

基于生成式知识迁移的多飞行器多目标任务分配

李猛¹, 果昊涵², 黄虎², 韩治国¹

(1. 西北工业大学 航天学院, 西安 710072)

(2. 中国运载火箭技术研究院 研究发展中心, 北京 100006)

摘要: 多飞行器多目标任务分配存在环境不确定性和任务高动态变化性, 导致传统算法分配结果的有效性和实时性难以保障。本文考虑飞行器位置、速度信息以及目标价值信息, 构建多飞行器多目标任务分配模型, 研究基于生成式知识迁移的任务分配算法, 引入生成式网络生成分配方案, 通过 Gumbel-Softmax 实现可微化处理, 解决离散分配方案难以梯度反向传播的问题; 为说明本文分配算法的有效性和实时性, 与传统智能算法在静态和动态两类场景进行对比仿真验证。结果表明: 分配算法提升了任务分配有效性和实时性, 可为多飞行器多目标任务分配方法提供参考。

关键词: 多飞行器多目标任务分配; 生成式知识迁移; 生成对抗网络

中图分类号: V249

文献标识码: A

Multi-vehicle multi-target task assignment based on generative knowledge transfer

LI Meng¹, GUO Haohan², HUANG Hu², HAN Zhiguo¹

(1. School of Astronautics, Northwestern Polytechnical University, Xi'an 710072, China)

(2. Research and Development Center, China Academy of Launch Vehicle Technology, Beijing 100006, China)

Abstract: Aiming at the problems of environmental uncertainty and high dynamic task variation in multi-vehicle multi-target assignment, traditional algorithms struggle to guarantee the effectiveness and real-time performance of allocation results. This paper constructs a multi-vehicle multi-target assignment model by considering the position and velocity information of vehicles as well as target value information. A task allocation algorithm based on generative knowledge transfer is studied; a generative network is introduced to generate allocation schemes, and the Gumbel-Softmax technique is adopted to achieve differentiable processing for discrete task selection, thereby solving the problem that discrete assignment schemes are not amenable to gradient backpropagation. To verify the effectiveness of the proposed algorithm, comparative simulations with traditional intelligent algorithms are conducted in both static and dynamic scenarios. The results show that the proposed algorithm can effectively improve the real-time performance and effectiveness of assignment, which can provide a valuable reference for the research and development of multi-vehicle multi-target assignment in high-dynamic scenarios.

Key words: multi-vehicle multi-target task assignment; generative knowledge transfer; generative adversarial network

收稿日期: 2026-04-02; 修回日期: 2026-07-27

基金项目: 空基信息感知与融合全国重点实验室和航空科学基金(202468, ASFC-20240001053003, ASFC-20230001053004, ASFC-20220001053001); 空基信息感知与融合全国重点实验室和航空科学基金(202468, ASFC-20240001053003, ASFC-20230001053004, ASFC-20220001053001)

通信作者: 黄虎(1986—), 男, 硕士, 研究员。E-mail: huanghu7@126.com

引用格式: 李猛, 果昊涵, 黄虎, 等. 基于生成式知识迁移的多飞行器多目标任务分配[J]. 航空工程进展.

LI Meng, GUO Haohan, HUANG Hu, et al. Multi-vehicle multi-target task assignment based on generative knowledge transfer [J]. Advances in Aeronautical Science and Engineering. (in Chinese)

0 引言

在军事应用领域,组合优化方法得到了广泛的应用,如战场医疗调度、通信结构优化及任务分配等等^[1-3]。其中多飞行器多目标任务分配属于组合优化问题,需要找出满足约束条件,同时最大化毁伤效果或者最小化弹药损失等的分配方案。任务分配可分为静态任务分配和动态任务分配,静态任务分配指的是一次分配,不涉及时间维度,动态分配指的是根据前一次的分配结果,一段时间后再次分配,可以说动态任务分配是多次静态任务分配的组合^[4]。在动态任务分配中,由于飞行器飞行过程中存在目标消失、飞行器被拦截等情况,需要对分配方案进行调整,以适应新的场景,同时需要满足有效性和实时性。目前有很多种求解目标分配问题的传统算法,能够精确或近似求解最佳分配方案,但对于规模大的场景实时性较差。而智能算法凭借其灵活性和良好的全局寻优能力,在近年来的研究中获得广泛关注^[5-6]。

当前普遍应用的智能算法有基于贪心算法、遗传算法、粒子群算法、蚁群优化算法等的种群优化算法^[7-9]以及基于强化学习的算法等。

傅勉等^[10]融合了贪心思想和模拟退火算法,但是贪心策略的引入容易陷入局部最优,且算法串行执行结构导致收敛速度较慢,难以适应战场态势快速变化的动态环境;常雪凝等^[11]设计了一种集成匈牙利和模拟退火的混合智能搜索算法,通过启发式算法和精确求解技术的结合,在保证求解质量的前提下,极大减少了计算时间,但匈牙利算法要求拦截器和目标数量相等,难以适应动态不对称作战场景;李世旺等^[12]通过对量子编码分布概率上下界进行动态约束调整来提高算法寻优效率,但是量子遗传算法参数设置复杂,量子旋转门更新机制计算开销较大;翁年凤等^[13]提出了一种基于蚁群算法的优化方法,提升了初始种群的多样性和算法的多样性,但未明确给出算法的时间复杂度分析,实时性难以保证;邱少明^[14]研究了基于改进粒子群优化-深度Q网络(PSO-DQN)的动态火力分配方法,利用改进粒子群算法求解纳什均衡提升结果质量,但是在突发态势下的方案不够合理;李洋等^[15]设计一种基于随机动态规划的动态武器目标分配决策算法,但动态规划存在“维度灾难”问题,对于不同规模武器目标分配

问题,计算复杂度随问题规模指数增长,难以满足实时性要求。

SONUC等^[16]提出了一种并行的模拟退火算法来提高算法的运行时间和求解质量,但运行时间仍在10 s以上;Durgut等人^[17]研究了基于人工蜂群算法的武器目标分配问题,探讨了三种局部搜索算子的效果,但是算法对于大规模武器目标分配问题的全局寻优能力有限,且未考虑动态战场环境下的实时调整需求;Zheng等^[18]建立了空战威胁指标评价模型,利用改进的遗传算法来解决目标分配问题;Li等^[19]提出了一种高效的分布式目标分配算法,显著提高了目标分配的效率,但测试结果局限于二对二、四对四等小规模的对战环境。

综上所述,当前运用的任务分配算法大多数虽然在求解质量上得到了提升,但是在实时性上会达不到要求,应对动态突发环境方案有效性不足。为了提高目标分配算法的实时性和在动态环境下的有效性,本文提出一种基于生成式知识迁移的任务分配算法。生成式知识迁移通过学习目标分配的联合概率分布,精准捕捉目标间的复杂联系(如资源竞争、任务协同等);其强大的生成能力,使得在面对未出现的分配环境时可以得出合理的方案。

1 任务分配模型构建

针对所研究的多飞行器多目标的任务分配问题,构建任务分配模型。

设飞行器数目为 m ,目标数目为 n ,分配方案是一个0/1矩阵 T ,例如4飞行器-4目标为

$$T = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

在训练过程中,根据某典型工程项目给定的任务分配场景最大规模约束,将飞行器数目最大值设为12,目标数目最大值设为8,该数值可根据实际研究情况进行调整,任务分配模型如图1所示。对分配矩阵进行扩展为12×8,对于不存在的飞行器矩阵对应位置设为0,4飞行器-4目标的扩展分配方案如下:

$$T_{12 \times 8} = \begin{bmatrix} 0 & 0 & 0 & 1 & \cdots & 0 \\ 0 & 1 & 0 & 0 & \cdots & 0 \\ 1 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 0 & 1 & 0 & \cdots & 0 \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ 0 & 0 & 0 & 0 & \cdots & 0 \end{bmatrix}$$

计算过程中采用掩码来区分飞行器目标是否存在,飞行器掩码为 1×12 的向量,目标为 1×8 的向量。




图1 任务分配模型图

Fig. 1 Task allocation model diagram

采用优势度评价指标来评价分配方案的好坏,评价指标的计算数据包括目标的位置、目标的综合价值、飞行器的位置和飞行器的速度等。优势度指标的计算可分为以下3个部分:距离优势度、速度优势度、价值优势度。其中距离优势度用于量化飞行器与目标之间的空间匹配程度,速度优势度用于反映飞行器的机动能力,价值优势度用于衡量目标的打击收益。三者共同构成多飞行器多目标任务分配的评价指标。

1) 距离优势度

$$a_1 = e^{-\frac{d}{\max D}} \quad (1)$$

式中: D 为所有飞行器到所有目标的距离; d 为单个飞行器到目标的距离,计算得到的是一个归一化的优势度矩阵,大小为 12×8 。

2) 速度优势度

$$a_2 = e^{\frac{v}{\max V} - 1} \quad (2)$$

式中: V 为所有飞行器到所有目标的速度; v 为单个飞行器的速度大小,计算出来的同样是一个 12×8 的优势度矩阵。

3) 价值优势度

$$a_3 = \frac{j}{\max J} \quad (3)$$

式中: J 为所有目标的综合价值,融合了目标的军事价值、政治价值等信息; j 为单个目标的价值,计算得到一个优势度向量。

评价指标的综合计算如下:

$$a = \omega_1 a_1 + \omega_2 a_2 + \omega_3 a_3 \quad (4)$$

式中: ω_1 、 ω_2 、 ω_3 为权重,权重可根据实际需求进行修正,本文选取权重取值根据工程项目层次分析法专家评审标定,最终取值选择为(0.3, 0.4, 0.3),优先考虑飞行器机动能力,兼顾空间匹配性与作战收益最大化。

每一个飞行器对于每一个目标都会计算出一个优势度值,组合成优势度矩阵 A ,形状与分配矩阵一致。

对于多飞行器多目标任务分配,为了实现分配合理性,设定任务约束条件:

1) 覆盖约束,每一个目标至少分配一个飞行器,即对于目标 j

$$\sum_{i=1}^m T_{i,j} \geq 1 \quad (5)$$

式中: T 为分配矩阵。

2) 密集约束,为了防止飞行器过度集中于优势度最大的目标,当一个目标分配飞行器数目大于1时,会有50%优势度衰减,衰减因子计算为:

$$m_j = \sum_{i=1}^m T_{i,j} \quad (6)$$

$$\eta_j = 0.5^{\max(m_j - 1, 0)} \quad (7)$$

最终评价指标计算:

$$s = \sum_{i=1}^m \sum_{j=1}^n T_{i,j} \cdot A_{i,j} \cdot \eta_j \quad (8)$$

式中: A 为优势度矩阵。

2 生成式知识迁移

2.1 生成对抗网络

生成式知识迁移是一种能够从训练数据中学习数据潜在分布的,进而生成与原数据分布类似的机器学习算法,训练好之后使用时可以直接通过生成器生成方案,能达到快速性的要求。

生成对抗网络(GAN)最早由Goodfellow^[20]于2014年提出,其核心思想就是博弈论中的“对抗学

习”,网络由生成器(Generator)和判别器(Discriminator)两个网络组成。生成器通过噪声生成伪造数据,而判别器负责区分真实数据和伪造数据。二者进行对抗博弈,最终使生成器能够生成逼真的样本,对应到任务分配中,生成器通过学习真实数据(专家知识,Expert Knowledge)中分配方案的潜在分布,将学到的知识迁移到新环境中,使得能够生成符合约束的合理方案。

GAN的训练是一个对抗博弈的过程:生成器通过噪声生成伪造数据,并将其输入判别器;判别器对伪造数据和真实数据进行判断,输出判别值;根据判别器的输出结果,更新判别器,再通过判别器知识迁移更新生成器,以提高各自的性能。

GAN流程如图2所示。




图2 GAN流程图

Fig. 2 Flowchart of the GAN

本文所用的生成器网络的输入是目标分配环境所计算出的优势度矩阵,输出目标分配概率矩阵。生成器的结构由4层全连接层以及激活函数等组成:

- 1) 输入为96+48维,优势度矩阵展平96维和噪声48维拼接,输出512维;
- 2) 输入512维,输出512维;
- 3) 输入512维,输出256维;
- 4) 输入256维,输出96维。

其中噪声维度的选取经过候选值24、48、96训练测试,当维度过小时会导致生成器生成方案陷入过拟合,维度过高会导致生成的方案随机性强,与环境不匹配,方案质量差,所以最终选取48作为生成器的噪声维度。

判别器网络的输入是环境优势度矩阵和分配矩阵,输出是一个值,该值代表了对应环境下分配矩阵的好坏。判别器结构如下:

- 1) 输入96+96维,优势度矩阵展平96维和分配矩阵展平96维拼接,输出256维;
- 2) 输入256维,输出128维;
- 3) 输入128维,输出1维。

2.2 Gumbel-Softmax离散化

由于目标分配最终所需的分配方案需要0/1的分配值,而不是生成器输出的概率矩阵,引入了Gumbel-Softmax离散化方法,在对生成器输出进行离散化操作的同时保留反向传播的梯度。

Gumbel分布是极值分布的一种,其概率密度函数(PDF)为

$$f_G(g; \mu) = \exp(-(g - \mu) - \exp(-(g - \mu))) \quad (9)$$

式中: μ 为位置参数。

通过逆变换采样,可从均匀分布 $U(0, 1)$ 生成Gumbel噪声:

$$B_i = -\log(-\log(U_i)), U_i \sim U(0, 1) \quad (10)$$

Gumbel-Max技巧利用这一特性,将离散采样转化为带噪声的argmax操作:

$$z = \arg \max_i (\log \pi_i + B_i) \quad (11)$$

式中: π_i 为类别概率。此时,采样结果 z 的分布与原类别分布一致。

为实现可微性,Gumbel Softmax用Softmax函数替代argmax,引入温度参数 τ 控制分布的平滑度:

$$y_i = \frac{\exp((\log \pi_i + B_i)/\tau)}{\sum_{j=1}^K \exp((\log \pi_j + B_j)/\tau)} \quad (12)$$

当 $\tau \rightarrow 0$ 时, y_i 趋近于one-hot向量,近似原始离散采样;当 $\tau \rightarrow \infty$ 时,分布趋于均匀,梯度更平滑。该过程可视为对离散分布的连续松弛,使得梯度 y_i 可通过反向传播至参数 π_i 。

为了确保探索性采样,在训练初期可以采用较高的温度(如 $\tau = 1.0$),随着训练推进逐渐降低温度,使采样结果逼近真实离散分布,本文采用的策略为线性下降,最低值为0.2。

2.3 损失函数设计

损失函数的设计分为两个部分。

1) GAN损失

生成器损失:最大化伪造数据的得分值。

$$\mathcal{L}_G = -E_{z \sim P_z} [D(G(z))] \quad (13)$$

式中: $G(z)$ 为生成器函数; $D(\bullet)$ 为判别器函数; E 为求期望; P_z 为隐变量分布,在此指生成器输入分布。

判别器损失:最大化真实数据和伪造数据得分差值。

$$\mathcal{L}_d = -(E_{x \sim P_r}[D(x)] - E_{z \sim P_z}[D(G(z))]) \quad (14)$$

式中: P_r 为真实数据分布。

2) 目标分配优势度约束损失以及覆盖约束损失

目标分配优势度约束损失:

$$\mathcal{L}_1 = -s \quad (15)$$

式中: s 为优势度得分。

覆盖约束损失:

$$y_j = \sum_{i=1}^m T_{i,j} \quad (16)$$

$$c_j = \max(1 - y_j, 0) \quad \forall j \in \{1, 2, \dots, N\} \quad (17)$$

引入二进制掩码 $\mathbf{M} \in \{0, 1\}^N$, $M_i = 1$ 表示第 i 个目标为有效目标), 最终的覆盖约束损失计算如下:

$$\mathcal{L}_2 = \frac{\sum_{i=1}^N (c_i \cdot M_i)}{\sum_{i=1}^N M_i} \quad (18)$$

3) 生成器综合损失函数

综合 GAN 损失、优势度损失和覆盖约束损失, 生成器综合损失函数设计为

$$L_g = \mathcal{L}_g + \beta_1 \times \mathcal{L}_1 + \beta_2 \times \mathcal{L}_2 \quad (19)$$

式中: β_1, β_2 分别为优势度损失和覆盖约束损失系数。

2.4 算法流程

算法训练流程如图 3 所示。




图 3 算法流程图

Fig. 3 Flowchart of the algorithm

1) 网络初始化: 对生成器和判别器参数进行随机初始化;

2) 加载训练数据集, 进行预处理, 计算出每一个场景下的优势度矩阵;

3) 判别器训练, 输入真实数据和伪造数据, 进行评估训练;

4) 生成器训练, 输入优势度矩阵和噪声, 使用判别器进行评估, 并通过知识迁移更新生成器;

5) 重复步骤 3) 和步骤 4), 直到满足要求。

3 实验设计及结果分析

3.1 生成对抗网络(GAN)训练过程

在训练阶段, 获取的数据集大小为 10 000 个场景分配方案(专家知识), 里面包含了不同场景下目标个数、目标位置、目标价值、飞行器个数、飞行器位置、飞行器速度以及分配的最佳矩阵。数据集参数如表 1 所示。

表 1 训练数据集参数
Table 1 Parameters of the training dataset

参数	飞行器	目标
经度/(°)	100~120	125~145
纬度/(°)	20~30	20~35
海平面高度/m	200~1 500	0
速度/(m·s ⁻¹)	300~1 200	—
价值	—	0~1

网络的训练参数如表 2 所示。

表 2 网络训练参数
Table 2 Network training parameters

参数	数值
生成器学习率	0.000 2
判别器学习率	0.000 1
批次数量	64
潜在空间维度	48
梯度惩罚系数	15

优势度损失系数和约束损失系数候选值有 (5, 30)、(15, 15)、(30, 5)、(60, 5), 分别进行训练, 训练完成之后的优势度损失函数和约束损失函数变化图如图 4~图 5 所示。




图4 优势度损失函数变化图

Fig. 4 Variation of advantage loss function




图5 覆盖损失函数变化图

Fig. 5 Variation of coverage loss function

从损图4~图5可以看出:4种组合在接近40回合时优势度损失和覆盖损失已经接近收敛,同时,当优势度损失系数相比覆盖损失系数越大,最后达到的优势度效果越好,但会牺牲覆盖约束条件,经过权衡,选取参数为(30,5)的组合进行场景实验。

3.2 静态场景实验

接下来对多飞行器多目标分配任务进行静态场景实验,随机生成100组场景的数据,将GAN算法与遗传算法、贪心算法生成的方案优势度得分分别进行对比,对比结果如图6~图7所示。




图6 GAN与遗传算法优势度对比图

Fig. 6 Comparison of advantage degree between GAN and genetic algorithm




图7 GAN与贪心算法优势度对比图

Fig. 7 Comparison of advantage degree between GAN and greedy algorithm

在图6中在76/100个场景下GAN生成的方案优势度得分大于遗传算法,图7中100/100个场景下GAN生成的方案优势度得分大于贪心算法。

运行时间方面,GAN算法平均分配时间为27.1 ms,遗传算法为332.4 ms,贪心算法为0.3 ms。贪心算法的运行时间很快,但由于贪心策略只考虑了每一步最优的选择,容易陷入局部最优,导致优势度计算得分普遍低于GAN算法和遗传算法;相比于遗传算法,GAN在大大降低计算时间的情况下,小幅度提升了优势度得分,使得分配方案更加合理,效果更优,实时性更好。

3.3 动态场景实验

为进行动态分析,设计一系列动态场景,其中某一场景数据如表3~表4所示。


表3 飞行器场景数据
Table 3 Vehicle scenario data

飞行器ID	飞行器位置/(°,°,m)	飞行器速度/(m·s ⁻¹)
1	(102.4, 24.9, 244)	(-542, -886, -413)
2	(106.2, 25.2, 910)	(54, -340, 313)
3	(118.8, 28.9, 977)	(300, 850, -680)
4	(100.9, 23.2, 705)	(-294, 370, 268)
5	(105.6, 25.4, 383)	(799, -66, -633)
6	(115.4, 21.9, 207)	(-128, -971, 330)
7	(115.4, 20.7, 666)	(-243, -238, 218)
8	(106.6, 20.6, 604)	(-359, -421, 209)
9	(117.7, 24.7, 355)	(-800, -324, 375)
10	(115.4, 24.9, 879)	(391, 315, -464)
11	(100.6, 26.4, 608)	(311, 607, 452)
12	(108.2, 27.5, 497)	(184, 296, -119)


表4 目标场景数据
Table 4 Target scenario data

目标 ID	目标位置/(°,°,m)	目标价值(归一化)
1	(132.5, 34.3, 0)	0.732
2	(128.1, 20.9, 0)	0.866
3	(125.4, 34.5, 0)	0.832
4	(128.6, 24.6, 0)	0.524
5	(137.2, 22.1, 0)	0.292
6	(140.7, 23.0, 0)	0.514
7	(137.2, 22.6, 0)	0.065
8	(141.2, 24.6, 0)	0.097


在此基础上先进行静态分配,得到初始分配结果,然后进行动态调整,飞行器 11 和飞行器 12 以及目标 8 模拟消失,再次进行分配,分配结果如下图 8 所示。



(a) GAN算法初始分配结果




(b) GAN变化场景分配结果




(c) 遗传算法分配结果



(d) 遗传算法变化场景分配结果



(e) 贪心算法分配结果



(f) 贪心算法变化场景分配结果

图8 分配算法变化场景分配结果

Fig. 8 Allocation results of allocation algorithms in changing scenarios

从图8可以看出:遗传算法、贪心算法在飞行器和目标数目发生变化时所导致的新分配方案中飞行器目标分配情况发生了很大变化。对于GAN算法,通过对比场景变化前后分配结果,在飞行器和目标数目发生变化后分配结果变化不大。场景动态变化前后优势度得分通过式(8)进行计算,结果如表5所示。

表5 变化前后优势度得分

Table 5 Advantage degree scores before and after the change

算法	GAN	遗传算法	贪心算法
初始得分	4.43	4.39	4.09
变化后得分	4.03	4.01	3.82

然后通过对不同作战规模下各50个动态案例进行测试对比,结果如表6~表8所示。

表6 8对4动态场景测试结果

Table 6 Test results of 8-to-4 matching in dynamic scenarios

算法	GAN	遗传算法	贪心算法
初始平均得分	2.25	2.24	1.98
变化后平均得分	1.71	1.71	1.57
分配平均变化数	3.3	4.3	2.6

表7 10对6动态场景测试结果

Table 7 Test results of 10-to-6 matching in dynamic scenarios

算法	GAN	遗传算法	贪心算法
初始平均得分	3.34	3.31	3.06
变化后平均得分	2.81	2.79	2.65
分配平均变化数	3.4	6.5	6.6

表8 12对8动态场景测试结果

Table 8 Test results of 12-to-8 matching in dynamic scenarios

算法	GAN	遗传算法	贪心算法
初始平均得分	4.46	4.43	4.18
变化后平均得分	3.93	3.89	3.75
分配平均变化数	4.4	8.6	7.1

从表6~表8可以看出:在动态作战环境下, GAN算法相比遗传算法,在改变较少数飞行器的分配结果的基础上保持了较高的优势度得分;在作战规模为8对4的环境下, GAN的平均变化数虽然大于贪心算法,但优势度得分明显增加,另外在规模为10对6、12对8的环境下平均分配变化数均少于贪心算法,验证了在动态场景该分配算法的有效性。

4 结 论

本文基于飞行器的位置与速度、目标价值等关键信息,在任务分配模型构建的基础上,提出了一种基于生成式知识迁移的任务分配算法。通过随机生成典型应用场景并与遗传算法、贪心算法进行对比实验,结果表明所提算法在优势度得分上显著优于传统智能算法,且计算运行时间较遗传算法大幅缩短。通过动态场景实验验证了所提算法的有效性,适用于动态战场环境。

后续将对本文算法展开更多维度信息融合方

法研究,提出更具工程应用价值的智能任务分配算法。

参考文献

- [1] Rodriguez C A, Jenkins P R, Robbins M J. Solving the joint military medical evacuation problem via a random forest approximate dynamic programming approach [J]. *Expert Systems With Applications*, 2023, 221: 1-11.
- [2] Maheswari U A, Suganthi P. Designing energy-efficient military communication using modified intelligent water drops algorithm on MANETs[J]. *International Journal of Information Technology*, 2023, 15(2): 991-1003.
- [3] 徐庆征, 马依笑, 王娜. 不确定环境下多无人机任务分配[J]. *海军航空大学学报*, 2023, 38(6): 473-482.
Xu Qingzheng, Ma Yixiao, Wang Na. Task Allocation of Multiple UAVs in Uncertain Environment [J]. *Journal of Naval Aviation University*, 2023, 38(6): 473-482. (in Chinese)
- [4] 刘诗瑶, 王明, 张耀, 等. 基于深度强化学习的无人战车多回合火力分配[J]. *火力与指挥控制*, 2023, 48(7): 79-84.
Liu Shiyao, Wang Ming, Zhang Yao, et al. Multi-round Firepower Allocation for Unmanned Combat Vehicles Based on Deep Reinforcement Learning[J]. *Fire Control & Command Control*, 2023, 48(7): 79-84. (in Chinese)
- [5] 赵国亮, 穆培培, 李泽文. 求解静态武器-目标分配问题的混合优化算法[C]//第十三届中国指挥控制大会. 北京: 中国指挥与控制学会, 2025: 74-81.
Zhao Guoliang, Mu Peipei, Li Zewen. Hybrid Optimization Algorithm for Solving Static Weapon-Target Assignment Problem[C]// The 13th China Command and Control Conference. Beijing: Chinese Institute of Command and Control Beijing, 2025: 74-81. (in Chinese)
- [6] 任涛, 吴晶, 易亮, 等. 武器-目标分配问题的智能优化算法研究进展[J]. *计算机仿真*, 2024, 41(12): 1-6, 12.
Ren Tao, Wu Jing, Yi Liang, et al. Research Progress on Intelligent Optimization Algorithms for Weapon-Target Assignment Problem [J]. *Computer Simulation*, 2024, 41(12): 1-6, 12. (in Chinese)
- [7] 王光源, 李浩民, 陈永展, 等. 基于灰狼算法的多平台火力分配优化模型[J]. *科学技术与工程*, 2023, 23(23): 10133-10138.
Wang Guangyuan, Li Haomin, Chen Yongzhan, et al. Optimization model of multi-platform firepower allocation based on grey wolf algorithm[J]. *Science Technology and Engineering*, 2023, 23(23): 10133-10138. (in Chinese)
- [8] 褚凯轩, 常天庆, 张雷. 基于改进人工蜂群算法的地面作战武器-目标分配[J]. *兵工学报*, 2023, 44(7): 2171-2183.
Chu Kaixuan, Chang Tianqing, Zhang Lei. Ground combat weapon-target allocation based on improved artificial bee colony algorithm[J]. *Acta Armamentarii*, 2023, 44(7): 2171-2183. (in Chinese)
- [9] 张杰, 吴曦, 李元龙. 基于改进果蝇优化算法的混合火力分配方法[J]. *火力与指挥控制*, 2023, 48(2): 86-89, 96.
Zhang Jie, Wu Xi, Li Yuanlong. Hybrid firepower allocation method based on improved fruit fly optimization algorithm[J]. *Fire Control & Command Control*, 2023, 48(2): 86-89, 96. (in Chinese)
- [10] 傅勉, 王丹丹. 使用贪心模拟退火算法求解 WTA 问题[J]. *河北北方学院学报(自然科学版)*, 2020, 36(1): 9-12, 36.
Fu Mian, Wang Dandan. Solving the WTA problem using a greedy simulated annealing algorithm[J]. *Journal of Hebei North University (Natural Science Edition)*, 2020, 36(1): 9-12, 36. (in Chinese)
- [11] 常雪凝, 石建迈, 陈超, 等. 基于匈牙利-模拟退火算法的多阶段武器目标分配方法[J]. *系统工程与电子技术*, 2023, 45(11): 3516-3523.
Chang Xuening, Shi Jianmai, Chen Chao, et al. Multi-stage weapon target allocation method based on Hungarian-simulated annealing algorithm[J]. *Systems Engineering and Electronics*, 2023, 45(11): 3516-3523. (in Chinese)
- [12] 李世旺, 杜溢华, 胡珊, 等. 基于改进量子遗传算法的集群空战多目标分配研究[C]//第十三届中国指挥控制大会. 北京: 中国指挥与控制学会, 2025: 274-280.
Li Shiwang, Du Yihua, Hu Shan, et al. Research on multi-target allocation in cluster air combat based on improved quantum genetic algorithm[C]// The 13th China Command and Control Conference. Beijing: Chinese Institute of Command and Control, 2025: 274-280. (in Chinese)
- [13] 翁年凤, 刘艺, 郑奇斌, 等. 基于遗传蚁群算法的武器目标分配优化方法[J]. *海军航空大学学报*, 2024, 39(5): 640-648.
Weng Nianfeng, Liu Yi, Zheng Qibin, et al. Optimization method for weapon-target allocation based on genetic-ant colony algorithm[J]. *Journal of Naval Aviation University*, 2024, 39(5): 640-648. (in Chinese)
- [14] 邱少明, 刘良玉, 黄昕晨, 等. 基于改进 PSO-DQN 的动态火力分配算法[J]. *电光与控制*, 2025, 32(6): 24-30.
Qiu Shaoming, Liu Liangyu, Huang Xinchun, et al. Dynamic firepower allocation method based on improved PSO-DQN[J]. *Electronics Optics & Control*, 2025, 32(6): 24-30. (in Chinese)
- [15] 李洋, 刘耿, 胡晓惠, 等. 基于 SDP 的动态武器目标分配决策算法研究[J]. *航空兵器*, 2023, 30(5): 50-56.
Li Yang, Liu Geng, Hu Xiaohui, et al. Research on dynamic weapon-target assignment decision-making algorithm based on semidefinite programming (SDP)[J]. *Aero Weaponry*, 2023, 30(5): 50-56. (in Chinese)
- [16] Sonuc E, Sen B, Bayir S. A parallel simulated annealing algorithm for weapon-target assignment problem[J]. *International Journal of Advanced Computer Science and Applications*, 2017, 8(4): 1-8.
- [17] Durgut R, Kutucu H, Akleylek S. An artificial bee colony algorithm for solving the weapon target assignment problem [R]. Samsun: Ondokuz Mayıs University, 2017.
- [18] Zheng G, Gang G, Han J G. Research on autonomous decision method of multi-aircraft cooperative mid-range confrontation[C]// Seventh Symposium on Novel Photoelectronic Detection Technology and Applications. Reston: AIAA, 2021: 11763.
- [19] Li W, Lyu Y, Dai S, et al. A multi-target consensus-based auction algorithm for distributed target assignment in cooperative beyond-visual-range air combat[J]. *Aerospace*, 2022, 9: 486.
- [20] Goodfellow I, Pouget-Abadie J, Mirza M, et al. *Generative Adversarial Nets*[M]. New York: MIT Press, 2014.

(编辑:丛艳娟)