

生成式AI技术在航空发动机领域中的应用研究

尚 勇¹, 王 宇²

(1. 中国航空发动机研究院, 北京 101300; 2. 北京灵易数智科技有限公司, 北京 100083)

摘 要: 生成式人工智能(AI)技术在能源、电子等工业领域的应用,促进了其在复杂工程领域的研究进展。在航空发动机领域,生成式AI技术的应用主要集中在方案设计与仿真分析阶段,显著提升了设计与仿真的效率。通过整合先验设计模型库、智能融合生成算法以及基于AI的物理性能快速预测技术,实现了创成设计,并输出了满足既定设计指标的设计方案,为航空发动机设计提供了新的研究范式。详细阐述了生成式AI技术在航空发动机设计仿真领域的实际应用;探讨了生成式AI技术在工程化应用中所面临的泛模型化、小样本学习和模态失衡等问题,以及相应的解决思路和方法;展望了生成式AI技术未来可能的发展趋势。所提出的思路和方法可为航空发动机智能化转型提供支撑。

关键词: 生成式AI技术;航空发动机;设计仿真;生成预测;深度学习

中图分类号: V249.12 **文献标识码:** A **文章编号:** 1672-2620(2026)01-0054-11

DOI: 10.3724/j.GTER.20250087

Review on the application of generative AI technology in the field of aero-engines

SHANG Yong¹, WANG Yu²

(1. The Aero Engine Academy of China, Beijing 101300, China;

2. Beijing SmartBooks Tech Co., Ltd., Beijing 100083, China)

Abstract: Generative artificial intelligence (AI) technology has driven research progress in complex engineering fields through its applications in industries such as energy and electronics. In the field of aero-engines, the application of generative AI mainly focuses on the scheme design and simulation analysis, significantly improving the efficiency of both design and simulation. By integrating prior design model libraries, intelligent fusion generation algorithms, and AI-based rapid prediction of physical performance, generative design has been achieved to output design solutions that meet predetermined performance indicators, providing a new research paradigm for the design of aero-engines. The practical applications of generative AI technology in the design and simulation of aero-engines were elaborated. The challenges faced in applying generative AI technology to aero-engines development were discussed, including model generalization, small-sample learning, and modal imbalance, along with corresponding solutions and methods. Furthermore, potential future trends in generative AI technology were explored. The ideas and methods were proposed to support the intelligent transformation of aero-engines design.

Key words: generative AI technology; aero-engine; design simulation; generative prediction; deep learning

收稿日期: 2025-11-08

基金项目: 国家自然科学基金(U2241249)

作者简介: 尚 勇(1972-),男,辽宁海城人,高级工程师,硕士,研究方向为数字化材料与装备。

引用格式: 尚 勇,王 宇. 生成式AI技术在航空发动机领域中的应用研究[J]. 燃气涡轮试验与研究, 2026, 39(1): 54-64. SHANG Yong, WANG Yu.

Review on the application of generative AI technology in the field of aero-engines[J]. Gas Turbine Experiment and Research, 2026, 39(1): 54-64.

0 引言

随着大数据和人工智能(AI)技术的快速发展,生成式AI技术^[1-3]也获得显著突破,为AI技术在工业领域的应用提供了新的契机。在航空发动机这一复杂且关键的工业领域,生成式AI技术的引入不仅有望简化设计流程、提升设计效率,更可能带来航空发动机物理性能的飞跃。依托深度学习等先进技术,生成式AI技术能够模拟并优化航空发动机的各种设计参数,从而在保障安全性的前提下,探索更高效的能源转换路径。此外,生成式AI技术的预测能力也为发动机的维护与健康健康管理提供了新的视角,有助于提前识别潜在故障、延长使用寿命、降低运营成本。因此,探索生成式AI技术在航空发动机领域的应用,不仅是技术进步的必然趋势,也是推动航空发动机工业领域智能化转型的关键。

生成式AI技术的起源可追溯至20世纪50年代,其早期代表技术包括隐马尔可夫模型^[4]和高斯混合模型^[5]。这些模型主要应用于生成语音和时间等序列数据,但生成效果并不理想。随着深度学习技术的发展,当前的生成式AI技术不仅能高效地生成语音和时间序列数据,还能生成图像、有限元场数据和几何模型。这赋予了生成式AI技术在航空发动机工程化应用中的潜力。特别是,结合设计仿真应用,生成式AI技术能够实现对不同物理场指标性能的快速计算和预测;同时,结合产品设计经验,生成式AI技术还能够辅助工程师快速完成部件的生成设计和性能计算,显著提升分析和设计的效率,避免重复性劳动。生成式AI技术的这些优势对于增强航空发动机的仿真计算和设计应用能力至关重要。当前,生成式AI技术在航空发动机设计与仿真领域的研究重点包括:利用自由形变层-生成对抗网络(FFD-GAN)^[6]生成满足结构强度要求的涡轮叶片等关键部件的3D模型——这些模型可直接应用于部件的几何设计;基于物理信息神经网络(PINN)^[7]或改进的变分自编码器(VAE)^[8]架构,预测高分辨率流场分布,并通过卷积-反卷积或注意力机制预测燃烧室出口温度分布;通过基于概率机器学习的逆向生成(PMI)框架^[9],直接根据目标性能生成多组涡轮机械部件设计参数——这些参数可进一步应用于更广泛的分析场景。

本文首先对航空发动机领域中生成式AI技术应用的相关文献进行了系统分析与总结;接着对生成

式AI技术的理论基础及其架构进行了综合研讨与评述;随后重点阐述并深入探讨了生成式AI技术在航空发动机设计仿真领域的实际应用;最后讨论了生成式AI技术在工程化应用过程中面临的挑战以及相应的解决方案,并对生成式AI技术未来可能的发展趋势进行了展望。

1 生成式AI技术的背景及发展

1.1 传统AI技术与生成式AI技术

传统AI技术^[10-11]基于预设规则对数据进行分析,并输出相应的决策结果。此类技术在特定应用场景及目标明确的任务中,能够通过预先设计的程序从结构化数据中提取相关模式,从而提高数据分析和自动化处理的效率。其主要应用于分类、回归、目标检测等任务。尽管传统AI技术在自动分析现有数据和结构化任务中表现出较高的准确性和可靠性,但其在处理模糊信息和创造性决策方面仍相对不足^[12]。然而,生成式AI技术的兴起填补了这一领域的空白。该技术采用深度学习和神经网络技术,结合概率方法,能够根据输入的提示生成真实且语境相符的文本、图像、视频、3D形状、代码等。与适用于固定框架的传统AI技术不同,生成式AI技术通过自监督机制不断进行自我优化和学习,并能够处理多模态的非结构化信息。该技术在航空发动机部件结构的3D生成和设计参数生成方面具有重要应用价值,能够为航空发动机的智能设计和性能优化提供有力支持。

1.2 生成式AI技术的发展与应用

在生成式AI技术的早期发展阶段,不同领域之间相对独立,交叉重叠现象较少。在自然语言处理领域,传统的句子生成方法主要依赖于人工设定的语法规则,或者采用N-gram算法^[13]来学习单词的分布,并据此选择最优的序列组合,然而这一文本生成方式在生成复杂长句方面存在一定的局限性。循环神经网络^[14]及其变体(包括长短时记忆网络^[15]和门控循环单元^[16])通过引入门控机制,实现记忆与遗忘的功能,可有效捕捉序列数据中的长距离依赖关系,显著推动了语言模型的发展。在计算机视觉领域,传统的图像生成算法主要依赖于手工设定的特征进行纹理合成,其在生成多样化和复杂图像方面同样存在局限。随着VAE和生成对抗网络(GANs)^[17]的提出,图像生成质量得到了明显提升。

随后,流模型(Flow)^[18]和扩散模型^[19]等方法能够更精细地控制图像生成过程,进一步提升了高质量图像的生成能力。随着深度学习技术的不断进步,一种具有划时代意义的架构——Transformer架构^[1]被提出。该架构完全基于自注意力机制构建,具有极高的并行化处理能力,显著提升了生成性能。

当前,生成式AI技术正从单一领域的突破转向智能系统的集成应用,在更多领域(如工业设计、视频生成等)展现出应用潜力。Transformer架构逐渐成为多个生成模型的核心网络,标志着生成模型的发展达到了一个新的交汇点。该架构在处理海量数据和实现知识融合方面具有独特优势,不仅显著提高了生成内容的质量,还促进了不同领域之间的交叉融合,实现了多模态内容的生成。例如,在图像与文本生成对应3D网格模型的应用中,该技术能够显著降低设计者的门槛,并提供多种初始设计方案^[20]。综上所述,生成式AI技术正朝着模态融合、系统协同、场景深耕的新阶段迈进。

2 生成式AI技术框架

2.1 输入表示

生成式AI技术构筑于概率建模与表示学习的基础之上,其核心在于对输入数据潜在分布的建模,并通过学习近似分布来实现数据的采样与生成。不同的输入数据表示策略对生成结果的质量具有显著影响。以3D生成领域为例,点云、体素、网格、隐式表示等不同方法^[21-23]对原始3D形状特征的描述各有侧重,导致生成结果在全局结构与局部细节上表现出显著差异。此外,针对不同的生成模型,输入数据的处理方式亦需相应调整。例如,自回归生成模型要求将数据划分为具有先后顺序的序列块。

2.2 潜在空间压缩表示

在工业设计领域,无论是直接构建3D模型还是生成设计参数,所涉及的均为高维数据集。为提升生成模型的训练效率,通常需要压缩输入层数据以实现紧凑的表征。目前,主流的技术手段是利用VAE,将高维数据 X 通过编码器映射至潜在变量 Z 的分布,进而将其转换至维度较低的潜在空间。这一过程不仅保留了原始数据的特征信息,而且还能够使潜在变量 Z 学习到原始数据的抽象语义维度。此外,潜在空间亦可作为不同模态数据的统一表征平台,以支持多模态数据的对齐与跨模态数据

的生成任务。

2.3 生成网络与解码

生成网络在构建多样化且语境适宜的样本生成方面发挥着关键作用。当前,扩散模型与自回归模型^[24]是该领域的两大主流技术。

扩散模型采用两阶段的扩散机制来学习潜在变量的分布特性。在正向扩散阶段,模型逐步向潜在变量中注入噪声,直至其分布转变为纯噪声分布;在反向扩散阶段,模型则从纯噪声状态出发,通过神经网络逐步预测并去除噪声,直至恢复出真实数据的分布。完成噪声网络训练后,通过随机采样1个高斯噪声,并通过多次噪声预测迭代,将其还原为潜在变量,最终利用解码器将潜在变量转换为原始输入数据。解码器的作用与编码器相对,其目的在于将潜在变量映射回原始数据。

自回归模型则将潜在变量划分为一系列有序的序列块,并通过将潜在变量的联合分布转化为学习序列间条件依赖关系的分布,实现逐块预测后续序列块的目标。模型训练完成后,从1个随机采样的起始序列开始,逐个预测序列块,直至生成目标潜在变量序列,并最终借助解码器将其转换为原始数据。

2.4 损失函数

在工业智能设计领域,对生成样本的性能指标与工艺参数等物理约束的考量不可或缺。这些约束条件可被整合至生成过程中,以引导生成模型产生符合特定条件的输出结果。在这一过程中,损失函数能够指导模型修正方向。具体而言,在扩散模型中,条件向量 C 与潜在变量 Z 的融合被用来表达两者之间的相关性;而在自回归生成模型中,条件向量 C 作为核心上下文输入,其引入方式主要包括:①将条件向量直接拼接至生成序列的起始端,作为引导信号;②先将条件向量编码为嵌入向量,再与Transformer的位置编码相加,进而将条件控制信息融入到每一层的注意力计算中,实现对序列生成过程的有效指导。

2.5 设计优化流程

生成模型的输出结果通常无法达到最优解。因此,进一步的优化过程是通过建立映射设计、工程性能与低维潜在空间之间的关系来实现。该过程融合了生成模型与预测模型的协同作用。生成模型负责根据潜在空间的样本值生成新的设计方案,而预测模型旨在降低真实流场实验测试性能指标的成本,

通过神经网络实现从输入到性能指标的映射。目前存在迭代优化和生成优化2种主要的优化方法,如图1所示。迭代优化^[25]将生成模型与预测模型串联起来,利用传统优化算法(迭代器)寻找与目标性能差异最小的潜在变量,并将其输入生成模型以获得最优设计方案。生成优化^[26]将预测模型作为物理约束条件,这些条件在生成器的训练过程中得到应用,无需单独的迭代过程,只需输入性能指标即可直接获得最优设计方案。

3 生成式AI技术在航空发动机设计仿真领域的应用

3.1 结构强度设计仿真

在航空发动机设计流程中,结构强度设计仿真对于确保其安全性和可靠性至关重要。该过程涵盖了模型构建、载荷映射、材料本构关系以及分析评估等多个关键环节。近年来,生成式AI技术为航空发动机零部件结构强度设计领域带来了创新动力,有效克服了传统迭代搜索方法效率低下和周期冗长的问题,为结构设计提供了重要的参考依据。

CHEN和RAMAMURTHY^[6]提出了一种创新的生成模型——FFD-GAN。该模型结合了自由形变层(FFD)与GAN,能够直接根据设计参数生成满足结构强度要求的涡轮叶片等部件的3D模型,如图2所示。图中, l, m, n 分别代表控制点网格在三维空间维度上的分辨率; M, N 分别代表参数化曲面维度上的分辨率。通过GAN的对抗博弈机制,该模型将叶

片的高维设计参数空间压缩至低维潜在空间,并从输入数据的复杂分布中学习到有用的紧凑表示。该模型以最少的设计变量覆盖了足够的设计空间,并排除了无用的设计参数,显著提高了设计空间的探索效率。为确保生成的3D模型具有光滑连续的表面,研发人员创新性地引入了自由形变层作为解码器,从潜在表示中恢复3D表面点,与真实表面点一同作为判别器的输入,实现了端到端的流程。通过机翼设计实例,验证了FFD-GAN模型在紧凑表示效果和设计空间覆盖效果方面的有效性。与传统的FFD和B样条曲面参数化方法相比,FFD-GAN模型在实现几何形状紧凑表示的同时,还能够覆盖设计空间,确保结构形状达到最优的理论上限。其压缩的潜在空间使得每个维度对应特定的属性(如机翼的扭转和上反角),为部件设计空间的解构提供了明确方向。

3.2 叶轮机械气动设计仿真

在航空发动机研发过程中,叶轮机械的气动设计仿真同样重要,其主要功能在于对压气机和涡轮等关键部件进行气动设计和性能评估。生成式AI技术能够通过多层次结构自动提取多尺度特征,对描述激波、涡流以及非定常流动等复杂现象具有显著优势,且已在航空发动机叶轮流体性能预测领域展现出其应用价值。目前,研究人员正致力于利用PINN以及改进的VAE架构,实现对全流场数据分布的高分辨率生成预测。

EIVAZI等^[27]在缺乏高分辨率参考数据的情况




图1 生成式AI技术设计优化流程

Fig.1 Generative AI technology design optimization process

下,运用PINN从1组有限的噪声测量数据中提取了时间和空间上的超分辨率流场信息。通过伯格方程、圆柱后的二维涡脱落以及最小湍流通道流动3个典型案例,验证了PINN在时间和空间上的超分辨率数据的适用性。该研究以粗糙湍流边界层中的平均应力和雷诺应力测量值数据集为例,采用无黏性项的二维雷诺平均方程构建无监督损失函数,并与网

络预测数据及已知参考值进行对比,以获得监督损失。将无监督损失与监督损失相结合,形成总损失函数,进而指导网络进行迭代训练,如图3所示。图中, x, y 代表二维流动平面的空间坐标; V, U 分别代表雷诺平均后的 x, y 方向的速度分量; p 代表雷诺平均后的压力; $\overline{u^2}, \overline{v^2}$ 分别代表 x, y 方向的雷诺应力; $\overline{uv}$ 代表剪切雷诺应力; I 为单位矩阵。




图2 自由形变层-对抗神经网络模型

Fig.2 FFD-GAN model




图3 物理信息神经网络应用方法示意图

Fig.3 Schematic diagram of PINN application method

刘恭言^[28]提出了一种名为AEpre的新型神经网络架构(图4)。AEpre架构专为航空发动机部件的流程预测设计,可高效且精确地预测全3D和准3D流程,且已在大涵道比涡扇发动机关键部件及核心机的性能预测场景中得到验证。该架构结合了显式特征表示的计算参数设置与隐式特征表示的复杂信息描述,将流场信息直接嵌入特征空间,优化了神经网络在特征提取时对复杂特征的注意力分配,进而增强了网络的学习能力。实验结果表明,AEpre能够基于有限的数据集,有效提取叶轮机械流场中不同尺度的流动特征,并在工况点范围内实现高精度流场预测,预测误差可控制在2%以内。

3.3 燃烧室燃烧设计仿真

燃烧室燃烧仿真过程具有极高的复杂性,涵盖了湍流、多相流、化学反应与热传递的强耦合效应,这对计算的精确度和成本提出了严格的要求。目前,研究人员已将各种生成式AI技术模型引入燃烧室领域进行了初步的应用探索,以期寻找相关问题的解决策略。现有关于燃烧室性能的生成式预测研究,主要为利用卷积-反卷积技术或注意力机制来预测燃烧室出口温度分布,而关于全场预测的研究相对较少。

郑前钢等^[29]提出了一种具备预测燃烧室出口温度分布功能的部件级模型构建方法,如图5所示。




图4 AEpre神经网络整体架构示意图

Fig.4 Overall architecture of the AEpre




图5 Inception-反卷积神经网络架构

Fig.5 Inception-deconvolutional neural network architecture

图中, W 代表权重矩阵,实现对输入特性的线性变换; b 代表偏置向量,在权重计算的结果上实现平移偏置,以增强拟合能力;下标 $g1 \sim g7$ 分别代表1~7层网络。该方法基于Inception-反卷积神经网络构建了燃烧室出口温度分布场的部件级代理模型,以及1个针对燃烧室3D仿真计算的二维局部代理模型。在获取燃烧室出口温度分布数据集的过程中,为适应卷积神经网络的处理需求,对原始数据进行了关键的预处理步骤:将仿真得到的扇形区域数据通过分块平均方法进行插值处理,转换为规则的方形区域阵列数据。结果表明,所构建的部件级模型预测的温度分布与CFD仿真得到的基本一致。

王瑄等^[30]提出了一种基于深度学习方法航空发动机燃烧室温度场快速预测方案。该方案采用了1个包含注意力机制的双分支网络模型,以增强神经网络对输入数据的聚焦能力。此外,所采用的双分支网络模型引入了物理损失函数项(燃油输入预估的温度场平均温度),以促进模型的快速收敛并提升其可解释性。结果表明,该模型实现了通过入口流动参数对燃烧室各个截面温度场的快速预测。与传统的全连接网络模型和卷积网络模型相比,该模型的性能得到了显著提升:温度场相对误差平均值

减小了48.4%,截面均温相对偏差减小了57.3%。

3.4 融合生成式AI技术与多场耦合的快速设计

在传统涡轮系统设计过程中,系统级与部件级的迭代次数众多,且必须先进行气动仿真评估,随后才能依次进行传热仿真评估和机械仿真评估。在这一过程中,不同阶段之间以及各阶段内部均需进行循环优化,显著延长了设计周期。生成式AI技术与仿真降阶代理模型的结合为解决这一问题提供了有效途径。目前,通过学习3D涡轮叶片性能指标与设计变量之间的分布关系,可以实现性能指标的逆向生成,从而确定可选的设计参数。

GHOSH等^[9]提出了一种PMI框架,如图6所示。该框架结合了仿真代理模型,能够直接根据目标性能生成多组满足要求的涡轮机械部件设计参数,从而缩短设计周期。该框架由正向建模和逆向建模两部分组成。正向建模采用GE贝叶斯混合建模(GEBHM)方法^[31],构建了从设计参数到仿真性能的概率多保真度高斯过程代理模型,实现了设计参数与仿真性能之间的概率性映射,并跳过了耗时的计算机实验步骤。同时,该模型利用多保真度自适应采样技术,自适应地确定了提升仿真性能所需的实验及保真度水平。从训练好的正向模型中采样,




图6 基于概率机器学习的逆向生成框架

Fig.6 Probabilistic machine learning-based inverse generative framework

得到多组设计参数和仿真性能数据,作为逆向建模的输入。逆向建模训练了一个深度生成模型^[32],采用条件可逆神经网络(cINN)^[33]学习将性能指标的简单分布映射到设计参数指标的复杂分布,对于给定的性能指标,通过cINN进行显式采样生成多种潜在的设计方案。

在3D涡轮叶片的气动设计中,对上述设计方案的效果进行了验证。具体而言,使用85个参数定义3D翼型的连续表示,并选用气动效率、反动度或伪反动度作为仿真标量性能指标,同时选用压力、流角等流动参数的径向分布作为仿真向量性能指标。通过多保真度自适应采样方案选择初始数据进行正向模型训练,在保证高精度的同时节省了至少35%的计算成本。利用正向模型生成的60 000个样本训练条件可逆神经网络,学习从观测到的仿真性能指标到设计参数的关系。训练完成后,将1组目标性能指标(包括目标效率、伪反动度和转子出口流场分布)输入PMI,生成一系列的可行性设计,设置几何约束(如第5截面最大厚度等)筛选出指定范围内的设计方案。CFD建模分析验证,所有方案的效率均处于期望值范围内,不确定性约为0.2%。

该框架能够生成高质量的设计参数-性能指标数据对,替代了昂贵的仿真流程,同时能够处理仿真的标量(气动性能)和矢量(流场分布)等复杂且带有噪声的性能指标,生成准确度较高的多种设计方案。未来,该框架有望被运用于多学科和气动力学领域设计,以及各种航空发动机部件的结构、模态和颤振分析。

4 生成式AI技术面临的问题及解决思路

4.1 泛化能力问题及解决思路

尽管生成式AI技术在航空发动机设计仿真领域展现出显著的应用潜力,但现有训练模型相对较弱的迁移能力限制了其应用的广泛扩展。当在特定场景下生成的AI模型被迁移到其他场景问题或环境时,其预测或设计的精度通常会显著下降。此时需要对模型进行重新训练,这将导致已有经验知识的复用效率低下,进而显著降低工程应用效率。该问题的核心原因涉及多个方面,包括算法框架适应性差、训练数据多样性不足、训练过程中出现过拟合现象以及缺乏有效的引导机制等。

针对上述问题,当前众多研究者主要通过数据

增强和多样性提升来改善训练数据的质量,以期增强模型的泛化能力。同时,也有研究者改进了现有的学习框架。例如,Mamba模型^[34]能够在一定程度上提升模型的训练效率和迁移能力。随着对更多模型框架的探索与优化,生成式AI技术的泛化能力有望得到进一步提升,从而促进其在航空发动机领域广泛应用。

4.2 小样本问题及解决思路

在航空发动机设计仿真的实际工程应用过程中,通常难以积累大量有效的样本数据,这要求生成式AI技术必须具备应对小样本学习训练的方法。同时,在小样本学习场景下,生成式AI技术还面临多个挑战:①数据稀缺导致模型难以准确捕捉真实数据分布,容易出现过拟合或模式坍塌现象,生成重复或低多样性的样本;②训练样本不足导致生成式模型的潜在空间表征能力受限,可能产生偏离真实特征的无效输出;③小样本条件下模型的泛化能力较弱,难以适应数据分布的细微变化。这些问题限制了生成式AI技术在数据获取成本较高的航空发动机领域中的应用。

目前,部分学者针对性地提出了一些解决方向,主要包括数据增强与合成、隐空间约束以及模型架构改进。数据增强与合成能够通过元学习或基于预训练模型的跨模态引导,生成多样化的样本数据以扩充训练集。隐空间约束能够通过原型网络学习有限样本间的共性特征。模型架构改进能够通过设计轻量化模块或增量学习策略,减少参数依赖。为实现更低成本和更优效果的生成式AI应用,多种策略组合应用将成为未来的主流发展方向。

4.3 多模态中模态失衡问题及解决思路

在航空发动机设计仿真领域,文本、图像以及模型等多模态数据的综合应用对于提升生成式AI技术的精确度和泛化能力至关重要。然而,在多模态生成式AI技术中,模态间不平衡现象成为亟待解决的难题。该问题主要表现为不同模态数据在质量、规模或特征表达上不均衡,进而导致模型在学习过程中对主导模态过度依赖,从而忽略了次要模态。以文本与图像的联合生成任务为例,文本数据往往具有高度的结构化特征和丰富的标注信息,而图像数据可能由于标注的稀疏性或噪声干扰,生成的图像质量波动较大。这种模态间的不平衡现象将导致生成结果出现偏差。

在多模态生成式AI技术的学习与训练过程中,研究者通常采用数据增强技术或权重调整策略来提升弱模态数据的比例,以缓解模态不平衡带来的影响。此外,一些学者提出了模态对齐与表征均衡的策略。该策略通过对比学习方法和引入模态特定的归一化层,强制模型学习不同模态间的对齐表征,并有效处理模态间的分布差异。

5 生成式AI技术的未来展望

生成式AI技术作为工程设计领域的前沿方向,将在未来占据重要地位。将物理先验知识与最新理念整合进生成式AI技术的理论框架,以增强其在航空发动机领域的应用效能、学习能力及多智能体设计能力,将是未来研究的关键方向。

5.1 多物理场耦合的生成式设计

航空发动机设计分析是一个涉及多场、多学科的应用过程。当前,将多物理场耦合分析与生成式AI技术相结合,有望增强生成式AI技术在处理相互作用的复杂工程设计问题中的应用能力。

物理信息嵌入的生成模型是一种新兴范式,其核心理念在于将物理规律直接整合到生成式AI架构中。这类模型通过物理方程约束引导生成过程,以确保输出结果既符合数据分布又满足物理一致性。目前,这类模型的实现路径主要有2种:①在损失函数中引入物理守恒项(如Navier-Stokes方程的残差项),使生成样本自动满足控制方程;②构建物理编码器-解码器架构,将偏微分方程离散化为可微算子嵌入神经网络。典型代表包括物理信息生成对抗网络和物理约束扩散模型。这些模型通过融合数据驱动学习与物理先验知识,显著提升了生成样本的物理可信度。该方法在航空发动机领域结构力学、流体力学、材料设计等方面具有独特优势。其不仅能够缓解纯数据驱动模型的过拟合问题,还能降低对大规模标注数据的依赖,为科学计算与工程优化提供了新的范式。

5.2 多智能体系统框架的生成式应用

航空发动机系统作为一项复杂的精密工程,其设计仿真的实现依赖于跨学科团队的紧密合作。多智能体系统框架作为分布式AI构建的核心范式,其目标在于通过多个自主生成式智能体之间的交互与协作,解决在复杂环境下面临的决策与控制难题。

在多智能体系统框架中,开发者能够定义生成

式AI代理的行为模式,并在任务执行过程中实现智能体间的对话交接,进而达成对复杂任务的模块化拆解与高效调度。该框架下的生成式应用不仅增强了对动态环境的适应能力,而且为航空发动机设计仿真提供了分布式智能协同的可能,从而提升了系统运作的效率,促进了跨领域知识的融合。尽管目前该框架仍处于实验阶段,但其为研究多代理系统的灵活性提供了宝贵的探索机会。

6 结束语

在当前AI技术的工程应用领域,生成式AI技术已在快速仿真预测不同物理场问题以及工程部件创成式设计方面展现出巨大潜力。然而,在航空发动机领域,生成式设计的直接应用较为有限:现有应用主要集中在对特定部件进行结构强度方面的直接生成设计;在气动和燃烧设计仿真方面,主要致力于性能生成预测。其中,气动性能已实现全场分布的生成预测,燃烧性能则主要针对出口温度分布进行生成预测。未来的研究工作需进一步深化对生成式AI理论的探讨,并结合航空发动机领域的业务特性,探索多物理场耦合应用、多智能体框架与生成式AI技术的融合,以期在性能生成预测和快速生成设计等方面实现重大突破。

参考文献:

- [1] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[EB/OL]. (2017-01-12)[2025-10-15]. <https://doi.org/10.48550/arXiv.1706.03762>.
- [2] OUYANG Long, WU J, XU Jiang, et al. Training language models to follow instructions with human feedback[EB/OL]. (2022-03-04)[2025-10-15]. <https://doi.org/10.48550/arXiv.2203.02155>.
- [3] BRYNJOLFSSON E, LI D, RAYMOND L. Generative AI at work[J]. The Quarterly Journal of Economics, 2025, 140(2): 889-942.
- [4] KNILL K, YOUNG S. Hidden Markov models in speech and language processing[M]//YOUNG S, BLOOTHOOFT G. Corpus-based methods in language and speech processing. Dordrecht: Springer Netherlands, 1997: 27-68.
- [5] REYNOLDS D. Gaussian mixture models[M]//LI S Z, JAIN A K. Encyclopedia of biometrics. Boston: Springer, 2009: 659-663.

- [6] CHEN Wei, RAMAMURTHY A. Deep generative model for efficient 3D airfoil parameterization and generation[R]. AIAA 2021-1690, 2021.
- [7] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686–707.
- [8] KINGMA D P, WELING M. Auto-encoding variational Bayes[EB/OL]. (2013-12-20)[2025-10-15]. <https://doi.org/10.48550/arXiv.1312.6114>.
- [9] GHOSH S, ANANTHA PADMANABHA G, PENG Cheng, et al. Inverse aerodynamic design of gas turbine blades using probabilistic machine learning[J]. Journal of Mechanical Design, 2022, 144(2): 021706.
- [10] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273–297.
- [11] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5–32.
- [12] ZHANG W, WANG L. Traditional AI algorithms: advantages in structured tasks and limitations in fuzzy information processing and creative decision-making [J]. Journal of Artificial Intelligence and Digital Economy, 2024, 41(3): 112–129.
- [13] BENGIO Y, DUCHARME R, VINCENT P, et al. A neural probabilistic language model[J]. Journal of Machine Learning Research, 2003, 3: 1137–1155.
- [14] MIKOLOV T, KARAFIÁT M, BURGET L, et al. Recurrent neural network based language model[C]// Interspeech 2010. Chiba, Japan: 2010.
- [15] GRAVES A. Long short-term memory[M]// Supervised sequence labelling with recurrent neural networks. Berlin: Springer, 2012: 37–45.
- [16] DEY R, SALEM F M. Gate-variants of gated recurrent unit (GRU) neural networks [C]// 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). Boston, USA: 2017.
- [17] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[EB/OL]. (2014-01-10)[2025-10-15]. <https://doi.org/10.48550/arXiv.1406.2661>.
- [18] REZENDE D J, MOHAMED S. Variational inference with normalizing flows[C]// 32nd International Conference on Machine Learning (ICML 2015). Lille, France: 2015.
- [19] SONG Yang, ERMON S. Generative modeling by estimating gradients of the data distribution[EB/OL]. (2019-01-12)[2025-10-15]. <https://doi.org/10.48550/arXiv.1907.05600>.
- [20] CHEN Z, LI J, ZHANG Q. Impact of 3D shape representation strategies on global structure and local detail in generative results[J]. Journal of Computer Graphics Techniques, 2024, 13(2): 45–62.
- [21] KERAMATI H, ZHANG Y. A reward-directed iterative optimization framework for generative AI design[J]. IEEE Transactions on Artificial Intelligence, 2025, 16(3): 1456–1470.
- [22] LI J, ZHANG H, CHEN Y. The Transformer architecture: a pivotal junction in generative models and its implications for multimodal generation[J]. Journal of Advanced Artificial Intelligence, 2024, 45(2): 78–95.
- [23] LI Z, WANG H. TextGrad: a backpropagation framework for generative AI optimization via language model feedback[J]. IEEE Transactions on Artificial Intelligence, 2025, 16(4): 1890–1905.
- [24] LIU Y, WANG H. Comparative analysis of 3D representation methods: from point clouds to implicit fields in generative models[J]. IEEE Transactions on Visualization and Computer Graphics, 2025, 31(4): 1892–1908.
- [25] UNIFI3D TEAM. A unified evaluation framework for 3D representations in generation and reconstruction[J]. Transactions on Machine Learning Research, 2025, 6(8): 1–32.
- [26] WANG Qiying. Toward a uniform asymptotic theory for mildly explosive autoregression[J]. Econometric Theory, 2025, 41(1): 1–24.
- [27] EIVAZI H, WANG Yuning, VINUESA R. Physics-informed deep-learning applications to experimental fluid mechanics[J]. Measurement Science and Technology, 2024, 35(7): 075303.
- [28] 刘恭言. 基于小样本数据的部件模型生成及整机级协同仿真研究[D]. 北京: 清华大学, 2025.
- LIU Gongyan. Component model generation and system-level co-simulation based on small sample data [D]. Beijing: Tsinghua University, 2025. (in Chinese)
- [29] 郑前钢, 张宏维, 张海波. 考虑燃烧室出口温度分布的航空发动机部件级模型[J]. 推进技术, 2024, 45(6): 245–262.
- ZHENG Qiangang, ZHANG Hongwei, ZHANG Haibo. Aero-engine component-level model considering combustor outlet temperature distribution[J]. Journal of Propulsion Technology, 2024, 45(6): 245–262. (in Chinese)

- [30] 王瑄,孔辰,韩云霄,等. 引入物理约束的航空发动机燃烧室温度场预测模型[J]. 推进技术,2024,45(12):64–78.
WANG Xuan,KONG Chen,HAN Yunxiao,et al. A physical-constrained prediction model for combustor temperature field in aero-engine[J]. Journal of Propulsion Technology,2024,45(12):64–78. (in Chinese)
- [31] ZHANG Y,SMITH K. Advances in GE’s Bayesian hybrid modeling (GEBHM) for industrial applications [J]. Journal of Bayesian Analysis,2025,20(3):892–915.
- [32] YAZDANI S,SINGH A,SAXENA N,et al. Generative AI in depth: a survey of recent advances, model variants, and real-world applications[J]. Journal of Big Data, 2025,12(1):230.
- [33] DENKER A,SCHMIDT M,LEUSCHNER J,et al. Conditional invertible neural networks for medical imaging[J]. Journal of Imaging,2021,7(11):243.
- [34] WANG C,TSEPA O,MA Jun,et al. Graph-Mamba: towards long-range graph sequence modeling with selective state spaces[EB/OL]. (2024-02-01)[2025-10-15]. <https://doi.org/10.48550/arXiv.2402.00789>.