

DOI:10.19651/j.cnki.emt.2519235

基于改进 A 星和灰狼优化的多点测试路径规划^{*}

周 虎 薛冰荣

(东华大学机械工程学院 上海 201600)

摘要: 针对电磁干扰测试多点路径规划问题,提出了一种基于改进 A 星算法与灰狼优化算法结合的路径规划方法。首先,对传统 A 星算法进行了改进,通过改进启发函数和引入冗余点删除策略,减少了路径长度和算法时间。然后,将测试路径规划问题转化为经典旅行商问题,并应用改进的灰狼优化算法进行求解,以获得最优测试路径。实验结果表明,与传统方法相比,改进方法的路径规划总距离平均减少了 4.73%,转弯次数平均减少了 30.42%,总转弯角度平均减少了 34.74%,计算时间平均减少了 39.47%,有效提升了测试的效率和安全性,为电磁干扰多目标点测试任务提供了一种可靠的解决方案。

关键词: 电磁干扰测试;路径规划;A 星算法;旅行商问题;灰狼优化算法

中图分类号: TN98;TP29 **文献标识码:** A **国家标准学科分类代码:** 520.1040

Multi-point test path planning based on improved A-star and grey wolf algorithms

Zhou Hu Xue Bingrong

(School of Mechanical Engineering, Donghua University, Shanghai 201600, China)

Abstract: Aiming at the multi-point path planning problem for electromagnetic interference testing, a path planning method based on the combination of improved A-star algorithm and grey wolf optimization algorithm is proposed. First, the traditional A-start algorithm is improved by modifying the heuristic function and introducing a redundant point deletion strategy, thereby reducing path length and algorithm runtime. Then, the test path planning problem is transformed into a classic traveling salesman problem and solved using the improved gray wolf optimization algorithm to obtain the optimal test path. Experimental results demonstrate that compared to traditional methods, the improved approach achieves an average reduction of 4.73% in total path planning distance, 30.42% in average number of turns, 34.74% in average total turning angle, and 39.47% in average computation time. This effectively enhances testing efficiency and safety, providing a reliable solution for electromagnetic interference multi-target point testing tasks.

Keywords: electromagnetic interference testing; path planning; A-star algorithm; traveling salesman problem; grey wolf optimization algorithm

0 引 言

近年来随着电子信息技术的不断发展,其集成密度逐步提高,电磁环境愈加复杂,电磁干扰(electromagnetic interference, EMI)的问题日益突出。EMI 会引发信号失真、数据丢失或设备故障等不良后果,直接影响设备稳定性和市场竞争力。因此,对 EMI 测试的路径进行有效规划,减少探针移动路径,提高测试效率就显得尤为重要,尤其在大批量测试(如电路板生产)中,能显著降低成本并提升效益。

EMI 自动化测试需要机器人将电磁场探针移动到若干设定的测试点上方,对所有的点位进行测试。在测试流程

中,该问题类似于旅行商问题(traveling salesman problem, TSP),电磁场探针要遍历一系列测试点,且遍历路径越短越好。常见的用于解决此类问题的算法有:粒子群优化算法(particle swarm optimization, PSO)^[1-2]、蝙蝠算法(bat algorithm, BA)^[3-4]和灰狼优化算法(grey wolf optimizer, GWO)^[5-6]等,GWO 由于其全局搜索能力强,且具备较好的鲁棒性和易用性,在 TSP 问题中展现了优异的性能。

然而,传统 TSP 问题中待访问的两两目标点之间距离通常为已知的欧氏距离,而在进行 EMI 测试时,由于待测件多种多样,其待测表面往往也是高低不平的,在对多个测试点进行路径规划时,为了防止电磁场探针受到损坏,还需

收稿日期:2025-06-30

^{*} 基金项目:上海市经信委产业化高质量专项(CYLGG-2024-1-32)资助

要考虑障碍物的影响,并在非欧氏距离度量下求解 TSP 问题。

在这些条件下,基于搜索的 A 星算法通过离散化空间和确定性搜索能够确保路径终点与测试点精确重合,而基于采样的算法由于随机性可能导致定位偏差。在路径质量方面,虽然 A 星算法在启发函数不可纳时无法保证全局最优性,但其生成的路径长度仍具有较高的稳定性,这对后续构建精确的距离矩阵以优化测试顺序至关重要。而基于采样的快速探索随机树 (rapidly-exploring random trees, RRT)^[7]等算法的随机性会导致路径长度存在方差,影响 TSP 求解的稳定性。此外,电磁测试对安全性和可重复性要求极高,A 星算法的确定性保证了每次规划结果一致,便于验证和标准化。虽然基于采样的算法在高维动态环境中更具优势^[8](如机械臂运动规划或无人机轨迹规划),但 EMI 测试通常只需二维位置规划,并且障碍物的位置都是固定的,A 星算法的计算效率已完全满足需求,且在在路径的精确性、最优性、可靠性上具有明显优势。

A 星算法通过融合广度优先和深度优先搜索的双重优势,配合可调节的启发式函数,可以灵活优化搜索过程^[9-10],研究者们对此进行多种尝试与改进。汪四新等^[11]通过引入中心虚拟目标点并构建衰减函数,促使双向 A 星算法搜索过程在中心区域收敛,虽然提升了算法收敛速度,但生成的路径仍存在节点冗余问题。王中玉等^[12]通过调整评价函数中各项权重的比例系数,降低了路径的冗余点,但该方法探索时间仍较长。Chen 等^[13]将方向约束条件融入节点扩展过程,配合自适应步长调整策略,该方法能获得更优搜索时间和更短搜索路径。

本文针对上述 EMI 多点测试的路径规划问题提出了一种改进 A 星与 GWO 相结合的算法:首先,在 A 星算法的启发函数中引入了包含障碍发布系数的动态权重,对冗余点进行删除后构建两两测试点距离矩阵;然后,采用 Tent 混沌映射初始化灰狼算法,结合非线性收敛因子和 2-opt、3-opt 等多种算子求解 TSP 问题,优化测试点顺序,最终得到安全高效的 EMI 测试路径。

1 改进的 A 星路径规划算法

1.1 经典 A 星算法原理

经典 A 星算法是一种广泛应用于路径规划的启发式算法。其在 Dijkstra 算法的基础上采用了启发式评估函数来指导搜索,同时保留了从起点到当前节点的实际代价信息,通过结合路径的实际代价和估算代价,有目标的在节点之间寻找综合代价最低的路径。其代价的评估函数表达式为:

$$f(n) = g(n) + h(n) \quad (1)$$

式中: $g(n)$ 表示从起点到当前节点的实际代价。 $h(n)$ 表示从当前节点到目标节点的启发式估计代价。 $f(n)$ 则为当前节点的综合代价值,代表了从起点经过该节点到目标

节点的预期总代价。

启发函数的代价评估通常采用曼哈顿距离、欧几里得距离或对角线距离来^[14]表示,计算公式如下:

$$d_M = |x_c - x_t| + |y_c - y_t| \quad (2)$$

$$d_E = \sqrt{(x_c - x_t)^2 + (y_c - y_t)^2} \quad (3)$$

$$d_D = |x_c - x_t| + |y_c - y_t| + (\sqrt{2} - 2) \min(|x_c - x_t|, |y_c - y_t|) \quad (4)$$

1.2 启发函数改进

在面对较为复杂的场景时,传统 A 星算法的启发函数在最优节点的评估上存在偏差,导致出现路径搜索效率低、规划出的路径并非最短、转角多等问题。

传统启发函数中,采用曼哈顿距离时,虽能生成平直路径,但未考虑斜向移动的距离,存在一定误差,而对角线距离更准确的反映了节点间的实际距离。将这 2 种距离结合起来表示当前节点 X 到目标节点 Y 之间的距离 $d_{x,t}$,可以取长补短,兼顾效率与准确性。

$$\begin{cases} d_{x,t} = \alpha \cdot d_M + \beta \cdot d_D \\ \alpha + \beta = 1 \end{cases} \quad (5)$$

式中: d_M 表示当前节点到目标节点的曼哈顿距离; d_D 表示当前节点到目标节点的对角线距离。根据文献[15], $\alpha = 0.4, \beta = 0.6$ 综合效果较好。

同时,传统 A 星算法中的启发函数权重固定,搜索速度慢,容易扩展无用节点,导致计算量大,搜索效率低下,且无法根据不同环境动态调整。针对上述问题,对启发函数引入新的动态权重系数 $w(n)$ 进行改善:

$$\begin{cases} F(n) = g(n) + w(n)h(n) \\ w(n) = \ln(e + r/R) - P \end{cases} \quad (6)$$

式中: $w(n)$ 为启发函数 $h(n)$ 的动态权重系数, r 为当前节点到目标节点的对角线距离, R 为起始点到目标点的对角线距离。

在开始时,启发函数权重较大,加速全局搜索;随着越来越接近目标点, $w(n)$ 逐渐降低,使算法可以在开始时快速探索出一条路线,减少无用节点的扩展,并在逐渐接近目标点的同时,增加探索节点的数量,增加路径的优良性。此外,动态权重系数考虑了不同地图下的当前节点与终点之间的障碍物分布系数 P 。

$$P = \frac{M}{(|X_t - X_c| + 1) \times (|Y_t - Y_c| + 1)} \quad (7)$$

式中:障碍物分布系数 P 表示当前节点与目标节点之间的障碍率, M 为两节点之间的障碍物的数量。

当两节点之间的障碍率 P 比较大时,应当对启发函数权重系数进行合理衰减,适当降低启发式搜索的导向强度,扩展算法的探索范围,提高搜寻的精度,以获得最优的路径,反之则应当增加启发函数的权重系数。不同的栅格地图,障碍物的分布率不同,引入障碍物分布系数 P ,可以对地图信息进行量化,调整相应权重值,更好地适应不同地图环境。

本节最终改进启发函数为:

$$F(n) = g(n) + (\ln(e + r/R) - P)h(n) \quad (8)$$

1.3 冗余点删除策略

当使用传统 A 星算法时生成的路径时,由于只能沿着栅格点依次形成避障路径,导致会存在一些不必要的冗余点和转折点。因此本文在改进启发函数的基础上,引入删除冗余节点策略对路径进行优化处理,缩短路径的长度。

采用了一种结合滑动窗口和碰撞检测的冗余节点删除策略,实现路径精简。具体而言,正向优化阶段:采用滑动窗口检测机制,以当前节点为基准点,寻找最远可直达节点,通过碰撞检测验证直线路径的可行性,删除中间冗余节点,保留关键转折点。反向优化阶段:沿逆向路径重复上述检测过程,重点解决正向优化可能遗留的局部最优问题。通过迭代执行“滑动窗口-碰撞检测-冗余点节点删除”的闭环优化,可动态剔除冗余中间点,最终生成由关键节点构成的最简安全路径。算法流程图如图 1 所示。

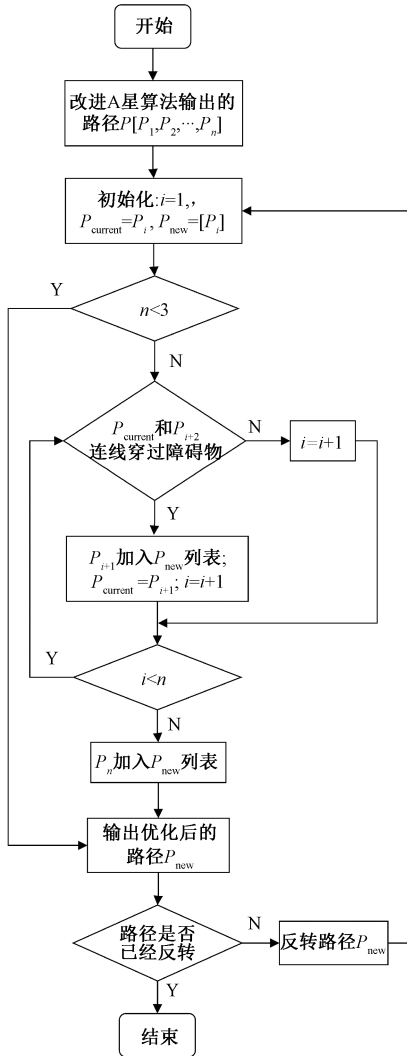


图 1 冗余点删除算法流程图

Fig. 1 Flowchart of redundancy point deletion algorithm

2 改进的灰狼算法

2.1 灰狼算法原理

GWO 是一种元启发式算法,其设计思想源于自然界灰狼种群的狩猎策略,通过模拟灰狼种群的社会层次结构及其协同狩猎机制来实现全局优化^[16]。灰狼群体社会等级结构如图 2 所示,分为 4 层等级,α 狼(领导者):对应优化问题中的最优解;β 狼(次级领导者):对应次优解;δ 狼(哨兵):对应第 3 优解;ω 狼(普通个体):对应其他候选解。



图 2 灰狼社会等级结构

Fig. 2 Social hierarchy structure of grey wolves

对其狩猎行为建模,用数学模型模拟追捕、包围和攻击猎物的过程,描述如下:

$$D = |C \cdot X_p(t) - X(t)| \quad (9)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (10)$$

式中: D 表示灰狼与猎物之间距离; $X(t)$ 表示第 t 次迭代时灰狼的位置向量; $X_p(t)$ 表示第 t 次迭代时猎物的位置向量; t 表示当前迭代次数; A 和 C 表示系数向量。

向量 A 和 C 的计算如下:

$$A = 2a \cdot r_1 - a \quad (11)$$

$$C = 2 \cdot r_2 \quad (12)$$

$$a = 2(1 - \frac{t}{T_{max}}) \quad (13)$$

式中:参数 a 表示收敛因子,其取值区间随迭代次数 t 线性递减(从 2 到 0); r_1 和 r_2 表示 $[0,1]$ 之间的随机向量; T_{max} 为预设的最大迭代次数。

在灰狼群体里,α 狼、β 狼和 δ 狼是距离猎物最近的,剩余的 ω 狼受这 3 种狼的引导进行位置更新,从而逐渐逼近猎物:

$$\begin{cases} D_\alpha = |C_1 X_\alpha(t) - X(t)| \\ D_\beta = |C_1 X_\beta(t) - X(t)| \\ D_\delta = |C_1 X_\delta(t) - X(t)| \end{cases} \quad (14)$$

式中:第 t 次迭代时 α、β、δ 狼的位置用 $X_\alpha(t)$ 、 $X_\beta(t)$ 、 $X_\delta(t)$ 表示;第 t 次迭代当前 ω 狼与 α、β、δ 狼之间的距离用 D_α 、 D_β 、 D_δ 表示。则有:

$$\begin{cases} X_1 = X_\alpha - A_1 D_\alpha \\ X_2 = X_\beta - A_2 D_\beta \\ X_3 = X_\delta - A_3 D_\delta \end{cases} \quad (15)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (16)$$

式中: \mathbf{X}_1 、 \mathbf{X}_2 、 \mathbf{X}_3 分别表示当前 ω 狼朝着 α 、 β 、 δ 狼位置前进的步长和方向; $\mathbf{X}(t+1)$ 表示灰狼更新后的位置。

2.2 目标函数构建

针对 EMI 测试路径的 TSP 问题,对于由 n 个测试点构成的有序路径集合 $P = [P_1, P_2, \dots, P_n]$, 其中 P_i 表示的是集合中第 i 个测试点的编号,则该路径序列的总长度可以表示为:

$$F(p) = \sum_{i=1}^{n-1} L(P_i + P_{i+1}) + L(P_n + P_1) \quad (17)$$

式中: $L(P_i + P_j)$ 表示测试点 P_i 和 P_j 之间的距离,该距离都采用本文所述改进 A 星算法计算所得出的距离。

解决的目标是通过优化测试点路径序列 P , 找到一条总距离最短的测试路径。

在算法的每次迭代的过程中,每只狼对应一个潜在的路径排列解(即测试点访问顺序),其适应度值可由式(17)所示的评价函数进行量化评估。由本文所述改进 A 星算法可计算得出两两测试点之间的距离矩阵 \mathbf{L} :

$$\mathbf{L} = \begin{bmatrix} 0 & l_{12} & \dots & l_{1n} \\ l_{21} & 0 & \dots & l_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ l_{n1} & l_{n2} & \dots & 0 \end{bmatrix} \quad (18)$$

式中:该距离矩阵满足 $\mathbf{L} = \mathbf{L}^T$, l_{ij} 表示两测试点 P_i 和 P_j 之间的距离。

通过改进 A 算法构建的距离矩阵 \mathbf{L} 已包含了规避障碍物的约束,确保任意两点间的距离值均为实际可行路径长度,从而为后续 TSP 求解器提供了物理可行的输入基础。

2.3 灰狼算法的改进


为确保 EMI 测试路径规划的离散可行性和求解效率, 本文将从以下几个方面对 GWO 进行改进。首先通过 Tent 混沌映射实现初始可行解的均匀分布,其次结合非线性收敛因子动态调节全局探索与局部开发强度,同时针对算法不同优化阶段的特点,设计了相应的离散算子并分阶段采用,既维持种群多样性又确保搜索始终在可行解空间内,最终获得满足约束的高质量路径。

1) 混沌初始化种群

为了使灰狼初始种群个体在分布时尽可能广泛均匀,降低种群集中导致算法陷入局部最优的风险,本文采用混沌映射初始化种群,通过构建(0,1)区间上的混沌变量序列,并将其映射至解空间实现种群分布。在典型混沌模型中,Tent 映射^[17]与 Logistic 映射均展现出良好的均匀性,而 logistic 映射的序列在区间边界处分布密度较大,在中间区域较小,其混沌值分布对比如图 3 所示。所以本文采用具有更优均匀分布特性的 Tent 映射策略。


其数学模型如式(19)所示。

$$Z_{k+1} = \begin{cases} Z_k/\beta, Z_k \in (0, \beta) \\ (1 - Z_k)/(1 - \beta), Z_k \in (\beta, 1) \end{cases} \quad (19)$$



(a) Tent映射混沌值分布($\beta=0.5$)

(a) Tent map chaotic value distribution ($\beta=0.5$)



(b) Logistic映射混沌值分布($\mu=4$)

(b) Logistic map chaotic value distribution ($\mu=4$)

图 3 混沌值分布对比

Fig. 3 Comparison of chaotic value distribution

式中: Z_k 表示在混沌序列生成过程中第 k 代迭代输出值; β 为调节参数, 本文设置 $\beta = 0.5$ 。通过 Tent 混沌映射后产生的随机数在 $[0, 1]$ 区间会更加均匀,从而降低了算法陷入局部最优的风险。

2) 引入非线性收敛因子

传统 GWO 中收敛因子 a 是线性递减的(从 2 到 0),可能导致算法在早期过度探索、后期开发不足,不利于算法的寻优。为动态平衡探索与开发,引入一种非线性收敛因子。在迭代初期时,收敛因子 a 减少速率慢,一直保持较大搜索步长,从而增强全局搜索能力,有助于避免算法陷入局部最优;而在后期,随着 a 值快速减小,搜索步长变小,使得算法能够在某一局部区域内更精细地寻找最优解,从而加速收敛。其表达式为:

$$a = a_{\text{initial}} - a_{\text{initial}} \left[\frac{1}{e-1} (e^{\frac{t}{t_{\text{max}}}} - 1) \right]^n \quad (20)$$

式中: t 为当前迭代次数; t_{max} 为最大迭代次数; $n \in [1, 2]$ 为非线性调制指数; a_{initial} 为收敛因子 a 的初始值, $a_{\text{initial}} = 2$ 。收敛因子 a 的非线性衰减对比如图 4 所示。

3) 构建算子

在 EMI 测试路径规划问题中,每个灰狼个体对应一个潜在的测试路径方案,由于经典灰狼优化算法的参数设置和位置更新机制是为了解决连续优化问题的,而路径组合优化问题是离散的,因此需要针对性的设计算子体系来实现灰狼个体的位置迭代更新。本文构建了 5 种算子,现以




图 4 收敛因子 a 非线性衰减对比

Fig. 4 Comparison of nonlinear attenuation of convergence factor a

一个包含 6 个检测节点的路径序列为例进行说明：

$a \rightarrow b \rightarrow c \rightarrow d \rightarrow e \rightarrow f$

(1) 交换算子: 在路径序列中交换第 i 个测试点和第 j 个测试点的位置 ($i \neq j, i \geq 1, j \leq n$)。若 $i=2, j=4$, 即交换测试点 b 和 d 的位置, 则进行交换操作后的访问顺序为 $a \rightarrow d \rightarrow c \rightarrow b \rightarrow e \rightarrow f$ 。

(2) 插入算子: 在路径序列中将第 i 个位置上的测试点插入到第 j 个位置上 ($i \neq j, i \geq 1, j \leq n$)。若 $i=2, j=4$, 即把测试点 b 插入到测试点 d 位置上, 则进行插入操作后的访问顺序为 $a \rightarrow c \rightarrow d \rightarrow b \rightarrow e \rightarrow f$ 。

(3) 滑动算子: 在路径序列中将第 i 个测试点至第 j 个测试点的访问顺序截取下来保持不变, 并将该子路径滑动到一个新的位置 ($i \neq j, i \geq 1, j \leq n$)。若 $i=2, j=4$, 即把子路径 $b \rightarrow c \rightarrow d$ 进行随机滑动, 则进行滑动操作后的一个可能访问顺序是 $a \rightarrow e \rightarrow b \rightarrow c \rightarrow d \rightarrow f$ 。

(4) 2-opt^[18]算子: 该算子属于组合优化领域的局部改进策略, 其通过重构路径中两条非相邻边的连接方式实现解的质量提升, 来获得更优的路径顺序。若 $i=2, j=4$, 即反转子路径 $b \rightarrow c \rightarrow d$ 的顺序, 则进行 2-opt 操作后的访问顺序是 $a \rightarrow d \rightarrow c \rightarrow b \rightarrow e \rightarrow f$ 。

(5) 3-opt^[19]算子: 该算子是 2-opt 的扩展形式, 通过选择 3 个断点断开路径, 移除对应的 3 条边 (需满足断点非相邻), 生成 4 个子段后尝试 7 种可能的重新连接方式。例如当 $i=1, j=3, k=5$ 时, 断开边 $a-b, c-d, e-f$, 将路径分割为 $a, b-c, d-e, f$ 四个子段, 则进行 3-opt 操作后一个可能的访问顺序是 $a \rightarrow d \rightarrow e \rightarrow b \rightarrow c \rightarrow f$ 。

4) 算法流程

在 GW0 的改进中, 采用了非线性收敛因子 a , 初期更注重全局探索, 后期则更侧重局部优化。为了进一步强化这种动态关系, 针对灰狼个体的位置更新方式, 基于收敛因子 a 的取值区间分为两个阶段, 分别采用不同的算子。

当 $a > 1$ 时, 在迭代早期使用滑动算子更新灰狼个体位置, 增强算法全局搜索能力, 同时允许部分 2-opt 操作, 避免盲目扰动, 加快整体收敛:

$$\begin{aligned} X_{i,1} &= operator(X_i, hd_a) \\ X_{i,2} &= operator(X_i, hd_\beta) \\ X_{i,3} &= operator(X_i, hd_\delta) \end{aligned} \tag{21}$$

式中: 以 $operator(X_i, hd_a)$ 为例, 表示对灰狼个体 X_i 进行 hd_a 次变换, 每次变换以 60% 概率采用滑动算子、40% 概率采用 2-opt 算子。 $hd_a, hd_\beta, hd_\delta$ 计算公式为:

$$\begin{aligned} hd_a &= Rand[1, hd(X_i, X_a)] \\ hd_\beta &= Rand[1, hd(X_i, X_\beta)] \\ hd_\delta &= Rand[1, hd(X_i, X_\delta)] \end{aligned} \tag{22}$$

式中: hd 表示灰狼个体 X_i 与 α 狼 X_a 、 β 狼 X_β 和 δ 狼 X_δ 之间的汉明距离。

当 $a < 1$ 时, 为增加算法的局部搜索能力, 提升解的质量, 使用交换、插入算子更新灰狼个体位置。变换后得到的灰狼个体位置采用 3-opt 算法进行进一步改进:

$$\begin{aligned} X_{i,1} &= operator(X_i, hd_a) + 3-opt \\ X_{i,2} &= operator(X_i, hd_\beta) + 3-opt \\ X_{i,3} &= operator(X_i, hd_\delta) + 3-opt \end{aligned} \tag{23}$$

式中: $operator$ 为 50% 概率采用交换算子、50% 概率采用插入算子, 3-opt 表示在 $operator$ 基础上再进行一次 3-opt 算子变换。


3 仿真试验

本文通过 3 个阶段实验来验证所提算法的性能优势, 以某型号电路板为例, 采用 60×60 栅格地图, 在测试时将高于测试平面的元器件设为障碍物, 实验统一在 MATLAB 仿真软件内进行, 软件版本为 R2022b, 计算机配置 Intel(R) Core(TM) i5-9300H CPU@2.40 GHz, 内存 8.00 GB。第 1 阶段针对两两测试点之间的路径规划问题, 评估改进 A 星算法的性能表现; 第 2 阶段聚焦测试点排序问题, 分析改进灰狼算法在 TSP 问题中的求解效果; 第 3 阶段进行融合验证, 将两种优化算法结合, 用于解决 EMI 多目标测试的路径规划问题。

3.1 改进 A 星算法实验结果

1) 改进启发函数实验

首先, 为了证明本节改进启发函数的作用, 在 30×30 地图上进行传统 A 星算法与改进启发函数算法的对比实验。两种算法的效果对比如图 5 所示。



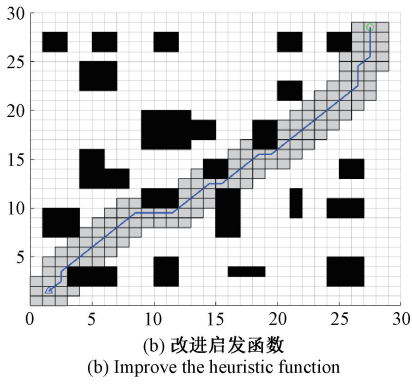


图 5 改进启发函数效果对比

Fig. 5 Comparison of the effectiveness of improving the heuristic function

由表 1 中的两种对比结果可知,虽然改进启发函数算法的搜索路径略长,但遍历节点数明显减少,决策时间更快,显著提升了算法的搜索效率。

表 1 改进启发函数算法对比结果

Table 1 Comparison results of improved heuristic function algorithms

算法名称	遍历节点数	路径长度	时间/s
传统 A 星	297	40.113	0.034
改进启发函数	129	40.698	0.021

2) 冗余点删除实验

本节还引入删除冗余节点策略对路径进行优化处理,增加路径的平滑性和缩短路径的长度。在实验 1 的改进启发函数算法的基础上进行冗余点删除,结果如图 6 所示。




图 6 冗余点删除效果

Fig. 6 Redundancy point deletion effect

由表 2 中的两种对比结果可知,在进行冗余点删除后,不仅减少了路径总长度,而且降低了转角数和转弯角度,提升了路径的平滑性。

3) 综合改进 A 星算法实验

为评估本节最终改进算法的性能表现,在 60x60 的地图上,将改进 A 星算法与 Dijkstra 算法、传统 A 星算法、文献[20]算法进行对比试验。试验结果如图 7~10 所示。

表 2 冗余点删除前后效果对比结果

Table 2 Comparison of effects before and after deletion of redundant points

实验名称	转角数	总转弯角度/(°)	路径长度
冗余点删除前	11	495	40.689
冗余点删除后	10	143.99	38.455




图 7 Dijkstra 算法

Fig. 7 Dijkstra algorithm




图 8 传统 A 星算法

Fig. 8 Traditional A-star algorithm




图 9 文献[20]算法

Fig. 9 Algorithm of literature [20]

由表 3 可知,Dijkstra 算法虽能得到相对较短的路径,但是遍历节点多、时间开销大且存在许多不必要的转角;文献[20]算法在节点数、转角数、总转弯角度和时间开销上均优于传统 A 星算法,但所得的路径长度相对较长;而本




图 10 本文算法

Fig. 10 Algorithm of this article

文所提出的改进 A 星算法,在有效降低了转弯次数和总转弯角度的同时,能够得到较短的路径,且时间开销仅次于文献[20]算法。

表 3 不同路径规划算法性能比较表

Table 3 Comparison of the performance of different path planning algorithms

算法名称	节点数	转角数	总转弯角度/(°)	路径长度	时间/s
Dijkstra 算法	2 775	10	450	85.297	0.369
传统 A 星	573	7	315	85.297	0.087
文献[20]算法	266	6	236.27	88.353	0.072
本文算法	288	5	187.18	85.230	0.081

3.2 改进灰狼算法实验结果

1) 混沌初始化种群实验

为了验证混沌初始化在 GWO 求解 TSP 问题中的作用,别采用随机初始化和 Tent 混沌初始化生成初始种群,种群规模设置为 30,测试点数量为 50,进行 50 次实验,当连续 50 次迭代后最优值没有变化则视为收敛。实验结果如表 4 所示,结果表明,Tent 混沌初始化能够一定程度提升初始种群质量,其生成的最优路径长度、平均路径长度和平均迭代次数均优于随机初始化。

表 4 种群初始化策略性能比较表

Table 4 Comparison of population initialization strategy performance

实验名称	最优路径	平均路径	平均收敛迭代次数
随机初始化	396.818	400.064	114
Tent 混沌初始化	393.963	398.98	107

2) 非收敛性因子和分段算子实验

本节还引入了非线性收敛因子 α ,并且基于收敛因子 α 的取值区间分为两个阶段,分别采用不同的算子,为单独验证其有效性,在随机初始化的基础上,使用测试点数量为

30,种群规模为 30 的条件进行 20 次实验,结果取平均值,实验结果如表 5 所示。结果表明,非收敛性因子和分段算子能够在得到更优路径的同时加速算法的收敛,减少时间开销,从而提升算法的性能表现。

表 5 收敛因子与算子策略性能对比表

Table 5 Comparison of convergence factors and operator strategy performance

实验名称	路径距离	收敛迭代次数	收敛时间/s
线性收敛因子和统一算子	306.459	54	1.279
非线性收敛因子和分段算子	305.151	31	1.067

3) 综合改进灰狼算法实验

为验证本文所提出的最终改进 GWO 的性能,分别使用数量为 30、50 的测试点,种群数 30,与传统 GWO、PSO、BA 作对比试验。实验得出的算法收敛曲线如图 11 所示。




图 11 不同算法收敛趋势对比

Fig. 11 Convergence trends of different algorithms

算法的随机性可能导致单次运行结果的偶然性偏差,影响对比的公平性。为降低随机性对结果的影响,每种算法进行 10 组试验,最终结果取平均值,实验结果如表 6 所示。

表 6 不同 TSP 优化算法性能比较表

Table 6 Comparison of the performance of different TSP optimization algorithms

测试点个数	算法名称	路径距离	收敛迭代次数	收敛时间/s
30	GWO	306.816	55	1.307
	PSO	306.917	102	2.014
	BA	307.653	116	2.325
	本文算法	304.145	27	0.928
50	GWO	400.595	112	5.212
	PSO	407.038	142	7.917
	BA	403.055	151	8.065
	本文算法	394.524	58	3.759

根据表 6 可知,与传统 PSO、BA 和 GWO 算法相比,改进 GWO 在不同规模的两组测试中均表现更优,其求解的路径更短、收敛更快且耗时更少,在处理 TSP 问题上表现出了优良的性能。

3.3 融合算法实验结果

在分别验证改进 A 星算法和改进 GWO 性能的基础上,现将两种算法进行融合,来解决 EMI 测试多目标点路径规划问题。并通过与传统算法组合的对比实验验证其性能效果。试验结果如图 12~13 所示。

从路径长度、转角个数、转角度数、时间开销四方面来比较不同算法组合下的性能,结果如表 7 所示。

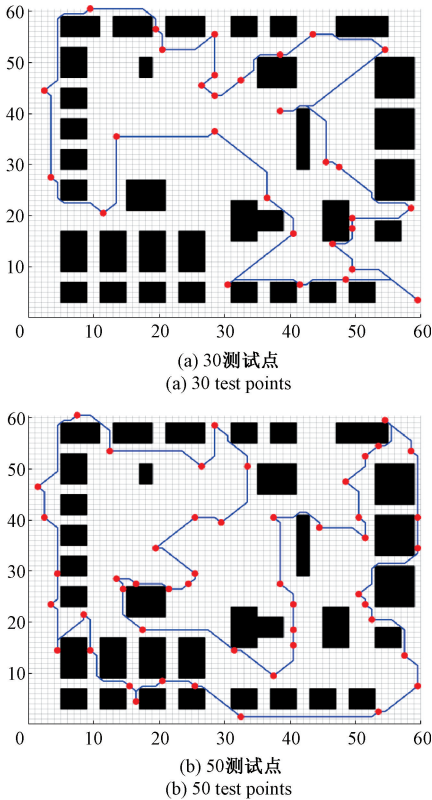


图 12 传统 A 星与 GWO 路径仿真

Fig. 12 Simulation of traditional A-star and gray wolf algorithm paths


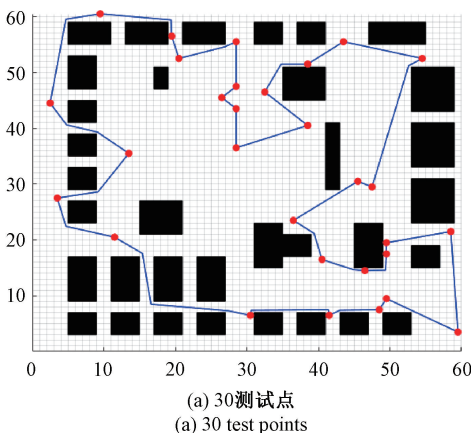


图 13 改进 A 星与 GWO 路径仿真

Fig. 13 Improved A-star and GWO path simulation

表 7 不同算法组合下的测试路径规划性能表
Table 7 Test path planning performance under different algorithm combinations

算法名称	测试点个数	路径长度	转角个数	转角度数/(°)	时间开销/s
传统 A 星	30	317.421	68	4 050	1.828
与 GWO	50	415.463	102	6 345	5.720
改进 A 星	30	303.996	48	3 092.714	1.179
与 GWO	50	393.762 8	70	4 637.166	3.988

实验结果表明,在 30 和 50 测试点两种场景下,本文所提出的融合算法在总路径长度、总转角数、总转角度数以及时间开销上都具有明显优势。

4 结 论

针对非欧氏距离下两两测试点距离未知的 EMI 测试多目标点路径规划问题,本文提出了一种结合改进 A 星与 GWO 算法的混合路径规划方法。通过三阶段实验验证,该方法在最短路径距离、运动平滑性及计算效率等方面均展现了一定优势,能够在复杂环境下生成高效且安全的测试路径,为解决实际应用中的 EMI 测试路径规划问题提供了一种有效的技术方案,具有较高的工程应用价值。

参考文献

[1] 申晓宁,潘红丽,陈庆洲,等. 引入启发信息的粒子群算法在低碳 TSP 中的应用[J]. 计算机工程与科学, 2022, 44(6):1114-1125.
SHEN X N, PAN H L, CHEN Q ZH, et al. Application of particle swarm optimization algorithm with heuristic information in low-carbon TSP [J]. Computer Engineering and Science, 2022, 44 (6): 1114-1125.

[2] WU J H, DUAN Q Q. An algorithm for solving travelling

- salesman problem based on improved particle swarm optimisation and dynamic step hopfield network [J]. International Journal of Vehicle Design, 2023, 91(1-2-3): 208-231.
- [3] SAJI Y, BARKATOU M. A discrete bat algorithm based on Lévy flights for euclidean traveling salesman problem[J]. Expert Systems with Applications, 2021, 172: 114639.
- [4] 李婷,张楠,吕志民,等.基于偏序对改进蝙蝠算法的旅行商问题研究[J].科学技术与工,2020,20(33): 13735-13739.
- LI T, ZHANG N, LYU ZH M, et al. Research on the traveling salesman problem based on partial order and improved bat algorithm[J]. Science, Technology and Engineering, 2020, 20(33): 13735-13739.
- [5] PANWAR K, DEEP K. Transformation operators based grey wolf optimizer for travelling salesman problem[J]. Journal of Computational Science, 2021, 55: 101454.
- [6] 梅伟,赵云涛,毛雪松,等.基于离散灰狼算法的喷涂机器人路径规划方法[J].计算机应用,2020,40(11): 3379-3384.
- MEI W, ZHAO Y T, MAO X S, et al. Path planning method for spray painting robots based on discrete grey wolf algorithm [J]. Computer Applications, 2020, 40(11): 3379-3384.
- [7] 李文君,李忠伟,罗偲.基于 RRT* 算法的移动机器人安全光滑路径生成[J].电子测量技术,2024,47(2): 51-60.
- LI W J, LI ZH W, LUO S. Safe smooth path generation for mobile robots based on the RRT* algorithm[J]. Electronic Measurement Technology, 2024, 47(2): 51-60.
- [8] 郭俊锋,袁俊平,朱红霞.基于改进 RRT 算法的双臂服务机器人运动规划研究[J].仪器仪表学报,2024, 45(12): 210-220.
- GUO J F, YUAN J P, ZHU H X. Research on motion planning for dual-arm service robots based on an improved RRT algorithm[J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 210-220.
- [9] ALLUS A, UNEL M. Angle-based multi-goal ordering and path-planning using an improved A-star algorithm[J]. Robotics and Autonomous Systems, 2025, 190: 105001.
- [10] 王敏,石明航,洪梅,等.基于同步双向 A 星和灰狼优化的多点巡航规划[J].电子测量技术,2025,48(1): 1-7.
- WANG M, SHI M H, HONG M, et al. Multi point cruise planning based on synchronous bidirectional A-star and grey wolf optimization [J]. Electronic Measurement Technology, 2025, 48(1): 1-7.
- [11] 汪四新,谭功全,蒋沁,等.基于改进 A* 算法的移动机器人路径规划[J].计算机仿真,2021,38(9): 386-389,404.
- WANG S X, TAN G Q, JIANG Q, et al. Path planning for mobile robots based on improved A* algorithm[J]. Computer Simulation, 2021, 38(9): 386-389,404.
- [12] 王中玉,曾国辉,黄勃,等.改进 A* 算法的机器人全局最优路径规划[J].计算机应用,2019,39(9): 2517-2522.
- WANG ZH Y, ZENG G H, HUANG B, et al. Improving the A* algorithm for global optimal path planning of robots[J]. Computer Applications, 2019, 39(9): 2517-2522.
- [13] CHEN J Q, LI M Y, SU Y SH, et al. Direction constraints adaptive extended bidirectional A* algorithm based on random two-dimensional map environments[J]. Robotics and Autonomous Systems, 2023, 165: 104430.
- [14] 鲁志,刘莹煌,张绪坤,等.融合 A* 与 DWA 算法的移动机器人动态避障研究[J].电子测量技术,2025, 48(8): 34-45.
- LU ZH, LIU Y H, ZHANG X K, et al. Research on dynamic obstacle avoidance for mobile robots integrating A* and DWA algorithms[J]. Electronic Measurement Technology, 2025, 48(8): 34-45.
- [15] 王志特,罗丽平,廖义奎.改进 A* 算法融合改进动态窗口法的移动机器人路径规划[J].计算机工程,2024, 50(8): 86-101.
- WANG ZH T, LUO L P, LIAO Y K. Improved A* algorithm fused with improved dynamic window method for mobile robot path planning[J]. Computer Engineering, 2024, 50(8): 86-101.
- [16] 袁钰婷,高岳林,左汶鹭.渐进式分组狩猎的灰狼优化算法及其工程应用[J].计算机应用研究,2024,41(5): 1409-1419.
- YUAN Y T, GAO Y L, ZUO W L. Grey wolf optimization algorithm for progressive group hunting and its engineering application [J]. Computer

- Application Research, 2024, 41(5): 1409-1419.
- [17] ZHANG Q ZH, LIU H SH, GUO J, et al. Improved GWO-MCSVM algorithm based on nonlinear convergence factor and tent chaotic mapping and its application in transformer condition assessment [J]. Electric Power Systems Research, 2023, 224: 109754.
- [18] LUO J, HENG H, WU G. Graph attention, learning 2-opt algorithm for the traveling salesman problem [J]. Complex & Intelligent Systems, 2025, 11(1): 117-117.
- [19] TUAIN F A, KEEDWELL E, COLLETT M. Heterogenous adaptive ant colony optimization with 3-opt local search for the travelling salesman problem [J]. Applied Soft Computing Journal, 2020, 97 (Part B): 106720.
- [20] 吴鹏, 桑成军, 陆忠华, 等. 基于改进 A* 算法的机器人路径规划研究 [J]. 计算机工程与应用, 2019, 55(21): 227-233.
- WU P, SANG CH J, LU ZH H, et al. Research on path planning of mobile robots based on improved A* algorithm [J]. Computer Engineering and Applications, 2019, 55(21): 227-233.

作者简介

周虎, 博士, 副教授, 主要研究方向为数控技术、机电控制与机器视觉。

E-mail: tigerzhou@dhu.edu.cn

薛冰荣 (通信作者), 硕士研究生, 主要研究方向为运动控制、轨迹规划。

E-mail: 2782846785@qq.com