

# 基于神经网络的重型燃气轮机压气机叶型性能预测

刘岩松<sup>1</sup>, 阙晓斌<sup>2</sup>, 吴帅<sup>2</sup>, 虞培祥<sup>1,3</sup>

(1. 上海交通大学机械与动力工程学院, 上海 200240; 2. 中国联合重型燃气轮机技术有限公司, 北京 100016;  
3. 上海交通大学燃气轮机与民用航空发动机教育部工程研究中心, 上海 200240)

**摘要:**为解决重型燃气轮机压气机定制叶型设计参数多,传统设计方法效率低的问题,通过人工神经网络方法建立了快速预测重型燃气轮机压气机定制叶型损失和落后角的代理模型。在该模型中,根据重型燃气轮机压气机定制叶型造型方法和S1分析工具建立初始数据库。为进一步提高计算效率,对叶型设计参数进行了敏感度分析,识别叶型设计关键参数并对代理模型降维。结果表明:代理模型具有良好的预测精度,且预测时间相较传统设计方法大幅降低;针对关键参数对代理模型降维可以降低训练成本,增强模型合理性,提高了代理模型在叶型优化设计中的应用价值。

**关键词:**损失系数;落后角;代理模型;神经网络;重型燃气轮机;压气机叶型

中图分类号:V231.3 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2025.05.003

[引用本文格式]刘岩松,阙晓斌,吴帅,等.基于神经网络的重型燃气轮机压气机叶型性能预测[J].热能动力工程,2025,40(5):21-31. LIU Yansong, QUE Xiaobin, WU Shuai, et al. Prediction of heavy-duty gas turbine compressor blade performance based on neural network[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(5): 21-31.

## Prediction of Heavy-duty Gas Turbine Compressor Blade Performance based on Neural Network

LIU Yansong<sup>1</sup>, QUE Xiaobin<sup>2</sup>, WU Shuai<sup>2</sup>, YU Peixiang<sup>1,3</sup>

(1. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai, China, Post Code: 200240;

2. China United Gas Turbine Technology Co., Ltd., Beijing, China, Post Code: 100016; 3. Gas Turbine and Civil Aviation Engine Engineering Research Center of the Ministry of Education, Shanghai Jiao Tong University, Shanghai, China, Post Code: 200240)

**Abstract:** In order to solve the problem of low efficiency of traditional design methods due to the multiple design parameters for customized blade of heavy-duty gas turbine compressor, a surrogate model for quickly predicting the loss and deviation angle of customized blade of heavy-duty gas turbine compressors was established based on artificial neural networks. In this model, an initial database was established based on the customized blade profiling method for heavy-duty gas turbine compressors and the S1 analysis tool. To further improve computational efficiency, sensitivity analysis was conducted on blade design parameters, identifying key parameters of blade design and reducing the dimensionality of the surrogate model. The results show that the surrogate models have good prediction accuracy, and the prediction time is significantly reduced compared to traditional design methods. Reducing the dimensionality of surrogate models based on key parameters can lower training costs, enhance model rationality, and improve the ap-

收稿日期:2024-11-28; 修订日期:2025-01-15

基金项目:国家科技重大专项(J2019-II-0005-0025, J2019-II-0004-0024, J2019-II-0017-0038), 航空发动机及燃气轮机基础科学中心项目(P2022-B-V-004-001)

**Fund-supported Project:** National Science and Technology Major Project (J2019-II-0005-0025, J2019-II-0004-0024, J2019-II-0017-0038); Science Center for Gas Turbine Project (P2022-B-V-004-001)

作者简介:刘岩松(2001-),男,上海交通大学硕士研究生.

通信作者:虞培祥(1986-),男,上海交通大学助理研究员.

plication value of surrogate models in blade design and optimization.

**Key words:** loss coefficient, deviation angle, surrogate model, neural network, heavy-duty gas turbine, compressor blade profile

## 引 言

重型燃气轮机作为一种高效的能源转换设备,是一个国家综合工业能力的集中体现<sup>[1]</sup>。重型燃气轮机具有雷诺数高、湍流强度大、运行工况复杂等特点。作为重型燃气轮机的核心部件之一,压气机的性能对整个燃气轮机的运行至关重要。

上世纪 70 年代,以三元流理论<sup>[2]</sup>为基础的压气机准三维设计体系逐渐建立。重型燃气轮机压气机的设计流程包括一维中线设计、S2 流面通流设计、S1 流面叶型设计、S2 通流校验分析和三维气动验证。在设计过程中,为保证 S1 流面的压气机叶型具有优良的气动性能,且与通流条件匹配良好,需要准确地评估叶型在不同攻角下的总压损失和落后角。在早期的压气机设计中,国外学者通过开展叶栅吹风试验积累了大量叶型气动性能的数据,并总结出了诸多被广泛应用的叶型损失模型和落后角模型<sup>[3-7]</sup>。然而,进行一次叶栅试验的成本较高,能够进行试验的叶型有限,总结出的叶型损失和落后角经验模型适用范围通常较窄,难以应用于其他种类叶型。

近年来,随着计算能力的不断发展,通过计算流体力学(Computational Fluid Dynamics, CFD)方法计算压气机叶型性能从而指导设计的方法得到了广泛应用<sup>[8]</sup>。然而重型燃气轮机压气机内部流动复杂,CFD 方法计算耗时长、成本高,难以在设计过程中快速进行叶型优化迭代。因此,在目前的压气机设计流程中,叶型损失和落后角的计算仍以经验模型为主,CFD 方法主要用于后期验证。

在设计重型燃气轮机压气机叶型时,不同的设计参数对叶型性能的影响不同,这也决定了叶型损失和落后角的预测问题是一个多维度参数的非线性问题。机器学习技术的发展与兴起为我们提供了预测压气机叶型损失和落后角的新思路,近年来有大量学者针对这方面内容开展研究。Schmitz 等人<sup>[9]</sup>针对一类重型燃气轮机定制叶型建立了一个  $10^6$  量

级的叶型数据库,并基于神经网络方法建立了该类叶型的损失和落后角代理模型。费腾等人<sup>[10]</sup>基于大量多圆弧叶型的数值模拟结果建立了叶栅性能数据库,并采用神经网络建立了叶栅基准损失和落后角模型,发现代理模型对提高压气机性能预测效果有积极影响。石凯凯等人<sup>[11]</sup>以转子叶根为研究对象,基于径向基神经网络建立了一种复杂进气条件下的损失预测模型,该模型可以快速预测叶根损失,预测精度相比传统经验模型有较大提高。杜周等人<sup>[12]</sup>以 NACA65 系列叶型为例,基于深度学习方法对压气机叶型在非设计工况下的损失和落后角进行了预测,发现代理模型具有速度快、预测准确的特点。陈晨铭等人<sup>[13]</sup>通过多种优化方法针对轴流风扇叶型 W65 开展了气动优化,发现人工神经网络方法的优化误差较小。

机器学习方法在传统叶型性能预测方面得到了广泛应用,传统叶型通常设计参数较少,而重型燃气轮机压气机的定制叶型设计参数多,针对其构建的代理模型具有数据样本量极大、计算和训练成本较高的问题,难以应用于工程实际。目前,重型燃气轮机压气机的叶型设计仍以基于 S1 分析的传统方法为主。本文针对设计自由度较高的重型燃气轮机压气机定制叶型建立了叶型数据库,通过人工神经网络方法建立了叶型损失和落后角代理模型,并基于代理模型对叶型设计参数进行了敏感度分析。根据分析结果识别叶型关键设计参数并对代理模型进行降维简化,最后通过某先进燃气轮机压气机叶型对代理模型的预测时间和精度进行了验证。

## 1 叶型数据库建立

### 1.1 数据库建立流程

利用神经网络方法构建叶型损失和落后角的代理模型,需要叶型计算数据作为训练样本。本文所用训练数据库构建流程如图 1 所示。首先,根据重型燃气轮机压气机定制叶型造型方法的几何设计参数建立样本空间并进行设计参数采样,将采样后的参数输入叶型造型程序批量生成叶型,再通过叶型

性能计算工具得到叶型在不同攻角下的总压损失和落后角的特性曲线,最后整理形成叶型数据库。

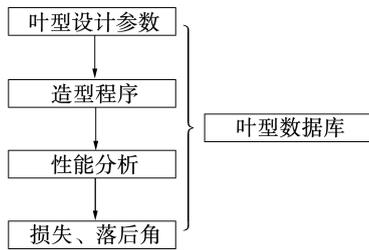


图1 叶型数据库计算流程

Fig. 1 Calculation process of blade database

## 1.2 叶型采样与数据库建立

本文采用文献[14]中的重型燃气轮机压气机定制叶型造型方法进行叶片造型,该方法可以直接绘制叶型型线。叶型前缘通过椭圆函数计算生成,尾缘采用圆弧设计,吸力面与压力面通过样条曲线控制保证叶型的光滑性和连续性,最大厚度等参数可以使绘制出的叶型满足重型燃气轮机的设计需求。该方法共包含13个设计参数,设计参数较多,叶型设计自由度较高,文献[14]中使用这种方法对部分压气机叶型进行了复现,证明了该方法的设计自由度和有效性。图2给出了叶型造型示意图及设计参数,包括安装角 $\beta_s$ 、进口几何角 $\beta_1$ 、出口几何角 $\beta_2$ 、前缘楔角 $\gamma_1$ 、尾缘楔角 $\gamma_2$ 及相对前缘半径 $R_1$ 、前缘椭圆率 $E_1$ 、相对尾缘厚度 $T_1$ 、吸力面控制点坐标 $(X_6, Y_6)$ 、压力面控制点坐标 $(X_2, Y_2)$ 、相对最大厚度 $T_m$ 。在造型时首先绘制平放的叶型,叶型前缘位于原点,生成完整叶型后根据安装角对叶型进行旋转操作,使叶型满足所在工况设计需求。

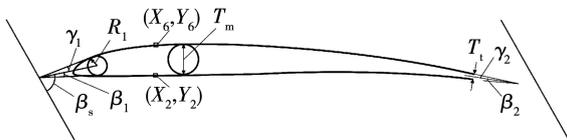


图2 叶型造型及设计参数

Fig. 2 Schematic diagram of blade profile and design parameters

本文计算工况为某重型燃气轮机亚音级中截面叶型工作工况,雷诺数为 $4.6 \times 10^6$ ,进口马赫数为0.68,轴向速度密度比为1.05。根据前期设计经

验,将安装角固定为 $46.9^\circ$ ,作为造型后的旋转角度;压力面控制点纵坐标默认为0;其余设计参数的采样范围在基准参数的基础上放开约50%建立设计空间,部分关键设计参数的采样范围放开约100%以增加数据库的样本自由度。设计参数与采样范围如表1所示。

表1 叶型设计参数与采样范围

Tab. 1 Design parameters and sampling range of blade profile

参数	采样范围
安装角 $\beta_s/(^\circ)$	46.9
进口几何角 $\beta_1/(^\circ)$	53~61
出口几何角 $\beta_2/(^\circ)$	39~41
前缘楔角 $\gamma_1/(^\circ)$	14~16
尾缘楔角 $\gamma_2/(^\circ)$	2~4
相对前缘半径 $R_1$	0.01~0.03
前缘椭圆率 $E_1$	1~2
相对尾缘厚度 $T_1$	0.01~0.014
吸力面控制点横坐标 $X_6$	0.1~0.5
吸力面控制点纵坐标 $Y_6$	0.05~0.12
压力面控制点横坐标 $X_2$	0.1~0.4
压力面控制点纵坐标 $Y_2$	0
相对最大厚度 $T_m$	0.06~0.1

表1中的非角度设计参数均除以弦长进行了无量纲化。基于拉丁超立方采样方法在设计空间内共采样得到4000组设计参数,以保证样本点尽可能均匀地分布在设计空间内。将叶型设计参数输入造型程序批量生成叶型并通过MISES进行性能计算,计算时调整进口气流角得到叶型在不同攻角下的性能曲线,计算完成后整理形成叶型数据库。

## 1.3 分析工具

本文所使用的叶型性能计算工具为S1流面分析工具(Multiple blade Interacting Stream Tube Euler Solver, MISES)<sup>[15-16]</sup>,该求解器采用欧拉无粘方程与边界层积分方程耦合的方式求解流场,并且引入了AGS(Abu-Ghannam and Shaw)转捩模型以考虑流动转捩。该求解器已经被广泛应用于叶型性能计算与压气机叶型设计中<sup>[17-19]</sup>,Kusters等人<sup>[20]</sup>已通过试验对MISES进行了校验。

本文通过某F级重型燃气轮机压气机亚音叶

型叶栅试验结果对 MISES 进行了校验,该叶型安装角为  $48^\circ$ ,稠度为 1.16。图 3 给出了设计状态下叶表马赫数沿弦长方向分布的试验值与 MISES 计算值的对比,横坐标  $x/c$  为归一化轴向弦长位置。可以看出,MISES 计算的  $Ma$  分布结果与试验结果均吻合较好,仅在压力面有较小偏差。图 4 给出了不同攻角下的叶型损失特性的试验值与 MISES 计算值的对比。可以看出,MISES 计算的总压损失系数与试验结果整体吻合较好,仅在大攻角处计算结果稍有偏高。

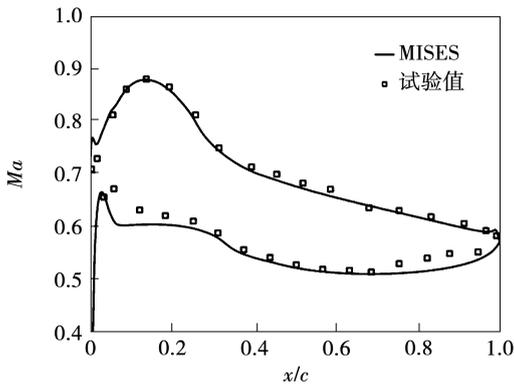


图 3 叶型表面马赫数分布的试验值与 MISES 计算值对比  
Fig. 3 Comparison between experimental result and MISES calculation result of Mach number distribution on airfoil surface

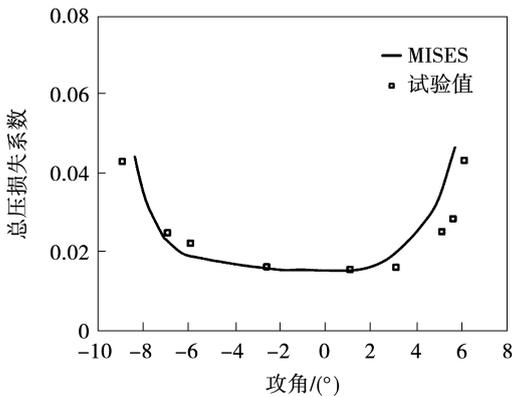


图 4 总压损失系数-攻角的试验值与 MISES 计算值对比  
Fig. 4 Comparison between experimental result and MISES calculation result of total pressure loss coefficient- incidence angle

## 2 数据处理与模型建立

### 2.1 数据预处理

数据样本的质量对神经网络的训练结果有至关

重要的影响,有效地筛选数据并剔除噪声数据能显著提高神经网络的训练效果。本文在进行神经网络训练,对数据库中的叶型计算数据进行了如下预处理:

(1) 在进行采样与造型时,由于叶型参数的随机组合,数据样本中会出现不满足设计要求的叶型,部分样本在输入 MISES 求解器计算时会出现不收敛的结果,在训练时需要剔除这部分叶型。

(2) 为了提高叶型损失特性曲线的宽度与精度,设定较大的进口气流角范围,并每隔  $0.5^\circ$  进行一次计算。但在大攻角状态下叶型表面通常存在较大尺度的流动分离,此时 MISES 的精度降低,计算得到的损失系数已失去参考价值。在工程应用中,压气机通常以二倍最小损失准则评估失速边界和堵塞边界,而对于压气机常用叶型,其最小损失通常不会超过 0.04。因此,本文剔除了叶型总压损失系数大于 0.08 的数据,在保证数据有效性的同时减少了噪声数据。

(3) 为了消除输入数据量纲与数量级不同对神经网络训练带来的不良影响,采用最大-最小归一化方法对数据进行处理,该方法可以保留数据集本身的分布特性,公式为:

$$x_N = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中:  $x_N$ —归一化后参数值;  $x$ —归一化前参数值;  $x_{\max}$  和  $x_{\min}$ —输入参数的最大值和最小值。

经过上述预处理后最终保留了 2 571 个叶型,在不同攻角下共计 75 467 个数据样本,用于搭建训练数据集。

### 2.2 代理模型建立

神经网络是机器学习领域常用的一种算法,对于叶型性能预测等复杂回归问题预测能力较强,且预测精度和鲁棒性均高于传统数学模型<sup>[21]</sup>。本文采用人工神经网络(Artificial Neural Network, ANN)构建代理模型,其结构如图 5 所示。输入层为叶型几何设计参数,输出层为叶型的损失系数或落后角,通过调整隐藏层层数和节点数可以调整神经网络的复杂程度。已有相关理论证明,含有两个隐藏层的神经网络可以逼近任意的连续函数<sup>[22]</sup>。

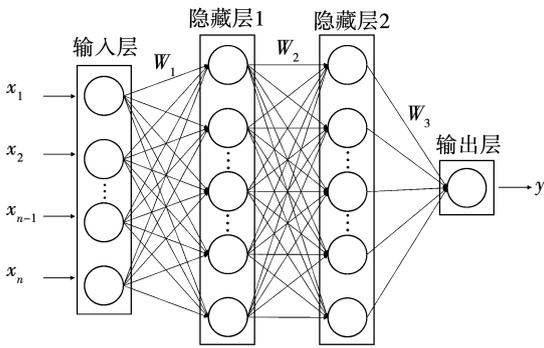


图5 人工神经网络结构示意图

Fig. 5 Schematic diagram of artificial neural network structure

本文使用一个两层的神经网络构建代理模型,通过改变隐藏层节点数调整神经网络复杂程度。为了评估神经网络训练效果,建立了均方误差 MSE、平均绝对误差 MAE 和决定系数  $R^2$  3 个评价指标,表达式分别为:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

式中: $n$ —参数量; $y_i$ —真实值; $\hat{y}_i$ —预测值; $\bar{y}$ —平均值。

表2给出了不同隐藏层节点数的神经网络对某样本集数据的训练结果对比。

表2 不同结构神经网络训练结果对比

Tab. 2 Comparison of training results of neural networks with different structures

隐藏层节点数	MSE	$R^2$	时间/s
32 - 32	0.095 7	0.874	237
64 - 64	0.062 3	0.918	258
128 - 128	0.042 1	0.944	289
256 - 256	0.031 2	0.959	483

从表2中可以看出,随着隐藏层节点数的增加,均方误差 MSE 降低, $R^2$  不断提高,这表明神经网络

的训练效果有所提升,但同时神经网络的训练时间也有所增加。当隐藏层节点数从 128 增加到 256 时,训练时间增加了 67%,但  $R^2$  仅提升 1.5%,所以本文决定采用两层隐藏层包含 128 个节点的神经网络结构构建代理模型,可以在保证精度的同时尽量减少训练时间。

神经网络的非线性拟合能力来源于神经元中的激活函数,选取合适的激活函数能够提高神经网络的训练效率,本文搭建的人工神经网络采用 ReLU 激活函数,其表达式为:

$$f(x) = \max(0, x) \quad (5)$$

ReLU 激活函数在输入变量大于零时返回其本身,在输入变量小于等于零时返回零,这种简单的非线性结构简化了神经网络的计算,可以提高神经网络的计算效率。

神经网络的反向传播过程是训练的关键,本文采用适应性矩估计 (Adaptive moment estimation, Adam)<sup>[23]</sup> 算法作为反向传播过程的优化器,该算法结合了动量法和 RMSProp 算法的思想,计算效率高,适应性强,可以自适应调整学习率,适用于处理高维度的复杂问题。

### 2.3 敏感度分析方法

在代理模型的训练中,将所有设计参数都作为输入变量会增加模型的输入维度,同时需要大量的数据样本来支撑训练。而某些叶型设计参数的变化对叶型的损失和落后角影响较小,将其作为训练参数会增加神经网络的训练工作量,因此需要对叶型设计参数进行敏感度分析,筛选对叶型损失和落后角影响较大的参数。

本文采用 Sobol 方法<sup>[24]</sup> 进行叶型设计参数敏感度分析。Sobol 方法是一种全局敏感度分析方法,其理念在于将一个复杂模型的结果分解为由单一输入参数或多个参数组合所构成的函数集合,通过运用蒙特卡洛积分分别计算各参数对输出方差的贡献,使我们能够定量评估每个参数及其交互作用对模型输出的影响。

首先假设模型可以分解为各参数的函数集合:

$$f(x) = f_0 + \sum_{i=1}^k f_i(x_i) + \sum_{1 \leq i < j \leq k} f_{ij}(x_i, x_j) + \dots + f_{12 \dots k}(x_1, \dots, x_k) \quad (6)$$

其中各分解项可以表示为:

$$\begin{cases} f_0 = E(Y) \\ f_i(x_i) = E(Y/x_i) - f_0 \\ f_{ij}(x_i, x_j) = E(Y/x_i, x_j) - f_0 - f_i(x_i) - f_j(x_j) \end{cases} \quad (7)$$

式中: $f_0$ —常数; $f_i(x_i)$ —变量  $x_i$  对输出的影响; $f_{ij}(x_i, x_j)$ —变量  $x_i$  和  $x_j$  共同作用对输出的影响; $E(Y)$ —期望; $E(Y/x_i)$ —除  $x_i$  外输入参数的期望; $E(Y/x_i, x_j)$ —除  $x_i$  和  $x_j$  外输入参数的期望。

假设  $f(x)$  是平方可积的,则对式(6)两边同时求方差可得:

$$V = \sum_{i=1}^k V_i(x_i) + \sum_{1 \leq i < j \leq k} V_{ij}(x_i, x_j) + \dots + V_{12\dots k}(x_1, \dots, x_k) \quad (8)$$

式中: $V$ —总方差; $V_i(x_i)$ —变量  $x_i$  对输出的方差; $V_{ij}(x_i, x_j)$ —变量  $x_i$  和  $x_j$  共同作用对输出的方差。

一阶敏感度指数  $S_i$  用于衡量变量  $x_i$  对输出的影响,总体敏感度指数  $S_{it}$  用于衡量变量  $x_i$  与其他变量的相互作用对输出的共同影响,其表达式为:

$$S_i = V_i/V \quad (9)$$

$$S_{it} = 1 - V_{ie}/V \quad (10)$$

式中: $V_{ie}$ —除参数  $x_i$  外其他参数共同作用产生的方差。

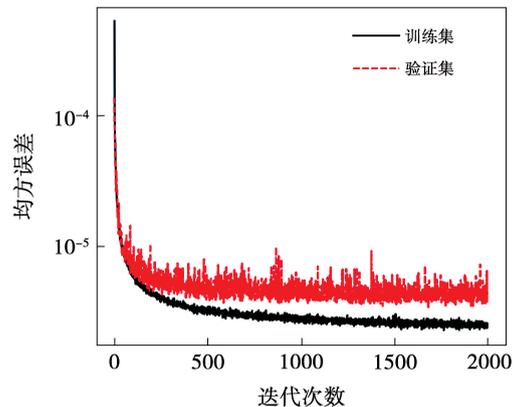
### 3 训练结果与分析

#### 3.1 训练结果

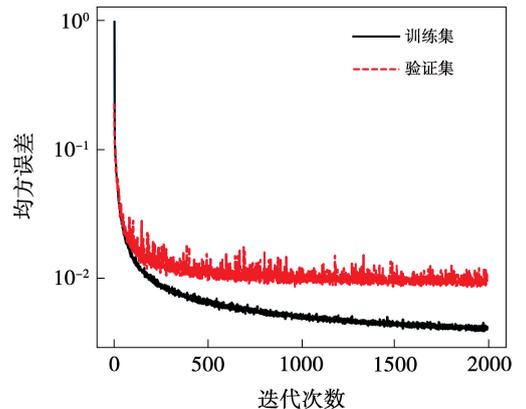
基于预处理后保留的数据样本,划分 80% 作为训练集用于神经网络的训练,20% 作为验证集用于评估神经网络的训练效果,采用均方误差作为神经网络训练过程中的损失函数,每次训练循环迭代 2 000 步,以保证数据集得到充分的训练。图 6 分别给出了损失和落后角代理模型在训练过程中损失函数随迭代次数的下降曲线。从图中可以看出,随着迭代次数增加,训练集与验证集的损失函数均不断减小,当迭代次数达到 1 000 步后损失函数基本趋于平稳,数据得到了充分训练。

为了检验代理模型在验证集上的预测效果,图 7 给出了损失和落后角代理模型对验证集数据的预测结果与 MISES 计算结果的对比。从图中可以看出,大部分数据都集中在理想预测结果分布线附近,

整体预测准确度较高,落后角模型相较总压损失模型数据分布更集中,训练效果更好。对于总压损失模型,当总压损失系数预测结果超过 0.04 时,部分数据偏离理想分布线较远,预测精度有所降低。对于性能优良的重型燃气轮机压气机叶型,其最小损失系数通常低于 0.02,而在评估压气机叶型特性时,通常按照二倍最小损失原则考虑叶型的失速和堵塞边界。当损失系数高于 0.04 时,大部分叶型已经超过失速或堵塞边界,此时叶型损失会在攻角变化较小的情况下急剧增加,因此对这部分数据进行性能计算时样本较少,代理模型的预测精度有所下降。



(a) 损失模型



(b) 落后角模型

图 6 代理模型训练迭代曲线

Fig. 6 Iterative curve of surrogate model training

表 3 给出了损失和落后角代理模型的评价指标 MAE 和  $R^2$ 。从表 3 中可以看出,损失代理模型的 MAE 小于 0.002,  $R^2$  达到 0.977,落后角模型的 MAE

小于  $0.5^\circ$ ,  $R^2$  达到 0.997, 说明本文建立的损失与落后角代理模型预测精度较高。

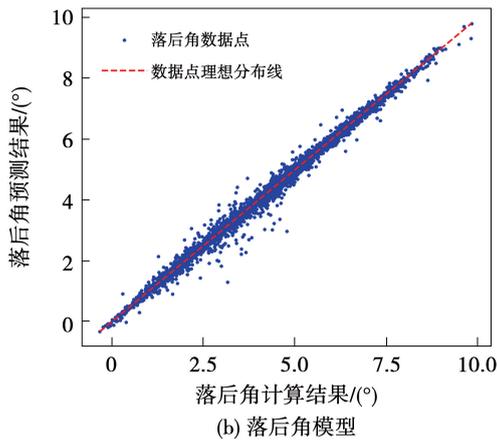
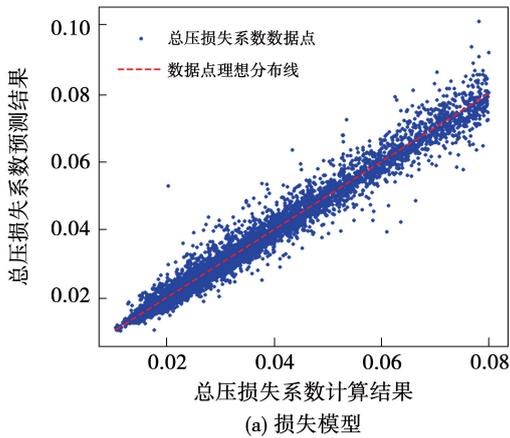


图 7 代理模型预测结果与 MISES 计算结果对比  
Fig. 7 Comparison between prediction result and MISES calculation result of surrogate model

表 3 代理模型对验证集数据的 MAE 和  $R^2$   
Tab. 3 MAE and  $R^2$  of the surrogate model on the validation set data

代理模型	MAE	$R^2$
损失模型	0.001 3	0.977
落后角模型	0.049 6°	0.997

### 3.2 敏感度分析结果

利用 Sobol 方法对叶型设计参数进行敏感度分析,采用两个敏感度系数进行评估。其中,一阶敏感度系数表征单设计参数的变化对叶型损失或落后角的影响,总体敏感度系数表征该参数变化及该参数与其他参数相互作用对叶型损失或落后角的影响。

图 8 给出了基于损失代理模型对叶型设计参数敏感度分析的结果。从图中可以看出,吸力面控制点对叶型损失的敏感度远高于其他设计参数。这是因为在叶型造型时,吸力面控制点的位置直接影响叶型吸力面样条曲线的形状,而叶型损失的主要来源与流体流过叶型吸力面所产生的附面层及分离有关,所以叶型吸力面的型线直接影响叶型的流动损失。其他设计参数对叶型损失的敏感度相对较小,其中  $T_m$  和  $R_1$  也对叶型损失有一定影响, $\beta_2$ 、 $\gamma_1$ 、 $\gamma_2$  和  $T_1$  这 4 个设计参数对叶型损失的影响最小。

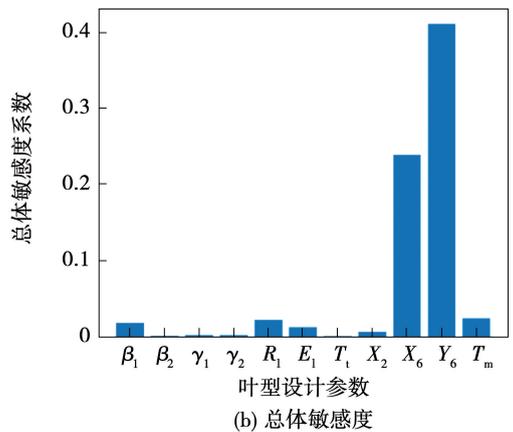
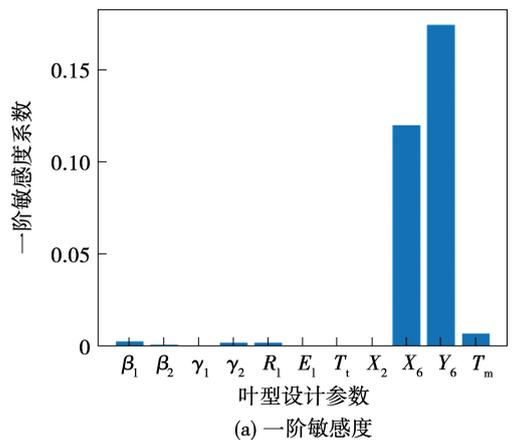


图 8 损失代理模型敏感度分析结果

Fig. 8 Sensitivity analysis results of loss surrogate model

图 9 给出了基于落后角代理模型对叶型设计参数敏感度分析的结果。从图中可以看出,对叶型落后角敏感度最大的参数也是吸力面控制点,吸力面型线的变化会影响叶型表面附面层的发展和流动的分流,进而影响落后角。除吸力面控制点外, $T_m$ 、 $\beta_1$ 、 $R_1$  和  $E_1$  等参数的敏感度系数也较高。文献[25-27]的研究

结果表明,叶型的前缘形状和最大厚度对叶型性能有较大影响,这也验证了本文敏感度分析结果的准确性,说明对于雷诺数较高的重型燃气轮机压气机,叶型吸力面型线的设计、前缘及最大厚度的控制对压气机性能有重要影响。

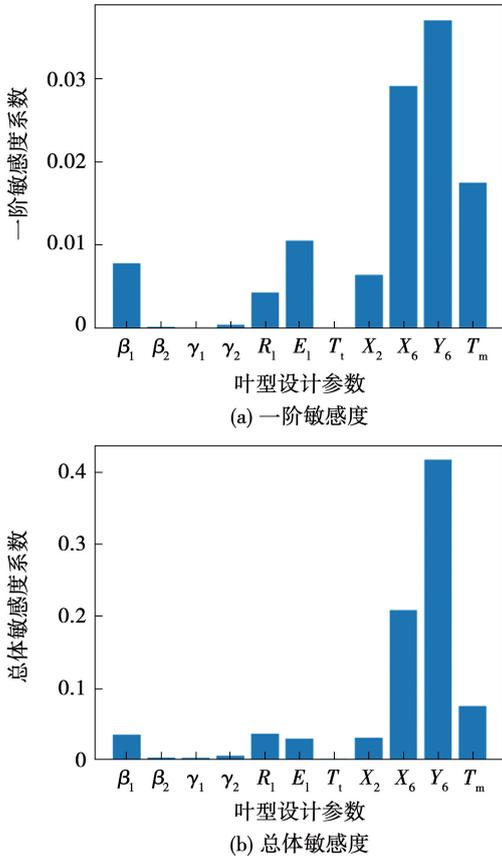


图9 落后角代理模型敏感度分析结果

Fig.9 Sensitivity analysis results of deviation angle surrogate model

### 3.3 代理模型降维

根据敏感度分析结果可知, $\beta_2, \gamma_1, \gamma_2$ 和 $T_1$ 这4个设计参数的敏感度较低,对叶型损失和落后角的影响较小,因此剔除这4个参数,从而减少损失模型的输入参数,降低训练所需的样本量。对数据进行筛选后保留了1 632个叶型,共计47 945个数据样本,并建立了包含7个设计参数的代理模型,以下简称“7参数模型”。图10给出了7参数模型对验证集数据的预测结果与MISES计算结果的对比。从图中可以看出,大部分数据仍分布在理想预测线附近,说明降低输入维度和减少样本量后,代理模型的预测精度仍然较高。

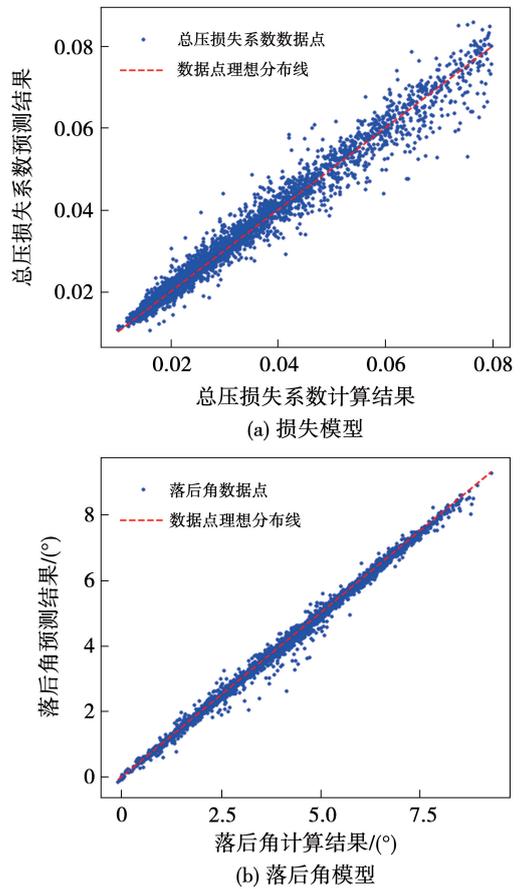


图10 筛选后的参数模型预测结果与MISES计算结果对比

Fig.10 Comparison between prediction result and MISES calculation result of 7-parameter model

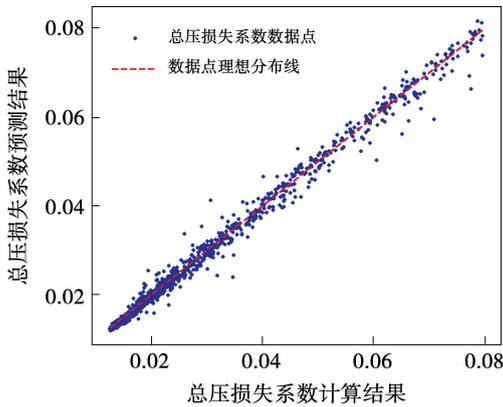
为了对敏感度较大的关键设计参数进行着重训练,针对吸力面控制点坐标( $X_6, Y_6$ )、 $T_m$ 和 $R_1$ 建立了包含4个设计参数的代理模型,以下简称“4参数模型”。采样筛选后共保留了319个叶型,共计9 324个数据样本。图11给出了4参数模型对验证集数据的预测结果与MISES计算结果的对比。从图中可以看出,在样本量较小的情况下,针对敏感度较高的设计参数建立的代理模型对验证集数据的预测精度仍较高。

表4给出了4参数模型、7参数模型与参数剔除前包含11个设计参数的代理模型(以下简称“11参数模型”)的MAE、 $R^2$ 及训练时间的对比。从表中可以看出,在输入维度和样本量降低后,模型的训练时间缩短,而模型对验证集数据的预测精度并未下降。3种损失模型的MAE均小于0.002, $R^2$ 系数均大于0.97;3种落后角模型的MAE均小于 $0.1^\circ$ , $R^2$

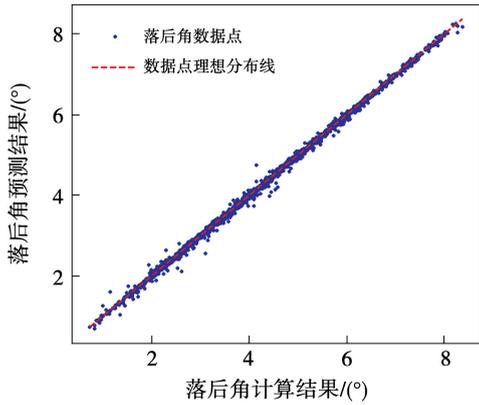
均大于 0.99。这说明根据敏感度分析结果识别关键设计参数对代理模型降维,可以减少设计变量,降低训练成本,提高代理模型应用价值。降维后的代理模型仍具有较高精度,可以用于叶型优化设计。

精度进行验证,分别利用代理模型和 MISES 求解器对该叶型进行损失和落后角特性的计算。

图 12 给出了 3 种损失和落后角代理模型对测试叶型损失和落后角特性的预测结果与 MISES 计算结果的对比。从图中可以看出,3 种损失模型在负攻角下的预测结果与计算结果吻合较好,7 参数模型对最小损失的预测值偏低。在正攻角下由于计算结果的波动,3 种模型的预测结果与计算结果有偏差,但在大攻角损失上升后预测曲线均与计算结果趋于一致。对于落后角模型,7 参数模型的拟合效果最佳,11 参数模型和 4 参数模型的预测偏低,但曲线走势均保持一致。



(a) 损失模型



(b) 落后角模型

图 11 4 参数模型预测结果与 MISES 计算结果对比

Fig. 11 Comparison between prediction result and MISES calculation result of 4-parameter model

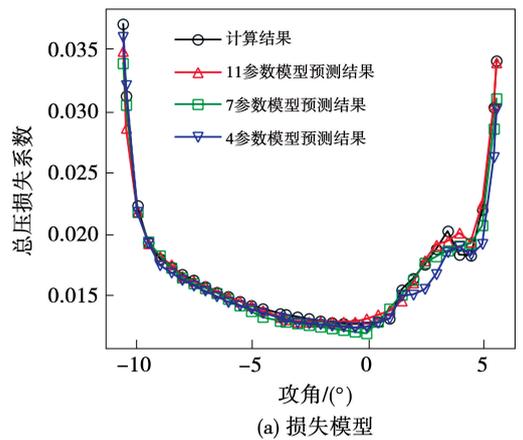
表 4 不同输入维度的代理模型训练结果对比

Tab. 4 Comparison of training results of surrogate models with different input dimensionalities

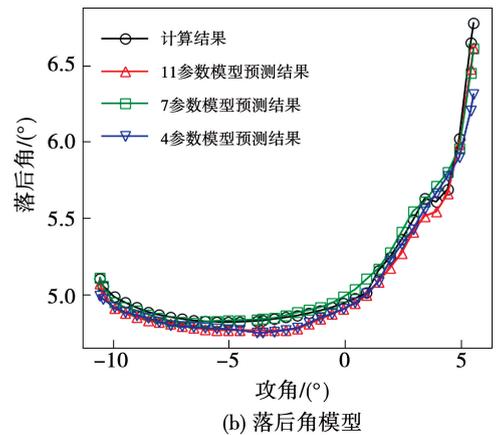
代理模型	叶型数量	损失模型			落后角模型		
		MAE	$R^2$	时间/s	MAE/(°)	$R^2$	时间/s
11 参数	2 571	0.001 3	0.977	4 828	0.049 6	0.997	4 778
7 参数	1 632	0.001 1	0.980	3 114	0.050 3	0.997	3 140
4 参数	319	0.000 7	0.993	755	0.036 5	0.998	733

### 3.4 代理模型验证

选用某先进重型燃气轮机第八级动叶叶中截面叶型为测试叶型,对不同输入维度代理模型的预测



(a) 损失模型



(b) 落后角模型

图 12 3 种代理模型对叶型特性的预测结果与 MISES 计算结果对比

Fig. 12 Comparison between prediction results and MISES calculation results of three kinds of surrogate models for blade profile characteristic

表 5 给出了 3 种模型对测试叶型性能预测结果的评价指标。从表中可以看出,11 参数模型与 7 参

数模型的  $R^2$  均达到了 0.97 以上,4 参数模型的误差最大,但  $R^2$  仍在 0.93 以上。3 种代理模型对测试叶型预测结果的总压损失系数平均绝对误差小于 0.001,落后角平均绝对误差小于  $0.1^\circ$ 。上述结果表明,3 种输入维度代理模型的预测精度均达到了较高水平,可以满足工程应用的需要,验证了代理模型的有效性。

表 5 测试叶型预测结果的评价指标

Tab.5 Evaluation indicators for verifying blade profile prediction results

模型	损失模型		落后角模型	
	MAE	$R^2$	MAE/ $^\circ$	$R^2$
11 参数	0.000 46	0.985	0.065	0.978
7 参数	0.000 69	0.974	0.039	0.985
4 参数	0.000 81	0.957	0.082	0.934

对于测试叶型的性能计算,MISES 求解器完成性能计算的耗时约为 300 s,而代理模型耗时约为 0.06 s,代理模型预测速度更快。相较于传统的基于 S1 分析的叶型设计方法,代理模型可以迅速计算得到大量叶型的性能,从而显著提高重型燃气轮机压气机叶型优化设计的效率。

## 4 结 论

(1) 针对重型燃气轮机压气机定制叶型建立的叶型损失和落后角代理模型具良好预测精度,且代理模型的预测时间相较于传统 S1 分析方法大幅降低,可以极大地提高叶型设计效率。

(2) 对于高雷诺数工作条件下的重型燃气轮机压气机定制叶型,吸力面控制点、前缘设计参数和最大厚度对叶型性能影响显著。根据敏感度分析结果识别叶型设计关键参数,对代理模型降维,可以减少设计变量,降低训练成本,提高代理模型应用价值。

(3) 对于高雷诺数工作条件下的重型燃气轮机压气机定制叶型,基于代理模型的设计思路满足工程设计需求,可应用于工程实际。但本文采用 MISES 作为数据生成工具,建立的代理模型精度受限于 MISES,在后续的工作中考虑以试验数据作为训练样本,可以进一步提高代理模型的准确性。

## 参 考 文 献:

[1] 束国刚,余春华,沈国华,等.新时期我国重型燃气轮机发展研

究[J].中国工程科学,2022,24(6):184-192.

SHU Guogang, YU Chunhua, SHEN Guohua, et al. Development of heavy-duty gas turbines in China in the new era[J]. Strategic Study of CAE, 2022, 24(6): 184-192.

[2] WU C H. A general theory of three-dimensional flow in subsonic and supersonic turbomachines of axial, radial, and mixed-flow types [J]. Transactions of the American Society of Mechanical Engineers, 1952, 74(8): 1363-1380.

[3] LIEBLEIN S. Loss and stall analysis of compressor cascades[J]. Journal of Basic Engineering, 1959, 81(3): 387-397.

[4] KOCH C C, SMITH L H. Loss sources and magnitudes in axial-flow compressors[J]. Journal of Engineering for Power, 1976, 98(3): 411-424.

[5] CARTER A D S. The low speed performance of related aerofoils in cascade[R]. ARC-CP-29, 1950.

[6] LIEBLEIN S. Incidence and deviation-angle correlations for compressor cascades[J]. Journal of Basic Engineering, 1960, 82(3): 575-584.

[7] CETIN M, HIRSCH C, SEROVY G K, et al. An off-design loss and deviation prediction study for transonic axial compressors [R]. ASME Paper 89-GT-324, 1989.

[8] 宋寅.先进高负荷压气机气动设计技术综述[J].分布式能源, 2018, 3(3): 1-9.

SONG Yin. Review on aerodynamics design of advanced highly-loaded compressor[J]. Distributed Energy, 2018, 3(3): 1-9.

[9] SCHMITZ A, AULICH M, NICKE E. Novel approach for loss and flow-turning prediction using optimized surrogate models in two-dimensional compressor design[C]//Proceedings of the ASME 2011 Turbo Expo; Turbine Technical Conference and Exposition. Vancouver, British Columbia, Canada; ASME, 2011: 1103-1114.

[10] 费腾,季路成,周玲.神经网络模型在压气机通流特性分析中的应用[J].航空动力学报, 2022, 37(6): 1260-1272.

FEI Teng, JI Lucheng, ZHOU Ling. Application of neural network model in compressor through-flow analysis[J]. Journal of Aerospace Power, 2022, 37(6): 1260-1272.

[11] 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 Hanan, 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.

[12] 杜周,徐全勇,马玉林,等.基于深度神经网络的压气机叶型性能预测[J/OL].航空动力学报, 2024-05-17 [2024-07-22]. <https://doi.org/10.13224/j.cnki.jasp>.

DU Zhou, XU Quanyong, MA Yulin, et al. Prediction of axial compressor blade performance under off-design conditions based on deep neural network[J/OL]. Journal of Aerospace Power, 2024-

- 05-17 [2024-07-22]. <https://doi.org/10.13224/j.cnki.jasp>.
- [13] 陈晨铭,郭雪岩,李春. 基于多种优化方法的轴流风扇叶型气动优化[J]. 热能动力工程,2024,39(9):54-60.  
CHEN Chenming, GUO Xueyan, LI Chun. Aerodynamic optimization of axial fan blade airfoil based on multiple optimization methods[J]. Journal of Engineering for Thermal Energy and Power, 2024,39(9):54-60.
- [14] KOLLER U, MONIG R, KUSTERS B, et al. Development of advanced compressor airfoils for heavy-duty gas turbines: Part I—Design and optimization[R]. ASME Paper 99-GT-95, 1999.
- [15] GILES M. Newton solution of steady two-dimensional transonic flow [R]. Massachusetts, US: Gas Turbine Laboratory, Report No. 186, 1985.
- [16] DRELA M. Two-dimensional transonic aerodynamic design and analysis using the Euler equations [R]. Massachusetts: Gas Turbine Laboratory, Report No. 187, 1986.
- [17] 阙晓斌,蒋洪德. 重型燃气轮机压气机高雷诺数前转掠叶型设计[J]. 航空动力学报,2013,28(10):2309-2315.  
QUE Xiaobin, JIANG Hongde. Design of high Reynolds number compressor airfoil with early transition for heavy-duty gas turbine [J]. Journal of Aerospace Power, 2013, 28(10):2309-2315.
- [18] SCHNOES M, NICKE E. Automated calibration of compressor loss and deviation correlations [C]//Proceedings of the ASME 2011 Turbo Expo 2015: Turbine Technical Conference and Exposition. Montreal, Canada: ASME, 2015: V02AT37A020.
- [19] SCHNOES M, NICKE E. A database of optimal airfoils for axial compressor throughflow design [J]. Journal of Turbomachinery, 2017, 139(5):051008.
- [20] KUSTERS B, SCHREIBER H A, KOLLER U, et al. Development of advanced compressor airfoils for heavy-duty gas turbines: Part II—Experimental and theoretical analysis [R]. ASME Paper 99-GT-96, 1999.
- [21] 马博文,巫骁雄,于洋. 基于机器学习方法的压气机落后角与总压损失预测代理模型[J]. 航空动力学报,2023,38(7):1675-1690.  
MA Bowen, WU Xiaoxiong, YU Yang. Surrogate model for deviation angle and total pressure loss prediction of compressor based on machine learning methods [J]. Journal of Aerospace Power, 2023, 38(7):1675-1690.
- [22] ISMAILOV V E. On the approximation by neural networks with bounded number of neurons in hidden layers [J]. Journal of Mathematical Analysis and Applications, 2014, 417(2):963-969.
- [23] KINGMA D P, BA J. ADAM: A method for stochastic optimization [EB/OL]. arXiv. 2017-01-30 [2024-07-22]. <http://arxiv.org/abs/1412.6980>.
- [24] SOBOL I M. Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates [J]. Mathematics and Computers in Simulation, 2001, 55(1/3):271-280.
- [25] 宋寅,顾春伟. 曲率连续的压气机叶片前缘设计方法[J]. 推进技术,2013,34(11):1474-1481.  
SONG Yin, GU Chunwei. Continuous curvature leading edge of compressor blading [J]. Journal of Propulsion Technology, 2013, 34(11):1474-1481.
- [26] 韩斌,虞培祥,童歆,等. 可控扩散叶型振荡叶栅边界层转捩特性分析[J]. 热能动力工程,2022,37(12):1-10.  
HAN Bin, YU Peixiang, TONG Xin, et al. Analysis of boundary layer transition characteristics of oscillating cascades with controlled diffusion airfoils [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(12):1-10.
- [27] TONG X, LIAN B, YU P, et al. The effect of leading-edge shape on separation-induced transition on the suction surface of a controlled-diffusion airfoil [J]. Physics of Fluids, 2023, 35(7):075117.

(刘颖编辑)