

基于物理嵌入神经网络的叶栅损失模型

冯云阳^{1,2}, 宋西镇^{1,2}, 袁巍^{1,2}, 鹿晗男^{1,2}

(1. 北京航空航天大学 能源与动力工程学院, 北京 102206;

2. 北京航空航天大学 航空发动机气动热力国家级重点实验室, 北京 102206)

摘 要: 为解决传统的叶栅损失经验模型在构建过程中对于强非线性函数关系总结能力不足, 导致其适用局限性、可修正性不好等问题。在一般端到端人工神经网络的基础上, 进一步发展了物理嵌入神经网络方法, 通过将叶栅表面压力分布引入神经网络建立叶栅损失模型, 对叶栅压力分布和性能进行预测。经验证, 相对于经验模型, 端到端神经网络模型总体损失预测误差降低 22.3%, 物理嵌入神经网络模型总体损失预测误差下降 37.9%。

关 键 词: 替代模型; 损失预测; 深度学习; 神经网络; 物理嵌入

中图分类号: V231.3

文献标志码: A

Physics-informed neural networks based cascade loss model

FENG Yunyang^{1,2}, SONG Xizhen^{1,2}, YUAN Wei^{1,2}, LU Ha'nang^{1,2}

(1. School of Energy and Power Engineering, Beihang University, Beijing 102206, China;

2. National Key Laboratory of Science and Technology on Aero-Engine Aero-thermodynamics, Beihang University, Beijing 102206, China)

Abstract: It is difficult to modify and broaden the scope of application for empirical models because of its inadequate ability to fit strong nonlinear function relationship. In order to solve these problems, a physics-informed deep learning cascade loss model of embedding the pressure distribution of cascade into neural networks was proposed. The loss prediction error decreased by 22.3% compared with empirical model for end-to-end neural networks and 37.9% compared with physics-informed model.

Keywords: surrogate model; loss prediction; deep learning; neural networks; physics-informed

现代航空发动机设计对高性能压气机的要求日益提高^[1]。由于气动参数之间的强非线性关系以及建模的复杂度问题, 压气机的全三维设计难以实现及普及, 主流设计方法大多采用二维或准三维设计^[2]。传统的压气机叶型设计方法使用经验模型对叶型的损失等性能进行预估以辅助设计, 借助数值模拟进行多次迭代最终满足设计要求, 其中经验模型的选择和精度直接决定了设计结果

的优劣^[3]。叶栅损失模型是压气机设计中常用的经验模型之一, 可以对常规工况下的叶栅性能进行快速预测以加快设计迭代。

研究人员对叶栅损失模型进行了一系列研究。Lieblein 模型是由叶栅测试数据进行数据关联后得到的, 对叶栅损失、设计攻角及落后角进行了预测^[4-5]。Kus 等人通过对转捩区的损失建模更精确地预测叶栅局部及整体的损失^[6]。这两个模型

收稿日期: 2022-09-30

作者简介: 冯云阳(1995—), 男, 博士生, 研究方向为压气机气动稳定性、人工智能辅助压气机设计。

通信作者: 袁巍(1974—), 男, 副教授、博士生导师, 博士, 研究方向为叶轮机气动力学、压气机稳定性、风力机、内流实验测试等。

E-mail: 07691@buaa.edu.cn

引用格式: 冯云阳, 宋西镇, 袁巍, 等. 基于物理嵌入神经网络的叶栅损失模型[J]. 航空动力学报, 2023, 38(7): 1615-1625. FENG Yunyang, SONG Xizhen, YUAN Wei, et al. Physics-informed neural networks based cascade loss model[J]. Journal of Aerospace Power, 2023, 38(7): 1615-1625.

基于边界层理论,建立了叶栅损失的数学表达式,主要关注的是低马赫数的工况。Banjac 等人基于数值模拟结果提出了一个统计学的损失及落后角模型,并考虑了径向效应的影响^[7]。Lengani 等人将叶栅损失分为四部分并分别进行预测,以提高预测精度^[8]。这两个模型建立了几何参数、来流条件和叶栅性能的纯数学模型,在建立模型的过程中没有引入任何物理机制。

随着大数据时代的到来和计算资源的飞速发展,深度学习在一系列机器学习算法中脱颖而出,成为应用最广、最具发展前景的机器学习算法。深度学习通过多层处理,逐渐将初始的“低层”特征表示转化为“高层”特征表示后,用“简单模型”的组合完成复杂的分类等学习任务^[9]。现在广泛使用的基于神经网络的深度学习方法,其随机梯度下降和误差反向传播的优化算法在 20 世纪 80 年代证明是行之有效的^[10]。在面对不同形式、结构的数据时,不同网络构架效果大有不同,研究人员对网络构架的选择进行了一系列研究。卷积神经网络大大减少了处理二维数据时神经网络的参数量,使得神经网络在深度方向上获得极大的扩展^[11]。循环神经网络(RNN)是广泛用于序列数据的深度学习模型,可以用于文本处理、语音识别等方面^[12]。Goodfellow 等人于 2014 年首次提出了生成对抗网络(generative adversarial nets, GANs)并给出了其收敛性的证明^[13]。Mirza 等人提出了条件对抗生成网络的结构,证明对抗生成式模型可以根据给定的方向进行生成^[14]。深度学习模型对高维、强非线性关系的拟合能力也许能为气动问题的解决提供新的方法。

研究人员对深度学习辅助的气动力学和叶轮机械设计方法进行了尝试^[15-19], Uelschen 等人结合神经网络和遗传算法,进行了压气机叶型的优化^[20]。Sekar 等人尝试了以翼型吸压力面的压力分布图像为输入,通过深度卷积网络进行了叶型几何反推的尝试^[21]; Lee 等人用 GANs 模型对圆柱绕流的非定常流场进行了预测^[22]。这些研究将深度学习方法应用到气体动力学问题中时,大多是建立了一个端到端(E2E)的判别式模型,一个由输入到输出的函数映射关系,完全摆脱了传统的设计方法和气动力学,是一个单纯的数学模型,这样的模型往往很难认识问题的物理本质。同时,判别式模型无法对流场的分布细节进行描述,模型缺乏普适性;且面对非适定问题(如叶栅设计反

问题)时,判别式模型将会直接失效。

为了解决以上问题,一种可行的方法是引入物理嵌入神经网络(physics-informed neural networks, PINNs)。这一模型将深度学习模型与实际问题进行关联,在深度学习模型中引入了物理机制。研究证明,这一神经网络结构在解决反问题以及有明确物理机制约束的问题时是行之有效的^[23-27]。这说明在建立压气机深度学习模型时,传统的压气机设计经验和气动准则不应被忽视,其在建立深度学习模型过程中可以起到指导作用,如辅助选择气动特征、设计网络结构等。

本文提出了一种基于物理嵌入的深度学习叶栅损失模型,其中最关键的问题是如何将物理机制引入损失预测流程。模型关注叶栅的壁面压力,通过 GANs 首先对壁面压力进行预测,并以压力分布为输入预测叶栅损失。本文通过 CFD 方法建立了一个足以支撑深度学习模型的数据库,并对比了经验模型、有物理嵌入的深度学习模型及无物理嵌入深度学习模型的性能。

1 问题概述

图 1 给出了传统压气机叶型设计流程。在通流设计给出叶栅设计目标后,结合经验模型(如损失模型、落后角模型)对叶栅进行迭代设计。显然,高精度、宽适用范围的经验模型可以更好地辅助二维叶型的设计。

传统经验模型的应用主要受制于两方面因素。第一,不同叶栅几何特征不尽相同,其参数化方




图 1 传统压气机叶型设计流程

Fig. 1 Design process of conventional compressor blade profile

法也可能存在差异;第二,物理机制和流场细节的缺失使其嵌入设计流程存在困难。端到端的深度学习模型也存在第二个问题。

为了对物理嵌入的深度学习叶栅损失模型进行建模,首先需要明确叶栅的气动特征。在亚声速基元中,气流流入叶栅通道,叶栅使气流方向发生转折,最终流出叶栅,减速增压。经过研究人员的探究总结,二维叶栅的损失主要由以下几个部分组成:摩擦损失、尾迹损失、分离损失、激波损失。由于本文主要针对亚声速基元叶型进行研究,尽管在叶型表面存在超声区,但激波损失相对较小。其余的损失组成部分都与剪切力紧密相关,其主要作用区域为叶型表面边界层,因此传统方法常常基于边界层理论来建立经验模型。本文选择了叶栅设计中典型的气动参数——叶栅壁面压力分布作为中间变量嵌入深度学习模型,

这一变量能够反映叶栅边界层内流动。

2 深度学习模型

2.1 总体结构

图2给出了经验模型、无物理嵌入模型和物理嵌入模型的损失预测流程的对比。物理嵌入模型在物理机制的指导下充分利用了神经网络的数据关联能力,集合了前两者的优点。同时,能够对流场参数分布进行可靠的描述,这一优势使其能够更好地嵌入叶型设计流程。

这3类模型都以叶型几何和来流条件为输入,以叶栅总压损失系数为输出。本文选取两个经过验证的经验模型作为对比,其简介见附录。无物理嵌入模型对输入与输出的函数关系进行了直接建模,而物理嵌入模型以叶栅壁面弦向压力分布作为中间参数引入深度学习模型。




图2 不同损失模型预测流程

Fig. 2 Predicting process of different loss model

2.2 神经网络模型

图3给出了物理嵌入模型的结构及输入、输出。本文用离散点坐标对叶型的几何进行描述,而非传统的参数化方法。这一描述方法可以适用于不同方法生成的叶型,同时可以更好地应用于叶型的反设计问题。深度学习模型的输入是长度为408的一维向量,由吸/压力面的离散点、来流条件、稠度及安装角组成。

为了适应不同问题的数据结构,研究人员对不同神经网络的架构进行了研究,本节对应用于本文模型的神经网络架构进行简要介绍。

2.2.1 多层感知机

这类神经网络完全由全连接层构成,相邻层与层之间每一个神经元都互相连接,是最简单的神经网络结构,也是其他架构神经网络的基础。其训练过程分为代价函数的计算和误差的反向传播。图4给出了1个3层感知机模型的结构图,其中第 l 层的第 i 个神经元的值为

$$a_i^{[l]} = \sum_{j=1}^n g(w_{ij}^{[l]} \cdot a_j^{[l-1]}) \quad (1)$$

式中 n 为网络第 $l-1$ 层的神经元个数, $w_{ij}^{[l]}$ 为第 $l-1$




图 3 物理嵌入模型架构

Fig. 3 Structure of physics-informed model




图 4 多层感知机

Fig. 4 Multiple layer perceptron

层第 j 个神经元与第 l 层第 i 个神经元之间的连接权重, W 是两层间权重矩阵。

2.2.2 卷积网络

卷积操作是如今深度学习能够广泛应用的重要原因之一, 图 5 给出了卷积层卷积操作示意图。与全连接层相比, 卷积层一大特点是权值共享, 应用在高维数据上可以大大减少参数的数目, 从而可以训练更深的神经网络。包含卷积层的神经网络即为卷积神经网络。卷积神经网络中一般也包含用于特征提取的池化层。

反卷积操作是卷积操作的逆操作, 主要应用于信号大小的还原或者上采样, 在生成式模型中可以用于图像的生成。

2.2.3 GANs

由于问题面向对象的联合概率分布计算困难,




图 5 3 层稠密连接网络

Fig. 5 3-layer dense block

因此生成式模型的训练远远难于判别式模型。GANs 将样本的概率分布以对抗的形式引入模型训练, Goodfellow 等人^[13]给出了其最优解在生成样本与数据库样本分布完全一致处和优化方法收敛性的证明。GANs 包含两个互相对抗的模型: 捕捉样本分布的生成式模型 G 和区分样本来自数据库或生成式模型 G 的判别式模型 D 。通过对抗训练, G 生成的样本与样本库中样本趋于一致。

CGANs 是基于 GANs 的条件生成模型, 将某些参数作为生成式模型 G 的输入, 使模型能够定向进行生成。

2.2.4 稠密连接网络

对于所有神经网络都会存在随着网络的加深, 梯度的消失与爆炸的问题, 稠密连接卷积网络 DenseNet 就是为了解决这一问题而产生的。区别于一般的神经网络, DenseNet 存在捷径连接 (shortcut connection)。这一方法缩短了输入到输

出的参数传递距离,缓解了深度神经网络的梯度消失问题,同时增加的参数不多。图 5 给出了 1 个 3 层的稠密连接网络示意图。

2.3 物理嵌入方法

边界层流动决定了叶栅的性能,因此一些经验模型基于边界层理论建立了模型。而无物理嵌入模型直接建立了输入到输出的函数关系。本文提出了一种物理嵌入的深度学习模型,以壁面压力的弦向分布为中间参数引入深度学习模型。壁面压力分布是对叶栅边界层发展的一种一维描述,通过引入这一参数,以期深度学习模型更加精确、合理、稳定。

物理嵌入方式大体分为 3 类,可以单独使用或耦合使用^[28]。在本次研究的模型中,同时引入了 3 类物理嵌入方法。

1) 将实验/模拟的大量数据嵌入深度学习模型。本文使用的深度学习模型以壁面压力分布为中间值,需要提取数值模拟中的叶栅流场压力作为标签量对生成式模型进行训练。

2) 将先验的知识反映在网络结构上。本文的模型结合前人对叶栅流动损失的研究结论,将直接建立叶栅几何、来流条件到叶栅损失的简单思路转变为先由叶栅几何、来流条件对叶栅壁面压力分布进行生成,再对叶栅损失进行预估。

3) 模型预测结果同时被误差和物理规律(如流体力学中的连续性、守恒性等)所约束,这一嵌入一般体现在模型的损失函数上。

2.4 模型训练

本文使用了批标准化这一广泛使用的重参数化的方法,大大缓解了深度神经网络的梯度消失与爆炸的问题,令神经网络学习率的可选择范围大大扩大,加快了神经网络的收敛。本次研究中使用的优化算法为 Adam 算法,初始学习率选择 2×10^{-5} 。

训练时,先以数据库中叶栅壁面压力分布和叶栅损失系数分别作为输入和输出进行判别式模型 D 的训练,直至模型收敛。再将叶栅几何和来流条件输入生成式模型 G,输出叶栅壁面压力分布,生成的压力分布输入判别式模型 D 进行叶栅损失预估,将模型 D 的误差作为对抗项引入模型 G 的损失函数中,综合考虑压力分布生成的误差和叶栅损失预估的误差,对模型 G 进行训练。无对抗的生成式模型与有对抗的生成式模型损失函数分别为

$$L_G = \frac{1}{n_x} \sum_{i=1}^{n_x} (p_i - \hat{p}_i) \quad (2)$$

$$L_{G_adv} = L_G + \varepsilon L_D \quad (3)$$

其中 L_G 、 L_{G_adv} 分别代表无对抗和有对抗生成模型的损失函数; L_D 代表判别式模型的损失; p_i 、 $\hat{p}_i$ 分别代表数值模拟结果与模型预测中压力分布第 i 个位置的值; n_x 代表压力分布向量的长度; ε 为超参数,代表对抗项的权重,在本文中取 0.1。

3 数据集

3.1 几何生成方法

叶型几何采用中弧线叠加厚度的形式产生,其中叶型中弧线形式为抛物线或双圆弧,厚度分布服从多项式分布,叶型控制参数在一定的约束条件下随机分布,部分典型参数的取值范围见表 1。样本库中包含 26 500 个样本,其中包含 25 000 个自动生成的样本和 1 500 个 NACA 或 C 系列叶型,来流马赫数范围为 (0.2, 1),攻角范围为 $(-6^\circ, +6^\circ)$ 。

表 1 部分叶栅几何参数取值范围

Table 1 Value ranges of geometry parameter of cascade

叶栅几何参数	取值范围
稠度 δ	(1, 3.3)
安装角 $\gamma/(^\circ)$	(0, 55)
弯角 $\varphi/(^\circ)$	(0, 65)
最大相对厚度 t/C	(0.025, 0.15)
最大厚度位置 $\bar{e}$	(0.25, 0.75)
最大挠度位置 $\bar{f}$	(0.25, 0.75)

3.2 数值模拟方法

本文使用 NUMECA 的网格绘制模块的脚本方法批量生成准二维网格,并使用其 Euranus 求解器进行数值计算,得到准二维流场。控制方程为 Navier-Stokes 方程,使用 4 阶 Runge-Kutta 方法进行时间离散,使用中心差分格式进行空间离散,湍流模型采用 shear stress transport (SST) 模型。叶型弦长为 0.1 m,计算域在 Y 方向(叶栅额线方向)为 1 个叶栅周期,在 X 方向为 $(-0.2, 0.4)$ m。网格结构为 O4H 的结构化网格,由 1 个包裹叶栅的 O 型网格和其四周的 4 个 H 型网格构成,网格数为 17 618。

对边界条件,进口边界给定总温 $T_1^* = 288.15$ K,

出口边界给定静压 $p_2 = 101\,325\text{ Pa}$, 在 $y = \pm 0.1/(2\delta)$ 处给定周期性边界条件。改变进口总压及来流气流方向以改变来流马赫数和攻角, 达到改变来流工况的效果。在数个叶型上完成了网格的无关性验证, 同时保证 $y^+ < 5$ 。

3.3 数值模拟方法验证

通过与 NACA65-(18)10 叶型的叶栅实验结果^[29]进行对比, 对本文所使用的数值模拟方法进行了验证。叶栅实验中, 来流雷诺数 $Re = 250\,000$, 0° 攻角时进口气流角为 45° 。图 6 为叶栅气流转角随进口气流角变化, 图 7 为 0° 攻角时, 文献^[29]中定义的压力系数 S 沿叶栅弦向分布对比。 S 定义为

$$S = \frac{p_1^* - p}{p_1^* - p_1} \quad (4)$$

其中 p_1^* 为进口总压, p 为当地静压, p_1 为叶栅进口静压。可以看到本文使用的数值模拟方法得到流场和叶栅特性与实验基本吻合, 数值模拟的精度能够满足本次研究的需求。




图 6 叶栅气流转角特性

Fig. 6 Turning-angle characteristic of cascade




图 7 S 沿叶栅弦向分布(进口气流角为 45°)

Fig. 7 Chordwise distribution of S (45° inlet flow angle)

3.4 数据集划分

模型训练时数据集中的样本被随机划分为包含 22 500 个样本的训练集、包含 2 500 个样本测试集以及由 1 500 个 NACA 或 C 系列叶型构成的特殊测试集。经验证, 训练集与测试集的参数分布保持了良好的一致性, 保证了数据集的划分不会造成模型的过拟合。NACA 和 C 系列叶型是代表性的传统叶型, 也是本文引用的两个经验模型建立的基础。为了验证深度学习模型的全面性和数据集的合理性, 所有模型都在由经典叶型组成的特殊测试集上进行了验证。同时, 为了保证经验模型与深度学习模型性能对比的公平性, 经验模型进行了最小二乘拟合, 使其经验参数更适用于本文所使用的数据库。

4 结果与讨论

对经验模型、无物理嵌入模型与物理嵌入模型性能及影响物理嵌入模型性能的因素进行了讨论, 给出了各模型的总体性能及不同条件下的性能, 验证了物理嵌入模型的性能优于经验模型及无物理嵌入模型。

4.1 总体性能

表 2 给出了各模型的归一化误差。其定义为

$$E = \sum_{i=1}^N \frac{|z_i - \hat{z}_i|}{N\sigma} \quad (5)$$

其中 N 为样本数量, z_i 和 $\hat{z}_i$ 分别为第 i 个样本的标签及预测值, σ 为数据集中 y 值的标准差。这一误差是将数据集标签进行归一化后, 模型预测的绝对误差与标准差的比值能够反映无量纲化的模型预测精度。

尽管在建立无物理嵌入模型时没有对其架构和超参数进行细致的调整, 其误差相对于经验模型仍降低了 22.3%。这说明深度学习模型对数据间的函数关系有很强的挖掘能力。同时, 物理嵌入模型的总体误差相较于无物理嵌入模型降低了 20.01%, 相较于经验模型下降了 37.9%。

表 2 各模型归一化误差

Table 2 Normalized errors of different models

模型名称	归一化误差
Lieblein 模型	0.249 6
Banjac 模型	0.201 4
无物理嵌入模型	0.156 4
物理嵌入模型	0.125 1

4.2 不同来流条件下叶型性能预测

为了探究不同来流条件下的模型性能,按照来流条件对数据集进行了划分并验证了各模型的效果。图 8 和图 9 给出了不同来流马赫数和叶栅攻角条件下的模型预测误差。其中,来流马赫数横轴代表其 ± 0.1 的邻域内所有样本,如来流马赫数 0.5 代表来流马赫数 $Ma_1 \in (0.4, 0.6]$ 的所有样本。可以预见,模型在高来流马赫数或大正/负攻角的工况下性能会恶化,造成这一现象的原因有二:①在数据集的边界处,数据量不足;②非设计工况下可能出现较强的激波或分离。从图 6 和图 7 中可以看出,深度学习模型在来流条件偏离设计条件时性能恶化较慢。相对于经验模型,无物理嵌入模型误差在 $Ma_1 > 0.6$ 时误差降低 23.5%,在攻角 $|\alpha| = 6^\circ$ 时误差降低 54.6%。这表明深度学习模型比经验模型适用范围更广。

对物理嵌入模型,非设计工况的损失预测误差得到了进一步的降低。相较于无物理嵌入模




图 8 不同攻角下模型预测误差

Fig. 8 Normalized predicting error of models at different incidences




图 9 不同来流马赫数下模型预测误差

Fig. 9 Normalized predicting error of models at different inflow Mach numbers

型,物理嵌入模型总体误差降低 20%,在 $Ma_1 > 0.6$ 时误差降低 20.4%,在攻角 $|\alpha| = 6^\circ$ 时误差降低 26.3%。物理嵌入在非设计工况下能够有效降低模型误差,一个可能的原因是物理嵌入模型提供了更细节的流场分布。对非设计工况下的激波、大逆压梯度等特征,模型可以在设计工况的部分区域的流场中进行学习,从而对非设计工况的损失进行更精准的预测。流场细节的补充可以看作对数据库的扩展,补充了数据库在各工况下的可学习信息。

4.3 特殊测试集中叶型性能预测

经验模型往往基于经典叶型的实验或数值模拟数据建立。为验证数据集的全面性及本次研究模型面对经典叶型时的性能,在包含 1 500 个 NACA 或 C 系列叶型的特殊测试集上对模型性能进行了测试。

表 3 给出了各模型在特殊测试集上的损失预测误差。无物理嵌入模型相对于经验模型已无明显性能优势,在某些工况下的预测误差大于经验模型。相较于一般的测试集,物理嵌入模型对预测误差的降低幅度较小。即便在经验模型的原始数据上,物理嵌入模型依然提供了最精准的误差预测。

表 3 特殊测试集上各模型预测误差

Table 3 Normalized predicting errors of different models on conventional sections

模型名称	归一化误差
Lieblein 模型	0.184 0
Banjac 模型	0.169 0
无物理嵌入模型	0.162 8
物理嵌入模型	0.131 0

4.4 实际压气机叶型性能预测

以 6 个实际压气机 (Stage67、Rotor37 等) 中不同叶高截面叶型为目标验证了物理嵌入模型的性能。部分几何参数及来流条件见表 4, 样本几何及模型预测损失、数值模拟损失见图 10。

物理嵌入模型给出了 5 个样本最准确的损失预测,并且在大攻角(样本 3、样本 5)和高来流马赫数(样本 3)样本上有效提高了预测精度。图 11 给出了数值模拟与物理嵌入模型对叶栅壁面压力分布的预测结果对比,可以看到模型对叶栅流场气动参数分布给出了较为准确的预估。

至此,基于物理嵌入神经网络的叶栅损失模

型性能基本得到验证。物理嵌入不仅提高了损失模型的精度,拓宽了模型的适用范围,还给出了可靠的叶栅流场细节预估,使其可解释性更强、更易收敛,同时可以更好地嵌入叶型设计流程。

表 4 样本几何参数及来流条件
Table 4 Geometry parameters and inlet conditions for samples

样本编号	几何参数				来流条件	
	稠度	安装角/(°)	弯角/(°)	最大厚度	马赫数	攻角/(°)
1	1.930	38.04	25.02	0.048	0.862	0
2	1.460	53.85	10.00	0.038	0.553	3
3	1.750	34.32	27.90	0.045	0.928	6
4	2.500	0.50	56.32	0.073	0.447	-3
5	2.188	27.87	31.34	0.058	0.711	-6
6	2.090	36.08	37.35	0.054	0.660	3





图 10 各模型样本损失预测及数值模拟结果对比

Fig. 10 Loss predictions of different models and loss from CFD results






图 11 叶栅壁面压力分布物理嵌入模型预测与数值模拟结果对比(每 20 个数据点显示 1 个点)

Fig. 11 Comparison of cascade wall pressure distribution between physics-informed model prediction and CFD
(1 scatter is displayed for every 20 points)

5 结 论

在包含 26 500 个样本的数据库上验证了经验模型、无物理嵌入模型和物理嵌入模型的性能并进行了对比。

1) 深度学习模型在叶栅损失预测问题中比经验模型误差小、适用范围宽,而物理嵌入可以进一步提高深度学习模型的性能。物理嵌入模型的总体归一化误差为 0.125 1,相较于无物理嵌入模型下降 20%,相较于经验模型下降 37.9%。同时,流场细节的嵌入使模型适用范围更宽,因为模型可以在低来流马赫数、小攻角工况下对流场细节进行学习以辅助非设计工况下的性能预测。

2) 叶栅壁面压力的弦向分布是反映叶栅边界层流动的重要一维气动特征,将其引入深度学习模型后可以指导深度学习模型的训练,提高深度学习模型的精度、可解释性。同时,对流场细节的描述使模型更易嵌入叶型反设计流程,工程实用价值更高。

3) 物理嵌入是将深度学习模型更好应用于实际物理、工程问题的有效方法,合理选择物理约束、特征及其嵌入方式可以提高深度学习模型解决实际问题的能力。

参考文献:

- [1] CUMPSTY N A. Compressor aerodynamics[M]. London: Longman Group, 1989.
- [2] CUMPSTY N A, GREITZER E M. Ideas and methods of turbomachinery aerodynamics: a historical view[J]. *Journal of Propulsion and Power*, 2004, 20(1): 15-26.
- [3] AUNGIER R H. Axial-flow compressors[M]. New York: ASME Press, 2003.
- [4] LIEBLEIN S. Loss and stall analysis of compressor cascades[J]. *Journal of Basic Engineering*, 1959, 81(3): 387-397.
- [5] LIEBLEIN S. Incidence and deviation-angle correlations for compressor cascade[J]. *Journal of Fluids Engineering*, 1960, 82(3): 575-584.
- [6] KUS U, CHAUVIN J. A rapid method for predicting global and local performance of cascades with special emphasis on the calculation of the transition region[R]. ASME Paper 94-GT-256, 1994.
- [7] BANJAC M, PETROVIC M V, WIEDERMANN A. A new loss and deviation model for axial compressor inlet guide vanes[J]. *Journal of Propulsion and Power*, 2005, 21(1): 1-11.

- nal of Turbomachinery, 2014, 136(7): 071011.1-071011.13.
- [8] LENGANI D, SIMONI D, UBALDI M, et al. Accurate estimation of profile losses and analysis of loss generation mechanisms in a turbine cascade[J]. Journal of Turbomachinery, 2017, 139(12): 121007.1-121007.9.
- [9] NIELSEN M A. Neural networks and deep learning[M]. Cambridge, US: Determination Press, 2015.
- [10] WERBOS P. Beyond regression: new tools for prediction and analysis in the behavioral sciences[D]. Cambridge, US: Harvard University, 1974.
- [11] LECUN Y, BOSER B, DENKER J S, et al. Handwritten digit recognition with a back-propagation network[C]//Proceedings of Advances in Neural Information Processing Systems. San Francisco, US: MIT Press, 1990: 396-404.
- [12] SUTSKEVER I, MARTENS J, HINTON G E. Generating text with recurrent neural networks[C]// Proceedings of 28th International Conference on Machine Learning. Washington DC: PMLR, 2011: 1017-1024.
- [13] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of Neural Information Processing Systems 2014. Montréal, US: MIT Press, 2014: 1-9.
- [14] MIRZA M, OSINDERO S. Conditional generative adversarial nets [EB/OL][2022-09-29].<https://arxiv.org/abs/1411.1784>.
- [15] WANG Shuyue, SUN Gang, CHEN Wanchun, et al. Database self-expansion based on artificial neural network: an approach in aircraft design[J]. Aerospace Science and Technology, 2018, 72: 77-83.
- [16] GAO Wenbo, ZHOU Xin, PAN Muxuan, et al. Acceleration control strategy for aero-engines based on model-free deep reinforcement learning method[J]. Aerospace Science and Technology, 2022, 120: 107248.1-107248.10.
- [17] MAGALHÃES J M, HALIL L O, KIM Y, et al. Intelligent data-driven aerodynamic analysis and optimization of morphing configurations[J]. Aerospace Science and Technology, 2022, 121: 107388.1-107388.15.
- [18] RENGANATHAN S A, MAULIK R, AHUJA J. Enhanced data efficiency using deep neural networks and Gaussian processes for aerodynamic design optimization[J]. Aerospace Science and Technology, 2021, 111: 106522.1-106522.15.
- [19] LI Jichao, ZHANG Mengqi. On deep-learning-based geometric filtering in aerodynamic shape optimization[J]. Aerospace Science and Technology, 2021, 112, 106603.1-106603.13.
- [20] UELSCHEN M, LAWRENZ M. Design of axial compressor airfoils with artificial neural networks and genetic algorithms[R]. AIAA 2000-2546, 2000.
- [21] SEKAR V, ZHANG Mengqi, SHU Chang, et al. Inverse design of airfoil using a deep convolutional neural network[J]. AIAA Journal, 2019, 57(3): 993-1003.
- [22] LEE S, YOU D. Data-driven prediction of unsteady flow fields over a circular cylinder using deep learning[J]. Journal of Fluid Mechanics, 2019, 879: 217-254.
- [23] WU Jinlong, KASHINATH K, ALBERT A, et al. Enforcing statistical constraints in generative adversarial networks for modeling chaotic dynamical systems[J]. Journal of Computational. Physics, 2020, 406: 109209.1-109209.26.
- [24] ZHU Weiqiang, XU Kailai, DARVE E, et al. A general approach to seismic inversion with automatic differentiation[EB/OL].[2022-09-29].<https://arxiv.org/abs/2003.06027>.
- [25] YOUSIF M Z, YU L, LIM H C. Physics-guided deep learning for generating turbulent inflow conditions[J]. Journal of Fluid Mechanics, 2022, 936: 1-25.
- [26] SIRIGNANO J, MACART J F, FREUND J B. DPM: a deep learning PDE augmentation method with application to large-eddy simulation[J]. Journal of Computational Physics, 2020, 423: 1-21.
- [27] 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.
- [28] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nature Reviews: Physics, 2021, 3: 422-440.
- [29] HERRIG L J, EMERY J C, ERWIN J R. Systematic two-dimensional cascade tests of NACA 65-Series compressor blades at low speeds[R]. NACA-TN-3916, 1957.
- [30] BANJAC M, PETROVIC M V. Development of method and computer program for multistage axial compressor design: Part I mean line design and example cases[R]. ASME Paper GT2018-75410, 2018.

(编辑: 陈 越)

附录: 经验模型

1) Lieblein 模型

Lieblein 基于大量实验数据,建立了叶栅损失和落后角、参考攻角预估的经验模型。Lieblein 认为叶型几何的改变主要通过改变速度扩散来影响叶栅尾缘的边界层动量厚度,从而影响叶栅的损失系数。式(A1)~式(A5)给出了 Lieblein 损失模型的具体表达,其中 $(\theta/C)_2$ 为叶栅尾缘边界层动量厚度与弦长之比, δ 、 H_2 、 β_1 、 β_2 、 $V_{\max,s}$ 、 V_1 、 V_2 分别代表叶栅稠度、尾缘边界层几何因子、进口气流角、出口气流角、吸力面最大速度、进口速度、出口速度。 ε 和 k_s 是两个经验参数,在本次研究中去 0.004 和 1.17。 c_1 、 c_2 、 c_3 、 c_4 是模型的可拟合参数。参考文献 [7,30],由式(A5)对攻角与来流马赫数对损失的影响进行预估。

$$\frac{V_{\max,s}}{V_1} = c_1 + c_2 \frac{\cos^2 \beta_1}{\delta} (\tan \beta_1 - \tan \beta_2) \quad (\text{A1})$$

$$\frac{V_{\max,s}}{V_2} = \frac{V_{\max,s}}{V_1} \cdot \frac{\cos \beta_2}{\cos \beta_1} \cdot \left[1 - \left(\frac{\theta}{C} \right)_2 \frac{H_2 \delta}{\cos \beta_2} \right] \quad (\text{A2})$$

$$\left(\frac{\theta}{C} \right)_2 = \frac{\varepsilon}{1 - k_s \ln \frac{V_{\max,s}}{V_2}} \quad (\text{A3})$$

$$\bar{\omega}_0 = 2 \left(\frac{\theta}{C} \right)_2 \cdot \frac{\delta}{\cos \beta_2} \cdot \left(\frac{\cos \beta_1}{\cos \beta_2} \right)^2 \cdot \left(\frac{2H_2}{3H_2 - 1} \right) \cdot \left[1 - \left(\frac{\theta}{C} \right)_2 \cdot \frac{H_2 \delta}{\cos \beta_2} \right] \quad (\text{A4})$$

$$\bar{\omega} = c_3 |\alpha| + \bar{\omega}_0 (1 + e^{c_4 Ma_1}) \quad (\text{A5})$$

2) Banjac 模型

为了综合叶栅几何(弯角与最大厚度)、来流条件(来流马赫数与攻角)对叶栅损失的影响, Banjac 等人基于 Mises 数值计算得到的大量数据, 通过数据关联建立了叶栅损失模型。式(A1)~式(A6)给出了 Banjac 的模型的具体表达, 其中 t 、 C 分别代表代表叶型最大厚度和弦长, c_5 、 c_6 、 c_7 、 c_8 、 c_9 、 c_{10} 为经验系数(不同系列叶型, 经验系数不同), $\bar{\omega}_0$ 给出了参考攻角下的叶栅损失, $\Delta \bar{\omega}_t$ 和 $\Delta \bar{\omega}_\alpha$ 分别对叶栅厚度和攻角变化的影响进行了预估, α_0 为参考攻角的预测。

$$\bar{\omega}_0 = \exp(c_5 + c_6 \varphi + c_7 \delta + c_8 Ma_1) + c_9 \delta \quad (\text{A6})$$

$$\Delta \bar{\omega}_t = (c_5 - c_6 \delta) \left(c_8 - \frac{t}{C} \right) (c_9 Ma_1 - c_{10}) \quad (\text{A7})$$

$$\Delta \bar{\omega}_\alpha = 0.0002 \cdot 1.48^\alpha \cdot 0.09^\delta (1 + 0.01 \varphi) \quad (\text{A8})$$

$$\bar{\omega} = \bar{\omega}_0 + \Delta \bar{\omega}_t + \Delta \bar{\omega}_\alpha \quad (\text{A9})$$

$$\alpha_0 = (0.025 \delta - 0.06) \varphi \quad (\text{A10})$$