基于因果效应估计的无人机海上侦察作战条件异质性分析

何冰雨[1]，孙建彬[1†]，崔瑞靖[2]，王 锐[1]

(1. 国防科技大学，系统工程学院，长沙 410073；2. 国防大学，军事管理学院，北京 100091)

摘 要: 随着无人机在现代海战侦察体系中的地位凸显, 其作战效能评估已超越单纯的装备性能检验, 对于揭示运用规律、指导战法创新及支撑任务决策具有深远的战略意义. 然而, 传统的效能评估方法往往仅关注变量间的相关性, 难以充分控制如机型、任务环境等变量所导致的混淆偏差, 进而影响决策的可信度. 为此, 本文提出了连续剂量响应因果效应估计网络. 该方法利用专家注意力机制将协变量解耦为工具、混淆与调整三类潜在因子, 并使用变系数网络构建基于积分概率度量的因果独立性约束, 从而实现对连续型作战决策变量的稳健因果效应估计. 通过脱密数据生成的半合成数据集验证, 所提模型的预测性能优于多种主流基线方法. 进一步的案例分析表明, 侦照高度对任务表现呈显著非线性关系且存在全局最优区间, 其因果效应在不同机型、载荷与任务类型间表现出显著异质性. 本研究为数据驱动的无人机作战效能评估提供了一种可参考的因果分析视角.

关键词: 无人机；效能评估；因果推断；因果效应估计；异质性效应；剂量响应函数

中图分类号: E91/TP399 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2026.0354

引用格式: 何冰雨, 孙建彬, 崔瑞靖, 等. 基于因果效应估计的无人机海上侦察作战条件异质性分析 [J]. 控制与决策.

Analysis of heterogeneity in UAV maritime reconnaissance combat conditions based on causal effect estimation

He Bingyu[1]，*Sun Jianbin*[1†]，*Cui Ruijing*[2]，*Wang Rui*[1]

(1. College of Systems Engineering，National Univerisity of Defense Technology，Changsha 410073，China；2. College of Military Management，National Defence University，Beijing 100091，China)

Abstract: As unmanned aerial vehicles (UAVs) become increasingly prominent in modern naval reconnaissance, their operational effectiveness evaluation has transcended mere equipment performance testing, bearing strategic significance for revealing operational patterns, guiding tactical innovation, and supporting mission decision-making. However, traditional evaluation methods often focus only on correlation, failing to adequately control confounding bias caused by variables such as aircraft type and mission environment, thereby undermining decision credibility. To address this, we propose a Continuous Dose-Response Causal Effect Estimation Network, which decouples covariates into instrumental, confounding, and adjustment factors via an expert attention mechanism and employs a varying-coefficient network with integral probability metric constraints to achieve robust causal effect estimation for continuous operational decision variables. Validated on semi-synthetic datasets generated from declassified data, the proposed model outperforms multiple mainstream baselines in prediction performance. Further case analysis reveals a significant nonlinear relationship between reconnaissance altitude and mission performance, with a global optimal interval; the causal effect exhibits substantial heterogeneity across different aircraft types, payloads, and mission types. This study provides a causal analysis perspective for data-driven UAV operational effectiveness evaluation.

Keywords: unmanned aerial vehicle (UAV)；effectiveness evaluation；causal inference；causal effect estimation；heterogeneous treatment effect；dose-response function

1 引 言

大型长航时侦察无人机是现代海战场信息优势与精准打击的关键装备. 精确量化关键作战条件对任务表现的因果效应已成为研究热点[1]. 在复杂海上侦察任务中, 任务表现不仅依赖平台性能, 还与侦照高度、飞行姿态等连续决策变量深度耦合. 然而, 指

收稿日期: 2026-04-22；**录用日期:** 2026-07-16.

基金项目: 国家自然科学基金面上项目 (72471238, 72431011).

责任编委: 许斌.

†通信作者. E-mail: sunjianbin@nudt.edu.cn.

挥员对参数设定仍高度依赖经验, 缺乏量化依据. 因此, 识别并量化作战条件的因果效应, 解析其机制与异质性, 具有重要理论意义与应用价值[2]

无人机效能评估旨在从历史数据中挖掘关键因素. 现有方法包括基于物理模型的仿真推演 (如 ADC 模型[3])、统计回归 (如层次分析法[4]、模糊综合评判[5]) 及机器学习预测 (如支持向量机[6]). 但这些方法或简化假设, 或限于相关关系, 难以区分因果关联. 观测数据中, “性能更优的平台承担更复杂任务”会导致混淆, 传统方法可能高估或低估决策的真实效应, 产生辛普森悖论. 因此, 引入因果推断框架可控制混淆, 获得更可信的效应估计[7].

军事数据常呈现复杂分布与高维交互. 高维协变量与非线性关系挑战稳定因果估计. 近年来, 表征学习从高维混淆数据中学习潜在表征, 估计连续干预变量的剂量响应函数[8-9]. 在无人机任务中, 装备、人员与任务类型的差异使相同侦照高度效果迥异. 因此, 将任务特征划分为装备、环境、人员与规划变量, 并结合内部因果结构探讨异质性效应, 对精细化任务规划至关重要.

为量化作战条件因果效应并分析异质性, 本文研究出发点包括: 1) 更准确地估计连续型作战条件 (如侦照高度) 的因果效应. 引入基于潜在结果框架的因果推断, 可系统控制混淆, 获得可解释的剂量响应曲线. 2) 解决高维混淆与复杂分布问题. 基于深度学习的表征学习可自动提取稳健潜在表征, 平衡协变量分布, 增强泛化与估计能力[10]. 3) 针对无人机决策特点合理建模. 基于协变量结构化分解与因果关系建模, 可准确模拟决策机制与环境反馈, 识别最优决策区间.

本文主要贡献: 1) 建立适用于无人机海上侦察的连续型干预因果推断模型, 将平均剂量响应函数与条件平均因果效应估计引入该领域. 2) 提出连续剂量响应因果效应估计网络 (CDDRN), 通过解耦表征学习与平衡重加权, 缓解混淆偏差, 提升因果结论稳健性. 3) 基于专家知识构造半合成数据集, 验证方法有效性, 并开展案例分析, 估计不同任务配置下侦照高度的平均因果效应, 提供异质性结论.

本文结构如下: 第 2 节回顾相关工作; 第 3 节给出问题定义与理论框架; 第 4 节详细介绍 CDDRN 模型; 第 5 节阐述数据集构建与方法验证; 第 6 节展示案例分析结果; 第 7 节总结与展望.

2 相关工作

在本节中, 将介绍与本文研究紧密相关的两个领域的研究工作: 一是无人机作战效能评估方法, 二是因果推断, 特别是连续因果效应估计方法. 对无人机作战效能的分析与优化是军事运筹与系统工程领域的经典问题, 而因果推断则为从观测数据中提取可靠决策知识提供了新兴且强大的理论工具.

2.1 无人机作战效能评估

随着人工智能、自主控制与网络通信技术的发展, 无人机已演变为具备察打一体、集群协同、智能决策能力的核心装备, 深刻改变了现代战争形态[1]. 在路径规划与协同作战方面, 车辆-无人机协同路径优化[11] 与时变风场下路径重规划[12] 等新技术不断涌现, 进一步拓展了其作战效能. 无人机以其无人员伤亡风险、长航时、低成本等优势, 在情报监视、精确打击、电子对抗等任务中作用关键[13-14]. 准确评估其作战效能, 是衡量任务完成程度、优化装备体系、支撑指挥决策的基础[15-16]. 作战效能是无人机效能体系的最高层次, 可细分为单项效能、系统效能与作战效能三层[3, 17]. 单项效能关注单一能力 (如侦察分辨率), 系统效能衡量平台内在综合能力, 而作战效能聚焦于实际战场环境下多因素耦合下达成任务目标的程度[4-5, 10].

然而, 精准评估面临严峻挑战. 无人机作战系统是人-机-环境复杂耦合系统, 受平台性能、载荷、数据链、人员、环境及对抗等多维非线性因素共同影响[18-19]. 传统方法如 ADC 模型[6]、层次分析法[7]、模糊综合评判[8] 等依赖专家经验或简化模型, 难以刻画动态复杂交互, 评估结果主观性强, 对新兴自主集群模式适应性不足[20-21]. 近年来, 海量多源异构数据累积, 为数据驱动量化分析提供了可能[22-23]. 现有机器学习方法 (如支持向量机[24]) 本质仍为关联预测, 在观测数据存在选择偏差时易混淆因果与相关关系, 导致有偏结论[2]. 因此, 引入因果推断理论, 构建从高维观测数据中稳健估计连续作战条件因果效应的框架, 对深化效能生成机理认识、提供量化决策依据具有重要理论与实践价值.

2.2 因果推断与连续因果效应估计

因果推断的核心目标是从观测性或实验性数据中识别干预对结果的纯净效应, 关键在于区分因果与关联, 为决策提供可靠依据[2]. 其现代理论体系主要构建于潜在结果模型 (RCM) 和结构因果模型 (SCM) 两大框架之上[25-26]. 在此背景下, 针对工业过程与时序数据的因果挖掘近年来受到关注[27-28], 但此类方法对领域知识的要求较高. 由于军事等实际场景中随机实验难以实施且缺少先验, 基于观测数据

的因果推断已成为主流范式[29-30]. 观测研究中主要面临反事实问题、混淆偏差与选择偏差三大挑战: 反事实问题源于无法同时观测同一对象在不同干预下的结果; 混淆偏差指同时影响干预与结果的混淆因素导致统计关联偏离真实因果; 选择偏差则因样本选取机制的系统性缺陷使组间不可比[31-33].

当干预变量为连续型 (如飞行高度) 时, 估计目标转变为剂量响应函数, 刻画干预水平连续变化对结果的动态影响[34]. 传统方法如广义倾向得分逆概率加权法在高维连续场景中易受模型设定偏差影响[35]. 近年来, 深度神经网络的因果表征学习为应对该难题提供了新思路[36-37], 通过将高维协变量映射到低维潜在表征空间以实现干预分配与潜在结果的近似独立. 代表性方法包括 DRNet(将连续值域离散化并训练子网络)[38]、VCNet(利用样条基函数输出平滑曲线)[39], 以及解耦表征学习方法 (将协变量分解为工具、混淆、调整因子以提升估计精度), 如 DTRNet 和 DRVAE 等[40-43].

然而, 现有方法大多将协变量视为扁平同质向量, 忽略了无人机任务分析中协变量天然具有的层次化、结构化特点, 难以有效剥离混淆效应并解释异质性来源. 因此, 本文旨在将领域知识融入因果表征学习框架, 针对军事数据的结构化特性设计更合理的模型架构, 以推动无人机作战任务规划从“经验驱动”向“因果驱动”范式转型, 为结构化军事决策问题提供新的分析工具.

3　问题描述与基本假设

本节旨在形式化地描述无人机海上侦察任务中连续作战条件的因果效应估计问题, 并阐述进行因果识别所需的基本假设. 本文遵循潜在结果框架, 将问题转化为对平均剂量响应函数与个体因果效应的估计, 并基于领域知识明确变量间的因果结构以指导后续建模.

3.1　问题描述

考虑一个包含N个独立同分布任务架次 (样本) 的观测数据集$\mathcal{D}=\{(\mathbf{x}_i,t_i,y_i)\}_{i=1}^N$. 其中:

- $\mathbf{x}_i\in\mathcal{X}\subseteq\mathbb{R}^m$为第$i$个样本的协变量向量, 包含了所有在干预变量赋值前可观测的作战条件特征, 可进一步结构化分解为装备状态、环境状态、人员状态与任务规划变量等子集.
- $t_i\in\mathcal{T}\subseteq\mathbb{R}$为连续型干预变量 (例如, 归一化后的侦照高度, $t_i\in[0,1]$).
- $y_i\in\mathcal{Y}\subseteq\mathbb{R}$为观测到的结果变量 (例如, 综合任务表现评分).

对于任意样本i与任意干预水平$t\in\mathcal{T}$, 存在一个潜在结果$y_i(t)$, 表示该样本若接受干预t时将产生的任务表现. 实际观测到的结果y_i是其在实际接受的干预t_i下对应的潜在结果, 即$y_i=y_i(t_i)$. 对于未实施的干预$t'\neq t_i$, 其对应的潜在结果$y_i(t')$是反事实且无法观测的.

本文的核心目标是估计以下两个因果量:

1) 平均剂量响应函数: 描述当总体中所有个体均被施加干预水平t时, 平均结果的期望值.

$$\psi(t):=\mathbb{E}[y(t)]. \tag{1}$$

2) 个体因果效应: 在给定个体协变量$\mathbf{x}$的条件下, 干预t对结果的期望影响.

$$\mu(t,\mathbf{x}):=\mathbb{E}[y(t)|\mathbf{X}=\mathbf{x}]. \tag{2}$$

通过对$\mu(t,\mathbf{x})$在t上积分或取期望, 可进一步得到个体层面的平均因果效应$\mu(\mathbf{x})=\mathbb{E}_t[\mu(t,\mathbf{x})]$.

从观测数据$\mathcal{D}$中估计$\psi(t)$和$\mu(t,\mathbf{x})$的主要挑战在于混淆偏差: 协变量$\mathbf{x}$同时影响干预分配t和潜在结果$y(t)$, 导致基于统计关联的直接估计 (如$\mathbb{E}[y|t]$) 并非真实的因果效应. 图 1 刻画了本文所考虑的变量间基本因果结构.

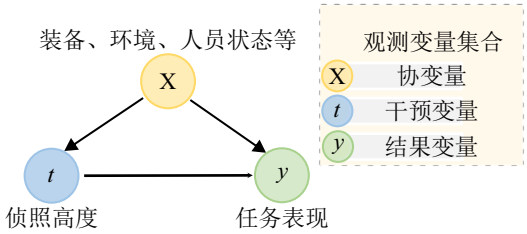

图 1　因果示意图

该图表明, $\mathbf{x}$是t和y的共同原因, 构成了后门路径$t\leftarrow\mathbf{x}\rightarrow y$. 若不控制$\mathbf{x}$, 则$t$与$y$的关联将混淆有$\mathbf{x}$的影响.

3.2　基本假设

为方便后续讨论, 记$\mathbf{X}$为协变量随机向量, T为干预随机变量, Y为观测结果随机变量, $Y(t)$为对应干预t的潜在结果随机变量. 所有观测样本$(\mathbf{x}_i,t_i,y_i)$均可视为这些随机变量的独立同分布实现. 为了能够从观测数据中一致地识别并估计因果量$\psi(t)$和$\mu(t,\mathbf{x})$, 必须满足以下三个基本假设:

假设 1 稳定单元值假设 (Stable Unit Treatment Value Assumption (SUTVA))　**1) 无干扰**: 任意样本的任务结果不受其他样本所接受侦照高度的影响; **2) 干预唯一性**: 每个侦照高度水平t对应唯一版本的干预. 这意味着对于样本i, 其潜在结果$y_i(t)$是明确定义的, 且仅取决于其自身的干预水平.

假设 2 可忽略性/无混淆性 (Ignorability /

Unconfoundedness) 给定所有观测到的协变量$\mathbf{x}$, 干预变量T与潜在结果$Y(t)$条件独立. 即,

$$Y(t) \perp\!\!\!\perp T \mid \mathbf{X}=\mathbf{x},\ \forall t \in \mathcal{T}. \tag{3}$$

此假设意味着协变量$\mathbf{x}$包含了所有同时影响T和Y的共同原因, 从而阻断了从T到Y的所有后门路径.

假设 3 正值性 (Positivity / Overlap) 对于任意可能的协变量取值$\mathbf{x} \in \mathcal{X}$和任意考虑的干预水平$t \in \mathcal{T}$, 在特征为$\mathbf{x}$的条件下被分配到$t$的概率为正. 即,

$$0 < p(T=t \mid \mathbf{X}=\mathbf{x}) < 1,\ \forall t \in \mathcal{T}, \forall \mathbf{x} \in \mathcal{X}. \tag{4}$$

此假设保证了对于具有任何特征组合$\mathbf{x}$的任务场景, 在理论上都有机会采用任意侦照高度t, 从而使得对$\psi(t)$的估计在整个定义域内有数据支撑.

上述假设在本文无人机海上侦察任务中可通过合理近似满足. 对于假设 1, 任务架次在时间、海域、无人机上完全分离, 结果互不影响, 且“侦照高度”为单一规划参数, 同一数值含义一致, 无干扰与干预唯一性自然成立; 对于假设 2, 有专家知识支撑时, 协变量基本覆盖需求, 未观测混淆的影响可近似接受; 对于假设 3, 在实际可行高度区间内, 各协变量组合下每个高度均有非零选择概率, 正值性近似成立. 三个近似共同保证了假设的基本成立.

在满足假设 1 和 2 的前提下, 平均剂量响应函数可以从观测数据中识别:

$$\psi(t) = \mathbb{E}[y(t)] = \mathbb{E}_{\mathbf{X}}\big[\mathbb{E}[y \mid T=t, \mathbf{X}=\mathbf{x}]\big]. \tag{5}$$

其中, 内层条件期望$\mathbb{E}[y \mid T=t, \mathbf{X}=\mathbf{x}]$即为$\mu(t,\mathbf{x})$. 假设 3 确保了这种条件化估计的可行性.

借助先进的机器学习方法, 在解耦表征学习的框架下, 从数据中学习满足或近似满足无混淆性的低维平衡表征, 从而实现对$\psi(t)$和$\mu(t,\mathbf{x})$的稳健估计. 是下一节所提出模型的核心设计动机.

4 模型方法

4.1 模型框架

针对高维结构化军事任务数据的连续因果效应估计问题, 提出连续剂量响应因果效应估计网络. 核心创新是将协变量$\mathbf{x}$解耦为三个统计独立的潜在因子: 工具因子Γ(仅影响干预)、混淆因子Δ(同时影响干预与结果)、调整因子Υ(仅影响结果). 通过积分概率度量约束确保因子满足因果识别条件, 并利用变系数网络估计剂量响应曲线. 模型框架如图 2 所示, 包含混合专家多头注意力解耦、IPM 正则化、条件密度预测网络及重加权与回归预测网络.

4.2 协变量解耦: 混合专家多头注意力模块

为从高维协变量$\mathbf{x}$中提取因果语义清晰的潜在表征, 本文设计了混合专家多头注意力模块. 该模块首先通过K个独立的专家网络提取初级特征矩阵$\mathbf{H}=[\mathbf{h}_1,\ldots,\mathbf{h}_K]^\top \in \mathbb{R}^{K\times e}$. 随后, 为整合不同专家网络的信息, 将$\mathbf{H}$输入一个多头注意力层. 具体地, 对于第$m$个头, 通过线性投影生成查询、键和值: $\mathbf{Q}_m=\mathbf{H}\mathbf{W}_m^Q, \mathbf{K}_m=\mathbf{H}\mathbf{W}_m^K, \mathbf{V}_m=\mathbf{H}\mathbf{W}_m^V$, 然后计算缩放点积注意力$\mathrm{head}_m$.

所有头的输出拼接后经线性投影得到最终表征:

$$\mathbf{Z} = \mathrm{MultiHead}(\mathbf{H}) = \mathrm{Concat}(\mathrm{head}_1,\ldots,\mathrm{head}_M)\mathbf{W}^O. \tag{6}$$

其中, $\mathbf{W}^O$是一个可学习的线性投影权重矩阵, 其作用是将多个注意力头输出的拼接特征整合并映射到目标维度, 从而融合不同注意力头捕获的多样化信息模式. 注意力层的输出$\mathbf{Z}$被送入三个独立的线性投

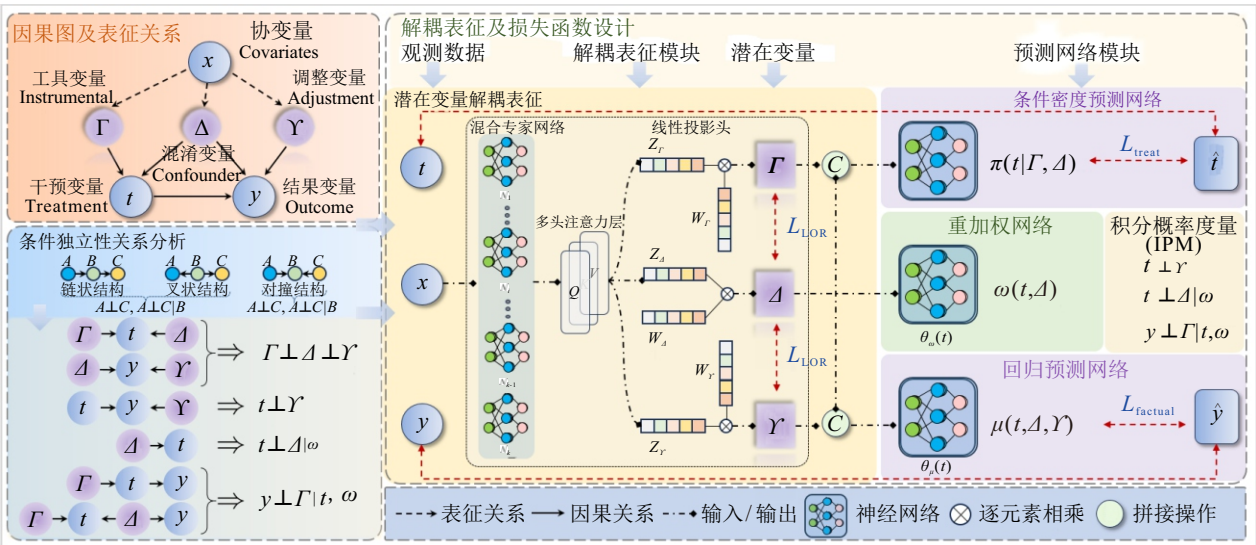

图 2 模型基本框架

影头, 分别生成三个潜在因子的初始表示$\mathbf{z}_\Gamma, \mathbf{z}_\Delta, \mathbf{z}_\Upsilon$.

为促进潜在因子之间的解耦, 本文引入正交正则化. 为每个因子配备一个可学习的调制向量$\mathbf{w}_\Gamma, \mathbf{w}_\Delta, \mathbf{w}_\Upsilon$, 并通过在损失函数中添加项$\mathcal{L}_{orth} = \sum_{i \neq j} |\mathbf{w}_i^\top \mathbf{w}_j|^2$来约束它们彼此正交. 最终, 解耦后的潜在因子通过逐元素调制得到:

$$\Gamma = \mathbf{z}_\Gamma \odot \mathbf{w}_\Gamma,\ \Delta = \mathbf{z}_\Delta \odot \mathbf{w}_\Delta,\ \Upsilon = \mathbf{z}_\Upsilon \odot \mathbf{w}_\Upsilon. \quad (7)$$

其中, $\odot$表示逐元素乘法. 正交约束迫使各调制向量关注不同的特征维度, 从而辅助实现表征的解耦.

4.3 条件密度预测网络

根据图 2 左侧所示的因果结构, 干预变量t由其父节点工具因子Γ和混淆因子Δ共同决定. 为建模干预分配机制并修正混淆偏差, 本文构建一个条件密度预测网络π, 用于估计给定Γ和Δ时t的条件概率密度: $\pi(t|\Gamma, \Delta) \approx p(t|\Gamma, \Delta)$.该网络以拼接后的$[\Gamma; \Delta]$为输入. 对于连续干预变量$t \in [0, 1]$, 本文采用网格化密度估计器: 将$t$的值域$[0, 1]$均匀划分为$B$个区间, 在$B+1$个网格点上估计条件概率, 并通过线性插值获得任意$t$值的密度.

基于估计的条件密度, 可计算广义倾向得分$g(t|\mathbf{x}) = \pi(t|\Gamma, \Delta)$, 进而得到逆概率权重$\omega_i^{\text{IPW}} = 1/g(t_i|\mathbf{x}_i)$. 然而, 在高维混淆下, 仅使用 IPW 可能方差较大. 为此, 本文引入一个可学习的重加权网络来优化权重.

4.4 重加权网络

为实现混淆因子Δ的平衡, 本文设计一个重加权网络$\omega(t, \Delta)$. 该网络以干预变量t和混淆因子Δ为输入, 输出一个样本级的权重调整因子. 为防止高维的Δ淹没t的影响, 这里选择引入变系数网络 (Varying-Coefficient Network)[39] 来构建该网络:

$$\omega(t, \Delta) = f_{\theta_\omega(t)}(\Delta), \quad (8)$$

其中, $f_{\theta_\omega(t)}$是一个多层感知机, 其参数$\theta_\omega(t)$是干预变量t的函数. 这意味着网络的结构根据t的值动态调整, 能更精细地刻画t与Δ的交互对权重的影响. 最终, 样本i的平衡权重为:

$$\omega_i = \omega(t_i, \Delta(\mathbf{x}_i)) \cdot \omega_i^{\text{IPW}}. \quad (9)$$

该权重将用于后续的独立性约束与效应估计, 其训练通过整体损失函数中的相关项间接优化.

4.5 回归预测网络

在混淆因子得到平衡的前提下, 个体剂量响应函数$\mu(t, \mathbf{x}) = \mathbb{E}[y|do(T=t), \mathbf{x}]$的估计可简化为对条件期望$\mathbb{E}[y|t, \Delta, \Upsilon]$的建模. 为此, 同样构建一个变系数效应估计网络$\mu(t, \Delta, \Upsilon)$. 该网络以干预变量$t$、混淆因子$\Delta$和调整因子$\Upsilon$为输入, 动态生成对结果变量$y$的预测:

$$\hat{y} = \mu(t, \Delta, \Upsilon) = f_{\theta_\mu(t)}([\Delta; \Upsilon]). \quad (10)$$

其中, $f_{\theta_\mu(t)}$同样是一个参数随t变化的变系数多层感知机. 其参数化方式与重加权网络一致: $\theta_\mu(t) = \sum_{j=1}^{J} \mathbf{W}_j^\mu \phi_j(t)$.

这种设计使得网络能够灵活捕捉干预变量t与潜在因子之间复杂的非线性交互效应, 同时保证估计的剂量响应曲线随t连续且平滑.

4.6 独立性约束: 积分概率度量正则化

解耦表征需满足因果推断中的条件独立性假设, 才能保证后续效应估计的无偏性. 为此, 本文引入了基于最大均值差异 (Maximum Mean Discrepancy, MMD) 的积分概率度量 (Integral Probability Metric, IPM) 约束:

1) 干预变量与调整因子独立性 ($t \perp \Upsilon$). 该约束确保调整因子Υ不包含影响干预分配的信息. 对应的损失函数为:

$$\mathcal{L}_{\text{IPM}}^{t \perp \Upsilon} = \text{MMD}(P(\Upsilon|t), P(\Upsilon)). \quad (11)$$

2) 给定权重因子下干预变量与混淆因子条件独立性 ($t \perp \Delta|\omega$). 该约束确保在倾向权重ω调整后, 混淆因子Δ的分布在各干预组间达到平衡. 对应的损失函数为:

$$\mathcal{L}_{\text{IPM}}^{t \perp \Delta|\omega} = \text{MMD}(P(\Delta|t, \omega), P(\Delta|\omega)). \quad (12)$$

3) 给定干预变量和权重因子下结果变量与工具因子条件独立性 ($y \perp \Gamma|t, \omega$). 该约束确保工具因子Γ仅通过干预t影响y. 对应的损失函数为:

$$\mathcal{L}_{\text{IPM}}^{y \perp \Gamma|t, \omega} = \text{MMD}(P(\Gamma|y, t, \omega), P(\Gamma|t, \omega)). \quad (13)$$

实践中, 为提高计算效率, 本文采用分组 IPM 计算方式, 将数据按干预值排序后分组, 计算组间 MMD 的最大值作为约束损失.

4.7 损失函数构造

模型的总损失函数为各组件损失的加权和, 具体定义如下:

1) 线性正交正则化损失: 强制三个潜在因子权重向量的正交性, 确保解耦的彻底性.

$$\mathcal{L}_{\text{LOR}} = (\tilde{\mathbf{w}}_\Gamma \cdot \tilde{\mathbf{w}}_\Delta)^2 + (\tilde{\mathbf{w}}_\Gamma \cdot \tilde{\mathbf{w}}_\Upsilon)^2 + (\tilde{\mathbf{w}}_\Delta \cdot \tilde{\mathbf{w}}_\Upsilon)^2, \quad (14)$$

其中, $\tilde{\mathbf{w}}_{(\cdot)} = \mathbf{w}_{(\cdot)}/\|\mathbf{w}_{(\cdot)}\|_2$为归一化后的权重向量.

2) 干预预测损失: 衡量模型对干预分配机制的建模能力, 采用负对数似然损失.

$$\mathcal{L}_{\text{treat}} = -\frac{1}{N} \sum_{i=1}^{N} \log \pi(t_i|\Gamma(\mathbf{x}_i), \Delta(\mathbf{x}_i)). \quad (15)$$

其中, $\pi(t_i|\Gamma(\mathbf{x}_i),\Delta(\mathbf{x}_i)$为协变量对应的条件密度预测网络, 该网络通过最小化负对数似然损失进行训练.

3) 事实结果预测损失: 衡量模型对观测结果y的预测精度, 采用均方误差.

$$\mathcal{L}_{\text{factual}}=\frac{1}{N}\sum_{i=1}^{N}(y_i-\mu(t_i,\Delta(\mathbf{x}_i),\Upsilon(\mathbf{x}_i)))^2. \quad (16)$$

其中, $\mu(t_i,\Delta(\mathbf{x}_i),\Upsilon(\mathbf{x}_i))$为模型对第$i$个样本的预测结果.

4) IPM 约束损失: 确保解耦表征满足因果推断的条件独立性假设, 由三个 MMD 损失组成.

$$\mathcal{L}_{\text{IPM}}=\mathcal{L}_{\text{IPM}}^{t\perp\Upsilon}+\mathcal{L}_{\text{IPM}}^{t\perp\Delta|\omega}+\mathcal{L}_{\text{IPM}}^{y\perp\Gamma|t,\omega}. \quad (17)$$

模型的总损失函数定义为以上各项损失的加权和:

$$\mathcal{L}_{\text{total}}=\alpha\mathcal{L}_{\text{factual}}++\beta\mathcal{L}_{\text{treat}}+\gamma\mathcal{L}_{\text{IPM}}+\lambda\mathcal{L}_{\text{LOR}}, \quad (18)$$

其中, $\alpha,\beta,\gamma,\lambda$为超参数, 通过交叉验证确定其最优值, 用于平衡模型在不同任务上的学习目标.

4.8 模型训练

CDDRN 模型的训练通过联合优化总损失函数$\mathcal{L}_{\text{total}}$实现. 算法 1 描述了对应的端到端训练流程.

算法1 CDDRN模型训练算法

输入: 数据集$\mathcal{D}=\{(\mathbf{x}_i,t_i,y_i)\}_{i=1}^N$; 超参数$\alpha,\beta,\gamma,\lambda$; 学习率$\eta$; 最大轮数$E$

输出: 训练好的模型参数Θ

初始化参数Θ;

for *epoch* $=1$ **to** E **do**

  随机打乱数据集$\mathcal{D}$;

  for 每个小批量$\mathcal{B}\subset\mathcal{D}$ **do**

    前向传播: 生成潜在因子Γ,Δ,Υ;

    训练三类预测网络$\pi(t|\Gamma,\Delta),\omega(t,\Delta),\mu(t,\Delta,\Upsilon)$;

    计算各损失项: $\mathcal{L}_{\text{factual}},\mathcal{L}_{\text{treat}},\mathcal{L}_{\text{IPM}},\mathcal{L}_{\text{LOR}}$;

    总损失: $\mathcal{L}_{\text{total}}=\alpha\mathcal{L}_{\text{factual}}+\beta\mathcal{L}_{\text{treat}}+\gamma\mathcal{L}_{\text{IPM}}+\lambda\mathcal{L}_{\text{LOR}}$;

    反向传播更新参数: $\Theta\leftarrow\Theta-\eta\nabla_\Theta\mathcal{L}_{\text{total}}$;

  if: 满足早停条件**then**

    break;

return Θ;

算法 1 通过小批量梯度下降联合优化所有损失项. 模型同时学习解耦表征、平衡权重与剂量响应函数, 最终获得能够进行无偏因果效应估计的稳健模型.

5 实验设计与方法有效性验证

为验证本文所提出的 CDDRN 模型在军事复杂场景下的科学性与有效性, 本节聚焦具体问题, 以某型大型长航时侦察无人机执行海上目标侦察任务为背景, 开展有效性验证. 首先, 阐述军事需求, 详细介绍基于脱密数据构建的半合成数据集; 其次, 列出用于对比的基线模型; 最后, 通过对比实验, 验证模型在估计侦照高度对任务表现因果效应上的优越性能.

5.1 军事需求与数据集构建

5.1.1 军事需求分析

现代海战场上, 大型长航时侦察无人机是实现广域态势感知的核心装备, 其任务表现关系决策时效性与准确性. 侦照高度作为连续变量, 探究最优值对最大化侦察效能与飞行安全有重要军事意义. 然而, 受限于装备成本与战场环境, 无法随机对照试验; 传统关联分析难以剥离机型、任务类型、气象等混淆因素, 结论易偏倚. 伴随无人机广泛应用, 已积累海量多维任务数据. 以数据驱动精准量化侦照高度的因果效应并解析其异质性差异, 既是提升装备科学化与智能化的需求, 也是因果推断与军事管理交叉创新的尝试.

5.1.2 变量说明

本研究数据来源于国内某型无人机执行海上目标侦察任务的历史记录. 经脱敏与清洗后, 共获取若干任务架次的有效观测, 任务时间跨度覆盖多个月份, 涵盖了不同海域、季节与气象条件. 参照专家经验与数据可用性, 本文构建了如表 1 所示的变量体系, 用于全面刻画每个任务架次的特征.

变量按照其性质分为基础信息、装备特征、环境变量、席位人员、飞行参数、任务复杂度、情报数据、干预变量及结果变量. 其中, 基础信息与席位人员为文本型标识变量, 仅用于记录与索引, 不含有效数值信息, 因此不作为协变量. 装备特征中的无人机型号与载荷类型亦为名义分类变量, 同样剔除. 其余变量均为数值型或有序分类变量, 具备明确的量纲或等级顺序, 能够反映任务中客观的作战条件, 故作为协变量纳入模型, 以控制不同任务架次间作战条件的差异对干预效果估计的混淆影响. 核心的干预变量为侦照高度 (t, 米), 表示任务中实施侦察探测的平均飞行高度; 结果变量为任务表现 (y, 归一化分数), 由任务完成后综合评估得出. 所有协变量、干预变量与结果变量构成了本研究中半合成数据集的变量基础.

5.1.3 半合成数据生成机制

为构建可定量评估模型性能的数据集, 本文设计了一套半合成数据生成机制. 该机制模拟指挥员决策过程, 构建具有清晰因果结构的任务表现模型,

表 1　合成数据变量说明

类别	变量名称与描述
基础信息	x_0: 任务ID(文本型)
	x_1: 日期时间(文本型)
	x_2: 起飞机场(机场代号A、B、C, 名义分类)
	x_3: 任务海域(1～5号海域, 名义分类)
	x_4: 任务类型(常规任务、重点侦察、应急响应, 名义分类)
装备特征	x_5: 无人机型号(I型、II型、III型, 名义分类)
	x_6: 服役年限(年, 连续型)
	x_7: 最近大修时间(天, 连续型)
	x_8: 载荷类型(光/雷复合型、光电、雷达、电子侦察, 名义分类)
环境变量	x_9: 能见度(1～5级, 有序分类)
	x_{10}: 海况(1～6级, 有序分类)
	x_{11}: 云层覆盖率(0%～100%, 连续型)
	x_{12}: 气温(℃, 连续型)
	x_{13}: 湿度(相对湿度%, 连续型)
	x_{14}: 风速(m/s, 连续型)
	x_{15}: 电磁环境指数(1～10级, 有序分类)
席位人员	x_{16}: 飞行控制员ID(文本型)
	x_{17}: 任务规划员ID(文本型)
	x_{18}: 情报判读员ID(文本型)
飞行参数	x_{19}: 发动机转速(RPM, 连续型)
	x_{20}: 滑油温度(℃, 连续型)
	x_{21}: 滑油压力(Bar, 连续型)
	x_{22}: 真空速(km/h, 连续型)
	x_{23}: 指示空速(km/h, 连续型)
	x_{24}: 天向加速度(m/s², 连续型)
	x_{25}: 横滚角变化频数(离散整数)
	x_{26}: 俯仰角标准差(连续型)
	x_{27}: 航向保持误差(°, 连续型)
任务复杂度	x_{28}: 预设航点数(离散整数)
	x_{29}: 海域威胁等级(1～4级, 有序分类)
	x_{30}: 通信中断次数(离散整数)
	x_{31}: 需规避目标数(离散整数)
情报数据	x_{32}: 侦察获目标数量(离散整数)
干预变量	t: 侦照高度(米, 连续型, 干预变量)
结果变量	y: 任务表现(归一化分数, 连续型, 结果变量)

为因果效应估计提供“真实值”. 由于保密要求, 数据集数值设定不符现实 (例如飞行高度低于 50 米). 该机制仅为研究因果机制, 与装备实际使用无关.

假设拥有N个独立同分布的任务样本, 每个样本包含高维协变量$\mathbf{x}$、干预变量 (侦照高度t) 与结果变量 (任务表现y). 数据生成过程严格遵循第 3 节中的基本假设, 并显式建模了协变量$\mathbf{x}$对干预t和结果y的复杂影响.

1) 干预变量t的生成: 模拟指挥员根据任务情境 ($\mathbf{x}$) 决策高度的过程. 该过程引入了选择偏差, 即t与$\mathbf{x}$相关, 构成了后续因果识别需要克服的混淆偏差.

$$t|\mathbf{x} \sim \mathrm{LogNormal}(\mu_t(\mathbf{x}), \sigma_t^2) \tag{19}$$

其中, 均值函数$\mu_t(\mathbf{x}) = \beta_0 + \boldsymbol{\beta}^T\phi(\mathbf{x})$, $\phi(\cdot)$为一个非线性特征映射函数, 将原始协变量$\mathbf{x}$映射为影响高度决策的特征. 参数$\beta_0, \boldsymbol{\beta}$的设定使得性能更优的机型、更复杂的任务倾向于被分配更高的侦照高度, 从而在数据中构造出真实的混淆关系.

2) 结果变量y的生成: 综合反映侦照高度、装备性能、环境、人员等多因素影响. 其生成公式明确分离了干预变量与协变量效应:

$$y = f(t, \mathbf{x}_s) \cdot g(\mathbf{x}_c) + \epsilon,\ \epsilon \sim \mathcal{N}(0, \sigma_y^2) \tag{20}$$

其中, $f(t, \mathbf{x}_s)$为**结构化因果效应函数**, 模拟侦照高度t与关键协变量子集$\mathbf{x}_s$(如机型、载荷类型) 交互产生的非线性、异质性干预效应. 具体形式采用高斯函数, 以模拟“存在机型/载荷相关的最优高度”这一领域知识:

$$f(t, \mathbf{x}_s) = \alpha_0 + \alpha_1(\mathbf{x}_s) \cdot \exp(-\frac{(t - \mu(\mathbf{x}_s))^2}{2\sigma(\mathbf{x}_s)^2}). \tag{21}$$

这里, $\mu(\mathbf{x}_s)$和$\sigma(\mathbf{x}_s)$是根据$\mathbf{x}_s$取值设定的参数. 例如, 为 I 型机设定更高的最优高度μ, 为光电载荷设定更窄的有效高度区间σ. α_0和$\alpha_1(\cdot)$为调节系数, 确保$f(\cdot)$的输出在合理范围内.

$g(\mathbf{x}_c)$为**协变量直接效应函数**, 表示除干预变量外, 其他协变量$\mathbf{x}_c$对任务表现的直接影响. 这里将其建模为多个子因子O_i的线性组合, 每个子因子对应一类作战条件, 并通过归一化处理保证数值稳定性:

$$g(\mathbf{x}_c) = \gamma_0 + \gamma_1 \prod_{i=1}^{6} O_i(\mathbf{x}_c). \tag{22}$$

各子因子O_i模拟了不同维度的影响:

$$\begin{cases} O_1 \propto \text{气象条件影响 (能见度、云层、风速)}, \\ O_2 \propto \text{人员经验影响 (各席位人员的等级)}, \\ O_3 = I(\text{服役年限} \leqslant 10\text{且距大修} \leqslant 90), \\ O_4 \propto (1 - \eta_1 \cdot \text{威胁等级} - \eta_2 \cdot \text{通信中断次数}), \\ O_5 \propto (1 - \eta_3 \cdot \text{飞行姿态稳定性指标}), \\ O_6 \propto (1 + \eta_4 \cdot \text{侦察获目标数量}). \end{cases} \tag{23}$$

其中, 函数$I(\cdot)$为示性函数, η_i为权重参数. 所有O_i均通过$\mathrm{clamp}(a, b, c) = \max(b, \min(a, c))$函数将其输出限制在合理区间, 以避免极端值.

ϵ为均值为零、方差为σ_y^2的随机噪声项, 代表未建模的随机因素.

与上文一致, 以上所用到的所有系数均为合理数值区间内的随机生成值, 无法反映装备应用的真实情况.

在上述机制的基础上, 植入了预设的、可解析的因果效应$f(t,\mathbf{x}_s)$. 因此, 可以精确计算出任何干预高度t下的真实平均剂量响应$\psi_{\text{true}}(t)=\mathbb{E}_{\mathbf{X}}[f(t,\mathbf{x}_s)\cdot g(\mathbf{x}_c)]$, 以及给定$\mathbf{x}$下的条件平均因果效应$\mu_{\text{true}}(t,\mathbf{x})$. 本研究基于真实数据, 应用此生成机制, 生成了对应的半合成数据集用于后续实验.

5.2 实验设置

CDDRN 模型的主要超参数设置如下: 隐藏层维度$h_{\text{hidden}}=64$, 潜在因子维度$d_{\text{expert}}=1024$, 专家网络数量$K=3$, 多头注意力头数$M=4$, 干预变量分箱数$B=80$, 丢弃率 dropout $=0.2$, IPM 分组数$k=10$, RBF 核参数$\sigma=1.0$. 每个专家网络由两层全连接组成, 每层后接批归一化、GELU 激活和 Dropout; 重加权网络为三层全连接, 激活函数为 Sigmoid; 变系数效应估计网络中的基网络为两层全连接, 系数网络为三层全连接, 最终输出层为单层全连接. 总损失函数中的加权系数通过初步网格搜索确定, 具体取值为$\alpha=1.0$、$\beta=1.0$、$\gamma=1.0$、$\lambda=1.0$.

模型使用 Adam 优化器训练, 初始学习率为 0.001, 权重衰减为0.0001. 采用阶梯式学习率衰减策略, 每 100 个轮次将学习率乘以 0.95. 批大小为 256, 总训练轮数为 300. 梯度裁剪阈值设为 1.0.

所有实验在配备 NVIDIA GPU L40 的服务器上进行, 操作系统为 Ubuntu 22.04, 深度学习框架为 PyTorch 1.13.1.

5.3 基线模型

为全面评估本文所提 CDDRN 模型的性能, 本文选取了以下三类代表性的基线模型进行对比实验. 这些模型涵盖了从传统回归、经典因果推断到前沿深度因果估计的广泛谱系, 确保了对比的全面性.

基于回归的传统预测模型: 此类模型旨在直接建立从协变量$\mathbf{x}$和干预变量t到结果y的映射函数$\hat{y}=h(\mathbf{x},t)$, 其优化目标为最小化预测误差, 而非直接估计因果效应. 无法显式控制混淆偏差, 但其预测性能可作为因果效应估计任务的基础参照.

- **广义加性模型 (Generalized Additive Model, GAM)**: 假设结果可表示为各特征平滑函数的和, $\mathbb{E}[y]=\beta_0+\sum f_j(x_j)+f_t(t)$.
- **线性回归 (Linear Regression, LR)** 与正则化变体: 包括 **Lasso 回归**与**岭回归 (Ridge Regression)**. 它们在 LR 模型$\mathbb{E}[y]=\beta_0+\boldsymbol{\beta}^T\mathbf{x}+\beta_t t$的基础上, 分别引入 L1 或 L2 正则化以应对高维特征与共线性, 是稳健的线性基准.
- **支持向量回归 (Support Vector Regression, SVR)**: 通过核函数将数据映射到高维空间进行线性回归.

基于统计的因果效应估计方法: 基于因果推断理论框架设计, 旨在通过显式建模干预分配机制或平衡协变量分布来估计因果效应.

- **因果森林 (Causal Forest, CF)** [43]: 基于随机森林的通用非参数方法. 通过构建专注于异质性因果效应估计的树, 并对样本进行加权, 从而估计条件平均因果效应.
- **基于广义倾向得分的匹配 (Generalized Propensity Score Matching, GPS)**: [44] 将二元干预下的倾向得分推广至连续型干预场景. 首先估计给定协变量下干预变量的条件密度 (广义倾向得分), 根据得分对样本进行匹配或加权, 以平衡协变量分布, 进而估计剂量响应函数.

基于神经网络的因果效应估计方法: 结合深度学习强大表征能力与因果推断框架的一类方法.

- **TARNet** [45]: 核心思想是学习一个共享的基线表征, 然后为干预组和对照组分别配备独立的输出头, 以估计异质性因果效应.
- **DRNet** [38]: 将干预变量的值域划分为多个区间, 为每个区间训练一个独立的子网络来预测该区间内的结果.
- **VCNet** [39]: 在 DRNet 的基础上加入变系数网络结构, 使网络参数成为干预变量t的平滑函数, 从而直接输出连续、平滑的$\mu(t,\mathbf{x})$估计.

5.4 模型对比与结果分析

为定量评估各模型在连续因果效应估计任务上的性能, 本文采用均方误差 (Mean Squared Error, MSE) 核心评估指标, 以衡量各模型对合成数据中结果变量y的估计误差. 在测试集上, 输入协变量$\mathbf{x}$和干预值t, 计算模型预测的$\hat{y}$与真实值y之间的 MSE 值. 实验基于 4.1 节的生成机制生成了 1 200 架次的飞行数据, 采取随机训练/测试划分 (80%/20%) 的方式进行 10 次重复实验, 最终报告各模型 MSE 的均值与标准差, 以评估其估计精度与稳健性.

表 2 展示了本文提出的 CDDRN 模型基线模型在半合成数据集上的 MSE 对比结果. 分析结果, 可以得出以下结论:

首先, 传统回归模型整体估计误差较高, 未显式建模混淆偏差, 受选择偏差影响显著, 在高维强混淆数据下存在明显局限性. 其次, 统计学因果推断方法整体优于传统模型: 因果森林 (CF) 通过自适应分组

表 2　不同模型的估计误差 (MSE) 对比

模型	MSE (均值 ± 标准差)
GAM	59.564 ± 4.785
Linear Regression	47.540 ± 4.746
Lasso Regression	74.839 ± 4.160
Ridge Regression	48.621 ± 4.835
SVR	40.990 ± 3.679
Causal Forest (CF)	38.085 ± 1.915
GPS Matching	45.480 ± 3.911
TARNet	102.654 ± 7.275
DRNet	102.277 ± 7.262
VCNet	35.692 ± 5.547
CDDRN (Ours)	$\mathbf{34.690 \pm 1.116}$

部分缓解混淆偏差, MSE(38.085 ± 1.915) 显著低于传统模型; 广义倾向得分匹配 (GPS) 依赖条件密度正确设定, 表现略逊于 CF(45.480 ± 3.911). 再次, 深度神经网络因果模型凭借非线性表征能力取得更优性能: TARNet 与 DRNet 表现欠佳 (约102.6), VCNet 通过平滑样条基函数实现最佳基线性能 (35.692±5.547). 最后, 本文 CDDRN 模型取得所有方法中的最佳性能, MSE($\mathbf{34.690 \pm 1.116}$) 低于 VCNet 且标准差最小, 验证了其在高维混淆连续因果效应估计中的有效性与优越性.

5.5　消融实验

为系统性地评估 CDDRN 模型中各核心组件的贡献, 本节设计了消融实验. 实验设置对应模型方法中协变量解耦模块、回归预测网络、IPM 独立性约束以及条件密度预测网络结构四个关键组件的消融. 需说明的是, 重加权网络作为实现混淆因子平衡的基础模块, 是其余各网络的共同前提, 在此不做单独解耦消融. 通过逐一移除或替换上述目标组件, 共构建了五个消融变体, 并在与前文一致的半合成数据集上进行评估. 实验结果如表 3 所示.

表 3　CDDRN 模型消融实验结果

解耦模块	条件密度网络	回归网络	IPM约束	MSE (均值±标准差)
√	√	√	√	$\mathbf{34.690 \pm 1.116}$
√		√	√	37.604 ± 5.722
√	√		√	1726.499 ± 46.748
√	√	√		38.816 ± 1.749
MLP	√	√	√	35.306 ± 2.648
Transformer	√	√	√	86.287 ± 8.494

从表 3 的数据可以看出, 移除回归预测网络导致 MSE 飙升至 1 726.499, 验证了变系数回归网络在估计剂量响应函数中的核心地位. 移除条件密度预测模块或停用 IPM 约束后, MSE 分别升至 37.604 和 38.816, 表明对混淆平衡模块进行训练并施加独立性约束, 对于缓解混淆偏差、提升估计精度具有重要意义. 此外, 以 MLP 替代混合专家多头注意力模块导致性能略有下降 (MSE 为 35.306), 而以 Transformer 编码器替代则使 MSE 大幅升至 86.287, 证明本文设计的混合专家多头注意力机制在学习结构性因果表征方面具有明显优势. 综上, 消融实验充分证明了 CDDRN 各核心组件设计的必要性与有效性, 核心组件共同实现了对因果效应的精确估计.

6　案例分析

上节已详细验证了本文所提出方法的有效性, 本节在上节的基础上, 进一步开展案例研究. 首先, 分析侦照高度对无人机任务表现的平均因果效应; 其次, 通过划分不同作战条件子群, 揭示侦照高度在不同作战条件子群体中的异质性因果效应; 最后, 根据所得到的结果, 提出相应的决策建议. 出于保密要求, 本案例研究同样基于合成数据集开展, 仅为了证明方法在应用层面能够提供一定的建议参考, 所绘制的曲线在趋势上并不反映现实情况, 所得出的系列结论与装备的实际应用并不相符.

6.1　侦照高度平均因果效应分析 $E[\psi(t)]$

通过分析侦照高度-任务表现的平均剂量响应曲线 (Average Dose-Response Function, ADRF), 可以理解侦照高度对任务表现的总体影响规律. 这里将连续型变量侦照高度 t 视为干预变量, 将无人机侦察任务完成情况 y 视为结果变量, 应用本文提出的 CDDRN 模型进行估计.

图 3 展示了应用模型估计得到的群体因果效应曲线 $\psi(t)$. 其中, 横轴表示干预变量 t, 即侦照高度 (米); 纵轴表示因果效应值, 即当侦照高度干预为 t 时, 无人机侦察任务表现的群体平均值 (百分制). 曲线上方子图给出了原始数据中侦照高度的分布情况. 对其进行分析后, 可以得到结论如下:

结论 1: 侦照高度对无人机任务表现的影响具有显著的非线性特征, 存在明确的最优侦照高度.

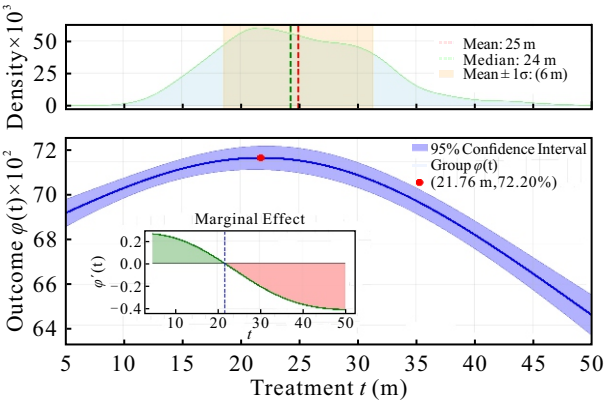

图 3　侦照高度对无人机侦察任务表现的因果效应曲线

从图 3 可以看出, 因果效应曲线呈现明显的“先上升、后下降”的单峰形态. 当侦照高度较低时 (如低于 15 米), 曲线呈快速上升趋势. 这表明在该区间内, 适当提升侦照高度可显著提升任务完成质量与效率. 曲线在$t = \mathbf{21.75}$**米**处达到峰值, 此时对应的最佳任务表现约为 **72.20%**, 此高度可视为群体层面的最优侦照高度. 当侦照高度超过最优值后, 曲线转为下降趋势. 可能由于过高的侦照高度会导致目标成像分辨率下降、信号传输延迟增加, 或受高空气象因素干扰增强, 对任务表现产生负向影响. 该结论从数据驱动的角度, 量化验证了军事实践中关于侦照高度存在“最佳区间”的经验认知.

6.2 作战条件的群体异质性分析

平均因果效应$\psi(t)$与个体效应$\psi(x)$的分析表明, 侦照高度的影响存在显著的异质性. 本小节进一步按作战条件 (机型、任务类型、载荷类型、起飞机场) 划分子群体, 分别估计各子群内的因果效应曲线$\psi(t|x)$, 以揭示群体异质性.

6.2.1 机型异质性分析

为了分析机型的影响, 将所有样本按机型划分为 I 型、II 型、III 型三个子群. 图 4(a) 展示了各机型子群的异质性因果效应曲线. 对其进行分析后, 可以得到结论如下:

结论 2: 机型是影响最优侦照高度与任务表现的核心因素, I 型无人机性能最优.

如图 4(a) 所示, 不同机型的因果效应曲线形态相似, 但峰值位置与高度存在显著差异. I 型无人机的最优侦照高度最高 (约 **30.04 米**), 且在此高度下能达到最佳任务表现 (**80.82%**). II 型和 III 型无人机的最优高度较低且基本一致 (均约 **25.33 米**), 对应的最佳任务表现也依次递减. 这表明 I 型无人机适合在更高空域执行侦察, 以获得更广的覆盖范围. 且 I 型无人机对侦照高度的适应性更强, 在较宽的高度范围内也能保持较好的任务表现.

6.2.2 任务类型异质性分析

为了分析任务类型的影响, 将所有样本按任务类型划分为常规任务、重点侦察、应急响应三个子群. 图 4(b) 展示了各任务类型子群的异质性因果效应曲线. 对其进行分析后, 可以得到结论如下:

结论 3: 不同任务类型的最优侦照高度策略不同, 需差异化调整.

图 4(b) 中按任务类型 (常规任务、重点侦察、应

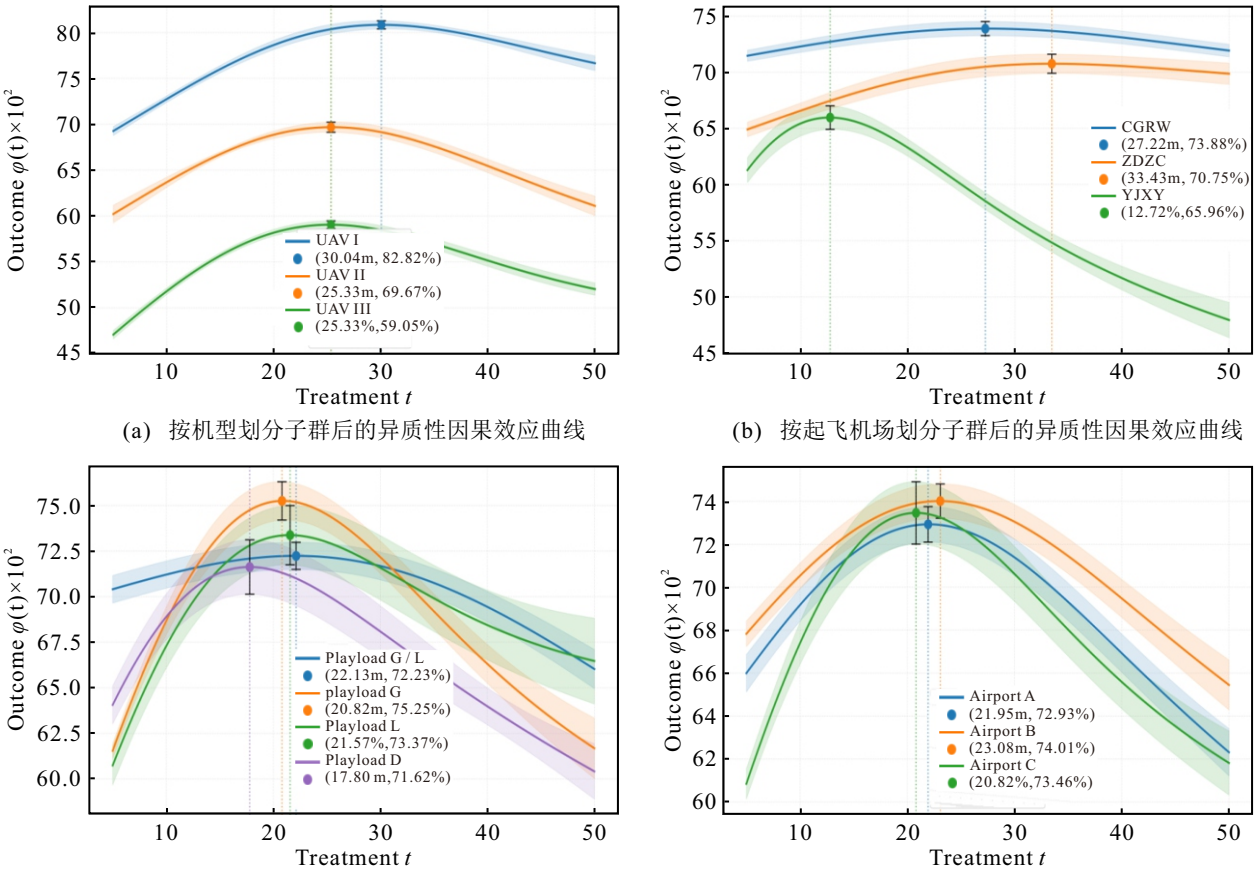

(a) 按机型划分子群后的异质性因果效应曲线

(b) 按起飞机场划分子群后的异质性因果效应曲线

(c) 按载荷类型划分子群后的异质性因果效应曲线

(d) 按起飞机场划分子群后的异质性因果效应曲线

注: 图中的曲线变化趋势基于合成数据, 不反映现实情况

图 4 异质性因果效应曲线

急响应)进行划分, “CGRW”表示常规任务、“ZDZC”表示重点侦察、“YJXY”表示应急响应. 常规任务与重点侦察任务均存在明确的最优侦照高度, 分别约为 **27.21 米**和 **33.43 米**. 常规任务中, 稍低的高度有助于平衡覆盖范围与识别精度; 重点侦察任务一般需要进行长时观察, 较高的侦照高度可以确保隐蔽性, 减少操作人员的操作压力. 应急响应任务的曲线呈现先增后降趋势, 且任务完成的适合高度区间相对较窄且处于较低高度, 表明在保障飞行安全的前提下, 应尽量降低侦照高度以提升响应速度与侦察清晰度.

6.2.3 载荷类型异质性分析

为了分析载荷类型的影响, 将所有样本按主要载荷类型划分为光电载荷、雷达载荷、光/雷复合载荷等子群. 图 4(c) 展示了各载荷类型子群的异质性因果效应曲线. 图中四种载荷类型对应的曲线分别标记为 Playload G/L、Playload G、Playload L、Playload D, 其中, 光/ 雷表示光电和雷达的复合型载荷. 对其进行分析后, 可以得到结论如下:

结论 4: 载荷类型显著影响最优侦照高度与任务表现, 光/雷复合载荷综合性能最优.

如图 4(c) 所示, 不同载荷类型的因果效应曲线存在差异. 光/雷复合载荷的最优侦照高度适中, 且在此高度下任务表现最为稳定和优异. 纯光电载荷在较低高度下表现较好, 但随高度增加性能衰减较快. 雷达载荷则在相对更高的高度下仍能保持一定的侦察效能. 这表明, 复合载荷通过多源信息融合, 在更宽的高度范围内具备更强的环境适应性与目标识别能力, 这与数据集的设置机制符合一致.

6.2.4 起飞机场异质性分析

为了分析起飞机场的影响, 将所有样本按起飞机场划分为不同子群. 图 4(d) 展示了各起飞机场子群的异质性因果效应曲线. 对其进行分析后, 可以得到结论如下:

结论 5: 起飞机场对最优侦照高度与任务表现的影响极小, 可忽略不计.

如图 4(d) 所示, 不同起飞机场子群的因果效应曲线几乎完全重合. 这表明, 在控制了机型、任务类型、载荷等作战条件后, 起飞机场本身对侦察高度与任务表现的关系无显著影响.

6.3 案例结论

基于第 **6.1** 与 **6.2** 节的案例分析结果, 本文对侦照高度影响任务表现的因果规律进行系统性归纳, 并结合合成数据机制验证. 在群体层面, 因果效应曲线$\psi(t)$呈显著非线性 (结论 1), 存在全局最优区间: 低于最优高度时, 通过扩大视场、降低截获概率等产生正向效应; 超过阈值后, 因分辨率衰减、传输延迟等导致负向效应. 该最优区间与合成数据设定一致, 验证了方法有效性. 在异质性层面, 机型、任务与载荷类型构成主要效应修饰因子 (结论 2-5): I 型机凭借优越性能在更宽高度域维持高效能; 重点侦察任务因侧重隐蔽与持续监视致最优高度上移, 应急响应则因时效需求使有效区间下移收窄; 光电载荷于低空优势显著, 雷达载荷对高度变化不敏感, 复合载荷则在中空实现效能均衡. 上述结论均符合前期设置, 验证了方法在异质性分析上的有效性.

7 总结与展望

本文针对无人机海上侦察中连续作战条件因果效应的量化难题, 提出一种基于解耦表征学习的连续剂量响应因果效应估计网络 (CDDRN). 研究构建了面向军事观测数据的因果推断框架, 通过混合专家多头注意力机制将协变量解耦为工具、混淆与调整三类潜在因子, 以积分概率度量约束近似无混淆性, 并由变系数网络实现平滑稳健的效应估计. 基于半合成数据集的实验表明 CDDRN 估计精度显著优于基线模型; 案例分析进一步揭示: 侦照高度对任务表现呈非线性影响, 存在全局最优高度, 且效应在不同机型、任务类型及载荷下呈现显著异质性, 验证了方法的初步有效性. 未来可构建更多作战条件数据集以验证全场景性能, 通过工具变量或多源数据融合应对未观测混淆, 显式编码领域知识以增强可解释性.

参考文献 (References)

[1] ZACHARIAS G L. Autonomous horizons: the way forward[R]. Washington D. C. : Office of the US Air Force Chief Scientist, 2019.

[2] 崔瑞靖, 孙建彬, 何冰雨, 等. 因果推断及其军事应用研究综述[J]. 系统工程理论与实践. https://link.cnki.net/urlid/11.2267.N.20251203.1054.002.
(Cui R J, Sun J B, He B Y, et al. A Review of Causal Inference and Its Military Applications[J]. Systems Engineering — Theory & Practice. https://link.cnki.net/urlid/11.2267.N.20251203.1054.002.)

[3] 焦松. 武器装备效能仿真评估关键问题研究[D]. 哈尔滨: 哈尔滨工业大学, 2014: 3, 11-12).
(Jiao S. Research on key problems of weapon equipment effectiveness simulation evaluation[D]. Harbin: Harbin Institute of Technology, 2014: 3, 11-12).)

[4] PAUL G F, THOMS J, GLEASON. 无人机系统导论[M]. 北京: 电子工业出版社, 2003: 30-41.
(PAUL G F, THOMS J, GLEASON. Introduction to UAV systems[M]. Beijing: Publishing House of

Electronics Industry, 2003: 30-41.)

[5] 刘大成, 蚩建峰, 刘宗福. 一种改进 ADC 模型的反辐射无人机作战效能评估方法研究[J]. 舰船电子工程, 2020, 40(8): 130-133.
(Liu D C, Chi J F, Liu Z F. Research on operational effectiveness evaluation method of anti-radiation UAV based on improved ADC model[J]. Ship Electronic Engineering, 2020, 40(8): 130-133.)

[6] 阴小晖. 有人机/无人机协同作战效能评估研究[D]. 南昌: 南昌航空大学, 2013: 12-15).
(Yin X H. Research on the effectiveness evaluation for cooperative combat of manned vehicle/unmanned aerial vehicle[D]. Nanchang: Nanchang Hangkong University, 2013: 12-15).)

[7] Saaty T L. The Analytic Hierarchy Process[M]. New York: McGraw-Hill International Book Co. 1980: 29-68.

[8] 陈侠, 胡乃宽. 基于改进型支持向量机的侦察无人机作战效能评估[J]. 火力与指挥控制, 2018, 43(10): 31-34.
(Chen X, Hu N K. Research on operational effectiveness assessment for reconnaissance UAV based on the improved SVM[J]. Fire Control & Command Control, 2018, 43(10): 31-34.)

[9] 李永新, 陈双艳, 甘旭升, 等. 对地攻击型无人机作战效能多核 RVM 评估模型[J]. 电光与控制, 2021, 28(10): 16-20.
(Li Y X, Chen S Y, Gan X S, et al. An operational effectiveness evaluation model based on multi-kernel RVM for ground-attacking UAVs[J]. Electronics Optics & Control, 2021, 28(10): 16-20.)

[10] Prosperi M, Guo Y, Sperrin M, et al. Causal inference and counterfactual prediction in machine learning for actionable healthcare[J]. Nature Machine Intelligence, 2020, 2(7): 369-375.

[11] 寇昆湖, 刘登攀, 鹿珂珂, 等. 无人机作战效能评估方法研究综述[J]. 兵工自动化, 2022, 41(11): 58-62.
(Kou K H, Liu D P, Lu K K, et al. Review of research on UAV operational effectiveness evaluation method[J]. Ordnance Industry Automation, 2022, 41(11): 58-62.)

[12] 刘树光, 邵明军. 无人机自主作战效能评估技术研究综述[J]. 电光与控制, 2024, 31(4): 55-64.
(Liu S G, Shao M J. A review on UAV autonomous combat effectiveness evaluation techniques[J]. Electronics Optics & Control, 2024, 31(4): 55-64.)

[13] Habayeb A R. System effectiveness[M]. UK: Pergamon Press, 1987: 25-32.

[14] 郭齐胜, 张磊. 武器装备系统效能评估方法研究综述[J]. 计算机仿真, 2013, 30(8): 1-4.
(Guo Q S, Zhang L. Research summary of weapons equipment systems effectiveness evaluation methods[J]. Computer Simulation, 2013, 30(8): 1-4.)

[15] 中华人民共和国国家军用标准: 装备费用-效能分析 GJB1364-92[S]. 北京: 国防科学技术工业委员会, 1993: 1-4.
(GJB: Cost-effectiveness analysis for materiel GJB1364-92[S]. Beijing: Commission of Science, Technology and Industry for National Defense, 1993: 1-4.)

[16] Li K, Huang Q. Effectiveness analysis of cooperative engagement for UAV swarm[C]. International Conference on Defence Technology. Beijing: The Academy of Military Science, 2018: 1009-1014.

[17] 谢春燕, 高俊峰, 朱齐阳. 末端防御弹炮结合武器系统综合效能评估模型研究[J]. 上海航天, 2010, 27(4): 49-55.
(Xie C Y, Gao J F, Zhu Q Y. Study on the effectiveness-to-cost model of end defense anti-aircraft Gun missile system[J]. Aerospace Shanghai, 2010, 27(4): 49-55.)

[18] 郭辉, 徐浩军, 任博, 等. 基于模糊综合评判的预警机作战效能评估[J]. 数学的实践与认识, 2012, 42(4): 102-106.
(Guo H, Xu H J, Ren B, et al. Combat effectiveness evaluation of AWACS based on fuzzy synthetic evaluation[J]. Mathematics in Practice and Theory, 2012, 42(4): 102-106.)

[19] 程恺, 车先明, 张宏军, 等. 基于支持向量机的部队作战效能评估[J]. 系统工程与电子技术, 2011, 33(5): 1055-1058.
(Cheng K, Che X M, Zhang H J, et al. Evaluation method of operational effectiveness based on support vector machine[J]. Systems Engineering and Electronics, 2011, 33(5): 1055-1058.)

[20] Vapnik V N. An overview of statistical learning theory[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 988-999.

[21] 齐小刚, 吴相远, 刘立芳. 无人机集群编队自组网可靠性评估[J]. 控制与决策, 2024, 39(2): 689-696.
(Qi X G, Wu X Y, Liu L F. Reliability evaluation of ad hoc network for UAV swarm formation[J]. Control and Decision, 2024, 39(2): 689-696.)

[22] 朴敏楠, 李浩龙, 李海丰, 等. 面向飞机蒙皮覆盖检测的多无人机协同任务规划[J]. 控制与决策, 2026, 41(3): 809-821.
(Piao M N, Li H L, Li H F, et al. Multi-UAV collaborative mission planning for aircraft skin coverage detection[J]. Control and Decision, 2026, 41(3): 809-821.)

[23] 宋璐璐, 邓超, 范莎. 基于事件触发的时变风场下无人机实时路径重规划策略[J]. 控制与决策, 2026, 41(3): 835-844.
(Song L L, Deng C, Fan S. Real-time path replanning strategy for UAVs in time-varying wind fields based on event-triggered mechanism[J]. Control and Decision, 2026, 41(3): 835-844.)

[24] 杨明园, 王伟. 基于模型与图强化学习驱动的车辆-无人机协同多目标路径优化方法[J]. 控制与决策, 2026, 41(7): 2013-2026.
(Yang M Y, Wang W. Model and graph-based reinforcement learning driven-multi-objective evolutionary algorithm for vehicles-drone cooperative routing problem[J]. Control and Decision, 2026, 41(7): 2013-2026.)

[25] Pearl J. Causal diagrams for empirical research[J].

Biometrika, 1995, 82(4): 669-688.

[26] Pearl J, Mackenzie D. The book of why: the new science of cause and effect[M]. New York: Basic Books, 2018.

[27] 李德志, 鲁云军, 吴健平, 等. 一种基于互信息度量的时序数据因果发现方法[J]. 控制与决策, 2024, 39(9): 3151-3159.
(Li D Z, Lu Y J, Wu J P, et al. A causal discovery method for time series data based on mutualinformation measurement[J]. Control and Decision, 2024, 39(9): 3151-3159.)

[28] 王姝, 魏楠, 孟思彤, 等. 基于时间动态因果图的复杂工业过程故障预测方法[J]. 控制与决策, 2024, 39(7): 2242-2250.
(Wang S, Wei N, Meng S T, et al. Fault prediction method for complex industrial process based on time dynamic causality diagram[J]. Control and Decision, 2024, 39(7): 2242-2250.)

[29] Guo R C, Cheng L, Li J D, et al. A survey of learning causality with data: Problems and methods[J]. ACM Computing Surveys, 2020, 53(4): 1-37.

[30] Yao L Y, Chu Z X, Li S, et al. A survey on causal inference[J]. ACM Transactions on Knowledge Discovery from Data, 2021, 15(5): 1-46.

[31] Guo R C, Cheng L, Li J D, et al. A survey of learning causality with data: Problems and methods[J]. ACM Computing Surveys, 2020, 53(4): 1-37.

[32] Yao L Y, Chu Z X, Li S, et al. A survey on causal inference[J]. ACM Transactions on Knowledge Discovery from Data, 2021, 15(5): 1-46.

[33] Chu Z X, Li S. Continual causal effect estimation: Challenges and opportunities[C]. Proceedings of Machine Learning Research, Hawaii, 2023, 208: 11-17.

[34] Hirano K, Imbens G W. The propensity score with continuous treatments[M]. Bayesian Modeling and Causal Inference from Incomplete-data Perspectives. New York: Wiley, 2004, 226164: 73-84.

[35] Deng Z Z, Tian H, Zheng X L, et al. Deep causal learning: Representation, discovery and inference[J]. ACM Computing Surveys, 2025, 58(2): 1-36.

[36] Li Z Y, Guo X B, Qiang S W. A survey of deep causal models and their industrial applications[J]. Artificial Intelligence Review, 2024, 57(11): 298.

[37] Schwab P, Linhardt L, Bauer S, et al. Learning counterfactual representations for estimating individual dose-response curves[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(4): 5612-5619.

[38] Nie L Z, Ye M, Liu Q, et al. VCNet and functional targeted regularization for learning causal effects of continuous treatments[PP/OL]. 2021, arXiv: 2103.07861.

[39] Wu A P, Yuan J K, Kuang K, et al. Learning decomposed representations for treatment effect estimation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(5): 4989-5001.

[40] Kuang K, Cui P, Zou H, et al. Data-driven variable decomposition for treatment effect estimation[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(5): 2120-2134.

[41] Hu M X, Chu Z X, Li S. DTRNet: Precisely correcting selection bias in individual-level continuous treatment effect estimation by reweighted disentangled representation[J]. Transactions on Machine Learning Research, 2024. https://openreview.net/forum.

[42] Cui R J, Sun J B, He B Y, et al. Disentangled representations for continuous treatment effect estimation[J]. International Journal of Approximate Reasoning, 2026, 189: 109601.

[43] Wager S, Athey S. Estimation and inference of heterogeneous treatment effects using random forests[J]. Journal of the American Statistical Association, 2018, 113(523): 1228-1242.

[44] Hirano K, Imbens G W. The propensity score with continuous treatments[M]. Bayesian Modeling and Causal Inference from Incomplete-data Perspectives. New York: Wiley, 2004, 226164: 73-84.

[45] Shalit U, Johansson F D, Sontag D. Estimating individual treatment effect: Generalization bounds and algorithms[PP/OL]. 2016, arXiv: 1606.03976.

作者简介

何冰雨 (2003−), 男, 硕士生, 主要从事装备复杂系统工程与因果推断等研究, E-mail: hebingyu20@nudt.edu.cn;

孙建彬 (1989−), 男, 副教授, 主要从事国防采办与体系工程管理、不确定决策分析、装备体系评估等方向研究, E-mail: sunjianbin@nudt.edu.cn;

崔瑞靖 (1996−), 男, 讲师, 主要从事装备复杂系统工程、战略管理、因果推断等研究, E-mail: cuiruijing@nudt.edu.cn;

王锐 (1986−), 男, 教授, 主要从事复杂系统建模仿真、智能优化、算法自主进化等研究, E-mail: ruiwangnudt@qq.com.