

基于深度学习的板壳结构网格智能划分技术研究

黄泽辉 唐洪斌 范阳 王士彬

(中国第一汽车股份有限公司研发总院, 长春 130013)

【摘要】为解决板壳结构网格划分效率低、合格率低等问题,提出了一种基于深度学习的板壳结构有限元网格智能划分技术。首先,对板壳结构典型特征进行分类,并为每类特征开发网格划分策略;其次,基于卷积神经网络训练特征识别模型,自动调用策略完成特征区域网格划分;最后,对非特征区域进行几何清理及网格优化。经某乘用车白车身验证,与主流 batchmesh 方法相比,该方法将网格自动划分合格率从 82.1% 提升至 92.6%,总工时减少 66.7%,显著改善了网格质量与效率。该技术通过 AI 模型与预定义策略的结合,减少了人工干预,为板壳结构网格划分提供了智能化解决方案。

关键词:深度学习 板壳结构 有限元分析 网格划分

中图分类号: TP181; O316 **文献标志码:** A **DOI:** 10.19620/j.cnki.1000-3703.20241025

Research on Intelligent Meshing Technology for Plate and Shell Structures Based on Deep Learning

Huang Zehui, Tang Hongbin, Fan Yang, Wang Shibin

(Global R&D Center, China FAW Corporation Limited, Changchun 130013)

【Abstract】To address the issues of low efficiency and low qualification rates in mesh generation for plate and shell structures, this paper proposes an intelligent finite element meshing technology based on deep learning. First, typical features of plate and shell structures are classified, and meshing strategies are developed for each feature type. Second, a feature recognition model is trained using convolutional neural networks to automatically invoke the corresponding strategies for meshing in feature regions. Finally, geometry cleanup and mesh optimization are performed for non-feature regions. Verified by the white body of a passenger car, this method increases the automatic meshing qualification rate from 82.1% to 92.6% and reduces total working hours by 66.7% compared with the mainstream batchmesh approach, significantly improving both mesh quality and efficiency. By combining AI models with predefined strategies, this technology minimizes manual intervention and provides an intelligent solution for meshing in plate and shell structures.

Key words: Deep learning, Plate and shell structures, Finite element analysis, Mesh generation

【引用格式】黄泽辉,唐洪斌,范阳,等.基于深度学习的板壳结构网格智能划分技术研究[J].汽车技术,2025(4):47-55.

HUANG Z H, TANG H B, FAN Y, et al. Research on Intelligent Meshing Technology for Plate and Shell Structures Based on Deep Learning[J]. Automobile Technology, 2025(4): 47-55.

1 前言

随着有限元分析(Finite Element Analysis, FEA)在工程领域的广泛应用,高效生成高质量网格成为缩短项目周期的关键。传统人工网格划分方法在处理汽车白车身等复杂板壳结构时,存在效率低、易出错等问题;而现有商业软件如 ANSA 和 Hypermesh 的批量网格划分方法(batchmesh)虽能实现自动化,但其网格合格率低、流向控制差、特征区域质量不足,仍需大量人工干预。

近年来,随着人工智能技术的进步,特别是深度学

习在图像识别、模式识别等方面的广泛应用^[1],研究人员开始探索其在网格划分领域的潜在应用。Carlos 等^[2]利用特征识别技术在关键区域进行局部网格细化,提高有限元求解精度;He 等^[3]基于深度神经网络模型在关键区域进行局部网格细化,提高有限元求解精度。Lu 等^[4]基于卷积神经网络处理复杂结构化网格边界条件和材料属性变化问题,有效处理高维数据。Xu 等^[5]基于数据驱动的网络密度提升模型 Super-Meshing-Net,缩短有限元计算时间和成本。Xu^[6]将 SuperMeshing 方法与传统的网格生成方法比较显示,SuperMeshing 方法在处理

复杂几何形状和边界条件时具有更好的适应性和灵活性。Jaeho等^[7]利用深度学习技术改进有限元网格划分过程,在保证计算精度的同时提高计算效率。刘翰林等^[8]利用深度学习技术对生成的网格分类筛选,在保证网格质量不下降的前提下提升工作效率。张伟等^[9]基于深度学习技术对三角形网格占比过多的曲面进行网格重建,提高有限元求解精度。

基于上述研究,本文提出一种基于深度学习的板壳结构网格智能划分技术。首先,分类典型特征并预定义对应网格划分策略;其次,训练卷积神经网络模型实现特征自动识别与策略调用;最后,对非特征区域进行几何清理与网格优化。该方法通过AI模型与预定义策略协同,显著降低人工干预,为板壳结构高效划分提供新方案。

2 深度学习模型架构适用性分析

在本研究中,为了识别出典型特征的类别,进而实现板壳结构网格的智能划分,采用卷积神经网络(Convolutional Neural Network, CNN)作为主要的模型架构。CNN通过局部连接与权重共享机制有效捕捉局部信息,同时减少模型参数数量,提高泛化能力。此外, CNN的层次化特征提取能力允许模型从低级特征,如边缘和纹理,逐步学习到更高级别的特征,如形状和对象,这对于复杂结构的识别至关重要。池化层的应用不仅有助于降低输出维度,还能够保持重要的特征信息,进一步提升模型的计算效率和抗过拟合能力。

针对识别典型特征类别的具体需求,选择4种典型的CNN模型:ResNet-50^[10]、VGG-16^[11]、DenseNet-121^[12]和MobileNet-v2^[13]。ResNet-50通过引入残差块解决了深层网络训练过程中的梯度消失问题,拥有50层的深度,能够在保持模型复杂度的同时大幅提升性能,适用于需要高精度的任务。VGG-16是一个经典且高效的深度卷积神经网络,通过堆叠多个3×3的小卷积核构建深层网络,能够有效提取图像的多层次特征;其结构简单、易于实现,适合作为基准模型进行性能对比。DenseNet-121通过密集连接每一层与其后所有层,促进了特征的重用和信息流的传递,有助于缓解梯度消失问题,同时减少了参数量。DenseNet-121版本具有较深的网络结构,适用于需要强大表达能力的任务。最后,MobileNet-v2通过引入倒残差结构和线性瓶颈层,在保持模型轻量化的同时提升了准确率,适用于资源受限环境下的板壳结构网格划分任务。通过对比这4种不同架构的CNN模型,本研究旨在探索其在板壳结构网格

智能划分任务中的表现差异,为实际应用提供理论依据和技术支持。

3 研究方法

本研究进行基于深度学习的板壳结构有限元网格智能划分。首先,使用深度学习技术对板壳结构典型特征进行识别并对不同AI模型进行对比;然后,根据AI模型识别结果调用相应的典型特征网格划分策略,实现典型特征网格划分;最后,对典型特征以外的结构进行几何清理、网格划分及质量优化。

3.1 特征识别

3.1.1 数据收集

本文选择40款典型的汽车白车身作为数据源,这些白车身涵盖了多种不同的设计风格和制造工艺。为了确保数据集的多样性和代表性,选取不同车型、不同年代的车辆。从这些白车身中,提取板壳结构的典型特征,包括各种类型的冲压起筋,数据收集结果如图1所示。




图1 数据收集结果

3.1.2 数据整理与预处理

首先,对原始数据进行清洗,去除冗余的信息和不必要的噪声。此外,由于原始数据可能存在格式上的差异,本文将统一转换为适合深度学习模型处理的jpg图像格式。最后,对数据进行标注工作,为每一种典型特征指定标签。初始样本统计如表1所示。

3.1.3 数据增强

本研究的典型特征识别分为10类任务,数据集的合理划分对于模型训练、验证和最终评估至关重要。本文借鉴了FashionMNIST数据集的划分方法,将数据集划分为训练集、验证集和测试集,具体比例为60 000个训练样本、10 000个验证样本和10 000个测试样本,每个类别典型特征的样本量至少为8 000个。

根据工程经验,同一类别的典型特征存在以下常见场景:形状一致,但角度不同;形状相似,但大小不同。因此,对于样本量不足8 000个的类别,本文采用旋转、

翻转、缩放等数据增强方法生成额外的样本;虽然经过上述变换,但是图像的核心特征仍然保留,即变换后的样本与原始样本属于同一类别。数据增强后样本统计如表2所示,所有类别的最终样本量至少为8 000个,增加了模型接触到的数据量;每个类别各取8 000个样本建立数据集,提高了模型对输入变化的鲁棒性。

表1 初始样本统计


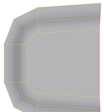

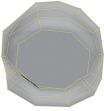
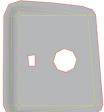
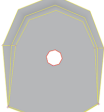

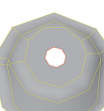
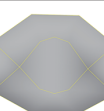
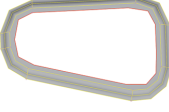
典型特征类别	初始样本量/个	示意图
01	40 668	
02	6 764	
03	4 355	
04	4 122	
05	2 161	
06	3 046	
07	18 956	
08	1 189	
09	8 980	
10	3 374	
总计	93 615	

表2 数据增强后样本统计

典型特征类别	初始样本数量/个	最终样本数量/个
01	40 668	40 668
02	6 764	8 000
03	4 355	8 000
04	4 122	8 000
05	2 161	8 000
06	3 046	8 000
07	18 956	18 956
08	1 189	8 000
09	8 980	8 980
10	3 374	8 000
合计	93 615	124 604

数据增强可以使AI识别模型不会过度依赖于训练集中的特定类别,减少过拟合,帮助AI识别模型更好地泛化到新的未见数据上;但是,可能会引入不属于工程实际的样本,导致AI识别模型学到错误的模式。数据增强对本文的影响需要根据AI识别模型的精度进行调整优化。

3.1.4 数据划分与管理

为了保证模型训练的有效性和评估的公正性,从数据增强后的样本中,按典型特征类别各取8 000个样本,共80 000个样本建立数据集。即每个类别各6 000个样本用于训练,每个类别各1 000个样本用于验证,每个类别各1 000个样本用于最终的模型测试,数据分类结构如图2所示。

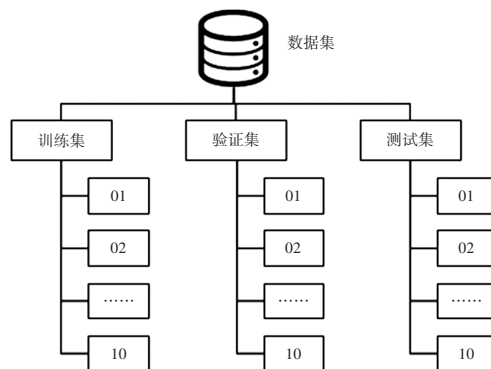


图2 数据分类结构

3.1.5 AI识别模型训练

使用迁移学习(Transfer Learning)的方法,分别基于ResNet-50、VGG-16、DenseNet-121、MobileNet-v24共4种卷积神经网络架构训练典型特征AI识别模型。实施模型迁移的流程如图3所示:首先,使用PyTorch深度学习框架加载预训练模型及其权重;然后,修改模型结构,冻结特征提取器结构及权重,修改分类器结构,将最后

一层替换为10个输出节点的全连接层;最后,进行AI识别模型训练,学习分类器权重。

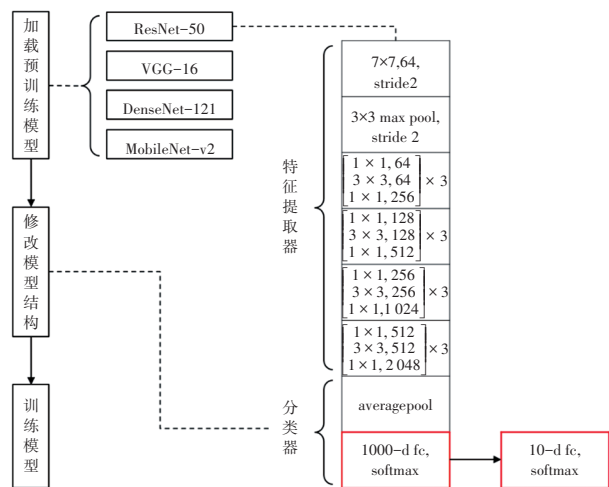


图3 迁移学习流程

训练环境及参数设置如表3所示。


表3 训练环境及参数设置

编程语言	Python 3.8.10
深度学习框架	PyTorch 2.0.0
图形处理器	NVIDIA TESLA P100
批大小	64
优化器	SGD
动量	0.9
学习率	0.001
损失函数	CrossEntropyLoss
训练轮数	20


ResNet-50模型训练结果如图4所示。模型训练过程中,损失函数在训练集、验证集上迅速减小然后逐渐收敛到一个较小的区间,精度在训练集、验证集不断增大并收敛到一个很小的区间,说明模型已经稳定;类别10的识别准确度最高,为99.7%,类别05、06的识别准确度最低,为91.3%,所有类别平均识别准确度为94.4%。

VGG-16模型训练结果如图5所示。模型训练过程中,损失函数在训练集、验证集上迅速减小然后逐渐收敛到一个较小的区间,精度在训练集、验证集不断增大并收敛到一个较小的区间,说明模型已经稳定;类别10的识别准确度最高,为99.6%,类别05的识别准确度最低,为90.8%,所有类别平均识别准确度为94.57%。


DenseNet-121模型训练结果如图6所示。模型训练过程中,损失函数在训练集、验证集上迅速减小然后逐渐收敛到一个较小的区间,精度在训练集、验证集不断增大并收敛到一个很小的区间,说明模型已经稳定;类别09的识别准确度最高,为99.5%,类别06的识别准确度最低,为90.6%,所有类别平均识别准确度为95%。



(a) 损失曲线




(b) 精度曲线




(c) 混淆矩阵


图4 ResNet-50模型训练结果



(a) 损失曲线




(b) 精度曲线




(c)混淆矩阵

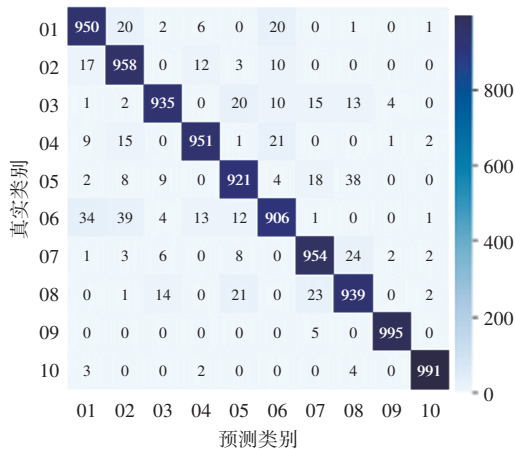
图5 VGG-16模型训练结果



(a)损失曲线




(b)精度曲线




(c)混淆矩阵

图6 DenseNet-121模型训练结果


MobileNet-v2模型训练结果如图7所示。模型训练过程中,损失函数在训练集、验证集上迅速减小然后逐渐收敛到一个较小的区间,精度在训练集、验证集不断增大并收敛到一个较小的区间,说明模型已经稳定;类别10的识别准确度最高,为99.5%,类别03、05的识别准确度最低,为91.2%,所有类别平均识别准确度为94.09%。



(a)损失曲线



(b)精度曲线



(c)混淆矩阵

图7 MobileNet-v2模型训练结果

综上,基于 ResNet-50、VGG-16、DenseNet-121、MobileNet-v2这4种卷积神经网络架构的AI识别模型中,所有模型的最低识别精度类别均未出现类别08(数据增强前初其始样本量仅为1 189个,后通过旋转、翻转等数据增强扩充至8 000个)。这一现象表

明,数据增强有效缓解了类别08因原始样本不足导致的模型欠拟合问题,使其分类精度显著提升。相比之下,最低识别精度集中于类别03、05、06,可能是类别之间差异较小、类别内部差异较大、模型能力不足、超参数设置不当等原因造成的。

3.1.6 AI识别模型对比

AI识别模型对比结果如表4所示。MobileNet-v2模型训练时间最短,为9.2 h,VGG-16模型训练时间最长,为10.8 h;DenseNet-121模型识别准确度最高,为95.00%,MobileNet-v2模型识别准确度最低,为94.09%。

表4 AI识别模型对比

卷积神经网络架构	训练时间/h	识别准确度/%
ResNet-50	9.9	94.40
VGG-16	10.8	94.57
DenseNet-121	10.0	95.00
MobileNet-v2	9.2	94.09

3.2 典型特征网格划分

3.2.1 典型特征网格划分策略

针对10类典型特征,制定10种典型特征网格划分策略,实现典型特征网格划分合格率100%。典型特征网格划分流程如图8所示,AI识别模型识别典型特征类别后,自动选择典型特征网格划分策略进行典型特征网格划分。其中,10类典型特征网格划分流程一致,为特征线清理、特征切割、网格生成、质量检查、网格调整、结果输出,子流程略有不同,可基于商业软件的二次开发功能实现流程自动化。

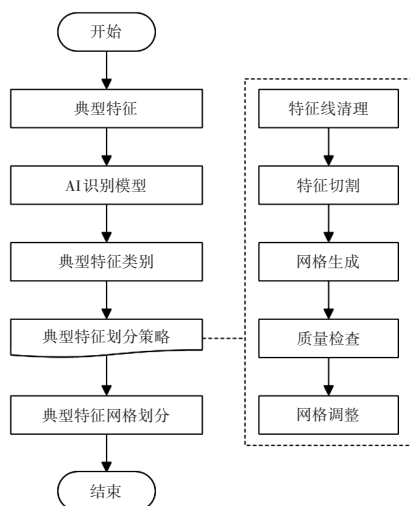


图8 典型特征网格划分流程

3.2.2 典型特征网格划分结果

典型特征网格划分结果如表5所示,网格合格率达到100%,以提升整体结构网格划分质量。

表5 典型特征网格划分结果

典型特征类别	示意图	网格划分结果
01		
02		
03		
04		
05		
06		
07		
08		
09		
10		

3.3 几何清理

对典型特征以外的结构进行几何清理,保留轮廓特征线,删除非轮廓特征线。图9为某乘用车车门内板几何清理过程:首先,读取剔除典型特征后的车门内板结构;然后,遍历并判断每条特征线是否与其他特征线闭合,若特征线可以与其他特征线闭合,则为轮廓特征线,须保留,若特征线无法与其他特征线闭合,则为非轮廓特征线,需删除;最后,得到清理后的车门内板几何结构。




图9 某乘用车车门内板几何清理过程

3.4 网格划分及优化

3.4.1 网格划分

基于商业软件的二次开发功能对清理后的几何结构进行网格划分,本文使用 ANSA 软件实现该功能,可实现网格划分自动化,主要参数设置如下:网格目标尺寸为 5 mm,扭曲距离为 20%,扭曲角度为 0°,最小网格尺寸为 3.05 mm,倒角尺寸为最小网格尺寸的 0.667 倍。

3.4.2 网格优化

网格自动划分后的合格率无法达到 100%,主要原因如下:首先,虽然每个典型特征网格划分策略都可以实现合格率 100%的网格划分,但是由于典型特征识别准确度无法达到 100%,导致 AI 识别模型无法 100%调用正确的典型特征网格划分策略,以致典型特征网格自动划分合格率无法达到 100%;其次,清理后的几何使用商业软件进行网格自动划分时,因技术原因无法保证合格率达到 100%。因此,为了获得用于有限元仿真的网格,需要对自动划分后的网格进行手动网格优化,提升网格合格率至 100%。

4 基于深度学习的板壳结构网格智能划分流程

某板壳结构零件如图 10 所示,以该零件为例介绍

基于深度学习的板壳结构网格智能划分流程,如图 11 所示。首先,使用 AI 识别模型对该零件的典型特征进行识别,得到典型特征类别;其次,根据典型特征类别调用对应的网格划分策略,进行典型特征网格划分;再次,对典型特征以外的结构进行几何清理,保留轮廓特征线、删除非轮廓特征线;然后,基于商业软件的二次开发功能对清理后的几何结构进行网格划分;最后,根据网格质量标准进行网格优化,得到用于有限元仿真的网格。




图 10 某板壳结构零件

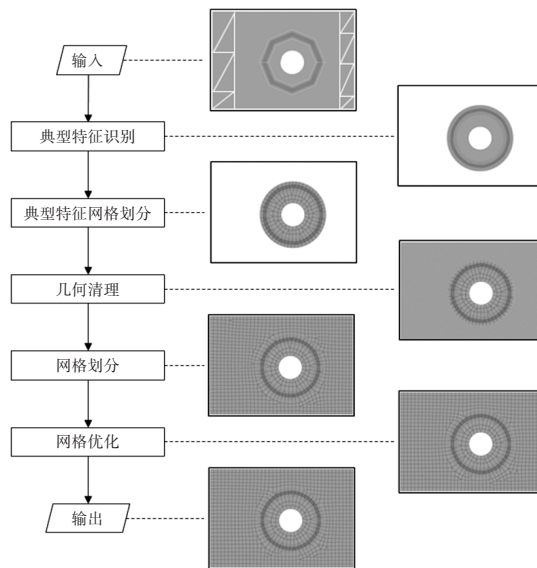


图 11 基于深度学习的板壳结构网格智能划分流程

5 网格划分结果对比

某乘用车白车身如图 12 所示,以该白车身为例,分别使用本文方法与 batchmesh 法进行网格自动划分并进行结果对比,网格质量标准如表 6 所示。




图 12 某乘用车白车身

表6 网格质量标准

检查项	单元类型	网格质量标准
扭曲	壳单元	$\leq 45^\circ$
翘曲	壳单元	$\leq 18^\circ$
雅可比	壳单元	≥ 0.7
长宽比	壳单元	≤ 5
最小角度	四边形壳单元	$\geq 40^\circ$
最大角度	四边形壳单元	$\leq 140^\circ$
最小角度	三角形壳单元	$\geq 20^\circ$
最大角度	三角形壳单元	$\leq 120^\circ$
三角形占比	壳单元	$\leq 5\%$
最小尺寸	壳单元	3 mm
平均尺寸	壳单元	5 mm
最大尺寸	壳单元	8 mm

网格自动划分合格率的对比如表7所示, batchmesh法网格自动划分合格率为82.1%, 本文方法网格自动划分合格率为92.6%, 说明本文方法可以显著提升网格自

动划分合格率。

表7 网格自动划分合格率对比

网格划分方法	batchmesh法	本文方法
网格自动划分合格率	82.1%	92.6%

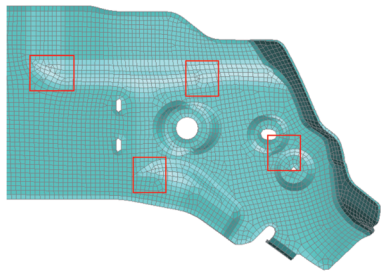
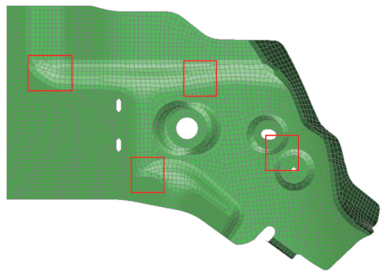
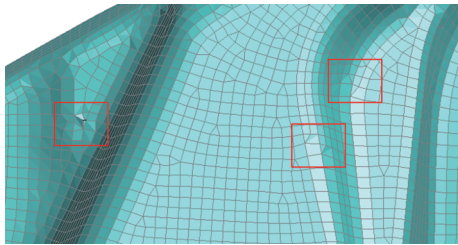
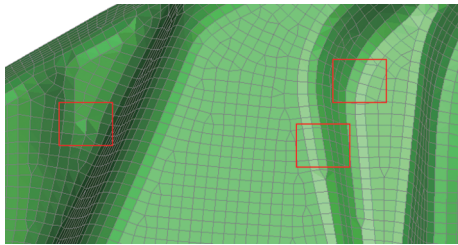
网格划分工时对比如表8所示, batchmesh法网格划分及优化总工时为24人日, 本文方法网格划分及优化总工时为8人日, 说明本文方法可以显著提升工作效率, 周期缩短66.7%。

表8 网格划分工时对比 人日

网格划分方法	batchmesh法	本方法
网格自动划分工时	0.5	1
网格手动优化工时	23.5	7
网格划分及优化总工时	24	8

局部网格划分质量对比如表9所示, batchmesh法存在三角形壳单元聚集、网格流向差、典型特征网格质量差、局部单元畸变等不足, 本文方法可以有效弥补以上不足, 说明本文方法可以显著提升网格自动划分质量。

表9 局部网格划分质量对比

网格划分方法	batchmesh法	本文方法
前纵梁局部网格		
A柱局部网格		

6 结束语

本文提出了一种基于深度学习的板壳结构有限元网格智能划分技术。首先, 结合深度学习技术和网格划分策略实现了板壳结构典型特征自动识别与网格划分, 然后, 通过几何清理、网格划分及优化实现了板壳结构主体结构网格划分。试验结果表明, 与当前主流的网格划分方法(batchmesh法)相比, 本文方法

可以显著提升网格自动划分合格率、工作效率及网格质量。

基于深度学习的板壳结构有限元网格智能划分技术的应用显著减少了人工干预, 为板壳结构有限元网格划分提供了一种新的智能化解决方案, 为未来的智能化工程设计奠定了坚实的基础。下一步, 将优化识别算法和网格生成技术, 进一步提升基于深度学习的板壳结构网格划分技术的应用价值。

参 考 文 献

- [1] 弗朗索瓦·肖莱. Python 深度学习[M]. 北京: 人民邮电出版社, 2018.
- FRANCOIS C. Deep Learning with Python[M]. Beijing: Posts & Telecom Press, 2018.
- [2] URIARTE C, PARDO D, JAVIER A, et al. A Finite Element Based Deep Learning Solver for Parametric PDEs[J]. Computer Methods in Applied Mechanics and Engineering, 2022, 391.
- [3] HE J, ABUEIDDA D, RAAL R, et al. A Deep Learning Energy-Based Method for Classical Elasticity[J]. International Journal of Plasticity, 2023, 162.
- [4] LU Y, LI H, ZHANG L, et al. Convolution Hierarchical Deep-Learning Neural Networks(C-HIDeNN): Finite Elements, Isogeometric Analysis, Tensor Decomposition, and Beyond[J]. Computational Mechanics, 2023, 72: 333–362.
- [5] XU Q F, NIE Z G, XU H D, et al. SuperMeshing: A New Deep Learning Architecture for Increasing the Mesh Density of Physical Fields in Metal Forming Numerical Simulation[J]. Journal of Applied Mechanics: Transactions of the ASME, 2022, 1(89): 1–10.
- [6] XU H, NIE Z, XU Q, et al. SuperMeshing: Boosting the Mesh Density of Stress Field in Plane-Strain Problems Using Deep Learning Method[J]. Journal of Computing and Information Science in Engineering, 2023, 23(3): 1–12.
- [7] JAEHO J, HYUNGMIN J, PHILL-SEUNG L, et al. Self-Updated Four-Node Finite Element Using Deep Learning[J]. Computational Mechanics, 2022, 69: 23–44.
- [8] 刘翰林, 崔会敏, 张珍, 等. 基于BP算法的二维阵面推进网格划分方法的优化与应用[J]. 计算力学学报, 2023, 8(30): 1–8.
- LIU H L, CUI H M, ZHANG Z, et al. Optimization and Application of 2D Front Advancing Mesh Generation Method Based on BP Algorithm[J]. Chinese Journal of Computational Mechanics, 2023, 8(30): 1–8.
- [9] 张伟, 姜献峰, 陈丽能, 等. 基于神经网络的三角形网格智能重建[J]. 工程图学学报, 2004, 25(1): 71–75.
- ZHANG W, JIANG X F, CHEN L N, et al. Intelligent Reconstruction of Triangular Meshes Based on Neural Networks [J]. Journal of Engineering Graphics, 2004, 25(1): 71–75.
- [10] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, Nevada, USA, 2016: 770–778.
- [11] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[EB/OL]. (2015-04-10) [2024-12-17]. <https://arxiv.org/abs/1409.1556>.
- [12] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely Connected Convolutional Networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, Hawaii, USA, 2017: 4700–4708.
- [13] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018: 4510–4520.

(责任编辑 王 一)

修改稿收到日期为2024年12月17日。