[引用格式]孙浩宇,王云超,温圣兴,等. 基于动态混合 PSO-GA 算法的 AGV 调度系统优化[J]. 集美大学学报(自然科学版),2026,31(5):581-592. DOI:10.19715/j.jmuzr.2026.05.07.

基于动态混合 PSO-GA 算法的 AGV 调度系统优化

孙浩宇，王云超，温圣兴，吴培廷，许申奥，刘金阳

（集美大学海洋装备与机械工程学院，福建 厦门 361021）

[摘要] 针对制造车间自动导引车（AGV）调度中存在收敛速度慢、易陷入局部最优及多目标难以协同优化等问题，本文提出一种动态混合频率的粒子群-遗传（PSO-GA）优化算法。该算法构建了以调度成本、任务延误及响应速度为核心的多目标加权模型，并通过分阶段动态调整种群混合频率与个体交换比例，有效平衡了全局探索与局部开发能力。基于企业无尘车间的真实排产数据，开展了所提算法分别与标准遗传算法（GA）、标准粒子群算法（PSO）的对比仿真实验。结果表明：与 GA 算法相比，本文算法将 AGV 需求量从 8 台降至 5 台（减少 37.5%），目标函数值降低，平均任务响应时间从 2.86 min 缩短至 1.29 min（缩短 54.9%），紧急任务响应时间低至 0.93 min，同时依然保证了 100% 的任务准时交付率；与 PSO 算法相比，本文算法在寻得更优解（目标函数值降低 2.3%）的同时有效避免了早熟收敛。本文算法显著提升了 AGV 系统的调度效率、资源利用率与动态适应性。

[关键词] AGV 调度；粒子群优化；遗传算法；动态混合策略；多目标优化

[中图分类号] TP 278；S 951；P 753 [文章编号] 1007－7405（2026）05－0581－12

Optimization of AGV Scheduling System Based on Dynamic Hybrid PSO-GA Algorithm

SUN Haoyu, WANG Yunchao, WEN Shengxing, WU Peiting, XU Shen'ao, LIU Jinyang

(College of Mechanical and Energy Engineering, Jimei University, Xiamen, 361021, China)

Abstract: Aiming at the problems of slow convergence, susceptibility to local optima, and difficulty in coordinating multi-objective optimization in automated guided vehicle (AGV) scheduling for manufacturing workshops, this paper proposed a dynamic hybrid frequency particle swarm optimization-genetic algorithm (PSO-GA). The algorithm constructed a multi-objective weighted model focusing on scheduling cost, task delay, and response speed, and achieves an effective balance between global exploration and local exploitation by dynamically adjusting the population hybrid frequency and individual exchange ratio in phases. Based on the real production scheduling data of an enterprise's dust-free workshop, comparative simulation experiments were carried out between the proposed algorithm, the standard genetic algorithm (GA) and the standard particle swarm optimization (PSO) algorithm. The results showed that, in comparing with the GA, the proposed algorithm reduced the AGV demand from 8 to 5 (a decrease of 37.5%), lowered the objective function value, shortened the aver-

[收稿日期] 2025－11－06

[基金项目] 国家自然科学基金面上项目子课题（52375046）

[通信作者] 王云超，博士，教授，主要从事多轴车辆动力学控制、油气悬架系统性能分析、无人驾驶技术研究等。

age task response time from 2. 86 to 1. 29 minutes (a reduction of 54. 9%), achieved an emergency task response time as low as 0. 93 minutes, and accomplished 100% of tasks without delay. Compared with PSO, it finds a better solution (a 2. 3% reduction in the objective function value) while effectively avoiding premature convergence. The algorithm significantly improves the scheduling efficiency, resource utilization, and dynamic adaptability of the AGV system.

Keywords: AGV scheduling; particle swarm optimization; genetic algorithm; dynamic hybrid strategy; multi-objective optimization

0 引言

随着制造业向智能化转型，自动导引车（automated guided vehicle，AGV）已成为生产车间柔性生产与智能物流的核心单元，应用日益广泛。AGV 调度系统作为协调设备、任务与资源的核心中枢，其优化水平直接决定生产物流的效率、成本与可靠性，是衡量智能制造水平的关键指标。为此，国内外学者提出多种调度算法，其中常见的有遗传算法（genetic algorithm，GA）和粒子群优化算法（particle swarm optimization，PSO）。遗传算法（GA）凭借全局搜索强、适配性广的优势成为经典，如张达等[1]提出遗传局部搜索算法来求解多目标生产车间调度问题；Cheng 等[2]设计等量分批策略 GA 以解决小批量混流车间调度。粒子群优化算法（PSO）以收敛快、局部优化高效著称，如汤旻安等[3]提出含综合影响因子的 PSO 算法来优化路径规划。

但单一算法存在固有缺陷：纯 GA 易在迭代后期陷入收敛停滞；纯 PSO 全局搜索不足，动态任务场景下易陷入局部最优。于是出现了固定模式混合 PSO-GA 算法，如：Yu 等[4]提出固定种群比例；Xu 等[5]采用每 3 代固定交换种群个体的策略。但这些固定模式混合 PSO-GA 算法仍缺乏对迭代进程与任务负载的动态适配性，且多目标优化片面侧重成本或效率，难以平衡调度成本、响应速度与任务可靠性。

针对上述瓶颈，本文提出一种动态混合频率的 PSO-GA 优化算法，旨在解决传统算法动态适应性差、多目标优化片面的问题，为复杂生产环境下 AGV 智能调度提供高效方案。本文的核心创新点体现在以下三方面：构建多目标加权模型，协同平衡多重指标；设计分阶段动态混合策略，实时调整种群交换频率与比例，兼顾全局连通与局部优化；提出自适应资源分配机制，动态调节采样粒度，降低计算冗余。

1 问题描述与数学模型

1. 1 问题描述

此次项目面向企业生产实际，应用环境为室内的无尘生产车间。AGV 在生产车间内作业的路线大致为一矩形环道，环道由磁条铺设而成，宽约 90 m，长约 120 m。该环道横跨三个生产区域。在环形轨道最左侧为入库待命区，含有仓储入库区、停止空闲等待区、包材放置区和栈板放置区。环形轨道中间区域为质检与充电区，对生产的液晶面板进行质量检测，并包含有充电区、调度平台服务器部署位置等[6]。环形轨道右侧为拣选装载区，有若干条生产线，以及每条生产线对应的用于 AGV 停止时装卸货物的等待站台。为后续建

模方便，绘制了 AGV 的运行地图（见图 1）。

AGV 运行地图建立后，为进一步实现对 AGV 调度的优化，在建立模型时，参照环形轨道小车的通用建模思路[7]，结合无尘车间 AGV 实际工况，对 AGV 的运行情况做如下假设：

1）忽略电量不足、AGV 故障、产线故障等造成的时间延误；

2）AGV 只能顺时针运行；

3）AGV 只有停止与匀速运动，行驶的后一台 AGV 无法超越前一台 AGV；

4）AGV 每次只能执行一个任务，且执行任务时均视为满载。

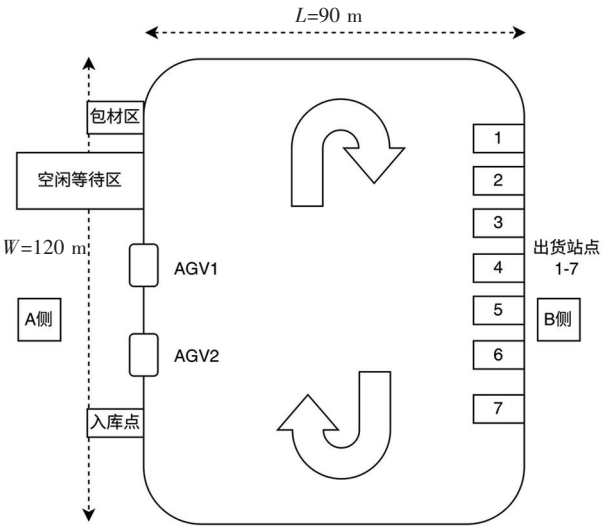


图 1　AGV 运行示意图

Fig.1　AGV operation diagram

1.2　数学模型

1.2.1　目标函数

建立综合考虑原始成本、延误惩罚和动态响应的多目标函数，即

$$\min Y = \lambda_1 \cdot n_c \sum_{i=1}^{n_r} c_r^i(T_T^i) + \lambda_2 \sum_{i=1}^{n_r} c_r^i \max(T_c^i - T_d^i, 0) + \lambda_3 \sum_{i=1}^{n_r} (c_r^i T_r^i + \theta i_i c_r^i)。 \quad (1)$$

其中：n_c—计划使用的 AGV 数量；c_r^i—第 i 个任务的产品价值权重；T_T^i—第 i 个任务的实际处理时间；T_c^i—第 i 个任务完成时间；T_d^i—第 i 个任务最晚完成时间；T_r^i—第 i 个任务响应时间；i_i—紧急任务标识（0 为常规任务，1 为紧急任务）；λ_1，λ_2，λ_3—权重系数（$\lambda_1 = 0.4, \lambda_2 = 0.3, \lambda_3 = 0.3$）；$\theta$—紧急任务惩罚系数（$\theta = 2$）。

该目标优化函数由调度成本、任务延误时长及响应速度三个子指标构成，旨在实现系统综合效能的最优平衡。其中：1）调度成本指标重点考量任务执行过程中的资源消耗，具体量化为 AGV 的投入数量及其运行的总服务时长，以促使算法在满足需求的前提下最小化资源负载。2）针对车间生产严格的时效性要求，模型引入软时间窗策略建立任务延误指标，允许在特定范围内的适度延误，但施加基于“延误时长 × 任务价值”的非线性惩罚，从而迫使高价值任务优先获得调度资源。3）响应速度指标侧重于评估系统对动态任务的敏捷性，特别是针对紧急插单任务引入阶跃式惩罚机制，若紧急任务未被及时响应，惩罚值将显著增加，迫使算法调整搜索方向以优先处理紧急队列。

本研究通过线性加权法将上述三个相互制约的指标耦合为单目标适应度函数，实现复杂约束下的协同优化。

1.2.2　约束条件

时间约束公式为：

$$T_c^i = T_s^i + T_w^i + T_{c1}^i + T_r^i + T_{ex}^i + T_{c2}^i + T_{c3}^i。 \quad (2)$$

其中：T_s^i为第 i 个任务开始执行时间；T_w^i为第 i 个任务等待 AGV 响应时间；T_{c1}^i 为第 i 个任务取物料时间，根据 AGV 状态动态调整；T_r^i为第 i 个任务 AGV 行驶时间；T_{ex}^i为第 i 个任

务从待命区出发的额外时间；T_{c2}^{i} 为第 i 个任务在 B 侧出货点装卸时间；T_{c3}^{i} 为在 A 侧入库点卸货时间。

停车容量约束公式为：

$$\sum_{k=1}^{n_r} P_k^t \leqslant n_m, t \in [8,20]。 \tag{3}$$

其中：n_r 为空闲 AGV 数量；P_k^t 为第 k 辆 AGV 在 t 时刻的位置状态；n_m 为最大停车容量。

任务完成时间约束公式为：

$$0 \leqslant T_n^i \leqslant T_c^i \leqslant T_m^i。 \tag{4}$$

其中：T_n^i 为完成第 i 个任务的理论最短时间；T_m^i 为第 i 个任务允许最长完成时间。

任务序列约束公式为：

$$t_s^k(n+1) \geqslant t_s^k(n) + \frac{W + 2L - L_s(X_k^n - 1)}{(1-\delta)v_1 + \delta - v_2} + T_{ci}^i。 \tag{5}$$

其中：$t_s^k(n+1)$ 为下一个任务开始时间；$t_s^k(n)$ 为当前任务开始时间；W 为环形轨道宽度；L 为环形轨道长度；L_s 为相邻出货点之间的距离；δ 为出发状态参数；X_k^n 为服务站点编号；v_1、v_2 分别为空载和满载行驶速度（$v_1 > v_2$）。

AGV 状态判定系数 δ 的表达式为：

$$\delta = \begin{cases} 1, P_k^t = 0, \\ 0, P_k^t = 1。 \end{cases} \tag{6}$$

其中：0 表示 AGV 位置为空闲等待区；1 表示 AGV 位置为非空闲等待区。

2 动态混合 PSO-GA 算法设计

2.1 编码方案与种群初始化

2.1.1 混合编码策略

PSO 编码策略：采用实数编码方式，每个染色体包含（2 × 站点数 + 1）个决策变量，染色体编码结构如图 2 所示。本研究设有 7 个站点，则每个染色体含 $2 \times 7 + 1 = 15$ 个决策变量（7 个站点的优先级、等待时间及 AGV 数量）。



图 2 PSO 染色体编码规则图

Fig.2 Diagram of chromosome encoding rules using PSO

PSO 编码实例：初始化种群规模为 200，采用实数编码，每个染色体代表一种调度方案。每个染色体包含 15 个决策变量（对应 7 个站点），7 个站点的染色体可编码为 [3,0,2,1,0,5,4,5,0,7,8,0,10,6,4]，表示站点 2 和 5 无任务、站点 4 优先级最高、使用 4 台 AGV。

GA 编码策略：由于实数编码不利于遗传算法搜索及迭代[8]，GA 转换为 5 位二进制编码以适配遗传操作。每个染色体的长度为 5 ×（2 × 站点数 + 1）。

2.1.2 种群初始化

采用分层初始化策略。设 PSO 种群有 120 个粒子，其位置和速度随机生成；设 GA

种群有 80 个个体，采用均匀分布随机生成；精英个体保留前代最优的 4 个个体。

2.2　适应度评估与优化机制

2.2.1　适应度函数设计

适应度函数定义为：

$$F = 10^9 - Y。\tag{7}$$

其中：Y 为目标函数值。为便于选择操作的概率计算，本设计确保适应度 F 的值始终为正数，且目标函数值越小，适应度越高。

2.2.2　粒子群优化机制

速度更新公式为：

$$v_{jd}^{t+1} = wv_{jd}^{t} = c_1 r_1(\mathrm{pdest}_{jd} - x_{jd}^{t}) + c_2 r_2(\mathrm{gbest}_{jd} - x_{jd}^{t})。\tag{8}$$

其中：v_{jd}^{t}为粒子 j 在维度 d 上 t 时刻的速度；w 为惯性权重；c_1 为个体学习因子；c_2 为社会学习因子；r_1、r_2 为增加搜索随机性的均匀分布随机数；pbest_{jd}为粒子 j 在维度 d 上的历史最优位置；gbest_{jd}为种群在维度 d 上的历史最优位置，x_{jd}^{t}为粒子 j 在维度 d 上 t 时刻的位置。

位置更新公式为：

$$x_{jd}^{t+1} = x_{jd}^{t} + x_{jd}^{t+1}。\tag{9}$$

自适应惯性权重 w 的计算公式为：

$$w = w_{\max} - (w_{\max} - w_{\min}) \times \frac{I}{I_{\max}}。\tag{10}$$

其中：$w_{\max} = 0.9$；$w_{\min} = 0.4$；I 当前迭代次数；$I_{\max}$为最大迭代次数。

2.2.3　遗传算法操作

GA 部分负责保持种群多样性，采用以下操作：

1）选择操作。采用锦标赛选择（规模 3），自适应调整选择压力。

2）交叉重组操作。使用单点交叉策略[9]，前期高位交叉探索解空间，后期低位交叉精细优化。

3）变异操作。采用单点变异策略[10]，每条染色体发生突变的概率为 1%，发生突变的个体在随机选择的位置经历 0 和 1 的随机翻转。

4）精英保留。每代保留 4 个最优解，确保优秀基因不会丢失。

2.3　动态混合策略

混合频率动态调整，根据优化进程分为两个阶段：前期阶段（迭代第 1—80 代）每 3 代进行一次种群交换，快速传播优良基因，加速收敛；后期阶段（迭代第 81—200 代）每 10 代进行一次种群交换，保持种群多样性，避免早熟收敛。交换比例动态调整，前期阶段交换种群 12% 的个体，进行 PSO 与 GA 双向交换；后期阶段交换种群 8% 的个体，进行单项交换。

2.4　终止条件

根据实际的生产情况设定最大迭代次数，当混合算法迭代次数达到最大迭代次数时，算法结束运行。这样能够在不牺牲解决方案精度的前提下，以较为简单且稳定的方

式结束算法的迭代。

2.5 算法框架

动态混合 PSO-GA 算法的核心思想是在不同优化阶段采用不同的混合策略，整体框架如图 3 所示。

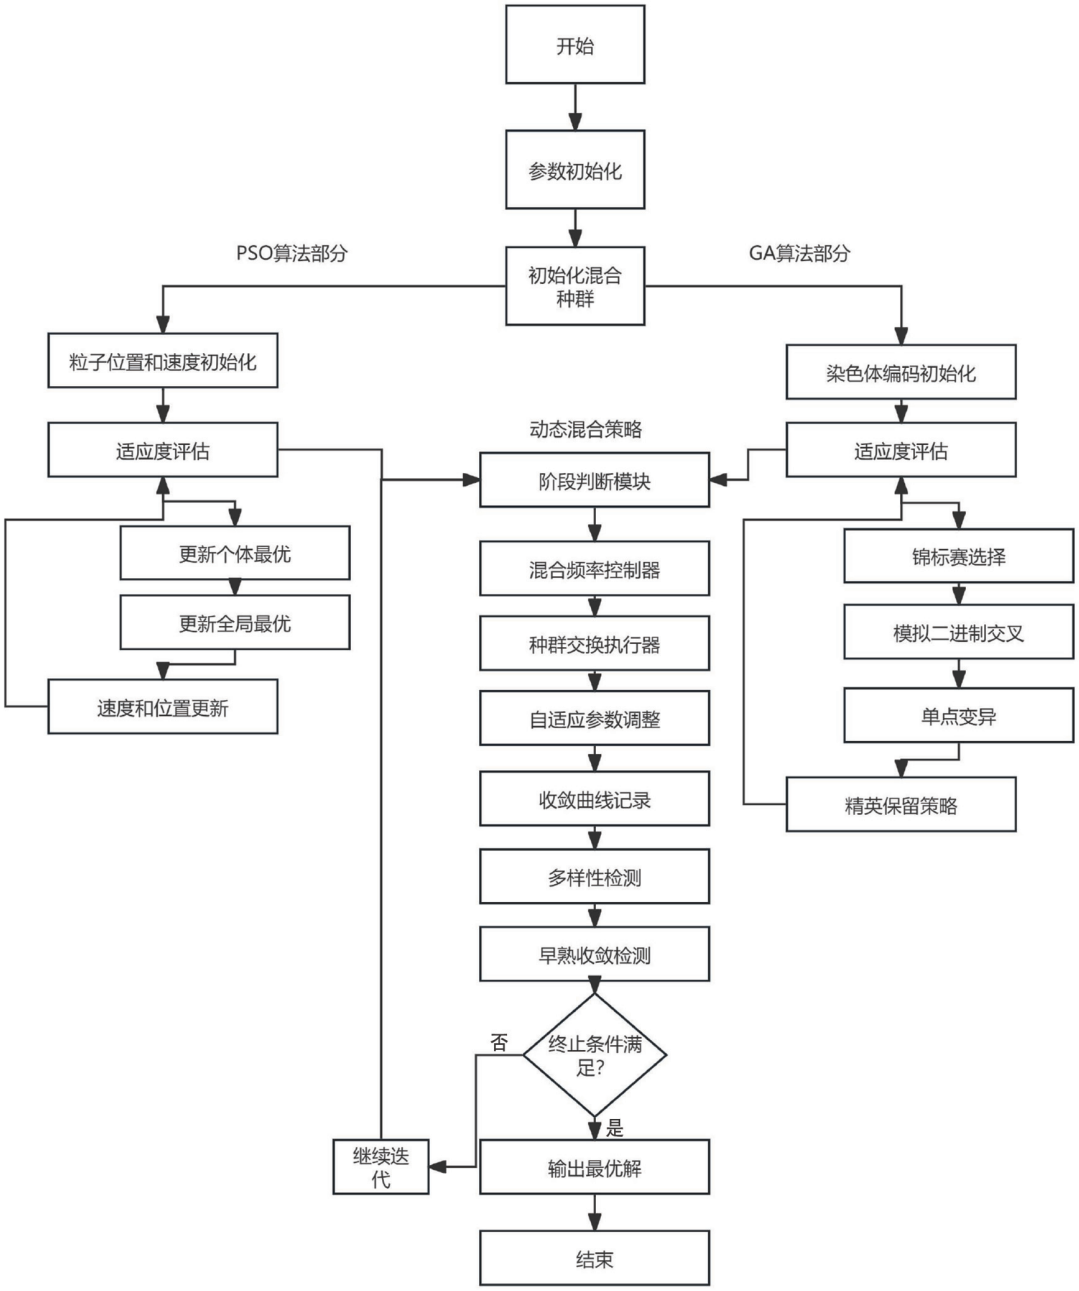


图 3 PSO–GA 混合算法流程图

Fig.3 PSO–GA hybrid algorithm flow chart

3 实验验证与结果分析

3.1 实验设计

实验在 Windows 10 系统下进行，使用 MATLAB R2022b 软件，硬件配置为 Intel Core

i5 处理器、8 GB 内存。为了还原真实生产场景，选取某工作日 8:00—20:00 的生产数据作为输入。仿真总任务数为 350 个，任务类型包括取料、送料、返库等，单位时间内的任务达到数量服从泊松分布。其中常规物料搬运任务占比 80%，紧急插单任务占比 20%。任务生成的具体分布涵盖了所有 7 个出货站点与 1 个入库点，能够充分测试算法在非均衡负载下的适应能力。

实验环境参数以及混合算法参数的设置如表 1、2 所示。其中 PSO 的惯性权重 w 设置为[0.4, -0.9]，是为了平衡前期的全局搜索与后期的局部开发；GA 的交叉概率为 0.8，变异概率为 0.1，这是遗传算法常用的经验值[10]，并经过 10 次预实验微调确定。该参数组合在收敛速度与种群多样性保持上表现最佳，混合频率与比例通过控制变量法的预实验确定。

表 1　实验环境参数

Tab.1　Experimental environment parameters

参数名称	参数单位	参数值
磁轨长度	m	120×90(长×宽)
AGV 行驶速度	$m \cdot s^{-1}$	0.6(空载),0.4(满载)
出货站点数	个	7
取材站点数	个	1
仓储站点数	个	1
等待区数	个	1

表 2　混合算法参数

Tab.2　Hybrid algorithm parameters

参数类型	参数名称	参数值
种群参数	总种群大小	200
	PSO 种群比例	60%
	GA 种群比例	40%
PSO 参数	惯性权重范围	[0.4,0.9]
	学习因子	$c_1=2.0, c_2=2.0$
GA 参数	交叉概率	0.8
	变异概率	0.1
	精英保留数	4
混合参数	前期混合频率	3
	后期混合频率	10

3.2　权重敏感性分析与选取依据

目标函数（式（1））中的权重系数 λ_1、λ_2、λ_3 分别反映了调度策略对系统运营成本、任务准时性及动态响应速度的侧重程度。由于多目标优化结果通常依赖于权重的分配，为了验证本文所选权重组合(0.4, 0.3,0.3)的合理性，并探究系统资源配置对决策偏好的敏感性，本文选取了三组具有代表性的权重场景进行对比实验，结果如图 4 所示。

方案一：成本优先策略下的资源约束与系统拥堵。当设定权重组合为 $\lambda_1=0.6$，$\lambda_2=0.2$，$\lambda_3=0.2$ 时，算法受到强烈的成本最小化约束，将 AGV 配置数量压缩至物理极限的 4 台。然而，仿真结果表明，此时系统的运力供给小于任务需求，导致任务队列积压严重。尽管设备成本降至最低，但产生了巨大的延误惩罚。这证明了在当前生产负荷下，4 台 AGV 无法满足基本的准时交付要求，即该配置方案不可行。

方案二：服务优先策略下的资源冗余与边际效益递减。当降低成本权重以追求极致服务质量时，在 $\lambda_1=0.2$，$\lambda_2=0.3$，$\lambda_3=0.5$ 条件下，系统倾向于配置 6 台 AGV。在此配置下，系统处于“资源富余”状态，平均响应时间压缩至物理极限 0.48 min。

方案三：均衡策略下的最优配置。在均衡权重组合 $\lambda_1=0.4$，$\lambda_2=0.3$，$\lambda_3=0.3$ 下，算法收敛于 5 台 AGV。此时系统达到了供需平衡的拐点。

相比于方案一，方案三仅增加 1 台 AGV 便消除了所有延误，平均响应时间骤降 76%

（至 1.29 min），实现了从“拥堵”到“通畅”的质变。相比于方案二，方案三在保证 100% 准时交付的前提下，有效控制了设备规模。方案二设备是 6 台，虽然比方案三缩短了响应时间，但是投入了额外的设备成本，在完成任务准时交付的前提下，存在资源浪费。

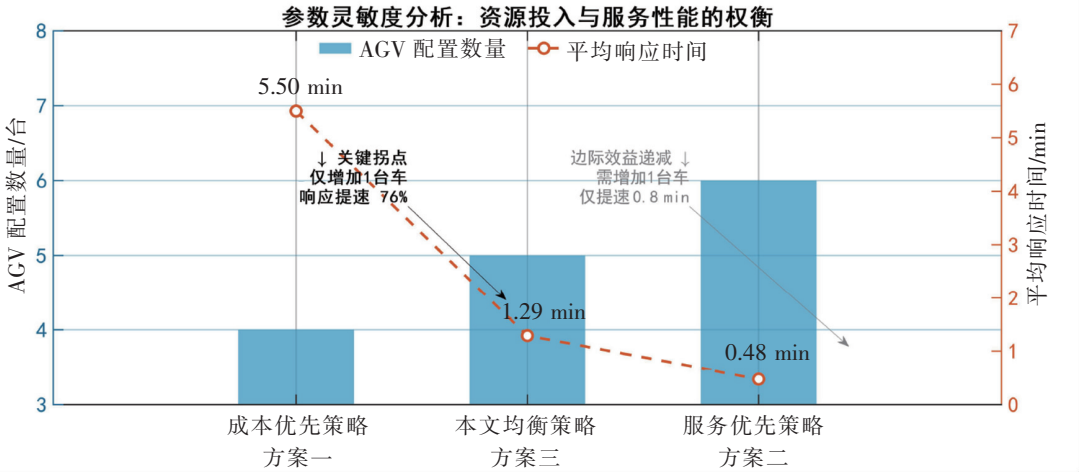


图 4 权重敏感性分析图

Fig.4 Weight sensitivity analysis diagram

3.3 结果对比与分析

根据上述实验设计，以车间实际排产任务进行仿真验证，并与传统 GA 算法以及传统 PSO 算法仿真效果进行对比。图 5、图 6、图 7 分别展示了在相同任务负载下，GA、PSO 以及本文提出的动态混合频率 PSO-GA 三种算法的全局调度甘特图。图 5 ~7 中，横坐标代表仿真时间，纵坐标代表 AGV 编号，不同颜色的色块代表不同的常规任务，红色色块代表紧急插单任务。

在 GA 算法中，系统需要调用 8 台 AGV 才能完成所有任务，且各 AGV 的时间轴上存在大量空白区域，表明资源冗余严重。PSO 算法将需求降低至 7 台 AGV，虽然数量有所减少，但在调度中仍有明显的资源闲置。而 PSO-GA 混合算法仅需 5 台 AGV 即可完成同等规模的任务量，各 AGV 的任务块排列紧凑，大幅减少了非工作状态的空窗期。相比之下，GA 与 PSO 算法的甘特图呈现出明显的稀疏特征，说明传统算法在处理多任务并行与冲突消解时，往往采用保守的等待策略，导致时间资源的浪费。这表明本文算法具有极强的全局搜索与资源优化能力，能够在减少 37.5% 的设备投入（相比 GA）的前提下，依然保证按时完成任务，极大降低了系统的硬件成本。

为了深入探究调度策略的差异，选取仿真初期高负荷时段（8:00—9:30）进行局部放大分析。在 GA 算法的局部视图中，任务块之间呈现明显的碎片化分布（见图 8）。例如，AGV 在完成一个任务后，往往需要等待较长时间才能衔接下一个任务，这种断断续续的模式极大地拉低了作业效率。PSO 算法虽然在一定程度上缩短了任务间隔，但任务块的排列仍呈阶梯状，并行度不足（见图 9）。相比之下，PSO-GA 混合算法展现了优异的任务衔接能力。如图 10 所示，不同颜色的任务块在时间轴上实现了更好的衔接。特别是在处理红色紧急任务与其他常规任务的冲突时，本文算法能够灵活调整常规任务的执行次序，利用微小的时间间隙插入任务，从而减少了不必要的等待时间。

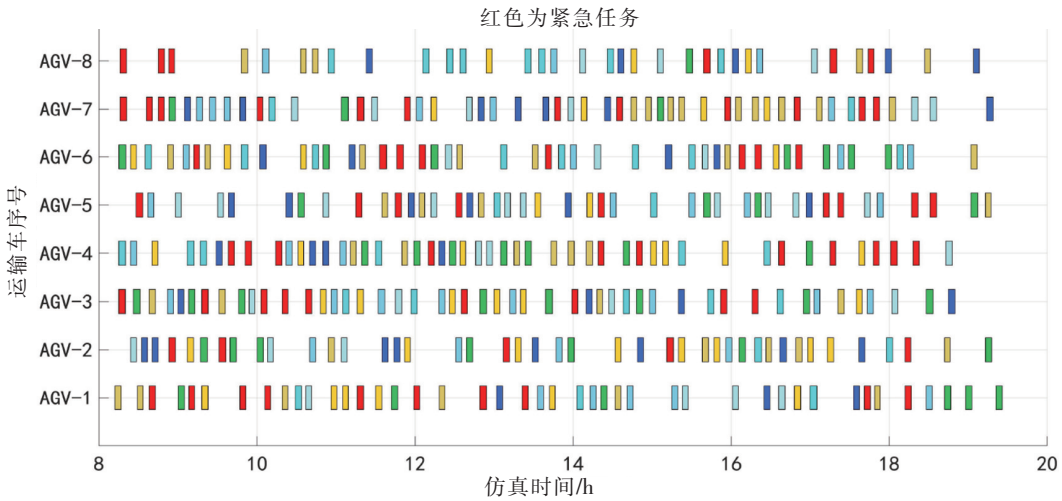


图 5　遗传算法任务执行甘特图

Fig.5　Gantt chart of genetic algorithm task execution

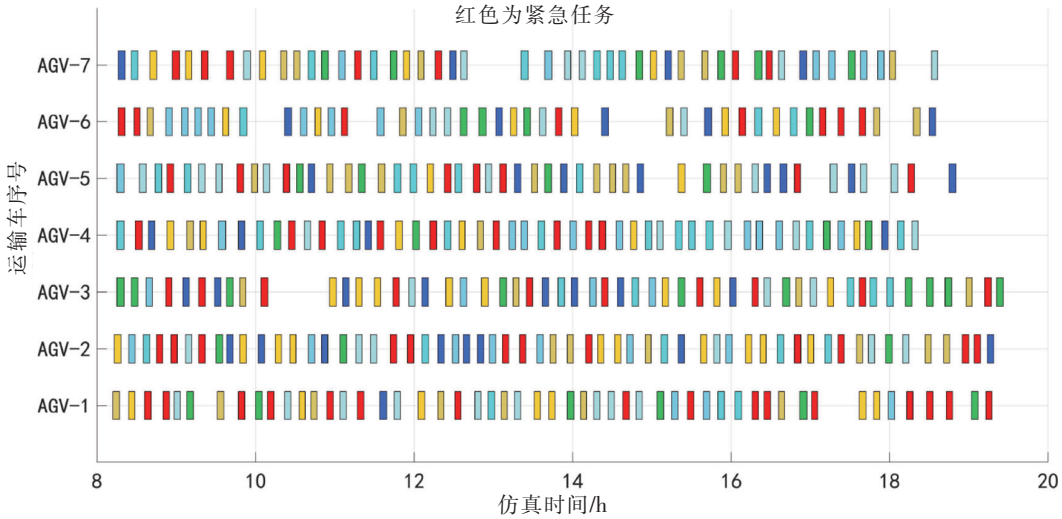


图 6　粒子群算法任务执行甘特图

Fig.6　Gantt chart of particle swarm algorithm task execution

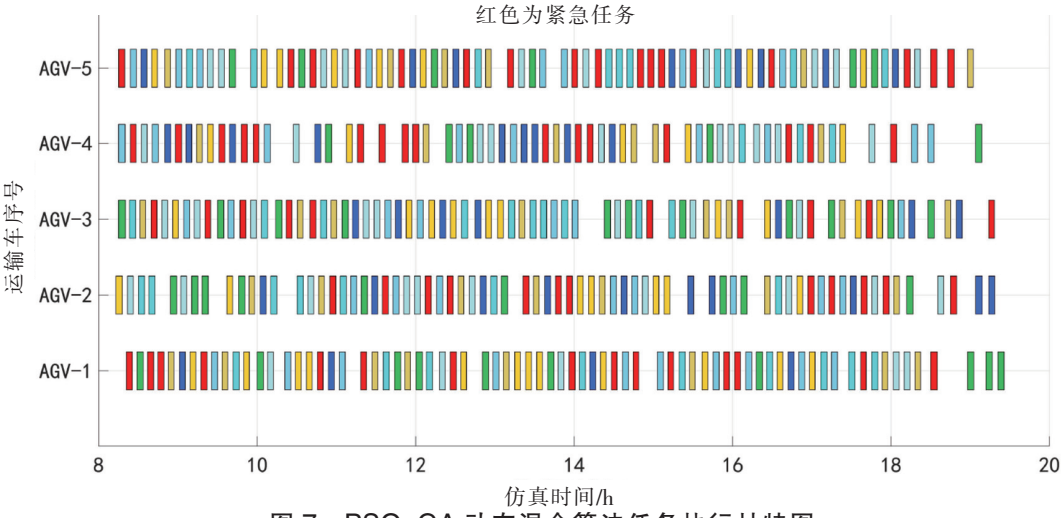


图 7　PSO-GA 动态混合算法任务执行甘特图

Fig.7　Gantt chart of PSO-GA dynamic hybrid algorithm task execution

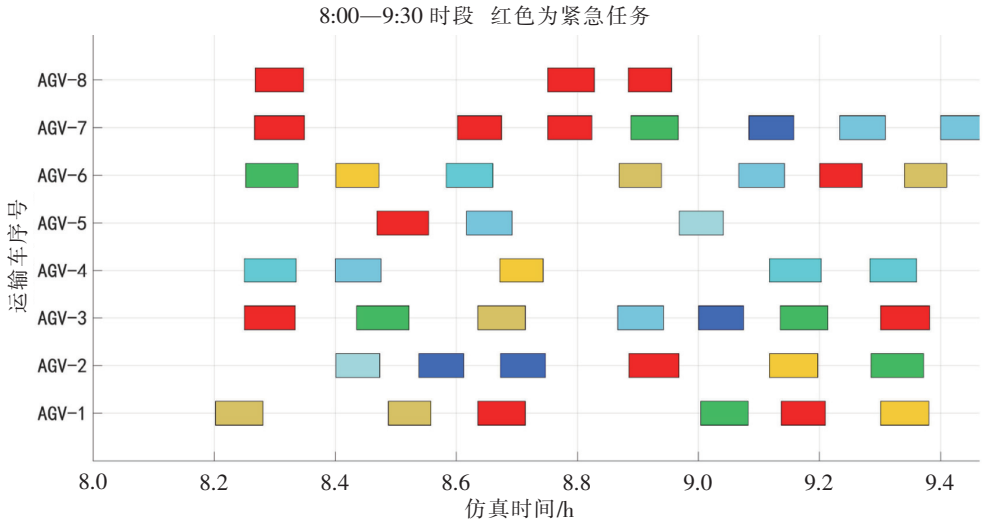


图 8 遗传算法任务执行的局部甘特图

Fig.8 Local gantt chart of genetic algorithm task execution

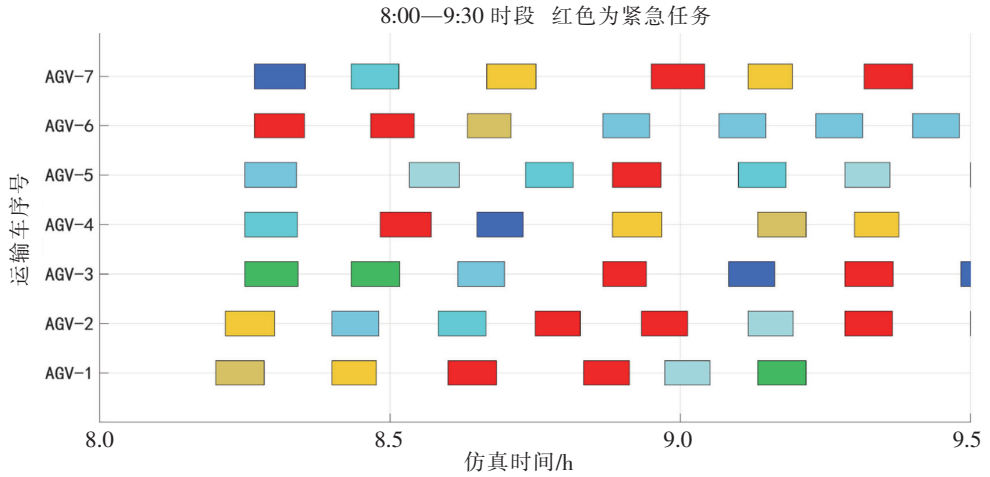


图 9 粒子群算法任务执行局部甘特图

Fig.9 Local gantt chart of particle swarm algorithm task execution

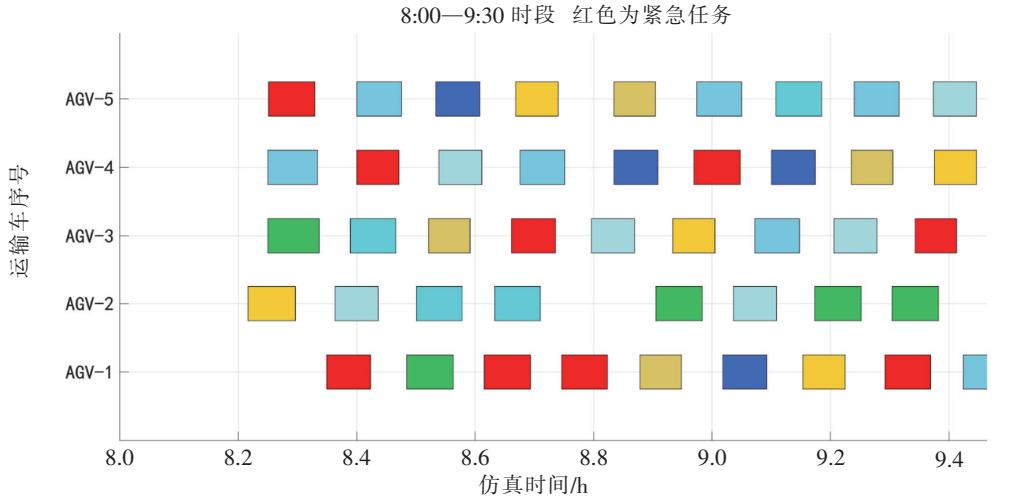


图 10 PSO-GA 动态混合算法任务执行局部甘特图

Fig.10 Local gantt chart of PSO-GA dynamic hybrid algorithm task execution

生成染色体后，目标函数随着迭代次数的增加逐渐降低，直至达到一个较优解。为能清晰看出优化过程，图 11 展示了在相同实验参数下，遗传算法、粒子群算法与本文提出的动态混合频率 PSO-GA 算法的目标函数值随迭代次数的变化曲线。图 11 中横坐标表示迭代次数，纵坐标表示目标函数值（适应度值），局部放大图展示了迭代后期（第 150—200 代）的详细收敛情况。从迭代初期（前 20 代）可以看出，PSO 算法（蓝色点划线）与 PSO-GA 混合算法（红色实线）的曲线下降斜率最大，表现出极快的收敛速度。这表明引入粒子群的记忆机制能够引导种群快速向更优解区域靠拢。相比之下，GA 算法（绿色虚线）的下降过程较为缓慢且呈现明显的阶梯状，说明单一的交叉变异操作在初期搜索效率较低，难以快速定位解空间中的优质区域。

在大约第 15 代之后，PSO 算法的曲线迅速趋于水平，不再下降。这说明标准 PSO 算法出现了明显的早熟收敛现象，粒子群陷入了局部极值点无法跳出。而本文算法在经历了初期的快速下降后，并未像 PSO 那样立即停滞，而是继续保持了一定的下降趋势。这得益于本文引入的动态调整策略以及遗传变异操作，使得算法在发现局部极值后仍保持了种群的多样性，具备持续进化的能力。

结合图 11 中的后期收敛放大图及表 3 可见，三种算法最终收敛的目标函数值呈现出显著差异。PSO 算法虽然最快稳定，但最终解的质量最差（值约为 4.44×10^4）。GA 算法虽然收敛慢，但最终精度优于 PSO（值约为 4.38×10^4），这证明了遗传算法在全局搜索上的优势。本文混合算法结合了二者的优点，最终收敛值最小（值约为 4.34×10^4）。相比于 GA 和 PSO，本文混合算法寻找到的解更优，这证明了本混合策略能够有效平衡开发与探索之间的矛盾，实现了全局最优解的快速定位。

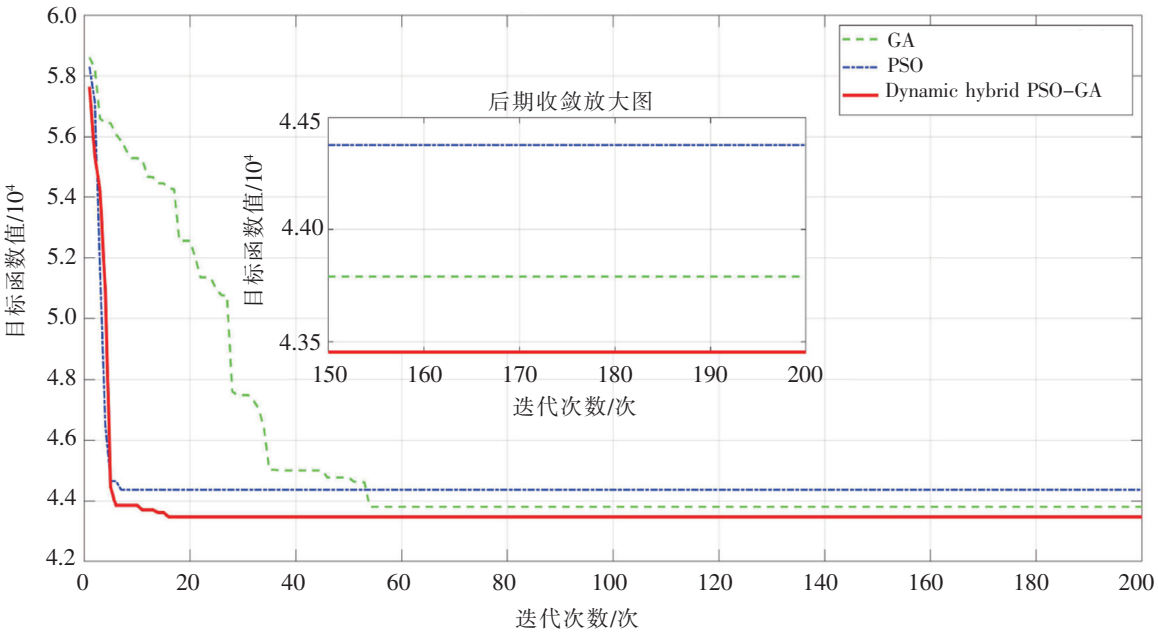


图 11　三种算法收敛曲线对比

Fig.11　Comparison of convergence curves

表 3 三种算法性能对比

Tab. 3 Comparison of the performances of three algorithms

性能	GA	PSO	PSO-GA
AGV 数量/台	8	7	5
任务延误率	0	0	0
目标函数值	4.38×10^4	4.44×10^4	4.34×10^4
紧急任务响应时间/min	1.43	1.14	0.93
平均任务响应时间/min	2.86	1.96	1.29

综上所述，本文提出的改进算法在保证收敛速度接近 PSO 的同时，大幅提升了求解精度，避免了陷入局部最优，在解决此类复杂调度问题时具有最佳的综合性能。

4 结论

本研究针对制造车间 AGV 调度中存在的收敛停滞、动态适应性弱及多目标平衡不足等问题，提出一种动态混合频率的 PSO-GA 优化算法。通过构建多目标加权模型，协同优化调度成本、任务延误时长与响应速度，利用分阶段动态调整种群混合频率及交换比例，结合自适应资源分配机制降低计算冗余，实现全局探索与局部优化能力的精准平衡。与单一 GA 以及 PSO 算法相比，目标函数值更低，紧急任务响应时间更短，仅需 0.93 min，且任务调度甘特图分布更加均衡。AGV 需求量从 8 台降至 5 台，减少了 37.5%，并且实现了平均任务的快速响应，平均响应时间仅 1.29 min。

[参 考 文 献]

[1]张达,田霖,刘振,等. 考虑 AGV 的电力设备测试车间柔性调度策略[J]. 河北电力技术,2025,44(4):24-30.

[2]Cheng W,Meng W. An efficient genetic algorithm for multi AGV schedulingproblem about intelligent warehouse[J]. Robotic Intelligence and Automation,2023,43(4):382-393.

[3]汤旻安,谷宝慧. 改进 PSO 在 AGV 系统路径优化调度中的应用研究[J]. 计算机工程与应用,2016,52(3):261-265.

[4]于蒙,刘德汉. 改进 PSO-GA 算法求解混合流水车间调度问题[J]. 武汉理工大学学报(交通科学与工程版),2021,45(3):586-590.

[5]岳笑含,许晓健,王溪波. 面向 FMS 基于改进的混合 PSO-GA 的多 AGV 调度算法研究[J]. 计算机科学,2018,45(增刊 2):167-171.

[6]任年路,袁一平,戴毅,等. 基于改进遗传算法的环形 RGV 系统调度优化[J]. 机械设计与制造,2023(4):1-5.

[7]Tetteh M,Li L,Minnick M,et al. Optimization of borehole thermal energy storage systems using a genetic algorithm[J]. Math Geosci,2025,57(2):1-22.

[8]Zhang H,Zheng T,Sun H,et al. Optimization of AGV scheduling system using genetic algorithm[C]//Wang Y,Yu T,Wang K. Advanced Manufacturing and Automation XIV. Singapore:Springer,2025:1-10.

[9]李昆鹏,韩雪芳. 智能仓库中多 AGV 在线任务指派与全局路径规划问题研究[J]. 中国管理科学,2025,33(3):264-276.

[10]宁方华,黄丙齐,周晓敏. 基于改进遗传算法的混合流水车间批量调度问题求解[J]. 软件导刊,2024,23(2):84-91.

(责任编辑 朱雪莲 英文审校 郑青榕)