

文章编号: 1000-8055(2023)07-1658-10

doi: 10.13224/j.cnki.jasp.20220754

基于卷积神经网络双层壁三维热应力预测方法

黄俊杰, 朱剑琴, 程泽源

(北京航空航天大学 能源与动力工程学院, 北京 100191)

摘 要: 为实现三维物理场的预测, 提出一种利用卷积神经网络(CNN)对双层壁冷却结构外壁三维热应力快速评估方法。针对双层壁冷却结构外壁平板状的结构特征, 沿壁厚方向将温度场切分为多个切片。将温度作为卷积网络输入张量的基本元素, 不同厚度位置的切片对应输入张量的通道维度, 从而实现将三维温度场输入进网络, 并输出在热载荷作用下的三维等效应力场。结果表明: 训练收敛后的网络在测试集上的平均绝对误差为 1.23 MPa, 平均相对误差为 15.10%, 对峰值应力的平均绝对误差为 16.10 MPa, 平均相对误差为 11.81%。对于双层壁冷却结构的热应力预测问题, CNN 能够很好地完成温度到应力的映射。使用深度学习方法探究热弹性问题的潜在机理有望实现。

关 键 词: 热应力预测; 三维物理场; 双层壁冷却结构; 卷积神经网络; 代理模型

中图分类号: V231.91

文献标志码: A

Three-dimensional thermal stress prediction method in double-wall structure using convolutional neural networks

HUANG Junjie, ZHU Jianqin, CHENG Zeyuan

(School of Energy and Power Engineering, Beihang University, Beijing 100191, China)

Abstract: To realize the prediction of 3D physical field, a method for rapid evaluation of 3D thermal stress on the outer wall of double-wall cooling structure using convolutional neural network (CNN) was presented. For the structural characteristics of the flat plate shape of the double-wall cooling structure outer wall, the temperature field was sliced into multiple sections along the wall thickness direction. The temperature was used as the basic element of the input tensor of the CNN, and the sections at different thickness positions corresponded to channel dimensions of the input tensor. The 3D temperature field was input into the CNN for output of the 3D von-Mises stress field under thermal load. The average absolute error of the trained converged network on the testing set was 1.23 MPa, with an average relative error of 15.10%, and the average absolute error for peak stresses was 16.10 MPa, with an average relative error of 11.81%. Results showed that for the thermal stress prediction problem of double-wall cooling structures, CNN can complete the temperature-to-stress mapping well. Exploring potential mechanisms of the thermoelasticity problems by using deep learning methods is expected to be realized.

Keywords: thermal stress prediction; three-dimensional physical field; double-wall cooling structure; convolutional neural networks; surrogate model

收稿日期: 2022-09-30

基金项目: 国家自然科学基金(51876005, 52122604)

作者简介: 黄俊杰(1998—), 男, 博士生, 主要从事航空发动机涡轮叶片冷却结构寿命引导优化方法研究。E-mail: buaahjj@buaa.edu.cn

通信作者: 程泽源(1992—), 男, 副研究员、硕士生导师, 博士, 主要从事人工智能技术在高效冷却系统设计中的应用等研究。

E-mail: chengzeyuan@buaa.edu.cn

引用格式: 黄俊杰, 朱剑琴, 程泽源. 基于卷积神经网络双层壁三维热应力预测方法[J]. 航空动力学报, 2023, 38(7): 1658-1667. HUANG Junjie, ZHU Jianqin, CHENG Zeyuan. Three-dimensional thermal stress prediction method in double-wall structure using convolutional neural networks[J]. Journal of Aerospace Power, 2023, 38(7): 1658-1667.

双层壁冷却结构是涡轮叶片上一种实施冲击气膜冷却的结构形式,该结构主体为内外双层薄壁,薄壁上有大量孔洞结构,这样的结构有效地冷却了涡轮叶片^[1-3],但也导致薄壁中温度变化十分剧烈。孔洞结构易产生应力集中,这使得热应力在孔洞区域产生的影响进一步增大,产生的热应力不可忽视,结构失效概率增高^[4-5],目前已有学者采用理论分析或数值模拟的方式针对双层壁冷却结构强度开展研究^[4-9]。

强度评估的首要步骤是应力分析,传统应力分析方法采用有限元方法(FEM)评估结构的应力分布^[10-14],但精准的FEM数值模拟会耗费很大的计算资源和时间。随着人工智能等先进信息化技术的发展^[15-17],构建深度学习模型作为有限元代理模型进行应力分析的模式成为目前比较主流的做法,这种应力分析模式在动力响应分析^[18]、生物医学工程^[19]、拓扑优化^[20]、复合材料设计^[21]、材料电镜图像分析^[22]等领域均有应用。Badarinarath等^[18]使用人工神经网络(ANN)作为代理模型,实现了一维梁在时变分布式载荷下的瞬态响应的预测。Liang等^[19]针对动脉管壁应力分布预测问题,首先使用主成分分析对动脉管形状进行降维编码,然后使用深度神经网络构建管壁形状编码和应力编码的映射关系,最后使用双向神经网络实现解码,实现了应力分布预测。针对二维拓扑优化问题,Herath等^[20]通过训练卷积神经网络(CNN)实现最优拓扑预测,再通过条件生成对抗模型(CGAN)预测该拓扑结构的应力场。生成对抗模型(GAN)能够学习到数据集服从的分布,其输出结果具备一定随机性,CGAN通过在生成器和判别器的输入中引入条件变量,条件变量带来的额外信息会约束模型,指导图像生成过程。Herath在使用CGAN时,将施加在结构上的载荷作为条件变量,引入到CGAN中,结果表明CNN预测的最优拓扑和有限元求解结果一致,CGAN生成的应力场最大应力的平均误差在9%以内。Yang等^[21]将CGAN作为代理模型实现了复合材料不同组合方案的应力场预测。Ning等^[22]利用CGAN可直接从两相材料的电镜扫描图片预测热应力。现有工作大多都是针对二维的应力分析问题,或者是将三维应力分析问题拆解为二维,模型输入为几何模型拓扑图片,输出为二维应力场图片,本质上输入输出为三通道的RGB(red green blue)值。采用RGB值作为输入输出数据基本元素使得网络难以学到现象本身背后的潜在机理,只是单纯地建立了数据间的映射关系,此外这样

的数据格式使得模型只能用于二维物理场的预测,而无法在三维物理场预测问题上得到应用。

本文利用CNN实现热载荷作用下双层壁冷却结构外壁三维等效应力场的预测。为将三维物理场作为网络的输入,将温度作为卷积网络输入张量的基本元素,对于一个三维温度场输入张量,在壁厚方向上截取16个二维温度场切片,作为网络架构中16个通道对应的输入。本文首先针对6个结构变量利用拉丁超立方采样,设计了25个不同的双层壁冷却结构模型,在12个不同组合的工况下求解温度场和热应力场,构建了包含300个样本的双层壁冷却结构温度-应力数据集。然后使用了下采样-上采样的网络架构,将温度场作为输入,应力场作为输出,采用跳连的方式连接卷积过程中的特征图,构建了温度-应力的映射网络。研究路线如图1所示。




图1 技术路线图

Fig. 1 Technology roadmap

1 研究模型

双层壁冷却结构平板单元如图2所示,其中 D_f 为气膜孔直径, α 为气膜孔倾斜角, P 为气膜孔展向间距, S 为气膜孔流向间距, H_o 为外壁厚, H 为冲击距离, T_m 为主流燃气温度, T_c 为冷气温度。双层壁冷却结构中冷气从底部进入,冲击到平板内侧,从气膜孔射出,在平板表面形成气膜,燃气从平板一侧于平板方向水平流入,从另一侧流出。在高温燃气和冷气的混合作用下,平板温




图 2 双层壁冷却结构单元

Fig. 2 Double-wall cooling structural unit

度场具备三维非线性特征, 因此很难通过理论求解出平板的热应力场。工程上通常采用计算流体力学(CFD)程序计算平板的温度场, 再将温度作为输入条件, 使用 FEM 来准确评估其热应力。

热应力的形成机理是固体受热产生的不协调变形进而形成应力, 热弹性力学针对由温度引起的线弹性小变形问题已经形成了较为成熟的理论, 对于热弹性问题而言, 其内部应力、应变、位移满足 3 个控制方程, 即平衡方程、几何方程、本构方程, 综合上述方程, 可得到由位移分量表示的平衡方程。

$$\begin{cases} (\lambda + \mu) \frac{\partial e}{\partial x} + \mu \nabla^2 u = \frac{E\alpha}{1-2\nu} \cdot \frac{\partial T}{\partial x} \\ (\lambda + \mu) \frac{\partial e}{\partial y} + \mu \nabla^2 v = \frac{E\alpha}{1-2\nu} \cdot \frac{\partial T}{\partial y} \\ (\lambda + \mu) \frac{\partial e}{\partial z} + \mu \nabla^2 w = \frac{E\alpha}{1-2\nu} \cdot \frac{\partial T}{\partial z} \end{cases} \quad (1)$$

观察方程组(式(1))可以发现, 在材料属性不变、边界不施加力或位移的情况下, 通过温度场即可求解出热载荷下的位移分量, 进而求解出热应力。因此利用 CNN 从温度场中提取特征预测结构热应力场这一研究思路有望实现。

2 数据集构建

2.1 几何和工况变量参数

为使得深度学习模型能够对大多数冲击气膜冷却外壁结构实现热应力预测, 本文选取 6 个重要的结构参数作为变量, 使用拉丁超立方采样, 设计了 25 个几何结构, 图 2 展示了几何参数的定义方式, 结构为冲击气膜冷却单元, 包含一个气膜孔和 4 个冲击孔, 流向上前后和冷气入口段延长了 5 倍气膜孔直径长度, 保证主流充分发展, 展向上计算域截止到气膜孔上下两侧冲击孔的圆心。冲击孔直径为常量 1 mm, 其余结构参数为变量。

结构变量范围的制定策略如下: ①考虑加工制造约束, 气膜孔直径最小为 0.4 mm, 考虑涡轮叶片常见气膜直径经验值, 直径最大为 0.9 mm, 壁厚根据设计经验, 取 0.7~1.2 mm 之间; ②为保证气膜有效覆盖, 气膜入射角变化范围在 20°~70°之间; ③为增大几何结构变量的参数空间, 流向间距、展向间距在 1~5 倍气膜孔直径之间变化、冲击距离在 0.7~1.2 倍气膜孔直径之间变化。选取了 3 个主要的工况因素, 根据典型涡轮叶片双层壁冷却结构数值模拟结果, 对代表性工况进行采样, 形成了 12 个不同的工况组合, 最终构建了 300 个样本数据, 第 m 个几何结构在第 n 个工况下的样本编号为 ID m -CD n , 其中 ID 表示几何模型编号, CD 为工况条件编号。所有的变量参数见表 1。

表 1 变量参数范围

Table 1 Range of variable parameters

参数	数值
气膜孔直径 D_f /mm	0.4~0.9
气膜孔倾斜角 α /°	20~70
气膜孔展向间距 P /mm	$3D_f \sim 5D_f$
气膜孔流向间距 S /mm	$3D_f \sim 13D_f$
外壁厚度 H_o /mm	0.7~1.2
冲击距离 H /mm	0.7~1.2
主流燃气温度 T_m /K	1 700, 1 900, 2 100
主流燃气速度 V_m /(m/s)	400, 800
吹风比 M	0.75, 1.25

2.2 数值模拟设定

选用商用软件 Fluent 进行 CFD 数值模拟。使用 Fluent Meshing 网格划分软件对几何模型产生网格, 使用非结构化网格, 网格生成方法选用 Poly-Hexcore 体网格生成方法, 能够有效提升六

面体网格数量。对孔柱区域网格进行加密,并在流体域壁面设置了边界层,边界层层数数量设置为6层,总体网格数量为18万。求解部分选用 Reynolds average Navier-Stokes (RANS)方法来模拟几何结构的流动和耦合换热过程,湍流模型选用 shear stress transport (SST) $k-\omega$ 模型。图3展示了计算域的边界条件和网格局部视图,主流入口和冷气入口均设置为流量入口条件,主流出口设置为压力出口条件,计算域左右边界设置为周期边界,整个结构包含流体域和固体域两部分,固体域只包括双层壁冷却结构外壁。为满足 SST $k-\omega$ 湍流模型的要求,调整近壁面网格尺寸,保证 y^+ 小于1。当温度场在1000步内保持稳定且最大残差小于 1×10^{-5} 时认为计算已收敛。




图3 几何模型网格

Fig. 3 Geometric model and mesh

在FEM数值模拟过程中,本文使用 Workbench 中的静力分析系统执行有限元计算。有限元计算仅在固体域执行,网格选用非结构化网格。在 Setup 组件中导入 Fluent 温度场结果,作为几何结构的温度场载荷。如图4所示,在平板的冲击靶面设置远端位移约束条件,设置3个方向的位移和旋转自由度为零,从而实现对平板的刚体位移约束,允许模型自由膨胀。网格选用2阶元网格,为保证孔边应力计算结果准确,对网格独立性进行检验,分别采用0.8万、1万、1.8万、3.7万网格进行数值模拟。采用范氏等效应力 σ_{Mises} 对气膜孔边强度进行评价,不同网格规模下气膜孔边等效应力 σ_{Mises} 沿着孔边无量纲位置 x_h/C_h 分布如图5所示,其中 x_h 为气膜孔零点位置开始孔边距离, C_h 为气膜孔周长,图左上角“0/1”表示分布起点和终点位置,箭头指向为分布方向, N 表示网格数。结果表明1.8万和3.7万网格的等效应力差值为1%,可以认为已达到网格无关解。在之后的数值模拟

过程中采用1.8万网格量的尺寸设置,全局尺寸设置为 5×10^{-4} m,孔边网格最大弧度角设置




图4 约束条件设置

Fig. 4 Constraint setting




图5 有限元分析网格无关性检验

Fig. 5 Grid independence check for finite element analysis

为 11.25° , 狭缝间最小网格数量设置为4。

2.3 数据预处理

通过 CFD 和 FEM 模拟得到了温度场和热应力场数据,但是由于数值仿真过程采用了非结构化网格,且模型的几何结构特征比较复杂,所得到的数值模拟数据在空间上并不是均匀排布的,因此无法直接使用卷积核进行卷积操作。目前的相关研究中,一般将导出的几何结构、温度场、应力场图片作为样本投入训练,这不利于 CNN 学习到产生热应力的潜在机理。本文使用三维温度场张量、三维热应力场张量作为模型的输入和输出,采用该空间坐标的温度值和应力值代替 RGB 颜色信息作为张量的基本元素。图6展示了处理后的数据格式,处理流程为通过生成三维均匀网格,使用最近邻采样方法对数据进行插值,得到数据集。




图6 数据处理示意图

Fig. 6 Schematic diagram of data processing

3 卷积神经网络

3.1 网络架构

采用的 CNN 架构如图 7 所示, 整体为下采样-上采样的架构。网络的输入包含 16 个通道, 每个通道的长宽分别为 256 和 64。对于一个双层壁冷却结构外壁三维温度场输入张量, 在壁厚方向上均匀截取 16 个切片, 作为网络架构中 16 个通道对应的输入。下采样网络由 4 个卷积模块组成, 每个模块由卷积、批标准化、Relu 激活函数、池化层组合而成, 卷积层采用了 3×3 大小的卷积核,

步长为 1, 池化层使用平均池化, 卷积核大小为 2×2 , 步长为 2。上采样网络采用和下采样网络对称的结构, 采用了 4 个转置卷积模块。图 7 介绍了卷积模块和转置卷积模块的具体结构, 其中 Conv 表示卷积操作, BatchNorm 表示标准化操作, Relu 表示激活函数映射操作, Pool 表示池化操作, ConvTransp 表示转置卷积操作。下采样过程中产生的多通道特征图跳跃连接到上采样的过程中, 确保模型在上采样过程中能获取更多温度信息, 解码出更加准确的结果。网络最终输出大小为 $16 \times 256 \times 64$ 的应力场张量。




图 7 CNN 网络结构

Fig. 7 Architecture of the CNN

3.2 损失函数和指标

使用均方误差(MSE, 量符号记为 E_{MSE})作为 CNN 模型的损失函数, 定义如下:

$$E_{MSE} = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (2)$$

其中 n 是样本点的数量, y_j 是 FEM 计算值, $\hat{y}_j$ 是 CNN 预测值。

选用以下 4 项指标评估模型性能: 平均绝对误差(MAE, 量符号记为 E_{MAE})、平均相对误差(MRE, 量符号记为 E_{MRE})、峰值应力平均绝对误差(PMAE, 量符号记为 E_{PMAE})、峰值应力平均相对误差(PMRE, 量符号记为 E_{PMRE})。以上 4 个指标都与模型的损失函数没有直接关系, 因此可用于评估模型预测结果质量。

E_{MAE} 和 E_{MRE} 可用于评估预测结果的整体质

量。 E_{MAE} 定义如下:

$$E_{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (3)$$

E_{MRE} 定义如下:

$$E_{MRE} = \frac{1}{n} \sum_{j=1}^n \frac{|y_j - \hat{y}_j|}{\varepsilon + \max(y_j, \hat{y}_j)} \times 100\% \quad (4)$$

其中 ε 是防止除数为 0 的极小值, 取 1×10^{-4} , 其他变量定义和 E_{MSE} 相同。

工程应用中峰值应力是几何结构应力场中最受关注的应力数据, E_{PMAE} 和 E_{PMRE} 可用于评估模型对于峰值应力的预测精度。 E_{PMAE} 定义如下:

$$E_{PMAE} = |\max\{Y\} - \max\{\hat{Y}\}| \quad (5)$$

其中 Y 是一个样本中所有点的 FEM 计算结果值, $\hat{Y}$ 是一个样本中所有点的 CNN 预测值。

E_{PMRE} 定义如下：

$$E_{\text{PMRE}} = \frac{E_{\text{PMAE}}}{\max\{Y\}} \times 100\%$$

(6)

4 预测精度表现

在 Pytorch 中构建代码，并在 NVIDIA GeForce RTX 3060Ti GPU(graphics processing unit) 上运行。采用学习率为 1×10^{-2} 的 Adam 优化算法进行训练, 批大小设为 8。在整个数据集上对模型进行了训练, 评估基于 CNN 的三维热应力预测模型的表现。将数据集按 9 : 1 比例分为训练集和测试集, 训练 4 000 轮次。



表 2 展示了 CNN 模型在训练集和测试集上的各项指标得分。图 8 展示了训练集中编号为 ID1- CD1 样本的预测效果, 样本各项变量具体值见表 3。图 8(a)展示了厚度方向上不同厚度二维切片云图, 从左至右分别是温度场、FEM 等效应力场、CNN 预测的等效应力场以及相对误差场, 截面 0 和截面 15 分别表示平板的冲击靶面和气膜覆盖面, 截面 7 是模型厚度方向的中截面。对于不同高度的截面, 卷积核很好地预测了等效应力, 预测的等效应力分布和 FEM 得到的应力分布高度一致, 对于孔边高应力值区域的重构效果也很好; 图 8(b) 展示了沿流向过气膜孔中心的切片的预测效果, 可以发现在不同的厚度上, CNN 都

能较好地重构出等效应力分布; 图 8(c)以模型气膜覆盖面上分别沿流向和展向不同位置上的等效应力曲线的形式, 对 FEM 数据和 CNN 预测数据进行定量比较。选取的 6 条曲线具有代表性, 因为它们穿过了气膜孔圆心或孔边等高应力区, 可以发现 CNN 模型在选取的区域都有很高的精度。图 9 展示了测试集中编号为 ID1-CD7 样本的预测效果, 各子图展示内容和图 8 相似。可以发现测试集上 CNN 模型很好地重构出了等效应力分布, 但是在预测精度上有所降低。图 8(a)和图 9(a)中的相对误差云图表明, 等效应力较高的区域相较于等效应力较低的区域, 相对误差更低, 这是因为 CNN 模型采用 MSE 作为损失函数, 该损失函数使得预测结果在各个区域的绝对误差相差不会很大, 但高应力区和低应力区在数值上相差 1~2 个数量级, 这导致了高应力区域有更小的相对误差。

表 2 训练集和测试集各项指标结果

Table 2 Indexes results of the training set and testing set

参数	训练集	测试集
$E_{\text{MSE}}/\text{MPa}^2$	0.40	3.49
$E_{\text{MAE}}/\text{MPa}$	0.43	1.23
$E_{\text{MRE}}/\%$	6.75	15.10
$E_{\text{PMAE}}/\text{MPa}$	2.63	16.10
$E_{\text{PMRE}}/\%$	2.39	11.81






图 8 训练集中 ID1 几何结构预测结果

Fig. 8 Prediction results of ID1 geometry in the training set


表 3 样本各项变量的具体取值

Table 3 Values of each variable in the sample

样本	训练集样本 ID1-CD1	测试集样本 ID1-CD7
D_f/mm	0.85	
$\alpha/(\text{^\circ})$	30.16	
P/mm	$4.09D_f$	
S/mm	$12.84D_f$	
H_o/mm	0.75	
T_m/K	1 700	
$V_m/(\text{m/s})$	400	
M	0.75	1.25

图 10 从统计的角度上展示了 CNN 模型分别在训练集和测试集上的绝对误差分布,图 10(a)是训练集,图 10(b)是测试集。可以发现在训练集上,99% 区域的绝对误差小于 0.95 MPa,在测试集上,99% 区域的绝对误差小于 2.98 MPa。

相较于其他指标,等效应力峰值更有工程意义,因此针对等效应力峰值进行了回归分析。回归分析指标 R^2 衡量了预测值和实际值的拟合程度,图 11 展示了回归结果,FEM 等效应力峰值和 CNN 等效应力峰值在训练集和测试集上的相关系数分别为 0.99 和 0.83,观察等效应力峰值分布可以发现,在训练集上,对于不同大小的等效应力值都能够精准预测,而在测试集上,较大等效应力点的预测误差更大。






图 9 测试集中 ID1 几何结构预测结果

Fig. 9 Prediction results of ID1 geometry in the testing set




图 10 训练集和测试集上的绝对误差分布

Fig. 10 Absolute error distribution on the training set and testing set




图 11 训练集和测试集上预测应力场峰值应力回归分析

Fig. 11 Peak stress regression analysis of predicted stress field on training set and testing set

5 结 论

本文为了实现双层壁冷却结构外壁三维热应力场的预测,基于 CNN 建立了三维热应力预测模型。模型将物理量作为输入张量的基本元素,将几何结构厚度维度对应 CNN 的通道维度,从而实现了三维物理场的输入和输出。采用 CFD 结合 FEM 数值模拟方法建立了双层壁冷却结构外壁热应力数据集。所建立的 CNN 模型能够准确地实现热应力场的预测,通过对训练集和测试集整体指标的评估,以及对典型几何结构的二维云图分析,验证了 CNN 模型的精度水平。通过对工作总结得到了以下结论:

1) 本文提出的以温度代替 RGB 值作为输入张量基本元素、将几何结构厚度维度对应 CNN 的通道维度的输入形式,能够实现将三维温度场输入到 CNN 中并进行训练,实验结果表明采用该

输入数据格式的模型能够建立三维物理场间的映射关系,并且具有很高的预测精度。这样的输入数据格式可广泛应用于三维物理场预测问题上。

2) 通过分析模型性能,所建立的模型在训练集上平均绝对误差为 0.43 MPa,平均相对误差为 6.75%,平均峰值绝对误差为 2.39 MPa,平均峰值相对误差为 2.69%,在测试集上平均绝对误差为 1.23 MPa,平均相对误差为 15.10%,平均峰值绝对误差为 16.10 MPa,平均峰值相对误差为 11.81%。针对预测结果绝对误差分布进行了统计,训练集上 99% 的区域应力小于 0.95 MPa,测试集上 99% 的区域应力小于 2.98 MPa。针对应力峰值进行了回归分析,在训练集和测试集上的相关系数分别为 0.99 和 0.83。

据作者所知,本文是最早利用 CNN 求解三维热弹性问题的工作之一。热应力的产生机理是由于固体受热产生的膨胀或者收缩导致的不协调变形,局部温度的大小一定程度上反映了局部的变形强弱,而 CNN 中的卷积计算收集了周围位置的信息,因此卷积核函数具备了求解热应力的基本条件。本文建立的 CNN 模型的网络架构采用了在计算机视觉领域较为主流的下采样-上采样架构,以数据驱动的形式实现了热应力预测,但本文工作仍有如下不足:

1) CNN 架构存在进一步优化的空间。神经网络架构和任务是紧密相关的,一个和任务匹配的架构能够使得预测精度和泛化性都得到增强。本文采用的 CNN 架构能够达到热应力预测任务的目标,但还存在一定的提升空间。

2) 预测模型的适用范围有待进一步扩展。本文建立的预测模型能够针对简化的双层壁外壁单元实现热应力的预测,但平板的曲率、壁内外的气体压力等因素未考虑进预测模型。

未来工作可考虑纳入更多对热应力形成存在影响的几何和工况参数,利用现有的热弹性力学知识对数据的学习过程进行约束,围绕热应力产生机理建立更加具备解释性的网络架构。

参考文献:

- [1] CHANG S W, CHIANG P A, CAI W L. Thermal performance of impinging jet-row onto trapezoidal channel with different effusion and discharge conditions[J]. International Journal of Thermal Sciences, 2021, 159: 106590.1-106590.21.
- [2] LIU Yuyang, RAO Yu, YANG Li, et al. Flow and heat transfer characteristics of double-wall cooling with multi-row short film cooling hole arrangements[J]. International Journal of Thermal Sci-

- ences, 2021, 165: 106878.1-106878.13.
- [3] MOON M A, KIM K Y. Analysis and optimization of fan-shaped pin-fin in a rectangular cooling channel[J]. *International Journal of Heat and Mass Transfer*, 2014, 72: 148-162.
- [4] WANG S, ZHANG Z. Failure mechanism of turbine guide vane and oxide composition analysis on the surface of failure vane cracks [J]. *Engineering Failure Analysis*, 2020, 117: 104763.1-104763.8.
- [5] GUO Zixu, SONG Ziyuan, FAN Jun, et al. Experimental and analytical investigation on service life of film cooling structure for single crystal turbine blade[J]. *International Journal of Fatigue*, 2021, 150: 106318.1-106318.13.
- [6] KIM K M, MOON H, PARK J S, et al. Optimal design of impinging jets in an impingement/effusion cooling system[J]. *Energy*, 2014, 66: 839-848.
- [7] ELMUKASHFI E, MURRAY A V, IRELAND P T, et al. Analysis of the thermomechanical stresses in double-wall effusion cooled systems[J]. *Journal of Turbomachinery*, 2020, 142(5): 051002.1-051002.13.
- [8] SKAMNIOTIS C, COCKS A C F. Minimizing stresses in double wall transpiration cooled components for high temperature applications[J]. *International Journal of Mechanical Sciences*, 2021, 189: 105983.1-105983.13.
- [9] GUO Zixu, HUANG Dawei, YAN Xiaojun, et al. A damage coupled elastic-plastic constitutive model and its application on low cycle fatigue life prediction of turbine blade[J]. *International Journal of Fatigue*, 2020, 131: 105298.1-105298.12.
- [10] HONG Hui, WANG Weizhe, LIU Yingzheng. High-temperature fatigue behavior of a steam turbine rotor under flexible operating conditions with variable loading amplitudes[J]. *International Journal of Mechanical Sciences*, 2019, 163: 105121.1-105121.13.
- [11] GIANNELLA V, VIVO E, MAZZEO M, et al. FEM-DBEM approach to simulate crack propagation in a turbine vane segment undergoing a fatigue load spectrum[J]. *Procedia Structural Integrity*, 2018, 12: 479-491.
- [12] CUNHA F J, DAHMER M T, CHYU M K. Thermal-mechanical life prediction system for anisotropic turbine components[J]. *Journal of Turbomachinery*, 2006, 128(2): 240-250.
- [13] BANASZKIEWICZ M. Numerical investigations of crack initiation in impulse steam turbine rotors subject to thermo-mechanical fatigue[J]. *Applied Thermal Engineering*, 2018, 138: 761-773.
- [14] MURRAY A V, IRELAND P T, RAWLINSON A J. An integrated conjugate computational approach for evaluating the aerothermal and thermomechanical performance of double-wall effusion cooled systems[R]. ASME Paper GT2017-64711, 2017.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th Medical Image Computing and Computer-Assisted Intervention (MICCAI) International Conference. Munich, Germany: Springer, 2015: 234-241.
- [16] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks[C]//Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. Salt Lake City, US: IEEE, 2018: 7132-7141.
- [17] LIU Peirong, TIAN Lin, ZHANG Yubo, et al. Discovering hidden physics behind transport dynamics[C]//Proceedings of the Institute of Electrical and Electronics Engineers/ Computer Vision Foundation (IEEE/CVF) Conference on Computer Vision and Pattern Recognition. Nashville, US: IEEE, 2021: 10082-10092.
- [18] BADARINATH P V, CHIERICHETTI M, KAKHKI F D. A machine learning approach as a surrogate for a finite element analysis: status of research and application to one dimensional system[J]. *Sensors*, 2021, 21(5): 1654.1-1654.18.
- [19] LIANG L, LIU M, MARTIN C, et al. A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis[J]. *Journal of The Royal Society Interface*, 2018, 15(138): 20170844.1-20170844.10.
- [20] HERATH S, HAPUTHANTHRI U. Topologically optimal design and failure prediction using conditional generative adversarial networks[J]. *International Journal for Numerical Methods in Engineering*, 2021, 122(23): 6867-6887.
- [21] YANG Zhenze, YU Chihua, BUEHLER M J. Deep learning model to predict complex stress and strain fields in hierarchical composites[J]. *Science Advances*, 2021, 7(15): 7416.1-7416.11.
- [22] NING L, CAI Z, LIU Y, et al. Conditional generative adversarial network driven approach for direct prediction of thermal stress based on two-phase material SEM images[J]. *Ceramics International*, 2021, 47(24): 34115-34126.

(编辑: 王碧琨)