

人工智能技术驱动的毁伤评估研究发展综述*

张克钊¹, 卢芳云², 李翔宇², 彭永², 陈荣², 张温馨¹, 张子瑄¹, 武晨阳¹, 李维娜¹, 段昂轩¹

(1.国防科技大学 试验训练基地, 陕西 西安, 710000; 2.国防科技大学 理学院, 湖南 长沙, 410072)

摘要: 毁伤评估是连接目标选取、方案筹划和作战反馈的关键环节, 既包括打击前面向毁伤概率、目标易损性和弹目匹配的武器毁伤效能评估, 也包括打击后面向目标状态、功能下降和任务效能的战场毁伤效果评估。随着机器学习、多源传感、数值仿真和智能计算技术的发展, 毁伤评估正由依赖经验规则、人工判读和单一数据源的静态评估, 转向感知识别、数据驱动建模、知识推理、多源融合和闭环决策相结合的智能化评估。本文围绕人工智能技术驱动的毁伤评估研究展开综述, 在明确毁伤评估内涵与人工智能赋能逻辑的基础上, 从感知与特征提取、数据驱动评估模型、知识驱动评估方法、多源融合以及智能决策与优化五个方面归纳关键技术进展, 并进一步讨论其面向打前预测、打后评估、体系目标评估和评估驱动再决策的应用链条。结果表明, 人工智能能够显著提升毁伤信息获取、特征提取、效应预测、状态估计和行动反馈的效率, 但仍面临真实样本不足、仿真偏差、功能映射不清、多源信息冲突、模型泛化与可信验证不足、评估结果难以稳定进入决策流程等问题。未来应围绕数据可信、机理约束、知识增强、多源融合、可解释验证和人机协同推进研究, 构建面向复杂作战环境的智能毁伤评估体系。

关键词: 毁伤评估; 人工智能; 多源信息融合; 知识图谱; 数据驱动; 智能决策; 作战应用

中图分类号: O383; TP18; E87

国标学科代码: 13035

文献标识码: A

Research review on damage assessment driven by artificial intelligence technologies

ZHANG Kefan¹, LU Fangyun², LI Xiangyu², PENG Yong², CHEN Rong², ZHANG Wenxin¹, ZHANG Zixuan¹, WU Chenyang¹, LI Weina¹, DUAN Angxuan¹

(1. Test Center, National University of Defense Technology, Xi'an 710000, Shaanxi, China;

2. College of Science, National University of Defense Technology, Changsha 410072, Hunan, China)

Abstract: Damage assessment is a key link between target selection, strike planning, operational feedback, and subsequent action adjustment. It includes pre-strike weapon damage effectiveness assessment (WDEA), which estimates damage probability, target vulnerability, and weapon and target matching, as well as post-strike battle damage assessment (BDA), which determines target status, functional degradation, and mission effectiveness after firepower employment. The review aimed to clarify how artificial intelligence (AI) is reshaping damage assessment and to identify the technical paths, application modes, and unresolved problems

* 收稿日期: 2026-06-11; 修回日期: 2026-07-14;

基金项目: 国家自然科学基金 (12302450);

第一作者: 张克钊 (1994—), 男, 博士, 助理研究员. E-mail: kfzhang_v@163.com;

通信作者: 卢芳云 (1963—), 女, 博士, 教授. E-mail: fyly@nudt.edu.cn.

in this field. A systematic review framework was established around data acquisition, feature extraction, state assessment, functional inference, and decision feedback. On the basis of the connotation of damage assessment and the enabling mechanism of AI, existing studies were classified from five technical perspectives: perception and feature extraction, data-driven assessment modeling, knowledge-driven reasoning, multi-source information fusion, and intelligent decision-making and optimization. Their roles were further compared in four operational scenarios: pre-strike prediction, post-strike assessment, system-of-systems target assessment, and assessment-driven re-decision-making. Particular attention was paid to how optical images, infrared data, synthetic aperture radar (SAR), sensor observations, numerical simulation results, test data, historical cases, expert knowledge, and operational reports were transformed into damage features, target states, functional conclusions, confidence measures, and decision-support information. Representative methods, including computer vision, change detection, deep learning, Bayesian networks, knowledge graphs, graph models, and optimization algorithms, were examined in terms of applicability, information requirements, uncertainty expression, and limitations. The review shows that AI substantially improves the efficiency of damage information acquisition, target localization, feature extraction, effect prediction, state estimation, and feedback generation. It also extends damage assessment from manual image interpretation and static rule-based judgment toward an intelligent chain integrating sensing, modeling, reasoning, fusion, and decision support. However, major constraints remain, including insufficient real damage samples, simulation bias, unclear mapping from physical damage to functional degradation and system effectiveness, conflicts among heterogeneous sources, weak cross-scenario generalization, inadequate trustworthy verification, and unstable interfaces between assessment outputs and command decision processes. AI enabled damage assessment is becoming an important direction for building faster, more accurate, more explainable, and more reliable assessment systems for complex operational environments. Future research should emphasize credible data, mechanism-constrained modeling, knowledge enhancement, multi-source fusion, explainable verification, uncertainty-aware outputs, and human and machine collaboration.

Keywords: Battle Damage Assessment; Artificial Intelligence; Multi-source Information Fusion; Knowledge Graph; Data-Driven; Intelligent Decision-Making; Operational Application

1 引言

1.1 毁伤评估的内涵与需求

毁伤评估是在战争和军事行动中,用于评估武器或军事行动对目标造成的毁伤程度、作战影响和任务效果的过程,是联合火力打击闭环中的关键环节。从作战流程看,与毁伤评估关系最为密切的环节主要包括武器毁伤效能评估(Weapon Damage Effectiveness Assessment, WDEA)和战场毁伤效果评估(Battle Damage Assessment, BDA)。前者通常位于打击方案形成之前,关注打前如何预测;后者通常位于火力实施之后,关注打后如何确认。二者共同构成火力运用从计划、实施到反馈修正的重要支撑^[1-2],如图1所示。




图 1 联合火力打击闭环中的毁伤评估位置

Fig. 1 WDEA and BDA in the closed-loop joint fire strike

武器毁伤效能评估（WDEA）主要服务于战前预测，可理解为在打击前估计武器弹药对特定目标可能产生的毁伤效果。它依托数理分析、仿真计算、试验归纳、经验模型和专家知识等手段，需要综合武器威力、目标易损性、投射精度、引信作用以及弹目交会条件等因素，主要回答弹药打击敌方目标时能造成怎样的毁伤程度、达到预期毁伤需要多少弹药，有时也延伸到弹药和引信选择、瞄准点确定等问题。武器毁伤效能评估是火力筹划和武器弹药试验鉴定的重要支撑^[1,3]。

战场毁伤效果评估（BDA）主要服务于战后反馈，可理解为在火力实施后确认已经打得怎样。它依托侦察监视、图像判读、传感器探测、情报融合和毁伤分析等手段，对目标毁伤状态、任务达成程度、武器作用效果以及可能的附带毁伤进行判断，并为是否需要再次打击、如何调整打击方案提供依据。与武器毁伤效能评估相比，战场毁伤效果评估更强调从实际观测数据出发进行归纳判断；与传统人工判读相比，现代战场毁伤效果评估对信息获取、快速处理、目标识别和不确定性表达提出了更高要求^[2]。

从作战概念看，毁伤评估最早就是从作战闭环和目标打击链条中延伸出来的。无论是OODA环所强调的“观察—判断—决策—行动”，还是现代杀伤链中常见的“发现、定位、跟踪、瞄准、打击、评估”流程，毁伤评估都不是行动结束后的附带统计，而是下一轮决策开始前的重要反馈。打前需要预测毁伤效果，以支撑武器选择、弹目匹配和任务规划；打后需要确认毁伤程度，以支撑补充侦察、再次打击、火力转移和战果判定。相关作战评估文件也将毁伤评估纳入战斗评估和再攻击判断流程，说明毁伤评估本质上服务于作战反馈，而不是孤立的结果判读。因此，毁伤评估的重要性并不只体现在“评得准”，更体现在它能够把打击结果重新转化为可用信息，推动后续行动持续修正^[2]。

毁伤评估领域已经发展多年，也形成了许多有价值的研究成果。早期研究多服务于实战需求，重点关注武器毁伤机理、目标结构响应、人工图像判读和经验规则评估。随着精确打击、遥感探测、仿真建模和信息系统的发展，毁伤评估逐渐从单目标、单手段、单结果的判断，转向多源数据支撑下的综合评估。上世纪末以来，局部冲突和新域新质战争不断暴露出打前预测与打后评估的重要性，推动了目标易损性分析、毁伤算法建模、战斗评估流程和再攻击决策等相关研究的发展^[1,3]。近年来，人工智能、遥感大数据、无人平台和高性能计算快速发展，又使毁伤评估的研究对象和方法体系进一步扩展：从人工判读走向自动识别，从单一指标走向多维指标，从局部目标毁伤走向体系效能影响，从静态评估走向动态闭环评估。这种发展不是简单的技术更替，而是需求牵引和方法进步共同作用的结果。一方面，现代作战对象越来越复杂，目标不再只是单个固定设施或单件装备，而可能是由指挥节点、通信链路、火力单元、机动平台和保障系统共同构成的目标体系。另一方面，战场节奏不断加快，毁伤评估所面对的数据量、时效性和不确定性都显著增加。传统方法在许多场景中仍然有其价值，但

也逐渐显现出难以回避的问题：人工判读主观性强、效率有限，难以处理持续增长的图像和传感器数据；物理仿真和毁伤机理模型解释性较好，但参数依赖强、计算耗时长，难以满足实时化要求；基于规则和浅层特征的评估方法往往适应性不足，在复杂背景、遮挡干扰、视角变化和跨场景迁移中容易失效；大量试验数据、仿真数据和侦察数据没有被充分组织和利用，造成了较明显的浪费。过去“绝对快、相对准”的评估思路，在信息化、智能化战争条件下已经难以完全适应新的任务需求。毁伤评估不但要快，而且要更加准确、稳定、可信、可解释，并且能够服务于更高层级的作战决策。

可见，毁伤评估既不是单一的结果判定，也不是单纯的武器威力计算，而是贯穿打前预测、打中跟踪、打后反馈和后续决策的闭环活动。其一方面依赖武器、目标、环境和作战任务等机理知识，另一方面依赖图像、传感器、试验、仿真和历史案例等数据资源。这种“机理约束与数据驱动并存”的特征，正是后文讨论人工智能赋能毁伤评估的基本出发点。

1.2 人工智能技术的赋能潜力

近年来人工智能技术的发展，为毁伤评估技术转型提供了新的可能。图像识别、目标检测、语义分割、变化检测、特征学习、数据挖掘、多源融合和智能决策等方法，能够在一定程度上弥补传统方法对人工经验、固定规则和单一数据源的依赖。以遥感建筑毁伤评估为例，公开灾前灾后影像数据和对象级变化检测方法，已经为毁伤识别和等级判定提供了较成熟的技术参照。这类研究虽然主要面向灾害场景，但其技术逻辑与军事毁伤评估具有相通性，即通过多时相、多源或多模态数据获取目标状态变化，再进一步推断毁伤等级和功能影响^[4-5]。

在军事目标毁伤评估方向，人工智能同样开始体现出应用潜力。已有研究将深度特征学习、目标检测、毁伤等级判定和传统指标体系结合，用于战场毁伤评估、巡飞弹对地面目标毁伤判定以及军事目标综合毁伤评估等任务^[6-8]。这些成果表明，人工智能对毁伤评估的推动已经不只是提高图像处理速度，而是在逐步改变毁伤评估的基本流程：由人工看图和人工比对，转向目标自动定位、特征自动提取和毁伤状态辅助判别。

无论从理论层面还是实操层面来看，毁伤评估都是一门综合性、体系性较强的交叉学科，也是一门亟待新技术赋能发展的学科。其中，军事学提供任务牵引，计算机科学提供感知识别和数据分析方法，力学与土木工程解释结构响应和毁伤机理，系统科学则支撑多目标、多指标和多层级效能评估。

李珩等针对大当量爆炸建筑物毁伤评估问题，将遥感影像、历史案例数据、网络图像视频和经验力学模型结合起来，构建建筑物毁伤评估模型，也说明毁伤评估正在从单一模型或单一数据源，转向多学科、多信息和多方法融合。正是因为这种交叉属性，毁伤评估不能只依赖某一种算法突破、某一种学科知识，也不能只停留在某一类应用场景，而需要在数据、特征、状态和决策之间形成更加完整的技术链条^[9]。

人工智能赋能毁伤评估的意义，在于推动毁伤评估从“结果判读”向“过程认知”发展，从“特征识别”向“预测与决策”延伸。图像、视频、雷达、红外、传感器、仿真和作战记录等多类数据，都可以成为毁伤评估的信息基础；单目标、多目标和体系目标，则对应不同层次的分析理论和评估方法；毁伤效应、毁伤等级、毁伤概率和成爆弹量等指标，也可从不同角度表征评估结果。由此，毁伤评估可被理解为“数据—特征—状态—决策”连续作用的体系问题。人工智能的价值不只在于提高某一环节的速度，更在于把数据获取、目标识别、毁伤特征提取、评估建模、多源信息融合、知识推理和决策优化连接起来。

现阶段，毁伤评估领域中人工智能的引入仍面临着一定的瓶颈和限制。真实毁伤数据难以获取，公开数据与实测、实战数据之间存在差距；不同传感器、不同尺度、不同时间的数据融合仍然困难；深度学习模型在跨目标、跨场景和强干扰条件下的泛化能力仍需检验；模型输出如何解释、如何验证、如何转化为作战决策依据，也仍是高水平研究必须面对的问题。特别是在军事应用中，毁伤评估不仅要求模型算得出来，还要求结果说得清楚、用得可靠、经得起验证。因此，后续研究不宜只追求更复杂的算法或模型，而应在数据真实性校核、多源信息融合、物理规则约束和辅助作战决策之间建立更

加稳健的衔接关系。

总体来看,毁伤评估领域发展至今,已经逐渐由点成线、聚线成面,局部的小体系和宏观的大生态都已有相当成效。早期研究基于国外文献、报告解决了“如何认识毁伤”的基础概念性问题,传统毁伤评估算法理论积累了“如何计算毁伤”的方法经验,信息化手段拓展了“如何获取毁伤信息”的技术渠道,而人工智能的发展正在进一步推动领域回答“如何快速、准确、可信地评估毁伤并支撑决策”这一新的问题。在这些成果的支撑下,毁伤评估领域正处在机遇与挑战并存的发展阶段。运用人工智能也好,跨学科交叉发展也好,构建“数字化+智能化”的毁伤评估体系都已经成为不可逆转的重要趋势。本文正是在这一背景下,聚焦智能驱动下毁伤评估技术的发展,围绕方法、应用与趋势展开综述,力图梳理现有研究的基本脉络,归纳人工智能赋能毁伤评估的主要路径,总结当前面临的关键问题,并进一步展望新时期毁伤评估技术的演进方向。

2 人工智能赋能毁伤评估的关键技术

毁伤评估技术的智能化发展并非孤立算法的更新,而是评估任务本身与支撑手段之间的持续适配。早期研究以经验公式、靶场试验和人工判读为主,能够处理的场景相对有限,但物理含义明确、结论可追溯。随后遥感、仿真和信息系统技术的引入拓宽了数据来源,使多源信息综合评估成为可能,但也暴露出特征提取依赖人工、数据处理效率低、复杂环境下适应性不足等问题。近十年来,以深度学习为代表的人工智能方法开始进入毁伤评估领域,评估流程逐步由静态分析转向数据驱动,由单环节处理转向多环节协同^[4-7,10-14]。

这种转变的内在原因在于,毁伤评估领域面临的主要问题已从数据匮乏和算力不足,转为多源异构数据的有效整合、小样本与高不确定性下的可靠建模、物理机理与数据驱动方法的结合,以及评估结果如何稳定进入后续决策。毁伤评估不再仅是预测计算、图像分析或等级判定,而逐步成为一个从感知、建模、推理到决策的系统性问题。在这一背景下,人工智能技术的作用不在于替代传统机理分析,而在于为特征分析、机理研究、评估建模、知识辅助推理和决策优化提供更高效的手段。本节围绕上述关键技术展开评述,重点讨论各方法在毁伤评估中的核心思路、适用条件和局限,并归纳分析各方法在毁伤评估不同应用场景中的适配关系。

2.1 感知与特征提取

感知与特征提取是智能毁伤评估(更侧重战场毁伤效果评估)的前端环节,其任务是从光学图像、红外、合成孔径雷达(Synthetic Aperture Radar, SAR)、视频和无人平台观测中提取弹坑、裂缝、塌陷、烧蚀、部件缺失、热异常等可判读毁伤特征。这个环节决定了后续模型能否获得可靠输入。对打后评估而言,感知结果直接影响毁伤等级和功能状态判断;对打前预测而言,可观测性也会反向影响评估指标设计,即预期毁伤效果必须能够被传感器稳定发现和量化,才可能进入后续评估流程。

2.1.1 图像信息的提取与处理

图像处理是战场毁伤评估中最常见的信息入口,通常包括去噪、辐射校正、几何配准、目标分割、边缘提取和纹理描述等步骤^[15-28]。这些基础处理直接影响后续判断。以机场跑道为例,打击前后影像若未准确配准,弹坑位置、剩余可用跑道长度和裂缝连通关系都会产生偏差;对桥梁、建筑和港口目标,阴影、烟尘、云层和观测角变化也可能被误判为结构变化。

xBD数据集提供了一个可借鉴的公开范式。该数据集包含灾前灾后卫星影像、建筑物轮廓和分级毁伤标注^[5]。Zheng等提出的ChangeOS框架进一步将对象级语义变化检测用于建筑毁伤评估,其核心思路是从逐像素变化分析转向目标对象与毁伤等级的联合判断^[4,29-32]。这类研究虽然主要面向灾害场景,但对固定目标打后评估具有参考价值。需要注意的是,军事打击往往具有小尺度、局部化、强遮蔽和离散损伤等特征,不能简单把灾害数据直接迁移到军事目标。图像处理结果应同时保留图像质量、配准误差和观测条件,避免后续模型把低质量图像信息当作稳定输入。

2.1.2 基于图像信息的目标匹配

目标匹配相关技术是目标选取和特征识别的前置条件，传统方法依赖 SIFT、SURF 等局部特征，具有较好的可解释性，适合结构清晰、视角变化有限的目标^[17-28,33]。近年来，深度匹配方法在弱纹理、视角变化和遮挡条件下提高了图像配准能力，为打前—打后图像对齐和毁伤特征定位提供了技术基础。^[34-65]。本文不展开比较其通用视觉性能，而重点关注其在打后图像分析、目标姿态变化分析和毁伤特征识别中的适用性。

在战场毁伤效果评估中，匹配误差不会停留在图像层面，而会继续传导到毁伤效应判定及后续的毁伤等级分析中。机场跑道上几个像素的配准偏差，可能改变弹坑是否压占跑道中心线的判断；装甲车辆或雷达车的姿态变化，会使局部部件难以与打前图像对应；港口、桥梁和阵地目标在烟尘、伪装和阴影影响下，可能出现大量伪匹配。因此，智能匹配模型不应只输出匹配点或相似度，还应给出匹配置信度和误差范围，使下游评估能够判断匹配结果是否可用。

2.1.3 基于图像信息的毁伤评估

基于图像的毁伤评估主要面向打后评估，包括目标检测、变化检测、毁伤区域分割和等级判定。深度学习将这一过程从人工特征设计推进到自动特征学习。ResNet 等卷积网络提高了复杂图像特征表达能力^[32,66-72]，YOLO 类检测网络可以在较高速度下完成目标定位^[71-73]，Grad-CAM 等解释方法则为检查模型关注区域提供了辅助工具^[74]。

Xu 等提出的 YOLO-VGGNet 是军事目标打后评估中较有代表性的工作。该方法先用 YOLOv3 检测和定位机动地面目标，再用 VGG (Visual Geometry Group Network) 网络判定毁伤等级，并通过卷积特征可视化分析受损关键部位^[7]，如图 2 所示。该工作的价值在于将目标检测、毁伤等级评估以及一定程度的可解释分析整合在同一流程中，契合巡飞弹等平台对在线评估时效性的需求。其不足也同样明显，训练数据主要来源于有限的目标类型和仿真环境，真实战场中的遮挡、烟尘、诱饵和复杂背景会显著影响其泛化能力。




图 2 基于 YOLO 算法框架的毁伤效果评估 (引自文献[7])

Fig. 2 BDA based on the YOLO algorithm framework (redrawn from Ref. [7])

孔祥锡等提出的基于深度学习与模糊层次分析的毁伤评估算法，则体现了视觉模型与传统评估指标体系相结合的一种思路^[8]。深度学习负责提取目标关键区域和毁伤特征，模糊层次分析用于综合不同部件和毁伤程度。与单纯的分类模型相比，这类方法更贴近 BDA 的实际需要，因为它试图将局部图像特征转化为综合性的毁伤结果。不过，其效果仍然依赖于指标权重、部件重要度和样本覆盖范围，不能简单将模型精度等同于评估可信度。

2.1.4 图像的小样本数据处理

真实毁伤图像数量有限、标签稀缺且类别不均衡,小样本问题在打前预测和打后评估中都存在。打前预测面对新型目标、新型弹药或极端工况时,缺少足够试验样本;打后评估面对真实战场毁伤时,也难以获得数量充足、标注可靠的图像数据。迁移学习、数据增强、元学习和少样本检测为此提供了技术入口,Meta-DETR 等研究表明,利用类别间关系可以在少量样本条件下改善目标检测表现^[75-89]。遥感变化检测领域的相关综述也表明,预训练、跨域迁移、伪标签和主动学习,正在成为缓解标注不足的重要方向^[12]。

对于武器毁伤效能评估,小样本处理还应与仿真和试验结合。特定命中角度下的装甲破坏、桥梁关键构件损伤、跑道多弹坑组合毁伤等,很难依靠真实试验大量获取。有限元仿真、三维建模或数字孪生可生成典型毁伤形态,再用少量试验图像校准。由此得到的数据不能直接等同于真实样本,但可帮助模型理解“命中部位—结构响应—外观特征”之间的关系。总体而言,小样本方法的价值不只是减少标注数量,而是把公开数据、仿真样本、少量真实观测和专家知识组织起来,并在输出中说明适用范围和不确定性^[90-92]。

总体看,计算机视觉方法在 BDA 中的应用相对易于实现。其优势为处理速度快、自动化程度高,适合弹坑、裂缝、倒塌、烧蚀和部件缺失等可见毁伤特征提取;局限在于对遮挡、烟尘、伪装和观测角变化敏感,且难以直接判断目标部件失效和功能毁伤。因而视觉模型更适合用于初步判定和特征提取,而暂不宜单独承担完整毁伤结论分析。

2.2 数据驱动的评估模型

数据驱动模型是预测与评估共同依赖的方法基础。在武器毁伤效能评估中,模型可从试验、仿真和历史案例中学习毁伤效应、功能毁伤与毁伤概率之间的非线性关系,用于提高多工况预测和方案优化效率。在战场毁伤效果评估中,模型可以将数据特征转化为毁伤等级和其他不确定性指标。二者虽然共享数据资源,但对数据覆盖范围、输入数据真实性和结论可追溯性的要求并不完全相同。

2.2.1 试验数据驱动

试验数据仍然是毁伤评估中最具说服力的依据,静爆试验、高速摄影、传感器和效应物测量能够记录弹体侵彻、冲击波、高速破片作用于不同目标的过程^[10,93-96]。这些数据既可用于校准传统毁伤工程算法,也可用于训练机器学习模型。尤其在 WDEA 中,试验数据直接决定了毁伤概率和毁伤判断是否有可靠依据。

杨伟涛和刘康泰讨论了多维数据分析与人工智能技术在弹药试验中的应用潜力,指出弹药试验数据可从单一结果记录转向多维状态采集和智能分析^[93]。这类研究的意义不在于用机器学习替代试验,而在于将高速图像、传感器时序、靶场环境和毁伤结果组织为可复用数据,使后续模型能够学习冲击载荷与毁伤结果之间的关联。对新型弹药和复杂目标而言,这种数据组织能力比单个算法更为重要。

试验数据驱动技术也有明显局限,比如高能载荷试验成本高、风险大,工况组合难以充分展开;传感器在高温、高压和强冲击条件下可能失效或饱和;部分毁伤过程难以直接观测。因此,试验数据驱动的智能算法更适合作为高可信基准和关键工况样本,用于校准仿真和约束数据模型,而不是包揽全部训练任务。

2.2.2 仿真数据驱动

仿真数据主要用于打前预测,也可用于打后评估提供对照。有限元、物质点法和多物理场计算可以改变装药量、入射角、目标材料、边界条件和命中部位,获得结构响应、破坏形态和毁伤效能等结果^[90-92,97]。在舰船舱内爆炸、城市建筑外爆威力场和重要目标毁伤效应评估等问题中,仿真能够扩展试验难以覆盖的参数空间^[90-92,97-99]。

潘刘娟等提出图学习驱动的爆炸冲击钢筋混凝土柱结构响应建模与预测方法,用图神经网络表达构件拓扑和力学关联,在多工况下预测三维结构响应^[13],如图 3 所示。这项工作代表了仿真数据与图学习结合的一类路径,不是简单地将结果送入神经网络,而是将有限元计算中网格节点间的传播过程转化为图结构的信息传播,更适合处理构件之间存在连接关系的目标。对打前评估而言,这类模型

可以加快参数扫描；对打后评估而言，它可为观测到的局部损伤提供结构响应解释。




图3 用图神经网络分析混凝土结构损伤的解码框架（改绘自文献[13]）

Fig. 3 Decoding framework for concrete structure damage analysis using graph neural networks (redrawn from Ref. [13])

事实上，仿真数据的问题不在数量，而在可信度。材料参数、接触算法、损伤准则和边界条件稍有偏差，就可能改变失效模式和毁伤结果。若缺少试验校准，大规模仿真样本会放大系统误差。因此，仿真数据应进入试验校准→仿真扩展→观测修正的循环，而不是被直接视为实际毁伤结果。

2.2.3 毁伤算法模型

在试验和仿真数据基础上，机器学习、深度学习、图神经网络和代理模型开始承担不同层级的评估任务。卷积神经网络和随机森林可用于图像或特征驱动的毁伤效果评估^[71-72,100-101]，改进 YOLO 模型可用于装甲目标毁伤状态估计^[71-72]，三维重建与层次分析结合的方法则为坦克等复杂装备的部件级判断提供了思路^[102]。


Qi 等提出的改进 Kullback-Leibler 散度稀疏自编码器用于战场毁伤评估，是较早把深度特征学习引入 BDA 的代表性工作^[6]。该方法通过稀疏自编码器进行特征学习，并用改进 KL 散度约束提升特征选择效果。它说明数据驱动模型可以在人工特征不足时自动提取评估特征，但也暴露出一个长期问题：若输入数据和标签无法对应真实毁伤机理，模型学到的可能只是统计相关信息，而不是可用于作战判断的因果依据。

不同层级的毁伤评估需要不同的模型，部件级分析关注裂纹、穿孔、烧蚀、变形和局部失效等物理毁伤效应；目标级分析关注这些毁伤效应如何影响通信、机动、发射、供电或承载等功能毁伤；体系级分析则处理节点关联、权重重分配和体系能力变化。忽略评估层级会致使数据驱动方法退化为一一般预测模型，分类精度看似提高，却无法解释目标为什么失能、失能到何种程度，以及结果能否迁移至新的目标和场景。

2.2.4 模型的可解释性

数据驱动模型在应用中始终面临一个基本问题，高精度并不直接等同于高可信。即便一个模型在测试集上取得高精度的分类准确率，但如果未能说明判断依据了哪些输入特征、在什么条件下该判断成立、哪些因素的扰动会显著改变输出，这些结果在实际决策中就仍然难以被直接采纳。

已有研究将可解释机器学习方法引入混凝土裂缝定量评估和钢筋混凝土梁概率毁伤评估等工作^[100,103]，如图 4 所示。基本思路较为一致，解释不应仅呈现为一张热力图，而需要回到物理逻辑和毁伤机理。当热力图的高亮区域集中在阴影、烟尘或背景纹理上时，所反映的往往不是模型给出了合理解释，而是它关注了与毁伤机理无关的区域。真正有意义的解释，应当是裂纹贯通的原因、局部破坏影响承载能力的因素比重，以及外观损伤与功能失效之间的映射关系是如何构建的。



观测信息、更新目标毁伤状态的后验概率^[107]。本体建模则侧重领域概念的规范化表达,相关工作在目标易损性本体、毁伤评估本体等方面已形成初步成果,试图为不同毁伤评估任务提供统一的语义基础^[1,3]。两者的共同局限在于,贝叶斯网络的结构设计和条件概率获取依赖领域专家,扩展性受限;本体模型如果不能与定量计算结合,容易停留在概念层面,难以直接支撑毁伤等级的数值判定。

在更接近目标结构响应的层面,知识驱动方法与物理仿真和深度学习的结合正在逐步深入。吴威涛等将图神经网络用于建筑侵爆毁伤数智仿真模型,利用图结构表达建筑构件的拓扑关系,将侵爆载荷与结构响应关联建模^[108]。Liu 等针对火灾受损钢筋混凝土结构,提出知识驱动的三维损伤映射和决策支持方法,将深度学习提取的多模态传感特征与结构力学知识结合,形成从观测信息到功能判断的评估链路^[109]。这两项工作的共同思路是:知识不再仅用于事后解释,而是嵌入模型结构中,为数据学习提供物理约束和表达边界。

三种方法的实际使用场景和应用思路略有不同。知识图谱和本体建模适合统一概念、结构和毁伤判据,优点是可追溯,难点是知识获取和维护成本较高;贝叶斯网络适合在信息不完备条件下更新毁伤状态,但条件概率依赖专家经验和样本支撑;图神经网络更适合表达结构连接和体系依赖关系,但可解释性和跨场景泛化仍需验证。

综合来看,知识驱动方法在毁伤评估中的核心价值,不在于取代数据模型,而在于为后者提供结构化约束和可追溯的推理路径。实际应用中的难点集中在知识粒度设计上,本体或规则设计过粗,只能得到“目标受损”、“结构破坏”等低分辨率的结论,无法支撑后续决策;设计过细,则知识获取和维护的成本急剧上升,推理效率也会成为瓶颈。现阶段通常采取折中的分层组织知识方法,即上层以目标结构、部件信息和毁伤判据为框架,底层由数据模型结合观测信息和参数估计。打前评估用结构知识和物理约束限定预测范围,打后评估用结构拓扑和功能关系将局部观测信息转化为目标功能毁伤结果。一方面,减少了纯数据模型脱离物理机理开展无效预测的现象,另一方面,为纯知识图谱在复杂场景下推理能力不足的问题提供了可拓展的方向。

2.4 数据的多源融合

数据多源融合是战场毁伤效果评估从单一图像判读走向综合评估分析的关键环节。单一传感器在面对复杂战场环境时,具有明显的局限性。光学图像能清晰呈现弹坑、裂缝等外观损伤,但受光照、烟尘和伪装遮蔽影响严重;红外数据对热异常敏感,却难以分辨热源来自弹药残余、环境辐射还是诱饵;SAR 具备全天候穿透能力,但空间分辨率较低且解译门槛高^[29-31,69-70];目标外观完整并不等同于功能完好——一栋框架建筑物表面未见明显裂缝,其承重梁、柱可能已经明显断裂;一辆没有弹孔的装甲车可能已因爆炸冲击而丧失了通信功能。可见毁伤效应与实际功能毁伤之间的不匹配,是现阶段单源图像评估方法的瓶颈,也是多源融合必须解决的核心问题。

从评估逻辑看,多源融合并不仅仅是增加输入通道。不同来源的信息在可信度、时间尺度、空间分辨率和语义粒度上各有差异,将它们简单地堆叠到一起,既无助于提升评估精度,还可能引入新的噪声和冲突。徐艺博等在研究巡飞弹对地目标识别与毁伤评估时,将可见光、红外与模型判别结果结合,通过多源互补提升了在线评估的稳定性^[7]。张涛面向装备作战效能评估提出的多源数据融合方法,则从装备状态、任务环境和效能指标三者之间建立评估关系,试图将异构数据纳入统一的评估框架^[110]。在民用基础设施领域,Liu 等针对火灾后钢筋混凝土结构的多模态三维损伤映射研究,将图像、结构传感数据和力学知识融合,为受损构件的状态判定构建了可追溯的评估链^[109]。这些工作的共同指向是多源融合的工程实现,实际效果取决于如何处理好数据信息之间的互补、冗余与冲突关系。




图 6 多源数据融合的工程实现（改绘自文献[7,109]）

Fig. 6 Engineering implementation of multi-source data fusion (redrawn from Refs. [7,109])

分层融合是当前处理上述问题较为成熟的框架。底层负责时间同步、空间配准和数据质量评估，判断数据能否使用；中层融合目标状态、毁伤特征和各传感器的置信度，确定不同数据在评估中的权重；高层引入知识信息（如 2.3 节的知识驱动模型），处理毁伤效应与功能毁伤的映射问题。在方法选择上，动态贝叶斯网络和状态空间模型适合处理不确定信息的时序更新，可表达毁伤状态随时间和观测积累的变化过程^[107,111]；深度学习则擅长从高维数据中自动提取特征和发现异常模式，在底层和中层融合中作用突出。也有研究将 **D-S 证据理论（Dempster-Shafer evidence theory）** 引入多源融合框架，用于处理不同传感器之间的信息冲突问题^[112]。两类方法结合后，可由数据驱动方法承担特征提取和毁伤效应更新，由概率图模型或知识推理方法完成不确定性传播和状态推断。

多源数据融合与火力筹划之间存在前置关联。融合策略的有效性很大程度上取决于打前能否合理预设观测窗口、传感器组合和判定准则。如果在火力筹划阶段未考虑打后评估所需的多源数据可获得性，融合模型的应用前景将非常有限。

2.5 智能决策与优化

智能化技术在提升毁伤评估流程的精度和可信度之外，也开始进入决策和优化相关问题。在武器毁伤效能评估和战场毁伤效果评估的基础上，评估结果可进一步支撑火力运用、资源分配和任务调整，使毁伤评估由结果判定延伸到后续行动建议。

在火力筹划阶段，智能决策与优化支撑**武器目标分配（Weapon-Target Assignment, WTA）**、火力资源规划和传感器任务设计，将打前预测结论转化为兵力与火力使用方案。武器目标分配是其中研究最为集中的问题。传统 WTA 模型将目标价值、武器数量、毁伤概率和约束条件统一纳入，形成了精确算法、启发式算法和智能优化算法等多种求解方法^[113,112]。林雕等进一步引入动态毁伤概率和目标价值，探讨了态势变化条件下的武器目标分配求解问题^[114]。随着强化学习和多智能体方法的发展，WTA 逐渐被描述为序列决策过程，系统根据当前态势选择分配动作，并依据预期毁伤效果和任务收益在线更新策略。这一路径增强了动态环境下的适应能力，但仍面临训练环境与真实战场之间的数据差异，策略的可解释性也尚不充分。

打后评估结论进入决策环节时，问题更为复杂。此时决策模型面对的是多源融合输出的实际毁伤状态及其不确定性，而非战前预设的参数。评估结论的误差会被决策环节逐级放大——若将未毁目标误判为已毁，可能导致任务目标遗漏；若将已毁目标误判为未毁，则可能引发不必要的重复打击。徐艺博等研究了无通信条件下基于视觉毁伤评估的弹群自主攻击决策，将目标识别、毁伤评估和攻击决策整合在同一闭环中，揭示了评估不确定性对决策效果的直接影响^[115]。这一工作说明，评估模型向决策环节传递的内容不能只有毁伤等级，还需要包含数据来源、功能下降和置信度，以便决策模型在实际场景中综合权衡。

现阶段，从评估到决策的衔接逻辑出发，智能决策模型的合理定位仍是辅助人工决策，而非完全替代。评估模型输出目标状态、功能毁伤和置信度，决策模型据此生成备选方案，同时说明各方案的

约束和边界，最终由指挥人员进行判定审查。智能化技术可以加速方案搜索、降低大规模数据处理的压力，但不能越过指挥链路、交战规则和附带损伤判断等必须由人工承担的决策环节。近年来，部分研究开始探索将可解释决策方法与深度强化学习结合，试图在保持决策效率的同时为策略选择提供理由说明^[116-117]，这一方向为评估与决策的可信衔接提供了新思路，但目前仍处于早期探索阶段。

表 1 人工智能技术驱动毁伤评估主要技术路线

Table 1 Main technical routes of damage assessment driven by artificial intelligence technology				
技术路线	输入/数据来源	主要用途/场景	核心优势	局限性
计算机视觉	光学、红外、SAR、视频、无人平台影像	打后评估、初步判定	实时性较好，适合可见毁伤特征提取	对遮挡、烟尘和跨域场景敏感，难以直接判断功能毁伤
代理模型	试验数据、仿真数据、历史案例	打前预测、参数验证、方案比对	可提高多工况计算效率	依赖样本覆盖和仿真验证，泛化能力不稳定
知识图谱	目标结构、部件功能、毁伤判据、专家知识	功能毁伤理解分析、体系目标评估	语义清晰，可追溯性较强	知识构建和维护成本高，动态推理能力不足
贝叶斯网络	多源观测、专家赋值、状态转移信息	打后状态更新、多源融合	适合表达不确定性和置信度	结构和概率参数获取困难
图神经网络	结构拓扑、网络关系、仿真样本	结构响应预测、体系目标毁伤评估	适合表达节点关联和传播效应	需要高质量图结构和跨场景验证
强化学习	毁伤结果、目标特性、约束条件、态势信息	火力筹划、评估驱动再决策	适合方案搜索和动态更新	训练环境与真实场景存在差距，可解释性不足

以上五方面内容共同构成智能毁伤评估的技术基础，具体技术路线及对比分析如表 1 所示。感知与特征提取将原始观测转化为可计算数据；数据驱动模型从样本中学习毁伤模式；知识驱动方法引入目标结构、部件功能和毁伤判据约束；多源融合按来源可信度和语义粒度整合信息；智能决策与优化则把毁伤结论与目标价值、武器效能和任务风险联系起来。由此，智能毁伤评估的技术链路可概括为：先形成可靠输入，再完成状态判断，最后支撑后续行动。

2.6 面向作战闭环的技术适配与应用前景

前述五类技术分别对应毁伤评估中的感知、建模、推理、融合和决策支撑能力。面向作战应用时，这些技术不能简单叠加，而要根据打前预测、打后判定、体系评估和再决策等环节的任务特点进行组合。不同环节对数据来源、时效性、可信度和解释性的要求不同，适合采用的智能化方法也存在差异。因此，智能毁伤评估的应用前景主要体现在技术与任务环节的适配关系上，即哪些技术适合进入哪些环节，以及以何种方式使用效果更好。

在打前预测环节，目标尚未发生实际毁伤，主要依赖目标构效关系、武器威力参数、弹目交会条件、试验数据和仿真数据进行推断。该环节对物理可信度要求高，单纯依靠数据驱动模型并不合适，应考虑在传统毁伤机理、靶场试验和高保真仿真的基础上，引入代理模型、图学习和不确定性量化方法，用于生成多工况数据和方案比对。结合有限元仿真和试验数据的代理模型可快速分析不同爆炸载荷参量和目标状态参量等因素对毁伤概率、结构毁伤范围和功能下降的影响^[13,90-92,98-99]。代理模型的出现和发展不是替代试验和高保真计算，而是在其约束下扩大参数覆盖范围，筛选敏感因素，并给出预测结果的置信区间和适用边界。进一步结合武器目标分配和智能优化方法，可为火力筹划提供候选方案，并反向明确打后评估需要重点观测的毁伤效应、传感器类型和判定指标^[114,112]。

在打后判定环节，评估依据来自实际观测数据，主要矛盾是如何在时间受限、信息不完整和环境干扰较强的条件下，快速形成可信判断。计算机视觉、目标匹配和变化检测是该环节中最容易落地的技术方向，可用于弹坑、倒塌、烧蚀、部件缺失、目标姿态变化等可见毁伤特征的自动发现。

YOLO-VGGNet、xBD 和 ChangeOS 等研究分别从军事目标在线判定、灾前灾后影像配准和对象级毁伤分级等角度提供了参考^[4-5,7]；Project Maven 的应用也表明，机器可承担大规模图像中的目标检测

和候选区域筛选,再由人员进行复核解释^[116]。但打后评估不能止步于图像标签。可见毁伤与功能毁伤之间常常不是一一对应关系,地下设施、电源系统、通信链路和关键内部部件的失效也未必能从光学图像中直接判断。因此,应由视觉模型承担毁伤特征提取和候选区域筛选,由多源融合、动态贝叶斯网络和知识图谱进一步整合光学、红外、SAR、电子侦察和任务报告等信息,形成带有信息来源、置信度和功能含义的状态判断^[104,109,106-108]。

在体系影响评估环节,单目标的毁伤评估仅作为评估基础,重点在于局部毁伤如何传导为功能下降,以及功能下降如何影响任务能力。对机场目标,评估重点不只是弹坑数量和开坑尺寸,还包括剩余可用跑道长度、抢修时间、单位时间出动能力和调度能力;对防空、指挥通信等阵地,评估重点则是关键节点受损后探测覆盖、指挥链路和恢复时间的变化。复杂网络、贝叶斯网络、知识图谱、图神经网络和作战效能评估方法与这一环节较为适配,因为它们能够表达节点、功能、任务和依赖关系之间的关联^[118-119,105,110-111]。不过,体系评估目前仍属于研究和应用基础较薄弱的方向,难点在于真实体系结构、数据链路、节点特性等数据难以获得。可考虑先围绕典型目标体系构建任务网络和功能网络,再把打后观测信息、仿真结果和专家知识映射到网络节点状态中,逐步实现从物理毁伤到体系效能变化的推理。

在评估驱动再决策环节,智能化技术的作用不应理解为自动给出打击命令,而是为再侦察、再筹划和再打击提供可复核的状态输入。CJCSI 3162.02A 明确将 BDA、弹药效能评估、附带损伤评估和再攻击建议共同纳入战斗评估框架;JADC2 也强调跨域数据连接与快速循环,这说明毁伤评估结果需要进入后续行动链条^[2,115,117,120]。适合该环节的技术主要包括不确定性表达、可解释决策、任务规划和人机协同方法。评估模型应输出评估数据、目标状态、置信度、潜在风险和补充侦察信息,而不是只输出“轻度、中度、重度毁伤”的等级标签。智能模型可用于信息筛选、状态更新和候选判断生成,专家和指挥人员则负责关键信息核查、功能含义解释和最终行动决策。只有把模型输出设计成可追溯、可复核、可修正的信息接口,智能毁伤评估才可能稳定支撑作战闭环中的后续行动调整。

3 问题与挑战

人工智能已经提升了毁伤评估中数据处理、特征提取和状态判定的效率,但尚未解决该领域的基础难题。相比单个模型精度还能提高多少,更需要关注的是数据、机理、效应、效能和决策之间能否形成稳定衔接。结合前文分析,当前问题主要集中在以下六个方面。

第一,真实毁伤数据仍然不足。毁伤试验成本高、风险大,能够覆盖的目标类型和打击工况有限;演习、实战样本受保密限制难以形成可公开复用的数据集。公开灾害数据、民用结构损伤数据和仿真数据可以提供补充,但与军事目标在材料结构、毁伤机理、测试条件和毁伤判据上存在明显差异。此外,后续研究需要区分试验数据、仿真数据、公开遥感数据和专家标注数据的适用边界,不能把不同来源的数据混在一起后直接训练和评价。

第二,物理毁伤、功能毁伤和体系效能之间的映射仍不清楚。现有许多研究能够识别弹坑、裂缝、倒塌、燃烧等可见毁伤,却难以说明目标是否失去完成既定任务的能力。对机场、防空体系、通信节点、桥梁和地下设施而言,外观毁伤与功能失效并不总是一一对应。后续研究需要把目标结构、关键部件、构效关系和任务指标组织起来,建立从物理毁伤到功能下降、再到体系能力变化的推理关系。这也是智能毁伤评估从“看见毁伤”走向“理解毁伤”的关键。

第三,多源信息融合仍缺少可靠的体系方法和质量控制。光学、红外、SAR、电子侦察、通信活动、传感器和任务报告在时间、空间、分辨率和语义粒度上差异很大,战场环境还会出现遮挡、伪装、模态缺失和数据冲突。如果融合模型不区分信息来源和可信度,反而可能把错误信息包装成看似稳定的结论。较合理的做法是先评价数据质量和数据冲突,再进行毁伤评估,并在输出中保留置信度、缺失信息和相互矛盾的标注数据。

第四,模型泛化和可信验证不足。毁伤结果受目标结构、材料本构、武器平台、测量方式、环境

条件和敌方欺骗手段等因素影响, 试验场景外性能下降是常态。现有研究往往重视平均准确率、检测精度或分类指标, 较少报告跨目标、跨传感器、跨区域和强干扰条件下的失效模式。面向应用的测试不应只给出单一因素牵引的指标, 还应包括域外测试、置信度校准、边界量化和复核机制。

第五, 评估结果进入决策链条的接口还不清晰。毁伤等级、功能下降、体系效能和再行动建议之间缺少统一话语体系, 导致不少模型结果仍停留在技术演示层面。可用于决策的评估输出, 应说明结果来源、目标状态、功能下降的具体结论, 以及结论可靠到什么程度、还需要补充哪些侦察信息。只有形成这种可解释、可复核的输出接口, 智能毁伤评估结果才能进入再侦察、再筹划和再打击过程。

第六, 人机协同和责任边界需要提前设计。毁伤评估结论可能影响后续打击、资源分配和威胁控制, 错误结论带来不可控的实际后果。AI 系统和模型可以处理数据、分析计算和评估判定, 但不能替代授权决策。系统设计应记录数据来源、模型版本、潜在风险、人工审核和结论修正过程, 使评估结果能够追溯、复核和改进。

综上, 智能化毁伤评估的关键难点不在于某一类算法本身, 而在于数据、机理、模型和决策之间尚未形成稳定衔接。后续研究应更加重视可信评估链条构建, 使毁伤特征识别、毁伤链路推理、多源信息校验和人机协同机制能够相互支撑, 从而提高毁伤评估结论的可解释性、可验证性和决策适用性。

4 结论

毁伤评估的核心问题始终没有变, 打前要预测武器作用后可能形成什么效果, 打后要确认目标是否达到预期毁伤, 进而支撑后续作战行动闭环。在这个过程中, 人工智能技术的价值在于提高信息处理效率, 扩展可分析的数据范围, 并把图像、传感器、仿真、试验和专家知识组织成可更新的评估流程。

从现有研究看, 人工智能已经在几个环节发挥了较明显的赋能作用。计算机视觉相关技术提高了目标定位、变化检测和毁伤区域识别效率; 数据驱动模型降低了部分仿真和工况扫描成本; 知识图谱、图模型和贝叶斯方法有助于把部件失效同功能毁伤联系起来; 多源融合和智能优化使评估结果有机会进入再侦察、再打击和资源调整过程。这些进展说明, 智能毁伤评估不再只是图像判读自动化, 而是在向打前预测、打后确认和闭环决策延伸。同时, 人工智能无法消除毁伤评估中的不确定性。真实样本少、仿真偏差、场景迁移、信息冲突和责任追溯, 都会限制模型应用。未来研究不宜只追求更大的网络或更高的分类精度, 而应围绕数据可信、机理约束、信息融合、功能推理和人机协同建立完整链条。

人工智能技术能否有效赋能毁伤评估, 不仅仅取决于某项技术的可行性或者数据体量、置信度的指标优势, 更取决于它能否在传统毁伤评估领域方法理论的基础上, 创建出与现代算力、指挥链、情报源等更为匹配的毁伤评估新范式, 推动整个领域向更快、更准、更可信的应用前景发展。

参考文献

- [1] 卢芳云, 李翔宇, 彭永, 等. 武器毁伤效能评估方法[M]. 长沙: 国防科技大学出版社, 2025:5-7.
- [2] Joint Chiefs of Staff. CJCSI 3162.02A: Methodology for combat assessment[R]. Washington, D.C.: Joint Chiefs of Staff, 2021.
- [3] 卢芳云, 彭永, 张克钊, 等. 目标易损性分析共性方法[M]. 长沙: 国防科技大学出版社, 2023:39-42.
- [4] Zheng Z, Zhong Y, Wang J, Ma A, Zhang L. Building damage assessment for rapid disaster response with a deep object-based semantic change detection framework: From natural disasters to man-made disasters[J]. Remote Sensing of Environment, 2021, 265: 112636. DOI: 10.1016/j.rse.2021.112636.

- [5] Gupta R, Hosfelt R, Sajeev S, et al. xBD: A dataset for assessing building damage from satellite imagery[EB/OL]. arXiv:1911.09296, 2019. DOI: 10.48550/arxiv.1911.09296.
- [6] Qi Z F, Liu Q Q, Wang J, Li J X. Battle damage assessment based on an improved Kullback-Leibler divergence sparse autoencoder[J]. Frontiers of Information Technology & Electronic Engineering, 2017, 18(12): 1991-2000. DOI: 10.1631/fitee.1601395.
- [7] Xu Y, Yu Q, Wang Y, Xiao J, Zhou Z, Lu H. Ground target detection and damage assessment by patrol missiles based on YOLO-VGGNet[J]. Applied Sciences, 2022, 12(19): 9484. DOI: 10.3390/app12199484.
- [8] 孔祥锡, 秦闻远, 苏飘逸, 等. 基于深度学习及模糊层次分析的毁伤评估算法[J]. 航空学报, 2024, 45(19): 329503. KONG X X, QIN W Y, SU P Y, et al. Damage assessment algorithm based on deep learning and fuzzy analytic hierarchy process[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(19): 329503. DOI: 10.7527/S1000-6893.2023.29503.
- [9] 李珩, 马国锐, 刘宇迪, 张海明. 基于遥感影像的大当量爆炸建筑物毁伤评估模型[J]. 爆炸与冲击, 2024, 44(3): 031407. LI H, MA G R, LIU Y D, ZHANG H M. A remote sensing imagery-based model for assessment of building damage induced by large-equivalent explosions[J]. Explosion and Shock Waves, 2024, 44(3): 031407. DOI: 10.11883/bzycj-2023-0331.
- [10] Wang L Q, Qian B W, Zhang C Y, et al. A review of artificial intelligence techniques in blast field shockwave pressure testing[J]. Journal of Measurements in Engineering, 2025, 13(2): 45-58. DOI: 10.21595/jme.2024.24423.
- [11] Li Y T, Qi H W, Chen H Y, et al. Deep change monitoring: A hyperbolic representative learning framework and a dataset for long-term fine-grained tree change detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2025: 27346-27356. DOI: 10.1109/cvpr52734.2025.02547.
- [12] Ding L, Hong D F, Zhao M F, et al. A survey of sample-efficient deep learning for change detection in remote sensing: Tasks, strategies, and challenges[J]. IEEE Geoscience and Remote Sensing Magazine, 2025, 13(3): 2-27. DOI: 10.1109/mgrs.2025.3533605.
- [13] 潘刘娟, 张雍奇, 王祉乔, 等. 图学习驱动的爆炸冲击钢筋混凝土柱结构响应的建模与预测[J]. 爆炸与冲击, 2026, 46(5): 051435. PAN L J, ZHANG Y Q, WANG Z Q, et al. Modeling and prediction of blast-induced response in RC columns using graph neural networks[J]. Explosion and Shock Waves, 2026, 46(5): 051435. DOI: 10.11883/bzycj-2025-0179.
- [14] 杨伟涛, 刘康泰, 邓鑫. 基于人工智能的弹药毁伤效能评估优化框架研究[J]. 装备环境工程, 2025, 22(9): 94-104. YANG W T, LIU K T, DENG L. Research on an optimization framework for ammunition damage effectiveness evaluation based on artificial intelligence[J]. Equipment Environmental Engineering, 2025, 22(9): 94-104. DOI: 10.7643/issn.1672-9242.2025.09.011.
- [15] Gonzalez R C, Woods R E. Digital Image Processing[M]. 3rd ed. Upper Saddle River: Pearson, 2008:15-17.
- [16] 陈曦, 翟红波. 基于图像的目标毁伤评估研究进展[J]. 兵器装备工程学报, 2024, 45(7): 224-234. CHEN X, ZHAI H B. Image-based damage assessment: a review[J]. Journal of Ordnance Equipment Engineering, 2024, 45(7): 224-234. DOI: 10.11809/bqzbgcxb2024.07.030.
- [17] Lewis J P. Fast normalized cross-correlation[C]//Vision Interface. 1995, 10(1): 120-123.
- [18] Barnea D I, Silverman H F. A class of algorithms for fast digital image registration[J]. IEEE Transactions on Computers, 1972, C-21(2): 179-186. DOI: 10.1109/tc.1972.5008923.
- [19] Harris C, Stephens M. A Combined Corner and Edge Detector[C]//Alvey, 1988. DOI: 10.5244/c.2.23.
- [20] Rosten E. Machine Learning for Very High-Speed Corner Detection[C]//ECCV, 2006. DOI: 10.1007/11744023_34.
- [21] Ke Y. PCA-SIFT: A More Distinctive Representation For Local Image Descriptors[C]//CVPR, 2004. DOI: 10.1109/cvpr.2004.1315206.
- [22] Bay H, Tuytelaars T, Van Gool L. SURF: Speeded up robust features[C]//European Conference on Computer Vision. 2006: 404-417. DOI: 10.1007/11744023_32.
- [23] Abdel-Hakim A. CSIFT: A SIFT Descriptor With Color Invariant Characteristics[C]//CVPR, 2006. DOI: 10.1109/cvpr.2006.95.

- [24] Mikolajczyk K, Schmid C. A Performance Evaluation of Local Descriptors[J]. TPAMI, 2005. DOI: 10.1109/tpami.2005.188.
- [25] Dalal N, Triggs B. Histograms of oriented gradients for human detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). San Diego, CA, USA, 2005: 886-893. DOI: 10.1109/cvpr.2005.177.
- [26] Kuglin C D, Hines D C. The phase correlation image alignment method[C]//Proceedings of the IEEE International Conference on Cybernetics and Society. San Francisco, CA, USA, 1975: 163-165.
- [27] Reddy B S, Chatterji B N. An FFT-based technique for translation, rotation, and scale-invariant image registration[J]. IEEE Transactions on Image Processing, 1996, 5(8): 1266-1271. DOI: 10.1109/83.506761.
- [28] Ma J, Jiang X, Fan A, et al. Image matching from handcrafted to deep features: A survey[J]. International Journal of Computer Vision, 2021, 129: 23-79. DOI: 10.1007/s11263-020-01359-2.
- [29] Kuncheva L I, Faithfull W J. PCA Feature Extraction for Change Detection in Multidimensional Unlabeled Data[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(1): 69-80. DOI: 10.1109/tnnls.2013.2248094.
- [30] Li Qiang, Gong Lixia, Zhang Jingfa. A Correlation Change Detection Method Integrating PCA and Multi-texture Features of SAR Image for Building Damage Detection[J]. European Journal of Remote Sensing, 2019, 52(1): 435-447. DOI: 10.1080/22797254.2019.1630322.
- [31] Osama Yousif, Ban Yifang. Improving Urban Change Detection from Multitemporal SAR Images Using PCA-NLM[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(4): 2032-2041. DOI: 10.1109/tgrs.2013.2245900.
- [32] Shen Yu, Zhu Sijie, Yang Taojianan, et al. BDANet: Multiscale Convolutional Neural Network with Cross-directional Attention for Building Damage Assessment from Satellite Images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14. DOI: 10.1109/tgrs.2021.3080580.
- [33] Lowe D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110. DOI: 10.1023/b:visi.0000029664.99615.94.
- [34] DeTone D, Malisiewicz T, Rabinovich A. SuperPoint: Self-supervised interest point detection and description[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2018: 224-236. DOI: 10.1109/cvprw.2018.00060.
- [35] Sarlin P E, DeTone D, Malisiewicz T, Pollefeys M. SuperGlue: Learning feature matching with graph neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 4938-4947. DOI: 10.1109/cvpr42600.2020.00499.
- [36] Sun J, Shen Z, Wang Y, Bao H, Zhou X. LoFTR: Detector-free local feature matching with transformers[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 8922-8931. DOI: 10.1109/cvpr46437.2021.00881.
- [37] Yi K M, Trulls E, Lepetit V, et al. LIFT: Learned invariant feature transform[C]//European Conference on Computer Vision. Springer, 2016: 467-483. DOI: 10.1007/978-3-319-46466-4_28.
- [38] Tian Y, Fan B, Wu F. L2-Net: Deep learning of discriminative patch descriptor in Euclidean space[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 661-669. DOI: 10.1109/cvpr.2017.649.
- [39] Mishchuk A, Mishkin D, Radenovic F, et al. Working hard to know your neighbor's margins: Local descriptor learning loss[C]//Advances in Neural Information Processing Systems. 2017, 30: 4826-4837. DOI: 10.48550/arxiv.1705.10872.
- [40] Tian Y, Yu X, Fan B, et al. SOSNet: Second order similarity regularization for local descriptor learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 11008-11017. DOI: 10.1109/cvpr.2019.01127.
- [41] Tian Y, Barroso-Laguna A, Ng T, et al. HyNet: Learning local descriptor with hybrid similarity measure and triplet loss[C]//Advances in Neural Information Processing Systems. 2020, 33: 7401-7412. DOI: 10.48550/arxiv.2006.10202.
- [42] Luo Z, Shen T, Zhou L, et al. ContextDesc: Local descriptor augmentation with cross-modality context[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 2522-2531. DOI: 10.1109/cvpr.2019.00263.

- [43] Dusmanu M, Rocco I, Pajdla T, et al. D2-Net: A trainable CNN for joint description and detection of local features[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 8092-8101. DOI: 10.1109/cvpr.2019.00828.
- [44] Luo Z, Zhou L, Bai X, et al. ASLFeat: Learning local features of accurate shape and localization[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 6588-6597. DOI: 10.1109/cvpr42600.2020.00662.
- [45] Revaud J, Weinzaepfel P, De Souza C, et al. R2D2: Repeatable and reliable detector and descriptor[C]//Advances in Neural Information Processing Systems. 2019. DOI: 10.48550/arxiv.1906.06195.
- [46] Xue F, Budvytis I, Cipolla R. SFD2: Semantic-guided feature detection and description[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 5206-5216. DOI: 10.1109/cvpr52729.2023.00504.
- [47] Tian Y, Balntas V, Ng T, et al. D2D: Keypoint extraction with describe to detect approach[C]//Computer Vision - ACCV 2020. Cham: Springer, 2021: 223-240. DOI: 10.1007/978-3-030-69535-4_14.
- [48] Li K, Wang L, Liu L, et al. Decoupling makes weakly supervised local feature better[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 15838-15848. DOI: 10.1109/cvpr52688.2022.01538.
- [49] Sun J, Zhu J, Ji L. Shared coupling-bridge for weakly supervised local feature learning[EB/OL]. arXiv preprint arXiv:2212.07047, 2022. DOI: 10.48550/arxiv.2212.07047.
- [50] Chen H, Luo Z, Zhang J, et al. Learning to match features with seeded graph matching network[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021: 6301-6310. DOI: 10.1109/iccv48922.2021.00624.
- [51] Shi Y, Cai J X, Shavit Y, et al. ClusterGNN: Cluster-based coarse-to-fine graph neural network for efficient feature matching[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 12517-12526. DOI: 10.1109/cvpr52688.2022.01219.
- [52] Lindenberger P, Sarlin P E, Pollefeys M. Light Glue: Local feature matching at light speed[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023: 17627-17638. DOI: 10.1109/iccv51070.2023.01616.
- [53] Rocco I, Cimpoi M, Arandjelović R, et al. Neighbourhood consensus networks[C]//Advances in Neural Information Processing Systems, 2018, 31: 1651-1662. DOI: 10.48550/arxiv.1810.10510.
- [54] Rocco I, Arandjelović R, Sivic J. Efficient neighbourhood consensus networks via submanifold sparse convolutions[C]//European Conference on Computer Vision. Springer, 2020: 605-621. DOI: 10.1007/978-3-030-58545-7_35.
- [55] Li X, Han K, Li S, et al. Dual-resolution correspondence networks[C]//Advances in Neural Information Processing Systems. 2020: 17346-17357. DOI: 10.48550/arxiv.2006.08844.
- [56] Truong P, Danelljan M, Van Gool L, et al. GOCor: Bringing globally optimized correspondence volumes into your neural network[C]//Advances in Neural Information Processing Systems. 2020: 14278-14290. DOI: 10.3929/ethz-b-000455564.
- [57] Chen H, Luo Z, Zhou L, et al. Aspanformer: Detector-free image matching with adaptive span transformer[C]//European Conference on Computer Vision. Springer, 2022: 20-36. DOI: 10.1007/978-3-031-19824-3_2.
- [58] Wang Q, Zhang J, Yang K, et al. MatchFormer: Interleaving attention in transformers for feature matching[C]//Proceedings of the Asian Conference on Computer Vision. 2022: 2746-2762. DOI: 10.1007/978-3-031-26313-2_16.
- [59] Xie T, Dai K, Wang K, et al. DeepMatcher: A deep transformer-based network for robust and accurate local feature matching[EB/OL]. arXiv preprint arXiv:2301.02993, 2023. DOI: 10.48550/arXiv.2301.02993.
- [60] Chang J, Yu J, Zhang T. Structured epipolar matcher for local feature matching[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 6176-6185. DOI: 10.1109/cvprw59228.2023.00657.
- [61] Edstedt J, Athanasiadis I, Wadenbäck M, et al. DKM: Dense kernelized feature matching for geometry estimation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 17765-17775. DOI: 10.1109/cvpr52729.2023.01704.
- [62] Edstedt J, Sun Q, Bökman G, et al. RoMa: Revisiting robust losses for dense feature matching[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2024: 19790-19800. DOI: 10.1109/cvpr52733.2024.01871.

- [63] Zhou Q, Sattler T, Leal-Taixé L. Patch2Pix: Epipolar-guided pixel-level correspondences[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 4669-4678. DOI: 10.1109/cvpr46437.2021.00464.
- [64] Huang D, Chen Y, Liu Y, et al. Adaptive assignment for geometry aware local feature matching[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 5425-5434. DOI: 10.1109/cvpr52729.2023.00525.
- [65] Ni J, Li Y, Huang Z, et al. PATS: Patch area transportation with subdivision for local feature matching[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 17776-17786. DOI: 10.1109/cvpr52729.2023.01705.
- [66] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778. DOI: 10.1109/cvpr.2016.90.
- [67] Doğru A, Bouarfa S, Arizar R, et al. Using convolutional neural networks to automate aircraft maintenance visual inspection[J]. Aerospace, 2020, 7(12): 171. DOI: 10.3390/aerospace7120171.
- [68] Xu G, Han X, Zhang Y, et al. Dam crack image detection model on feature enhancement and attention mechanism[J]. Water, 2023, 15(1): 64-80. DOI: 10.3390/w15010064.
- [69] Pan H, Zhao X, Ge H, et al. Hyperspectral image classification based on multiscale hybrid networks and attention mechanisms[J]. Remote Sensing, 2023, 15(11): 2720-2751. DOI: 10.3390/rs15112720.
- [70] Cui Y, Li W, Chen L, et al. Feature fusion network model based on dual attention mechanism for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61(10): 1-16. DOI: 10.1109/tgrs.2023.3325253.
- [71] Luo DM, Han J, Wang TZ, et al. Research on intelligent diagnosis of freeze-thaw damage of concrete based on improved YOLO v8s-Segformer integrated model[J]. Engineering Structures, 2025, 343: 121177. DOI: 10.1016/j.engstruct.2025.121177.
- [72] Yin XF, Wang CH, Chen W, et al. A UAV-deployable lightweight framework for real-time bridge crack detection via YOLO-LY algorithm[J]. Engineering Structures, 2026, 358: 122629. DOI: 10.1016/j.engstruct.2026.122629.
- [73] Redmon J, Farhadi A. YOLOv3: An incremental improvement [EB/OL]. arXiv:1804.02767, 2018. DOI: 10.48550/arXiv.1804.02767.
- [74] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[C]//Proceedings of the IEEE International Conference on Computer Vision. 2017: 618-626. DOI: 10.1109/iccv.2017.74.
- [75] Zhang G, Luo Z, Cui K, Lu S. Meta-DETR: Image-level few-shot detection with inter-class correlation exploitation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(11): 12832-12843. DOI: 10.1109/tpami.2022.3195735.
- [76] ZHANG H, CISSE M, DAUPHIN Y N, et al. mixup: beyond empirical risk minimization[C]//Proceedings of the 6th International Conference on Learning Representations. Vancouver: ICLR, 2018. DOI: 10.48550/arXiv.1710.09412.
- [77] SCHWARTZ E, KARLINSKY L, SHTOK J, et al. Delta-encoder: an effective sample synthesis method for few-shot object recognition[C]//Proceedings of the 32nd Conference on Neural Information Processing Systems. Montreal: NeurIPS, 2018: 2845-2855. DOI: 10.48550/arXiv.1806.04734.
- [78] CHEN Z T, FU Y W, ZHANG Y D, et al. Multi-level semantic feature augmentation for one-shot learning[J]. IEEE Transactions on Image Processing, 2019, 28(9): 4594-4605. DOI: 10.1109/tip.2019.2910052.
- [79] ZHANG R, CHE T, GHAHRAMANI Z, et al. MetaGAN: an adversarial approach to few-shot learning[C]//Proceedings of the 32nd Conference on Neural Information Processing Systems. Montreal: NeurIPS, 2018: 2361-2370. DOI: 10.5555/3327144.3327163.
- [80] CHEN W Y, LIU Y C, KIRA Z, et al. A closer look at few-shot classification[C]//Proceedings of the 7th International Conference on Learning Representations. New Orleans: ICLR, 2019. DOI: 10.48550/arXiv.1904.04232.
- [81] DHILLON G S, CHAUDHARI P, RAVICHANDRAN A, et al. A baseline for few-shot image classification[C]//Proceedings of the 8th International Conference on Learning Representations. Addis Ababa: ICLR, 2020. DOI: 10.48550/arXiv.1909.02729.
- [82] QI H, BROWN M, LOWE D G. Low-shot learning with imprinted weights[C]//Proceedings of the IEEE/CVF Conference

- on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 5822-5830. DOI: 10.1109/cvpr.2018.00610.
- [83] QIAO S Y, LIU X C, SHEN W, et al. Few-shot image recognition by predicting parameters from activations[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7229-7238. DOI: 10.1109/cvpr.2018.00755.
- [84] RAVI S, LAROCHELLE H. Optimization as a model for few-shot learning[C]//Proceedings of the 5th International Conference on Learning Representations. Toulon: ICLR, 2017: 458-469.
- [85] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney: JMLR, 2017: 1126-1135. DOI: 10.5555/3305381.3305498.
- [86] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]//Proceedings of the International Conference on Machine Learning Deep Learning Workshop. Lille: ICML, 2015.
- [87] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: NeurIPS, 2016: 3637-3645. DOI: 10.5555/3157382.3157504.
- [88] SNELL J, SWERSKY K, ZEMEL R S. Prototypical networks for few-shot learning[C]//Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach: NeurIPS, 2017: 4077-4087. DOI: 10.5555/3294996.3295163.
- [89] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: relation network for few-shot learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 1199-1208. DOI: 10.1109/cvpr.2018.00131.
- [90] Lu AG, Zhou H, Luo F, et al. Study on blast loading of charges with Al/PTFE reactive casing in confined spaces[J]. International Journal of Impact Engineering, 2026, 213: 105693. DOI: 10.1016/j.ijimpeng.2026.105693.
- [91] Kong XS, Zhu Z, Zheng C, et al. Numerical investigation on the dynamic behavior of thermoplastic fiber-metal laminates subject to confined explosion loading[J]. Thin-Walled Structures, 2025, 214: 113354. DOI: 10.1016/j.tws.2025.113354.
- [92] Kong XS, Zhu Z, Zheng C, et al. Dynamic response and failure behaviour of thermoplastic fibre-metallaminates subjected to confined blast load[J]. Thin-Walled Structures, 2023, 187: 110760. DOI: 10.1016/j.tws.2023.110760.
- [93] 杨伟涛, 刘康泰. 多维数据分析与人工智能技术在弹药试验中的应用潜力分析[J]. 装备环境工程, 2025, 22(8): 81-88. YANG W T, LIU K T. Application potential of multidimensional data analysis and artificial intelligence in ammunition testing[J]. Equipment Environmental Engineering, 2025, 22(8): 81-88. DOI: 10.7643/issn.1672-9242.2025.08.011.
- [94] 齐国飞, 雷婧宇, 梁争峰. 典型爆炸及冲击载荷作用下钢筋混凝土结构毁伤行为综述[J]. 兵器装备工程学报, 2025, 46(11): 282-294. QI G F, LEI J Y, LIANG Z F. Review on damage behavior of reinforced concrete structures under typical explosion and impact loads[J]. Journal of Ordnance Equipment Engineering, 2025, 46(11): 282-294. DOI: 10.11809/bqzbgcxb2025.11.034.
- [95] 刘颖茜, 姚小明, 李碧波. 高速摄像在某强冲击试验中的试验弹测速应用研究[J]. 机械科学与技术, 2024, 43(5): 904-910. LIU Y Q, YAO X M, LI B B. Application of high-speed photography to projectile velocity measurement in a strong impact test[J]. Mechanical Science and Technology for Aerospace Engineering, 2024, 43(5): 904-910. DOI: 10.13433/j.cnki.1003-8728.20220261.
- [96] 顾廷炜, 汤明宏, 孙晓冬. 智能传感器技术应用现状与发展趋势综述[J]. 物联网技术, 2025, 15(1): 59-63. GU T W, TANG M H, SUN X D. Review of application status and development trend of intelligent sensor technology[J]. Internet of Things Technologies, 2025, 15(1): 59-63.
- [97] 周沪. 舰船舱内爆炸载荷燃热增强效应及结构毁伤特性研究[D]. 武汉: 武汉理工大学, 2024.
- [98] 彭江舟, 潘刘娟, 高光发, 等. 城市建筑外爆威力场与毁伤效应数智仿真模型及应用[J]. 爆炸与冲击, 2026, 46(2): 022202. PENG J Z, PAN L J, GAO G F, et al. A digital intelligence simulation model for explosion power field and urban building damage effect and its application[J]. Explosion and Shock Waves, 2026, 46(2): 022202. DOI: 10.11883/bzycj-2024-0471.

- [99] 何勇, 戎晓力, 吴威涛, 等. 数物驱动智能仿真在重要目标毁伤效应评估中的应用[J]. 防护工程, 2023, 45(6): 19-30. HE Y, RONG X L, WU W T, et al. Application of digital-physical driven intelligent simulation in damage effect assessment of important targets[J]. Protective Engineering, 2023, 45(6): 19-30. DOI: 10.3969/j.issn.1674-1854.2023.06.005.
- [100] Yu MY, Chen W, Hou J. Intelligent quantitative assessment of concrete cracks: adaptive data-driven dynamic segmentation model and damage grading architecture[J]. Measurement, 2025, 256: 118274. DOI: 10.1016/j.measurement.2025.118274.
- [101] Kawerinder Singh Sidhu, Adithya Jakkaraju, Prasad Prakash Yacham, et al. A Hybrid CNN-Logistic Regression Model for Accurate and Efficient Car Damage Assessment[C]//2025 6th International Conference for Emerging Technology (INCET). 2025. DOI: 10.1109/incet64471.2025.11140052.
- [102] 张子豪, 娄文忠, 郭志明, 等. 基于神经辐射场和层次分析的坦克三维重建和毁伤评估模型[J]. 兵工学报, 2025, 46(12): 241154. ZHANG Z H, LOU W Z, GUO Z M, et al. Damage assessment of tank based on neural radiance fields and hierarchical analysis[J]. Acta Armamentarii, 2025, 46(12): 241154. DOI: 10.12382/bgxb.2024.1154.
- [103] Chen Q S, Li B. Probabilistic damage assessment of longitudinally reinforced concrete beams using explainable AI and image-based analysis for structural health monitoring[J]. Structures, 2026, 87: 111594. DOI: 10.1016/j.istruc.2026.111594.
- [104] Ji S, Pan S, Cambria E, et al. A survey on knowledge graphs: Representation, acquisition, and applications[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(2): 494-514. DOI: 10.1109/tnnls.2021.3070843.
- [105] 金晓航, 王奇超, 张元鸣, 等. 知识图谱与时空图神经网络融合驱动的风电机组状态监测[J]. 仪器仪表学报, 2025, 46(12): 59-74. JIN X H, WANG Q C, ZHANG Y M, et al. Wind turbine condition monitoring driven by fusion of knowledge graph and spatio-temporal graph neural network[J]. Chinese Journal of Scientific Instrument, 2025, 46(12): 59-74.
- [106] 王继民, 姜灿, 韩斌, 等. 意外爆炸毁伤知识图谱研究[J]. 爆炸与冲击, 2026, 46(5): 051444. WANG J M, JIANG C, HAN B, et al. Research on the knowledge graph of accidental explosion damage[J]. Explosion and Shock Waves, 2026, 46(5): 051444. DOI: 10.11883/bzycj-2025-0329.
- [107] Murphy K P. Dynamic Bayesian Networks: Representation, Inference and Learning[D]. Berkeley: University of California, Berkeley, 2002.
- [108] 吴威涛, 谢文, 王祉乔, 等. 基于图神经网络的建筑侵爆毁伤数智仿真模型[J]. 陆军工程大学学报, 2025, 4(2): 71-79. WU W T, XIE W, WANG Z Q, et al. Digital-intelligent simulation model for building penetration-explosion damage based on graph neural network[J]. Journal of Army Engineering University of PLA, 2025, 4(2): 71-79. DOI: 10.12018/j.issn.2097-0730.20241007001.
- [109] Liu C W, Tian L B, Wang P F, et al. Knowledge-driven 3D damage mapping and decision support for fire-damaged reinforced concrete structures using enhanced deep learning and multi-modal sensing[J]. Advanced Engineering Informatics, 2025, 68: 103715. DOI: 10.1016/j.aei.2025.103715.
- [110] 张涛. 面向装备作战效能评估的多源数据融合方法研究[D]. 长沙: 国防科技大学, 2022:39-43.
- [111] 马晓明, 丁平, 晏卫东. 基于贝叶斯网络的舰船目标毁伤评估[J]. 兵工自动化, 2016, 35(6): 72-75. MA X M, DING P, YAN W D. Damage assessment of ship target based on Bayesian network[J]. Ordnance Industry Automation, 2016, 35(6): 72-75. DOI: 10.7690/bgzd.2016.06.017.
- [112] 蔡怀平, 陈英武. 武器-目标分配(WTA)问题研究进展[J]. 火力与指挥控制, 2006(12): 11-16. CAI H P, CHEN Y W. Research progress on weapon-target assignment (WTA) problem[J]. Fire Control & Command Control, 2006(12): 11-16.
- [113] El Sallab A, Abdou M, Perot E, et al. Deep reinforcement learning framework for autonomous driving[J]. Electronic Imaging, 2017, 2017(19): 70-76. DOI: 10.2352/issn.2470-1173.2017.19.avm-023.
- [114] 林雕, 朱燕, 杨剑. 面向动态毁伤概率和目标价值的武器目标分配方法[J]. 火力与指挥控制, 2024, 49(2): 138-143. LIN D, ZHU Y, YANG J. Weapon-target assignment method for dynamic damage probability and target value[J]. Fire Control & Command Control, 2024, 49(2): 138-143.
- [115] 徐艺博, 颜佳润, 曾志文, 等. 无通信条件下基于视觉毁伤评估的弹群对地目标自主攻击决策[J]. 兵工学报, 2024, 45(12): 4435-4450. XU Y B, YAN J R, ZENG Z W, et al. Autonomous attack decision-making of missile swarm against ground

targets based on visual damage assessment without communication[J]. *Acta Armamentarii*, 2024, 45(12): 4435-4450.

[116] Pellerin C. Project Maven to deploy computer algorithms to war zone by year's end[EB/OL]. U.S. Department of Defense, 2017.

[117] U.S. Department of Defense Responsible AI Working Council. Responsible Artificial Intelligence Strategy and Implementation Pathway[R/OL]. Washington, D.C.: Department of Defense, 2022.

[118] Jiang LZ, Yi J, Wu LX, et al. Rapid evaluation of seismic damage of regional railway lines based on GNN and genetic algorithm[J]. *Structures*, 2025, 79: 109548. DOI: 10.1016/j.istruc.2025.109548.

[119] Liu FY, Lu XZ, Ding WQ, et al. Graph neural network-based region-building seismic damage prediction[J]. *Engineering Structures* 349 (2026) 121881. DOI: 10.1016/j.engstruct.2025.121881.

[120] U.S. Department of Defense. Summary of the Joint All-Domain Command and Control Strategy[R/OL]. Washington, D.C.: Department of Defense, 2022.