

基于数据驱动的复杂进气下风扇转子叶根损失模型

石凯凯^{1,3}, 鹿晗男^{1,3}, 潘天宇^{2,3}, 李秋实^{1,4}

(1. 北京航空航天大学 能源与动力工程学院, 北京 100191;

2. 北京航空航天大学 航空发动机研究院, 北京 100191;

3. 先进航空发动机协同创新中心, 北京 100191;

4. 西华大学 航空航天学院, 成都 610039)

摘 要: 发展了一种基于数据驱动的复杂进气下风扇转子叶根损失预测方法。提取了影响风扇转子叶根损失的关键气动参数作为输入变量, 熵损失系数作为输出参数; 采用计算耗时小的单叶片通道定常模型, 通过给定不同边界条件并进行组合来构建样本数据库, 使得数据库中样本点尽可能覆盖更广的复杂进气工况; 采用径向基神经网络训练并构建输入变量与输出参数之间的映射, 实现叶根损失的快速预测。计算结果表明: 该损失模型能够准确捕捉叶根损失的径向分布趋势, 并且相比于传统损失模型能够大幅提升预测精度。在不同流量、进气旋流以及畸变强度工况下, 叶根流动损失平均预测误差基本小于 10%。

关 键 词: 数据驱动; 损失模型; 神经网络; 复杂来流; 跨声速风扇

中图分类号: V231.3

文献标志码: A

A data-driven based hub region loss model of fan rotor under complex inflow condition

SHI Kaikai^{1,3}, LU Ha'nian^{1,3}, PAN Tianyu^{2,3}, LI Qiushi^{1,4}

(1. School of Energy and Power Engineering, Beihang University, Beijing 100191, China;

2. Research Institute of Aero-Engine, Beihang University, Beijing 100191, China;

3. Collaborative Innovation Center for Advanced Aero-Engine, Beijing 100191, China;

4. School of Aeronautics and Astronautics, Xihua University, Chengdu 610039, China)

Abstract: A data-driven based hub loss prediction model was developed for the fan rotor under complex inflow conditions. The key aerodynamic parameters were extracted as input parameters and the entropy loss as output parameter. The sample database was constructed based on computation-efficient single-blade-passage steady computational method. Different boundary conditions were set and combined to make the database samples cover a wide range of complex inflows as far as possible. The RBF neural network was used to construct the mapping between input and output parameters to realize rapid prediction of hub loss. Results showed that the loss model can accurately capture the radial distributions of hub loss and significantly improve the prediction accuracy. Meanwhile, the averaged loss prediction error in the rotor hub region was mostly lower than 10% under different inlet mass flow, inlet swirl angle and inflow distortion conditions.

收稿日期: 2022-09-30

基金项目: 中央高校基本科研业务费专项资金

作者简介: 石凯凯(1993—), 男, 博士生, 主要从事叶轮机气动力学方面的研究。E-mail: shikaikai2021@163.com

通信作者: 鹿晗男(1987—), 男, 讲师, 博士, 主要从事叶轮机气动力学方面的研究。E-mail: luhanan2013@163.com

引用格式: 石凯凯, 鹿晗男, 潘天宇, 等. 基于数据驱动的复杂进气下风扇转子叶根损失模型[J]. 航空动力学报, 2023, 38(7): 1637-1647. SHI Kaikai, LU Ha'nian, PAN Tianyu, et al. A data-driven based hub region loss model of fan rotor under complex inflow condition[J]. Journal of Aerospace Power, 2023, 38(7): 1637-1647.

Keywords: data-driven; loss model; neural network; complex inflow condition; transonic fan

传统的风扇/压气机气动设计通常是针对均匀来流工况开展的,然而,由于飞行器的特殊气动布局方式或在飞行过程中飞行工况的改变会使得动力系统面临特殊来流条件^[1-5],常常导致风扇/压气机工作于复杂非均匀来流工况,造成气动性能的显著下降^[6-9]。因此,为了更大程度地削弱复杂非均匀来流的负面作用,需在风扇/压气机的气动设计阶段就有效考虑非均匀来流的影响。

纵然,采用三维全叶片通道非定常 RANS (Reynolds-averaged Navier-Stokes) 数值模拟方法能够较为准确地评估风扇/压气机对复杂非均匀来流的气动响应,但是单次计算就需要消耗大量的时间和资源,无法适用于风扇/压气机的气动性能快速评估和迭代设计。因此,计算更为高效的低阶方法(如通流算法^[10]、激盘模型^[11]、体积力方法^[12]等)被发展并用于快速评估复杂来流工况下风扇/压气机的气动性能,这些低阶计算方法固然能够大幅降低计算时间消耗,但是对于性能的计算精度却极大程度上依赖于叶片气动损失的准确模化。也就是说,流动损失的准确预测对低阶计算方法的预测精度具有重要作用。

针对风扇/压气机内部的流动损失,近年来学者们开展了一系列关于损失模型的研究工作。他们首先将流动损失根据物理特征进行分类,然后基于物理简化或经验来建立不同气动和几何参数与流动损失之间的数理关联。目前比较常用的损失模型包括叶型损失模型^[13-14]、激波损失模型^[15-16]、二次流损失模型^[17-18]以及叶尖泄漏损失模型^[19-20],这些损失模型经过经验参数校准能够应用于风扇/压气机内的流动损失预测。

上述的基于物理简化或经验的损失模型在常规均匀来流的设计工况下往往能够展现出较好的预测能力,然而,针对复杂非均匀来流条件,压气机叶片往往严重偏离设计工况,叶片通道内部出现强烈的三维流动特征,相比于设计工况,气动和几何参数(损失模型输入参数)与流动损失(损失模型输出参数)之间往往呈现出较为复杂的多重非线性数学特征(近线性、低阶非线性和高阶非线性特征),同时,气动和几何输入参数的取值也超出了传统模型的标定范围。此时,传统的基于物理简化或经验的损失模型在预测复杂非均匀来流条件下风扇/压气机流动损失时就遇到了极

大挑战,严重制约了低阶快速计算方法的评估可信度。

实际上,借助于一定的物理认知或物理参数嵌入,基于数据驱动的机器学习算法通过大量有效的数据样本训练能够学习出复杂的数据关联特征,为复杂非均匀来流工况下风扇/压气机内部流动损失的高精度预测提供了可供尝试的一种思路。而且,前人也已经采用神经网络模型实现了二维叶型/翼型流场关键物理参数的捕捉^[21-22]以及风扇/压气机特性图谱的预测^[23-24],这就更进一步说明了基于数据驱动的机器学习算法在刻画输入参数与输出参数之间复杂非线性关系的巨大潜力。

为了克服传统的基于物理简化或经验的损失模型在预测复杂非均匀来流条件下风扇/压气机内部流动损失时的弊端,同时也考虑到基于数据驱动的机器学习算法在构建复杂非线性数据关联方面的重要潜力,本文以流动损失极易触发的风扇转子叶根为例,发展了一种基于数据驱动的复杂进气下风扇转子叶根流动损失预测模型。首先提取了对风扇/压气机转子叶根损失具有重要影响的气动参数作为输入变量,熵损失系数作为输出参数;然后,采用计算量相对较小的单叶片通道定常计算模型,通过给定不同的进出口边界条件并进行不同边界条件之间的组合来生成单个数据样本,使得数据库中样本点所形成的输入向量空间具有更加宽广的覆盖范围;接着,基于样本数据库,采用径向基函数神经网络建立模型输入参数与输出参数之间的非线性数据关联,实现流动损失的快速预测;最后,还对本文发展的损失模型进行了校验。本项研究的最终目的就是为复杂来流条件下风扇/压气机内部流动损失的快速准确预测提供一条可行的思路,从而服务于复杂工况下风扇/压气机气动性能的快速评估。

1 问题描述

在风扇/压气机的初始气动设计阶段,往往需要采用低阶计算方法(如通流算法、体积力法等)对气动性能进行快速评估,而低阶计算方法中又通常嵌入损失模型,流动损失的准确预测就对低阶计算方法的精度具有重要的影响。在复杂进气条件下,风扇/压气机转子叶根区域存在强烈的三维流动特征,叶片吸力面边界层在逆压力梯

度的作用下发生流动分离, 并发生径向扩展, 非设计工况时更为严重, 因此, 叶根流动损失的快速准确预测对于初始设计阶段评估风扇/压气机气动性能具有重要意义。

传统损失模型被广泛应用于均匀来流条件下的风扇/压气机内部损失预测, 但是在复杂进气工况下其预测偏差较大。图1给出了非均匀进气条件下传统损失模型与CFD数值模拟对转子叶根流动损失的预测结果对比, 其中, 该算例的非均匀进口来流特征取自边界层抽吸型(boundary layer ingestion, BLI)风扇畸变区中心位置的叶片进气条件, 传统的损失模型分别命名为H模型和B模型, 前者由叶型损失模型^[14]和Hearsey等^[18]提出的二次流损失模型线性叠加而成, 后者则由叶型损失模型和Banjac等^[17]线性叠加构成。从图中对比结果可见, 在10%叶高以上, 相比于CFD计算结果, 传统损失模型能够预测损失沿径向的变化趋势, 但是存在较大的绝对数值偏差, 而越靠近叶根区域(6%~10%叶高), 损失变化趋势和绝对数值都存在较明显的偏差。通过计算6%~28%叶高范围的质量流量平均误差(用 e_{ave} 表示), 其定义式如式(1)所示, 序号 i 从1~12表示6%~28%之间(间隔2%)的12个叶高, 结果显示H模型和B模型的平均预测误差分别为18.4%和42.5%, 说明传统损失模型在预测复杂进气条件下风扇/压气机叶根流动损失能力方面还存在不足。

$$e_{ave} = \frac{\sum_{i=1}^{12} |m_i \cdot (\hat{y}_i - y_i)|}{\sum_{i=1}^{12} m_i \cdot y_i} \quad (1)$$




图1 复杂进气下压气机近最高效率点叶根损失的传统损失模型预测结果

Fig. 1 Predicted hub flow loss by physics-based loss models at peak efficiency point under complex inflow conditions

2 基于数据驱动的损失模型构建

本部分内容主要是基于神经网络机器学习算法构建一种以气动参数为输入、熵损失系数为输出的复杂进气条件下风扇转子叶根流动损失快速预测模型。损失模型构建流程如图2所示, 主要分为3步, 分别为输入参数筛选与提取、样本数据库生成以及模型构建。




图2 基于数据驱动的损失预测模型构建流程图

Fig. 2 Framework of data-driven hub flow loss prediction model

2.1 输入参数筛选与提取

对于输入参数筛选与提取, 主要分为两部分: ①确定叶根区域对流动损失具有重要作用的关键气动参数; ②将关键气动参数沿叶高分布从流场中提取出来。

在逆压力梯度的作用下, 风扇/压气机转子叶根区域极易发生边界层分离, 并形成严重的分离

损失。因此, 分离流场特征参数的选取是构建叶根损失模型输入参数向量的关键, 本小节通过总结前人对于叶根分离流动的研究, 筛选出关联复杂进气下叶根区域流动损失的关键气动参数。

1) 从Lei等^[25]对叶栅角区流动分离的研究中可以发现, 边界层分离与流动的周向压力梯度和流向压力梯度关系密切, 而周向压力梯度和流

向压力梯度对于流动负荷的表征可以用扩压因子描述。

2) 通过 Benner 等^[26]对涡轮角区边界层分离的研究可以发现,收缩比($\cos \alpha_1 / \cos \alpha_2$)一定程度上能够描述叶根区域的流动堵塞状态,其中 α_1 为转子叶片进口气流角, α_2 为转子叶片出口气流角。

3) 从进气速度三角形的角度考虑,来流畸变导致轴向速度降低,此时周向速度基本不变,本文选择攻角来表征进气状态,这是由于攻角的大小与进口气流轴向速度和周向速度比值密切相关。

基于以上分析,本文最终选择了攻角、扩压因子以及收缩比作为损失模型的输入参数,同时,选取熵损失系数作为输出参数,其定义如下:

$$\zeta = \frac{T_1 \Delta S}{0.5 \cdot V_1^2} \quad (2)$$

其中 T_1 和 V_1 表示进口质量平均的静温和速度,

$$\mathbf{X} = [i_{4\%} \ i_{6\%} \ i_{8\%} \ \cdots \ i_{32\%} \ D_{4\%} \ D_{6\%} \ D_{8\%} \ \cdots \ D_{32\%} \ (\cos \alpha_1 / \cos \alpha_2)_{4\%} \ \cdots \ (\cos \alpha_1 / \cos \alpha_2)_{32\%}] \quad (3)$$

$$\mathbf{Y} = [\zeta_{6\%} \ \zeta_{8\%} \ \zeta_{10\%} \ \cdots \ \zeta_{28\%}] \quad (4)$$

2.2 样本数据库生成

对于样本数据库生成,本文以 BLI 畸变来流条件下的风扇为例,采用准定常假设,针对单叶片通道定常计算模型通过给定不同典型的边界条件及其组合使得损失模型输入向量空间能够尽可能覆盖更广的流场参数变化范围,即采用单叶片通道定常模型生成样本数据库来预测复杂畸变来流条件下风扇转子叶根的流动损失。

文中对于单个数据样本点的计算采用 Numeca Fine-Turbo EURANUS 求解器,其通过有限体积法对三维可压缩雷诺平均的 Navier-Stokes 方程进行求解,空间离散采用中心差分法,时间离散采用 4 阶显式龙格库塔法,工质选用理想气体,湍流模型选取一方程 Spalart-Allmaras 模型。研究对象选取跨声速风扇转子 NASA Rotor 67,计算域如图 3 所示,进口边界给定总温、总压和进气角度,出口边界给定平均静压。

计算网格的无关性校验结果如图 4 所示,单叶片通道计算模型分别选取了 36 万(网格 A)、68 万(网格 B)和 92 万(网格 C)3 种网格数目,圆圈代表绝热效率,方框表示总压比。从图中可以看到,随着网格数目从网格 A 增加至网格 B,绝热效率值增长速度较快,而网格数目从网格 B 增加至网格 C,绝热效率值增长速率明显减缓,维持

ΔS 为流体通过叶片通道的熵增量,采用流线追踪法获得^[27]。

由于压气机不同叶高位置的损失机制不同,比如叶尖区域以激波和泄漏损失为主,叶中区域以激波和叶型损失为主,叶根区域以二次流损失为主,损失源不同会使得预测模型的输入参数也不同。考虑到 6% 叶高以下涉及到边界层内流动,28% 叶高以上二次流对损失的影响大幅减弱,叶型损失为主要损失源,而 6%~28% 叶高范围内二次流损失占主导,因此,本文构建了 6%~28% 叶高范围内的损失预测模型。同时,为了使输入向量空间能够覆盖尽可能大的参数变化范围,输入向量由进气攻角、扩压因子和收缩比在 4%~32% 叶高范围内的分布值(取值间隔 2% 叶高)组成,如式(3)所示,同时,输出向量由熵损失系数在 6%~28% 叶高范围内的分布值(取值间隔 2% 叶高)组成,如式(4)所示。

在一个稳定水平。对于总压比而言,随着网格数目从网格 A 增加到网格 B,总压比值明显降低,




图 3 跨声速风扇转子 NASA Rotor 67 单通道计算域
Fig. 3 Computational domain of the single-passage model of transonic fan rotor NASA Rotor 67




图 4 网格无关性验证

Fig. 4 Independence validation of grid numbers

随后网格数目从网格 B 增加至网格 C, 总压比基本维持不变。综合考虑计算时间和计算精度, 本文最终选取单叶片通道计算模型网格数为 68 万。

为了校验数值方法的可靠性, 首先将 Rotor 67 特性图谱的数值计算结果与公开实验数据^[28]进行了对比, 如图 5 所示。从图中可以看到, 随着流量的变化, 数值模拟获得的等熵效率和总压比的变化趋势与绝对量值都与实验数据吻合较好。




图5 风扇转子特性图谱对比

Fig. 5 Comparison of fan rotor performance maps

进一步, 图 6 还对比了风扇转子出口静压和总温的径向分布结果, 可以看出, 数值模拟结果能够较好地捕捉到出口静压和总温的径向变化趋势, 整体来说与实验数据吻合较好, 这就更进一步验证了本文所选取的数值计算方法具有较好的准确性和可靠性。

为了使模型输入向量空间(由进气攻角、扩压因子和收缩比参数组成)能够获得尽可能大的覆盖范围, 本文针对单叶片通道定常计算模型给定不同的畸变强度、进气旋流角度、出口反压以及三者的组合。




图6 风扇转子出口静压和总温的径向分布对比

Fig. 6 Radial distribution comparison of static pressure and total temperature at the fan rotor outlet

1) 三组径向总压畸变(如图 7 所示, 横轴为无量纲进口总压, 其中 $p_{t,ref}$ 为标准大气压 101 325 Pa, 纵轴为叶高), 总压畸变强度(DA, 量符号记为 S_{DA})分别为 0、3.7% 和 11.1%, 总压畸变强度定义如下:

$$S_{DA} = (p_{t,max} - p_{t,min}) / p_{t,ave} \quad (5)$$

其中 $p_{t,max}$ 和 $p_{t,min}$ 分别为进口截面总压的最大值和最小值, $p_{t,ave}$ 为进口平均总压。




图7 进口总压径向分布

Fig. 7 Radial distributions of total pressure at inlet

2) 11 组进气旋流角度分别为 0° 、 $\pm 2^\circ$ 、 $\pm 4^\circ$ 、 $\pm 6^\circ$ 、 $\pm 8^\circ$ 、 $\pm 10^\circ$ 。

3) 给定计算域的出口压力, 以此来改变转子负荷。

通过上述条件的任意组合, 最终获得了 387 个数据样本点。

2.3 损失模型构建

本文中机器学习算法选用径向基神经网络,

其具有结构简单、学习收敛速率快、对复杂数学关系逼近精度高的特点^[29]。径向基神经网络由输入层、隐藏层以及输出层 3 部分构成,如图 8 所示,工作原理为对于 M 维输入向量 $\mathbf{X}_k=[X_{k1} \ X_{k2} \ \cdots \ X_{kM}]$,在隐藏层中通过 N 个 $\mathbf{C}_i=[C_{i1} \ C_{i2} \ \cdots \ C_{iM}]$ 为中心的高斯函数进行非线性变换,在输出层经过线性变化,权值 $\mathbf{W}_i=[w_{i1} \ w_{i2} \ \cdots \ w_{iJ}]$,偏置 $\mathbf{B}=[b_1 \ b_2 \ \cdots \ b_J]$,映射到 J 维输出向量 $\mathbf{Y}_k=[Y_{k1} \ Y_{k2} \ \cdots \ Y_{kJ}]$ 的过程,其中输入向量 $\mathbf{X}_k$ 和输出向量 $\mathbf{Y}_k$ 的下标“ k ”表示第 k 个输入或输出向量,中心向量 $\mathbf{C}_i$ 以及权值向量 $\mathbf{W}_i$ 的下标“ i ”表示第 i 个中心点或权值向量。




图 8 径向基(RBF)神经网络示意图

Fig. 8 Schematic diagram of radial basis function (RBF) neural network

本文选取的径向基神经网络的数学表述形式可以表达为

$$Y_{kj} = \sum_{i=1}^N w_{ij} \Phi(X_k, C_i) + b_j \quad (j = 1, 2, \dots, J) \quad (6)$$

其中 $\Phi(X_k, C_i) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{X}_k - \mathbf{C}_i\|^2\right)$ 。在上述径向基神经网络运算过程中有 3 组未知量有待确定,分别为基函数中心 $\mathbf{C}_i$ 、基函数标准差 σ 以及输出层的权值和偏置 $[\mathbf{W}_i; \mathbf{B}]$ 。径向基神经网络通过训练数据样本来确定以上未知量的具体值,首先通过 K-means 聚类方法确定隐藏层基函数的中心 $\mathbf{C}_i$,然后,用各个中心之间的距离按照式(7)确定基函数的标准差 σ

$$\sigma_i = \lambda \min_{j=1 \sim N} \|\mathbf{C}_i - \mathbf{C}_j\| \quad (i = 1 \sim N) \quad (7)$$

文中重叠系数选取为 $\lambda = 2 \times 10^5$ 。最后,输出层的权值和偏置通过求解线性方程组获得。这样,在给定输入向量/输入参数的情况下就能够获得损失的输出值。

3 预测性能验证

3.1 随机取样验证

本文从 387 个样本点中随机选取了 20 个样本点(约为样本总数的 5%)进行模型预测精度分析,剩余的 367 个样本点用来训练预测模型。随机取样的预测结果如图 9 所示,横轴代表随机样本序号,纵轴为轮毂区域 6%~28% 叶高范围内熵损失系数的质量平均值,采用 $\zeta_{\text{hub-ave}}$ 表示,其定义式如下:

$$\zeta_{\text{hub-ave}} = \frac{\sum_{i=1}^{12} m_i \cdot \zeta_i}{\sum_{i=1}^{12} m_i} \quad (8)$$

从图 9 可以看出,针对随机选取的样本点,本文的损失模型能够准确预测叶根损失值,评估结果表明,随机选取的 20 个测试样本的叶根损失平均预测误差为 5.87%。




图 9 随机取样预测结果

Fig. 9 Predicted result of random samples

3.2 均匀进气不同流量工况验证

进一步,还对比分析了均匀来流设计转速情况不同流量工况(近堵塞点至近失速点)下本文损失模型预测结果与 CFD 计算结果,如图 10 所示,其中横坐标为进气攻角,纵坐标为叶根质量平均的熵损失系数值。可见,随着压气机的运行工况从近堵塞点移至近最高效率点,叶根损失快速下降,然后从近最高效率工况至近失速工况,叶根损失不再下降。通过对比可以得知本文的损失预测模型能够较好地捕捉到叶根流动损失随工作流量的变化趋势,而且,从近堵塞工况至近失速工况,不同工况点的转子叶根流动损失的平均预测误差为 $e_{\text{ave}} = \{6.05\%, 7\%, 7\%, 6.1\%, 3.6\%, 1.3\%, 3.1\%, 4.5\%, 5.8\%, 6.8\%, 6.9\%, 4.7\%, 2.1\%, 3.7\%\}$,均不超过 7%。




图 10 均匀进气时不同流量工况下损失模型预测结果与 CFD 结果对比

Fig. 10 Comparison between predicted results and CFD results of loss model at different mass flow conditions under clean inflow

图 11 对比了 3 种典型流量工况(近堵塞(NC)点、最高效率(PE)点和近失速(NS)点)下熵损失系数在靠近叶根区域不同叶高位置的径向分布结果。其中横轴为熵损失系数,纵轴为不同叶高位置。从图中可以看到,相比于传统损失模型(H模型和 B 模型),本文的损失预测模型能够更加准确地捕捉 3 种典型流量工况下损失沿叶高的变化趋势。

3.3 不同畸变强度进气工况验证

选取了进气畸变强度 $S_{DA}=7.5\%$ 和 $S_{DA}=12.7\%$ 的两种径向总压畸变进气,用来校验本文损失模型对不同畸变强度下转子叶根损失的预测效果。进口总压径向分布如图 12 所示,其中虚线为要验证的畸变进气总压分布曲线,实线为构建数据库样本所选择的畸变进气总压分布曲线。

图 13 给出了畸变进气($S_{DA}=7.5\%$)不同流量工况(近堵塞点至近失速点)下本文的损失模型预




图 11 不同典型流量工况下熵损失系数径向分布

Fig. 11 Radial distributions of entropy loss coefficient at different mass flow conditions




图 12 不同进口径向总压畸变分布

Fig. 12 Radial distributions of different total pressure inflow distortions




图 13 畸变进气($S_{DA}=7.5\%$)不同流量工况下损失系数对比

Fig. 13 Comparison of loss coefficient at different mass flow conditions with inflow distortion ($S_{DA}=7.5\%$)

测结果与 CFD 结果的对比。由图中可以看出,从近堵塞点至近失速点,随着攻角增加,熵损失系数数值呈现出先快速下降、而后缓慢上升的变化趋势。与 CFD 结果相比,本文的损失预测模型较准确地捕捉到了这种变化趋势,并且所有工况下叶根损失的预测误差全部小于 7%。

图 14 还给出了畸变进气($S_{DA}=7.5\%$)下 3 个典型流量工况(近堵塞点、最高效率点和近失速点)损失系数的径向分布对比结果。从图中可以看到,相比于传统损失模型,本文的损失模型预测结果无论在径向变化趋势还是在绝对量值方面都与 CFD 计算结果吻合较好。




图 14 畸变进气($S_{DA}=7.5\%$)典型流量工况下损失系数径向分布对比

Fig. 14 Radial distributions comparison of loss coefficient at typical mass flow conditions with inflow distortion ($S_{DA}=7.5\%$)

图 15 为畸变进气($S_{DA}=12.7\%$)不同流量工况(近堵塞点至近失速点)下本文的损失模型预测结果与 CFD 结果的对比。从图中可以看到,本文损失模型的预测结果与 CFD 结果变化趋势一致,吻合较好。关于预测精度,近失速点预测误差为 16%,其余工况点预测误差全部小于 10%。

图 16 给出了畸变进气($S_{DA}=12.7\%$)下 3 个典型流量工况(近堵塞点、最高效率点和近失速点)损失系数的径向分布对比结果。从图中可以看到,




图 15 畸变进气($S_{DA}=12.7\%$)不同流量工况下损失系数对比

Fig. 15 Comparison of loss coefficient at different mass flow conditions with inflow distortion ($S_{DA}=12.7\%$)

与传统损失模型的预测结果相比,本文损失模型给出的损失沿径向分布趋势和绝对量值都与 CFD 计算结果较为一致。

3.4 不同旋流进气工况验证

图 17 给出了近最高效率点处 3 种进气条件($S_{DA}=0$ 、 $S_{DA}=7.5\%$ 、 $S_{DA}=12.7\%$)不同进气旋流角条件下本文损失模型预测结果与 CFD 结果的对比。从图中可以看到,3 种进气条件下本文的损失模型能够较为准确地预测出损失随着旋流角度的变化趋势,其中畸变强度 $S_{DA}=12.7\%$ 下预测误差略微偏大,整体平均误差为 7.4%。

图 18 为进气畸变强度 $S_{DA}=7.5\%$ 不同旋流角度条件下本文损失模型与 CFD 关于叶根损失径向分布的对比结果。从图中可以看到,在 3 种旋流角度条件下,本文的损失模型能够准确地预测叶根流动损失沿径向的变化趋势。

3.5 不同转速下损失预测结果验证

本小节校验了损失模型在不同转速(Ω)工况时的预测效果,如图 19 所示。从图中可以看到,在 $90\%\Omega \sim 105\%\Omega$ 范围内,损失随流量变化趋势的预测结果与 CFD 结果吻合较好,进一步, $95\%\Omega$ 和 $105\%\Omega$ 下叶根损失平均预测误差分别为 11.02% 和 10.23%,而 $90\%\Omega$ 下平均误差相对偏大,其值




图 16 畸变进气($S_{DA}=12.7\%$)典型流量工况下损失系数径向分布对比Fig. 16 Radial distributions comparison of loss coefficient at typical mass flow conditions with inflow distortion ($S_{DA}=12.7\%$)

图 17 3 种畸变强度不同进气旋流下本文损失模型预测结果与 CFD 结果对比

Fig. 17 Comparisons of predicted results and CFD results of loss model in this paper under different inlet swirl flows for three distortion intensities

图 18 畸变强度 $S_{DA}=7.5\%$ 近最高效率点工况不同旋流角条件下叶根损失的径向分布对比Fig. 18 Comparisons of radial distributions of hub loss for different swirl flow angles at peak efficiency point under inflow distortion intensity $S_{DA}=7.5\%$




图19 不同转速下本文损失模型对叶根损失的预测结果与CFD结果的对比

Fig. 19 Comparisons of hub loss between RBFnn and CFD results under different blade rotating speeds

为18.6%。可见,在风扇常用工作转速范围内,本文损失模型仍具有较好的预测效果。

4 结 论

为了克服传统的基于物理简化或经验的损失模型在预测复杂非均匀来流情况下风扇/压气机内部流动损失时的弊端,结合数据驱动机器学习算法在建立模型输入和输出参数之间复杂非线性关联方面的优势,本文以风扇转子叶根损失预测为例,发展了一种基于数据驱动的复杂来流下风扇转子叶根流动损失预测方法,并获得如下主要结论:

本文发展的损失模型能够准确预测不同流量、进气旋流和畸变强度等工况下的叶根流动损失。其中,在不同流量(负荷)和旋流工况下,叶根流动损失平均预测误差都小于或接近7%;对于不同畸变强度情况,相对弱畸变强度下叶根损失的预

测误差全部小于7%,相对强畸变强度下只有近失速点叶根损失的预测误差为16%,其余工况点预测误差全部小于10%,同时,本文的模型还能够较好地捕捉叶根损失的径向变化趋势。

在 $90\%\Omega \sim 105\%\Omega$ 范围内,本文的损失模型能够较好地捕捉到叶根损失随流量的变化趋势,同时,在 $95\%\Omega$ 和 $105\%\Omega$ 工况下,叶根流动损失的平局预测误差分别为11.02%和10.23%。

参考文献:

- [1] KO A, LEIFSSON L, SCHETZ J, et al. MDO of a blended-wing-body transport aircraft with distributed propulsion[R]. AIAA-2003-6732, 2003.
- [2] KIM H, LIOU M S. Flow simulation of N2B hybrid wing body configuration[R]. AIAA-2013-0221, 2003.
- [3] LIU Lei, CHEN Fu, CHEN Huanlong, et al. Numerical investigation on impact of a flush-mounted air intake exit distortion to the rear fan performance[C]//Proceedings of ASME Turbo Expo. Düsseldorf, Germany: ASME, 2014: 1-9.
- [4] VUNNAM K, HOOVER R. Modeling of inlet distortion using a combined turbofan and nacelle inlet model during crosswind and low speed forward operation[C]//Proceedings of ASME Turbo Expo. Vancouver, Canada: ASME, 2011: 371-380.
- [5] BEN SGHAIR T, MEHDI A, PACHIDIS V, et al. A parametric numerical study of the effects of inlet swirl distortion on a transonic compressor stage[C]//Proceedings of ASME Turbo Expo. San Antonio, US: ASME, 2013: 1-11.
- [6] LONGLEY J P, GREITZER E M. Inlet distortion effects in aircraft propulsion system integration[R]. Neubiberg, Germany: NASA Steady and Transient Performance Prediction of Gas Turbine Engines, 1992.
- [7] 李茂义, 陆亚钧, 弓志强, 等. 进口畸变条件下轴流压气机转子内流的PIV研究[J]. 航空动力学报, 2006, 21(3): 461-466. LI Maoyi, LU Yajun, GONG Zhiqiang, et al. PIV investigation of the internal flow in an axial flow compressor rotor under inlet distortion[J]. Journal of Aerospace Power, 2006, 21(3): 461-466. (in Chinese)
- [8] SUN Peng, GAO Haiyang, ZHONG Jingjun, et al. Study on the influence of total pressure distortion on end wall flow field in a supersonic compressor[C]//Proceedings of ASME Turbo Expo. San Antonio, US: ASME, 2013: 1-8.
- [9] PAGE J H, HIELD P, TUCKER P G. Effect of inlet distortion features on transonic fan rotor stall[J]. Journal of Turbomachinery, 2018, 140(7): 071008.1-071008.11.
- [10] VALENCIA E, HIDALGO V, NALIANDA D, et al. Discretized Miller approach to assess effects on boundary layer ingestion induced distortion[J]. Chinese Journal of Aeronautics, 2017, 30(1): 235-248.
- [11] HALL D K, GREITZER E M, URANGA A, et al. Inlet flow distortion in an advanced civil transport boundary layer ingesting engine installation[J]. Journal of Turbomachinery, 2022, 144(10): 101002.1-101002.11.
- [12] HALL D K, GREITZER E M, TAN C S. Analysis of fan stage conceptual design attributes for boundary layer ingestion[J]. Journal of Turbomachinery, 2017, 139(7): 071012.1-071012.10.
- [13] LIEBLEIN S. Loss and stall analysis of compressor cascades[J].

- Journal of basic engineering*, 1959, 81(3): 387-397.
- [14] AUNGIER R H. Axial-flow compressors: a strategy for aerodynamic design and analysis[M]. New York: ASME Press, 2003.
- [15] BLOCH G S, COPENHAVER W W, O'BRIEN W F. A shock loss model for supersonic compressor cascades[J]. *Journal of Turbomachinery*, 1999, 121(1): 28-35.
- [16] BOYER K M, O'BRIEN W F. An improved streamline curvature approach for off-design analysis of transonic axial compression systems[J]. *Journal of Turbomachinery*, 2003, 125(3): 475-481.
- [17] BANJAC M, PETROVIC M V, WIEDERMANN A. Secondary flows, endwall effects, and stall detection in axial compressor design[J]. *Journal of Turbomachinery*, 2015, 137(5): 051004.1-051004.12.
- [18] HEARSEY R M. Program HT0300[R]. Chicago, US: the Boeing Company, 1994.
- [19] LAKSHMINARAYANA B. Methods of predicting the tip clearance effects in axial flow turbomachinery[J]. *Journal of Basic Engineering*, 1970, 92(3): 467-480.
- [20] DENTON J D. Loss mechanisms in turbomachines[J]. *Journal of Turbomachinery*, 1993, 115(4): 621-656.
- [21] HUI Xinyu, BAI Junqiang, WANG Hui, et al. Fast pressure distribution prediction of airfoils using deep learning[J]. *Aerospace Science and Technology*, 2020, 105: 105949.1-105949.12.
- [22] PAZIREH S, DEFOE J J. A new loss generation body force model for fan/compressor blade rows: an artificial-neural-network based methodology[J]. *International Journal of Turbomachinery, Propulsion and Power*, 2021, 6(1): 1-23.
- [23] FEI Jingzhou, ZHAO Ningbo, SHI Yong, et al. Compressor performance prediction using a novel feed-forward neural network based on Gaussian kernel function[J]. *Advances in Mechanical Engineering*, 2016, 8(1): 1-14.
- [24] ZHAO Yongping, HU Qiankun, XU Jianguo, et al. A robust extreme learning machine for modeling a small-scale turbojet engine[J]. *Applied Energy*, 2018, 218: 22-35.
- [25] LEI V M, SPAKOVSKY Z S, GREITZER E M. A criterion for axial compressor hub-corner stall[J]. *Journal of Turbomachinery*, 2008, 130(3): 031006.1-031006.10.
- [26] BENNER M W, SJOLANDER S A, MOUSTAPHA S H. An empirical prediction method for secondary losses in turbines: Part II a new secondary loss correlation[J]. *Journal of Turbomachinery*, 2006, 128(2): 281-291.
- [27] YANG Zhe, LU Hanan, PAN Tianyu, et al. Numerical investigation on the influences of boundary layer ingestion on tip leakage flow structures and losses in a transonic axial-flow fan[J]. *Journal of Fluids Engineering*, 2021, 143(11): 111207.1-111207.14.
- [28] STRAZISAR A J, WOOD J R, HATHAWAY M D, et al. Laser anemometer measurements in a transonic axial-flow fan rotor[R]. NASA-TP-2879, 1989.
- [29] 阮晓钢. 神经计算科学: 在细胞的水平上模拟脑功能[M]. 北京: 国防工业出版社, 2006.

(编辑: 王碧琚)