

基于端到端深度学习模型 TOPO-U型网的结构拓扑优化方法

王浩^{1,2} 罗浩东³ 施亚中⁴ 王立文^{5*} 张威⁵ 王忠⁶

1. 中国民航大学安全科学与工程学院, 天津, 300300
2. 中国民航大学工程技术训练中心, 天津, 300300
3. 中国民航大学航空工程学院, 天津, 300300
4. 北京飞机维修工程有限公司西南航线中心, 成都, 610000
5. 中国民航大学科技创新研究院, 天津, 300300
6. 中国航发成都发动机有限公司, 成都, 610500

摘要:针对结构拓扑优化中的“灰度单元”问题和“计算成本”挑战,提出一种基于端到端深度学习模型 TOPO-U-Net 的结构拓扑优化方法,该模型包括高低阶特征提取模块、深度可分卷积、组归一化,并设计了一种基于中间密度单元偏移函数的评价方法。实验结果表明,所提模型的中间密度偏移率达到 85.42%,平均优化计算时间仅为固体各向同性材料惩罚模型方法的 1%,显著减少了“灰度单元”数量,提高了设计的可制造性和结构拓扑优化的效率。

关键词:固体各向同性材料惩罚模型;深度学习;拓扑优化;U型网络

中图分类号:O241.82;TP183

DOI:10.3969/j.issn.1004-132X.2026.01.018

开放科学(资源服务)标识码(OSID):



A Topology Optimization Method Based on End-to-end Deep Learning Framework TOPO-U-Net

WANG Hao^{1,2} LUO Haodong³ SHI Yazhong⁴ WANG Liwen^{5*} ZHANG Wei⁵ WANG Zhong⁶

1. College of Safety Science and Engineering, Civil Aviation University of China, Tianjin, 300300
2. ETTC, Civil Aviation University of China, Tianjin, 300300
3. College of Aeronautical Engineering, Civil Aviation University of China, Tianjin, 300300
4. Southwest China Line Center, Aircraft Maintenance and Engineering Corporation, Chengdu, 610000
5. Institute of Technology and Innovation, Civil Aviation University of China, Tianjin, 300300
6. AECC Chengdu Engine Co., Ltd., Chengdu, 610500

Abstract: To address the problems such as “grey elements” and “computational cost” in structural topology optimization, an end-to-end deep learning model TOPO-U-Net was proposed. The model integrated high and low feature extraction modules, depth separable convolution, and group normalization. In addition, an evaluation method was designed based on intermediate density element deviation function. Experiments show that the intermediate density deviation rate of the proposed model reaches 85.42%. And, the average optimization computation time is as 1% of that required by the SIMP method, which may significantly reduce the number of “grey elements”, improve the manufacturability of complex structures and computational efficiency of topology optimization.

Key words: solid isotropic material with penalization(SIMP); deep learning; topology optimization; U-Net

0 引言

结构拓扑优化是在给定的设计空间中,根据指定的载荷工况、约束条件和优化参数合理分配

材料、寻找最优传力路径的方法。目前,代表性的拓扑优化方法包括均匀化方法^[1]、固体各向同性材料惩罚(solid isotropic material with penalization, SIMP)模型^[2]、双向渐进结构优化(bi-directional evolutionary structural optimization, BESO)法^[3]、水平集(level set, LS)方法^[4]、移动变形组件(moving morphable components, MMC)法^[5]。上述方法在实际应用中面临计算成本和实时性的

收稿日期:2024-11-20

基金项目:国家自然科学基金(U2133202);四川省重大科技专项(2021ZDZX0001);中央高校基本科研业务费专项资金(XJ2024002201)

技术难题,特别是面对大型结构或需要获得更精细结构的场景。

随着人工智能算法的进步和图形处理器的算力提升,引入机器学习来提高拓扑优化效率有望降低计算成本。SOSNOVIK等^[6]将卷积编码器-解码器架构作为逐像素图像标记技术来执行拓扑优化,减小了总体时间消耗。QIU等^[7]提出的数据驱动框架引入监督学习模型,并将演化过程导入到带有长短期记忆(long short-term memory, LSTM)网络的循环神经网络,减小了时间成本。SENHORA等^[8]建立的带有残差连接的卷积神经网络可解决具有不同几何形状、边界条件、网格大小、体积分数和滤波半径的多样化问题。上述方法均建立在传统拓扑优化的框架内,虽然理论解释性强,但计算时间减少不多。基于初始应力学习的深度学习模型^[9]能学习结构的主应力矩阵和最终拓扑优化结果之间的关系,并显著提高计算效率。ABUEIDDA等^[10]开发的卷积神经网络模型(用于线性弹性材料和 Neo-Hookean 材料)能预测优化设计的结构。SEO等^[11]开发了一个使用 U-Net 和 U-Net++ 的准确替代模型,通过输入初始静态分析的结果来预测最优的结构布局,避免了迭代优化计算。

U-Net 网络因良好的图像分割能力、多尺度特征提取和端到端训练特性而广泛用于拓扑优化问题的研究。具备泛化能力的 U-Net^[12]通过变密度法生成的数据集训练模型,在几乎不牺牲结果质量的情况下显著降低了计算成本。与变密度法相比,用于三维结构拓扑优化的 U-Net 模型^[13]在略微牺牲结构性能的条件下显著降低了计算成本。基于 U-Net 的拓扑优化方法^[14]通过输入应变和体积分数约束,能在短时间内预测船体横框架的最优结构。项程等^[15]提出一种基于 U-Net 的多材料结构拓扑优化方法,钢与铝合金的实验结果表明,该方法能在极短时间内得到多材料优化结构,且几乎不牺牲结构性能。目前,U-Net 虽在拓扑优化上有优势,但仍存在以下问题:①模型训练的目标通常像素相似度高、优化目标单一;②如何平衡模型规模与泛化能力亟待解决。

目前,基于深度学习的拓扑优化专注于寻找与经典方法结果相同或相近的高效计算方法,对深度学习模型能否提高结果质量却没有研究。另外,特征融合、注意力机制和损失函数等技术对模型性能影响的相关研究也较少。因此,本文提出一种端到端的深度学习模型 TOPO-U-Net 来代

替 SIMP 方法执行拓扑优化,以高效实现材料的最优分布;以验证损失、体积分误差为模型评价准则,提出一种基于评价中间密度单元偏移函数的评价方法。实验结果表明,TOPO-U-Net 可在忽略不计的时间内预测出最优结构的构型,且优化结果中的中间密度单元大量减少,获得更清晰的边界。

1 前序基础工作

1.1 SIMP 方法

SIMP 方法是一种在结构设计中广泛采用的拓扑优化技术。优化问题本身的非凸性,以及由数值稳定性和计算精度限制引起的数值问题,使得最终设计普遍存在中间密度,导致设计难以直接转化为产品且材料利用率较低。

本文的数据集是以结构的体积为约束、最小柔度为目标的拓扑优化问题,其优化问题的表达式为

$$\left. \begin{aligned} \min C &= U^T K U = \sum_{i=1}^N \mathbf{u}_i^T \mathbf{k}_i \mathbf{u}_i = \sum_{i=1}^N x_i^p \mathbf{u}_i^T \mathbf{k}_i \mathbf{u}_i \\ \text{s.t. } F &= \mathbf{K}(x_i) U \\ V &= \varphi V_0 = \sum_{i=1}^N x_i v_i \\ 0 < x_{\min} &\leq x_i \leq 1 \end{aligned} \right\} \quad (1)$$

式中: C 为结构柔度; U 为结构位移矢量; K 为总体刚度矩阵; \mathbf{u}_i 为结构设计域内第 i 个单元的位移向量; v_i 为结构设计域内第 i 个单元的体积; x_i 为结构设计域内单元相对密度 $X(X \in D)$ 的第 $i(i=1, 2, \dots, N)$ 个单元的值; D 为结构总设计域; x_{\min} 为单元相对密度的下限; N 为设计域内单元的总数; F 为结构外载荷矢量; \mathbf{k}_i 为单元刚度矩阵; p 为惩罚因子,工程上的取值一般为 3; V 为结构总体积; V_0 为设计域体积; φ 为目标体积分数。

1.2 U-Net 架构

深度学习已在包括语义分割在内的众多图像处理任务中发挥了关键作用。语义分割的方法研究中,U-Net 模型由于卓越的性能和结构效率而受到广泛认可^[16]。U-Net 是一种具有对称结构的卷积神经网络,包括通过跳跃连接相连的编码器和解码器。编码器通过连续的卷积和池化操作捕获从局部到全局的图像特征。解码器模块通过上采样和卷积逐步恢复图像的空间分辨率,以逼近原始输入的尺寸并细化细节,从而精确预测每个像素的类别标签。跳跃连接的引入使网络能在上采样过程中利用编码器模块保留详细的上下文信息,有效避免了传统卷积网络中连续池化操作导致的信息丢失问题。U-Net 的训练过程高度有效,在数据较少的情况下也能达到很好的学习效果,这使得它尤其适合于可用训练样本有限的问题。

2 端到端拓扑优化模型 TOPO-U-Net

2.1 模型结构

TOPO-U-Net主要由编码器、解码器组成,编码器负责从输入数据提取特征,解码器则基于特征生成分割图。整个模型包含1个输入转换模块、8个深度可分离卷积块、3个最大池化层、3个高低阶特征提取(high and low feature extraction, HLFE)模块、3幅掩码及对应的生成层、3个上采样层,如图1所示。引入HLFE模块代替跳跃连接,以保留空间信息并提高分割精度。充分融合高阶特征图与低阶特征图中的不同尺度信息,建

立远距离的特征连接,各卷积-上采样过渡处引入1个掩码支路来集成保存二值/概率信息。采用深度可分离卷积块替代标准卷积块,可在保持较小损失精度的前提下减小计算量和参数量。网络在卷积层与上采样(或下采样)层之间的过渡阶段都使用组归一化来加快训练并提高模型的性能^[17]。

本文模型将有限元网格划分为 40×80 个单元、 41×81 个节点。节点承载位移、受力位置、受力角度等信息,因此,将张量传递给网络之前需要调整张量的尺寸。输入转换模块采用 3×3 的普通卷积和自适应池化,将输入张量的尺寸由 $5 \times 41 \times 81$ 转换为 $16 \times 40 \times 80$ 。

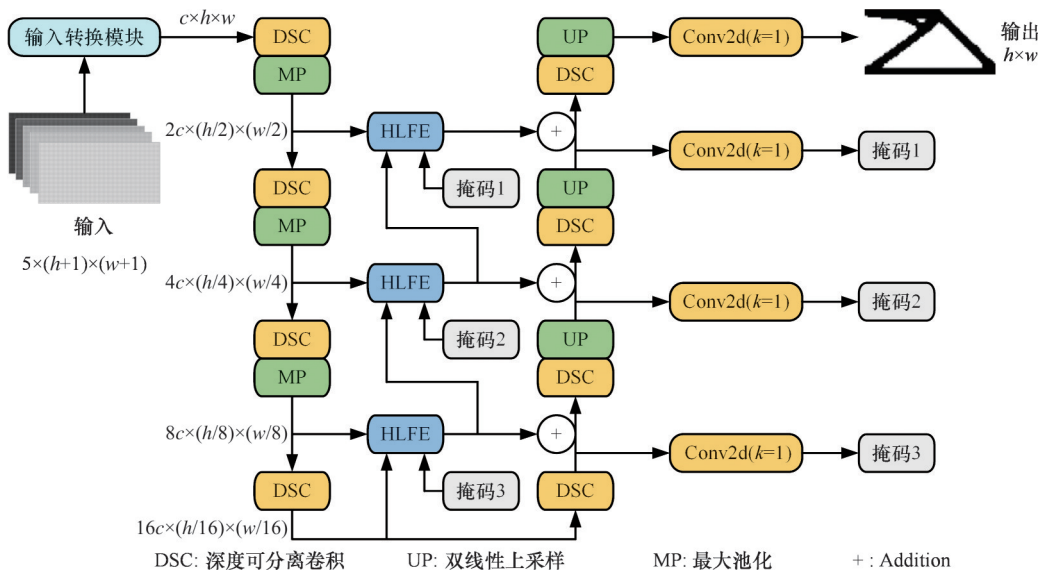


图1 TOPO-U-Net结构

Fig.1 Architecture of TOPO-U-Net

2.2 模型设计

2.2.1 高低阶特征提取模块

如图2所示,高低阶特征提取模块的核心设计思想是,对高阶特征先执行 1×1 普通卷积以调整通道数,再用双线性上采样将空间分辨率扩大到与低阶特征相同,保证后续可逐像素融合。采用多尺度区域特征捕获,对齐后的特征图与原始低阶特征并分别送入共享的扩张卷积层^[1,2,5,7],即在同一级特征图上并行放置4条分支,每条分支先用不同“视野”的扩张卷积遍历一次,再将4张结果concat/add起来,让网络一次就拥有 $1 \times \rightarrow 2 \times \rightarrow 5 \times \rightarrow 7 \times$ 的感受野组合。每个扩张卷积层针对特定的空间范围进行特征提取,4条支路输出按通道拼接,一次完成“局部-全局”编码,有效减少灰度单元并提高拓扑预测精度,确保特征信息在多尺度融合过程中的稳定性和一致性^[18]。

2.2.2 损失函数

本文选择的损失函数为Dice损失函数,同时

利用均方误差(mean squared error, MSE)和二元交叉熵(binary cross entropy, BCE)说明不同损失函数对最终结果的影响。

Dice损失函数的优化目标是最大化模型输出与真实标签之间的重叠度。Dice损失函数源自Dice系数:

$$D_{\text{coefficient}} = 2 \sum_{i=1}^N p_i g_i / \sum_{i=1}^N (p_i + g_i) \quad (2)$$

式中: p_i, g_i 分别为第*i*个像素的预测值和实际标签值; N 为图像中的像素总数。

Dice系数的计算核心部分是预测结果和真实标签结果的重叠程度。 $2 \sum_{i=1}^N p_i g_i$ 不仅考虑了重叠区域的像素数量,而且通过加权处理来放大预测值和标签值均接近1的像素对损失计算结果的贡献,保证优化过程中的模型更加关注目标区域的分割效果。 $\sum_{i=1}^N (p_i + g_i)$ 用于归一化交集部分的

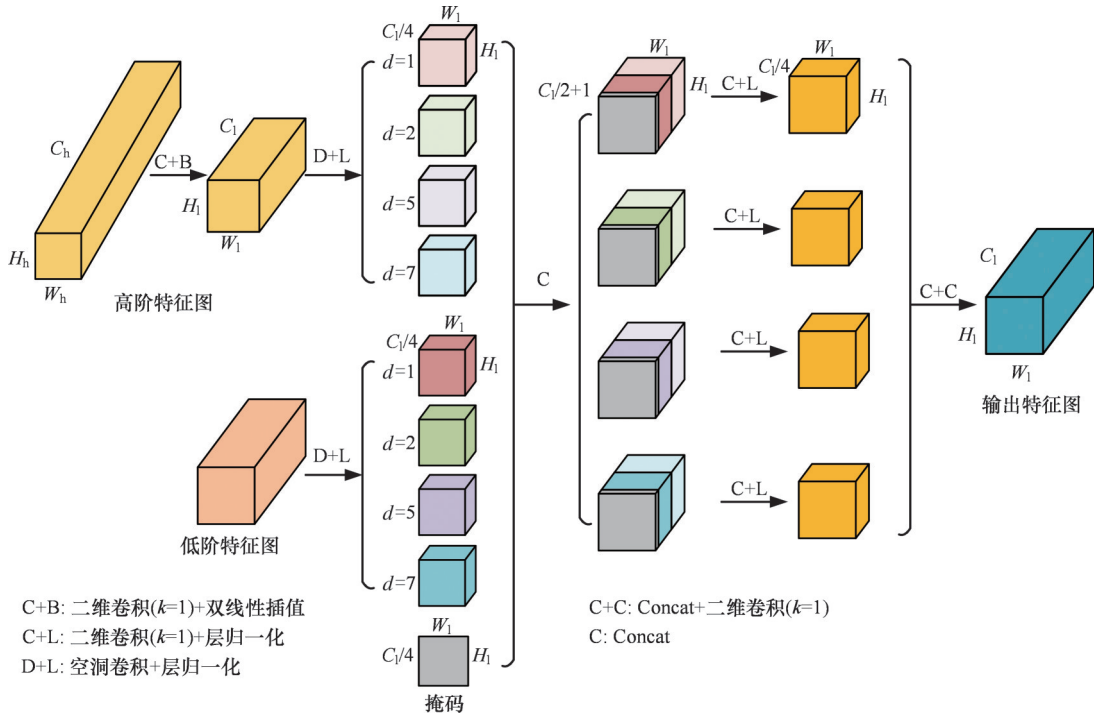


图2 高低阶特征提取模块结构

Fig.2 The architecture of high and low feature extraction module

贡献,确保Dice系数在不同大小的目标区域具有一致性,避免目标区域大小差异引起的优化偏差。

Dice损失函数定义为

$$D_{\text{loss}} = 1 - D_{\text{coefficient}} \quad (3)$$

Dice损失函数确保模型优化更关注目标区域的分割精度,在目标区域较小或边界不清晰的情况下能有效提高目标边界的识别能力。

MSE的数学表达式为

$$I_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

式中: y_i 为实际值; \hat{y}_i 为预测值; n 为样本数量。

二元交叉熵损失为

$$L_{\text{BCE}} = -\frac{1}{n} \sum_{i=1}^n [z_i \ln \hat{z}_i + (1 - z_i) \ln (1 - \hat{z}_i)] \quad (5)$$

式中: z_i 为第*i*个样本的标签; \hat{z}_i 为模型第*i*个样本的预测概率。

2.3 中间密度偏移率与中间密度指数

SIMP方法将材料密度作为设计变量,利用惩罚因子控制材料分布,在给定体积约束下优化结构,但优化结果会出现灰度单元(单元相对密度介于0和1的单元)。灰度单元会给优化结果带来许多不利的影响,如结果边界不清晰、可制造性差等,造成实际应用的困难。因此,减少结果中的灰度单元能有效提高优化质量。

能否有效处理灰度单元、获得清晰的结构是衡量模型的一个性能指标。结构清晰度评价函数可获得中间密度分布,但复杂且难以反映中间密

度的变化。为量化中间密度单元的偏移,提出中间密度偏移率(intermediate density deviation rate, IDDR)和中间密度指数(intermediate density index, IDI)的概念。中间密度偏移率 R_{IDD} 和中间密度指数的 I_{ID} 计算公式为

$$R_{\text{IDD}} = \frac{T_s + T_b}{T_s + T_b + F_s + F_b} \quad (6)$$

$$I_{\text{ID}} = \frac{T_s + T_b - F_s - F_b}{T_s + T_b + F_s + F_b} \quad (7)$$

式中: T_s 、 F_s 分别为标签数据内同一位置单元(中间密度0.1~0.5)在计算输出后中间密度变小和变大的数量; T_b 、 F_b 分别为标签数据内同一位置单元(中间密度0.5~0.9)在计算输出后中间密度变大和变小的数量。

需要特别说明的是, $I_{\text{ID}}=0$ 表明SIMP方法得出的标签和输出基本相同,中间密度单元没有任何变化; $I_{\text{ID}}=1$ 表明所有单元的中间密度都趋向于0或1; $I_{\text{ID}}=-1$ 表明所有单元的中间密度趋向于(0,1)之间的某个数值。 T_s+T_b 越大,模型越能有效使模型的中间密度向0或1移动; F_s+F_b 越大,模型越不能妥善处理这些中间密度单元。

为处理单元中间密度变化过小的情况,引入过滤半径 r ,并设置 $r=0.05$ 。中间密度变化小于0.05的单元不被统计。

2.4 实验设计

2.4.1 数据集构建

模型的所有数据集由经典SIMP拓扑优化程序(88行)^[19]生成。数据集包含12 710组样本,按

照9:1的比例划分为用于模型训练的训练集和验证集。此外,引入不同的输入参数(例如,体积分数、力的位置与角度),采用相同方法构建了一个包含1000组样本的测试集。测试集中的样本完全独立于训练过程,模型在训练时未见过这些样本,以验证模型的泛化能力和在未见过数据上的表现。需要说明的是,将SIMP方法生成的样本作为数据集时,经过充分训练的模型会继承SIMP方法结果的优点和缺点,使用其他拓扑优化方法生成数据集样本也会面临同样的问题。使用88行代码可快速生成大规模样本,因此本文没有使用数据增强技术。样本的设计域如图3所示,拓扑优化问题参数详情如下:①网格划分为 80×40 个单元;②边界条件为悬臂梁边界;③过滤半径为3;④惩罚因子为3;⑤外力 $F=1\text{N}$;⑥体积分数在0.35~0.80内随机取值;⑦受力位置为AB边的随机位置;⑧受力角度 θ 在 $0 \sim 180^\circ$ 内随机取值。



图3 样本的设计域

Fig.3 The design domain of sample

模型的输入包括均匀分布的体积分数、力的位置和角度,模型的标签数据是初始条件对应的拓扑优化结果。模型的输入是 $5 \times 41 \times 81$ 的张量,其中,5个通道分别表示X方向的初始位移场 U_x 和外载荷分布 F_x ,Y方向的初始位移场 U_y 和外载荷分布 F_y ,以及体积分数。标签是一个 40×80 的张量,即由SIMP方法计算获得的拓扑优化结果,每个点均代表拓扑优化网格单元的中间密度,范围为 $(0, 1)$ 。同时,将模型的输出设置为 40×80 的张量,将本文提出模型的输出作为拓扑优化的结果,如图4所示。

2.4.2 实验设置

为确保实验不受设备性能的影响,TOPO-U-Net及其他网络模型的实验均由同一工作站完成。模型训练实验平台硬件环境为i9-11900、GeForce RTX 3070(8.0 GB)、内存32.0 GB,软件环境为Windows10, CUDA 12.2和Python 3.8。

使用Pytorch深度学习框架进行训练,优化器选择Adam算法^[20],Adam算法的参数直接使用默认值。其余实验参数设置如表1所示。




图4 神经网络的输入与输出

Fig.4 The input and output of the neural network

表1 模型训练过程的超参数

Tab.1 Hyperparameters of the model training process

训练参数	设置	说明
优化器	Adam	梯度下降算法
学习率	0.001	初始学习率
批大小	8	每次训练的样本数
轮次	200	总训练轮次
CUDNN	enable	GPU加速库

3 实验结果与讨论

3.1 模型的表现

如图5所示,TOPO-U-Net在训练迭代过程中的验证损失随迭代的增多而快速收敛,在25个epoch后小于0.07,随后缓慢下降,在120个epoch后逐渐稳定,最终收敛于0.06。将初始条件输入模型,神经网络预测的输出结果如图6所示。由图6可看出结果拥有非常清晰的结构,大量中间密度单元消失,取而代之的是密度为1的实体单元或者密度为0的空心单元,结构边界仍残留少量中间密度单元(红色单元)。YAN等^[19]提出的方法将设计域剖分为 221×31 个有限元单元,而本文采用 80×40 的稀疏网格,网格密度大幅降低后,拓扑优化后的边界更加清晰,表明本文方法在提升结构可辨性上有显著优势。

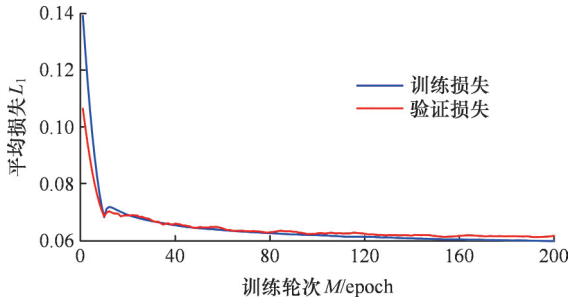


图5 训练与验证损失

Fig.5 Training and validation loss values



图6 模型预测结果的内部细节

Fig.6 Internal details of model prediction results

3.2 消融实验

设计消融实验,以验证高低阶特征提取模块在结构拓扑优化计算过程的效果。

体积分数误差率 R_{VFE} 为

$$R_{VFE} = |V_{pred} - V_d| / V_d \quad (8)$$

式中: V_{pred} 为预测结果的体积分数; V_d 为拓扑优化问题设置的体积分数。

平均绝对误差

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

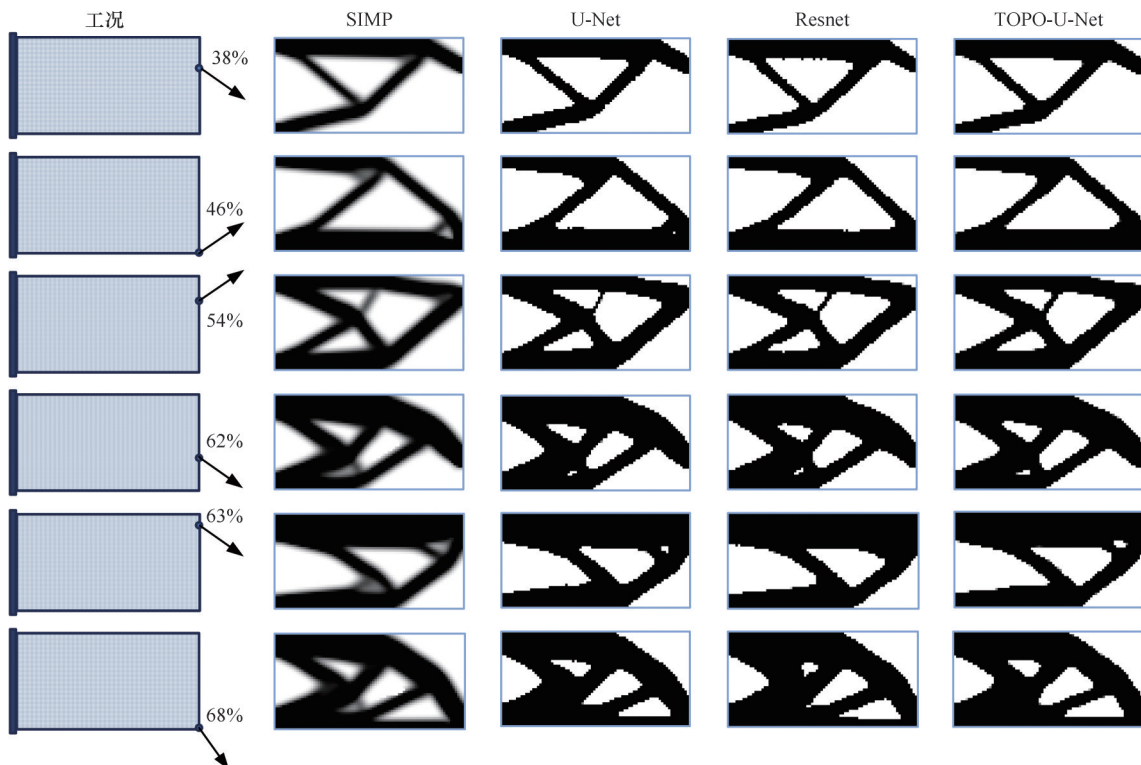


图7 结构拓扑优化效果对比示意图

Fig.7 Comparison of topology optimization results

可衡量标签值和预测值的差异。

如表2所示,引入HLFE模型后, I_{ID} 提高了0.0349, R_{IDD} 增大了1.74个百分点, R_{VFE} 、 E_{MA} 减小。对比实验证明 TOPO-U-Net 模型获得最优拓扑配置必须使用HLFE模块。

表2 HLFE模块消融实验效果对比

Tab.2 Comparison of HLFE module ablation experiment

	I_{ID}	$R_{IDD}/\%$	$R_{VFE}/\%$	E_{MA}
未引入HLFE	0.6735	83.68	2.97	0.0663
引入HLFE	0.7084	85.42	2.96	0.0651

3.3 不同神经网络模型的对比试验

本文利用不同荷载下的拓扑优化结果验证 TOPO-U-Net 的性能。如图7所示, SIMP、U-Net 和 Resnet 都能获得清晰的结构,且基本结构构型与 SIMP 方法相一致,都预测出最优的传力路径。与其他三种网络模型相比, TOPO-U-Net 的优势主要体现在预测结果的细节上。在最优构型边界的平滑处, SIMP、U-Net 和 Resnet 都会出现网格级别的小突起或小凹陷,这部分单元的拓扑优化结果究竟属于是实体单元或空心单元差异较大。 TOPO-U-Net 不仅能消除突起和凹陷,正确区分设计域拓扑优化结构的视角和背景,且边界细节更清晰。 TOPO-U-Net 网络引入 HLFE 模块,实现跨尺度信息对齐与多范围区域特征提取,为结构拓扑提供更准确的边界细节和

更接近真实的轮廓。

如表3所示, TOPO-U-Net的 I_{ID} 和 R_{IDD} 明显大于U-Net和Resnet的 I_{ID} 和 R_{IDD} , TOPO-U-Net的 R_{VFE} 略差于Resnet。综合所有评价指标来看, TOPO-U-Net的评估性能最好。由于引入了HLFE模块, 网络能从初始条件中提取更深层次的特征, 并将其与较浅层次的特征融合。

表3 三种神经网络模型的对比

Tab.3 Comparison of three deep learning models

不同模型	I_{ID}	$R_{IDD}/\%$	$R_{VFE}/\%$	E_{MA}
U-Net	0.6798	83.99	3.76	0.0669
Resnet	0.6467	82.34	2.94	0.0690
TOPO-U-Net	0.7084	85.42	2.96	0.0651

图8表明U-Net、Resnet的损失变化趋势与TOPO-U-Net一致, 但验证损失略大且迭代过程中损失值的振荡幅度更大, 说明模型训练相对不稳定, 可泛化性有待提高。然而, TOPO-U-Net在训练初始阶段(前20 epoch)的验证损失减小得最快, 这表明该模型在早期阶段能更快学习到数据的特征。大约100 epoch后, TOPO-U-Net的验证损失趋于平稳, 且最终的损失最小, 损失曲线

最为平滑, 显示出较好的稳定性, 这说明采用组归一化方法将各层输入分布固定在相对稳定的位置, 抑制内部协变量移动, 使梯度更稳定、模型更快找到泛化解。

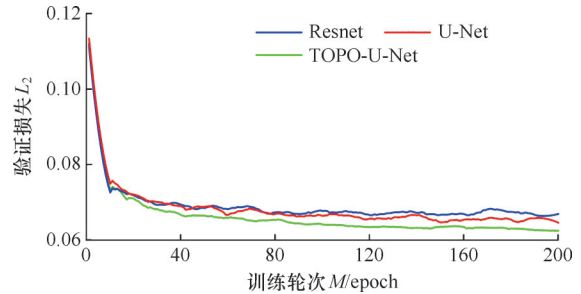


图8 三种神经网络在训练时的验证损失变化

Fig.8 Validation loss variation during training for the 3 neural networks

3.4 不同损失函数的对比实验

损失函数对最终结果产生重大影响, 选择合适的损失函数会使中间密度向0或1偏移, 提高优化结果的边界清晰度和平滑度, 补全SIMP方法结果中可能的结构缺失。不同条件的拓扑优化结果如图9所示, 其中, 百分数为体积分数。使用



图9 SIMP和三种损失函数的拓扑优化结果对比

Figure.9 Comparison of topology optimization results of SIMP and three loss functions

DICE 损失函数训练的模型能妥善处理大部分中间密度单元,在获得最清晰结构的同时能保证结构的平滑度。这说明模型在中间密度单元密集的区域能进行有效判断,将密度向 0 或 1 偏移,使单元向实体单元或空心单元演化,从而突出最优设计的结构。使用 MSE、BCE 作为损失函数训练的模型表现中规中矩,模型生成的优化结果与 SIMP 方法(标签值)相近,能得到与最优构型的边界轮廓相同的结构拟合效果,但在部分情况下,模型可能产生误判,使中间密度单元占据最优设计的结构连接处,虽未必造成结构断裂,但会对后续处理造成影响。

1000 个样本的测试集中,4 种方法在 6 个不同密度区间的平均分布情况如表 4 所示。密度在 [0, 0.1] 内的单元非常接近空心单元,在 (0.9, 1] 内的单元非常接近实体单元。以 SIMP 方法的平均数量为基准,在 (0.1, 0.9] 区间, DICE 损失函数平均分布最小。整个分布中, MSE 与 BCE 训练模型的输出分布与 SIMP 相近。

表 4 四种方法在六种密度范围内的平均分布

Tab.4 Average distribution within 6 different density ranges for 4 methods

密度范围	方法	平均分布	密度范围	方法	平均分布
[0, 0.1]	SIMP	1011.1290	(0.5, 0.7]	SIMP	134.3720
	MSE	994.8630		MSE	127.5620
	BCE	976.6470		BCE	129.0490
	DICE	1254.0620		DICE	2.4320
(0.1, 0.3]	SIMP	155.9580	(0.7, 0.9]	SIMP	178.0110
	MSE	175.7750		MSE	204.0700
	BCE	170.0760		BCE	200.2030
	DICE	3.8410		DICE	3.8170
(0.3, 0.5]	SIMP	122.0810	(0.9, 1.0]	SIMP	1598.4490
	MSE	123.3500		MSE	1574.3800
	BCE	125.0660		BCE	1598.9590
	DICE	2.4820		DICE	1933.3660

表 5 展示了 SIMP 和 3 种损失函数模型的中间密度偏移的平均分布。(0.1, 0.3] 内,以 SIMP 生成的标签数据(155.958 个单元)为参考, DICE 将其中的 143.336 个单元向“0”的方向偏移; (0.7, 0.9] 内,以 SIMP 生成的标签数据(178.011 个单元), DICE 将其中 171.426 个单元向“1”的方向偏移。其他密度区间内, DICE 都拥有最大的中间密度偏移量, MSE 与 BCE 的中间密度偏移量相差较小。由此可知, DICE 的中间密度偏移能促进最优构型得到最清晰的边界。

表 4、表 5 所示结果由不同损失函数的目标特性导致。MSE 损失函数直接最小化预测值与真

表 5 4 种方法的中间密度偏移的平均分布

Tab.5 Average distribution of IDDR for 4 methods

密度范围	方法	平均分布	密度范围	方法	平均分布
[0, 0.1]	SIMP	1011.1290	(0.5, 0.7]	SIMP	134.3720
	MSE	81.1290		MSE	67.7520
	BCE	68.5380		BCE	82.0020
	DICE	398.9640		DICE	110.5270
(0.1, 0.3]	SIMP	155.9580	(0.7, 0.9]	SIMP	178.0110
	MSE	87.7060		MSE	94.1190
	BCE	66.3910		BCE	108.0310
	DICE	143.3360		DICE	171.4260
(0.3, 0.5]	SIMP	122.0810	(0.9, 1]	SIMP	1598.4490
	MSE	67.3130		MSE	40.9640
	BCE	50.3680		BCE	45.2150
	DICE	77.6050		DICE	116.5720

实值的平方差,使模型在每个单元的预测密度尽可能接近真实密度,从而保证预测结构与真实结构的高度相似性。二元交叉熵损失以逐元素类别概率拟合为核心,其优化驱动力集中于提高单点预测精度,而非显式强化决策边界,故对中间密度单元缺乏向“0”或“1”两端迁移的约束作用。相较之下, DICE 损失以区域重叠度为优化目标,不再独立评价各有限元网格单元的取值,而是通过最大化预测结果与真实标签的整体交集,迫使网络将模糊区域推向“0”或“1”两端,从而有效减少灰度单元并提高拓扑边界的锐利度。

3.5 拓扑优化计算效率

使用 SIMP 方法和 TOPO-U-Net 模型进行拓扑优化所花费的时间如表 6 所示,其中, SIMP 方法拓扑优化的计算时间均值为 1.18 s, TOPO-U-Net 的预测时间均值为 0.01 s。

3.6 拓扑优化结果性能

神经网络生成的优化结构依赖模型的预测,这意味着结果的性能不能完全保证,并可能存在结构断裂的风险。因此,对模型输出的拓扑结构进行柔度和完整性分析,以评估其性能。

使用测试集中的所有样本分别计算 SIMP 方法和模型预测结果的柔度,并计算柔度误差率:

$$R_{CE} = (C_{pred} - C_s) / C_s \quad (10)$$

式中: C_{pred} 、 C_s 分别为预测结果和 SIMP 生成结果的柔度。

表 7 展示了测试集中所有样本在不同柔度误差率的分布, 94.1% 的样本柔度误差率为负值,说明预测结果的刚度更大,具备更强的抗变形能力; 约 1.2% 的样本柔度误差率大于 10%, 即预测结果柔度超过 SIMP 方法 10%。总体而言,大部分的预测结果柔度更小,有更大的刚度,即模型输出的清晰结果有益于增大结构刚度。

表6 拓扑优化计算时间

Tab.6 Computational time of topology optimizations

工况					
	63%	73%	38%	83%	30%
SIMP	2.04	2.03	1.02	0.82	0.18
本文方法	0.01	0.01	0.0099	0.0099	0.01
工况					
	46%	54%	62%	54%	63%
SIMP	1.46	0.6	1.15	0.94	1.21
本文方法	0.009	0.0099	0.01	0.01	0.01

表7 测试集样本在不同柔度误差率的分布

Tab.7 Distribution of test-dataset samples in different compliance error rates

柔度误差率	样本分布数	柔度误差率	样本分布数
(-1,-0.4)	0	[0,0.1)	47
[-0.4,-0.3)	19	[0.1,0.2)	4
[-0.3,-0.2)	34	[0.2,0.6)	2
[-0.2,-0.1)	122	[0.6,1)	1
[-0.1,-0)	766	≥1	5

结构的完整性与结构性能密切相关,模型预测结果的部分区域可能由于材料分布不均匀而形成孤立区域。这些孤立区域会影响整体结构的稳定性和负载承载能力,因此须评估预测结果的结构完整性。

利用连通性检查方法验证预测结果中各区域的连通性,并评估是否存在孤立或断裂。利用基于广度优先搜索(breadth-first search, BFS)的算法遍历结果中的各个区域,统计孤立区域的数量。详细设置如下:①密度阈值设为0.5,其中,密度大于0.5的区域视为结构主体,密度小于0.5的部分视为无材料区域;②最小面积阈值设为5,仅当孤立区域包含至少5个单元时才认为该区域为孤立区域。图10所示为设定的孤立区域。

使用测试集中的1000个样本进行连通性检




图10 孤立区域示例

Fig.10 The example of isolated region

查,统计得到的孤立区域数量如表8所示。SIMP方法、本文所提方法中,99.8%和98.1%的样本中的孤立区域数目为1即样本仅存在一个结构主体,未出现结构断裂或孤立的情况。整体来看,大部分测试样本的结构完整性良好,两种方法的差距仅为1.7%,这说明 TOPO-U-Net 模型性能较好,可保证结果的完整性。

表8 两种方法结果中的孤立区域数目对比

Tab.8 Comparison of the number of isolated regions

	孤立区域数			
	1	2	3	大于3
SIMP	998	2	0	0
TOPO-U-Net模型	981	17	2	0

4 结论

基于 TOPO-U-Net 提出的端到端深度学习模型可高效实现拓扑优化。考虑中间密度单元对结构拓扑优化效果的影响,提出了一个针对模型预测清晰度的评价函数。二维悬臂梁的拓扑优化案例验证了 TOPO-U-Net 模型的有效性。与现有的深度学习模型相比,TOPO-U-Net 模型的中间密度偏移率达到85.42%,可在低分辨率下高效获得边界清晰的拓扑优化结果。不同损失函数的模型输出结果证明损失函数是影响拓扑优化效果的重要因素。未来的工作将把拓扑优化算法拓展到三维几何模型,并探索如何设计更符合拓扑优化特征的损失函数。

参考文献:

[1] BENDSOE M P, KIKUCHI N. Generating Optimal Topologies in Structural Design Using a Homogenization Method[J]. Computer Methods in Applied Mechanics and Engineering, 1988, 71(2): 197-224.
 [2] ZHOU M, ROZVANY G I N. The COC Algorithm, Part

- II: Topological, Geometrical and Generalized Shape Optimization[J]. Computer Methods in Applied Mechanics and Engineering, 1991, 89(1/3): 309-336.
- [3] XIE Y M, STEVEN G P. A Simple Evolutionary Procedure for Structural Optimization[J]. Computers & Structures, 1993, 49(5): 885-896.
- [4] WANG M Y, WANG Xiaoming, GUO Dongming. A Level Set Method for Structural Topology Optimization [J]. Computer Methods in Applied Mechanics and Engineering, 2003, 192(1/2): 227-246.
- [5] GUO Xu, ZHANG Weisheng, ZHONG Wenliang. Doing Topology Optimization Explicitly and Geometrically—a New Moving Morphable Components Based Framework [J]. Journal of Applied Mechanics, 2014, 81(8): 081009.
- [6] SOSNOVIK I, OSELEDETS I. Neural Networks for Topology Optimization [J]. Russian Journal of Numerical Analysis and Mathematical Modelling, 2019, 34(4): 215-223.
- [7] QIU Cheng, DU Shanyi, YANG Jinglei. A Deep Learning Approach for Efficient Topology Optimization Based on the Element Removal Strategy [J]. Materials & Design, 2021, 212: 110179.
- [8] SENHORA F V, CHI Heng, ZHANG Yuyu, et al. Machine Learning for Topology Optimization: Physics-based Learning through an Independent Training Strategy [J]. Computer Methods in Applied Mechanics and Engineering, 2022, 398: 115116.
- [9] YAN Jun, ZHANG Qi, XU Qi, et al. Deep Learning Driven Real Time Topology Optimisation Based on Initial Stress Learning [J]. Advanced Engineering Informatics, 2022, 51: 101472.
- [10] ABUEIDDA D W, KORIC S, SOBH N A. Topology Optimization of 2D Structures with Nonlinearities Using Deep Learning[J]. Computers & Structures, 2020, 237: 106283.
- [11] SEO J, KAPANIA R K. Topology Optimization with Advanced CNN Using Mapped Physics-based Data[J]. Structural and Multidisciplinary Optimization, 2023, 66(1): 21.
- [12] WANG Dalei, XIANG Cheng, PAN Yue, et al. A Deep Convolutional Neural Network for Topology Optimization with Perceptible Generalization Ability[J]. Engineering Optimization, 2022, 54(6): 973-988.
- [13] XIANG Cheng, WANG Dalei, PAN Yue, et al. Accelerated Topology Optimization Design of 3D Structures Based on Deep Learning[J]. Structural and Multidisciplinary Optimization, 2022, 65(3): 99.
- [14] 李振荣, 夏利娟, 冯朔. 基于UNet深度学习的VLCC横框架拓扑优化分析[J]. 中国舰船研究, 2024, 19(6): 108-116.
- LI Zhenrong, XIA Lijuan, FENG Shuo. Topology Optimization Analysis of VLCC Transverse Web Based on UNet Deep Learning [J]. Chinese Journal of Ship Research, 2024, 19(6): 108-116.
- [15] 项程, 陈艾荣. 基于深度学习的多材料结构拓扑优化方法 [J]. 同济大学学报(自然科学版), 2022, 50(7): 975-982.
- XIANG Cheng, CHEN Airong. Topology Optimization of Multimaterial Structures Based on Deep Learning[J]. Journal of Tongji University (Natural Science), 2022, 50(7): 975-982.
- [16] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation [M] // Medical Image Computing and Computer-assisted Intervention—MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241.
- [17] WU Y, HE K. Group Normalization [C] // Proceedings of the European Conference on Computer Vision (ECCV), Lecture Notes in Computer Science. Munich, 2018: 3-19.
- [18] LEI B J, KIROS J R, HINTON G E. Layer normalization [EB/OL]. ArXiv e-prints, 2016: arXiv:https://doi.org/10.48550/arXiv.1607.06450.
- [19] YAN Jun, GENG Dongling, XU Qi, et al. Real-time Topology Optimization Based on Convolutional Neural Network by Using Retrain Skill[J]. Engineering with Computers, 2023, 39(6): 4045-4059.
- [20] ANDREASSEN E, CLAUSEN A, SCHEVENELS M, et al. Efficient Topology Optimization in MATLAB Using 88 Lines of Code[J]. Structural and Multidisciplinary Optimization, 2011, 43(1): 1-16.

(编辑 张 洋)

作者简介:王 浩,男,1985年生,硕士研究生。研究方向为航空器智慧维修、增材制件结构拓扑优化。发表论文5篇。E-mail: wanghao@cauc.edu.cn。王立文^{*}(通信作者),男,1963年生,研究员、博士研究生导师。研究方向为机场工程自动化、机场地面特种设备。发表论文80余篇。E-mail: hbgdwh@126.com。

本文引用格式:

王浩,罗浩东,施亚中,等. 基于端到端深度学习模型 TOPO-U型网的结构拓扑优化方法[J]. 中国机械工程, 2026, 37(1): 174-183.

WANG Hao, LUO Haodong, SHI Yazhong, et al. A Topology Optimization Method Based on End-to-end Deep Learning Framework TOPO-U-Net[J]. China Mechanical Engineering, 2026, 37(1): 174-183.