{k_{\max}} \end{cases} \tag{20}$$

式中：$c_{1\mathrm{s}}$，$c_{1\mathrm{e}}$分别为个体学习因子的上限与下限；$c_{2\mathrm{s}}$，$c_{2\mathrm{e}}$分别为群体学习因子的上限与下限；k为当前迭代次数；$k_{\max}$为最大迭代次数。本研究中，$c_{1\mathrm{s}}$=2.5，$c_{1\mathrm{e}}$=1.25；$c_{2\mathrm{s}}$=1.25，$c_{2\mathrm{e}}$=2.5。通过实验验证，学习因子c_1、c_2可影响迭代前期个体的探索与后期全局收敛的动态平衡，上下限取此值时可使算法在迭代前期突出粒子的“自我认知”，避免列车工况优化初期陷入局部最优解；迭代后期强化“群体学

习”加速收敛至全局最优工况序列。

3.2　融合SA接受机制与速度随机扰动机制

为提高算法的全局搜索能力，在传统PSO算法基础上融合了模拟退火接受机制，通过Metropolis准则来判定是否接受新的解[15]，允许算法早期广泛探索解空间，后期逐步收敛至最优解。粒子位置的更新根据接受准则进行，如式(21)—(22)所示。

$$P_{\text{accept}}=\begin{cases}1 & \Delta f<0\\ e^{\left(\frac{-\Delta f}{T(k)}\right)} & \Delta f\geqslant 0\end{cases} \tag{21}$$

$$\begin{cases}\Delta f=f\left(x_{i,j}(k+1)\right)-f\left(x_{i,j}(k)\right)\\ T(k+1)=\alpha\cdot T(k) \quad 0<\alpha<1\end{cases} \tag{22}$$

式中：Δf为新解与当前解的适应度差值；$T(k)$为逐步衰减的温度；α取0.9。

同时引入速度随机扰动机制[16]，该机制在粒子更新时对当前位置向最优目标位置处引入一定的随机性，增加搜索空间的多样性，提高搜索效率，随机扰动机制可表示为

$$v_{i,j}(k+1)=\omega v_{i,j}(k)+c_1r_1\left(p_{i,j}(k)-x_{i,j}(k)\right)+c_2r_2\left(g_{i,j}(k)-x_{i,j}(k)\right)+\lambda\left(x_{i,j}(k)-g\right) \tag{23}$$

式中：λ为(0，1]内的随机数；g为最优目标，也就是对应满足所有约束条件的全局最优工况序列及速度曲线的解，通过引入当前位置指向最优目标点的向量，可进一步丰富粒子速度更新约束，使得各粒子更快逼近最优目标点，有效减少传统粒子群算法迭代次数。

3.3　改进算法优化步骤

步骤1：输入列车参数与线路数据，确定搜索空间边界、搜索速度的上下限、设定种群规模Size和最大迭代次数$K_{\max}$。

步骤2：为种群内全部粒子随机生成初始位置x和初始速度v。

步骤3：利用自定义函数求解各粒子工况轨迹对应的适应度值，设置退火初温$T_{\max}$、最小温度$T_{\min}$和衰减系数α。

步骤4：依据当前适应度值，对惯性权重ω、学习因子c_1和c_2进行自适应调节。

步骤5：迭代更新粒子位置和速度，执行寻优操作。

步骤6：重新计算适应度，更新粒子个体历史最优位置及种群全局最优位置。

步骤7：计算出新解的接受概率。

步骤8：使用Metropolis准则判断，将接受概率与随机数rand对比，判断是否以新解替换全局最优解，并对温度进行衰减处理。

步骤9：检查是否达到最大迭代次数$K_{\max}$，若未达到返回步骤5继续优化。

步骤10：输出当前最优解算法终止。

算法优化流程图如图2所示。

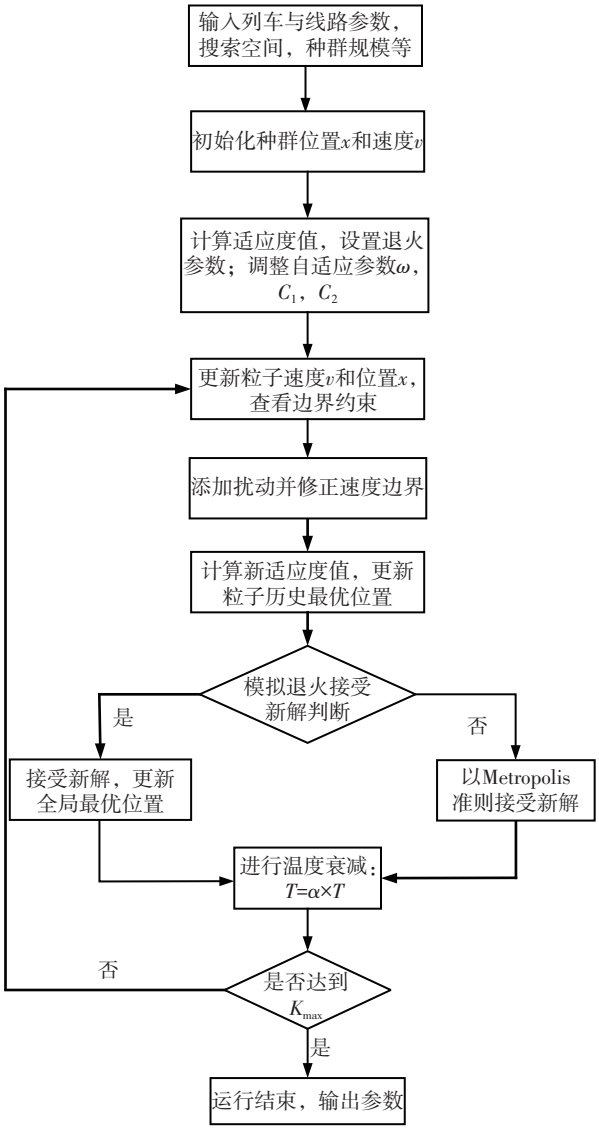


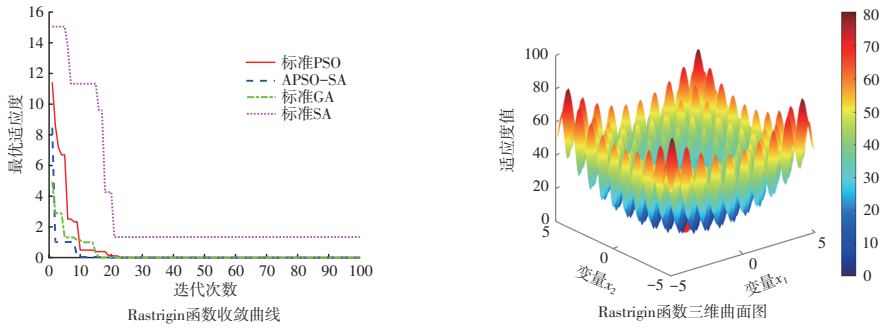
图2　算法优化流程图

Fig.2　Flowchart for algorithm optimization

3.4　算法评价

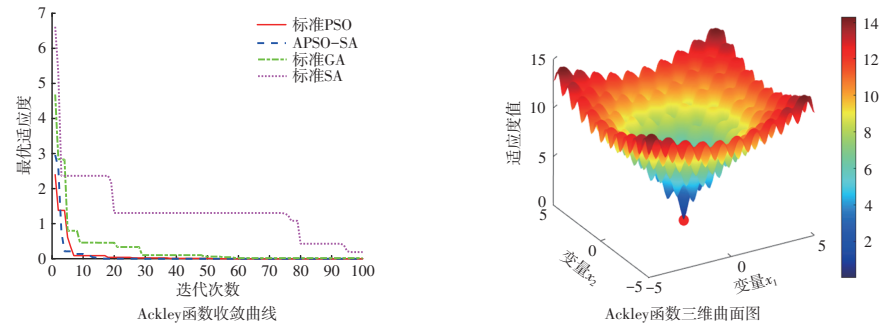
为全面评估所提出的改进粒子群优化算法的性能，选择4个经典测试函数：Sphere，Rastrigin，

Ackley，Griewank，作为算法性能的测试基准。仿真算法种群规模设置为50，迭代次数100代。4种算法在4个经典测试函数下的性能比较如图3所示，改进的粒子群优化算法相比于标准PSO算法种群全局搜索性更强、收敛速度更快、适应度值更小。



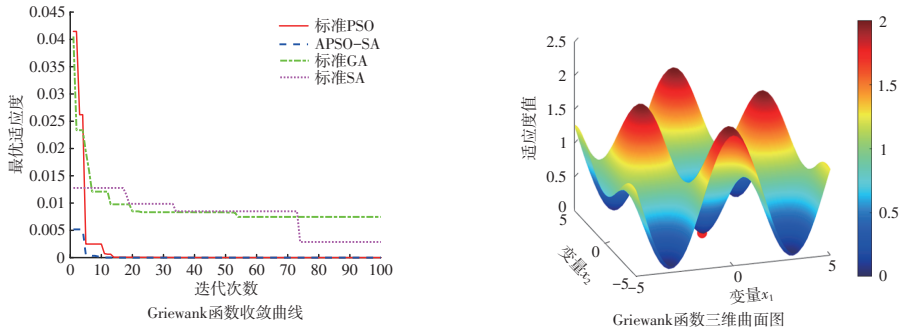
a　Rastrigin函数性能测试

a　Performance test of Rastrigin function



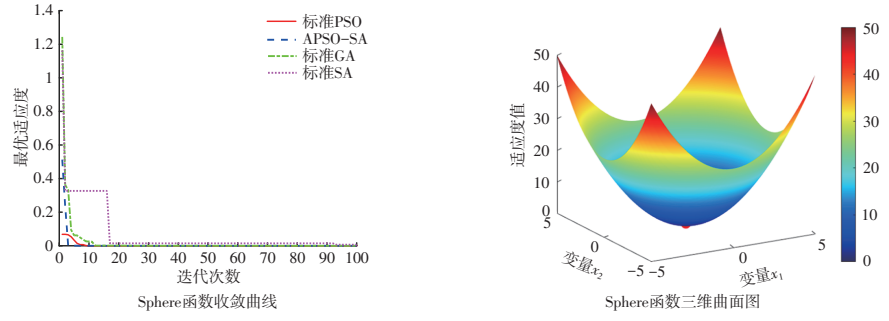
b　Ackley函数性能测试

b　Performance test of Ackley function



c　Griewank函数性能测试

c　Performance test of Griewank function



d　Sphere函数性能测试

d　Performance test of Sphere function

图3　4种算法在4个经典测试函数下的性能比较

Fig.3　Performance comparison of four algorithms on four classical test functions

4　仿真验证分析

为验证改进APSO-SA算法的可行性与有效性，选择西安地铁4号线[17]常青路—市中医医院区间作为仿真验证分析条件，区间全长1 474 m，包含下坡、上坡路段，具有典型节能坡段的特征，区间计划运行时间为101 s，仿真实验列车参数如表3所示，线路限速如表4所示，线路坡度如表5所示。

表3　列车参数

Tab.3　Train parameters

列车基本参数	取值
车型	B2
列车重量/t	206
列车长度/m	118
最大加速度/(m/s^2)	1
最大减速度/(m/s^2)	1
最大运行速度/(km/h)	80
基本运行阻力/(N/kN)	0.000 429v^2+2.755 102
牵引力/kN	F_q=203 kN(0 km/h≤v≤55 km/h); −0.002 032v^3+0.492 8v^2−42.13v+ 1 343(55 km/h≤v≤80 km/h)
制动力/kN	F_b=166 kN(0 km/h≤v≤77 km/h); 0.134v^2−25.07v+1 300(77 km/h≤v≤80 km/h)

表4　线路限速

Tab.4　Line speed limits

起点/m	终点/m	长度/m	限速/(km/h)
0	192	192	80
192	792	600	60
792	1 273	481	80
1 273	1 345	72	60
1 345	1 474	129	80

表5　线路坡度

Tab.5　Line gradient

起点/m	终点/m	长度/m	坡度/‰
0	119	119	−2
119	319	200	−18.3
319	653	334	−8
653	1 170	517	5.78
1 170	1 381	211	25
1 381	1 474	93	2

使用标准粒子群优化算法与所提的改进APSO-SA优化算法分别对线路区间的运行工况转换点进行寻优并获得列车最优速度曲线与运行能耗，将标准粒子群优化算法与改进的APSO-SA算法优化后的区间运行能耗进行对比分析，仿真优化结果对比分析如表6所示.

表6　仿真优化结果对比分析

Tab.6　Comparative analysis of simulation optimization results

算法	计划时间/s	实际时间/s	能耗/(kW·h)
PSO	101	101.3	20.560
APSO-SA	101	103.9	18.326

通过表6中数据分析可知，列车在满足各种约束条件下，改进的APSO-SA优化算法相比于传统PSO算法，列车区间运行时间相比于计划运行时间延长了2.9 s，满足运行时间的要求，乘客在整体出行时间中并无明显体感，且算法优化的运行工况平滑转换，可提升乘客舒适度，在整个调度系统中处于时间波动阈值内，不会引发列车晚点、站台客流积压等连锁反应，且算法可以在后续区间动态调整运行时间，保障全程的准点率；在能耗优化方面，优化前的列车站间运行能耗为25.358 kW·h，经过传统PSO算法优化的运行能耗为20.560 kW·h，改进的APSO-SA算法优化的运行能耗为18.326 kW·h，相比于传统PSO算法，经改进APSO-SA算法优化后运行能耗降低约10.86%；经上述分析，在满足各约束条件下，改进APSO-SA算法能够通过优化工况转换有效降低运行能耗，保证乘客乘坐体验和调度系统协同。

改进APSO-SA算法优化后的速度-距离曲线如图4所示，加速度变化曲线如图5所示，运行工况转换位置如图6所示，2种算法的运行速度曲线对比图如图7所示。由图4—图6分析可知，改进的APSO-SA算法优化后的列车运行工况以最大牵引工况起步加速运行，随后转为惰性工况利用下坡的

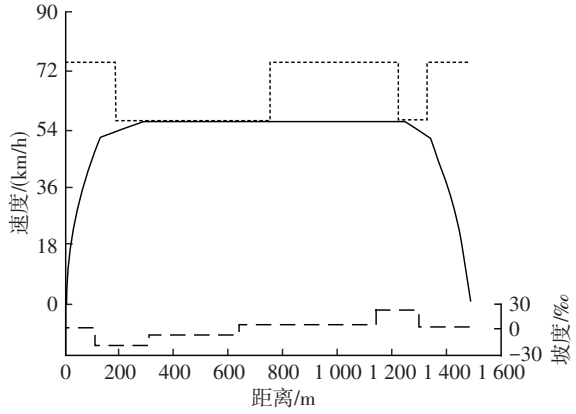


图4　改进APSO-SA算法优化后的速度-距离曲线

Fig.4　Velocity-distance curve optimized by the improved APSO-SA algorithm

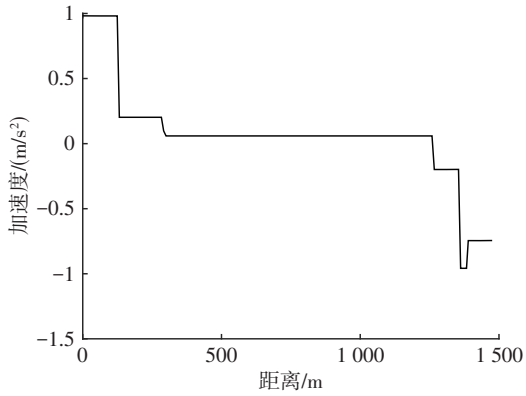


图5　加速度变化曲线

Fig.5　Acceleration variation curve

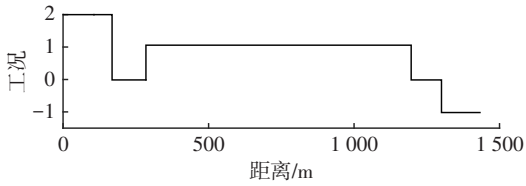


图6　运行工况转换位置

Fig.6　Switching positions of operation conditions

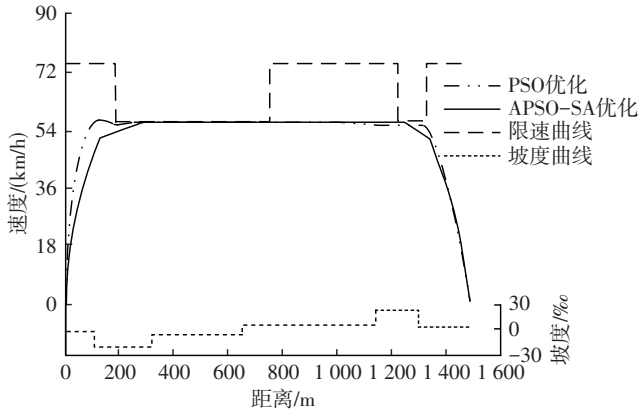


图7　2种算法的运行速度曲线对比图

Fig.7　Comparison of running speed curves of two algorithms

势能提高速度，达到最高限速后转为巡航工况，运行一段距离后再次转换为惰性工况，减小列车运行能耗，最后以制动工况进站停车。列车运行工况序列为：牵引-惰行-巡航-惰行-制动。由图7可以看出，经过改进的APSO-SA算法优化后得到的运行速度曲线较平稳，同时能满足列车运行时各种约束条件，节约列车运行能耗，能够为地铁列车节能优化策略提供有效的指导。

5　结论

（1）建立了均质刚性质点列车模型，采用改进的粒子群优化算法对单个复杂坡度区间下的单列车运行工况转换位置进行寻优。以西安地铁4号线常青路—市中医医院上行单向区间为案例进行验证，在满足列车运行时间、停车精度、乘客舒适度等约束条件下，可获得最优工况组合的列车速度曲线。相比于传统粒子群算法，改进的粒子群优化算法可使列车能耗降低10.86%，案例应用验证了改进粒子群优化算法寻优运行工况的有效性，表明本方法在复杂坡度场景下具备显著节能效果，可显著降低线路运营成本，符合城市轨道交通低碳化发展需求。

（2）尽管优化后存在运行速度较快的曲线，但列车运行控制系统通常会对速度进行平滑处理，可以有效避免速度变化对舒适性和设备稳定性的影响。本研究提出的算法为离线优化模式，可在运行图编制阶段预先生成并存储最优曲线，列车运行时仅需按预生成曲线执行速度追踪，在实际自动运行控制系统中具备可行性和实用性。

（3）在求解时选用的模型为均质刚性单质点模型，未考虑列车间的相互作用力，后续研究可以考虑使用受力更加准确的多质点模型进行求解；只考虑了单列车单区间场景下优化控制策略，未考虑多列车多区间条件下的协同配合，后续可进一步进行研究。

参考文献：

[1] 张惠茹，贾利民，王　莉. 基于Pareto多目标优化的高速铁路列车节能驾驶曲线集生成[J]. 铁道学报，2021，43(3)：85-91.
ZHANG Huiru，JIA Limin，WANG Li. Study on Generation of Energy-Saving Driving Curves of High Speed Train Based on Pareto Multi-Objective Optimization[J]. Journal of the China Railway Society，2021，43(3)：85-91.

[2] SONG Y D，SONG W T. A Novel Dual Speed-Curve Optimization Based Approach for Energy-Saving Operation of High Speed Trains[J]. IEEE Transactions on Intelligent Transportation Systems，2016，17(6)：1564-1575.

[3] LIU W T，TANG T，SU S，et al. Energy-Efficient Train Driving Strategy with Considering the Steep Downhill Segment[J]. Processes，2019，7(2)：77.

[4] CHEN X Q，MENG J J，XU R X，et al. Research on Multi-

Objective Optimization Methods of Urban Rail Train Automatic Driving Based on NSGA-II[J]. Electronics，2024，13(19)：3971.

[5] WANG G Y，XIAO S，CHEN X，et al. Application of Genetic Algorithm in Automatic Train Operation[J]. Wireless Personal Communications，2018，102(2)：1695-1704.

[6] GAO F，LI F，YU Z，et al. Study on Optimization of Automatic Train Operation Based on Grey Genetic Algorithm[J]. Journal of Physics：Conference Series，2019，1237(2)：022147.

[7] NING L B，ZHOU M，HOU Z P，et al. Deep Deterministic Policy Gradient for High Speed Train Trajectory Optimization[J]. IEEE Transactions on Intelligent Transportation Systems，2022，23(8)：11562-11574.

[8] 徐　凯，吴　磊，杨飞凤. PSO-ICS算法优化的城轨列车自动驾驶系统[J]. 铁道科学与工程学报，2017，14(12)：2704-2712.
XU Kai，WU Lei，YANG Feifeng. Automatic Train Operation System in Urban Rail Transit Based on PSO-ICS Algorithm Optimization[J]. Journal of Railway Science and Engineering，2017，14(12)：2704-2712.

[9] SHANGGUAN W，YAN X H，CAI B G，et al. Multiobjective Optimization for Train Speed Trajectory in CTCS High Speed Railway with Hybrid Evolutionary Algorithm[J]. IEEE Transactions on Intelligent Transportation Systems，2015，16(4)：2215-2225.

[10] 高　豪，柴　娟，凌小雀，等. 基于列车节能运行的惰行-巡航组合控制策略[J]. 城市轨道交通研究，2024，27(11)：13-17.
GAO Hao，CHAI Juan，LING Xiaoque，et al. Coasting-Cruising Combined Control Strategy Based on Train Energy-Efficient Operation[J]. Urban Mass Transit，2024，27(11)：13-17.

[11] HE D Q，ZHANG L，GUO S L，et al. Energy-Efficient Train Trajectory Optimization Based on Improved Differential Evolution Algorithm and Multi-Particle Model[J]. Journal of Cleaner Production，2021，304：127163.

[12] 王清永，钱广民，刘　颖，等. 考虑驾驶策略与再生能利用的城轨列车运行图节能优化[J]. 铁道运输与经济，2024，46(11)：30-38.
WANG Qingyong，QIAN Guangmin，LIU Ying，et al. Energy Saving Optimization of Urban Rail Train Working Diagram Considering Driving Strategy and Regenerative Energy Utilization[J]. Railway Transport and Economy，2024，46(11)：30-38.

[13] 杨　辉，李　莹，周艳丽. 基于APSO的地铁节能运行速度优化研究[J]. 铁道科学与工程学报，2020，17(8)：1926-1934.
YANG Hui，LI Ying，ZHOU Yanli. Research on Optimization of Energy-Saving Operation Speed of Metro Based on APSO[J]. Journal of Railway Science and Engineering，2020，17(8)：1926-1934.

[14] 苏明健，肖宝弟，岳丽丽. 基于改进PSO-SA算法的城轨列车ATO节能优化研究[J]. 传感器与微系统，2023，42(10)：64-67，76.
SU Mingjian，XIAO Baodi，YUE Lili. Research on ATO Energy Saving Optimization of Urban Rail Train Based on Improved PSO-SA Algorithm[J]. Transducer and Microsystem Technologies，2023，42(10)：64-67，76.

[15] 刘晓飞，米根锁，赵　妍. 改进粒子群算法在城轨列车节能运行中的应用[J]. 传感器与微系统，2021，40(8)：152-156.
LIU Xiaofei，MI Gensuo，ZHAO Yan. Application of Improved PSO Algorithm in Energy Saving Operation of Urban Rail Train[J]. Transducer and Microsystem Technologies，2021，40(8)：152-156.

[16] 倪建云，张风杰，尚红志，等. 改进A-Star算法融合提升DWA算法的路径规划[J]. 陕西师范大学学报(自然科学版)，2025，53(6)：32-40.
NI Jianyun，ZHANG Fengjie，SHANG Hongzhi，et al. Integrating the Improved A-Star Algorithm and the Enhanced DWA Algorithm for the Path Planning[J]. Journal of Shaanxi Normal University (Natural Science Edition)，2025，53(6)：32-40.

[17] 杨晓芳. 基于改进粒子群算法的城轨列车节能优化方法[C]//中国科学技术协会. 2023世界交通运输大会(WTC2023)论文集(下册). 北京：人民交通出版社，2023：754-758.

(责任编辑　汪沁萱)