


DOI:10.11943/CJEM2025083

文章编号:1006-9941(2025)07-0683-06



深度学习技术赋能工程结构爆炸毁伤评估

现代战争条件下,优先摧毁重点设施及重要经济目标能够达到瘫痪控制体系、瓦解经济基础的作用,是先发制人、制敌先机的重要手段,建筑目标的高效毁伤及评估技术成为当前世界强国的关注重点。随着科技的不断进步,各类精确制导弹药凭借超高速、远射程、高精度、大威力的优势,已成为打击建筑目标的首选武器。精确制导弹药打击建筑目标通常搭载侵爆战斗部,其产生的冲击和爆炸效应不仅会导致结构构件出现弯曲和剪切整体毁伤模式,还会出现成坑、贯穿、冲切、震塌等局部毁伤模式,关键承力构件的失效更可能引发结构连续性倒塌,从而有效摧毁重要设施,并对经济造成重大打击。俄乌、巴以冲突持续不断地提醒我们,只有高度重视工程结构的爆炸毁伤评估问题,才能做到胸有成竹、运筹帷幄,掌握主动权。

尽管“十三五”以来我国在毁伤评估领域已经取得了长足的技术进步及经验积累,但囿于工程结构几何构型的复杂性、材料属性的多样性以及荷载工况的不确定性,工程结构爆炸毁伤评估领域仍存在战场目标特性不清、毁伤效应计算效率低下、毁伤后评估方法匮乏等突出难题。面对以上难题,传统基于经验公式、理论分析与数值模拟的三大研究范式已面临难以突破的瓶颈,而深度学习作为数据密集型科学的核心技术,推动了以数据驱动发现新规律这一第四研究范式的形成,在量子多体问题求解、蛋白质结构预测等基础领域,以及大语言模型、自动驾驶等工程应用中均展现出颠覆性创新能力。因此,如何利用深度学习技术赋能解决工程结构爆炸毁伤评估突出难题,是每一个研究者在当前阶段需要思考的重要问题。

研究从工程结构爆炸毁伤评估的核心流程出发,提炼出工程结构模型智能生成、毁伤效应智能加速计算、毁伤效果智能后评估三个亟需突破的关键环节,探讨各环节面临的基础科学问题与技术挑战,浅略分析适用于不同场景的深度学习方法及其工程化应用路径,以期为该领域的交叉研究提供新思路,推动学术共同体对相关问题的深入探讨。

1. 工程结构模型智能生成

完备的目标信息是开展毁伤评估的前提。工程结构具有显著的异构性—其几何构型、功能布局及材料属性因设计标准、使用场景的差异呈现高度多样性,难以通过预置模型描述。因此,如何通过回传的情报或影像信息,快速生成包含结构形式、空间布局、关键构件分布的高精度数字孪生模型,成为毁伤评估流程的首要技术瓶颈。美国2001年研发的Smart Target Model Generator(STMG)系统虽开创了工程结构建模的工程化尝试,但其依赖简单建筑规范与经验规则的生成逻辑,导致模型理想化程度高、人工干预成本大,难以满足复杂战场环境下的快速建模需求(VERNER D, DUKES R. Automating ground-fixed target modeling with the smart target model generator [C]. Defense and Security Symposium, 2007:656401)。随着现代信息技术的爆炸式发展,高分遥感卫星、高空无人侦察机、单兵无人机等均可在分钟时间量级迅速回传大量的工程结构目标外部信息,如何充分利用这些建筑外部

信息,结合部分先验知识,通过深度学习方法的端到端特性,自动生成工程结构的三维几何模型及功能模型,是当前最具发展潜力的技术路径。

工程结构模型智能生成可划分为外部信息重构和内部信息生成两个步骤,二者通过数据接口形成闭环:前者基于情报数据构建结构外部轮廓与几何特征,后者依托生成模型推演内部功能布局与构件参数,最终形成包含几何-物理-功能属性的完整数字模型。

1.1 工程结构外部信息重构

外部信息重构的核心任务是从侦察数据中解译结构的三维几何特征,包括平面轮廓、高程分布、立面细节等可观测属性。相较于内部布局的隐蔽性,外部特征可通过光学/红外影像、激光点云等非接触手段直接获取,构成模型构建的基础数据层,同时为内部信息推理提供边界约束条件。

工程结构外部信息重构本质上属于计算机视觉中的特征识别问题,其技术路径可分为像素级语义解析与实例级几何建模两类方法。由于外部信息重构方法利用的数据通常为图像数据,因此采用的基础网络模型结构一般为以图像分析见长的卷积神经网络(Convolutional Neural Network, CNN)。语义分割(Semantic Segmentation)的本质是像素级的分类操作,通过为图像每个像素赋予语义标签,达到区分工程结构与无关背景的目的,经过对样本标签的监督训练,实现工程结构外部特征的自动提取。语义分割方法的发展已相当成熟,其经典模型FCN、U-net、SegNet、ResNet等均可在复杂数据集上实现高精度的预测效果(SHELHAMER E, LONG J, DARRELL T. *Fully Convolutional Networks for Semantic Segmentation*[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651)。然而,由于语义分割方法根据图像像素为每个纹理或类别分配唯一的类别标签,其无法区分同类目标中的不同实例。比如,若一张卫星图像中有多栋建筑,语义分割方法将无法独立区分其中任意两栋建筑。为解决以上问题,在语义分割的基础上发展出了实例分割方法,其具体方法又可进一步地细分为基于检测的分割(Detection-Based)与基于分割的检测(Segmentation-Based)。基于检测的分割以目标检测为核心,首先定位图像中的物体边界框(Bounding Box),再在检测框内预测每个实例的像素级掩码(Mask),从而实现不同实例的区分。基于分割的检测则仍以语义分割为基础,首先预测像素级别的类别信息,再通过聚类、嵌入向量等技术区分不同实例。由于基于检测的分割更适合物体边界清晰、中等密集的场景,更适用于工程结构外部信息重构,其代表性模型有Mask R-CNN、Cascade Mask R-CNN等(HE K, GKIOXARI G, DOLLAR P, et al. *Mask R-CNN*[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988)。此外,工程结构作为人造物往往具有规则轮廓,而图像数据中由于光照、阴影、云雾等干扰,往往使建筑纹理分布发生变化,导致识别出的建筑出现虚假的非规则轮廓,该问题可以通过轮廓回归的方法,修正得到正确的规则建筑轮廓,该类方法的具体实现可参考DeepSnake、E2EC等模型(PENG S, JIANG W, PI H, et al. *Deep Snake for Real-Time Instance Segmentation*[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020: 8530-8539)。

工程结构外部信息的来源并不限于图像数据,目前基于红外遥感数据、激光三维点云数据等数据类型的三维重建技术发展也相当迅速。对于具体方法的选择,尤其应当注意精度与时效的平衡问题,例如,通过三维点云反演建筑外部模型,虽然能获得毫米级的精度,但激光雷达扫描所需的时长往往是图像摄影测量时长的2~5倍,因此对时敏要求不同的任务,需权衡分析获取最适合当前场景的数据获取方式。

1.2 工程结构内部信息生成

内部信息生成旨在基于外部几何约束,推演房间布局、梁柱分布、材料属性等不可观测参数,为毁伤效应计算提供结构力学及功能模型输入。

工程结构内部信息生成早先多依赖基于参数化规则及优化算法的方法,但由于工程规范的内容难以实现全部参数化,且结构设计往往带有主观及经验因素,参数化规则的生成方法很难反映既有建筑的真实内部信息分布。此外,该类问题是典型的非凸优化问题(NP-hard),传统优化算法存在计算复杂度高、约束条件难以处理、缺乏全局收敛性等瓶颈问题。深度学习方法由于其数据驱动的特性,理论上如果能够提供符合真实建筑内部信息分布的数据集,便可训练对应的神经网络模型,生成高度近似分布的新数据,这种方法相较传统优化算法显然更有潜力。在结构设计自动领域,已有部分成果可用于工程结构内部信息生成,其中最常见的深度学习框架是生成对抗网络(Generative Adversarial Network, GAN),其本质是通过对抗性训练让两个神经网络(生成器与判别器)在博弈中共同进化。其基本原理是通过构建生成器并接收随机噪声,生成接近真实数据的样本(如假图像),目标是“骗过”判别器;构建的判别器通过接收真实数据和生成数据,输出真伪概率,目标是准确区分两者;通过对抗训练让二者在迭代中互相优化,最终使生成数据与真实数据分布趋于一致,即判别器无法区分二者的区别,则认为生成的数据达到了“以假乱真”的效果。

GAN是一种学习策略,其底层的数据处理及运算依然需要结合数据类型选择合适的基础网络架构。对于工程结构内部信息生成,早先多使用图像数据(建筑平面设计图或结构设计图),因此基础架构多选用CNN。但由于图像数据并不包含不同房间布局或构件间的拓扑信息,且其数据精度受图像分辨率影响较大,带来诸多数据预处理问题,因此最近更多工作转而采用图神经网络(Graph Neural Network, GNN)作为基础架构。GNN是专门处理图数据结构的一类深度学习架构,图数据与图像数据具有本质的不同,图像数据存储的是每个像素点上的通道信息,而图数据存储的是不同节点和边自身及其关联关系的信息,其数据内涵更为丰富,尤其适合表达本身具有强物理意义或关联关系的数据。因此,可以将工程结构内部分区或构件表示为图中的节点,将它们之间的拓扑关系表示为图中的边,节点和边上均可定义各类需要参与计算的属性(房间功能、位置坐标、构件材料、截面尺寸等),在此基础上的运算便可以同时考虑各个实体(房间或构件)之间的关联关系及实体所具有属性之间的关系。以上仅是一种将问题转化成图表示的方法,实际上同一问题可以有多种图表示方法,而图表示方法的设计也是GNN设计的重要环节之一。基于GNN结构内部信息生成方法中较具代表性的有用于平面房间布局生成的Graph2Plan,以及用于结构布局生成的GNN-EP-4(LIAO W, LU X, FEI Y, et al. Generative AI design for building structures[J]. Automation in Construction, 2024, 157:105187)。除了以上用于建筑平面生成的方法,近来也有部分工作着力于直接生成建筑的三维布局(如Building-GAN)或三维结构(如NeuralSim)。

2. 毁伤效应智能加速计算

毁伤效应是指工程结构在爆炸荷载作用下其内部威力场(冲击波、破片等)演化效应及结构构件/整体的响应。毁伤效应的预测与计算是毁伤评估需解决的核心问题,至今已发展了大量的理论、经验方法和数值计算方法。然而,爆炸荷载往往导致建筑结构出现强非线性响应和复杂的局部损伤特征,此类难解问题往往需要借助数值方法近似计算,而传统数值模拟方法面对大规模强动载效应(高应变率、强非线性、波动效应)计算仍存在显著的效率和可靠性问题,在可预见的未来仍难以大幅改善。而深度学习方法由于其“一次训练,高效推理”的执行机

制以及并行计算与硬件适配的天然优势,非常适合于实现毁伤效应智能加速计算。

2.1 毁伤终态预测的深度学习方法

虽然爆炸问题是动态问题,但针对仅需关键毁伤指标的快速评估场景,终态预测方法可通过构建“初始条件—毁伤结果”的直接映射关系,将动态过程压缩为静态函数拟合问题。基于通用近似定理(Universal Approximation Theorem),任何连续非线性函数都可以用一定参数量的前馈神经网络(Feedforward Neural Network, FNN)来近似,因此FNN(也称多层感知机,Multi-Layer Perceptron, MLP)强大的拟合能力可以很方便地用于构建各类毁伤效应预测的“初态—终态”的映射关系。此外,为了缓解维数灾难、局部化最优等问题,经常使用遗传算法、支持向量机、XG-Boost、Transformer等其他深度学习方法与FNN配合使用,以进一步提高预测精度(LI Q, WANG Y, SHAO Y, et al. A comparative study on the most effective machine learning model for blast loading prediction: From GBDT to Transformer[J]. *Engineering Structures*, 2023, 276:115310)。此类方法最常见的应用场景是通过大量数据的收集和模型训练,构建不同毁伤元、毁伤目标初始特性(材料、形状、尺寸等)条件下对关键荷载特征量(超压、冲量、动能等)或目标响应特征量(最大位移、速度、加速度等)的快速预测。

然而,毁伤终态预测方法存在一些难以忽视的问题:1)由于数据复杂度的限制,毁伤终态预测方法的预测对象一般只能限制在一些关键特征标量,难以预测空间场变量,在计算中抛弃了大量空间信息;2)“初态—终态”的直接映射模式下难以反映毁伤过程的动态特性,在计算中抛弃了大量时间信息;3)计算中大量抛弃空间、时间信息导致模型在训练过程中很难学习到现象背后的物理规律,导致模型泛化能力不足,预测结果易出现非物理“幻觉”,同时所需训练样本量大幅增加。这些问题只有在毁伤过程预测的深度学习方法框架内才能得到有效解决。

2.2 毁伤过程预测的深度学习方法

毁伤过程预测的深度学习方法在功能上与数值模拟方法相同,基于初始条件能够实现物理量的全场时空预测,但不同于数值模拟方法需要求解大量偏微分方程,深度学习方法利用数据驱动或物理损失方程使模型逼近真实物理系统的行为,这类问题在深度学习领域被称为物理模拟器(physics simulator)构建问题。

要实现物理系统的三维全场时空预测首先需要确定表征空间物理信息的方法,由于CNN对空间信息表征直观,且技术成熟度高,因此早期的深度学习物理模拟器往往使用CNN实现空间信息的演化。然而,CNN只能处理固定大小的像素或体素数据,导致其在解决拉格朗日网格、非规则网格等常见爆炸数值模拟的网格类型时存在严重的几何兼容性问题。此外,CNN不符合物理系统的坐标不变性(coordinate invariance)原则,因此常常需要对训练数据进行旋转、平移、翻转等数据增强操作,增大训练难度的同时降低了模型的泛化能力。鉴于CNN的以上不足,近年来众多深度学习物理模拟器的研究转而采用GNN实现空间信息演化。相较于CNN,GNN在处理爆炸问题的空间演化时具有四大优势:1)数据结构灵活,可直接处理任意网格类型,且符合坐标不变性原则;2)不同节点/边共享权重参数,天然支持组合泛化(combinatorial generalization),从而极大提升模型的泛化能力;3)消息传递(message-passing)机制的局部演化特性非常适合捕捉爆炸过程中的波传播过程。4)能够充分利用物理模拟中丰富的时空信息,从而大大降低训练所需的样本量(LI B, Bin, Feng, Li, Chen. A graph network-based learnable simulator for spatial-temporal prediction of rigid projectile penetration[J]. *International Journal of Impact Engineering*, 2025)。

在时间物理信息表征方面,最常见的方法是自回归(self-regression)方法,即选用某种显式函数将下一时间

步的物理状态表示为前一步或几步物理状态的因变量。自回归方法本质上将物理过程当做一个马尔可夫过程进行处理,其实现方法简单,但由于各时间步上的误差在不断自回归过程中会不断叠加,导致自回归方法在长时间序列预测中存在明显的误差累积问题。近年来诸多学者尝试使用循环神经网络(Recurrent Neural Network, RNN)中的门控机制、时间序列的Transformer模型、隐式神经网络等深度学习方法构建时间物理信息表征模块,进一步提高了时程预测精度(HAN X,GAO H,PFALL T,et al. *Predicting Physics in Mesh-reduced Space with Temporal Attention*[PP]. *arXiv:2201.09113*.)。

3. 毁伤效果智能后评估

毁伤后评估是指在爆炸事件发生之后对工程结构的毁伤等级及受损程度进行定量化的过程,相较于可依靠高精度易损性模型的事前评估,后评估所依据的往往只有回传的部分建筑影像信息,其信息完整度和可控性较低。此外,毁伤后评估的需求场景一般为灾后应急救援或作战临机火力筹划,对时效性的要求较事前评估更高。毁伤后评估的核心任务是根据工程结构的外部影像,判断其当前的毁伤等级(轻度毁伤、中度毁伤、重度毁伤等),从而为后续决策提供基本依据。

基于影像数据判断毁伤等级对应于计算机视觉领域中的特征识别与分类问题。目前已有大量深度学习方法可基于卫星影像评估大范围建筑集群在灾后或战后的毁伤等级。基于卫星影像的早期方法常利用双时相影像,即通过对相同目标爆炸前和爆炸后的卫星影像进行变化检测,进而通过变化阈值划分毁伤等级。但此类方法需要两次影像获取操作,增加了数据获取难度。同时,两次影像由于拍摄时间不同,影像数据在角度、光照、阴影、云雾遮挡等方面均会出现变化,提高了影像判别的复杂性。因此,仅基于爆炸后的建筑单时相影像进行毁伤后评估显然更为有利。基于单时相影像的后评估方法通过学习大量已毁伤建筑及未毁伤建筑的影像及附带的标签信息,识别已毁伤建筑中有别于未毁伤建筑的纹理模式(裂纹、穿孔、建材碎块、火光等),以实现毁伤等级的自动划分。此外,由于毁伤等级之间存在自然顺序关系,毁伤等级划分实际上是一个有序多分类问题(Ordinal Multi-class Classification),其模型的损失函数需要进行针对性设计。由于需处理影像信息,该类模型多基于CNN架构,经典模型包括VGGNet、ResNet、EfficientNet、RegNet等。由于Transformer模型善于捕捉长程的非局部信息,近年来也有部分工作使用基于图像的Transformer架构进行开展单时相影像的毁伤后评估,如Vision Transformer、Swin Transformer等(DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*[PP]. *arXiv:2010.11929*)。然而,由于Transformer架构抛弃了CNN在空间关系上的归纳偏置,其训练需要的数据量更大;与之相对的,在数据量充足的情况下,Transformer架构能够获得更高的准确率。

虽然基于卫星影像的工程结构毁伤后评估已有许多成果,但使用卫星影像作为输入数据仍然有较大局限性。首先,卫星影像一般拍摄范围较大,其单个建筑分辨率较低,细部特征易缺失;其次,由于俯视角拍摄,卫星影像通常仅能获取建筑的顶面的破坏情况,而难以获知建筑立面的毁伤情况。因此,基于卫星影响的毁伤后评估方法更适合在大范围内对工程结构受灾情况进行统计性估计,而无法胜任对单个建筑的精细化评估。随着无人机倾斜摄影技术的普及,获取单个建筑高清晰度立面图像已不再困难,因此采用建筑立面图像或立面俯视多视角图像相结合的毁伤后评估方法显然更有发展潜力,但目前这个方向成果仍十分有限。

此外,以上方法仅适用于评估工程结构毁伤状态的外部可见情况,对于某些大规模结构或深侵彻武器打击场景,爆炸可能仅在建筑内部发生,而外部未出现明显的破坏及坍塌,仅有部分武器入射孔洞可供观察,此时仅基于外部图像信息难以支撑准确地毁伤评估。针对这种情况,应当考虑毁伤后图像信息与毁伤效应知识相结合,通过图像输入与深度学习方法定位位置,结合毁伤效应进行内部破坏预测,建立内部破坏与外部破坏的关联,完成毁伤评估任务。

如前所述,目前工程结构毁伤后评估的发展显著滞后于事前评估,但已有的众多深度学习模型已可部分解决毁伤后评估中的关键问题,而如何高效整合相关技术,形成端到端的毁伤后评估能力是当前阶段急需解决的问题。

4. 结语

他山之石,可以攻玉。

深度学习技术发展至今,已积累了众多的通用架构及专用方法,其中很多成果已可直接应用于工程结构模型智能生成、毁伤效应智能加速计算、毁伤效果智能后评估等关键环节,经过进一步的技术修正、改进和整合,深度学习方法有望大幅提升工程结构爆炸毁伤评估的计算效率及易用性。然而,深度学习方法应用在毁伤评估领域尚存在一些共性的矛盾问题:1)毁伤评估领域缺乏专用数据集,毁伤评估相关数据采集难度大,数据敏感性与保密性强,标注成本与专业门槛高,目前在关键领域数据集开发、合规数据共享机制建设、数据增强及跨域迁移技术发展方面还有许多工作亟待开展;2)小样本学习方法研究不足,由于数据获取天然受限,即使构建专用数据集,毁伤评估数据的样本量也无法达到常见互联网公开数据集的量级,当前小样本学习的主流研究多基于通用任务,难以直接迁移至毁伤评估领域,急需构建领域专用小样本学习框架,强化模型对先验知识的利用效率;3)模型泛化能力与场景特异性存在矛盾,毁伤场景具有强特异性(如不同材料的抗毁伤特性、不同载荷的作用模式),而深度学习模型在迁移至未训练过的新场景时(如新型材料目标、非常规毁伤载荷),易因数据分布偏移出现性能骤降,需要积极探索元学习、物理先验嵌入等新方法,提高模型对不同毁伤场景的泛化能力。

冯彬^{1,2}, 陈力^{1,2}

1. 东南大学土木工程学院

2. 东南大学爆炸安全防护教育部工程研究中心

e-mail: bin.feng@seu.edu.cn