动态非全信息环境下武器目标分配问题的多模态鲁棒进化求解方法

姚兴懿，李文桦†，李水佳，王 锐，张 涛

(国防科技大学 系统工程学院， 长沙 410073)

摘 要: 武器目标分配 (Weapon-Target Assignment, WTA) 是防空作战指挥决策领域的核心组合优化问题, 现有研究多基于完全信息假设并采用单解范式, 忽视了信息不完备性和多模态解的鲁棒性差异, 且跨阶段知识利用不足. 针对此, 本文提出动态部分可观测武器目标分配 (Dynamic Partially-Observable WTA, D-POWTA) 框架, 首先建立完整的数学模型, 显式刻画信息不完备性并纳入 13 类实战约束; 其次提出基于汉明邻域的鲁棒性度量指标 (Robustness Metric Index, RMI), 定量刻画多模态解在编码邻域内的局部质量支配特征; 最后设计知识引导的动态滚动多模态进化算法 (Knowledge-Guided Dynamic Rolling Evolutionary Algorithm, KG-DREA), 通过跨阶段知识复用、汉明距离小生境保持和 RMI 驱动的鲁棒优选实现知识—多模态—鲁棒性的有机统一. 实验结果表明, 在包含 24 至 500 个目标的 10 个测试算例上, KG-DREA 在求解质量与收敛稳定性上均获得了最佳性能表现, 消融实验进一步验证了跨阶段知识迁移、多模态保持与鲁棒优选三个核心机制各自的有效性与贡献.

关键词: 武器目标分配；动态非全信息；多模态优化；鲁棒性度量；知识引导；进化算法；知识迁移

中图分类号: TP18 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0271

引用格式: 姚兴懿, 李文桦, 李水佳, 等. 动态非全信息环境下武器目标分配问题的多模态鲁棒进化求解方法 [J]. 控制与决策, xxxx, x(x): xxxx-xxxx.

A multimodal robust evolutionary solution method for the weapon-target assignment problem in dynamic partially-observable environments

YAO Xing-yi，*LI Wen-hua*†，*LI Shui-jia*，*WANG Rui*，*ZHANG Tao*

(College of Systems Engineering， National University of Defense Technology， Changsha 410073， China)

Abstract: Weapon-Target Assignment (WTA) is a core combinatorial optimization problem in the domain of air defense command decision-making. Existing studies largely rely on the complete-information assumption and adopt a single-solution paradigm, thereby overlooking the robustness differences arising from incomplete information and multimodal solutions, as well as the insufficient exploitation of knowledge across stages. To address this, this paper proposes a dynamic partially-observable WTA (D-POWTA) framework. First, a complete mathematical model is established to explicitly characterize information incompleteness and incorporate 13 classes of operational constraints. Second, a Robustness Metric Index based on the Hamming neighborhood (RMI) is introduced to quantitatively characterize the local quality-dominance margin of multimodal solutions within their encoding neighborhoods. Finally, a Knowledge-Guided Dynamic Rolling Evolutionary Algorithm (KG-DREA) is designed, achieving an organic unification of knowledge—multimodality—robustness through cross-stage knowledge reuse, Hamming-distance-based niche preservation, and RMI-driven robust selection. Experimental results show that, across 10 test instances with 24 to 500 targets, KG-DREA achieves the best performance in both solution quality and convergence stability, and ablation studies further verify the effectiveness and contribution of the three core mechanisms: cross-stage knowledge transfer, multimodal preservation, and robust selection.

Keywords: weapon-target assignment；dynamic partially-observable；multimodal optimization；robustness metric；knowledge-guided；evolutionary algorithm；knowledge transfer

收稿日期: 2026-03-31；**录用日期:** 2026-07-31.

基金项目: 中国博士后创新人才支持计划 (BX20250439) 和国家自然科学基金 (62503488).

责任编委: 黄敏.

†通信作者. E-mail: liwenhua1030@aliyun.com.

0 引 言

武器目标分配 (Weapon-Target Assignment, WTA) 问题是防空作战指挥决策领域最核心的组合优化问题之一, 该问题可表述为: 在给定防御武器集合与来袭目标集合的条件下, 确定最优的武器—目标配对方案, 以最大化对来袭目标群的整体毁伤效能, 或最小化打击行动结束后残余目标的威胁总量[1-2]. 根据决策时序的不同, WTA 问题通常分为静态武器目标分配 (Static WTA, SWTA) 与动态武器目标分配 (Dynamic WTA, DWTA) 两类. SWTA 在单一决策时刻为当前来袭目标集一次性确定最优分配方案, 是 DWTA 的基础子问题; DWTA 则在多个离散决策周期内滚动迭代求解, 随战场态势演变持续修正分配策略[3-4]. 即便是中等规模的 SWTA 实例, 其解空间规模也随武器数与目标数的增长呈指数级膨胀, 且已被证明是 NP 难问题[5]. 在现代防空作战中, 随着高超声速滑翔飞行器、低可观测巡航导弹及大规模饱和攻击等新型威胁样式的持续涌现, 防空系统所面临的目标数量与威胁复杂度显著提升, 对武器目标分配方案的实时性与精准性提出了前所未有的挑战, 因此 WTA 研究的战略价值与现实紧迫性日益凸显[6-7].

由于 DWTA 本质上是在多个离散决策周期内对 SWTA 子问题进行滚动求解, SWTA 层面的建模与求解缺陷会直接影响 DWTA 的跨阶段决策质量. 现有研究方法通常将单周期优化目标定位于寻找"单一最优分配方案", 而忽略了该问题解空间的多模态结构: 在中大规模 SWTA 实例中, 由于离散组合解空间的高度对称性与约束耦合性, 往往存在多组目标函数值相等或接近的武器—目标配对方案, 构成等价最优解集合[8]. 沿用"单解范式"意味着所执行的方案可能恰好是其中局部质量优势较弱的方案, 从而造成跨阶段作战效能的系统性损失. 因此, 有必要在每一个决策阶段同时维护多个高质量的候选分配方案, 并通过对其局部质量优势的量化分析, 优先执行在编码邻域内具有最大质量领先余量的方案.

基于此, 本研究将针对鲁棒多模态优化与动态武器目标分配问题进行研究. 在多模态优化领域, 实现多峰值保持的核心手段是小生境 (Niching) 机制, 代表性方法包括拥挤机制[9-11]、全局与局部 Pareto 前沿保持[12]、适应度共享 [13]、清除策略[14] 及物种保留策略[15-16] 等; 近期研究还将鲁棒性分析引入多模态框架, 以解空间邻域内的目标函数稳定性作为方案优劣的补充评判准则[17-19]. 在 DWTA 领域, 当前研究多采用滚动时域规划[20]、马尔可夫决策过程[21-22]、强化学习[23-25] 以及面向动态环境的进化算法[26-29] 等求解框架.

但是, 现有研究在面向动态非全信息场景时仍存在以下不足: 首先, 许多 WTA/DWTA 模型仍以完全信息为基础, 难以刻画实际防空作战中感知质量和制导链路可用性的动态不完备性. 其次, 现有求解方法多以单一 (近似) 最优解为输出, 较少关注目标函数值相近的多组可行方案在结构及其鲁棒性上的差异, 所选方案在动态环境下的稳定性缺乏有效保障. 最后, 当前动态进化方法通常将各决策阶段视为相互独立的重优化问题, 未能将历史交战中积累的低效分配模式抽象为可复用的结构性知识并用于后续阶段的搜索加速, 在决策时效紧张的情况下收敛效率仍有提升空间. 针对上述不足, 本文提出了一个面向动态部分可观测环境的武器目标分配 (Dynamic Partially-Observable WTA, D-POWTA) 综合求解框架, 主要贡献如下:

(1) SWTA 解空间多模态结构刻画与跨时间周期鲁棒性分析. 本文对 SWTA 解空间的多模态特性进行了详细的刻画, 揭示了等价最优解在编码邻域内局部质量支配裕度的本质差异. 本文提出了一种面向离散组合解空间的鲁棒性度量指标, 该指标通过度量解在其汉明邻域内的质量支配裕度, 将近似最优解集中的"局部占优解"与"局部劣势解"加以区分.

(2) 动态部分可观测 WTA 数学模型 (D-POWTA) 的构建. 本文以多阶段滚动优化为基础框架, 建立了一套完整的 D-POWTA 数学模型, 将信息不完备性由定性假设提升为可直接驱动决策的量化建模要素. 模型嵌入了"感知—决策—打击—评估"四阶段闭环状态更新机制, 考虑武器资源消耗、有效射程、打击时效窗口 (随目标逼近动态收缩)、探测保障与武器优先级匹配等 13 类硬约束, 在数学层面系统刻画了非全信息动态对抗环境的关键特征.

(3) 知识引导的动态滚动多模态进化算法 (KG-DREA) 的设计. 针对 D-POWTA 求解面临挑战, 本文提出了知识引导的动态滚动多模态进化算法 (Knowledge-Guided Dynamic Rolling Evolutionary Algorithm, KG-DREA). 算法引入面向离散组合解空间的小生境机制, 在每一决策阶段主动维持种群多样性, 同步发现多组等价最优分配方案, 并结合上述鲁棒性度量指标从中优选执行方案; 还设计了基于历史阶段分配冲突模式的知识提取与复用机制, 融入变异算子与环境选择策略, 使后续阶段的搜索过

程能够定向规避已知低效区域; 此外, 在开始优化前执行约束预处理, 依据射程、时效窗口及探测保障约束对候选配对空间实施剪枝, 大幅压缩有效搜索空间, 显著提升收敛效率.

本文余下内容的组织结构如下: 第一节建立 D-POWTA 数学模型, 涵盖多阶段动态框架与完整约束体系, 并对 SWTA 解空间多模态结构进行刻画, 提出鲁棒性度量指标; 第二节介绍总体求解框架与 KG-DREA 算法的知识管理、知识引导算子与约束预处理机制; 第三节介绍标准化测试集与实验设置, 并给出对比实验与消融实验结果分析; 第四节总结全文.

1　模型构建

1.1　问题概述

1.1.1　场景描述

动态部分可观测武器目标分配 (D-POWTA) 问题以多阶段防空作战为背景. 表 1 为本文所提模型的符号及定义. 防御方部署 m 个武器平台与 L 部组网雷达, 面对来袭目标群的持续威胁, 须在有限的决策时效内滚动制定最优分配方案. 作战过程离散化为 T_{total} 个决策周期, 各周期以固定间隔 Δt 推进, 记第 t 个决策周期 ($t = 1, 2, \ldots, T_{\text{total}}$) 时的来袭目标集合为 $\mathcal{T}_t$, 其中目标数量 $n_t = |\mathcal{T}_t|$ 随战场推进而变化, D-POWTA 问题的示意图如图 1 所示.

武器平台与弹药结构: 每个武器平台 $i(i = 1, 2, \ldots, m)$ 配备一定数量的拦截弹药, 在每个决策周期内, 武器平台 i 可向一个或多个目标分配弹药, 亦可对同一目标分配多发弹药.

雷达–武器协同制导: 拦截弹药从发射至命中目标的过程, 须由一部指定雷达提供持续的制导信息支援 (即火控制导通道). "武器平台–雷达"组合的协同作战能力由系统预先评估并以协同效能系数 α_{ijkt} 表征; 若某武器平台 i 与雷达 k 在第 t 周期内不具备协同制导能力 (如距离超限、频段不兼容等), 则 $\alpha_{ijkt} = 0$, 对应的"平台–雷达–目标"三元交战组合不可用.

每一决策周期内, 防御系统须完成"**感知—决策—打击—评估**"四阶段闭环 (如图 1 所示). 目标集合的更新规则为:

$$\mathcal{T}_t = (\mathcal{T}_{t-1} \backslash \mathcal{T}_{\text{dest},t}) \cup \mathcal{T}_{\text{new},t}. \tag{1}$$

其中, $\mathcal{T}_{\text{dest},t}$ 为第 t 周期被成功摧毁的目标集合, $\mathcal{T}_{\text{new},t}$ 为第 t 周期新进入探测范围的目标集合. 武器平台 i 的弹药余量跨周期更新规则为:

表 1　模型符号定义汇总

符号	含义与说明
集合与索引	
t	决策周期索引, $t = 1, 2, \ldots, T_{\text{total}}$
T_{total}	总决策周期数
$\mathcal{T}_t$	第 t 周期的来袭目标集合, $\lvert\mathcal{T}_t\rvert = n_t$
$\mathcal{T}_{\text{dest},t}$	第 t 周期被成功摧毁的目标集合
$\mathcal{T}_{\text{new},t}$	第 t 周期新进入探测范围的目标集合
$\mathcal{B}_{jt}$	第 t 周期对目标 j 形成有效探测的雷达子集
i	武器平台索引, $i = 1, 2, \ldots, m$
j	目标索引, $j \in \mathcal{T}_t$
k	雷达索引, $k = 1, 2, \ldots, L$
决策变量	
x_{ijkt}	第 t 周期武器平台 i 向目标 j 发射、由雷达 k 制导的拦截弹药数量
$\mathbf{X}_t$	第 t 周期的完整分配方案张量, $\mathbf{X}_t \in \mathbb{Z}_{\geqslant 0}^{m \times n_t \times L}$
y_{ijt}	辅助 0-1 变量; 表示第 t 周期武器平台 i 是否参与打击目标 j
目标函数参数	
$F_t(\mathbf{X}_t)$	第 t 周期的优化目标值(越小越优)
Th_{jt}	第 t 周期目标 j 的威胁等级(归一化至 $[0, 1]$)
P_{ijkt}	第 t 周期武器平台 i 发射的弹药在雷达 k 制导下对目标 j 的单发毁伤概率
雷达探测与协同参数	
η_{jt}	第 t 周期目标 j 的多雷达融合探测质量指数, $\eta_{jt} \in [0, 1]$; 通过约束C10影响优化可行域
p_{kjt}	第 t 周期第 k 部雷达对目标 j 的探测概率, $p_{kjt} \in [0, 1]$
α_{ijkt}	第 t 周期武器平台 i、雷达 k 对目标 j 的协同制导可行性系数, $\alpha_{ijkt} \in \{0, 1\}$
λ_k	第 k 部雷达的综合系统性能参数(越小雷达性能越强)
d_{kjt}	第 t 周期第 k 部雷达与目标 j 之间的欧氏距离
σ_j	目标 j 的雷达截面积(RCS), 单位 m^2
R_k^{radar}	第 k 部雷达的最大探测作用距离
p_{th}	单部雷达有效探测的探测概率门限阈值
C_k^{track}	第 k 部雷达同时可制导的最大火控通道数(跟踪容量上限)
武器资源约束参数	
m	武器平台总数
q_{it}	武器平台 i 在第 t 周期的剩余可用弹药数量
a_{it}	武器平台 i 在第 t 周期的可用状态, $a_{it} \in \{0, 1\}$(平台损毁或弹药耗尽时为 0)
L	雷达总数量
打击约束参数	
d_{ijt}	第 t 周期武器平台 i 发射阵地与目标 j 预测拦截点之间的欧氏距离
$R_i^{\max}$	武器平台 i 的最大有效射程
τ_i^{react}	武器平台 i 的发射反应时间
v_i	武器平台 i 拦截弹药的平均飞行速度
W_{jt}	第 t 周期目标 j 的有效打击窗口时长(随目标逼近动态收缩)
U_{jt}	第 t 周期针对目标 j 允许分配的弹药数量上限
$P_{jt}^{\min}$	第 t 周期对目标 j 实施打击所须满足的最低综合毁伤概率门限
ℓ_i	武器平台 i 的优先级等级, $\ell_i \in \{1, \ldots, L_w\}$
$\phi(\cdot)$	目标威胁等级到武器最低优先级要求的映射函数

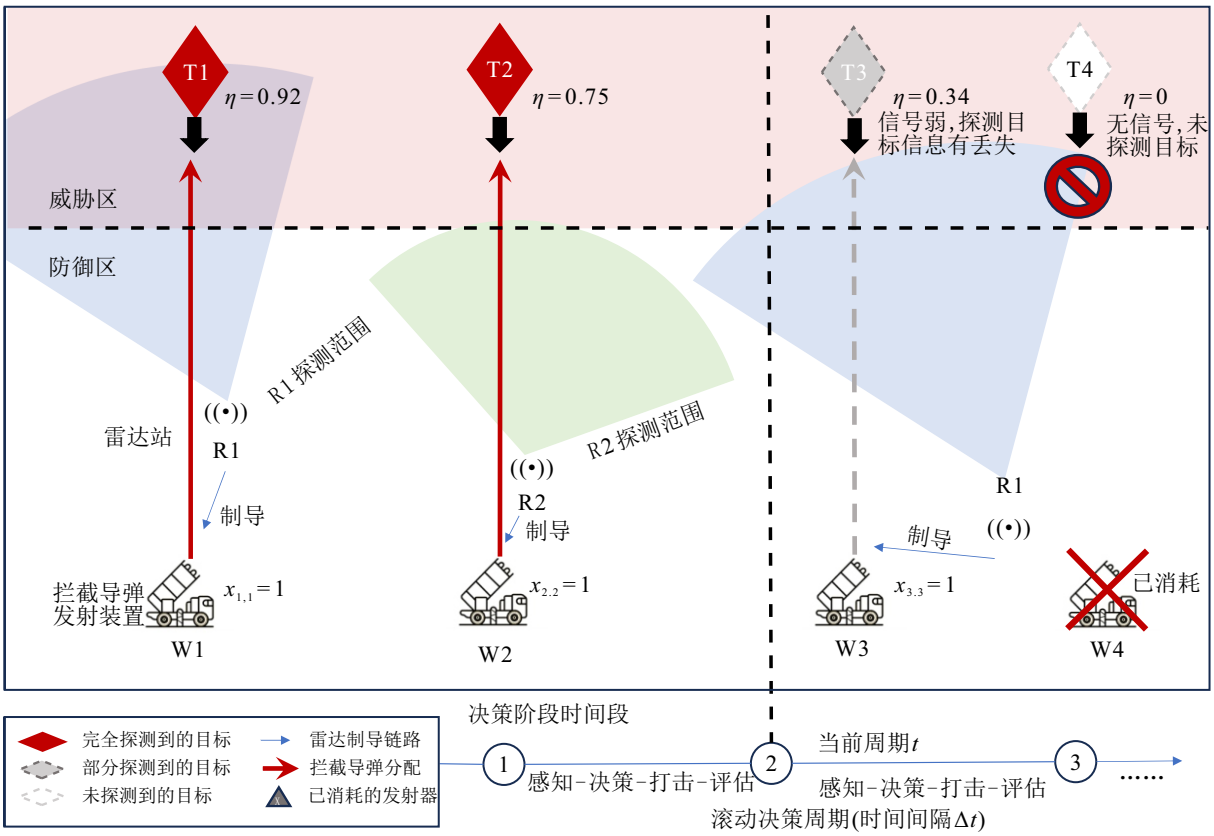

图 1 D-POWTA 问题示意图

$$q_{i,t} = q_{i,t-1} - \sum_{j\in\mathcal{T}_{t-1}} \sum_{k=1}^{L} x_{ijk,t-1},\ \forall i,\ \forall t \geqslant 2. \quad (2)$$

1.1.2 决策变量

表 1 已给出模型主要符号. 本节进一步说明决策变量的取值范围及辅助变量构造. 本模型的核心决策变量为四维非负整数张量 $\mathbf{X}_t$, 其元素定义为:

$$x_{ijkt} \in \mathbb{Z}_{\geqslant 0},\ i = 1,\dots,m,\ j \in \mathcal{T}_t,\ k = 1,\dots,L,\ t = 1,\dots,T_{\text{total}}. \quad (3)$$

其中, x_{ijkt} 表示第 t 周期武器平台 i 向目标 j 发射、并由雷达 k 制导的拦截弹药数量. 其数值直接表示该三元交战组合下的弹药投入数量; 每个非零的 x_{ijkt} 同时确定武器平台、目标和制导雷达. 为便于表达武器平台是否参与打击目标, 引入辅助 0-1 变量:

$$y_{ijt} = \mathbf{1}[\sum_{k=1}^{L} x_{ijkt} \geqslant 1],\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (4)$$

即 $y_{ijt} = 1$ 当且仅当武器平台 i 在第 t 周期参与打击目标 j. 该变量通过以下约束与 x_{ijkt} 关联:

$$y_{ijt} \leqslant \sum_{k=1}^{L} x_{ijkt} \leqslant q_{it} \cdot y_{ijt},\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (5)$$

其中右端上界 q_{it} 为武器平台 i 在第 t 周期的剩余弹药量, 作为平台特定上界直接使用, 无需引入全局大-M 参数. 该约束确保: 当 $y_{ijt} = 0$ 时, 平台 i 不向目标 j 发射任何弹药; 当 $y_{ijt} = 1$ 时, 总投弹量不超过该平台自身剩余弹药总量. 每一决策周期的分配张量 $\mathbf{X}_t \in \mathbb{Z}_{\geqslant 0}^{m\times n_t\times L}$ 构成该周期的完整作战方案.

1.1.3 武器平台–雷达协同制导能力

为刻画武器平台、雷达与目标之间的协同制导可行性, 引入协同制导能力系数 $\alpha_{ijkt} \in \{0,1\}$, 其定义为:

$$\alpha_{ijkt} = \mathbf{1}[d_{ikt}^{\text{comm}} \leqslant R_{ik}^{\text{comm}} \ \wedge\ \text{频段兼容}(i,k) \ \wedge\ a_{it} = 1 \ \wedge\ k \in \mathcal{B}_{jt}]. \quad (6)$$

其中 d_{ikt}^{comm}、R_{ik}^{comm} 分别为武器平台 i 与雷达 k 之间的通信距离及最大有效数据链通信距离, 频段兼容性由系统配置决定. 当且仅当 $\alpha_{ijkt} = 1$ 时该"平台–雷达–目标"三元组合可用, 否则强制 $x_{ijkt} = 0$.

1.2 信息不完备性建模与 D-POWTA 框架说明

经典全信息 WTA 模型将目标精确状态与各武器–目标毁伤概率均视为已知, 而真实作战环境中防御系统仅能通过有限的传感器网络获取部分信息. 本文的 D-POWTA 框架对此作如下形式化处理:

真实状态 (不可完全直接获取): 目标 j 在第 t 周期的精确位置、速度向量、威胁等级 Th_{jt} 等参数, 在实战中仅能通过传感器网络估计获取, 存在固有不确定性.

可观测信息 (通过雷达网络感知): 防御系统在第 t 周期实际可获取的信息为: 有效探测雷达子集

$\mathcal{B}_{jt}$(约束 C6、C7 定义, 由雷达距离与探测概率门限决定) 和多雷达融合探测质量指数 $\eta_{jt} \in [0,1]$(量化当前探测体系对目标 j 的信息完整程度).

信息不完备性的两层体现: 其一, 并非所有雷达对所有目标均能形成有效探测 ($\mathcal{B}_{jt}$ 可能为空集, 对应目标完全不可见, 由约束 C10 强制排除分配); 其二, 即便 $\mathcal{B}_{jt} \neq \varnothing$, $\eta_{jt} < 1$ 表明探测质量仍不完备, 相应毁伤概率 P_{ijkt} 的估计存在不确定性.

信息更新机制: 在每一决策周期 t 开始时, 系统基于最新的雷达组网探测数据更新 $\mathcal{B}_{jt}$ 和 η_{jt}, 从而更新当前阶段的可行分配空间与毁伤概率估计值 (参见目标集合更新规则式 (1)).

本文采用"信息质量加权可行域"的实用化处理方式, 而非维护完整的贝叶斯信念状态: 通过 η_{jt} 和 $\mathcal{B}_{jt}$ 对信息不完备性进行可计算的量化刻画, 在保留"非全信息"核心特性的同时满足实战决策时效要求.

1.3　目标函数

本模型采用单目标优化框架. 在第 t 决策周期, 目标函数 F_t 为最小化以威胁等级加权的全场残余威胁总量:

$$\min\ F_t(\mathbf{X}_t) = \sum_{j\in\mathcal{T}_t} Th_{jt} \cdot \prod_{i=1}^{m}\prod_{k=1}^{L}(1-P_{ijkt})^{x_{ijkt}}. \quad (7)$$

$\prod_{i=1}^{m}\prod_{k=1}^{L}(1-P_{ijkt})^{x_{ijkt}}$ 为目标 j 未被任何已分配弹药摧毁的残存概率. 每发弹药独立地以概率 P_{ijkt} 命中, 故该平台–雷达组合的联合未毁伤概率为 $(1-P_{ijkt})^{x_{ijkt}}$; 对所有平台与所有雷达制导通道取连乘, 即得目标 j 在全部交战行动后的残存概率. 将其乘以目标 j 的威胁等级 Th_{jt} 并对全体目标求和, 即得本周期作战结束后的加权残余威胁期望总量.

$F_t(\mathbf{X}_t)$表示第t周期作战结束后的全场加权残余威胁期望. 最小化该目标是在全体来袭目标范围内降低总体残余威胁; 其中Th_{jt}作为威胁权重, 使高威胁目标在资源竞争中获得更高优先级, 但并不将低威胁目标排除在优化对象之外. 最终分配方案仍须同时满足 C1–C13 约束, 从而保证资源优先性与全局可行性兼顾.

值得说明的是, η_{jt}(多雷达融合探测质量指数) 不直接出现在目标函数式中, 而是通过约束 C10 对优化可行域施加影响: 当 $\eta_{jt} = 0$ 时, C10 强制令目标 j 的全部分配变量 $x_{ijkt} = 0$, 该目标被排除在当期优化对象之外; 当 $\eta_{jt} > 0$ 时, 目标 j 方可进入上述求和范围. 因此, η_{jt} 通过约束层面的可行域塑造间接影响目标函数的实际取值, 是 D-POWTA 信息不完备性建模的核心量化指标.

1.4　约束条件

为保证分配方案的可行性, 模型设置以下十三类硬约束. 所有约束均须在每一个决策周期 t 内严格满足, 并随战场状态的推进实时更新.

C1: 武器平台弹药总量约束

每个武器平台 i 在第 t 周期内发射的弹药总数不得超过其当期剩余可用弹药数量 q_{it}:

$$\sum_{j\in\mathcal{T}_t}\sum_{k=1}^{L} x_{ijkt} \leqslant q_{it},\ \forall i \in \{1,2,\ldots,m\},\ \forall t. \quad (8)$$

C2: 武器平台可用状态约束

处于故障状态或弹药已耗尽的武器平台不得参与分配决策. 设 $a_{it} \in \{0,1\}$ 为武器平台 i 在第 t 周期的可用状态指示变量 (1 表示可用, 0 表示不可用), 则:

$$x_{ijkt} \leqslant M \cdot a_{it},\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall k,\ \forall t. \quad (9)$$

武器平台可用状态的跨周期更新规则为:

$$a_{it} = \mathbf{1}[a_{i,t-1} = 1\ \wedge\ q_{it} > 0],\ \forall i,\ \forall t \geqslant 2. \quad (10)$$

即武器平台在弹药耗尽或自身损毁后, 后续所有周期均不再可用.

C3: 目标最大拦截弹药数量约束

针对每个目标 j 的分配弹药总数存在上限 U_{jt}, 以避免资源过度集中于单一目标:

$$\sum_{i=1}^{m}\sum_{k=1}^{L} x_{ijkt} \leqslant U_{jt},\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (11)$$

U_{jt} 由目标 j 的威胁等级 Th_{jt} 决定, 威胁等级越高则允许集中越多弹药.

C4: 射程有效性约束

武器平台 i 仅能向处于其最大有效射程 $R_i^{\max}$ 以内的目标发射弹药:

$$x_{ijkt} \leqslant M \cdot \mathbf{1}[d_{ijt} \leqslant R_i^{\max}],\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall k,\ \forall t. \quad (12)$$

其中, d_{ijt} 为第 t 周期武器平台 i 发射阵地与目标 j 预测拦截点之间的欧氏距离.

C5: 打击时效性约束 (打击窗口约束)

武器平台 i 发射的弹药从接令至完成拦截的总耗时, 须不超过目标 j 在第 t 周期的有效打击窗口时长 W_{jt}:

$$(\tau_i^{\text{react}} + \frac{d_{ijt}}{v_i}) \cdot y_{ijt} \leqslant W_{jt} \cdot y_{ijt},\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (13)$$

其中, τ_i^{react} 为武器平台 i 的反应时间, v_i 为弹药平均飞行速度, W_{jt} 随目标高速运动持续收缩 (若目标超出防区则 $W_{jt} = 0$).

C6: 雷达探测距离约束

雷达 k 仅对处于其最大作用距离 R_k^{radar} 以内的目标形成有效探测, 超出此距离的目标不计入有效探测雷达子集 $\mathcal{B}_{jt}$:

$$p_{kjt} > 0 \;\Leftrightarrow\; d_{kjt} \leqslant R_k^{\text{radar}},\ \forall k,\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (14)$$

等价表述为: 当 $d_{kjt} > R_k^{\text{radar}}$ 时, 令 $p_{kjt} = 0$, 该雷达不纳入 $\mathcal{B}_{jt}$.

C7: 雷达探测概率阈值约束

即使目标处于雷达探测距离以内, 若单部雷达的探测概率低于系统预设阈值 p_{th}(如受目标高隐身性能或强电磁干扰影响), 该雷达亦不能形成有效探测, 不计入融合计算, 也不得为任何弹药提供制导支援:

$$k \in \mathcal{B}_{jt} \;\Leftrightarrow\; p_{kjt} \geqslant p_{\text{th}} \text{ 且 } d_{kjt} \leqslant R_k^{\text{radar}},\quad \forall k,\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (15)$$

C8: 武器平台–雷达协同制导可行性约束

武器平台 i 向目标 j 发射、由雷达 k 制导的弹药, 当且仅当该"平台–雷达"组合具备协同制导能力时方可实施, 否则该三元交战行动禁止启用:

$$x_{ijkt} \leqslant q_{it} \cdot \alpha_{ijkt},\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall k,\ \forall t. \quad (16)$$

其中 $\alpha_{ijkt} \in \{0,1\}$ 为武器平台 i、雷达 k 对目标 j 在第 t 周期的协同制导可行性系数 (定义见式 (6)). 注意 α_{ijkt} 的定义已内嵌了雷达有效探测条件 $k \in \mathcal{B}_{jt}$: 当且仅当该雷达同时满足通信距离、频段兼容、平台可用及有效探测四个条件时, $\alpha_{ijkt} = 1$; 否则为 0. 因此, C8 约束 $x_{ijkt} \leqslant q_{it} \cdot \alpha_{ijkt}$ 已完整涵盖了有效探测的要求, 无需单独添加 $k \in \mathcal{B}_{jt}$ 条件. 该约束从根本上消除了"无制导保障的盲目发射"和"无有效探测支援的制导"两类非法情形.

C9: 雷达火控通道容量约束

每部雷达 k 在单个决策周期内可同时制导的弹药总数 (即同时开启的火控通道数) 不得超过其最大跟踪容量 C_k^{track}:

$$\sum_{i=1}^{m} \sum_{j \in \mathcal{T}_t} x_{ijkt} \leqslant C_k^{\text{track}},\ \forall k \in \{1,2,\ldots,L\},\ \forall t. \quad (17)$$

该约束表达了雷达制导资源的有限性: 即使武器平台弹药充足, 若所有可用制导雷达的火控通道均已饱和, 则不再向任何目标发射新的弹药. 该约束与 C1(武器平台弹药总量约束) 共同构成双端资源限制, 从发射端与制导端两个维度约束弹药的可分配总量.

C10: 目标可探测性约束 (制导保障约束)

目标须处于有效探测状态 (即至少有一部有效探测雷达可为制导弹药提供支援), 否则不得对该目标实施任何打击分配:

$$\sum_{i=1}^{m} \sum_{k=1}^{L} x_{ijkt} \leqslant M \cdot \mathbf{1}[\eta_{jt} > 0],\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (18)$$

当 $\eta_{jt} = 0$(目标完全不可探测, $\mathcal{B}_{jt} = \varnothing$) 时, 任何武器平台均不得向该目标分配弹药, 强制令所有对应的 $x_{ijkt} = 0$.

C11: 最低有效毁伤概率约束

当某目标 j 被分配了至少一发弹药时, 各平台–雷达组合对该目标施加的综合毁伤概率须不低于该目标的最低毁伤概率门限 $P_{jt}^{\min}$:

$$1 - \prod_{i=1}^{m} \prod_{k=1}^{L} (1 - P_{ijkt})^{x_{ijkt}} \geqslant P_{jt}^{\min} \cdot \mathbf{1}[\sum_{i=1}^{m} \sum_{k=1}^{L} x_{ijkt} \geqslant 1]\ \forall j \in \mathcal{T}_t,\ \forall t. \quad (19)$$

其中, $P_{jt}^{\min}$ 随目标威胁等级 Th_{jt} 单调递增 (高威胁目标要求更高的毁伤确定性), 以确保每次打击行为具备实质性的毁伤效果, 避免低效的"象征性打击".

C12: 武器优先级匹配约束

设武器平台 i 的优先级等级为 $\ell_i \in \{1,2,\ldots,L_w\}$ (等级越高优先级越高), 目标 j 的威胁等级为 Th_{jt}. 一般地, 武器平台优先级应与目标威胁等级相匹配, 以体现高性能资源优先满足高威胁目标最低拦截需求的战场资源调配逻辑:

$$x_{ijkt} \leqslant M \cdot \mathbf{1}[\ell_i \geqslant \phi(Th_{jt})],\quad \forall i,\ \forall j \in \mathcal{T}_t,\ \forall k,\ \forall t. \quad (20)$$

其中, $\phi(Th_{jt})$ 为威胁等级到武器最低优先级要求的映射函数, 由作战规则预先确定.

C13: 决策变量非负整数约束

$$x_{ijkt} \in \mathbb{Z}_{\geqslant 0},\ \forall i,\ \forall j \in \mathcal{T}_t,\ \forall k,\ \forall t. \quad (21)$$

1.5 鲁棒性度量指标与方案优选机制

在 D-POWTA 的多阶段滚动优化框架下, 第t决策周期的最优解通常并不唯一. 本文将目标函数值处于$[F_t^*, F_t^* + \varepsilon]$内的全体可行方案定义为**近似最优解集**$\mathcal{S}_t^{\varepsilon}$. 虽然这些方案在当期等价最优, 但其在编码邻域内的局部质量支配裕度可能存在较大差异.

1.5.1 鲁棒性度量指标定义

为定量刻画方案在编码邻域内的局部质量优势, 引入{r阶汉明邻域}的概念. 在 TC-FCE 编码下, 两个个体$\mathbf{c}_t, \mathbf{c}_t'$之间的距离定义为拦截决策不一致的目标数目:

$$d_{\text{TC}}(\mathbf{c}_t, \mathbf{c}_t') = \sum_{j=1}^{n_t} \mathbf{1}[c_{jt} \neq c_{jt}']. \quad (22)$$

方案$\mathbf{c}_t$的r阶汉明邻域定义为:

$$\mathcal{N}_r(\mathbf{c}_t) = \{\mathbf{c}'_t \in \mathcal{F}_t | d_{\mathrm{TC}}(\mathbf{c}_t, \mathbf{c}'_t) \leqslant r\}. \tag{23}$$

其中r为邻域半径 (默认$r = 2$), 对应单周期内至多两个目标的拦截决策改变, 覆盖了方案在执行偏差与局部决策变动下最典型的变化幅度.

鲁棒性度量指标 (RMI) 定义为方案相对于其邻域内所有方案的目标函数值优势均值:

$$\rho(\mathbf{c}_t) = \frac{1}{|\mathcal{N}_r(\mathbf{c}_t)|} \sum_{\mathbf{c}'_t \in \mathcal{N}_r(\mathbf{c}_t)} [F_t(\mathbf{c}'_t) - F_t(\mathbf{c}_t)]. \tag{24}$$

$\rho(\mathbf{c}_t)$ 越大, 说明 $\mathbf{c}_t$ 在 TC-FCE 编码空间的局部景观中处于更深的"优化谷底"——其邻域内大多数可行方案的目标函数值显著高于当前方案, 当前方案具有更大的**编码邻域质量领先余量**.

RMI 的鲁棒性含义应从$\mathcal{S}_t^\varepsilon$的决策情境出发来理解. ε-近优解集的构造已将参数不确定性因素纳入: 所有适应度差异在$\varepsilon = 1\%$以内的候选方案均进入$\mathcal{S}_t^\varepsilon$, 即"相邻替代方案的质量损失有明确上界". 在此基础上, $\mathcal{S}_t^\varepsilon$内部各候选方案的适应度已高度相近, 进一步优选所依据的不再是参数不确定性, 而是**离散选择层面的保守性**: 高 RMI 方案相对其编码邻域内所有替代方案均保持最大的质量领先余量, 体现了"在多个近似等效方案中优先选取质量支配优势最强者"的保守决策逻辑, 类似于工程设计中"多个满足规格的方案中优先选取安全裕度最大者".

需要特别说明的是, 本文 RMI 与连续优化中常见的"平坦稳定"型鲁棒性指标针对的不确定性来源不同: 后者关注目标函数在参数扰动下的变化幅度 (适用于连续参数不确定性场景); 本文 RMI 关注离散组合解在编码邻域内的质量支配深度 (适用于$\mathcal{S}_t^\varepsilon$内多模态候选方案的优选场景). 在本文框架中, ε-近优解集机制承担了"控制扰动后性能损失"的功能, RMI 在此基础上进一步解决"从多个满足约束的候选方案中再选哪个"的决策问题, 两者在机制层面是互补的.

1.5.2　大规模问题的蒙特卡洛近似

对大规模实例 ($n_t > 100$), 精确邻域枚举计算复杂度过高, 采用蒙特卡洛采样以S个随机邻居近似 RMI:

$$\widehat{\rho}(\mathbf{c}_t) = \frac{1}{S} \sum_{s=1}^{S} [F_t(\mathbf{c}_t^{(s)}) - F_t(\mathbf{c}_t)],$$
$$\mathbf{c}_t^{(s)} \sim \mathbf{Uniform}(\mathcal{N}_r(\mathbf{c}_t)). \tag{25}$$

邻域采样通过随机选取r个基因位并从对应$\mathcal{A}_{jt}$中重新采样实现, 确保邻居仍为可行解. 默认$S = 50$, 计算复杂度降至$O(S \cdot n_t \cdot H_{\max})$, 满足决策时效要求.

2　求解方法

2.1　总体求解框架

针对 D-POWTA 问题的 NP 难性质与严格的时效约束, 本文设计了一个三层次递进式求解框架 (见图 2). 任意决策周期内的单周期子问题 (本质为 SWTA, 已知为 NP-hard[5]) 要求算法在有限计算预算内逼近高质量解, 且 13 类硬约束的复杂耦合使随机采样的候选方案大多不可行.

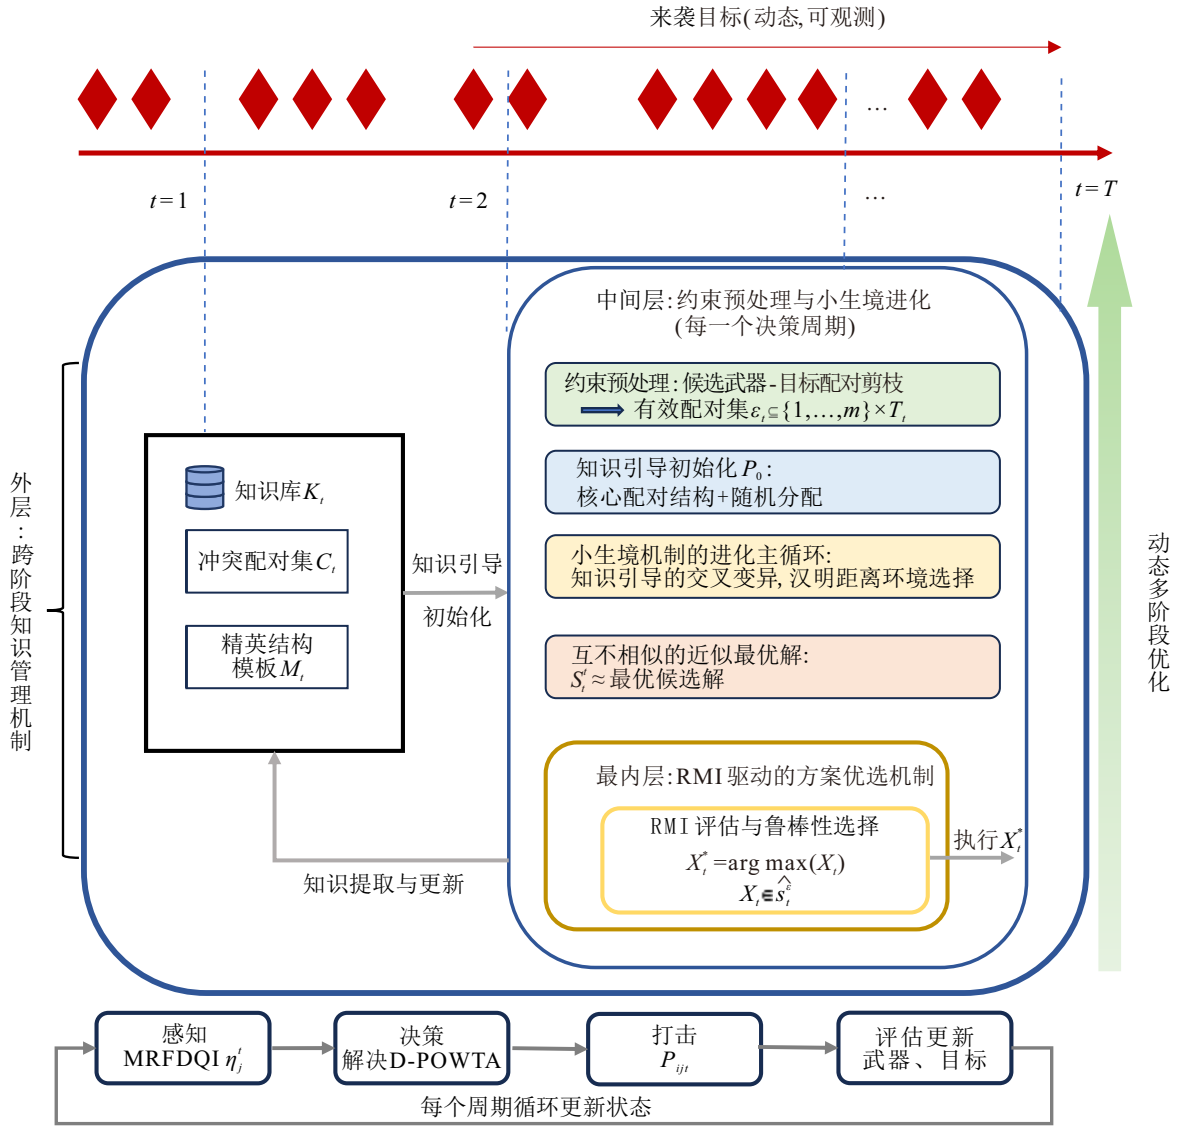

图 2 三层次递进式求解框架示意图

现有 DWTA 求解方法的普遍不足在于: 其一, 各决策周期被视为相互独立的重优化任务, 历史搜索信息没有发挥其作用; 其二, 沿用"单解范式", 为了解的迅速收敛, 会破坏解空间的多模态结构, 导致执行方案可能恰好是近似最优解集中鲁棒性最差的.

为此, 本文提出知识引导的动态滚动多模态进化算法 (Knowledge-Guided Dynamic Rolling Evolutionary Algorithm, KG-DREA). 该算法将 D-POWTA 的多阶段滚动求解过程具体执行为一个"知识积累→搜索加速→多模态保持→鲁棒优选"的闭合学习回路, 而非传统的孤立重优化序列. 该算法框架由三个相互嵌套的层次构成:

外层: 跨阶段知识管理. 第一个决策周期的初始知识库为空, 算法首先依赖当前周期约束预处理结果生成可行组合; 在每一周期的优化完成并执行方案后, 算法将进化过程中反复被淘汰且未被精英个体保留的低效配对模式抽象为分配冲突知识 (Assignment Conflict Knowledge, ACK), 存入知识库$\mathcal{K}$. 随着阶段推进, $\mathcal{K}$不断积累与更新, 使后续周期的搜索能从更优质的初始状态出发, 并通过知识引导算子主动规避已知无效区域.

中层: 约束预处理与小生境进化. 在种群初始化前, 依据当前周期约束状态对候选配对空间实施剪枝, 构造可行组合集$\mathcal{A}_{jt}$. 当$t=1$时, 初始化基于$\mathcal{A}_{jt}$进行混合随机采样; 当$t>1$时, 初始化进一步结合历史冲突知识提取无冲突候选集. 随后, 经由带小生境机制的进化主循环在多个优良模态上同步收敛, 最终保留互不相似的近似最优解集$\mathcal{S}_t^{\varepsilon}$.

内层: 鲁棒性驱动的方案优选. KG-DREA 不从$\mathcal{S}_t^{\varepsilon}$中简单取 fitness 最优解执行, 而是对每个候选方案计算鲁棒性度量指标$\rho(\mathbf{X}_t)$, 优先执行编码邻域内质量领先余量最大的方案$\mathbf{X}_t^*$.

2.2 KG-DREA 算法流程与框架设计

KG-DREA 的核心在于将多阶段滚动求解过程

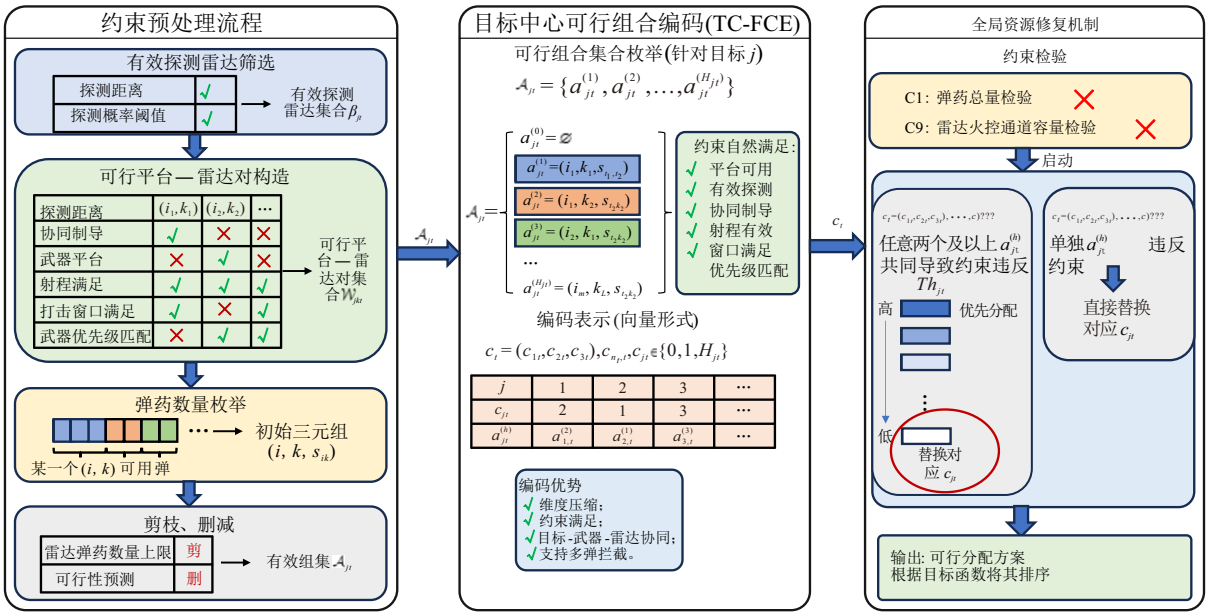

图 3　约束预处理、TC-FCE 编码与全局资源修复流程示意图

具体执行为一个"知识积累→搜索加速→多模态保持→鲁棒优选"的闭合学习回路, 而非传统孤立重优化的序列. 需要说明的是, 知识库并非在优化前人工给定完整规则库, 而是在滚动求解过程中逐阶段积累: 第一个周期设$\mathcal{K}_0 = \varnothing$, 算法仅利用当前周期约束预处理得到的可行组合集进行混合随机初始化; 从第二个周期开始, 上一阶段搜索中形成的冲突知识被用于初始化和变异. KG-DREA 算法流程如下:

输入: 动态环境状态序列$\{\mathcal{E}_1, \mathcal{E}_2, \ldots, \mathcal{E}_{T_{\text{total}}}\}$, 初始知识库$\mathcal{K}_0 = \varnothing$, 种群规模$N$, 最大代数$G_{\max}$.

输出: 各阶段执行方案序列$\{\mathbf{c}_1^*, \mathbf{c}_2^*, \ldots, \mathbf{c}_{T_{\text{total}}}^*\}$.

主循环:

1. 初始化: $\mathcal{K} \leftarrow \mathcal{K}_0$

2. **For** $t = 1$ to T_{total} **do**

约束预处理: 构造可行组合集$\mathcal{A}_{jt}, \forall j \in \mathcal{T}_t$

种群初始化: 若$t = 1$, 基于$\mathcal{A}_{jt}$混合随机生成$\mathcal{P}_0$; 若$t > 1$, 基于$\mathcal{K}_{t-1}$提取$\widetilde{\mathcal{A}}_{jt}$并生成知识引导初始种群

进化主循环: **For** $g = 1$ to $G_{\max}$ **do**

$\mathcal{Q}_g \leftarrow$ 交叉、知识引导变异、修复操作

执行汉明距离小生境环保选择, 得$\mathcal{P}_g$

End For

鲁棒优选: 构造$\mathcal{S}_t^{\varepsilon}$, 计算各方案 RMI 值$\rho(\mathbf{c}_t)$

优选方案: $\mathbf{c}_t^* \leftarrow \arg\max_{\mathbf{c}_t \in \mathcal{S}_t^{\varepsilon}} \rho(\mathbf{c}_t)$

知识更新: 统计目标–组合淘汰频次, 更新$\mathcal{C}_{t+1}$和$\mathcal{K}_{t+1}$

执行$\mathbf{c}_t^*$, 接收战场反馈

3. **End For**

4. **Return** $\{\mathbf{c}_1^*, \mathbf{c}_2^*, \ldots, \mathbf{c}_{T_{\text{total}}}^*\}$

KG-DREA 通过跨阶段知识库持久化目标-组合冲突模式, 在后续阶段的初始化和变异中优先采样无冲突补集$\widetilde{\mathcal{A}}_{jt}$, 主动规避已知无效区域以加速收敛. 基于汉明距离的小生境机制维持N个分散的种群个体在多个局部最优区域开展并行搜索, 系统发现等价最优解集$\mathcal{S}_t^{\varepsilon}$并避免标准进化算法的早熟收敛. 与传统单解范式不同, KG-DREA 对$\mathcal{S}_t^{\varepsilon}$中各方案计算鲁棒性度量指标$\rho(\mathbf{c}_t)$, 优先执行处于编码空间深谷底的方案, 该优选准则的双重作用详见 2.7 节.

2.3　编码设计与约束预处理

2.3.1　目标中心的可行组合编码 (TC-FCE)

原始模型的决策变量x_{ijkt}为四维非负整数张量(维度规模达$m \times n_t \times L$), 且 13 类约束相互耦合, 直接进化搜索维度高、可行解稀疏. 为解决此问题, 本文提出目标中心的可行组合编码 (Target-Centric Feasible Combination Encoding, TC-FCE), 将约束处理前置于编码设计阶段.

对第t个决策周期的目标$j \in \mathcal{T}_t$, 定义其可行交战组合 (Feasible Engagement Combination, FEC) 为一个三元组(i, k, s), 表示"武器平台i向目标j发射s发弹药、由雷达k制导"的交战行动, 其中$s \in \{1, 2, \ldots, \min(q_{it}, U_{jt})\}$. 该三元组须同时满足以下六类条件:

$$
\begin{aligned}
& a_{it} = 1 && \text{(武器平台可用, C2)} \\
& k \in \mathcal{B}_{jt} && \text{(雷达有效探测, C6,C7)} \\
& \alpha_{ijkt} = 1 && \text{(对目标}j\text{的协同制导可行, C8)} \\
& d_{ijt} \leqslant R_i^{\max} && \text{(目标在射程内, C4)} \\
& \tau_i^{\text{react}} + \frac{d_{ijt}}{v_i} \leqslant W_{jt} && \text{(在打击窗口内, C5)} \\
& \ell_i \geqslant \phi(Th_{jt}) && \text{(武器优先级匹配, C12).}
\end{aligned} \tag{26}
$$

对目标j在第t周期的所有可行三元组按固定顺序 (如武器编号-雷达编号-弹药数的字典序) 枚举, 记为:

$$
\begin{aligned}
\mathcal{A}_{jt} = \{(i,k,s) \mid \text{上述六条件同时成立}\} = \\
\{\mathbf{a}_{jt}^{(1)}, \mathbf{a}_{jt}^{(2)}, \ldots, \mathbf{a}_{jt}^{(H_{jt})}\}.
\end{aligned} \tag{27}
$$

其中$H_{jt} = |\mathcal{A}_{jt}|$为目标$j$的可行组合总数. 特别地, 定义$\mathbf{a}_{jt}^{(0)} = \varnothing$表示"不拦截"的空动作. 若$H_{jt} = 0$, 则强制仅$\mathbf{a}_{jt}^{(0)}$可选.

基于上述定义, 第t周期的候选解编码为长度为n_t的非负整数向量:

$$
\begin{aligned}
& \mathbf{c}_t = (c_{1t}, c_{2t}, \ldots, c_{n_t,t}), \\
& c_{jt} \in \{0, 1, \ldots, H_{jt}\}.
\end{aligned} \tag{28}
$$

其中$c_{jt} = h(h \geqslant 1)$ 表示对目标j采用第h个可行交战组合$\mathbf{a}_{jt}^{(h)} = (i_{jt}^h, k_{jt}^h, s_{jt}^h)$; $c_{jt} = 0$表示不拦截.

约束预处理、TC-FCE 编码与全局资源修复的完整流程如图 3 所示.

本编码方案具有以下优势: (1) 维度大幅压缩, 从原始 $m \times n_t \times L$ 决策张量降至 n_t 维编码向量, 每维候选取值数从 $m \times L$ 量级收缩至预筛选的可行组合数 H_{jt}; (2) 天然满足六类约束, 字典$\mathcal{A}_{jt}$的构造内嵌 C2、C4、C5、C8、C10、C12, 任意合法编码对应约束可行解; (3) 显式建模协同制导并自然支持多弹拦截, 每个基因位包含武器、雷达、弹药三重信息, 通过$s_{jt}^h \geqslant 1$直接编码弹药数量.

2.3.2 约束预处理流程

在第t周期优化启动前, 执行全量约束扫描为每个目标构造$\mathcal{A}_{jt}$:

步骤 1 (有效探测雷达子集): 对每个目标j, 基于 C6、C7 筛选: $\mathcal{B}_{jt} = \{k | d_{kjt} \leqslant R_k^{\text{radar}} \wedge p_{kjt} \geqslant p_{\text{th}}\}$. 若$\mathcal{B}_{jt} = \varnothing$, 则$H_{jt} = 0$, 目标不可拦截.

步骤 2 (可行平台-雷达对): 基于 C8、C2、C4、C5、C12, 对每个(k,i)对筛选可用平台.

步骤 3 (弹药数量枚举): 对每个 $(i,k) \in \mathcal{W}_{jkt} \times \mathcal{B}_{jt}$, 枚举 $s \in \{1, \ldots, \min(q_{it}, U_{jt})\}$生成三元组加入$\mathcal{A}_{jt}$.

步骤 4 (C9 启发式剪枝): 若全局所有目标向雷达k的总弹药超过C_k^{track}, 对弹药上界施加启发式约束: $s \leqslant \lfloor \frac{C_k^{\text{track}}}{|\{j' \in \mathcal{T}_t : k \in \mathcal{B}_{j't}\}|} \rfloor$

步骤 5 (C11 可行性预检): 删除毁伤概率低于$P_{jt}^{\min}$且存在更优替代的低效三元组.

预处理总时间复杂度为$O(n_t \cdot m \cdot L \cdot q_{\max})$, 在实际规模下 $(n_t \leqslant 100, m \leqslant 160, L \leqslant 10)$ 通常不超过毫秒量级.

2.3.3 全局资源一致性修复

TC-FCE 编码天然满足针对单目标的局部约束, 但 C1 与 C9 是跨目标全局约束, 需在解码阶段修复.

给定编码$\mathbf{c}_t$, 解码方案需满足:

$$
\begin{aligned}
& \text{C1 检验:} \quad \sum_{j \in \mathcal{T}_t} s_{jt}^{c_{jt}} \cdot \mathbf{1}[i_{jt}^{c_{jt}} = i] \leqslant q_{it}, \ \forall i \\
& \text{C9 检验:} \quad \sum_{j \in \mathcal{T}_t} s_{jt}^{c_{jt}} \cdot \mathbf{1}[k_{jt}^{c_{jt}} = k] \leqslant C_k^{\text{track}}, \ \forall k.
\end{aligned} \tag{29}
$$

若违反资源约束, 则执行威胁优先级驱动的贪心修复: 将违反约束的目标$c_{jt} \neq 0$按Th_{jt}降序排列, 依次令其在剩余可行组合中重新选择; 无可行替代则令$c_{jt} \leftarrow 0$.

2.4 跨阶段知识管理机制

2.4.1 知识结构定义

在 TC-FCE 编码下, 知识库$\mathcal{K}_t$存储截至第$t-1$周期积累的历史冲突知识, 而不是第t周期优化前人工预设的完整知识. 其核心内容为目标–组合冲突集:

$$
\mathcal{C}_t = \{(j,h) | \mathbf{a}_{jt}^{(h)} \text{在历史周期中高频淘汰}\}. \tag{30}
$$

在第t周期进化结束后, 将最终种群中排名靠前的个体记为精英集, 将环境选择中被淘汰的个体记为淘汰集. 若某目标–组合(j,h)多次出现在淘汰个体中而未被精英个体稳定保留, 则累计其淘汰计数. 定量地, 第$t+1$周期的冲突集更新为:

$$
\mathcal{C}_{t+1} = \{(j,h) | \text{elim-count}_t^{(j,h)} \geqslant \theta_c\}. \tag{31}
$$

其中$\text{elim-count}_t^{(j,h)}$表示截至第$t$周期, 组合$(j,h)$在淘汰个体中出现且未被精英个体保留的累计次数, θ_c为冲突判定阈值, 用于避免将偶然淘汰的组合过早写入冲突知识库. 基于预实验比较, $\theta_c = 5$在小规模算例 I1–I3 和大规模算例 I8–I10 上均表现稳定, 本文统一取$\theta_c = 5$. 某组合在历史搜索中持续被优胜个体舍弃, 说明其在当前态势下效率较低, 后续周期应减少对此区域的探索.

2.4.2 跨阶段知识迁移规则

由于动态环境中目标集合 $\mathcal{T}_t$ 随阶段变化, 知识库 $\mathcal{K}_t$ 中存储的冲突对 (j,h) 在阶段间迁移时, 需按目标的存续状态进行条件处理:

(1) 目标消失 ($j \notin \mathcal{T}_{t+1}$): 若目标 j 在第 $t+1$

周期已被摧毁或飞出防区, 则涉及该目标的所有冲突对 $\{(j,h) \mid (j,h) \in \mathcal{C}_t\}$ 从知识库中清除, 不向后续周期传递.

(2) 新目标出现 ($j \in \mathcal{T}_{t+1}$ 且为首次出现): 新出现的目标无历史搜索记录, 其冲突集初始化为空集 $\mathcal{C}_{t+1}^{(j)} = \varnothing$, 即对其所有可行交战组合一视同仁, 不施加知识约束.

(3) 目标持续存在 ($j \in \mathcal{T}_t \cap \mathcal{T}_{t+1}$): 传递该目标的历史冲突记录. 需要强调的是, 可行组合字典 $\mathcal{A}_{jt}$ 由约束预处理按固定顺序枚举生成, 索引 h 仅是物理组合三元组 (i,k,s)(武器平台–雷达–弹药数) 在第 t 阶段字典中的位置编号, 并不具备跨阶段语义: 当目标机动、弹药消耗或探测条件变化导致可行集合变化时, 同一索引在新旧字典中可能指向不同的物理组合. 因此, 跨阶段迁移按物理组合而非索引进行匹配: 先将历史冲突索引 h 经 $\mathcal{A}_{jt}$ 解码为其物理组合 $(i,k,s) = \mathbf{a}_{jt}^{(h)}$, 再在 $\mathcal{A}_{j,t+1}$ 中检索该物理组合的新索引 h':

$$\mathcal{C}_{t+1}^{(j)} = \{h' | (j,h) \in \mathcal{C}_t,\ \exists\, h'' \in \{1,\ldots,H_{j,t+1}\} : \mathbf{a}_{j,t+1}^{(h'')} = \mathbf{a}_{jt}^{(h)}\}. \tag{32}$$

即仅保留其物理组合在第 $t+1$ 周期仍可行的历史冲突记录, 并将其重定位到新索引; 若资源耗尽或态势变化导致该物理组合在新字典中已不可行, 对应冲突记录自动失效, 不向后续周期传递.

上述规则以目标编号 j 为键、以物理组合 (i,k,s) 为匹配基准进行条件迁移, 确保知识库内容在不同阶段的可行组合字典之间始终保持语义一致, 新目标与已消亡目标的处理均有明确界定.

2.4.3　知识引导的种群初始化

对目标j的无冲突候选集定义为:

$$\widetilde{\mathcal{A}}_{jt} = \{h \mid (j,h) \notin \mathcal{C}_t, h \in \{1,\ldots,H_{jt}\}\}. \tag{33}$$

当$t=1$时, $\mathcal{C}_1 = \varnothing$, 因此$\widetilde{\mathcal{A}}_{j1} = \{1,\ldots,H_{j1}\}$, 初始化退化为基于可行组合集的混合随机初始化; 当$t>1$时, 算法利用历史冲突集过滤可行组合. 初始种群$\mathcal{P}_0$的生成规则为: **前$\lfloor N/2 \rfloor$个体**: 每个基因位c_{jt}从$\widetilde{\mathcal{A}}_{jt} \cup \{0\}$均匀随机采样 (偏向无冲突组合); **后$\lfloor N/2 \rfloor$个体**: 每个基因位$c_{jt}$从完整集合$\{0,1,\ldots,H_{jt}\}$均匀随机采样 (保持种群多样性, 防止知识库过时导致早熟收敛). 初始化所用知识主要来自两部分: 一是由射程、探测、协同制导、打击窗口和武器优先级等作战规则形成的当前阶段可行组合知识; 二是从第二阶段开始积累的历史冲突知识.

所有初始个体生成后均通过全局资源一致性修复确保可行性. 这种混合初始化策略既利用历史知识加速收敛, 又通过部分随机个体防止陷入知识过时的局部极值.

表 2　D-POWTA 标准化测试集配置

算例	武器数 m	雷达数 L	总目标数 N	阶段数 T_{total}	各阶段目标数 n_t
I1	6	6	24	2	13, 11
I2	6	6	30	3	11, 10, 9
I3	6	6	50	4	14, 13, 12, 11
I4	6	6	100	5	22, 21, 20, 19, 18
I5	8	6	100	8	14, 13, 13, 13, 12, 12, 12, 11
I6	8	6	200	5	43, 41, 40, 39, 37
I7	10	6	200	10	22, 21, 21, 20, 20, 20, 19, 19, 19, 19
I8	10	8	300	6	53, 52, 51, 49, 48, 47
I9	10	8	500	8	67, 65, 64, 63, 63, 62, 61, 55
I10	10	8	500	10	53, 52, 51, 51, 50, 50, 49, 48, 48, 48

2.5　知识引导的进化算子

对两个父本$\mathbf{c}_t^{(1)}, \mathbf{c}_t^{(2)} \in \mathbb{Z}^{n_t} \geqslant 0$, 采用均匀交叉: 对每个基因位$j$以概率 0.5 分别遗传自父本的组合选择:

$$c_{jt}^{\text{child}} = \begin{cases} c_{jt}^{(1)}, & \text{以概率 } 0.5 \\ c_{jt}^{(2)}, & \text{以概率 } 0.5 \end{cases} \tag{34}$$

对个体$\mathbf{c}_t$的每个基因位j, 变异操作根据当前取值是否属冲突集分流处理. 若当前武器分配(j, c_{jt})已被记录在冲突集中, 则以概率p_{guided}从补集$\widetilde{\mathcal{A}}_{jt} \cup \{0\}$中均匀采样一个新的武器编号; 否则以标准变异率均匀随机采样. 当某个目标的所有组合均已纳入历史冲突集合 (即$\widetilde{\mathcal{A}}_{jt} = \varnothing$) 时, 算子退化为在完整集合$\{0,1,\ldots,H_{jt}\}$上进行均匀随机采样, 确保变异操作不会因冲突信息过度而失效. 完成基因位层面的变异后, 对整个个体执行全局资源一致性修复, 确保生成的分配方案满足所有的武器资源、探测覆盖和约束条件.

知识引导变异的核心设计思想: 对处于冲突区域的个体施加强制性的知识纠正 (更高的引导变异率p_{guided}), 而对非冲突区域的个体保持温和的探索压力 (标准变异率p_{mut}), 从而既主动规避已知无效区域, 又保留对新区域的适度探索.

2.6　基于汉明距离的小生境环保选择

2.6.1　编码空间距离定义

在 TC-FCE 编码下, 两个个体$\mathbf{c}_t, \mathbf{c}_t'$之间的距离定义为拦截决策不一致的目标数目 (汉明距离的变体):

$$d_{\mathrm{TC}}(\mathbf{c}_t, \mathbf{c}'_t) = \sum_{j=1}^{n_t} \mathbf{1}[c_{jt} \neq c'_{jt}]. \tag{35}$$

该度量直接反映两个方案在"目标拦截决策"层面的差异数量. 即使两个方案对某目标的物理效果相近, 若选择了不同的武器平台-雷达-弹药组合, 距离即计为 1, 从而在语义层面更精确地刻画了"分配方案结构性差异".

2.6.2 小生境选择流程

在每一代的环境选择阶段, 将当代种群 P_g 与子代 Q_g 合并为候选池 $R_g = P_g \cup Q_g$, 按如下过程选取下一代种群 P_{g+1}:

首先, 将 R_g 中的所有个体按目标函数值 $F_t(c)$ 升序排列构建精英队列, 再执行峰值保护选择: 依次取出候选个体 c, 若 c 与已选入种群中所有个体的汉明距离均大于小生境半径 δ, 则直接加入; 否则, 在与 c 距离不超过 δ 的已选个体中找出目标函数值最小者 c^*, 若 $F_t(c) < F_t(c^*)$ 则以 c 替换 c^*, 否则丢弃 c. 重复上述过程直至种群规模达到 N.

2.7 基于 RMI 的方案优选规则

在每一决策周期, KG-DREA 通过小生境机制同步维持多个精英候选方案, 形成近似最优解集$\mathcal{S}_t^{\varepsilon}$. 从该集合中, 按如下规则优选执行方案:

$$\mathbf{c}_t^* = \arg\max_{\mathbf{c}_t \in \mathcal{S}_t^{\varepsilon}} \rho(\mathbf{c}_t). \tag{36}$$

若存在ρ值并列的情形, 则以$F_t(\mathbf{c}_t)$更小者优先, 体现"同等鲁棒性下优先选取当期效能最优方案"的决策逻辑.

该优选规则具有双重作用: 其一, 在当期阶段, ε-近优解集的构造已保证所有候选方案的适应度损失在$\varepsilon = 1\%$以内 (即"扰动后性能损失有明确上界"), 而高 RMI 方案在此基础上进一步具备邻域内最大的质量领先余量, 是在多个近似等效候选中最具保守性的执行选择; 其二, 同期将该方案的编码模式写入知识库, 高 RMI 解 (深谷底) 比低 RMI 解更准确地代表当期已被进化搜索彻底覆盖的分配区域, 使跨阶段知识迁移更为有效. 两个作用共同提升了多阶段滚动求解的整体效能.

3 实 验

3.1 实验设置

3.1.1 测试集构建

鉴于当前领域缺乏针对动态部分可观测 WTA 问题的公开基准数据集, 本文构建了包含 10 个标准测试算例的评测集. 这些算例沿规模维度 (总目标数 24 至 500) 和时序复杂度维度 (决策阶段数 2 至 10) 进行了正交设计.

为确保对实际作战场景的充分覆盖, 测试集引入了多雷达探测质量差异、目标隐身特性差异以及相邻阶段间目标集动态演变等异质性因素. 表 2 详细列出了所有算例的配置参数, 覆盖了从小规模快速反应到大规模饱和攻击的多样化实战场景. 对于第i个算例, 总目标数N分配至T_{total}个决策阶段, 满足$\sum_{t=1}^{T_{\mathrm{total}}} n_t = N$; 通过调整$N$、$T_{\mathrm{total}}$及各阶段的目标分配比例, 可便捷地生成覆盖更大规模或更复杂时序结构的新算例.

3.1.2 对比算法设置

由于 D-POWTA 属于本文首次提出的新型动态优化问题, 现有文献中的算法无法直接应用. 因此选取三类具有代表性和参考价值的对标算法与所提 KG-DREA 进行系统对比.

启发式分配算法 (HA) 是基于专家规则的工程基线方法, 每个决策周期按固定的优先级规则一次性生成完整分配方案: 以目标威胁等级Th_{jt}为主排序键、探测质量指标η_{jt}为次排序键对目标降序排列, 对每个目标从满足约束 C4、C5、C8、C10 的可用武器中贪心选取毁伤概率最高者, 并通过资源保护参数$\gamma = 0.5$防止武器资源过度集中于最高威胁目标. HA 计算效率最高, 但优化品质受限.

标准遗传算法 (GA) 在每个决策周期独立执行标准进化搜索, 采用与 KG-DREA 相同的编码方式以保证对比公平性, 但不纳入跨阶段知识迁移、知识引导变异、小生境多模态保持与 RMI 优选机制, 以精确量化所提机制组合对性能的贡献.

知识引导大规模防空资源分配进化算法 (LKEA) 是由 Li 等人[30] 针对大规模 SWTA 问题专门设计的最新方法. LKEA 融入了知识引导的种群初始化和进化算子, 代表了当前 WTA 领域中知识引导进化范式[30-31] 的先进水平. 本文以动态滚动方式在各决策周期顺序调用 LKEA 作为单周期求解器, 其原有的算法组件保持完全不变. LKEA 不具备针对离散组合解空间的多模态保持与鲁棒优选机制, 通过对比可充分评估本文多模态-鲁棒框架相对于现有知识引导范式的性能增益.

KG-DREA 的超参数通过网格搜索在预实验阶段确定, 在所有测试算例上保持统一固定. 种群规模设定为$5 \cdot n_t$, 最大迭代代数为 100, 蒙特卡洛邻域采样数为 50, 冲突判定阈值设为$\theta_c = 5$. 受篇幅限制, 本文仅报告参数调整后的统一取值; 更详细的参数配置与代码实现见文中开源地址. 对比算法 GA 和

LKEA 采用相同的种群规模和迭代代数, 其余参数按各自原始文献中的推荐值设置; HA 的资源保护参数设为 0.5. 所有算法在同一硬件平台上独立运行 31 次, 报告目标函数值的均值 (Mean) 和标准差 (Std). 采用显著性水平$\alpha = 0.05$的 Wilcoxon 秩和检验来判断不同算法间性能差异是否具有统计学意义, 并用"+"、"−"、"≈"分别标记 KG-DREA 相对于对比算法显著优于、显著劣于或无显著差异的情况.

3.2　结果分析

3.2.1　总体性能对比

表 3 总结了全部对比算法在所有测试算例上的求解结果. KG-DREA 在全部 10 个测试算例上均显著优于三个对比算法, 表明无论问题规模和时序复杂度如何变化, 知识迁移、多模态保持与鲁棒优选的有机结合均可持续获得高质量的动态分配方案.

表 3　全部算法在标准测试集上的性能对比 (残余威胁值, 越小越优)

算例	HA	GA	LKEA	KG-DREA	显著性检验[a]
I1	6.3812	4.3729 ± 0.12	4.3952 ± 0.11	3.8028 ± 0.02	+/+/+
I2	8.7661	5.9895 ± 0.09	5.9804 ± 0.05	5.6434 ± 0.01	+/+/+
I3	15.3235	11.1388 ± 0.16	11.2219 ± 0.20	9.5226 ± 0.04	+/+/+
I4	26.7514	20.9342 ± 0.26	21.0150 ± 0.21	18.3216 ± 0.06	+/+/+
I5	21.9975	15.9611 ± 0.10	15.9783 ± 0.08	15.4877 ± 0.02	+/+/+
I6	61.2779	43.4277 ± 0.27	43.7273 ± 0.33	37.0943 ± 0.23	+/+/+
I7	33.2545	27.4135 ± 0.07	27.4241 ± 0.13	26.4619 ± 0.04	+/+/+
I8	92.3745	72.8553 ± 0.41	73.1812 ± 0.47	65.2937 ± 0.25	+/+/+
I9	157.4035	131.6789 ± 0.69	132.0855 ± 0.66	116.9982 ± 0.33	+/+/+
I10	118.3776	95.6350 ± 0.39	95.7239 ± 0.49	86.3838 ± 0.23	+/+/+

注: 表中数据为目标函数值(残余威胁, Mean±Std)的31次独立运行结果. 显著性标记对应"vs. HA / vs. GA / vs. LKEA"的Wilcoxon秩和检验结果 ($\alpha = 0.05$).

表 4　代表性算例中的多模态结构分析 (前 5 个近似最优解)

算例-阶段	解序号	Fitness	RMI	汉明距离[a]	分配数	备注
I1-第1阶段	1	1.8091	0.1246	—	10	最优解
	2	1.8180	0.1301	5	10	$\Delta F = 0.0089$
	3	1.8248	0.1811	6	10	$\Delta F = 0.0157$
	Fitness跨度: 0.0157 | RMI跨度: 0.0565 | 汉明距离: min=5, max=6, mean=5.5					
I2-第2阶段	1	1.3371	0.1682	—	7	最优解
	2	1.3421	0.1607	6	7	$\Delta F = 0.0050$
	3	1.3421	0.1531	7	7	$\Delta F = 0.0050$
	4	1.3421	0.1644	7	7	$\Delta F = 0.0050$
	5	1.3450	0.1434	5	7	$\Delta F = 0.0079$
	Fitness跨度: 0.0079 | RMI跨度: 0.0249 | 汉明距离: min=5, max=7, mean=6.25					
I5-第5阶段	1	2.6013	0.0592	—	7	最优解
	2	2.6013	0.0695	6	7	$\Delta F = 0.0000$
	3	2.6013	0.0538	5	7	$\Delta F = 0.0000$
	4	2.6013	0.0832	4	7	$\Delta F = 0.0000$
	5	2.6013	0.0730	4	7	$\Delta F = 0.0000$
	Fitness跨度: 0.0000 | RMI跨度: 0.0294 | 汉明距离: min=4, max=6, mean=4.75					
I6-第3阶段	1	8.2197	0.0636	—	22	最优解
	2	8.2831	0.0823	9	22	$\Delta F = 0.0634$
	3	8.2971	0.1251	7	22	$\Delta F = 0.0773$
	Fitness跨度: 0.0773 | RMI跨度: 0.0615 | 汉明距离: min=7, max=9, mean=8.00					
I7-第1阶段	1	9.3095	0.0390	—	15	最优解
	2	9.3110	0.0625	9	15	$\Delta F = 0.0015$
	3	9.3155	0.0550	10	15	$\Delta F = 0.0060$
	4	9.3155	0.0398	6	15	$\Delta F = 0.0060$
	5	9.3155	0.0243	6	15	$\Delta F = 0.0060$
	Fitness跨度: 0.0060 | RMI跨度: 0.0382 | 汉明距离: min=6, max=10, mean=7.75					

注: [a]汉明距离表示该解与最优解之间的目标分配决策差异度. ΔF为该解与最优解的Fitness差值.

KG-DREA 相比 LKEA 的性能提升幅度为 3.1% 至 15.2%, 整体平均提升 10.6%, 在约束较为复杂的算例 (I3、I6) 上提升尤为显著, 充分说明了多模态保持与鲁棒优选在高复杂度分配问题中的协同价值. KG-DREA 相比 GA 的性能提升幅度为 3.0% 至 14.6%, 整体平均提升 10.3%, 验证了知识引导与多模态保持在多阶段大规模问题上的强化作用. 相比工程基线 HA, KG-DREA 整体平均性能提升达 29.0%, 验证了进化优化相对于简单贪心策略的必要性. 特别地, 在绝对威胁量最大的算例 I9 上, HA 的残余威胁高达 157.403 5, 而 KG-DREA 仅为 116.9982.

图 4 展示了 KG-DREA 在代表性算例 (I3) 上的迭代收敛曲线. 可以发现, 通过知识迁移和引导性初始化, KG-DREA 快速接近前沿解; 小生境机制则激活多条进化路径的并行探索, 在保持种群多样性的同时进行深度开采. 同时, KG-DREA 在各算例上的标准差显著低于对比算法: 以大规模算例 I10 为例, KG-DREA 的标准差为 0.23, 较 LKEA(0.49) 和 GA(0.39) 分别降低 53.1% 和 41.0%, 说明所提方法兼具更优的解质量与收敛稳定性. 图 5 进一步给出了 KG-DREA 在算例 I3 各决策阶段的武器–目标分配结果, 可直观观察到算法随各阶段来袭目标与可用资源的动态变化对拦截部署的实时调整.

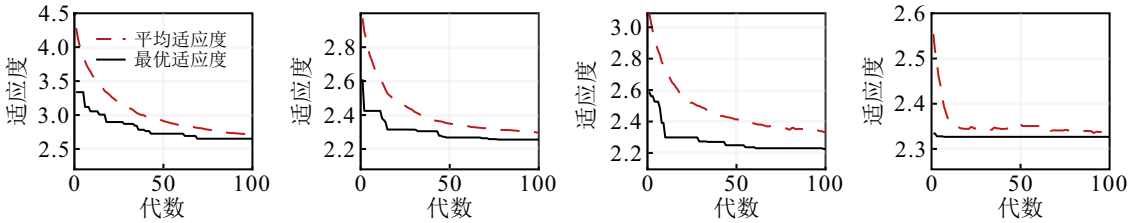

(a) 第 1 阶段 (b) 第 2 阶段 (c) 第 3 阶段 (d) 第 4 阶段

图 4 KG-DREA 求解算例 I3 各阶段算法收敛曲线

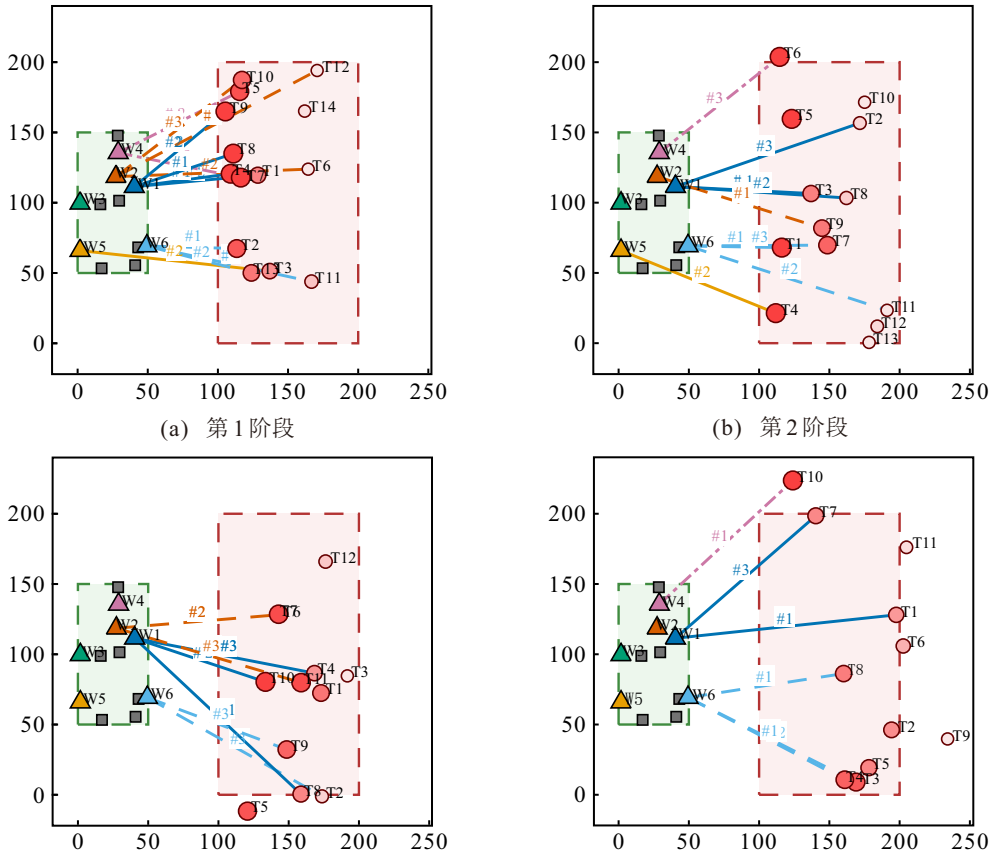

(a) 第 1 阶段 (b) 第 2 阶段 (c) 第 3 阶段 (d) 第 4 阶段

图 5 KG-DREA 求解算例 I3 各阶段武器-目标分配结果 ((a)-(d) 分别对应第 1-4 阶段; ▲为武器平台, ■为雷达, ●为来袭目标 (颜色越深威胁度越高); 连线颜色与线型对应各武器平台, $\times n$为分配弹药数; 绿色虚线框为防御区域, 红色虚线框为来袭区域)

3.2.2 多模态特性的实验验证

为验证 SWTA 解空间多模态特性的普遍性和

重要性, 本文在 10 个测试算例的各个决策阶段中对识别出的近似最优解进行了详细分析. 表 4 汇总了代表性算例中多个近似最优解的具体指标, 具体观察如下:

(1) 多模态的普遍存在性: 在全部代表性算例中, 除 I6 第 3 阶段仅识别出 3 个近似最优解外, 其余均发现了 4 个以上的近似最优解. 这些解虽然目标函数值 (Fitness) 极为接近 (相对差异 $\leqslant 0.8\%$), 但在目标分配决策上存在显著差异. 例如在 I7 第 1 阶段, 5 个近似最优解的 Fitness 跨度仅为 0.0060(相对差异 0.064%), 但汉明距离的范围达到 6–10, 平均距离为 7.75, 说明这些在目标函数值上几乎无差异的解采取了结构差异很大的分配方式.

(2) 多模态解的鲁棒性差异显著: 更为关键的是, 这些近似最优解在 RMI 指标上呈现出明显的分化. 在 I5 第 5 阶段, 5 个解的 Fitness 值完全相同 (均为 2.6013), 但 RMI 值跨度高达 0.0294(从 0.0538 至 0.0832), 相对差异达 54.7%; 在 I6 第 3 阶段, 最优解与第 3 个解的 RMI 分别为 0.0636 和 0.1251, 后者达前者的 1.97 倍. 这直观说明若算法仅根据单一目标函数值进行选择, 可能选中局部质量优势较弱的方案, 从而忽视鲁棒性维度上的重要差异, 充分验证了 RMI 优选机制的必要性.

3.2.3　残余威胁与拦截率分析

从残余威胁指标看, KG-DREA 在全部 10 个算例上的整体残余威胁平均为 38.50, 相比 GA(42.94) 和 LKEA(43.07) 分别降低 10.3% 和 10.6%.

特别值得关注的是大规模算例中 KG-DREA 的表现. 在 I9(总目标数 500, 8 个阶段) 上, 平均每阶段的残余威胁为 13.86, 相当于平均拦截率约为 97.2% (基于统计平均威胁值假设). 在 I10(总目标数 500, 10 个阶段) 上, 由于阶段数增多导致资源压力相对缓解, 平均拦截率更是达到 97.8%, 充分体现了 KG-DREA 在真实防空作战中的适用价值.

3.3　消融实验

为系统评估三个核心机制的贡献, 本文设计了三个算法变体以隔离其独立贡献: (1) KG-DREA-KT——禁用知识迁移机制, 改为每个阶段的种群纯随机初始化; (2) KG-DREA-MM——禁用基于汉明距离的多模态保持机制, 改为标准的全种群排序选择; (3) KG-DREA-RMI——禁用 RMI 鲁棒优选机制, 改为单纯基于目标函数值的精英保留. 全部 10 个测试算例独立运行 31 次, 结果汇总于表 5. 消融实验结果揭示了三个核心机制的相对贡献:

表 5　三个核心机制的消融实验结果 (全部 10 个测试算例, 31 次独立运行的平均残余威胁值)

算例	KG-DREA	-KT	-MM	-RMI
I1	3.8028	3.8912	3.8256	3.8312
I2	5.6434	5.8234	5.7512	5.7645
I3	9.5226	9.8145	9.7423	9.7234
I4	18.3216	19.5423	18.9756	18.7834
I5	15.4877	16.3912	16.1267	15.9523
I6	37.0943	39.6234	38.3156	38.6912
I7	26.4619	28.9756	28.3678	27.8123
I8	65.2937	71.8567	69.4923	70.2345
I9	116.9982	121.3456	118.6234	118.3567
I10	86.3838	97.5123	93.8912	94.5834
平均下降	—	7.2%	4.7%	3.3%

知识迁移机制 (KT) 贡献度最大, 在所有 10 个算例中平均性能下降 7.2%, 其优势在大规模问题上尤为突出 (I7–I10 下降 9.6%–12.8%), 表明从前阶段优质解附近初始化能显著减少盲目探索、加速算法收敛.

多模态保持机制 (MM) 贡献度次之, 平均性能下降 4.7%, 且呈明显的规模依赖特性: 在小规模问题 (I1–I3) 上下降约 1.0%–2.2%, 而在大规模问题 (I8–I10) 上上升至 5.7%–8.3%, 表明小生境机制在大规模约束紧张的问题中能有效防止种群陷入单一局部最优, 维持多条并行搜索路径.

鲁棒优选机制 (RMI) 贡献度相对较小, 平均性能下降 3.3%, 但在大规模多阶段问题中的累积效应不容忽视. KG-DREA 每阶段从近似最优解集 $\mathcal{S}_t^{\varepsilon}$ 中选取 ρ 值最大的方案执行, 其依据在于: 实际战场中弹药命中率具有随机性、目标状态可能临时变化, 这些**当期执行层面的不确定性**在 TC-FCE 编码空间中等价于对当前方案的局部扰动. 高 RMI 解处于编码空间深谷底, 局部变动所触及的邻域解均显著较差, 方案在执行偏差下的实际残余威胁退化幅度更小; 禁用 RMI 后改为执行 min-fitness 解, 其浅谷底特性使执行偏差更易触及方案质量下限, 多阶段累积后整体性能显著退化.

4　结　论

本文针对动态非全信息环境下的武器目标分配问题, 从多模态优化和鲁棒性分析的联合视角, 揭示了 SWTA 解空间固有的多模态结构, 提出基于汉明邻域的鲁棒性度量指标 (RMI) 以定量刻画近似最优解在编码邻域内的局部质量支配裕度; 建立了显式刻画信息不完备性的完整 D-POWTA 数学模型; 并提出了知识引导的动态滚动多模态进化算法 (KG-DREA), 通过跨阶段知识管理、汉明距离小生境维持

和 RMI 驱动的鲁棒优选, 实现了知识、多模态与鲁棒性的有机统一. 系统实验表明, KG-DREA 在全部 10 个测试算例 (目标数 24 至 500, 阶段数 2 至 10) 上均显著优于对比方法, 相比启发式、标准遗传和最新知识引导算法的性能提升分别达 29.0%、10.3% 和 10.6%; 消融实验揭示了知识迁移、多模态保持和鲁棒优选三个机制的平均贡献分别为 7.2%、4.7% 和 3.3%; 在大规模多阶段问题 (I9、I10) 上, KG-DREA 的平均拦截率分别达 97.2% 和 97.8%, 验证了所提框架对实战防空需求的适应性.

参考文献 (References)

[1] Li J R, Wu G H, Wang L. A comprehensive survey of weapon target assignment problem: Model, algorithm, and application[J]. Engineering Applications of Artificial Intelligence, 2024, 137: 109212.

[2] Menq J Y, Tuan P C, Liu T S. Discrete Markov ballistic missile defense system modeling[J]. European Journal of Operational Research, 2007, 178(2): 560-578.

[3] Kline A, Ahner D, Hill R. The weapon-target assignment problem[J]. Computers & Operations Research, 2019, 105: 226-236.

[4] Lai C M, Wu T H. Simplified swarm optimization with initialization scheme for dynamic weapon-target assignment problem[J]. Applied Soft Computing, 2019, 82: 105542.

[5] Xu H, Zhang A, Bi W H, et al. Dynamic Gaussian mutation beetle swarm optimization method for large-scale weapon target assignment problems[J]. Applied Soft Computing, 2024, 162: 111798.

[6] Acar E, Hatipoğlu S, Yılmaz İ. A quantum algorithm for solving weapon target assignment problem[J]. Engineering Applications of Artificial Intelligence, 2023, 125: 106668.

[7] Hughes M S, Lunday B J. The weapon target assignment problem: Rational inference of adversary target utility valuations from observed solutions[J]. Omega, 2022, 107: 102562.

[8] Li W H, Yao X Y, Li K W, et al. Knowledge-guided competitive evolutionary algorithm for multi-solution sensor-weapon-target assignment problem[J]. IEEE Transactions on Evolutionary Computation, DOI: 10.1109/TEVC.2026.3653800.

[9] Wang Z J, Zhan Z H, Lin Y, et al. Automatic niching differential evolution with contour prediction approach for multimodal optimization problems[J]. IEEE Transactions on Evolutionary Computation, 2020, 24(1): 114-128.

[10] 程适, 刘悦, 王雪萍, 等. 改进头脑风暴优化算法求解多模态多目标问题[J]. 华中科技大学学报: 自然科学版, 2024, 52(6): 24-31.
(Cheng S, Liu Y, Wang X P, et al. Improved brain storm optimization algorithm for solving multimodal multiobjective problems[J]. Journal of Huazhong University of Science and Technology: Natural Science Edition, 2024, 52(6): 24-31.)

[11] 段鑫绘, 江巧永, 林艳艳, 等. 排斥机制驱动的不平衡多模态多目标进化算法[J]. 控制与决策, 2026, 41(8): 2215-2228.
(Duan X H, Jiang Q Y, Lin Y Y, et al. Imbalanced multi-modal multi-objective evolutionary algorithm driven by exclusion mechanism[J]. Control and Decision, 2026, 41(8): 2215-2228.)

[12] 李文桦, 明梦君, 张涛, 等. 考虑全局和局部帕累托前沿的多模态多目标优化算法[J]. 自动化学报, 2023, 49(1): 148-160.
(Li W H, Ming M J, Zhang T, et al. Multimodal multi-objective evolutionary algorithm considering global and local Pareto fronts[J]. Acta Automatica Sinica, 2023, 49(1): 148-160.)

[13] Bian Q, Nener B, Wang J P, et al. A fitness sharing based ant clustering method for multimodal optimization of the aircraft longitudinal automatic carrier landing system[J]. Aerospace Science and Technology, 2022, 122: 107392.

[14] Wang W L, Li G Q, Wang Y L, et al. Clearing-based multimodal multi-objective evolutionary optimization with layer-to-layer strategy[J]. Swarm and Evolutionary Computation, 2022, 68: 100976.

[15] Lin H Y, Liang J, Yue C T, et al. A similar-niching-based differential evolution for constrained multimodal multiobjective optimization[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2025, 55(10): 6710-6722.

[16] Jiang Y, Zhan Z H, Tan K C, et al. Optimizing niche center for multimodal optimization problems[J]. IEEE Transactions on Cybernetics, 2023, 53(4): 2544-2557.

[17] 白臻祖, 侯一帜, 何章鸣, 等. 考虑随机扰动的动态武器目标分配优化[J]. 系统仿真学报, 2025, 37(12): 2967-2980.
(Bai Z Z, Hou Y Z, He Z M, et al. Optimization of dynamic weapon target assignment considering random disturbances[J]. Journal of System Simulation, 2025, 37(12): 2967-2980.)

[18] Reza M K, Prater-Bennette A, Asif M S. Robust multimodal learning with missing modalities via parameter-efficient adaptation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(2): 742-754.

[19] 徐标, 吕修豪, 李文姬, 等. 基于多场景建模的动态鲁棒多目标进化优化算法[J]. 控制与决策, 2024, 39(12): 3997-4006.
(Xu B, Lv X H, Li W J, et al. Dynamic robust multi-objective evolutionary optimization algorithm based on multi-scenario modeling[J]. Control and Decision, 2024, 39(12): 3997-4006.)

[20] Jeong S K, Uhm H S, Lee Y H. Rolling-horizon scheduling algorithm for dynamic weapon-target assignment in air defense engagement[J]. Journal of the

Korean Institute of Industrial Engineers, 2020, 46(1): 11-24.

[21] 韩松臣, 秦俊奇, 韩品尧, 等. 马尔可夫决策过程在目标分配中的应用[J]. 哈尔滨工业大学学报, 1996(2): 32-36.
(Han S C, Qin J Q, Han P Y, et al. An application of the Markov decision process to target assignment[J]. Journal of Harbin Institute of Technology, 1996(2): 32-36.)

[22] 刘传波, 邱志明, 吴玲, 等. 动态武器目标分配问题的研究现状与展望[J]. 电光与控制, 2010, 17(11): 43-48.
(Liu C B, Qiu Z M, Wu L, et al. Review on current status and prospect of researches on dynamic weapon target assignment[J]. Electronics Optics & Control, 2010, 17(11): 43-48.)

[23] Tashakori S, Ranjbar M, Balochian S, et al. Dynamic soft-kill weapon-target assignment in naval environments[J]. Computers & Industrial Engineering, 2024, 197: 110606.

[24] Liu C, Li J, Wang Y, et al. A time-driven dynamic weapon target assignment method[J]. IEEE Access, 2023, 11: 129623-129639.

[25] 王晴, 王浩然, 辛斌, 等. 基于近端策略优化的动态武器目标分配[J]. 控制与决策, 2026, 41(4): 919-930.
(Wang Q, Wang H R, Xin B, et al. Dynamic weapon-target assignment based on proximal policy optimization[J]. Control and Decision, 2026, 41(4): 919-930.)

[26] Chang T Q, Kong D P, Hao N, et al. Solving the dynamic weapon target assignment problem by an improved artificial bee colony algorithm with heuristic factor initialization[J]. Applied Soft Computing, 2018, 70: 845-863.

[27] 王洲强, 陈万春, 陈中原. 基于双层自适应 MOEA/D 的多阶段武器目标分配方法[J]. 战术导弹技术, 2022(4): 113-123.
(Wang Z Q, Chen W C, Chen Z Y. Multi-stage weapon target assignment method based on two-layer adaptive MOEA/D[J]. Tactical Missile Technology, 2022(4): 113-123.)

[28] 张丽园, 刘建昌, 刘圆超, 等. 基于自适应响应选择的动态多目标进化算法[J]. 控制与决策, 2025, 40(12): 3689-3703.
(Zhang L Y, Liu J C, Liu Y C, et al. A dynamic multi-objective optimization algorithm based on adaptive response selection[J]. Control and Decision, 2025, 40(12): 3689-3703.)

[29] 范勤勤, 李盟, 黄文焘, 等. 时空视角下的动态多目标进化算法研究综述[J]. 控制与决策, 2024, 39(1): 1-16.
(Fan Q Q, Li M, Huang W T, et al. A research survey of dynamic multi-objective evolutionary algorithms from spatiotemporal perspective[J]. Control and Decision, 2024, 39(1): 1-16.)

[30] Li W H, Wang R, Heng Y, et al. Knowledge-guided evolutionary optimization for large-scale air defense resource allocation[J]. IEEE Transactions on Artificial Intelligence, 2024, 5(12): 6267-6279.

[31] 闫李, 马佳慧, 柴旭朝, 等. 基于知识引导的自适应动态多模态差分进化算法[J]. 控制与决策, 2023, 38(11): 3048-3056.
(Yan L, Ma J H, Chai X Z, et al. Adaptive dynamic multimodal differential evolution algorithm based on knowledge guidance[J]. Control and Decision, 2023, 38(11): 3048-3056.)

作者简介

姚兴懿 (1994−), 女, 博士在读, 主要研究方向为智能优化、多模态优化、鲁棒优化等, E-mail: 781402238@qq.com;

李文桦 (1995−), 男, 副教授, 博士/硕导, 主要研究方向为进化算法、人工智能等, E-mail: liwenhua1030@aliyun.com;

李水佳 (1995−), 男, 副教授, 博士, 主要研究方向为进化算法、多任务优化等, E-mail: lisj@nudt.edu.cn;

王锐 (1986−), 男, 教授, 博导, 主要研究方向为多目标优化、机器学习等, E-mail: ruiwangnudt@gmail.com;

张涛 (1976−), 男, 教授, 博导, 主要研究方向为能源互联网、鲁棒优化等, E-mail: zhangtao@nudt.edu.cn.