

飞行器智能流场建模方法研究进展

张好, 沈洋, 黄伟*, 赵振涛, 安凯, 刘双喜

(国防科技大学空天科学学院, 湖南长沙 410073)

摘要:智能流场建模方法通过融合深度学习在特征提取与动态响应预测中的优势,以及在多学科设计优化(multidisciplinary design optimization, MDO)架构中的创新潜力,已成为实现复杂流动系统高效建模与高性能提升的研究热点。本文从数据驱动方法与物理约束方法两方面系统梳理了智能流场建模的研究现状,并指出了发展面临的三大关键挑战:高保真数据获取、复杂边界几何特征表达以及鲁棒物理约束的构建。进一步地,展望了融合气动与多学科耦合效应的联合建模框架,或能通过多尺度物理信息嵌入与自适应优化机制,革新下一代飞行器MDO范式。提供了数据知识与物理机理的深度融合新思路,旨在推动智能流场建模在航空航天等领域的跨学科创新。

关键词:智能流场预测;深度学习;代理模型;数据驱动;物理约束;多学科设计优化

中图分类号:V211.3 **文献标志码:**A **文章编号:**1001-2486(2026)01-001-15

Research progress on intelligent flow field modeling method for aircraft

ZHANG Hao, SHEN Yang, HUANG Wei*, ZHAO Zhentao, AN Kai, LIU Shuangxi

(College of Aerospace Science and Engineering, National University of Defense Technology, Changsha 410073, China)

Abstract: Intelligent flow field modeling methods, by integrating the strengths of deep learning in feature extraction and dynamic response prediction with architectural innovation potential in MDO (multidisciplinary design optimization), have emerged as research hotspot for achieving efficient modeling of complex flow systems and enhancing high-dimensional performance. The state-of-the-art in intelligent flow field modeling was systematically reviewed from two perspectives: data-driven approaches and physics-constrained methodologies. Three critical challenges, including acquisition of high-fidelity data, representation of complex boundary geometries, and establishment of robust physical constraints, were identified. Furthermore, a joint modeling framework that integrated aerodynamics and multidisciplinary coupling effects was expected to revolutionize the next generation of aircraft MDO paradigm through multi-scale physical information embedding and adaptive optimization mechanisms. A new idea for the deep integration of data knowledge and physical mechanisms was provided, aiming to inspire interdisciplinary innovations for intelligent flow field modeling in aerospace and other fields.

Keywords: intelligent flow field prediction; deep learning; surrogate model; data-driven; physics-constraint; multidisciplinary design optimization

飞行器学科间耦合严重且高度非线性、建模难度大、大规模计算效率低、准确预测难,与流场特性密切相关,而高超声速流场的计算复杂性对相关学科建模提出了严峻挑战,进而限制了多学科设计优化^[1] (multidisciplinary design optimization, MDO)的整体效率。高速流场建模依赖于计算流体力学(computational fluid dynamics, CFD)的反复、大量高成本模拟,但是对

人工经验的依赖导致数值模拟的自动化实现困难,这成为MDO框架效率的重要瓶颈。

近年来,随着人工智能技术的蓬勃发展,具备强大非线性拟合能力的深度学习作为其重要分支,在图像处理^[2-4]、自然语言处理^[5]等领域取得了突破性的进展,并逐渐在其他工业领域的应用中展现出广泛潜力。为了探究深度学习技术与飞行器MDO结合的系统性创新架构,研究以深度

收稿日期:2025-04-16

基金项目:国家自然科学基金资助项目(12472338);航空科学基金资助项目(20220014079001)

第一作者:张好(2000—),女,甘肃定西人,博士研究生,E-mail:onenut_hao@yeah.net

*通信作者:黄伟(1982—),男,湖北天门人,研究员,博士,博士生导师,E-mail:gladrain2001@163.com

引用格式:张好,沈洋,黄伟,等.飞行器智能流场建模方法研究进展[J].国防科技大学学报,2026,48(1):1-15.

Citation: ZHANG H, SHEN Y, HUANG W, et al. Research progress on intelligent flow field modeling method for aircraft[J]. Journal of National University of Defense Technology, 2026, 48(1): 1-15.

学习代理模型为主体的流场建模方法至关重要^[6-8]。随着计算机技术的发展与 CFD 数据在飞行器设计领域内的积累,智能流场建模展现出巨大的发展空间。

智能流场建模往往通过深度学习算法来分析和重构复杂流体力学现象。该方法通过端到端学习直接建立几何、流场与目标性能间的隐式映射关系,能够从大规模流场数据或物理方程的约束中学习潜在模式,构建可以有效捕捉复杂流动特征的模型,适用于 MDO 中的流场分析任务^[9]。

针对智能流场建模已有部分综述工作,如: Faroughi 等^[10]着重于物理机理对科学计算的影响,

王泽等^[11]总结了基于数据驱动的气动热建模方法,Wang 等^[12]、Hakeem 等^[13]和 Liu 等^[14]先后梳理了智能流场建模的技术发展现状、面临的挑战并对未来发展进行了展望。本文在参考上述工作的基础上,创新性地首先按照二维和三维流场问题对基于数据驱动的方法进行了研究综述,然后以强约束和弱约束对物理增强方法进行了归纳总结,最后结合与 MDO 框架的耦合关系对其进行了现有技术总结和展望。如表 1 所示,根据精度表现、计算效率、数据需求、适用场景以及核心特性(优势与局限)五个方面将经典智能流场预测模型进行归纳整理,方便读者进行对比选择。

表 1 智能流场预测模型特点
Tab. 1 Characteristics of intelligent flow field prediction models

模型类型	精度表现	计算效率	数据需求	适用场景	核心特性
卷积神经网络	像素化损失严重	架构内在高效	大量标签数据	流场识别	优势:高效局部特征提取 局限:非结构化适配差
点云网络	几何细节保留	采样策略敏感	足够密度点云	复杂几何边界	优势:几何泛化性强 局限:稀疏数据敏感
图卷积网络	图结构适配强	对稀疏图高效	明确拓扑关系	流场重构	优势:网络信息充分利用 局限:几何泛化性差
物理信息网络	依赖训练设置	迭代效率低	无数据监督	微分方程求解 (正/逆向问题)	优势:物理可解释性 局限:复杂方程收敛难
神经算子	依赖数据分布	高效算子映射	场数据支撑	参数化场	优势:函数空间映射 局限:网格适配受限

1 数据驱动的智能流场建模方法

近年来,数据驱动的深度学习模型在流场建模领域展现出革命性突破,其通过端到端非线性映射能力突破了传统基于人工定义变量集与经验闭合模型的局限性,显著提升了泛化构型的跨工况预测性能^[15]。由于这类模型能够显著提升流场响应速度,已在航空航天等领域获得了广泛关注。随着 CFD 数据量的快速增长,研究人员迫切需要开发能够高效处理和分析复杂流场的工具,以减少对显式物理建模的依赖。研究者们不仅对基于数据驱动方法的二维流场建模进行了方法探索,且尝试对更贴近于工业实际的三维流场建模提供突破方案。

1.1 二维流场建模

在二维流场建模的研究中,深度学习方法已

取得了显著进展,尤其是在航空航天设计领域的应用。近年来,卷积神经网络(convolutional neural networks,CNN)作为基础模型被大规模地应用于流场建模研究。Zhang 等^[16]的研究展示了 CNN 在预测翼型升力系数中的应用,尽管该模型未能实现对整个流场的全面预测,但其特征提取方法为后续研究提供了重要启示。在此基础上,Bhatnagar 等^[17]的研究进一步验证了使用 CNN 进行翼型流场建模的可行性,如图 1 所示,该研究通过像素格式的距离场表示翼型几何形状,成功应用于二维流场的预测。文献[18-19]进行了类似的研究,也将输入翼型处理为像素化图像,并采用 CNN 进行翼型流场的预测与逆向设计。Sekar 等^[18]的研究表明,训练后的模型在面对未见过的翼型时仍能保持较高的预测精度,展现出 CNN 强大的泛化能力,特别是在有限数据量条件下表现优异。




图 1 基于像素的距离场被用于模型输入^[17]

Fig.1 Pixel based distance field is used as model input^[17]

Duru 等^[20]的研究继续采用距离场作为输入特征,通过建立如图 2 所示的 CNN 架构有效预测了跨声速翼型的流场,展现了模型在多种工况下的强适应性和稳健性。随后,其他多项研究^[21-26]进一步验证了 CNN 在不同工况条件下的预测准确性,证明了其在变工况场景中的推测能力。Hui 等^[27]则针对 RAE 2822 翼型,基于 CNN 识别自由

网格变形参数化设计特征,训练模型不仅提高了气动外形设计的效率,还为设计过程提供了更具解释性的输出,有力支持于气动优化。Thuerey 等^[28]通过将流场投影至均匀笛卡儿网格,提出了基于 U-Net 神经网络(一种多个 CNN 模块组成的编码器-解码器架构)的图像到图像的端到端映射方法,建立了翼型几何、流动条件与速度场、压力场之间的关联映射。

然而,以上针对像素化的 CNN 方法在处理非结构网格时,插值操作会导致精度的损失。处理二维复杂边界条件或三维流场时,像素化方法由于无法准确捕捉几何特征的细节,会严重阻碍模型的泛化表现。Chen 等^[29]则继续基于 U-Net 神经网络,提出了一种基于坐标变换的流场预测方法,如图 3 所示。相较于直接的像素化方法,该技术通过自适应坐标变换保留了近壁面区域的流场细节。Hu 等^[30]提出 Mesh-Conv 算子,构建了更具鲁棒性的网格空间信息表示能力的模型,实现了网格而非传统像素化的流场重构模式。




图 2 基于像素距离场输入的流场预测 CNN 架构^[20]

Fig.2 CNN architecture for flow field prediction based on pixel distance field input^[20]

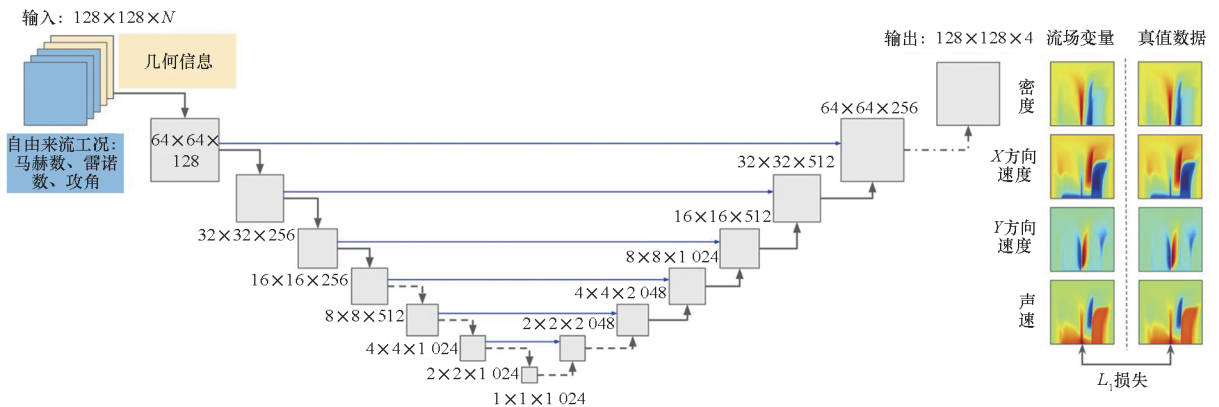


图 3 基于坐标变换输入的 U-Net 架构^[29]

Fig.3 U-Net architecture based on coordinate transformation input^[29]

为了更有效地捕捉流场结构,学者们^[31-40]研究探索了 CNN 以外的深度学习模型在流场建模中的应用。Wang 等^[31]训练了一个变分自动编码器(variational autoencoder, VAE),其中编码器将

流场图像提取为潜在特征,并结合解码器将潜在特征转换为生成的流场图像。进一步结合多层感知机(multi-layer perceptron, MLP)结构,连接翼型控制点输入和上述提取的潜在特征,实现在翼型

周围流动空间的准确预测与快速收敛,其预测效果如图 4 所示。Liu 等^[32]基于相似的思路,将翼型的类别-形状变换(class-shape transformation, CST)参数与全连接神经网络结合,用于气动设计优化。相对于此前的 CNN 模型研究,这种设计使

得它们的泛化能力在参数化范围之外的场景中表现受限。然而,这些模型的有效性依赖于具体的参数化方法,因此应用场景受到限制,无法适应更为复杂、非参数化的几何形状和广泛的流场建模需求。

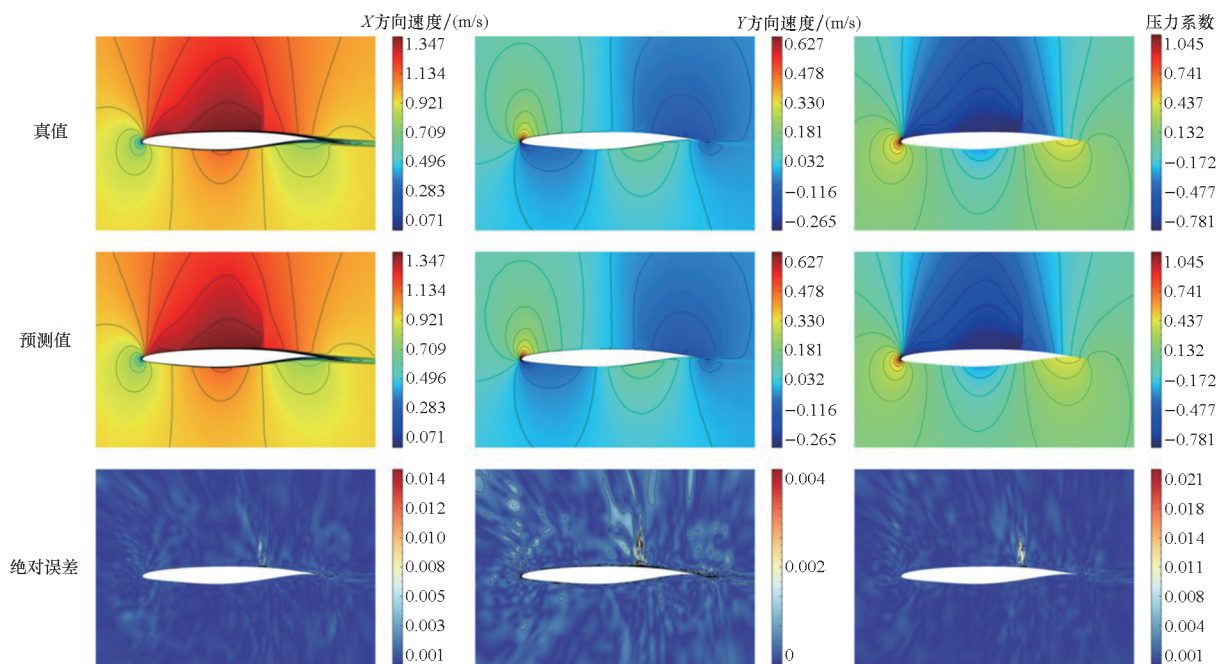


图 4 基于 VAE 模型的流场预测展示^[31]

Fig. 4 Exhibition of flow field prediction based on the VAE model^[31]

在直接输入几何形状的建模研究方面,学者们^[33-36]研究采用了实际的形状几何作为模型输入,利用自动编码器(autoencoder, AE)基础框架或类似的全连接神经网络结构,实现了翼型的准确表达。相较于此前普遍采用的像素图像表达,这些方法因其在建模质量和计算效率上的优势而被广泛认可。Wang 等^[33]提出联合 VAE 和生成对抗网络(generative adversarial network, GAN)的端到端翼型生成优化框架,利用 VAE 将翼型坐标序列压缩为低维潜变量,捕捉几何与气动特征的隐式关联,利用 GAN 通过对抗训练生成平滑翼型。Wu 等^[34]在翼型气动系数的预测中,也直接利用几何坐标作为全连接神经网络的输入,展现了较高水平的预测精度。此外,Deng 等^[35]设计了改进的视觉变换器(vision transformer, ViT)用于超临界翼型跨声速流场预测,首次将 ViT 的全局注意力机制与编码器-解码器结构结合,显著提升了对激波、分离流等复杂流动特征的捕捉能力。采用几何编码与激波优化的协同设计,构建端到端预测框架,直接输入翼型几何与流动条件,并通过预训练-微调框架,为实际工程中数据稀缺问题提供了新思路。Wang 等^[36]提出了组合自

编码器(combined autoencoder, CAE)网络架构设计,将几何编码与流动条件融合作为输入,直接预测气动系数与压力分布。CAE 通过分离几何特征提取(AE)与物理量预测(MLP),简化了模型复杂度;通过在大规模数据集上预训练 AE 模块,并在小数据集上微调 MLP 模块,显著提升了小样本场景下的泛化能力。

另外,基于点云的方法通过直接利用网格点数据,准确表达几何边界的同时,避免了插值的精度损失,具有更加灵活的数据处理形式,在二维问题的研究^[37-41]中表现优异,也更有潜力拓展到三维流场预测。Kashefi 等^[37-38]提取网格点坐标信息作为点云以表示流场空间,展现了超越之前流场建模研究的形状泛化能力,所形成的对不同几何体的预测如图 5(a)所示,良好的泛化能力意味着单个模型可以用于多种场景的流场预测。为了更完整地表达几何关系,有研究^[39-41]不仅输入点云还输入点间拓扑关系,如 Chen 等^[39]提出将图神经网络(graph neural network, GNN)直接应用于贴体三角形网格,而非传统的规则像素网格。Strönisch 等^[40]也提出基于 GNN 直接处理大规模变尺寸二维点云的学习框架,如图 5(b)所示成功

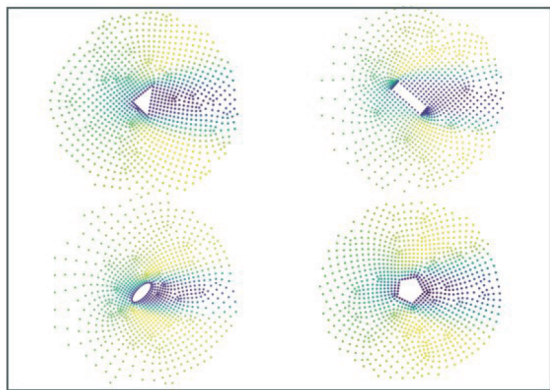

(a) 小规模点云^[37](a) Small-scale point cloud^[37](b) 大规模点云^[40](b) Large-scale point cloud^[40]

图5 点云模型在流场预测中的形状泛化能力

Fig.5 Shape generalization ability of point cloud model in flow field prediction

预测绕翼型的流场分布,验证了方法的几何泛化能力。Lan等^[41]基于GNN的深度学习框架,利用大规模点云数据预测叶栅跨声速流场。通过多层图结构,模型能够同时捕捉流场的激波分布和边界层分离,并直接处理非结构化点云数据。相较于传统CFD方法,该框架在保证精度的同时,预测速度提升了近4倍,体现了数据驱动模型在加速复杂流场模拟中的潜力。Xie等^[42]提出了一种结合图卷积网络(graph convolutional network, GCN)和循环神经网络(recurrent neural network, RNN)的新型降阶模型,用于预测圆柱体周围的非结构化瞬态流场序列。

综上所述,基于数据驱动的智能流场建模方法已成为备受关注的研究方向。尽管目前的研究主要集中在二维翼型的预测上,但通过引入新模型和不同的几何表达方式,已有研究推动了更复杂流场建模场景的探索。这些研究不仅验证了模型在预测精度和适应性方面的潜力,也为飞行器

复杂流场建模的发展提供了新的思路。

1.2 三维流场建模

在飞行器设计优化中,具有形状泛化能力的三维流场模型需求尤为突出,然而现有的流场建模研究大多集中于二维对象。二维流场建模难以向三维拓展的主要原因在于维度扩展带来了指数级增长的数据处理规模。单个飞行器形状及其流场数据量极为庞大,现有模型难以构建通用的三维几何特征提取模式。具体的技术瓶颈在于,参考CFD数值模拟,网格的数量和质量对于获得准确的流场计算至关重要,而主流的像素化几何表达难以通过合理的计算资源满足这一需求。这一限制导致三维流场建模未能从CNN等模型技术的快速发展中获得同等的进展。尽管目前针对三维流场建模的研究较为有限,但它们为未来工业级复杂流场建模的探索提供了重要的启示。

在当前有限的研究中,Li等^[43]通过图6所示的SA-HFNet架构预测三维飞行器的表面热通量,该模型通过表面图像合并局部表面坐标来增强特征构造。由图6可以观察到模型通过多个层级的融合设计,提取了飞行器的全局形状,在最终的测试结果中展现了一定的形状泛化性能。Sabater等^[44]开发了全连接神经网络模型的飞行器气动预测方法,旨在通过减少CFD仿真的计算成本来快速预测飞机表面压力分布。此工作主要处理同一形状下,不同位置、不同工况时的流动特性。因为模型的输入是飞行器几何离散坐标,彼此之间相互孤立,不具备全局几何提取的结构,因而缺乏对其他飞行器形状的应用能力。

基于点云网络的研究在三维场景上展现出优异的适用性,如Xiong等^[45]提出了一种基于点云深度神经网络的气动预测模型,输入ONERA M6机翼表面形状的三维点云数据进行训练,模型不仅能提取三维翼型的几何特征,而且能经过分支输入工况变量马赫数和攻角,实现不同飞行条件下的气动预测。通过将模型应用于气动形状优化,验证了模型的有效性。Shen等^[46]针对数据驱动深度学习模型在飞行器表面流场的高维数据处理问题,提出了能有效提取飞行器形状特征的深度学习建模方法,如图7所示。通过设计图8所示的基于PointNet++模型的飞行器表面流场预测框架,解决了不同构型下流场建模的统一性问题。针对模型训练过程中样本标签不足的问题,继而提出了PointNeXtReg框架^[47],并通过小样本迁移学习,针对三维飞行器几何外形进行了跨设计维度的预测研究。另外,通过将来流物理




图 6 SA-HFNet 网络架构^[43]

Fig. 6 SA-HFNet network architecture^[43]

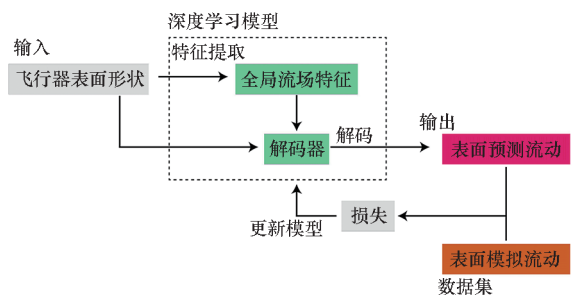


图 7 表面流场模型设计方法

Fig. 7 Design methodology for surface flow field modeling

信息融入 PointNeXtReg 框架, 针对单一目标飞行器实现了对不同来流条件下表面压力场的更精确预测, 进一步验证了此框架的有效性^[48]。进一步, Shen 等针对深度学习模型在高速流动干扰中长距离推理能力缺失问题, 提出了如图 9 所示可推广至空间流场的通用模型设计方法。通过采用改进的注意力机制对流场空间特征解耦, 实现了长距离信息传播, 使得模型能够在稀疏流场数据上进行训练, 捕捉包括激波在内的长距离复杂流动现象, 展现突出的准确性和泛化能力^[49]。




图 8 基于 PointNet++ 深度学习模型的飞行器表面流场预测框架^[46]

Fig. 8 Aircraft surface flow field prediction framework based on PointNet++ + deep learning model^[46]

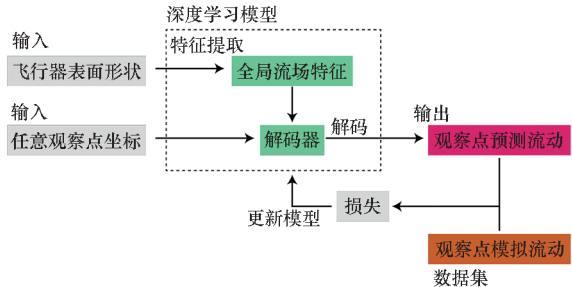


图 9 空间流场模型设计方法^[49]

Fig. 9 Design methodology for spatial flow field modeling^[49]




图 10 以节点特征和边权重的图形式表征网格^[50]

Fig. 10 Mesh represented as a graph with node features and edge weights^[50]

通过充分利用图 10 所示的网格拓扑关系, Massegur 团队设计了多网格图卷积自编码器^[50], 通过层次化图结构融合多尺度流场特征, 在三维非结构化网格上完成稳态流场端到端预测。Hines 等^[51]采用 GNN 对三维飞行器表面压力场

进行建模, 在保留非结构化网络拓扑属性的同时, 实现了关于 6 个参数的外推预测并且涉及几何控制点的微小变形。但现有图学习方法受限于邻域节点拓扑关系的显式建模需求, 其计算复杂度随

网格规模呈指数增长,难以实现对复杂几何的泛化。Zhang 等^[52]提出一种基于残差图卷积网络的初始流场设定方法,通过将网格转化为图结构并设计改进的图神经网络,实现对任意类型网格的流场预测。该方法并非直接替代 CFD,而是作为辅助工具为其提供高质量初始场,在保证计算精度的同时提升收敛效率。

也有部分学者^[53-54]结合场反演与符号回归方法,尝试将显示的数学理论公式赋予抽象的数据知识形式,即将黑箱的数据驱动模型白箱化。如 Sun 等^[53]提出了一套覆盖数据生成、特征构建、模型训练到部署验证的完整数据驱动湍流建模流程。与传统基于 RANS (Reynolds-averaged Navier-Stokes) 方程的方法相比,该框架通过场反演与符号回归的结合,提升了模型分离流、失速特性下的复杂流动预测能力,显著改善了三维高升力构型的失速预测精度。这一流程的标准化为数据驱动模型从理论到工程应用的转化提供了范式。Zhang 等^[54]同样使用场反演与符号回归的结合修正,并采用迁移策略,验证了修正项在不同湍流模型间的可移植性。该方法突破了传统数据驱动模型局限于单一方程框架的瓶颈,为复杂构型的多场景应用奠定基础。

上述流场建模研究在三维空间中的成功拓展均源自其对飞行器形状在模型中的特征表达创新,分析认为具有如下特点:

1) 模型的主要输入为飞行器表面的几何特征,通过集中学习这些表面特征来捕捉关键的流场信息。这一设计策略显著不同于二维流场建模方法,后者通常依赖大量空间内的流场数据和 CFD 的精细网格。相比之下,三维流场建模设计中倾向于减少对大规模网格的依赖,目的是使计算成本可控,但需要同时兼顾对复杂三维形状的敏感性。

2) 模型展示了对不同形状进行泛化的能力。这一能力可能得益于模型在训练过程中建立了全局几何特征表达,即通过捕捉飞行器整体的几何结构,模型能够学习形状与流场间的潜在映射关系。这种全局性的特征提取策略在复杂构型下尤为有效,因为它避免了对局部流场数据的过度依赖,提升了模型在不同构型下的适应性。

3) 尽管模型表现出一定的形状泛化能力,但当训练样本数量有限时,模型在未见形状上的预测精度显著下降。这表明深度学习模型在三维飞行器形状建模中,仍然需要大量高质量样本来支撑其泛化能力,特别是在构型形状变化较大的情况下。

数据驱动模型在流场预测中体现出高精度、高效性和强泛化性。然而,模型对高质量数据的依赖及“黑箱”特性仍是工业落地的关键挑战。实现从经验驱动向数据-物理混合驱动的范式转变,其与白箱化的可解释性增强技术和物理约束的协同将是未来突破方向。

2 物理约束的智能流场建模方法

近年来,智能流场预测方法逐渐从纯数据驱动转向与物理约束的融合范式,在提升预测精度的同时增强模型鲁棒性和数据效率,为复杂流体动力学问题提供了更可靠的解决方案。

2.1 强物理约束

物理信息神经网络^[55] (physics-informed neural networks, PINN) 作为一种新兴技术,已在流场建模领域引起了广泛关注。PINN 通过将流体动力学的基本物理定律融入神经网络的损失函数,显著增强了模型的物理一致性。

许多研究利用 PINN 针对经典的层流和湍流问题进行了稀疏数据条件下的流体动力学模拟^[10]。例如:Rao 等^[56]扩展 PINN 至低雷诺数下瞬态圆柱绕流的模拟,通过时间域离散化与空间域联合采样,捕捉流场随时间的演化特性,展示了 PINN 在层流模式下的精确建模能力,并证明了其与传统 CFD 结果的一致性。Hu 等^[57]以绕圆形和椭圆粒子的流动案例进一步扩展了 PINN 对不同二维几何的适应性。Mao 等^[58]基于 PINN 的框架求解高速空气动力学中的欧拉 (Euler) 方程 (见图 11),覆盖了一维接触间断、二维斜激波正向问题和密度梯度重构、参数辨识的逆问题。通过将欧拉方程及初/边值条件嵌入损失函数,仅需少量随机分布点即可捕捉激波位置,但正向问题精度仍低于传统数值方法。Ren 等^[59]将 PINN 扩展至可压缩定常流动的高雷诺数跨声速圆柱绕流场景,并对薄边界层域进行了采样及硬约束化改进,针对需

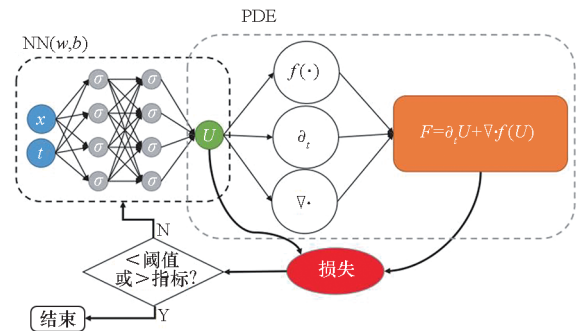


图 11 基于 PINN 的欧拉方程求解原理^[58]

Fig. 11 Schematic of PINN for the Euler equations^[58]

二阶导数的 RANS 方程与仅一阶导数的 Euler 方程设计梯度权重因子,分别构建了 PINN-RANS 与 PINN-Euler 方法。这些研究共同表明了 PINN 在不同流体流动形式下的强适应性和广泛应用潜力。

为了提升 PINN 对复杂几何的适应性,Kashefi 等^[60]提出使用基于点云的 PointNet 网络捕捉不规则计算区域的几何特征,克服了传统 PINN 无法将几何信息融入输出的限制,通过单次训练即可解决多组高差异性不规则几何的流动问题,并支持对未见几何的预测;其在后续研究^[61]中进一步结合 KAN (Kolmogorov-Arnold network) 提升了多孔介质问题在稀疏观测数据下的预测精度。Kang 等^[62]提出了一种结合物理信息驱动的 PointNet 与二次残差网络的集成算法,通过引入物理守恒原理约束神经网络训练,显著提升了血流动力学参数的预测精度,首次实现了从稀疏点云到四维血流动力学参数的直接映射。Peng 等^[63]提出将 GCN 与 PINN 结合,GCN 基于非结构化网格节点间的邻域关系建模热对流场,PINN 通过嵌入控制方程至损失函数强化物理约束。这一协同机制既保留了 GCN 对复杂几何的适应性,又通过物理规律提升预测精度、减少对数据的依赖。Shao 等^[64]基于 OpenFOAM 模拟提出 PIGNN-CFD 模型,通过物理信息图神经网络+非结构网格建模,解决了传统 CFD 计算效率低、数据驱动模型受限于规则网格的难题,程序流程如图 12 所示。

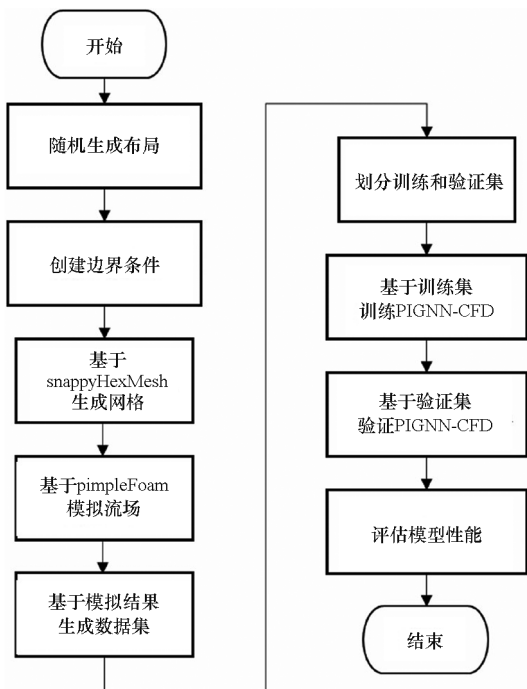


图 12 PIGNN-CFD 模型程序流程^[64]

Fig. 12 Flow chart corresponding to the program of the PIGNN-CFD^[64]

针对翼型,在采取像素化输入的 PINN 研究方面,Kan 等^[65]首次将交叉注意力机制与 PINN 结合,选择性地聚焦目标信息的关键维度,增强复杂流场特征的捕捉能力,确保预测结果符合物理规律,同时增强模型的可解释性;结合图像信息融合模块,从飞机几何图像中提取多尺度特征,与飞行状态参数融合,提升预测精度。Liu 等^[66]利用 CNN 从翼型图像中提取特征,将形状压缩为 6 个低维参数,显著降低设计空间维度;采用 PINN 模型替代 Xfoil,解决传统方法的不稳定性,提升气动预测的鲁棒性,基于近端策略优化的深度强化学习 (deep reinforcement learning, DRL) 框架,整合参数降维与性能评估模块,实现端到端优化。CNN-PINN-DRL 的深度融合,为高维气动优化问题提供了高效、稳定的智能解决方案,推动了数据-物理融合驱动设计范式在航空航天领域的应用。

但是对于飞行器的复杂翼型绕流问题,传统 PINN 面临难以捕捉翼型前缘附近的局部剧烈流动速度梯度突变且对壁面边界条件处理不稳定的挑战。研究者们多提出高效求解架构,采用端到端训练策略,直接输出流场分布,避免传统 CFD 的网格依赖性。Ang 等^[67]提出了一种基于 PINN 的翼型绕流场代理模型,用于预测不同攻角下的压力与速度分布,并通过物理约束优化模型精度。刘霞等^[68]把 PINN 与 CFD 仿真结果进行融合,在流场抽样点处的损失函数中增加偏差值,从而提高了神经网络的建模精度,并于 NACA0012 翼型上进行了测试。Harmening 等^[69]通过数据辅助训练与物理约束的深度融合,为翼型分离流动的高效预测提供了新范式,推动了 PINN 在复杂气动问题中的工程化应用。Cai 等^[70]通过不显式施加边界条件,仅通过数据驱动与方程残差联合优化,增强模型对不完整或噪声数据的鲁棒性,并在 NACA0012 翼型绕流 CFD 数据中进行了验证。Sarker^[71]提出多保真物理信息神经网络,整合低-高保真仿真数据,通过子网络分层建模多尺度物理特征,结合自动编码器进行流形对齐,消除多源数据间的模态差异,提升跨保真度预测的一致性,显著降低高保真飞行器流场计算需求。Huang 等^[72]提出了一种物理信息神经网络压缩机制,通过融合知识蒸馏与自适应剪枝技术,解决了深度学习模型在翼型流场预测中参数冗余与实时性不足的问题。

关于翼型的设计应用,Sun 等^[73]将翼型坐标和设计参数作为如图 13 所示 PINN 模型的输入,

通过自适应采样搭配点确保 Navier-Stokes 方程在全局搜索空间内近似满足,并利用 PINN 的自动微分特性计算升阻比关于形状参数的梯度,然后通过优化实现了高效气动设计。Wong 等^[74]提出了一种基于低可信度流场数据与物理残差融合的混合驱动模型,利用低可信度数据提供初始流场分布、物理残差优化细节特征,用于高雷诺数

($Re = 1.0 \times 10^6$) 下翼型的逆向设计。Cao 等将翼型形状参数与流动条件整合为高维输入,使单一模型覆盖工程中所有可能的无黏流场景^[75];通过坐标变换将物理空间流动问题映射到规则计算空间^[76],简化 PINN 对复杂几何的建模难度,提升训练稳定性,实现了多参数耦合场景下的高效流动预测与逆向设计。

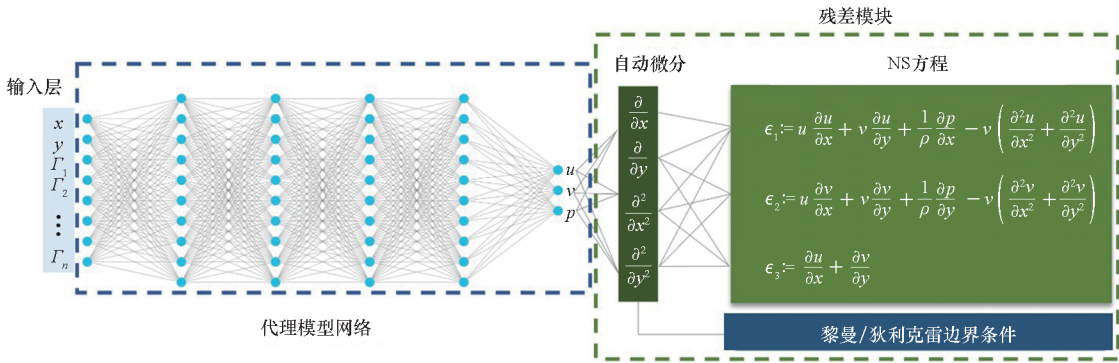


图 13 基于 PINN 的代理模型网络架构^[73]

Fig. 13 Network architecture used to construct a PINN-based surrogate model^[73]

尽管 PINN 在众多物理现象建模和应用中展现出潜力,但其训练过程仍面临显著挑战^[77],例如:不同损失项的梯度量级差异大,导致训练不稳定;自动微分 CFD 方程的高阶导数时,计算复杂度随维度指数增长;噪声与稀疏数据的敏感性;传统 PINN 通过损失函数软约束间接引导网络满足边界条件,但对于复杂几何形状、高阶边界条件、多物理场耦合场景难以严格保证满足。当前阶段的 PINN 在解决许多前向问题时,其精度和效率仍不及传统数值方法,短期内难以胜任 MDO 中高频次的流场分析任务。

2.2 弱物理约束

算子学习 (operator learning) 是深度学习在物理建模领域的新兴方向,其核心目标是学习无限维函数空间之间的映射关系,以替代传统数值方法求解偏微分方程^[78] (partial difference equation, PDE)。目前主流方法包括 DeepONet^[79] 和傅里叶神经算子^[80] (Fourier neural operator, FNO), Lu 等^[81] 在应用层面针对这两个神经算子进行了对比测试。其中,DeepONet 采用分支网络 (Branch Net) 编码输入函数,通过主干网络 (Trunk Net) 在任意坐标点生成输出函数值。其优势在于解空间查询的灵活性,但输入函数需在预定义网格上均匀采样,且训练与测试需保持相同观测网格,往往限制了其对不同几何的适应性。FNO 作为神经算子家族^[82] 的代表,通过快速傅里叶变换 (fast Fourier transform, FFT) 将输入映射至频域,利用

低维谱空间实现高效核积分。虽然 FNO 在均匀网格大数据场景下计算效率显著,但其频域操作导致无法处理不规则网格,且对几何拓扑变化敏感。

针对算子方法存在对新几何结构外推能力不足的问题, Li 等^[83] 提出一种基于 Transformer 的算子框架,通过自注意力捕捉输入函数内部的全局模式,并通过交叉注意力建模输入函数与任意查询位置之间的动态关系,无须预设网格结构或采样模式,适用于不规则或随机采样的输入。Hao 等^[84] 利用 Transformer 的大规模参数空间,首次实现对不规则网格和多输入函数的统一建模。Shih 等^[85] 首次从理论上建立了如图 14 所示以 Transformer 作为神经算子的通用逼近定理,证明了其能够近似无限维函数空间中任意连续的非线性偏微分方程解算子,为 Transformer 在 PDE 求解中的有效性提供了数学基础。论文通过理论证明和多个低正则性案例验证了 Transformer 的通用逼近性与精度优势。通过灵活编码初始条件、边界条件和外力项作为输入,Transformer 无须针对不同条件重新训练模型即可直接预测对应解。这种能力在传统数值方法和现有神经算子中难以实现,尤其适用于多场景工程问题。Boya 等^[86] 提出了物理信息 Transformer 神经算子 (physics-informed Transformer neural operator, PINTO), PINTO 采用完全基于物理损失残差的训练方式,摆脱了对大规模仿真或观测数据的依赖,相比传

统神经算子需要数据 + 物理损失的混合训练模式,这一创新显著降低了数据获取成本。通过引入基于交叉注意力的迭代核积分算子单元,将 PDE 解的域点动态映射与为初始/边界条件相关的表示向量。这种机制使模型能自适应不同边界条件,无须针对新条件重新训练,突破了现有方法需重复训练的瓶颈,并实现了在训练时间步之外的高精度预测。

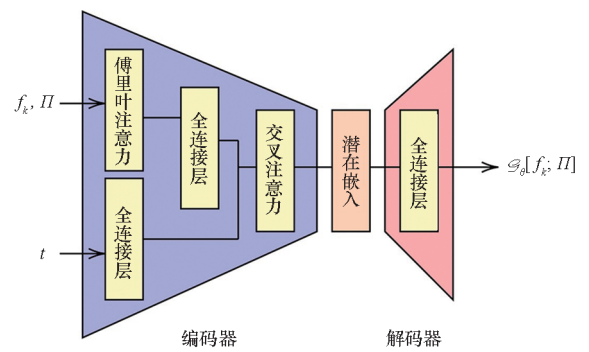


图 14 基于 Transformer 架构的算子逼近模型^[85]

Fig. 14 Transformer architecture to approximate the operator^[85]

在应用层面,对于复杂几何与通用性提升的算子学习研究工作已大量开展。Serrano 等^[87]利用基于坐标的输入突破传统神经算子对网格离散化的依赖,支持非凸域、多孔介质等任意几何形状的流场预测,给神经算子在实际工程中的几何适应性问题提供了解决方案。Shukla 等^[88]通过将翼型变形控制点参数输入分支网络,首次实现了以 DeepONet 作为高效代理模型的气动优化,与梯度优化算法的结合,验证了其在最大化升阻比任务中的鲁棒性;将 DeepONet 应用于高超声速乘波器气动热预测,模型在未知攻角下的热流分布预测精度与 CFD 相当,但计算速度提升千倍以上。Liu 等^[89]针对超临界翼型,提出如图 15 所示 DeepONet-MLP-VAE 复合架构,实现高效流场特征建模。在 VAE 中引入了物理约束,将几何参数

化输入 DeepONet-MLP,并采用自适应潜在空间优化策略平衡重构精度与模型泛化性,为气动外形优化提供了实时流场预测工具。He 等^[90]将 DeepONet 框架扩展至参数化三维几何的场预测任务,输入不仅包含几何的显式网格坐标,还通过符号距离函数(sign distance function, SDF)编码隐式形状拓扑。SDF 作为附加输入注入主干网络,增强了模型对复杂几何边界条件的捕捉能力,解决了传统方法在非结构化网格上的精度瓶颈。Park 等^[91]首次将点云处理框架 PointNet 集成到 DeepONet 中,直接处理非参数化三维几何点云,无须网格参数化或重训练。DoMINO 模型^[92]同样采用点云,但通过局部几何信息的动态融合捕捉多尺度流动现象。

参考 DeepONet 结构,Xiong 等^[93]提出双分支网络架构,将神经算子用于自由流条件的泛化建模,结合 CNN 从翼型图像提取几何特征,实现跨模态信息的高效融合。Li 等^[94]提出了由 ShapeNet 和 HyperNet 两个子网络组成的隐式解码器。其中 ShapeNet 基于隐式神经表示,将空间坐标映射到物理场,直接处理非结构化网格数据;HyperNet 则生成 ShapeNet 的权重参数,通过条件输入(攻角、马赫数)动态调整模型,支持多工况预测。

Deng 等^[95]提出了一种结合贴体网格变换与深度学习技术的非定常流场时序预测方法,通过融合 U-Net 与 FNO 的优势,实现了复杂流动场景下的高效高精度预测。Li 等^[96]提出了如图 16 所示几何变形与谱算子结合的 Geo-FNO 框架,通过可学习的变形网络将不规则物理域映射到潜在空间的均匀网格,这种物理域到潜在域的坐标变换既保留了 FFT 的计算效率,又支持复杂几何,避免了直接插值的信息损失。另外,此团队在文献[97-98]中分别研究了 Geo-FNO 潜在空间映射对非周期条件的兼容性,以及利用图结构处理

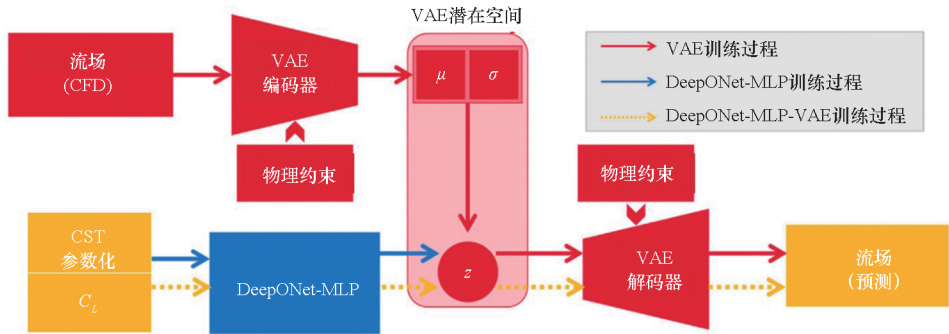


图 15 DeepONet-MLP-VAE 模型框架示意图^[89]

Fig. 15 Sketch of the DeepONet-MLP-VAE model framework^[89]

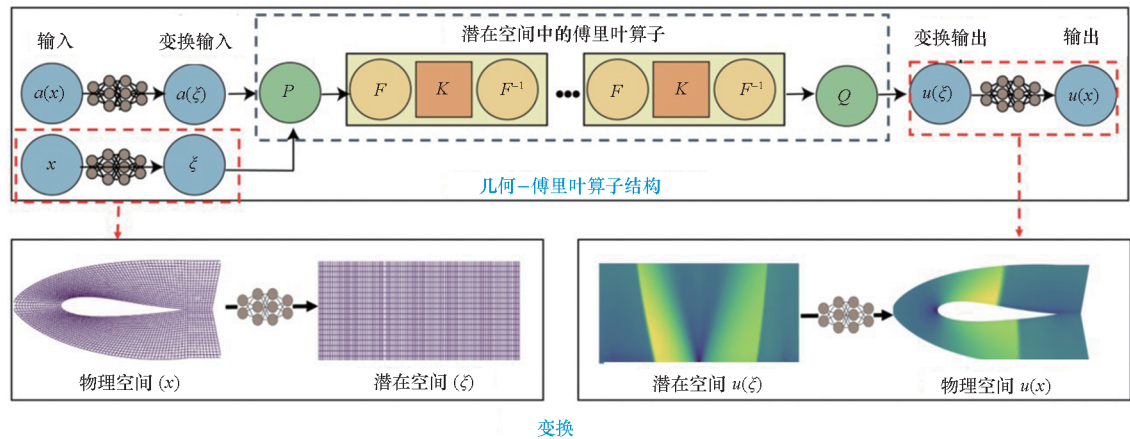


图 16 几何感知的傅里叶神经算子 (Geo-FNO): 一种具有几何形变的 FNO 框架^[96]

Fig. 16 Geometry-aware Fourier neural operator (Geo-FNO): a FNO framework with geometric deformation^[96]

输入后将其映射到潜在规则网格上应用 FNO 进行快速傅里叶变换的可行性。

Wu 等^[99]在变形基础上引入物理注意力机制的 Transolver 算子模型,通过将离散化的计算域自适应地划分为可学习的柔性形状切片,使相同物理状态的网格点归入同一切片,实现了几何自适应的物理建模。Sun 等^[100]首次将多模态学习引入 PDE 建模,可以同时训练多个一维非线性常系数 PDE 算子,并引入符号模态作为额外约束,解决了多算子联合训练中常见的不适定问题。模型不仅预测短期动态,还能通过物理特征的泛化实现时间外推。对于空气动力学形状设计而言,快速预测和设计工具是所期望的,算子学习能融合数据驱动模型已取得的显著性能,并突破输入维度限制,已成为流场预测领域的重要工具,未来有望进一步推动 CFD 的智能化革新。

在算子学习之外, Yang 等^[101]通过 VAE 模型,利用巡航条件下的流场作为先验信息,对非设计工况下的流场进行预测。该模型通过编码器提取翼型几何特征,并通过解码器生成新的流场图像,进而结合质量通量约束的损失函数来提高预测的精度和泛化能力。针对三维复杂构型, Wang 等^[102]提出将欧拉方程嵌入双系列残差神经网络,通过求解欧拉方程近似边界层外缘的物理特征,并将这些特征作为输入,实现了气动热建模的物理一致性。这一方法将无黏流场解析与数据驱动模型结合,克服了传统纯数据驱动模型忽略流动物理机制的缺陷。Michek 等^[103]使用 PINN 进行飞行动力学不确定性量化建模,有利于极端飞行条件下的系统辨识。Zhang 等^[104]提出物理信息机器学习框架,整合氢动力飞机的电、液、机械、化学多领域物理方程与数据驱动模型,突破传统

单一领域建模的局限性。然后基于 Xilinx[®] UltraScale⁺™ VCU128 FPGA 平台,开发并行硬件加速仿真架构,实现多域系统的实时数字孪生,提升仿真效率与工程适用性。“物理机理 + 硬件加速”的协同创新,为飞机复杂系统设计提供了高效建模与验证工具。

总之,物理约束建模有效缓解了传统数据驱动模型对大规模标注数据的依赖,并增强了对物理规律的遵循性,其对从分系统层面到总体集成层面的飞行器设计效益提升有显著的发展潜力。

3 总结与展望

智能流场预测在飞行器 MDO 中展现出巨大的应用潜力,通过高效的流场分析,该技术能够显著缩短设计迭代周期,提升整体设计效率。然而,当前的研究成果在适用范围上仍存在明显局限性,主要困难在于高保真数据获取、复杂边界几何特征表达以及鲁棒物理约束的构建。进一步提升模型的形状泛化能力、预测精度和不同物理场景中的适用性,是推动流场建模迈向实际应用的关键挑战。

1) 深度学习在高维数据处理和自动特征提取方面具有强大的学习能力,而主动学习在有效降低标注成本方面具有显著潜力。若结合深度学习和主动学习,将在样本质量层面高效提升智能模型的预测性能。尽管关于主动学习查询策略的研究相当丰富^[105-106],但直接将这种策略应用于深度学习仍然相当困难,核心在于动态样本选择机制与深度架构的协同创新。

2) 现有基于深度学习的流场预测模型在三维复杂外形与宽速域变工况场景中适应性不足。当前研究多聚焦于二维简化构型或固定飞行状态

下的流场建模,而高超声速飞行器真实三维外形具有非对称气动舵面、多曲率融合特征及跨速域甚至全速域气动/热力学特性突变等特点,现有模型在几何特征解耦表征与跨工况参数泛化机制上存在显著缺陷。物理约束的多模态数据融合、迁移学习增强的小样本泛化能力有望给予突破。

3) 多学科耦合建模的端到端框架尚未突破跨领域特征交互的技术瓶颈。现有智能预测模型多局限于单一学科,缺乏对多学科耦合作用的联合建模能力,原因在于无法通过隐式特征学习建立跨学科参数的全局关联映射,导致多学科协同优化效率低下。通过主动学习可以量化耦合敏感性,实现不确定性传播路径的显式建模,建立基于智能策略的 MDO 框架^[107],进而基于 MDO 架构构建高保真数字孪生体,支持飞行器的在线健康监测与控制^[108]。

综上,智能流场建模正从单一学科高精度仿真向多学科动态耦合演进,而数据驱动方法与物理约束的结合将成为突破计算复杂度壁垒的关键。当前研究需进一步解决跨尺度参数传递的保真度、智能算法的可解释性等核心问题。物理信息架构有望调和数据驱动预测与基本守恒定律的矛盾,从而提升新型气动构型的预测外推能力。持续突破这些技术瓶颈将加速智能流场预测与 MDO 工作流的深度集成,最终支持多物理约束下复杂设计空间的高效探索。

参考文献 (References)

- [1] MARTINS J R R A, LAMBE A B. Multidisciplinary design optimization: a survey of architectures[J]. AIAA Journal, 2013, 51(9): 2049–2075.
- [2] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84–90.
- [3] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770–778.
- [4] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139–144.
- [5] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st Conference on Neural Information Processing Systems, 2017.
- [6] SIMPSON T W, MARTINS J R R. The future of multidisciplinary design optimization (MDO): advancing the design of complex engineered systems[R/OL]. (2010–09–16) [2024–10–02]. https://www.academia.edu/643586/The_Future_of_Multidisciplinary_Design_Optimization_MDO_Advancing_the_Design_of_Complex_Engineered_Systems.
- [7] ALLISON J T, HERBER D R. Special section on multidisciplinary design optimization: multidisciplinary design optimization of dynamic engineering systems[J]. AIAA Journal, 2014, 52(4): 691–710.
- [8] SOBIESZCZANSKI-SOBIESKI J, MORRIS A, VAN TOOREN M. Multidisciplinary design optimization supported by knowledge based engineering[M]. Hoboken: Wiley, 2015.
- [9] SUN G, WANG S Y. A review of the artificial neural network surrogate modeling in aerodynamic design[J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2019, 233(16): 5863–5872.
- [10] FAROUGHI S A, PAWAR N, FERNANDES C, et al. Physics-guided, physics-informed, and physics-encoded neural networks in scientific computing[EB/OL]. (2022–11–14) [2024–10–10]. <https://arxiv.org/abs/2211.07377v2>.
- [11] 王泽, 宋述芳, 王旭, 等. 数据驱动的气动热建模预测方法总结与展望[J]. 气体物理, 2024, 9(4): 39–55.
WANG Z, SONG S F, WANG X, et al. Summary and prospect of data-driven aerothermal modeling prediction methods[J]. Physics of Gases, 2024, 9(4): 39–55. (in Chinese)
- [12] WANG H X, CAO Y D, HUANG Z J, et al. Recent advances on machine learning for computational fluid dynamics: a survey[EB/OL]. (2024–08–22) [2024–10–11]. <https://arxiv.org/abs/2408.12171v1>.
- [13] HAKEEM M F, FURQAN M, BATTOOL L, et al. Enhancing computational fluid dynamics simulations with machine learning: techniques, challenges, and future prospects[J]. Annual Methodological Archive Research Review, 2025, 3: 201–219.
- [14] LIU X G, YANG S Y, SUN H F, et al. Review of deep learning-based aerodynamic shape surrogate models and optimization for airfoils and blade profiles[J]. Physics of Fluids, 2025, 37(4): 041304.
- [15] WANG P, HU G Z, HU W L, et al. Deep learning-based rapid flow field reconstruction model with limited monitoring point information[J]. Aerospace, 2024, 11(11): 871.
- [16] ZHANG Y, SUNG W J, MAVRIS D N. Application of convolutional neural network to predict airfoil lift coefficient[C]//Proceedings of the 2018 AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference, 2018.
- [17] BHATNAGAR S, AFSHAR Y, PAN S W, et al. Prediction of aerodynamic flow fields using convolutional neural networks[J]. Computational Mechanics, 2019, 64(2): 525–545.
- [18] SEKAR V, JIANG Q H, SHU C, et al. Fast flow field prediction over airfoils using deep learning approach[J]. Physics of Fluids, 2019, 31(5): 057103.
- [19] SEKAR V, ZHANG M Q, SHU C, et al. Inverse design of airfoil using a deep convolutional neural network[J]. AIAA Journal, 2019, 57(3): 993–1003.
- [20] DURU C, ALEMDAR H, BARAN O U. A deep learning approach for the transonic flow field predictions around airfoils[J]. Computers & Fluids, 2022, 236: 105312.
- [21] FAN C L, WANG S S. Aerodynamic prediction of airfoil based on convolution neural network[C]//Proceedings of the International Conference on Electronic Information Technology

- (EIT 2022), 2022.
- [22] YANG H, YUAN W M, ZHU W J, et al. Wind turbine airfoil noise prediction using dedicated airfoil database and deep learning technology[J]. *Applied Energy*, 2024, 364: 123165.
- [23] HU J W, ZHANG W W. Flow field modeling of airfoil based on convolutional neural networks from transform domain perspective[J]. *Aerospace Science and Technology*, 2023, 136: 108198.
- [24] CATALANI G, COSTERO D, BAUERHEIM M, et al. A comparative study of learning techniques for the compressible aerodynamics over a transonic RAE2822 airfoil [J]. *Computers & Fluids*, 2023, 251: 105759.
- [25] RAFFEINER P, BERGER M, PILLEI M. Prediction of 2D aerodynamic flow fields on the example of a NACA0012 airfoil: a comparison of experimental data, CFD simulations and CNN predictions [C]//*Proceedings of the 3rd MCI Medical-, Health- and Sports Engineering Bachelor's Conference*, 2023.
- [26] ZHANG C, HU Z Y, SHI Y J, et al. Fast aerodynamic prediction of airfoil with trailing edge flap based on multi-task deep learning[J]. *Aerospace*, 2024, 11(5): 377.
- [27] HUI X Y, BAI J Q, WANG H, et al. Fast pressure distribution prediction of airfoils using deep learning[J]. *Aerospace Science and Technology*, 2020, 105: 105949.
- [28] THUEREY N, WEIBENOW K, PRANTL L, et al. Deep learning methods for Reynolds-averaged Navier-Stokes simulations of airfoil flows[J]. *AIAA Journal*, 2019, 58(1): 25–36.
- [29] CHEN L W, THUEREY N. Towards high-accuracy deep learning inference of compressible flows over aerofoils[J]. *Computers & Fluids*, 2023, 250: 105707.
- [30] HU J W, ZHANG W W. Mesh-Conv: convolution operator with mesh resolution independence for flow field modeling[J]. *Journal of Computational Physics*, 2022, 452: 110896.
- [31] WANG J, HE C, LI R Z, et al. Flow field prediction of supercritical airfoils via variational autoencoder based deep learning framework[J]. *Physics of Fluids*, 2021, 33(8): 086108.
- [32] LIU J Q, CHEN R Q, LOU J H, et al. Deep-learning-based aerodynamic shape optimization of rotor airfoils to suppress dynamic stall[J]. *Aerospace Science and Technology*, 2023, 133: 108089.
- [33] WANG Y Y, SHIMADA K, FARIMANI A B. Airfoil GAN: encoding and synthesizing airfoils for aerodynamic shape optimization[EB/OL]. (2021–01–12)[2024–10–15]. <https://arxiv.org/abs/2101.04757v2>.
- [34] WU M Y, YUAN X Y, CHEN Z H, et al. Airfoil shape optimization using genetic algorithm coupled deep neural networks[J]. *Physics of Fluids*, 2023, 35(8): 085140.
- [35] DENG Z W, WANG J, LIU H S, et al. Prediction of transonic flow over supercritical airfoils using geometric-encoding and deep-learning strategies[J]. *Physics of Fluids*, 2023, 35(7): 075146.
- [36] WANG X, QIAN W Q, ZHAO T, et al. Fast prediction of airfoil aerodynamic characteristics based on a combined autoencoder[J]. *Symmetry*, 2024, 16(7): 791.
- [37] KASHEFI A, REMPE D, GUIBAS L J. A point-cloud deep learning framework for prediction of fluid flow fields on irregular geometries[J]. *Physics of Fluids*, 2021, 33(2): 027104.
- [38] KASHEFI A, MUKERJI T. Point-cloud deep learning of porous media for permeability prediction [J]. *Physics of Fluids*, 2021, 33(9): 097109.
- [39] CHEN J, HACHEM E, VIQUERAT J. Graph neural networks for laminar flow prediction around random two-dimensional shapes[J]. *Physics of Fluids*, 2021, 33(12): 123607.
- [40] STRÖNISCH S, MEYER M, LEHMANN C. Flow field prediction on large variable sized 2D point clouds with graph convolution[C]//*Proceedings of the Platform for Advanced Scientific Computing Conference*, 2022: 1–10.
- [41] LAN X Y, WANG L Y, WANG C, et al. Prediction of transonic flow over cascades via graph embedding methods on large-scale point clouds [J]. *Aerospace*, 2023, 10(12): 1029.
- [42] XIE H R, HUA Y, LI Y B, et al. Estimation of sequential transient flow around cylinders using recurrent neural network coupled graph convolutional network[J]. *Ocean Engineering*, 2024, 293: 116684.
- [43] LI T, GUO L, YANG Z G, et al. An automatic shape-aware method for predicting heat flux of supersonic aircraft based on a deep learning approach [J]. *Physics of Fluids*, 2022, 34(7): 077103.
- [44] SABATER C, STÜRMER P, BEKEMEYER P. Fast predictions of aircraft aerodynamics using deep-learning techniques[J]. *AIAA Journal*, 2022, 60(9): 5249–5261.
- [45] XIONG F F, ZHANG L, HU X, et al. A point cloud deep neural network metamodel method for aerodynamic prediction[J]. *Chinese Journal of Aeronautics*, 2023, 36(4): 92–103.
- [46] SHEN Y, HUANG W, WANG Z G, et al. A deep learning framework for aerodynamic pressure prediction on general three-dimensional configurations [J]. *Physics of Fluids*, 2023, 35(10): 107111.
- [47] SHEN Y, ZHANG H, HUANG W, et al. Geometric-perspective transfer learning for fast aerodynamic prediction in few-shot tasks[J]. *Physical Review Fluids*, 2024, 9(10): 104101.
- [48] ZHANG H, SHEN Y, HUANG W, et al. Deep transfer learning for three-dimensional aerodynamic pressure prediction under data scarcity[J]. *Theoretical and Applied Mechanics Letters*, 2025, 15(2): 100571.
- [49] SHEN Y, HUANG W, WANG Z G. Achieving generalized three-dimensional flow field prediction for high-speed flight vehicles using an attention-inspired architecture [J]. *Computers & Fluids*, 2025, 299: 106726.
- [50] MASSEGUR D, DA RONCH A. Graph convolutional multi-mesh autoencoder for steady transonic aircraft aerodynamics[J]. *Machine Learning: Science and Technology*, 2024, 5(2): 025006.
- [51] HINES D, BEKEMEYER P. Graph neural networks for the prediction of aircraft surface pressure distributions [J]. *Aerospace Science and Technology*, 2023, 137: 108268.
- [52] ZHANG X Y, SUN G P, ZHANG P, et al. A residual graph convolutional network for setting initial flow field in computational fluid dynamics simulations [J]. *Physics of Fluids*, 2024, 36(3): 037150.
- [53] SUN X X, LIU Y L, ZHANG W W, et al. Development and

- deployment of data-driven turbulence model for three-dimensional complex configurations[J]. Machine Learning: Science and Technology, 2024, 5(3): 035085.
- [54] ZHANG S G, WU C Y, ZHANG Y F. Numerical simulation of three-dimensional high-lift configurations using data-driven turbulence model[EB/OL]. (2025-03-19) [2025-03-22]. <https://arxiv.org/abs/2503.14859v1>.
- [55] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics informed deep learning (part I): data-driven solutions of nonlinear partial differential equations[EB/OL]. (2017-11-28) [2025-03-22]. <https://arxiv.org/abs/1711.10561v1>.
- [56] RAO C P, SUN H, LIU Y. Physics-informed deep learning for incompressible laminar flows[J]. Theoretical and Applied Mechanics Letters, 2020, 10(3): 207-212.
- [57] HU B C, MCDANIEL D. Applying physics-informed neural networks to solve Navier-Stokes equations for laminar flow around a particle[J]. Mathematical and Computational Applications, 2023, 28(5): 102.
- [58] MAO Z P, JAGTAP A D, KARNIADAKIS G E. Physics-informed neural networks for high-speed flows[J]. Computer Methods in Applied Mechanics and Engineering, 2020, 360: 112789.
- [59] REN X, HU P, SU H, et al. Physics-informed neural networks for transonic flow around a cylinder with high Reynolds number[J]. Physics of Fluids, 2024, 36(3): 036129.
- [60] KASHEFI A, MUKERJI T. Physics-informed PointNet: a deep learning solver for steady-state incompressible flows and thermal fields on multiple sets of irregular geometries[J]. Journal of Computational Physics, 2022, 468: 111510.
- [61] KASHEFI A, MUKERJI T. Prediction of fluid flow in porous media by sparse observations and physics-informed PointNet[J]. Neural Networks, 2023, 167: 80-91.
- [62] KANG J H, LI G Y, CHE Y, et al. Four-dimensional hemodynamic prediction of abdominal aortic aneurysms following endovascular aneurysm repair combining physics-informed PointNet and quadratic residual networks[J]. Physics of Fluids, 2024, 36(8): 081904.
- [63] PENG J Z, HUA Y, LI Y B, et al. Physics-informed graph convolutional neural network for modeling fluid flow and heat convection[J]. Physics of Fluids, 2023, 35(8): 087117.
- [64] SHAO X Q, LIU Z J, ZHANG S Q, et al. PIGNN-CFD: a physics-informed graph neural network for rapid predicting urban wind field defined on unstructured mesh[J]. Building and Environment, 2023, 232: 110056.
- [65] KAN Y D, LIU X D, LIU H K. An image and state information-based PINN with attention mechanisms for the rapid prediction of aircraft aerodynamic characteristics[J]. Aerospace, 2025, 12(5): 434.
- [66] LIU Y Y, SHEN J X, YANG P P, et al. A CNN-PINN-DRL driven method for shape optimization of airfoils[J]. Engineering Applications of Computational Fluid Mechanics, 2025, 19(1): 2445144.
- [67] ANG E, NG B F. Physics-informed neural networks for flow around airfoil[C]//Proceedings of the AIAA SciTech 2022 Forum, 2022: 0187.
- [68] 刘霞, 冯文晖, 连峰, 等. 基于物理信息神经网络的气动数据融合方法[J]. 空气动力学学报, 2023, 41(8): 87-96.
- LIU X, FENG W H, LIAN F, et al. Aerodynamic data fusion method based on physics-informed neural network[J]. Acta Aerodynamica Sinica, 2023, 41(8): 87-96. (in Chinese)
- [69] HARMENING J H, PIOCH F, FUHRIG L, et al. Data-assisted training of a physics-informed neural network to predict the separated Reynolds-averaged turbulent flowfield around an airfoil under variable angles of attack[J]. Neural Computing and Applications, 2024, 36(25): 15353-15371.
- [70] CAI Z M, LIN X Q, LIU T S, et al. Determining pressure from velocity via physics-informed neural network[J]. European Journal of Mechanics-B/Fluids, 2025, 109: 1-21.
- [71] SARKER A. Efficient aircraft design optimization using multi-fidelity models and multi-fidelity physics informed neural networks[EB/OL]. (2024-12-24) [2025-03-15]. <https://arxiv.org/abs/2412.18564v1>.
- [72] HUANG H Y, YE Y Y, et al. Physics-informed neural network compression mechanism for airfoil flow field prediction[J]. Physics of Fluids, 2025, 37(3): 036115.
- [73] SUN Y B, SENGUPTA U, JUNIPER M. Physics-informed deep learning for simultaneous surrogate modeling and PDE-constrained optimization of an airfoil geometry[J]. Computer Methods in Applied Mechanics and Engineering, 2023, 411: 116042.
- [74] WONG B Y J, DAMODARAN M, KHOO B C. Physics-informed machine learning using low-fidelity flowfields for inverse airfoil shape design[J]. AIAA Journal, 2024, 62(8): 2846-2861.
- [75] CAO W B, SONG J H, ZHANG W W. Solving high-dimensional parametric engineering problems for inviscid flow around airfoils based on physics-informed neural networks[J]. Journal of Computational Physics, 2024, 516: 113285.
- [76] CAO W B, SONG J H, ZHANG W W. A solver for subsonic flow around airfoils based on physics-informed neural networks and mesh transformation[J]. Physics of Fluids, 2024, 36(2): 027134.
- [77] CAI S Z, MAO Z P, WANG Z C, et al. Physics-informed neural networks (PINNs) for fluid mechanics: a review[J]. Acta Mechanica Sinica, 2021, 37(12): 1727-1738.
- [78] AZIZZADENESHELI K, KOVACHKI N, LI Z Y, et al. Neural operators for accelerating scientific simulations and design[J]. Nature Reviews Physics, 2024, 6(5): 320-328.
- [79] LU L, JIN P Z, KARNIADAKIS G E. DeepONet: learning nonlinear operators for identifying differential equations based on the universal approximation theorem of operators[EB/OL]. (2019-10-08) [2025-03-10]. <https://arxiv.org/abs/1910.03193v3>.
- [80] LI Z Y, KOVACHKI N, AZIZZADENESHELI K, et al. Fourier neural operator for parametric partial differential equations[EB/OL]. (2020-10-18) [2025-03-10]. <https://arxiv.org/abs/2010.08895v3>.
- [81] LU L, MENG X H, CAI S Z, et al. A comprehensive and fair comparison of two neural operators (with practical extensions) based on FAIR data[J]. Computer Methods in Applied Mechanics and Engineering, 2022, 393: 114778.
- [82] KOVACHKI N, LI Z Y, LIU B, et al. Neural operator: learning maps between function spaces with applications to PDEs[J]. Journal of Machine Learning Research, 2023,

24(89): 1–97.

[83] LI Z J, MEIDANI K, FARIMANI A B. Transformer for partial differential equations’ operator learning [EB/OL]. (2022–05–26) [2025–03–10]. <https://arxiv.org/abs/2205.13671v3>.

[84] HAO Z K, WANG Z Y, SU H, et al. Gnot: a general neural operator transformer for operator learning[C]//Proceedings of the 40th International Conference on Machine Learning, 2023.

[85] SHIH B, PEYVAN A, ZHANG Z Q, et al. Transformers as neural operators for solutions of differential equations with finite regularity[J]. Computer Methods in Applied Mechanics and Engineering, 2025, 434: 117560.

[86] BOYA S K, SUBRAMANI D. A physics-informed transformer neural operator for learning generalized solutions of initial boundary value problems[EB/OL]. (2024–12–12) [2025–03–10]. <https://arxiv.org/abs/2412.09009v4>.

[87] SERRANO L, BOUDECE L L, KOUPAI A K, et al. Operator learning with neural fields: tackling PDEs on general geometries [C]//Proceedings of the 37th Conference on Neural Information Processing Systems, 2023.

[88] SHUKLA K, OOMMEN V, PEYVAN A, et al. Deep neural operators as accurate surrogates for shape optimization[J]. Engineering Applications of Artificial Intelligence, 2024, 129: 107615.

[89] LIU M X, YANG Y J, WU C Y, et al. A fast prediction model of supercritical airfoils based on deep operator network and variational autoencoder considering physical constraints[J]. Aerospace Research Communications, 2024, 2: 13901.

[90] HE J Y, KORIC S, ABUEIDDA D, et al. Geom-DeepONet: a point-cloud-based deep operator network for field predictions on 3D parameterized geometries[J]. Computer Methods in Applied Mechanics and Engineering, 2024, 429: 117130.

[91] PARK J, KANG N. Point-DeepONet: a deep operator network integrating PointNet for nonlinear analysis of non-parametric 3D geometries and load conditions [EB/OL]. (2024–12–24) [2025–03–10]. <https://arxiv.org/abs/2412.18362v1>.

[92] RANADE R, NABIAN M A, TANGSALI K, et al. DoMINO: a decomposable multi-scale iterative neural operator for modeling large scale engineering simulations [EB/OL]. (2025–01–23) [2025–03–10]. <https://arxiv.org/abs/2501.13350v1>.

[93] XIONG H L, LI Y B, WU A P, et al. Multimodal flow field prediction method fusing operator learning and convolutional neural network [J]. Physics of Fluids, 2024, 36 (12): 127110.

[94] LI R Z, ZHANG Y F, CHEN H X. Mesh-agnostic decoders for supercritical airfoil prediction and inverse design [J]. AIAA Journal, 2024, 62(6): 2144–2160.

[95] DENG Z W, LIU H S, SHI B J, et al. Temporal predictions of periodic flows using a mesh transformation and deep learning-based strategy [J]. Aerospace Science and Technology, 2023, 134: 108081.

[96] LI Z Y, HUANG D Z, LIU B, et al. Fourier neural operator with learned deformations for PDEs on general geometries [EB/OL]. (2024–03–02) [2025–03–10]. <https://arxiv.org/abs/2207.05209v2>.

[97] LIU Z Y, WU Y H, HUANG D Z, et al. SPFNO: spectral operator learning for PDEs with Dirichlet and Neumann boundary conditions [EB/OL]. (2023–12–12) [2025–03–10]. <https://arxiv.org/abs/2312.06980v1>.

[98] LI Z Y, KOVACHKI N B, CHOY C, et al. Geometry-informed neural operator for large-scale 3D PDEs [EB/OL]. (2023–09–01) [2025–03–10]. <https://arxiv.org/abs/2309.00583v1>.

[99] WU H X, LUO H K, WANG H W, et al. Transolver: a fast transformer solver for PDEs on general geometries [EB/OL]. (2024–02–04) [2025–03–10]. <https://arxiv.org/abs/2402.02366v2>.

[100] SUN J M, LIU Y X, ZHANG Z C, et al. Towards a foundation model for partial differential equations: multioperator learning and extrapolation [J]. Physical Review E, 2025, 111(3): 035304.

[101] YANG Y J, LI R Z, ZHANG Y F, et al. Flowfield prediction of airfoil off-design conditions based on a modified variational autoencoder[J]. AIAA Journal, 2022, 60(10): 5805–5820.

[102] WANG Z, WANG X, ZHANG W W, et al. ED-ResNet: Euler equation embedding double-series residual neural network for aerothermal modeling[J]. AIAA Journal, 2024, 63(1): 134–147.

[103] MICHEK N, MEHTA P, HUEBSCH W. Flight dynamic uncertainty quantification modeling using physics-informed neural networks [C]//Proceedings of the AIAA SciTech 2024 Forum, 2024: 0575.

[104] ZHANG S Y, DINAHAHI V, LIANG T. Towards hydrogen-powered electric aircraft: physics-informed machine learning based multi-domain modeling and real-time digital twin emulation on FPGA[J]. Energy, 2025, 322: 135451.

[105] LUGHOFFER E. On-line active learning: a new paradigm to improve practical usability of data stream modeling methods[J]. Information Sciences, 2017, 415/416: 356–376.

[106] REN F, HU H B, TANG H. Active flow control using machine learning: a brief review [J]. Journal of Hydrodynamics, 2020, 32(2): 247–253.

[107] WANG C, FAN H R, QIANG X. A review of uncertainty-based multidisciplinary design optimization methods based on intelligent strategies[J]. Symmetry, 2023, 15(10): 1875.

[108] SMITH L J, HALIM L J, KENNEDY G, et al. A high-fidelity coupling framework for aerothermoelastic analysis and adjoint-based gradient evaluation [C]//Proceedings of the AIAA SciTech 2021 Forum, 2021: 0407.