考虑双层供应中断的制造企业海外基地采购计划优化

刘瑞琪[1,2]，王国强[1,2†]，王玉琦[1,2]，罗 贺[1,2,3]

(1. 合肥工业大学 管理学院，合肥 230009；2. 过程优化与智能决策教育部重点实验室，合肥 230009；
3. 数据科学与智慧社会治理教育部哲学社会科学实验室，合肥 230009)

摘 要: 供应中断呈现出供应商层面与国家层面并存的双层中断特征, 使得海外基地采购计划在不确定性与风险结构上不同于传统采购问题. 基于上述现实需求, 对考虑双层供应中断的制造企业海外基地采购计划优化问题进行研究, 引入关税、税收政策等国际因素, 以总期望成本最小化为目标, 建立非线性随机规划模型, 并设计一种双深度Q网络引导的改进自适应遗传算法. 所提出算法包含启发式种群初始化方法、基于贪婪的跨周期局部搜索算子、基于双深度Q网络的参数更新机制三种改进机制. 在数值实验中, 与 Gurobi 求解器和其他算法进行对比, 实验结果表明所提出算法在求解质量、稳定性和计算时间方面均具有明显优势. 之后通过消融实验验证了算法中各改进机制的有效性. 同时, 通过案例分析验证了所提出方法在实际采购决策场景中的适用性. 最后, 通过敏感性实验分析税收减免比例的变化对采购成本的影响.

关键词: 海外基地；供应中断；采购计划优化；遗传算法；双深度 Q 网络；参数调优

中图分类号: F272；F273；TP312 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0193

引用格式: 刘瑞琪, 王国强, 王玉琦, 等. 考虑双层供应中断的制造企业海外基地采购计划优化 [J]. 控制与决策.

Optimization of procurement plan for overseas bases of manufacturing enterprises considering double supply disruption

LIU Rui-qi[1,2]，*WANG Guo-qiang*[1,2†]，*WANG Yu-qi*[1,2]，*LUO He*[1,2,3]

(1. School of Management，Hefei University of Technology，Hefei 230009，China；2. Key Laboratory of Process Optimization and Intelligent Decision-Making，Ministry of Education，Hefei 230009，China；3. Laboratory of Data Science and Smart Society Governance of the Ministry of Education，Hefei 230009，China)

Abstract: Supply disruption presents the characteristics of double-layer disruption at the supplier level and the national level, which makes the procurement plan of overseas bases different from the traditional procurement problems in terms of uncertainty and risk structure. Based on the above practical needs. This paper studies the procurement plan optimization of overseas bases of manufacturing enterprises considering two-tier supply disruption, introduces international factors such as tariffs and tax policies, establishes a non-linear stochastic programming model with the objective of minimizing the total expected cost, and designs an improved adaptive genetic algorithm guided by double deep Q-network (DDQN). The algorithm includes three improved mechanisms: heuristic population initialization method, greedy cross periodic local search operator, and parameter update mechanism based on DDQN. In numerical experiments, compared with Gurobi solver and other algorithms, the experimental results show that the algorithm has obvious advantages in solving quality, stability and computing time. The effectiveness of each improved mechanism in the algorithm is verified by the ablation study. At the same time, the applicability of this method in the actual purchase decision scenario is verified by case analysis. Finally, the sensitivity experiment is used to analyze the impact of the change of tax relief ratio on procurement costs.

Keywords: overseas base；supply disruption；optimization of procurement plan；genetic algorithm；double deep Q-network；parameter tuning

0 引 言

随着全球供应链复杂性与不确定性的增强, 制造企业在跨国采购过程中面临两方面的供应链中断风险. 一方面, 供应商可能因设备故障、劳动力短缺

收稿日期: 2026-03-10；**录用日期:** 2026-08-14.
基金项目: 国家重点研发计划项目 (2019YFE0110300)；国家自然科学基金青年项目 (71901086).
责任编委: 唐加福.
†通信作者. E-mail: gqwang2017@hfut.edu.cn.

等局部性事件导致供给中断[1-3]; 另一方面, 地缘政治、自然灾害等国家性冲击可能同时影响同一国家或地区内的多家供应商, 造成系统性供应链中断[4-5]. 而只考虑单一中断风险的采购优化模型难以满足刻画双层供应链中断风险的实际需求[6]. 因此制造企业海外基地在制定采购计划时不仅需要考虑传统采购成本, 还要考虑国家与供应商供给中断的情况. 同时, 在研究跨国采购问题时也需要考虑海外基地所在国家相关政策带来的影响.

许多学者对于多周期、多物料、多供应商环境下的采购计划优化问题开展了系统性研究. Dou 等[7] 构建了包含生产成本、供应中断成本以及供应商可靠性的多目标优化模型, 平衡了成本与风险. Hasani 等[8] 构建了以最小化经济成本、环境影响以及供应中断风险的多目标模型. 董乾东和李敏[9] 则构建了动态采购决策模型, 分析动态供应商选择和采购批量最优决策问题.

在跨国采购的过程中, 外部国际贸易环境与宏观政策同样对采购计划优化产生影响, 部分学者进一步关注关税、税收政策等国际因素对采购计划优化的综合影响. Yilmaz[10] 研究了多国家关税与汇率的变化对采购策略的影响. 蒋媛媛等[11] 的研究强调了税收政策对制造企业海外基地采购计划的影响. 陈志祥等[12] 考虑了汇率、关税等多个国际因素, 构建了利润最大化和交货质量最大化的多目标优化模型. Yang 等[13] 考虑了碳关税、汇率等因素, 通过数学规划分析确定制造商的物料采购策略.

全球供应链中断风险不确定性的增强提高了采购计划制定的复杂度, 相关研究也关注于考虑中断风险的采购计划优化. Fattahi 等[14] 提出一种两阶段随机优化模型, 研究供应链中断情景下的供应链网络设计, 优化订单规模决策. Lee 等[6] 考虑了区域和供应商中断风险, 构建了单周期、单物料条件下的供应商选择和订单分配模型. 伍佳妮和龙燕妮[15] 从供应链韧性视角考虑供应商失效情景, 构建了包含韧性预防、响应和恢复策略的应急物资供应链决策优化模型, 通过多源采购、备用供应商以及供应商产能恢复策略提升供应链应对中断风险的能力. 储开伟和朱建军[3] 研究了二级供应链系统发生中断时, 制造商如何制定采购策略, 并分析了中断概率的大小对采购策略的影响. 当前研究已通过随机优化、鲁棒优化等方法刻画了供应链中断风险. 然而, 将国际因素与供应链中断风险综合考虑的多周期、多物料、多供应商采购优化研究相对不足. 与此同时, 大部分研究仅关注单一层级的中断情形, 未能充分考虑国家中断和供应商个体中断对采购计划的综合影响. 因此, 需要构建更加全面的模型, 提升制造企业在复杂采购环境下的供应链韧性与采购效率.

在模型的求解方法上, 目前启发式算法是求解采购计划优化问题较为常用的方法[16-17], 但其求解效果在很大程度上依赖于超参数的设定. 许多研究通过设计自适应参数机制[18-21], 增强算法的适应能力. 然而, 这些参数调优方法通常受到问题本身差异性和复杂性的限制. 因此, 许多研究将强化学习引入启发式算法中, 根据算法所处状态动态更新超参数. 韩红桂[22] 等人运用 Q 学习在线更新多任务多目标粒子群优化算法的惯性权重、加速度参数和知识迁移率. 张国辉[23] 等人将非支配排序遗传算法 II 与强化学习相结合, 强化学习动态调整交叉变异率. 上述研究表明, 通过强化学习动态调整启发式算法的参数, 有助于增强算法在不同阶段的适应能力, 提高算法性能. 但现有强化学习辅助调参的相关研究多采用 Q 学习机制实现启发式算法参数的在线更新. 相比之下, 双深度 Q 网络能够通过深度网络表现复杂状态, 并通过双网络结构缓解 Q 值高估问题, 有助于提高参数决策的稳定性.

鉴于此, 针对制造企业海外基地在跨国采购中面临的国家和供应商双层中断风险, 本文构建了非线性随机规划模型, 结合国家层级和供应商层级的联合中断概率, 综合考虑跨国采购中关税、税收优惠政策以及紧急采购、现货市场采购等采购渠道. 针对该模型在双层中断情景下呈现出的多周期耦合、可行域复杂等特点, 设计了一种双深度 Q 网络引导的改进自适应遗传算法. 该算法包括启发式种群初始化、跨期局部搜索等改进机制, 并通过双深度 Q 网络动态调整交叉率和变异率. 随后, 通过数值实验验证算法的有效性和性能, 并通过消融实验验证各个改进模块的有效性.

1 问题描述与模型构建

1.1 问题描述

在包括一个制造基地和来自多个国家的供应商的两级供应链内, 制造基地需要从供应商集合中选择供应商, 并进行订单分配, 非制造基地所在国和所有供应商都有中断风险.

本文基于制造企业各时期的物料需求, 综合考虑供应商个体中断与国家中断的双层不确定性, 以及跨国采购中涉及的关税、运输成本、清关费用与税收优惠政策等国际因素, 同时结合正常采购、紧急采购以及现货市场采购三种采购渠道, 以期望综合采购成本最小化为优化目标, 制定面向双层不确定性的多周期采购计划. 问题场景如图 1 所示.

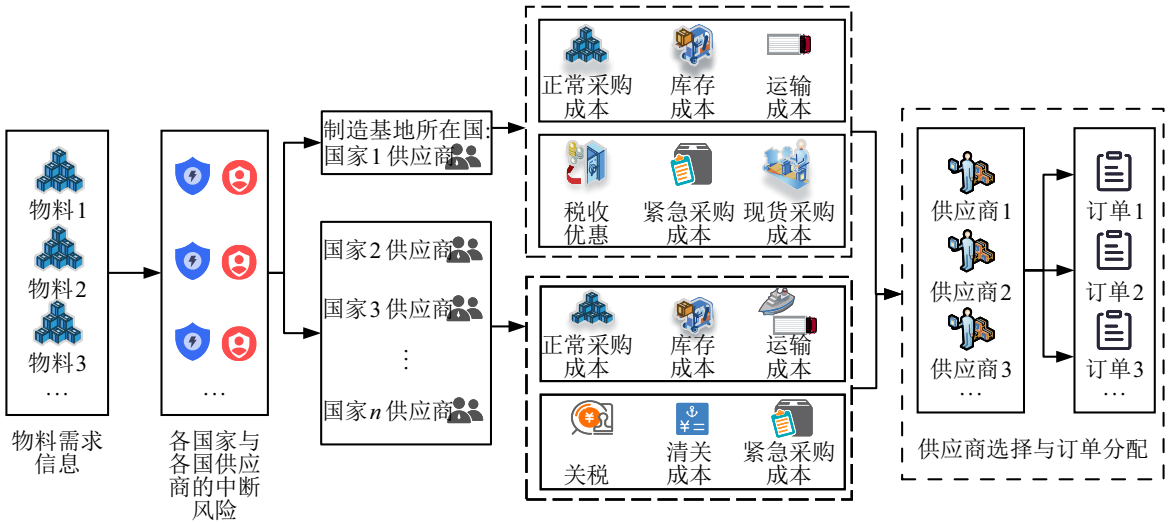

图 1　问题场景示意图

针对本文的问题场景, 提出以下假设:

(1) 参考 Lee 等[6] 国家中断和供应商中断的区分方式, 设定国家中断表示同一国家内所有供应商均无法交付, 而供应商中断仅影响单一供应商. 制造基地所在国不存在国家中断.

(2) 场景发生的概率由国家级中断概率和供应商中断概率联合确定, 所有场景概率之和等于 1.

(3) 在每一时间周期和场景下, 制造企业对各类物料的需求计划由生产消耗量和库存水平共同决定, 若物料上期末库存水平可以满足本期生产消耗的需求, 则本期物料的需求量为 0.

(4) 正常采购单价低于紧急采购单价, 现货市场价格高于正常采购和紧急采购的单价.

1.2　符号体系

具体模型参数和决策变量如表 1 所示.

表 1　模型参数和决策变量设置

符号	含义
参数:	
i	供应商序号, $i \in \{1,2,3,\ldots,I\}$
n	国家序号, $n \in \{1,2,3,\ldots,N\}$, $n=1$表示制造基地所在国
$n(i)$	供应商i所属的国家的编号, $n \in \{1,2,3,\ldots,N\}$
δ_i	若供应商i所属国家为非制造基地所在国, 即$n(i) \neq 1$, 则$\delta_i = 1$, 否则$\delta_i = 0$
j	物料种类序号, $j \in \{1,2,3,\ldots,J\}$
t	时间周期序号, $t \in \{1,2,3,\ldots,T\}$(以月为单位进行编号)
s	场景序号, $s \in \{1,2,3,\ldots,S\}$
p_{ij}^t	在时间周期t时无折扣条件下从供应商i订购物料j的价格
r_{ij}^t	在时间周期t时从供应商i购买物料j达到定额要求时的价格折扣率
z_{ij}^t	在时间周期t时从供应商i购买物料j的折扣阈值
$cts_{n(i)j}^t$	在时间周期t时从供应商i所在国家n运输物料j的单位陆运成本

表 1 (续)

符号	含义
$ctl_{n(i)j}^t$	在时间周期t时从供应商i所在国家n运输物料j的单位海运成本
$Spot_j^t$	在时间周期t时从现货市场采购的物料j的数量.
a_{ij}^t	在时间周期t时从供应商i紧急采购物料j的价格
H_j	在时间周期t时从现货市场采购物料j的单位成本
α	保险费率
TR_j	海外基地当地国对进口物料j所征收的关税税率
σ	码头费率
μ	采购物料的外贸系统费
per	可享受税收减免的总得分
γ	税收减免比例
g_j	物料j的税收优惠分数
K_j	物料j可计算税收优惠分数的采购比例
h_j	物料j的周期单位库存成本
$\overline{w}_i^{ts}$	在时间周期t时、场景s下第i个供应商在供应物料时的自然状态. 如果第i个供应商中断, 则$\overline{w}_i^{ts}=0$; 否则$\overline{w}_i^{ts}=1$.
w_i^{ts}	在时间周期t时、场景s下第i个供应商在供应物料时的最终状态. 如果第i个供应商所属国家n发生中断, 则$w_i^{ts}=0$; 否则$w_i^{ts}=1$.
P_s^t	在时间周期t时场景s发生的概率
ϕ_i^t	在时间周期t时供应商i的中断概率
β_n^t	在时间周期t时国家n的中断概率
S_{ij}^t	在时间周期t时供应商i针对物料j的最大供应数量
π_n^{ts}	在时间周期t时、场景s下第n个国家的中断状态. 如果第n个国家中断, 则$\pi_n^{ts}=0$; 否则$\pi_n^{ts}=1$.
D_j^{ts}	在时间周期t时制造商对物料j的需求量
G_j^t	在时间周期t时, 场景s下物料j的消耗量
I_{js}^t	在时间周期t末, 场景s下物料j的库存量
θ	供应商可提供额外应急供货能力不超过常规供货能力的θ倍
决策变量:	
Q_{ij}^t	在时间周期t时从供应商i处正常采购物料j的数量
e_{ij}^t	在时间周期t时从第i个供应商紧急采购的物料j的数量

1.3 模型构建

1.3.1 目标函数

基于 Mahapatra 等[24] 的研究, 采用决策树方法对供应中断风险进行建模, 将供应中断状态表示为若干场景, 并根据各节点状态的发生概率计算对应场景概率. 如图 2 所示, 以两个国家、五个供应商为例, 国家 1 为制造基地所在国, 供应商 1、2、3 隶属于国家 1; 供应商 4、5 隶属于国家 2. 制造基地所在国不发生国家中断, 其供应商的最终状态仅由供应商中断状态决定; 而国家 2 可能发生国家中断, 其供应商的最终供货状态同时受到国家状态和供应商状态的影响.

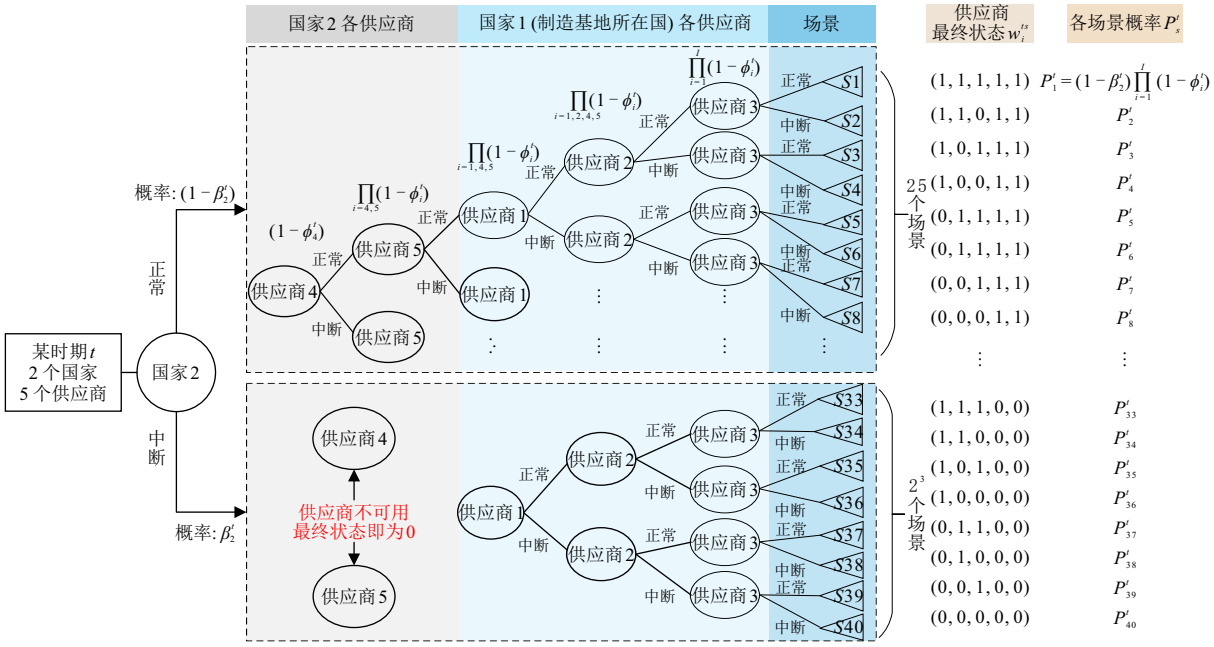

图 2 双层中断场景生成示意图

当国家 2 处于正常状态时, 每个供应商均存在正常与中断两种可能, 因此可形成 2^5 个场景; 当国家 2 处于中断状态时, 供应商 4 和供应商 5 受国家 2 影响, 其最终供货状态为不可用 ($w_i^{ts}=0$); 此时仅需考虑供应商 1、2、3 中断的可能性, 因此形成 2^3 个场景. 由此, 共形成 40 个场景.

因此, 对于 N 个国家, I 个供应商而言, 场景总数计算如下文式 (1) 所示. 制造基地所在国不存在国家供应中断, 如下文式 (2) 所示.

$$S=2^{|\{i|n(i)=1\}|}\prod_{n=2}^{N}(1+2^{|\{i|n(i)=n\}|}), \tag{1}$$

$$\beta_n^t=0,\ if\ n=1. \tag{2}$$

只有当供应商所属国家正常且供应商自身正常时, 该供应商才可提供物料. 供应商最终状态为

$$w_i^{ts}=\pi_n^{ts}\overline{w}_i^{ts}. \tag{3}$$

在得到各场景下国家状态和供应商最终供货状态后, 进一步根据国家中断概率 β_n^t 和供应商中断概率 ϕ_i^t 计算场景 s 在周期 t 的发生概率, 所有场景概率之和为 1, 如下所示:

$$P_s^t=\prod_{n=1}^{N}[(1-\beta_n^t)^{\pi_n^{ts}}\beta_n^{t\,(1-\pi_n^{ts})}]\cdot \prod_{i=1}^{I}[(1-\phi_i^t)^{\overline{w}_i^{ts}}\phi_i^{t\,(1-\overline{w}_i^{ts})}]^{w_i^{ts}}. \tag{4}$$

将每个场景发生的概率作为权重, 以此计算总期望成本, 包括正常采购成本、紧急采购成本、现货市场采购成本、运输成本、关税、海关清关费用、库存成本以及税收优惠, 目标函数为

$$\mathrm{Min}TC=\sum_{s=1}^{S}\sum_{t=1}^{T}P_s^t(f_1^{ts}+f_2^{ts}+f_3^{ts}+f_4^{ts}+ f_5^{ts}+f_6^{ts}+f_7^{ts})-f_8. \tag{5}$$

(1) 正常采购成本: 指在正常供应的条件下, 向各供应商采购物料所产生的成本. 其计算公式如下所示:

$$f_1^{ts}=\begin{cases}\sum_{i=1}^{I}\sum_{j=1}^{J}P_{ij}^tQ_{ij}^tw_i^{ts},\ if\ Q_{ij}^t<z_{ij}\\ \sum_{i=1}^{I}\sum_{j=1}^{J}P_{ij}^tr_{ij}^tQ_{ij}^tw_i^{ts},\ if\ Q_{ij}^t\geqslant z_{ij}\end{cases} \tag{6}$$

当采购量达到折扣阈值时, 单位采购价格按照折扣后的价格计算.

(2) 紧急采购成本: 是指制造企业为弥补正常采

购不足而从未发生中断的供应商处额外采购物料所产生的成本. 其计算公式为

$$f_2^{ts}=\sum_{t=1}^{T}\sum_{j=1}^{J}(\sum_{i=1}^{I}a_{ij}^{t}e_{ij}^{t}w_i^{ts}). \tag{7}$$

(3) 现货市场采购成本: 是指当正常采购和紧急采购都无法满足物料需求时, 通过现货市场采购物料产生的成本. 其中, 现货市场采购量由实际缺货量确定, 实际缺货量由物料需求量、本期采购量决定, 物料需求量由计划生产消耗量和上期末库存水平共同决定, 如下所示:

$$f_3^{ts}=\sum_{j=1}^{J}\sum_{t=1}^{T}H_jSpot_j^t, \tag{8}$$

$$Spot_j^t=max\{0,D_j^{ts}-\sum_{i=1}^{I}w_i^{ts}(Q_{ij}^t+e_{ij}^t)\}, \tag{9}$$

$$D_j^{ts}=max\{0,G_j^t-I_{js}^{t-1}\}. \tag{10}$$

(4) 运输成本: 是指将物料运送至制造企业海外基地仓库的成本, 由跨国运输费用和境内运输费用构成. 其计算方式为

$$f_4^{ts}=\sum_{i=1}^{I}\sum_{j=1}^{J}w_i^{ts}(ctl_{n(i)j}^t+\delta_i cts_{n(i)j}^t)(Q_{ij}^t+e_{ij}^t). \tag{11}$$

(5) 关税: 制造企业在跨国采购物料时, 根据海外基地所在国的关税政策, 以进口物料的到岸价为基础, 对进口物料按照规定税率缴纳的税费. 物料到岸价包含该周期内物料离岸价、海运运输费用以及保险费用. 其计算公式为

$$\begin{aligned}f_5^{ts}=&\sum_{i=1}^{I}\sum_{j=1}^{J}[w_i^{ts}\delta_i(Q_{ij}^t+e_{ij}^t)\cdot\\&(P_{ij}^tr_{ij}+cts_{n(i)j}^t)(1+\alpha)TR_j].\end{aligned} \tag{12}$$

(6) 海关清关费用: 是指物料办理海关清关手续时产生的费用, 包括码头费和外贸系统费. 其中: 码头费通常以物料的离岸价格计算, 而外贸系统费用则以固定金额的形式计入清关成本. 其计算公式为

$$f_6^{ts}=\sum_{i=1}^{I}\sum_{j=1}^{J}[w_i^{ts}\delta_i(Q_{ij}^t+e_{ij}^t)P_{ij}^tr_{ij}\sigma+\mu]. \tag{13}$$

(7) 库存成本: 是指制造企业海外基地在各时间周期末对尚未使用物料进行库存管理所产生的费用, 如下所示:

$$f_7^{ts}=\sum_{j=1}^{J}h_jI_{js}^t. \tag{14}$$

(8) 税收优惠: 由关税和税收减免比例构成. 计算公式为

$$f_8=\begin{cases}\gamma\sum\limits_{t=1}^{T}\sum\limits_{s=1}^{S}f_5^{ts},\\ if\ \dfrac{\sum\limits_{t=1}^{T}\sum\limits_{s=1}^{S}\sum\limits_{i=1}^{I}(1-\delta_i)P_s^t(Q_{ij}^t+e_{ij}^t)}{\sum\limits_{t=1}^{T}\sum\limits_{s=1}^{S}\sum\limits_{i=1}^{I}P_s^tw_i^{ts}(Q_{ij}^t+e_{ij}^t)}\geqslant K_j\\ \quad and\ \sum\limits_{j=1}^{J}g_j\geqslant per\\ 0,\ \text{otherwise}\end{cases} \tag{15}$$

当某一物料的本土采购量占总采购量的比例达到当地政府规定的最低要求时, 可获得相应的税收优惠分数. 当所有物料的分数之和达到规定的最低分时, 制造企业海外基地可以享受关税减免政策, 减免额度由规定的减免比例决定.

1.3.2 约束条件

(1) 紧急采购订单分配: 在任何情况下, 只有非中断状态的供应商能供应超过正常采购数量的额外订单, 如下所示:

$$e_{ij}^t(1-w_i^{ts})\leqslant Q_{ij}^tw_i^{ts}. \tag{16}$$

(2) 供应商供应能力的硬性约束: 若供应商i在某场景s下处于中断状态, 则供应商i处的正常采购量和紧急采购量均为零; 反之, 则采购总量不得超过其最大供给能力S_{ij}^t. 具体如下所示:

$$Q_{ij}^t+e_{ij}^t\leqslant S_{ij}^tw_i^{ts}. \tag{17}$$

(3) 供应商可扩展产能约束: 参考 Mahapatra 等[24]的研究, 本文假设紧急采购只能由仍处于正常状态的供应商提供, 且紧急采购量受到供应商可扩展产能的限制. 具体如下所示:

$$e_{ij}^t\leqslant\theta Q_{ij}^t \tag{18}$$

(4) 库存数量一致约束: 本期的期末库存由上一期的期末库存、本期采购量以及本期物料消耗量共同决定, 有

$$I_{js}^t=I_{js}^{t-1}+\sum_{i=1}^{1}w_i^{ts}(Q_{ij}^t+e_{ij}^t)+Spot_j^t-G_j^t \tag{19}$$

2 求解算法

2.1 算法框架

为了解决多供应商、多物料、多时期且存在国家和供应商双重中断风险的采购决策模型, 本文设计一种双深度 Q 网络引导的改进自适应遗传算法 (DDQN-IAGA). DDQN-IAGA 算法总体框架如图 3 所示.

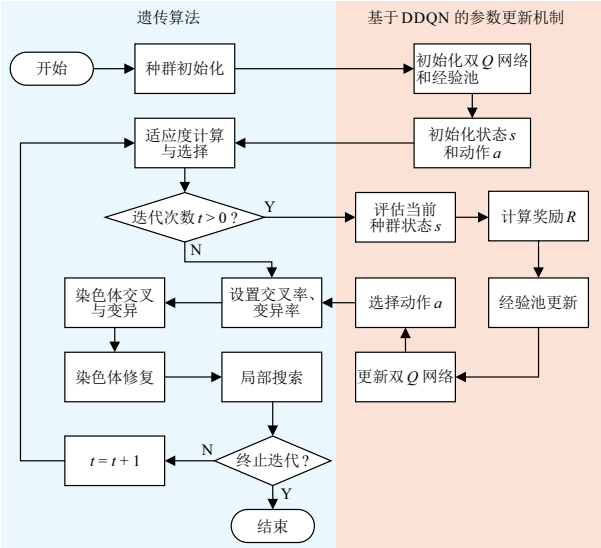

图 3 DDQN-IAGA 算法框架

2.2 遗传算法

2.2.1 编码与种群初始化

采用整数编码方式. 每一条染色体由两部分组成, 分别对应正常采购量Q_{ij}^t和紧急采购量e_{ij}^t. 二者均为三维编码方式, 其中三个维度分别表示供应商、物料和时间周期. 如图 4 所示, 是按时间周期t展开的二维示意图.

		$t=1$			$t=2$			…	$t=11$			$t=22$		
		1	…	J	1	…	J		1	…	J	1	…	J
Q_{ij}^t	1	20	…	25	13	…	20	…	30	…	16	22	…	39
	2	40	…	…	25	…	19	…	38	…	40	29	…	31
	⋮	5	…	60	45	…	7	…	16	…	0	13	…	8
	I	10	…	28	40	…	12	…	23	…	62	55	…	11
e_{ij}^t	1	0	…	0	6	…	0	…	4	…	8	0	…	3
	2	0	…	4	0	…	0	…	13	…	0	0	…	0
	⋮	15	…	10	0	…	3	…	0	…	0	0	…	0
	I	0	…	0	0	…	0	…	9	…	0	17	…	5

图 4 染色体编码示意图

本文设计了一种基于混合策略的启发式种群初始化方法. 基于成本最小化策略, 对供应商正常采购成本排序并采用贪婪策略生成 15% 的初始染色体; 基于风险最小化策略, 对供应商的中断概率排序, 优先将正常采购量分配给低风险的供应商, 生成 15% 的初始染色体; 最后生成其余 70% 的随机个体, 以增加种群多样性, 防止陷入局部最优. 三类个体按顺序加入初始种群, 后生成个体需与当前种群中的已有个体进行重复性检查. 若新个体与已生成个体在染色体编码上完全相同, 则不予保留, 并重新生成; 若不存在重复, 则将其加入种群. 在此基础上对初始染色体施加随机扰动生成初始种群, 具体步骤如下.

算法1 启发式种群初始化

输入: 种群规模N, 各供应商单位采购成本, 各供应商中断概率, 随机扰动参数

输出: 初始种群p

Step1: 根据单位采购成本的大小对供应商进行排序, 并使用贪婪策略生成15%的初始染色体

Step2: 根据供应中断风险大小对供应商进行排序, 优先将正常采购量分配给低风险的供应商, 生成15%的初始染色体

Step3: 随机生成70%的初始染色体

Step4: 生成与染色体维度一致的随机矩阵, 对初始染色体施加随机扰动

Step5: 对染色体进行可行性修复, 将正常采购量Q_{ij}^t限制在供应能力区间$[0, S_{ij}^t w_i^{ts}]$内, 并将紧急采购量e_{ij}^t限制在由正常采购量决定的比例区间$[0, \theta Q_{ij}^t]$内

Step6: 复执行Step2–Step4, 直至生成种群规模N的初始种群

Step7: 输出p作为初始种群

2.2.2 适应度计算与选择

适应度函数由所有成本项组成. 本文采用精英保留和锦标赛选择机制, 根据染色体的适应度值对种群进行排序, 保留适应度最优的个体进入下一代, 其余染色体采用锦标赛选择机制进行抽样, 选择适应度最小的个体参与后续的交叉与变异操作, 直到满足种群规模的要求.

2.2.3 交叉操作

本文采用两点交叉的方式, 如图 5 所示, 计算两个父代染色体在每个物料j和时期t组合上的正常采购量差异度, 并对差异度进行排序, 在差异较大的区域内随机选择两个交叉点, 确定一段连续的基因区间, 交换该区间内所有(j,t)组合对应的总正常采购量. 采购量差异度的计算方式如公式 (20) 所示.

$$d_j^t = \sum_{i=1}^{I} |Q_{ijt}^{(1)} - Q_{ijt}^{(2)}|. \tag{20}$$

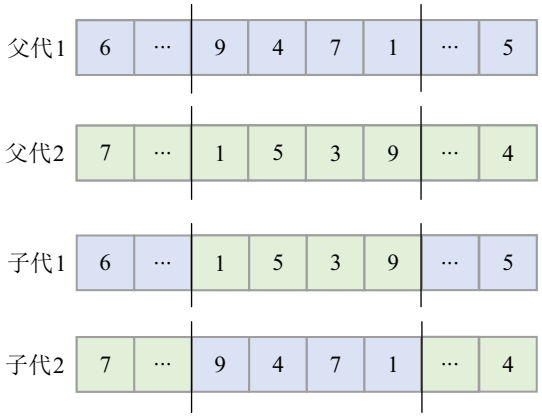

图 5 染色体交叉示意图

其中, d_j^t表示在时期t时, 两个父代染色体对物料j正常采购量的差异度; $Q_{ijt}^{(1)}$, $Q_{ijt}^{(2)}$分别表示父代染色体 1 与父代染色体 2 在时期t时从供应商i正常采购物料j的数量.

2.2.4　变异操作

本文设计了一种成本导向的变异操作. 首先在同一物料与时期下比较不同供应商的成本下降空间, 如下文式 (21)-(23) 所示. 在不改变正常采购量的前提下, 选取总成本下降空间较大的决策量, 总成本下降空间计算公式如下文式 (24) 所示. 将部分正常采购量由高成本供应商转移至低成本供应商, 从而得到变异后的染色体.

$$c_{ij}^t = p_{ij}^t(1+TR_j) + cts_{n(i)j}^t + ctl_{n(i)j}^t + \lambda_j^t(\beta_n^t + \phi_i^t), \tag{21}$$

$$\Delta c_j^t = \underset{i}{max} c_{ij}^t - \underset{i}{min} c_{ij}^t, \tag{22}$$

$$q_j^t = \sum_i Q_{ij}^t, \tag{23}$$

$$score_j^t = \Delta c_j^t \cdot q_j^t. \tag{24}$$

其中c_{ij}^t表示单位边际采购成本, λ_j^t表示缺货惩罚系数. 在此基础上, 不同供应商之间的边际成本差异定义为Δc_j^t, q_j^t表示在固定物料和时期下的总正常采购量, 成本下降空间$score_j^t$定义为二者的乘积.

如图 6 所示, 给出了不同供应商的边际成本, 其中最小成本为 6, 最大为 15. 将高成本供应商的部分采购量转移至低成本供应商, 即将 10 单位采购量从基因位 45 转移至基因位 25, 得到子代染色体.

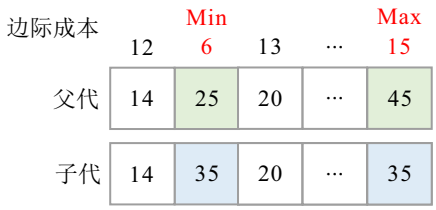

图 6　染色体变异示意图

2.2.5　染色体修复

为保证解的可行性, 本文引入染色体修复机制. 当某物料的正常采购量Q_{ij}^t和紧急采购量e_{ij}^t之和超过供应商供给能力时, 即

$$Q_{ij}^t + e_{ij}^t > S_{ij}^t w_i^{ts}. \tag{25}$$

优先减少紧急采购量; 若仍不满足供给能力约束, 则进一步压缩正常采购量, 直至满足约束.

在此基础上, 检查紧急采购比例约束. 当紧急采购量超过正常采购量所允许的扩展比例时, 即

$$e_{ij}^t > \theta Q_{ij}^t. \tag{26}$$

将紧急采购量修复为该比例约束下的最大允许值. 修复后的染色体同时满足供应能力约束与紧急采购比例约束. 通过上述机制, 可以有效避免交叉与变异操作产生不可行解.

2.2.6　局部搜索算子

为进一步提升解的质量, 本文设计了一种基于贪婪的跨周期局部搜索算子, 对于给定的供应商i和物料j, 通过在相邻周期之间重新分配正常采购量Q_{ij}^t构造邻域解. 如图 7 所示, 将部分采购量由单位成本p_{ij}^t较高的周期t转移至成本较低的相邻周期t', 转移量记为Δq. 为保证调整后的解仍满足供应能力约束, Δq在周期t的正常采购量Q_{ij}^t和t'的剩余供应能力$S_{ij}^{t'} - Q_{ij}^{t'}$中取最小, 如公式 (27) 所示. 比较局部搜索前后解的目标函数值, 如果改进则接受该调整并继续搜索, 若连续多次局部搜索未能改进, 则终止局部搜索过程.

$$\Delta q = min(Q_{ij}^t, S_{ij}^{t'} - Q_{ij}^{t'}). \tag{27}$$

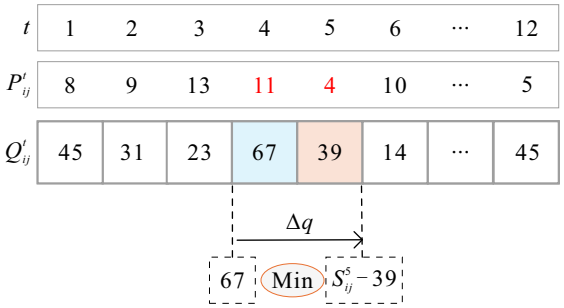

图 7　局部搜索示意图

2.3　基于双深度 Q 网络的参数更新机制

本文构建一种融合深度强化学习的遗传算法参数调优机制, 通过在线学习的方式动态调整遗传算法参数, 从而提升遗传算法对复杂采购计划问题的求解适应性.

2.3.1　MDP 模型

在融合深度强化学习的参数调优机制中, 马尔可夫决策过程 (MDP) 主要由状态空间S、动作空间A和奖励函数R三部分构成, 具体设计如下:

(1) 状态空间S

由于参数调优的核心目标在于平衡搜索多样性与收敛效率, 本文从种群总体水平、种群多样性水平、种群近期的相对改进、算法的迭代进度等角度构建状态描述. 设计了三个状态, $s_1, s_2, s_3, s = [s_1, s_2, s_3], s \in S$.

s_1: 种群总体水平. 表示种群第t次迭代时的平均适应度相对于初始种群平均适应度的变化情况, 其计算方式如下:

$$s_1(t)=\frac{\overline{f}_t}{\overline{f}_1}. \tag{28}$$

其中, $\overline{f}_t$表示第t代种群的平均适应度; $\overline{f}_1$表示第一代种群的平均适应度值.

s_2: 种群多样性水平. 表示种群第t次迭代时, 种群中个体适应度的离散程度, 从而反映种群结构的多样性水平, 其计算方式如下:

$$s_2(t)=ln(1+\frac{\sigma_t}{\sigma_1}). \tag{29}$$

其中, σ_t表示第t代种群中的适应度标准差, σ_1为初始种群的适应度标准差.

s_3: 种群近期的相对改进. 由种群第t次迭代时, 最近十代中平均适应度和最优个体适应度的提升情况来表示, 用于评估种群在该时间段内的迭代效果. 其计算方式如下:

$$s_3(t)=\frac{0.5(\overline{f}_{t-9}-\overline{f}_t)+0.5(f^*_{t-9}-f^*_t)}{|f^*_1|}. \tag{30}$$

其中, $\overline{f}_{t-9}$和$\overline{f}_t$分别表示第$t-9$代和t代种群的平均适应度; f^*_{t-9}和f^*_t分别表示第$t-9$代和t代种群的最优个体适应度, f^*_1是初始种群的最优个体适应度, 用于归一化.

(2) 动作集A

已有研究表明, 交叉概率通常取较高水平, 以增强种群重组能力, 而变异概率通常取较低水平, 以维持种群多样性并避免过度扰动[25]. 参考供应链中断领域中 Al-Zuheri 等[26] 的研究, 选取代表性的交叉概率 p_c区间 [0.5,0.7,0.9] 和变异概率 p_m区间 [0.1, 0.3,0.5] 中取值进行组合, 构建出动作集合A, 即

$$\begin{aligned}A=\{1,2,3,4,5,6,7,8,9\}=\\ \{(0.5,0.1),(0.5,0.3),(0.5,0.5),\\ (0.7,0.1),(0.7,0.3),(0.7,0.5),\\ (0.9,0.1),(0.9,0.3),(0.9,0.5)\}.\end{aligned} \tag{31}$$

在算法运行期间, 智能体依据当前种群的状态信息, 从可选动作集中挑选出合适的参数组合, 并将其反馈给遗传算法模块, 以实现对交叉率与变异率的动态自适应调节.

(3) 奖励函数R

本文将相邻两代种群的平均适应度和个体最优适应度的相对改进值加权求和, 得到奖励函数R_t. R_1表示第t代种群平均适应度相对于上一代的变化情况, 反映了参数组合对种群整体搜索质量的影响; R_2表示第t代种群中个体最优适应度相对于上一代的变化情况, 反映了参数组合对最优采购方案改进的作用. 公式如下所示:

$$R_1=\frac{\overline{f}_{t-1}-\overline{f}_t}{|\overline{f}_{t-1}|}, \tag{32}$$

$$R_2=\frac{f^*_{t-1}-f^*_t}{|f^*_{t-1}|}, \tag{33}$$

$$R_t=0.5R_1+0.5R_2. \tag{34}$$

2.3.2 参数更新算法

本文设计了基于双深度 Q 网络的遗传算法参数更新算法. 在进化过程中, 依据种群适应度的变化情况来判定当前所处状态及对应的奖励值. 构建在线网络与目标网络的双网络架构, 通过贪婪策略从动作空间中选取动作, 即获取一组参数配置, 并将其返回至遗传算法中, 实现对参数的动态调节与优化. 算法步骤如下:

算法2 基于双深度Q网络的遗传算法参数更新

输入: 状态集S, 动作集A, 种群适应度, 超参数α, γ, 最大迭代次数Max

输出: Q网络, 新的种群状态s_{t+1}, 新的动作a_{t+1}

Step1: 初始化在线网络与目标网络, 初始化经验池, 迭代次数$t=1$

Step2: 根据初始种群, 计算种群状态s_t

Step3: 随机从动作集A中选择动作a_t, 向遗传算法传递p_c, p_m

Step4: 根据新种群计算状态s_{t+1}, 计算奖励R_{t+1}

Step5: 将$(s_t,a_t,R_{t+1},s_{t+1})$存入经验回放池D, 若经验池样本量未满足采样条件, 则转到Step8; 否则执行Step6

Step6: 从经验池中采样, 在线网络选择下一状态的最优动作a^*, 目标网络$Q_{target}(s_{t+1},a^*,\theta_t)$评估$Q$值, 构造时序差分目标

Step7: 最小化时序差分的误差, 更新在线网络$Q_{online}(s_t,a_t,\theta_t)$和目标网络$Q_{target}(s_{t+1},a^*,\theta_t)$的参数

Step8: 根据更新后的在线网络的参数θ_{t+1}, 用贪婪策略重新选择动作a_{t+1}, 执行动作, 并向遗传算法传递p_c, p_m

Step9: $s_t\to s_{t+1}$, $a_t\to a_{t+1}$, 若$t=Max$, 则停止, 否则转到Step10

Step10: 令$t=t+1$, 转到step4

在算法运行过程中, 智能体根据当前种群状态s_t, 通过在线网络$Q_{online}(s_t,a_t,\theta_t)$从动作集合 A 中选择交叉率和变异率组合$a_t$, 并将其传递至遗传算法完成种群进化. 执行动作后, 计算新种群状态s_{t+1}根据种群适应度变化计算即时奖励R_{t+1}, 并将样本$(s_t,a_t,R_{t+1},s_{t+1})$存入经验回放池.

当经验池满足训练条件后, 利用在线网络$Q_{online}(s_t,a_t,\theta_t)$和目标网络$Q_{target}(s_{t+1},a^*,\theta_t)$分别完成动作选择与价值评估, 并根据当前状态转移关系更新网络参数. 通过双网络结构降低 Q 值高估

问题, 使算法能够动态调整交叉概率p_c和变异概率p_m, 提高遗传算法在不同阶段的搜索能力.

3 数值实验

为测试 DDQN-IAGA 算法性能, 分别进行了小规模实验、大规模实验和消融实验. 同时, 通过案例分析进一步验证本文方法在实际采购决策场景中的适用性. 最后, 通过敏感性实验分析税收减免比例的变化对采购成本的影响.

3.1 数据集

以相关领域的已有研究为依据[7,18], 构建了不同参数组合的问题实例, 如表 2 所示. 问题实例中国家数量N的取值区间为 2、4、6; 供应商数量I的取值区间为 5、10、20; 物料数量取值J区间为 10、20、30; 时间周期T以月为单位, 固定为 12. 根据N、I和J的取值不同生成 9 个规模的问题实例, 每个问题实例下包含 5 个算例.

表 2　问题实例的描述

问题实例	N	I	J	T
2-5-10-12	2	5	10	12
2-5-20-12	2	5	20	12
2-5-30-12	2	5	30	12
4-10-10-12	4	10	10	12
4-10-20-12	4	10	20	12
4-10-30-12	4	10	30	12
6-20-10-12	6	20	10	12
6-20-20-12	6	20	20	12
6-20-30-12	6	20	30	12

3.2 有效性实验

将 Gurobi 求解器与 DDQN-IAGA 算法的求解结果进行对比. 实验设置 Gurobi 的最优性差距 (Optimality Gap) 为 0.01%, 时间上限为 3 600 s. 运行 10 次 DDQN-IAGA 算法, 统计实验结果的平均目标函数值 (单位: 元) 和计算时间 (单位: 秒), 与 Gurobi 的计算结果进行比较, 统计两者间的差距 Gap, 公式如 (35) 所示.

$$Gap = [(G - D)/D] \times 100\%. \tag{35}$$

其中, G表示 Gurobi 求解器的求解的平均目标函数值或计算时间, D表示 DDQN-IAGA 算法求解的平均目标函数值或计算时间. 当Gap为正数时表示 DDQN-IAGA 算法求解的平均目标函数值更低或计算时间更短. 实验结果如表 3 所示.

由表 3 可得, 在平均目标函数值的计算结果上, 前 4 个问题实例中, DDQN-IAGA 算法与 Gurobi 求解器的差距在 2% 以内. 在计算时间上, 由于问题实例 2-5-10-12 的规模较小, Gurobi 求解器可以在更短的时间内找到精确解; 但随着问题规模的增大, 本文算法的计算时间显著小于 Gurobi 求解器; 并且在较大规模实例下, Gurobi 求解器无法在规定时间 (3 600 s) 内得到最优解. 总体而言, DDQN-IAGA 算法具有较好的性能.

表 3　DDQN-IAGA 与 Gurobi 求解结果差距表

问题实例	平均目标函数值(×10⁶)			计算时间		
	Gurobi	DDQN-IAGA	Gap(%)	Gurobi	DDQN-IAGA	Gap(%)
2-5-10-12	39.94	39.97	−0.07	1.95	5.27	−63.00
2-5-20-12	73.48	73.55	−0.10	55.85	16.62	236.04
2-5-30-12	105.53	105.68	−0.14	82.26	51.53	59.64
4-10-10-12	42.80	43.03	−1.43	1 338.65	305.33	338.43
4-10-20-12	—	81.59		>3 600	—	—
4-10-30-12	—	122.44		>3 600	—	—

3.3 性能对比实验

为验证 DDQN-IAGA 算法的性能, 将改进的整数编码遗传算法 (IICGA)[27]、改进的遗传算法 (IGA)[17]、改进的离散粒子群优化算法 (MDPSO)[9]、改进的人工蜂群算法 (I-ABC)[7] 作为对比算法.

(1) 求解质量对比

以算法求解的目标函数值作为解质量的评价依据. 本文采用相对偏差率 (RPD) 作为评价指标, 其计算方法如下所示:

$$RPD = [(D(A) - D_{Best})/D_{Best}] \times 100\%. \tag{36}$$

其中$D(A)$表示算法A在问题实例D下目标函数值, D_{Best}表示五种算法的目标函数值里的最优值. 在九种问题实例分别选取五组独立算例, 并对每组算例运行十次. 统计五种算法在所有运行结果中的最优值即最小值 (min) 以及最优值均值 (avg) 的相对偏差率, 如表 4 所示.

其中, DDQN-IAGA 在所有问题实例中均取得了最低的最优值和最优值均值. 与 IICA、IGA、MDPSO、I-ABC 相比, 其平均性能提升幅度分别为 27.59%、22.26%、28.89%、36.03%. 在国家和供应商规模固定的情况下, 随着物料的增加, 四种对比算法的 RPD 呈现上升趋势. 在最大规模实例下, 四种对比算法的 RPD 均超过了 60%. 说明传统启发式算法在面对大规模复杂决策时, 解质量明显下降. 而 DDQN-IAGA 在所有规模下均展现出优异的求解质量.

针对本文算法与各对比算法在所有实例上的求解结果, 采用 Mann-Whitney U 非参数检验方法进行显著性分析. 设定置信水平α=0.05, 原假设为两组数据之间不存在显著差异. 若显著性概率p值不小于 0.05, 则接受原假设, 记检验判定结果h=0, 认为两组

表 4 DDQN-IAGA 与 IICGA, IGA, MDPSO, I-ABC 的求解结果相对偏差率表

问题实例	$D_{Best}(\times 10^6)$		RPD									
			DDQN-IAGA(%)		IICGA(%)		IGA(%)		MDPSO(%)		I-ABC(%)	
	min	avg	min	avg	min	avg	min	avg	min	avg	min	avg
2-5-10-12	39.97	39.97	**0.00**	**0.00**	14.13	14.98	14.28	14.52	13.91	14.76	18.38	18.70
2-5-20-12	73.56	73.56	**0.00**	**0.00**	26.55	28.29	25.65	26.05	22.70	26.22	32.70	32.95
2-5-30-12	105.69	105.69	**0.00**	**0.00**	28.86	27.80	26.42	24.47	26.24	24.88	33.58	31.35
4-10-10-12	43.42	43.03	**0.00**	**0.00**	13.28	11.91	11.74	9.90	3.44	3.26	24.44	22.43
4-10-20-12	81.87	81.59	**0.00**	**0.00**	22.34	20.04	21.83	19.24	8.33	12.01	36.68	33.84
4-10-30-12	122.44	122.44	**0.00**	**0.00**	22.18	22.96	23.01	23.20	17.68	19.16	38.34	38.69
6-20-10-12	37.57	37.47	**0.00**	**0.00**	35.21	37.28	45.53	45.68	15.51	24.49	47.22	47.31
6-20-20-12	89.77	88.57	**0.00**	**0.00**	16.93	16.22	24.38	22.83	7.66	10.96	25.03	23.51
6-20-30-12	97.14	97.14	**0.00**	**0.00**	68.54	68.85	74.71	75.03	62.72	64.60	75.30	75.53

数据无统计学意义上的差异; 反之, 则拒绝原假设, 认为两组数据存在显著差异, 记h=1. 在所有问题规模下, h均为 1, DDQN-IAGA 算法相较于各对比算法的求解结果存在显著差异, 进一步验证了本文算法的性能显著优于各对比算法.

(2) 求解稳定性对比

为评估五种算法在不同问题规模下的求解稳定性, 分别在代表性实例 4-10-20-12 和 6-10-20-12 下进行 10 次独立求解, 并绘制目标函数值的箱型图, 如图 8 所示. 分析箱型图可知, 在实例 4-10-20-12 中, DDQN-IAGA 算法与 MDPSO、IGA 和 I-ABC 三种算法相比, 箱体更为集中, 数据分布范围较窄, 稳定性较好. IICGA 的稳定性略优于 DDQN-IAGA. 而在实例 6-10-20-12 中, 四种对比算法的箱体高度都相对较大, 解分布较为分散, 呈现出较大的波动性. 同时, DDQN-IAGA 算法的中位数始终低于四种对比算法, 表明其在保持求解稳定性的同时, 能取得相对更优的目标函数值, 具备更强的鲁棒性. 并且随着问题规模的扩大, 其稳定性上的优势更加突出.

(3) 求解效率对比

对比 DDQN-IAGA 与 IICGA、IGA、MDPSO、I-ABC 算法在各个问题实例下的运行时间. 如图 9 所示, 在所有问题实例中, DDQN-IAGA 算法的运行时间都显著低于 IICGA、IGA 和 I-ABC 的运行时间. 对于小规模问题实例, 由于 MDPSO 算法结构相对简单, 其计算时间略短于 DDQN-IAGA. 然而, 随着问题规模的逐步扩大, MDPSO 计算时间的增长更为明显, 而 DDQN-IAGA 仍能保持较低的运行时间. 说明 DDQN-IAGA 算法的在求解效率方面具有良好的的性能表现.

(4) 参数组合迭代变化情况分析

为进一步验证本文所引入的双深度 Q 网络机制在参数自适应更新过程中的有效性, 在大规模实例

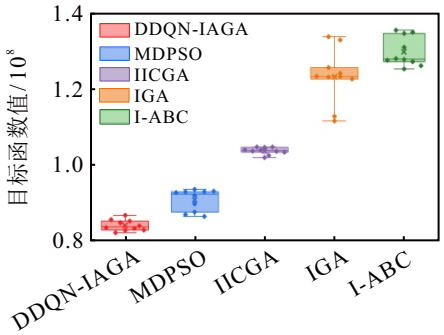

(a) 实例4-10-20-12

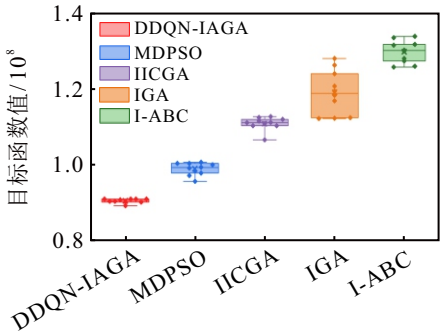

(b) 实例6-20-20-12

图 8 5 种算法求解目标函数值的分布情况

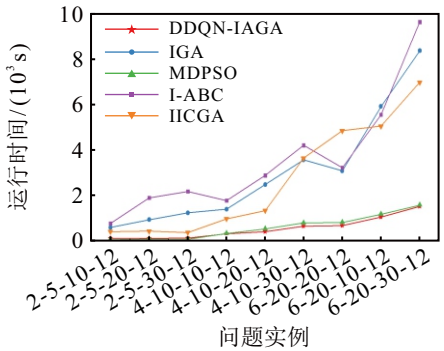

图 9 5 种算法的计算时间对比

6-20-30-12 中, 记录了遗传算法迭代过程中交叉概率和变异概率组合的变化过程. 如图 10 所示. 从图中可以看出, 迭代初期参数组合的选择表现出较强的

波动性, 说明算法对不同参数组合进行充分探索. 随着迭代次数的增加, 参数更新幅度逐渐减小, 最终收敛到一组较优的参数组合. 实验结果表明基于双深度 Q 网络的参数更新机制能够根据种群进化状态动态调整参数, 使算法在初期保持较强的全局搜索能力, 在后期强化局部搜索, 提升遗传算法的求解效率与求解质量.

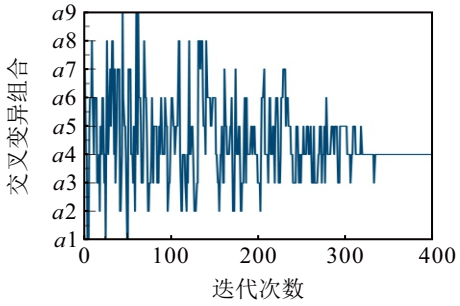

图 10　参数组合变化曲线

3.4　消融实验

选取 DDQN-IAGA 作为基准算法, 并构造三种变体进行分析, 一是移除深度强化学习模块以评估自适应调参机制的贡献, 修改后的算法记为 non-Double Deep Q-Network(简称 non-DDQN); 二是移除启发式种群初始化机制, 修改后的算法记为 non-Heuristic Population Initialization(简称 non-HPI); 三是移除局部搜索机制以检验全局搜索与局部优化的协同效应, 修改后的算法记为 non-Local Search(简称 non-LS); 四是移除以上三个模块以全面评估各子模块对整体性能的影响, 修改后的算法记为 non-DDQN-HPI-LS. 选取九组实例的第一组算例, 将三种算法在相同算例条件下独立运行十次, 统计最优值均值.

如图 11 所示, 实验结果表明, 移除 DDQN 模块后, 算法在各规模数据下的最优值均值都低于 DDQN-IAGA 算法, 验证了融合双深度 Q 网络参数更新机制的有效性, 这是由于 DDQN 通过学习参数调整对长期解质量的影响, 降低了固定参数带来的搜索效率的损失和过早收敛的可能性, 从而在不同规模问题实例下均显著提升了求解质量. 与此同时, 移除 HIP 模块的算法在所有数据集中的表现都劣于 DDQN-IAGA 算法, 说明 HPI 机制生成了较优的初始解, 提升了求解质量. 移除 LS 模块的算法在所有数据集中的最优值均值都低于 DDQN-IAGA 算法, 表明 LS 机制通过对不同采购周期之间的采购量进行局部调整, 使算法在进化过程中逐步向最优解收敛, 提升了算法性能. 而移除 DDQN、HPI、LS 三个模块后的算法在所有问题实例下的最优质均值最高, 证明了三个改进机制之间的协同对 DDQN-IAGA 算法性能的提升作用.

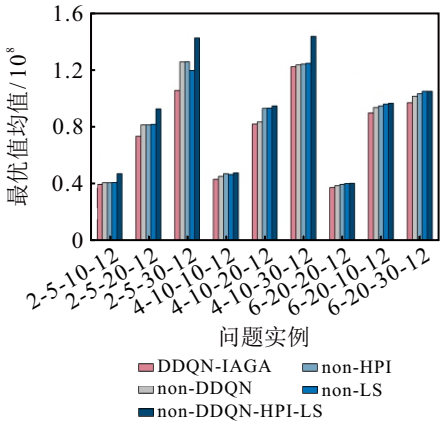

图 11　最优目标函数值的消融实验结果对比

3.5　案例分析

为验证本文模型与算法在实际采购决策场景中的适用性, 以某家电制造企业在巴西所设立的海外生产基地为研究对象. 以该生产基地 2026 年每季度十种物料的需求计划为基础, 制定该年度的物料采购计划, 研究不同策略下的采购总成本的区别.

在该案例中, 该基地有分属于四个国家的供应商, 并分别设置供应商总数量为 5、10、15 和 20 四种规模, 对比分析巴西基地原采购计划与本文算法改进后的采购方案在总成本上的差异, 并计算其相对百分比变化率 (Relative Percentage Change, RPC), 如公式 (37) 所示.

$$RPC = [(O(X) - N(X))/O(X)] \times 100\%. \quad (37)$$

其中, $O(X)$表示在供应商数量为X时原采购计划的总成本, $N(X)$表示供应商数量为X时用本文方法改进后的总成本. RPC用于改进后总成本相对于原计划成本的改进幅度, 其数值越大, 表明本文算法对采购计划的优化效果越显著.

成本变化如图 12 所示, 在供应商数量为 5 时, 改进后总成本相较于原计划成本降低约为 2.38%; 当供应商数量增加至 10 时, 成本降幅为 2.73%; 当供应商数量进一步增加至 15 和 20 时, 成本降幅分别达到 2.87% 和 2.88%. 整体来看, 本文算法在不同供应商规模下均表现出稳定的成本优化效果.

进一步分析可以发现, 采购总成本与供应商数量之间呈现出明显的负相关关系, 即随着供应商数量的增加, 原采购成本和改进后总成本均呈现出下降趋势. 然而, 当供应商数量增加到一定规模后, 成本下降的幅度逐渐减小, 趋于平稳. 这表明, 增加供应商数量有助于提升采购决策的灵活性, 在一定程度上能降低采购总成本. 但当供应商数量增加到一

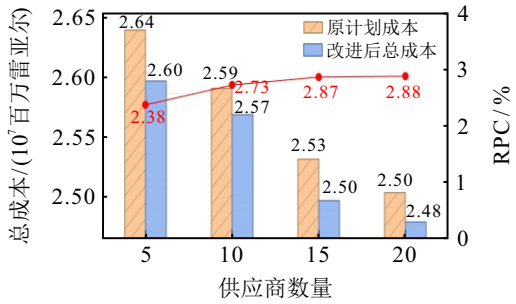

图 12 原计划成本与改进后总成本对比

定水平后, 其对成本优化的作用趋于有限. 总体来看, 本文算法能够在不同供应商规模条件下保持较好的优化效果.

3.6 敏感性分析

以问题实例 4-10-20-12 为基准测试案例, 分析税收减免比例的变化如何影响采购成本. 实验中税收减免比例分别设置为 0.2、0.5、0.8. 实验结果如图 13 所示, 随着税收减免比例的增加, 最优值均值即采购总成本呈现下降趋势, 税收优惠均值呈现上升趋势. 表明税收减免比例越高, 企业在满足税收优惠政策条件时所获得的税收优惠额度越大, 抵消了部分成本支出. 这是由于税收减免比例的提升不仅影响总成本水平, 也会对采购策略产生一定引导作用. 当税收优惠比例较低时, 模型更倾向于优先选择采购价格较低的供应商; 而当税收减免比例提高后, 适当增加本土供应商采购比例反而会降低成本. 由此可见, 税收优惠政策不仅能够降低企业采购成本, 还能够通过改变其大小对采购策略产生影响.

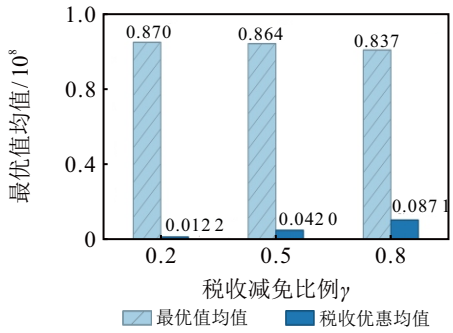

图 13 税收减免比例对采购成本的影响结果

4 结 论

针对制造企业海外生产基地的跨国多源采购需求, 本文构建了考虑双层供应中断风险的非线性随机规划模型, 并提出一种双深度 Q 网络引导的改进自适应遗传算法 (DDQN-IAGA). 实验结果表明本文提出的 DDQN-IAGA 算法在求解性能上整体表现较优. 在消融实验中, 三种改进机制均能够提升问题的求解质量. 本文还以某家电制造企业在巴西所设立的海外生产基地为研究对象进行案例分析, 进一步验证本文方法在实际采购决策场景中的适用性. 最后, 通过敏感性实验分析税收减免比例的变化对采购成本和策略的影响. 未来研究中, 可以进一步拓展问题模型与算法框架. 在模型上综合考虑供应链中断和需求波动、价格不确定等不确定性因素. 在算法层面, 可以进一步将深度强化学习的动作空间扩展成连续动作, 或将自适应机制扩展至算子选择层.

参考文献 (References)

[1] Wu M, Zhang J W, Chen X. Managing supply disruptions for risk-averse buyers: Diversified sourcing vs. disruption prevention[J]. Omega, 2025, 131: 103217.

[2] Vahidi F, Torabi S A, Ramezankhani M J. Sustainable supplier selection and order allocation under operational and disruption risks[J]. Journal of Cleaner Production, 2018, 174: 1351-1365.

[3] 储开伟, 朱建军. 中断风险下考虑随机参照价格效应的复杂产品多源采购策略[J]. 控制与决策, 2026, 41(2): 543-554.
(Chu K W, Zhu J J. A multi-source procurement strategy of manufacturers considering stochastic reference price effect under risk of disruption[J]. Control and Decision, 2026, 41(2): 543-554.)

[4] Bednarski L, Roscoe S, Blome C, et al. Geopolitical disruptions in global supply chains: A state-of-the-art literature review[J]. Production Planning & Control, 2025, 36(4): 536-562.

[5] Luo L, Li X Y, Zhao Y X. A two-stage stochastic-robust model for supply chain network design problem under disruptions and endogenous demand uncertainty[J]. Transportation Research — Part E: Logistics and Transportation Review, 2025, 196: 104013.

[6] Lee J, Moon I. Supplier selection and order allocation problems considering regional and supplier disruptions with a risk-averse strategy[J]. Computers & Industrial Engineering, 2024, 187: 109810.

[7] Dou R L, Liu X, Hou Y C, et al. Mitigating closed-loop supply chain risk through assessment of production cost, disruption cost, and reliability[J]. International Journal of Production Economics, 2024, 270: 109174.

[8] Hasani A, Mokhtari H, Fattahi M. A multi-objective optimization approach for green and resilient supply chain network design: A real-life case study[J]. Journal of Cleaner Production, 2021, 278: 123199.

[9] 董乾东, 李敏. 考虑不同碳排放处理模式的动态供应商选择及采购批量问题研究[J]. 中国管理科学, 2022, 30(8): 106-116.
(Dong Q D, Li M. Research on the dynamic supplier selection and lot-sizing by considering different modes dealing with carbon emission[J]. Chinese Journal of Management Science, 2022, 30(8): 106-116.)

[10] Yilmaz E D. Tariff-sensitive global supply chains: Semi-Markov decision approach with reinforcement learning[J]. Systems, 2025, 13(8): 645.

[11] 蒋媛媛, 罗贺, 吴志伟, 等. 制造企业海外基地采购计

划与供应商选择联合优化问题研究[J]. 中国管理科学, 2025, 33(10): 126-137.
(Jiang Y Y, Luo H, Wu Z W, et al. Research on the joint optimization of procurement planning and supplier selection for the overseas base of manufacturing enterprises[J]. Chinese Journal of Management Science, 2025, 33(10): 126-137.)

[12] 陈志祥, 王伟洁, 杜志娇. 考虑进口配额的跨国供应商选择与订单分配模糊多目标优化决策[J]. 北京交通大学学报: 社会科学版, 2021, 20(2): 113-122.
(Chen Z X, Wang W J, Du Z J, et al. Fuzzy multi-objective optimization decision of multinational supplier selection and order allocation considering import quota[J]. Journal of Beijing Jiaotong University: Social Sciences Edition, 2021, 20(2): 113-122.)

[13] Yang C T, Gu M, et al. Multistage global supply chain inventory model with the impact of carbon tariffs for deteriorating items[J]. Journal of Industrial and Management Optimization, 2024, 20(3): 1271-1295.

[14] Fattahi M, Govindan K, Maihami R. Stochastic optimization of disruption-driven supply chain network design with a new resilience metric[J]. International Journal of Production Economics, 2020, 230: 107755.

[15] 伍佳妮, 龙燕妮. 韧性视角下考虑供应商失效的应急物资供应链决策优化[J]. 控制与决策, 2025, 40(8): 2439-2449.
(Wu J N, Long Y N. Decision optimization of emergency materials supply chain considering supplier failure from perspective of resilience[J]. Control and Decision, 2025, 40(8): 2439-2449.)

[16] Shabani-Naeeni F, Yaghin R G. Integrating data visibility decision in a multi-objective procurement transport planning under risk: A modified NSGA-II[J]. Applied Soft Computing, 2021, 107: 107406.

[17] El Hiri M, En-Nadi A, Chafi A. Order allocation using genetic algorithm[J]. Journal of Engineering Science and Technology Review, 2020, 13(2): 127-134.

[18] Van Hop N. Demand allocation and lot-sizing solution of single product deterministic demand[J]. Expert Systems with Applications, 2024, 245: 122927.

[19] Xie L, Wang Y, Tang S Q, et al. A novel adaptive parameter strategy differential evolution algorithm and its application in midcourse guidance maneuver decision-making[J]. Complex & Intelligent Systems, 2024, 10(1): 847-868.

[20] Brest J, Greiner S, Boskovic B, et al. Self-adapting control parameters in differential evolution: A comparative study on numerical benchmark problems[J]. IEEE Transactions on Evolutionary Computation, 2006, 10(6): 646-657.

[21] Wang W C, Su B D, Zhou Q, et al. A gray predictive evolutionary algorithm with adaptive threshold adjustment strategy for photovoltaic model parameter estimation[J]. Mathematics, 2025, 13(15): 2503.

[22] 韩红桂, 徐子昂, 王晶晶. 基于 Q 学习的多任务多目标粒子群优化算法[J]. 控制与决策, 2023, 38(11): 3039-3047.
(Han H G, Xu Z A, Wang J J. A Q-learning-based multi-task multi-objective particle swarm optimization algorithm[J]. Control and Decision, 2023, 38(11): 3039-3047.)

[23] 张国辉, 伦伟航, 李亮, 等. 基于混合学习策略进化算法的柔性作业车间节能分批调度研究[J]. 控制与决策, 2025, 40(12): 3655-3666.
(Zhang G H, Lun W H, Li L, et al. A hybrid learning strategy evolutionary algorithm for energy-efficient flexible job shop batch scheduling problem[J]. Control and Decision, 2025, 40(12): 3655-3666.)

[24] Mahapatra M S, Pradhan P C, Jha J K. Sourcing decisions with order allocation under supply disruption risk considering quantitative and qualitative criteria[J]. Operational Research, 2022, 22(4): 3291-3333.

[25] Srinivas M, Patnaik L M. Adaptive probabilities of crossover and mutation in genetic algorithms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1994, 24(4): 656-667.

[26] Al-Zuheri A, Ketan H S, Alwan L L. Analysis effect of parameters of genetic algorithm on a model for optimization design of sustainable supply chain network under disruption risks[J]. Management Systems in Production Engineering, 2024, 32(2): 252-264.

[27] 任东燕, 罗贺, 陈盈盈, 等. 考虑供货提前期的制造企业海外基地采购计划优化[J]. 计算机集成制造系统, 2025, 31(8): 3057-3071.
(Ren D Y, Luo H, Chen Y Y, et al. Procurement plan optimization at overseas base of manufacturing enterprises considering supply lead time[J]. Computer Integrated Manufacturing Systems, 2025, 31(8): 3057-3071.)

作者简介

刘瑞琪 (2001−), 女, 硕士生, 主要研究方向为采购计划优化, E-mail: 2497734975@qq.com;

王国强 (1982−), 男, 副教授, 博士, 主要研究方向为多平台协同优化与智能决策、制造企业海外基地采购计划优化方法, E-mail: gqwang2017@hfut.edu.cn;

王玉琦 (1997−), 女, 博士生, 主要研究方向为调度优化, E-mail: 1990798156@qq.com;

罗贺 (1982−), 男, 教授, 博士, 主要研究方向为多主体协同优化、智能决策、数据治理, E-mail: luohe@hfut.edu.cn.