

# 基于数据驱动的航空发动机风扇叶型 气动性能优化设计\*

宋源峰, 金源航, 陶俊

(复旦大学 航空航天系, 上海 200433)

(我刊青年编委陶俊来稿)

**摘要:** 提出了一种流动特征嵌入(embedding flow-feature network, EFFN)代理模型,通过将流场信息融入代理模型中,提高了代理模型的预测精度,同时令代理模型具有流动特征预测能力.EFFN 模型对训练数据样本总量的需求与传统用于气动优化的代理模型一致甚至更少.它在样本数量相同的情况下比传统代理模型拥有更高的预测精度,并且它能够准确预测流动特征,同时一定程度上解决了代理模型物理可解释性差的问题.由于 EFFN 模型相较传统代理模型提供了更可靠的预测值,在气动优化设计中拥有更好的优化结果.对二维叶型总体气动性能优化的结果表明,基于 DBN 模型的优化叶型总压损失系数相对减少 17.3%,而 EFFN 模型的优化叶型总压损失系数相对减少 18.0%,基于 EFFN 模型优化叶型的损失性能得到更好地改善.

**关键词:** 数据驱动; 优化设计; 神经网络; 叶型; 流动特征

**中图分类号:** V231 **文献标志码:** A **DOI:** 10.21656/1000-0887.460084

## Optimization Design of Aerodynamic Performances of Aircraft Engine Fan Blade Profiles Based on Data Driven Methods

SONG Yuanfeng, JIN Yuanhang, TAO Jun

(Department of Aeronautics and Astronautics, Fudan University,  
Shanghai 200433, P.R. China)

(Contributed by TAO Jun, Member of the Youth Editorial Board of AMM)

**Abstract:** A flow feature embedding proxy model (embedding flow feature network, EFFN) was proposed, to improve the prediction accuracy of the proxy model by integrating the flow field information into the proxy model, and enable the proxy model to predict flow features. The requirement for the total number of training data samples in the EFFN is consistent or even less than that of traditional surrogate models used for aerodynamic optimization. It has higher prediction accuracy than traditional surrogate models with the same sample size, and can accurately predict flow characteristics, while to some extent solving the problem of poor physical interpretability of surrogate models. Meanwhile, due to the more reliable values predicted by the EFFN, it has

\* 收稿日期: 2025-04-24; 修订日期: 2025-05-04

基金项目: 国家自然科学基金(12302297)

作者简介: 宋源峰(1999—),男,硕士(E-mail: syf19921941071@163.com);

陶俊(1989—),男,副教授,博士(通信作者. E-mail: juntao@fudan.edu.cn).

引用格式: 宋源峰,金源航,陶俊.基于数据驱动的航空发动机风扇叶型气动性能优化设计[J].应用数学和力学,2026,47(5):605-620.

better optimization results in aerodynamic optimization design. The results of optimizing the aerodynamic performances of the 2D blade profiles show that, the total pressure loss coefficient of the optimized blade profile based on the DBN model relatively decreases by 17.3%, while the total pressure loss coefficient of the optimized blade profile based on the EFFN model relatively decreases by 18.0%. The loss performance of the optimized blade profile based on the EFFN model was highly improved.

**Key words:** data driven; optimize design; neural network; blade cascade; flow features

## 0 引 言

航空发动机被誉为航空工业皇冠上“最璀璨的明珠”<sup>[1]</sup>,是大飞机的“心脏”,航空发动机的研制是我国发展大飞机事业的重要一环,先进航空发动机基本上是朝着高推重比、高安全性和低油耗率等方向不断发展<sup>[2]</sup>.在高性能的需求驱动下,大涵道比涡扇发动机的研发与设计成为必然.随着商用大涵道比涡扇发动机尺寸的不断增大,发动机所产生的流动损失在飞机整体流动损失中所占的比例迅速增加,其中诸如风扇叶片等大尺寸部件贡献的流动损失尤为明显<sup>[3]</sup>.因此,需要通过气动优化设计方法来提升风扇叶片的气动性能.大涵道比风扇具有复杂的几何外形,在进行优化时,需要使用大量参数对几何进行表述,大规模的设计变量为风扇气动优化设计带来了巨大困难.另一方面,风扇叶片通道中涵盖了从亚音到超音的流动状态,风扇内部的二次流动使得其内部流场繁冗复杂,流动损失来源多种多样<sup>[4]</sup>,主要包括湍流边界层黏性损失、湍动能损失、激波边界层干扰损失.复杂的流动现象同样使得风扇内部流场的数值模拟昂贵,大幅增加了风扇气动设计的成本.

从数据分析的角度来看,空气动力学设计通常涉及大量与高维数据相关的计算、分析和操作<sup>[5]</sup>.例如,当使用 CFD 方法求解三维气动配置周围的流场时,总网格尺寸通常达到数百万甚至数十亿.此外,在气动设计过程中,通常需要模拟和分析大量具有不同流入条件/模式和几何参数配置的流场,这显然带来了巨大的计算成本和工作量.因此,为了提高高维设计问题的实现效率,将数据驱动方法引入气动设计<sup>[6]</sup>,主要应用固定统计分析模型对数据进行降维或分类操作.一般来说,传统的数据降维方法可分为两类:以正交分解(POD)和主成分分析(PCA)为代表的线性方法<sup>[7]</sup>,以及以核主分量分析(KPCA)为表示的非线性方法<sup>[8]</sup>.Toal 等<sup>[9]</sup>提出了一种基于 POD 方法的几何滤波算法,该方法不仅可以降低变量的维数,还可以保持设计配置在几何维度上的合理性.

目前,机器学习等人工智能技术的快速发展为气动设计的研究提供了新的思路.作为一种典型的机器学习方法,代理模型是在输入和输出之间建立映射的元模型.对于航空领域的设计问题,通常使用替代模型来代替昂贵且耗时的 CFD 模拟,以缩短设计周期并降低设计成本.在航空优化领域,替代模型辅助进化算法得到了广泛的应用<sup>[10]</sup>.刘伟等<sup>[11]</sup>开发了一种替代模型辅助的 3D 叶片优化方法,提出将神经网络模型引入优化过程,解决了无效样本区域对遗传算法优化的干扰问题,从而提高了优化算法的性能.郝书荣<sup>[12]</sup>基于高保真叶片气动样本数据训练了一个机器学习模型来分析叶片流型.常见的替代模型包括多项式响应面法、Kriging 模型和人工神经网络(ANN)<sup>[13-14]</sup>.在各种替代模型中,当训练样本量足够大时,ANN 是一种具有保证拟合精度的模型<sup>[15]</sup>.因此,基于 ANN 的替代模型已被广泛研究用于气动参数预测,并广泛应用于各种飞机部件的气动形状优化研究<sup>[16]</sup>.Secco 等<sup>[17]</sup>使用 ANN 对具有各种机翼平面形状、翼型形状和飞行条件的机翼-机身飞机配置的升力和阻力系数进行建模.通过使用全速势求解计算黏性效应生成的约 10 万个训练数据,ANN 对升力和阻力系数预测的平均绝对误差分别为 0.004 和 0.000 5. Du 等<sup>[18-19]</sup>开发了基于 ANN 的通用翼型分析模型,用于快速预测空气动力学阻力、升力和俯仰力矩系数,并与基于 CFD 的优化相比,获得了良好的优化设计结果. Wang 等<sup>[20]</sup>使用 ANN 对任何翼型的升力、阻力和扭矩系数进行建模,发现 ANN 模型的性能优于 Kriging 模型的混合模型,并且在优化中使用 ANN 模型得到了与高保真 CFD 基于优化的设计相似的翼型形状.在亚音速和超音速状态下,阻力系数差异分别为 0.01 和 0.12. Li 等<sup>[21]</sup>在转子 37 的多设计点优化问题中使用了改进的 NAGA-II 和基于 ANN 的替代模型.随着对气动设计需求的增加,一些更复杂的神经网络方法逐渐被应用于气动设计,如卷积神经网络(CNN)、递归神经网络(RNN)和生成对抗网络(GAN)等<sup>[22]</sup>.

然而,上述方法主要侧重于通过使用机器学习技术来提高特定过程的局部设计效率或性能.此外,使用传统替代模型通过降维获得的特征是潜在空间中的向量,缺乏可解释性.对于高维气动优化问题,为了进一步提高优化效率,我们期望新兴的优化方法能够从流场中挖掘有利于优化设计的信息,即流场特征驱动的优化方法.

因此本文提出了一种全面性很强的全局数据驱动气动设计方法,以实现整个过程中的机器设计<sup>[22]</sup>.同时,流场信息被嵌入到替代模型中,以提高数据的可解释性,与传统的替代模型相比,这使得它在预测流动特性方面更加准确,为气动设计提供了更可靠的观测结果.

## 1 考虑来流工况的叶型性能数据集设计

### 1.1 叶型几何参数化设计

几何参数化定义了设计变量和设计空间,对叶型的设计优化问题十分重要.在本文中,进行几何参数化主要有两个目的:①对原始叶型/叶片几何进行扰动,通过抽样方法获得几何数据库,用于代理模型的训练;②确定几何设计空间,开展气动性能优化.因此,我们选择使用 Hicks-Henne 型函数对叶型局部形状进行扰动,并将 Hicks-Henne 型函数参数作为局部修型几何设计参数.Hicks-Henne 参数化方法<sup>[23]</sup>最早由 Hicks 和 Henne 提出,用于进行翼型的优化设计.该方法为控制修改量的参数化方法,在基准翼型上叠加他们共同提出的 Hicks-Henne 型函数,从而改变翼型.经过学者的使用,发现将 Hicks-Henne 型函数用于叶型的修改量叠加,也能够有效地优化叶型,得到能够达到实际需求的设计叶型,故在叶型的参数化领域也被多次使用.

Hicks-Henne 参数化方法将叶型函数分为基准叶型、Hicks-Henne 型函数以及函数的参数三部分,取函数的参数作为设计变量,其表达式为

$$\begin{cases} y_{\text{suc}} = y_{0\text{suc}} + \sum_{k=1}^n c_k f_k(x), \\ y_{\text{pre}} = y_{0\text{pre}} + \sum_{k=1}^n c_{k+n} f_k(x), \end{cases} \quad (1)$$

其中  $y_{\text{suc}}$  和  $y_{\text{pre}}$  分别表示叶型吸力面与压力面的函数;  $y_{0\text{suc}}$  和  $y_{0\text{pre}}$  分别表示吸力面与压力面的基准叶型函数;  $x$  表示弦长方向的相对位置,标准化后取值为  $0 \sim 1$ ;  $n$  为型函数的数目,根据设计需求确定,  $n$  越大叶型描述越准确;  $f_k(x)$  为 Hicks-Henne 型函数;  $c_k$  为型函数的参数,即设计变量,共  $2n$  个.

该参数化方法在提出时,其型函数表示为

$$f_k(x) = \begin{cases} x^{0.25}(1-x)e^{-20x}, & k=1, \\ \sin^w(\pi x^{e(k)}), & k \geq 2, \end{cases} \quad (2)$$

$$e(k) = \frac{\ln 0.5}{\ln x_k}, \quad 0 \leq x \leq 1, \quad (3)$$

其中  $x_k$  和  $w$  根据设计需求指定,  $x_k$  控制鼓包的位置,  $w$  控制鼓包的宽度.

Zhou 等<sup>[24]</sup>对 Hicks-Henne 型函数进行改进,添加了一项函数,得到如式(4)所示的函数表达式:

$$f_k(x) = \begin{cases} x^{0.25}(1-x)e^{-20x}, & k=1, \\ \sin^w(\pi x^{e(k)}), & 2 \leq k \leq n-1, \\ 8x(1-x)e^{-10(1-x)}, & k=n. \end{cases} \quad (4)$$

大量学者对叶型的研究证明,叶型的前缘几何形状对于压气机叶片的气动性能有较大影响<sup>[25-27]</sup>,用较少设计变量对前后缘形状添加改变量难以保证拟合的精度,故本文仅取中间段型函数进行使用,并取  $w=3$ ,如式(5)所示:

$$f_k(x) = \sin^3(\pi x^{e(k)}), \quad 1 \leq k \leq n. \quad (5)$$

本文选择某航空发动机 45% 叶高的叶型作为基准叶型,通过添加修改量获取训练集叶型.图 1 为 Hicks-Henne 型函数的曲线,型函数个数  $n=4$ ,即在 4 个位置添加鼓包,分别为  $x_1=0.3, x_2=0.45, x_3=0.55, x_4=0.70$ ,于是得到吸力面与压力面各 4 个,共计 8 个设计变量.




图1 Hicks-Henne 型函数图

Fig. 1 The Hicks-Henne type function diagram

注 为了解释图中的颜色,读者可以参考本文的电子网页版本,后同。

## 1.2 Latin 超立方抽样设计

基于神经网络代理模型的气动设计方法,代理模型精度很大程度上取决于训练的样本集.为了利用最少的资源获得最全面的信息,许多学者在优化时会采用实验设计方法获得训练样本,如正交实验设计、均匀实验设计、球面对称实验设计、二次通用旋转实验设计以及 Latin 超立方采样(LHS)实验设计<sup>[28-29]</sup>.LHS 采用随机抽样的方法使设计点的估计无偏,而通过样本空间的分块使得样本值具有较小的方差,因此本文采用 LHS 方法进行几何空间抽样,参数设置如表 1 所示。

表 1 Latin 超立方抽样参数设置

Table 1 Latin hypercube sampling parameter settings

parameter	setting
number of samples	400
number of dimensions	8
stratification	equal-width
sampling method	random
variable bound	$[-0.006, 0.006]$

设计变量所在的空间为 8 维的几何参数空间,通过在参数空间采样,生成对应的 Hick-Henne 型函数,并与原始叶型叠加获得二维叶型几何样本,从而生成二维叶型几何数据库.最终形成样本点个数为 400 的二维叶型数据库,其中 360 组样本作为训练集进行训练,40 组样本作为测试集来测试训练结果.采用 Hicks-Henne 型函数对标准叶型进行修改量叠加,为保证叶型光滑且不会出现交叉,设计变量的范围一般位于  $\pm 0.010$  之间,本文 LHS 采样范围为  $[-0.006, 0.006]$ .生成的叶型设计空间如图 2 所示,图中倾斜表示 45% 叶高处叶型的安装角。

## 1.3 叶型几何网格划分

本文对二维叶型进行数值模拟,叶高方向分为两层网格,第一层壁面厚度为  $5 \times 10^{-6}$  m.叶型计算网格如图 3 所示,可以看出前缘及尾缘端面网格质量均良好.网格无关性验证由表 2 给出.可以看出,当计算网格总数由 24 万进一步增加至 30 万时,叶型总体性能参数的变化小于 0.5%.因此,选择网格数为 24 万的网格作为后续二维叶型气动性能优化的计算网格。

## 1.4 叶型初始构型的气动性能数值计算

本文选择湍流的 N-S 方程以及 SA 湍流模型,对初始叶型构型进行数值模拟.数值模拟的设计参数如表 3 所示,初始条件为进口气流流速 141.4 m/s,压强 80 000 Pa,总温 293 K.对 400 组数据进行批处理的网格划分和计算,其中基准叶型的出口气流角方向为  $22.50^\circ$ ,基准叶型的总压损失系数为 0.028 9。




图 2 叶型设计空间

Fig. 2 The design space of blade profiles




图 3 计算网格划分

Fig. 3 The computational mesh of the cascade blade

表 2 不同网格数下 45% 相对叶高叶型性能参数

Table 2 Computed performances of 45% span cascades with different meshes

number of grid nodes	total pressure loss coefficient	outlet flow angle/(°)
127 098	0.029 5	22.4
173 666	0.029 2	22.5
240 298	0.028 9	22.5
303 458	0.028 8	22.5

表 3 数值模拟设计参数

Table 3 Numerical simulation design parameters

parameter	value
freestream velocity	0.8Ma
fluid density/(kg/m <sup>3</sup> )	1.047
reference length/m	0.1
inlet total temperature/K	293
inlet total pressure/Pa	122 800
inlet flow angle/(°)	45.56
turbulent viscosity coefficient/(m <sup>2</sup> /s)	0.000 1
outlet static pressure/Pa	101 325
blade pitch/m	0.061 1

## 2 基于数据驱动的二维叶型气动优化设计框架

### 2.1 深度置信神经网络代理模型

深度置信神经网络(DBN)<sup>[30]</sup>最早由 Hinton 等提出,是一种已经经过大量研究且应用比较广泛的深度学习结构,可以由一系列的受限 Boltzmann 机(restricted Boltzmann machine, RBM)堆叠得到,前一层 RBM 的输出作为下一层的输入,最后一个 RBM 层的输出经由一层神经网络(如反向传播网络分类器等)转化为 DBN 最终的输出.由于其具有较好的学习及预测效果,常用于建立气动设计代理模型,以减小设计成本.拥有 2 层 RBM 的 DBN 神经网络结构如图 4 所示.




图 4 DBN 模型结构示意图

Fig. 4 The schematic architecture of the deep belief network (DBN) model

### 2.2 流场降维模型

为了利用数据驱动方法的诸多优势实现复杂构型的气动设计,我们期望利用从 CFD 计算中获得的物理信息,并且希望通过流场信息来指导几何设计,因此,建立一个气动参数空间是本文优化设计所需的.

对于叶型优化问题,我们希望通过叶型表面的等熵 Mach 数分布来构建气动参数空间.但是构建完整的等熵 Mach 数分布曲线需要上百个数据点,如果将等熵 Mach 数分布直接作为中间空间,中间空间的维数将非常高.并且,这上百维数据中存在大量的冗余,这为在创新设计方法中使用流场信息带来了困难.因此,需要通过空间降维来获得一个更低维度的气动空间,同时我们期望空间降维所带来的物理信息丢失尽可能少,降维气动空间能够与原始气动空间有几乎相同的表达能力.

自动编码器(autoencoder, AE)<sup>[31]</sup>是一种基于 ANN 实现的无监督降维模型,它能够学习高维数据的低维表示.AE 的目的是通过编码输入数据来提取潜在的低维特征,并且能够在新数据上进行重建.AE 的网络模型结构如图 5 所示,其由两部分组成,分别是编码器(encoder)与解码器(decoder).编码器与解码器都是由 ANN 构成.编码器的功能是将高维输入通过神经网络映射到低维的潜在特征(latent features)上,而解码器的功能是将降维的嵌入层重新映射回输入上.因此,整个模型的结构呈现沙漏状,潜在特征层表现为整个模型最窄的“瓶颈”.

### 2.3 嵌入流场特征的神经网络代理模型

传统的神经网络代理模型,以 DBN 为例,在气动外形优化问题中,被用来建立几何-总体性能映射.输入为几何参数,输出为总体性能参数,例如总压比、等熵效率等,而 CFD 计算所得的流场信息并没有得到利用.对于 DBN 的模型结构,如果模型参数量较小,那么模型无法拟合复杂的流动物理规律.为了更加充分地利用 CFD 计算所得的流场信息训练模型,本文提出了一种流动特征嵌入(EFFN)代理模型,即将流场特征嵌入到传统的神经网络代理模型中.与传统用于气动设计的神经网络代理模型相比,EFFN 模型对训练数据样本总量的需求没有增加,但可以提高代理模型的预测精度,从而为气动设计提供可靠的预测值.




图 5 自动编码器模型架构示意图

Fig. 5 Schematic diagram of the autoencoder model architecture

EFFN 模型结构如图 6 所示,其与 DBN 有着类似的结构,区别在于 EFFN 在中间某一层的隐藏层之后将输出映射到具有标签(真实值)的流场流动特征层上,之后再通过多层隐藏层映射为总体性能参数.即将流场流动特征嵌入到几何-总体性能的多层神经网络中,并使用从 CFD 计算中所得的真实流场流动特征标签来修正流动特征嵌入层的输出.EFFN 的网络模型架构如图 6 所示,神经网络的隐藏层被分成两个部分,在第一部分隐藏层的输出被映射到流动特征嵌入层,然后,流动特征向量与原输入向量拼接,组成新的输入向量传递给第二部分隐藏层,并通过正向推理最终输出总体性能参数.

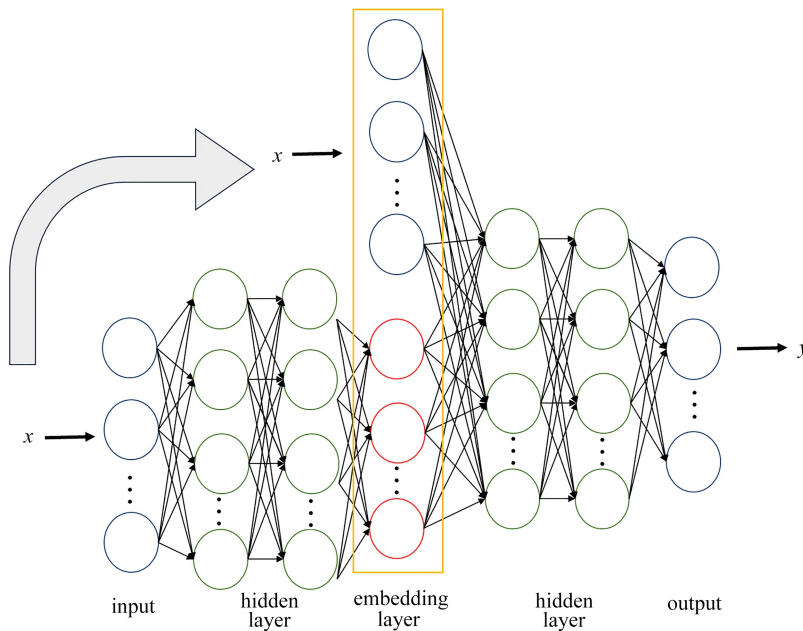


图 6 EFFN 模型结构示意图

Fig. 6 The schematic architecture of the EFFN model

EFFN 模型的损失函数  $L_{total}$  由两部分构成:

$$L_{total} = L_{embedding} + L_{output},$$

其中  $L_{output}$  表示 EFFN 的输出(总体性能参数)损失,

(6)

$$L_{\text{output}} = \text{MSE}(\hat{y}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2), y), \quad (7)$$

式中  $\boldsymbol{\theta}_1$  与  $\boldsymbol{\theta}_2$  分别代表第一部分与第二部分隐藏层的权重参数,  $y$  与  $\hat{y}$  分别代表总体性能参数的真实值与预测值;  $L_{\text{embedding}}$  表示 EFFN 的中间流动特征嵌入层的损失,

$$L_{\text{embedding}} = \text{MSE}(\hat{f}(\boldsymbol{\theta}_1), f), \quad (8)$$

式中  $f$  与  $\hat{f}$  分别代表被嵌入的流动特征参数的真实值与预测值.

因此, EFFN 的训练损失  $L_{\text{total}}$  的计算图节点即为对  $L_{\text{embedding}}$  与  $L_{\text{output}}$  的求和操作. 在训练过程中, EFFN 的学习目标不单单追求对输出的预测精度(通过对  $\boldsymbol{\theta}_1, \boldsymbol{\theta}_2$  的更新), 同样追求对流动特征的预测精度(通过对  $\boldsymbol{\theta}_1$  的更新).

### 3 基于 EFFN 的二维叶型气动优化设计

#### 3.1 叶型流动特征提取

为了充分利用 CFD 计算结果的复杂流场中所蕴含的物理信息, 本文提取叶型几何表面的气动参数分布, 并期望从表面气动参数分布中发掘能够影响几何优化设计的潜在特征. 本文选择等熵 Mach 数分布作为叶型表面的气动参数分布, 等熵 Mach 数的定义为

$$Ma_{\text{is}} = \sqrt{\left( \left( \frac{P_1^*}{P_{\text{loc}}} \right)^{(\gamma-1)/\gamma} - 1 \right) \cdot \frac{2}{\gamma-1}}, \quad (9)$$

其中  $P_1^*$  为进口总压,  $P_{\text{loc}}$  代表当地局部静压,  $\gamma$  为绝热系数.

对于每一个 CFD 计算结果, 提取了二维叶型壁面第一层网格点上的 1 410 个等熵 Mach 数, 其中原始叶型等熵 Mach 数分布如图 7 所示. 因此, 等熵 Mach 数分布的参数空间维度为 1 410, 其中有着大量冗余的气动信息, 同时, 过高的参数空间维度不利于指导几何优化设计, 因此需要通过降维模型来发掘低维潜在流动特征.




图7 叶型表面等熵 Mach 数分布

Fig. 7 The isentropic Mach number distribution on the blade surface

使用 AE 自编码器对等熵 Mach 数进行降维, 发掘潜在降维特征的目的就是期望在信息丢失尽量小的情况下, 用更少的特征表示原始信息. 本文期望使用尽量少的流动特征, 即追求更高的降维效率. 因此, 在训练 AE 时, 吸力面分布模型与压力面分布模型各自的潜在特征维度都选择为 6. AE 降维模型的具体参数设置如表 4 所示.

图 8 展示了使用 AE 模型对测试集中案例所重构的等熵 Mach 数分布与真实分布的对比. 从图中可以看出, 重构的等熵 Mach 数分布与真实分布基本一致. 对于前缘吸力峰以及吸力面激波区域的分布, AE 都能够很好地基于降维后特征进行重构. 这表明 AE 降维模型能够在大幅降低气动参数维度的同时, 保留关键信

息,并可以利用潜在低维特征重构出气动参数分布。

表 4 AE 降维模型参数设置

Table 4 AE dimensionality reduction model parameter settings

parameter	value
number of encoder hidden layers	3
encoder hidden layer size	64
number of decoder hidden layers	3
decoder hidden layer size	64
learning rate	0.002
number of max epochs	2 000
number of batches	64




图 8 AE 模型叶型表面等熵 Mach 数分布重构

Fig. 8 Reconstruction of the isentropic Mach number distribution on the blade surface by the AE model

### 3.2 嵌入流场特征的神经网络代理模型构建

为了进行对比,本文分别训练了基于传统 DBN 结构以及基于本文所提出的 EFFN 结构的代理模型.神经网络的输入为叶型改变量的几何参数,维度为 8,输出则为通过 CFD 计算获得的总压损失系数  $\omega$  和出口气流角  $\beta_2$ ,其定义分别为

$$\omega = \frac{P_1^* - P_2^*}{P_1^* - P_1}, \quad (10)$$

$$\beta_2 = \arctan\left(\frac{v_{y2}}{v_{x2}}\right), \quad (11)$$

其中  $P_1^*$  与  $P_2^*$  分别为叶型进口与出口总压,  $P_1$  为进口静压;  $v_{x2}$  与  $v_{y2}$  分别为叶型出口轴向与切向速度。

对输出变量进行归一化,即  $\tilde{y} = y/(y_{\max} - y_{\min})$ .嵌入流动特征为通过 AE 模型对叶型壁面等熵 Mach 数分布降维所获得的流动特征,即嵌入层的维度为 16。

传统 DBN 与 EFFN 的网络结构都使用 3 层隐藏层,隐藏层后的激活函数都使用 tanh 函数,两个网络模型的结构如图 9 所示, EFFN 在嵌入层之前有 2 层隐藏层,在流动特征嵌入层之后有 1 层隐藏层.两个神经网络的训练批次大小都为 64,训练集迭代次数 epoch 为 1 000.为了确定神经网络学习效果最佳的隐藏层节点数量以及学习率,本文使用网格搜索对上述超参数进行了调优.每一层隐藏层节点数的搜索范围都为 [16, 128],学习率的搜索范围为  $[3 \times 10^{-4}, 3 \times 10^{-3}]$ .通过网格搜索,传统 DBN 最佳的三层隐藏层节点数分别为 128, 64, 16,学习率为  $1.6 \times 10^{-3}$ ; EFFN 最佳的三层隐藏层节点数分别为 32, 64, 128,学习率为  $1.4 \times 10^{-3}$ .

根据上述最优超参数配置,分别对传统 DBN 以及 EFFN 进行训练,训练过程的验证集输出损失  $L_{\text{output}}$  变化曲线如图 10 所示.可以看出经过迭代后, EFFN 的验证集损失函数显著低于 DBN 的验证集损失函数,即平

均相对误差 MSE 更小,拥有更高的精度.

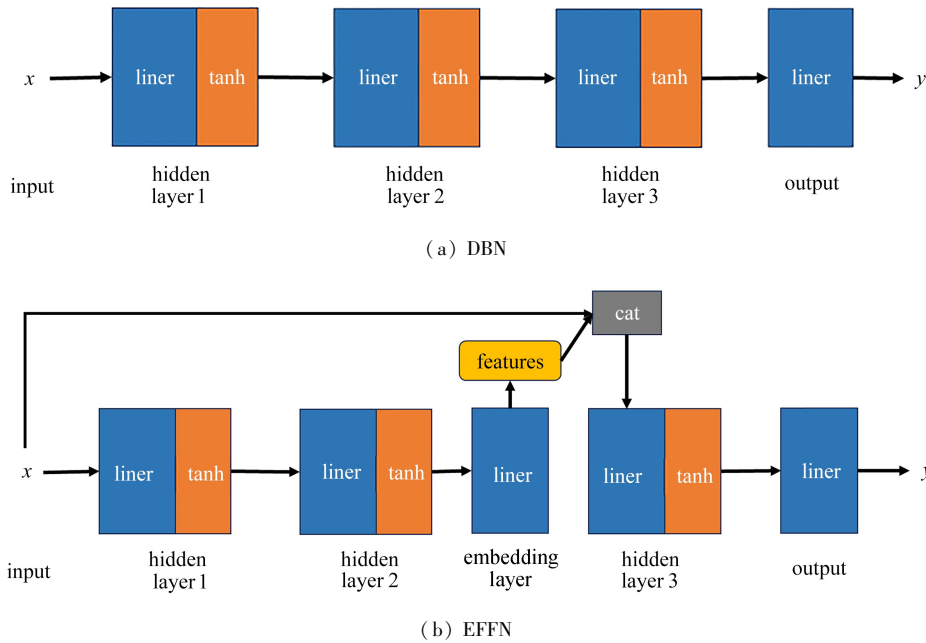
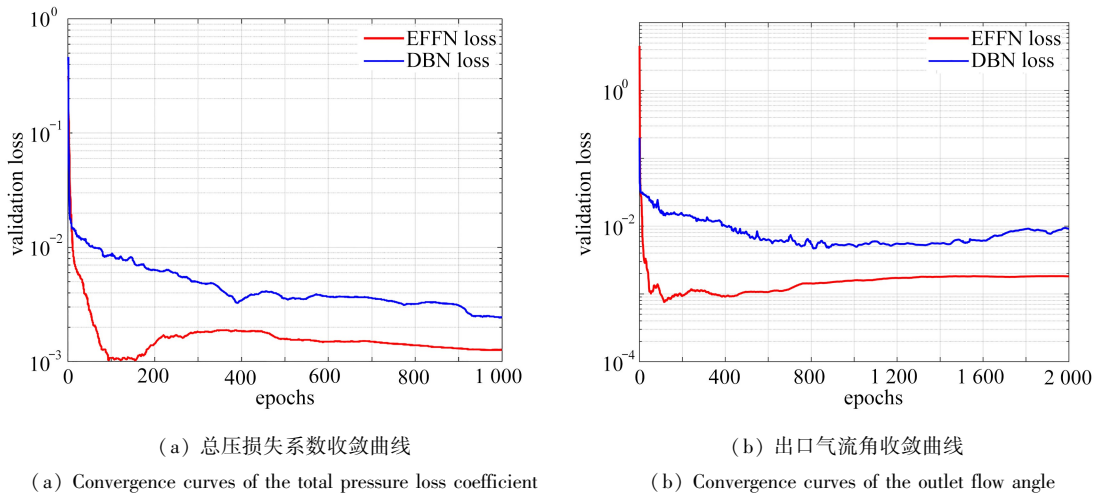


图9 两种代理模型结构示意图

Fig. 9 Schematic diagram of 2 types of surrogate models



(a) 总压损失系数收敛曲线

(a) Convergence curves of the total pressure loss coefficient

(b) 出口气流角收敛曲线

(b) Convergence curves of the outlet flow angle

图10 代理模型收敛曲线

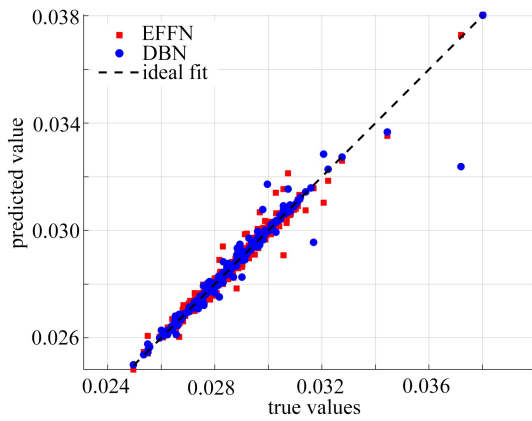
Fig. 10 Convergence curves of surrogate models

图11展示了EFFN模型和DBN模型的总压损失系数预测结果.可以看出,对于总压损失系数集中在0.025到0.03附近的数据,无论训练集还是测试集,EFFN与DBN没有明显区别.但超出0.03范围后,EFFN在测试集的预测效果显现,相比DBN拥有更低的预测误差,测试集回归系数可以达到0.98,而DBN只有0.93.同时,从误差直方图可明显看出EFFN的误差分布更集中,锐度更高,在测试集预测上拥有更好的表现.

图12展示了EFFN模型和DBN模型的出口气流角预测结果.可以看出,无论训练集还是测试集,EFFN模型的预测效果都优于DBN模型,EFFN模型测试集回归系数可以达到0.97,而DBN只有0.92.同时,从误差直方图可以明显看出EFFN的误差分布集中在原点两侧,且异常预测值更少,相比DBN模型在测试集预测上拥有更好的表现.


图13展示了测试集EFFN模型和DBN模型的相对误差对比,可以看出EFFN相对误差整体小于DBN.图13(a)中除个别样本点外,EFFN模型总压损失系数测试集相对误差小于2%,而DBN模型则有多个样本点误差超过4%.图13(b)中除个别样本点外,EFFN模型出口气流角测试集相对误差均小于1%,而DBN模

型则有多个样本点误差较大。




(a) 训练集预测回归散点图

(a) The scatter plot of the training set prediction regression




(b) 测试集预测回归散点图

(b) The scatter plot of the test set prediction regression



(c) 训练集预测误差直方图

(c) The histogram of the training set prediction errors

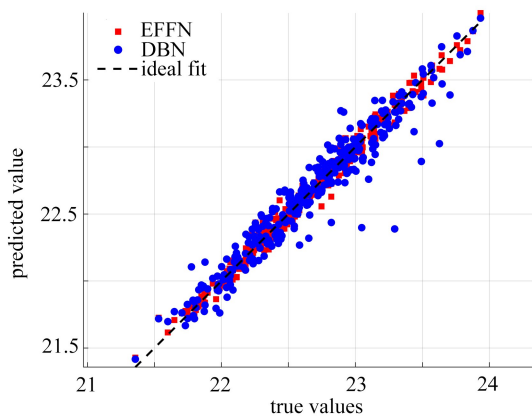


(d) 测试集预测误差直方图

(d) The histogram of the test set prediction errors


图 11 二维叶型总压损失系数预测

Fig. 11 Predictions of total pressure loss coefficients for 2D blade profiles



(a) 训练集预测回归散点图

(a) The scatter plot of the training set prediction regression



(b) 测试集预测回归散点图

(b) The scatter plot of the test set prediction regression

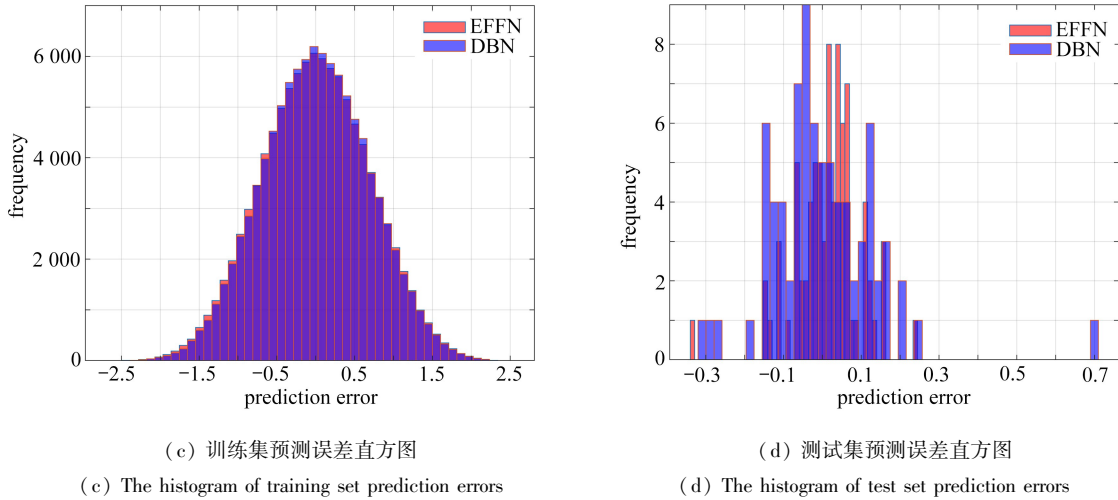


图 12 二维叶型出口气流角预测  
Fig. 12 Predictions of outlet flow angles for 2D blade profiles

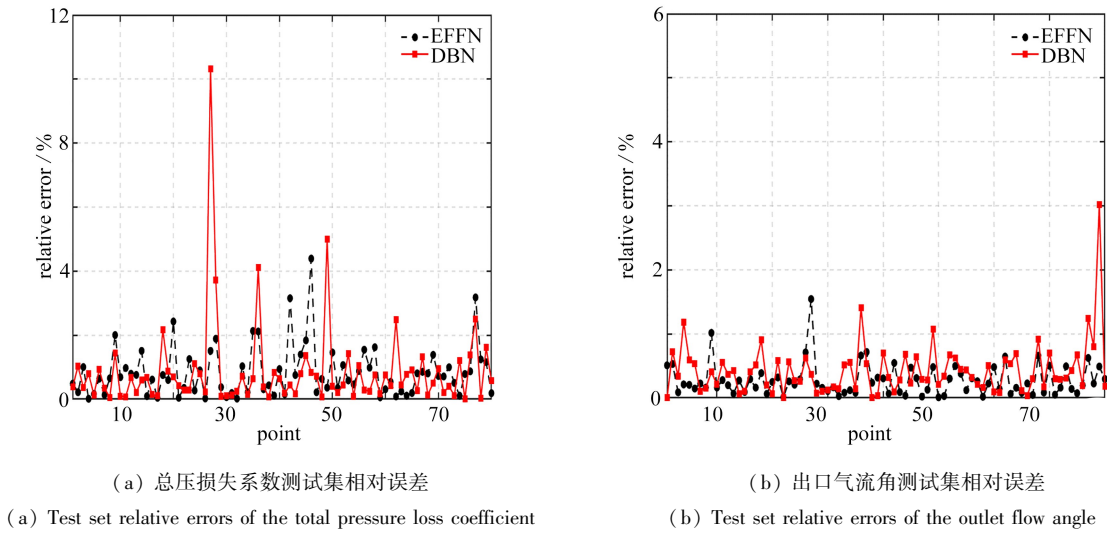


图 13 EFFN 与 DBN 测试集相对误差

Fig. 13 Relative errors of EFFN and DBN on the test set

### 3.3 基于遗传算法的优化设计方法

基于上述流动特征空间以及代理模型开展二维叶型的损失性能目标优化.二维叶型总压损失气动性能的优化问题可以表述为

$$\begin{cases} \min f_1 = \omega(\mathbf{g}), \\ \text{s.t. } |\beta_2 - \beta_2^0| \leq 0.5^\circ, \end{cases} \quad (12)$$

其中,设计变量为叶型的几何改变量参数  $\mathbf{g}$ , 并约束出口气流角  $\beta_2$  相对于原始叶型出口气流角  $\beta_2^0$  的变化量不超过  $0.5^\circ$ .

使用遗传算法对二维叶型气动性能进行优化,优化目标为得到总压损失系数最小的叶型.其中,遗传算法的参数如表 5 所示,未设置破出循环条件.


在使用遗传算法寻优的过程中,总压损失系数随着迭代的改变如图 14(a) 所示,各设计变量的变化如图 14(b) 所示.

与使用传统 DBN 模型进行优化比较,结果如表 6 所示.基于 EFFN 的最优叶型总压损失系数为 0.023 7, 相对基准叶型降低 18.0%;基于 DBN 代理模型的最优叶型总压损失系数为 0.023 9, 相对减少 17.3%.因此, EFFN 模型与传统 DBN 模型优化下的结果相比提升了优化能力.

表 5 遗传算法参数设置

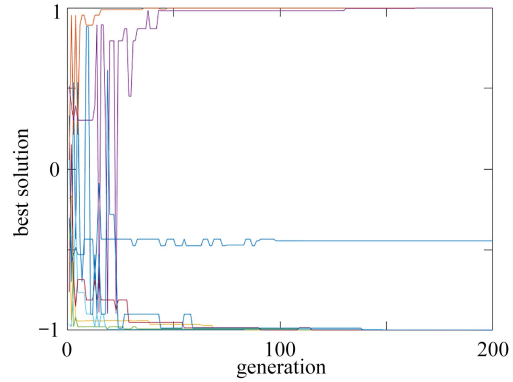
Table 5 Parameter settings of the genetic algorithm

parameter	value
population size	100
crossover probability	0.5
mutation probability	0.1
number of maximum generations	200



(a) 总压损失系数最优解迭代过程

(a) The iteration process of optimal solutions of the total pressure loss coefficient



(b) 设计变量迭代过程

(b) The iteration process of design variables

图 14 遗传算法迭代过程

Fig. 14 The genetic algorithm iteration process

同时,对于叶型而言,出口气流角的变化对其在三维叶片中的效率有较大影响,故需保证出口气流角变化量较小,EFFN 代理模型优化得到的出口气流角相对变化仅为 1.3%。

表 6 基准叶型与最优叶型对比

Table 6 Comparison of baseline and optimal blade profiles

	total pressure loss coefficient	relative error/%	outlet flow angle/(°)	relative error/%
baseline	0.028 9	-	22.5	-
EFFN OPT	0.023 7	-18.0	22.8	1.3
DBN OPT	0.023 9	-17.3	22.9	1.8

## 4 优化结果分析

### 4.1 总体性能分析

原始与优化叶型几何对比如图 15 所示,与原始叶型相比,两种模型优化后的叶型吸力面中部的厚度以及曲率都有一定的增加,压力面中部厚度略微增加且形状更为平坦,其中 EFFN 模型优化后叶型在吸力面中部的厚度明显大于 DBN 优化后叶型。

进一步分析叶型优化结果,对优化后叶型进行了流场分析,并与原始叶型进行了比较.优化后叶型设计性能参数的真实值与预测值如表 7 所示.基于 EFFN 的代理模型对于最终优化后叶型的总压损失系数与出口气流角预测的相对误差均小于 1.5%,表明了使用代理模型辅助优化算法所获得的优化结果具有可靠性。

### 4.2 流场对比分析

原始与优化叶型的静压分布云图如图 16 所示.从图中可以看出,经过优化设计后,原始叶型的前缘压力面静压分布更加平滑,原始叶型前缘压力面处的静压洼地消失,流动情况明显改善.基于 EFFN 模型优化后的构型整体载荷分布大于 DBN 模型的优化结果,且 EFFN 模型优化结果在吸力面中后部的静压明显大于 DBN 优化结果,因此 EFFN 模型总压损失系数更小,拥有更好的优化效果。

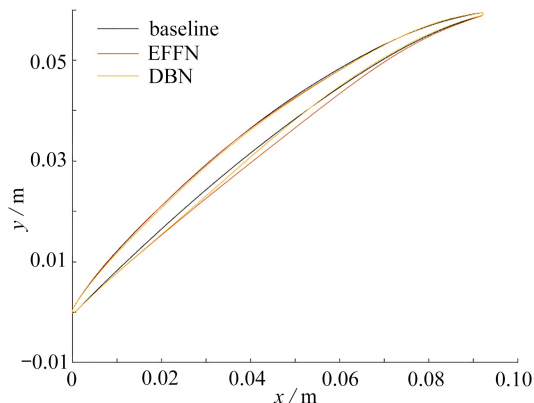


图 15 原始与优化叶型几何拓扑结构

Fig. 15 Comparison of geometric topologies between original and optimized blade profiles

表 7 优化叶型气动参数对比

Table 7 Comparison of aerodynamic parameters for optimized blade profiles

	total pressure loss coefficient	relative error/%	outlet flow angle/(°)	relative error/%
CFD	0.024 0	-	22.7	-
EFFN	0.023 7	1.3	22.8	0.4

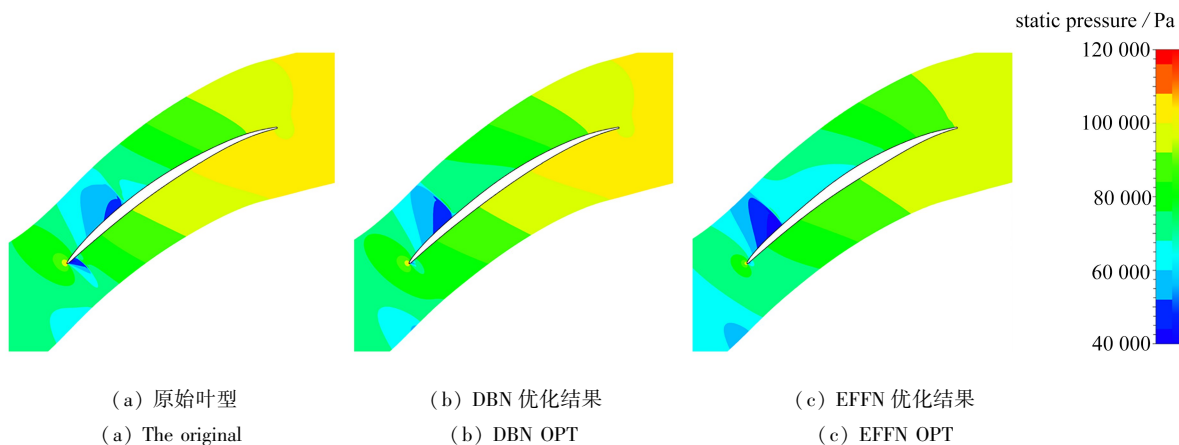


图 16 原始与优化叶型的静压分布云图对比

Fig. 16 Comparison of the static pressure contours between the original and optimized blade profiles




图 17 原始与优化叶型的等熵 Mach 数分布云图对比

Fig. 17 Comparison of the isentropic Mach number contours between the original and optimized blade profiles

原始与优化叶型的表面等熵 Mach 数分布云图如图 17 所示.从图中可以看出,经过优化设计后,吸力峰

有一定减弱,吸力面波前的载荷以及等熵 Mach 数峰值得到了一定的降低.基于 EFFN 模型优化后的等熵 Mach 数在压力面前段小于 DBN 模型的优化结果,流动特征的改善导致 EFFN 模型总压损失系数优化结果优于 DBN 模型.

## 5 结 论

本文提出一种 EFFN 代理模型,在样本数量及隐藏层数量相同的情况下,基于 EFFN 的代理模型对于真实值的预测精度高于 DBN,且对于真实值具有更高的回归拟合能力.基于 EFFN 的代理模型对于叶型气动优化问题的优化性能同样优于 DBN 模型.在对原始叶型进行优化设计后,基于 DBN 模型的优化叶型总压损失系数相对减少 17.3%,而 EFFN 模型的优化叶型总压损失系数相对减少 18.0%,基于 EFFN 模型优化叶型的损失性能得到更好地改善.

## 参考文献(References):

- [1] 王强,郑日恒,陈懋章.航空发动机科学技术的发展与创新[J].科技导报,2021,39(3):59-70.(WANG Qiang, ZHENG Riheng, CHEN Maozhang. Development and innovation of aeroengine science and technology[J]. *Science & Technology Review*, 2021, 39(3): 59-70. (in Chinese))
- [2] 周正贵.压气机/风扇叶片自动优化设计的研究现状和关键技术[J].航空学报,2008,29(2):257-266.(ZHOU Zhenggui. Current situations and key techniques of automatic aerodynamic design of compressor/fan blades [J]. *Acta Aeronautica et Astronautica Sinica*, 2008, 29(2): 257-266. (in Chinese))
- [3] CUMPSTY N A. *Compressor Aerodynamics*[M]. 2nd ed. Cambridge: Cambridge University Press, 2004.
- [4] DENTON J D. Loss mechanisms in turbomachines[R]. New York: American Society of Mechanical Engineers, 1993.
- [5] 陈懋章,刘宝杰.大涵道比涡扇发动机风扇/压气机气动设计技术分析[J].航空学报,2008,29(3):513-526.(CHEN Maozhang, LIU Baojie. Fan/compressor aero design technology for high bypass ratio turbofan[J]. *Acta Aeronautica et Astronautica Sinica*, 2008, 29(3): 513-526. (in Chinese))
- [6] 王聪.多流程数据驱动正/反设计方法研究及其在航空发动机部件气动设计中的应用[D].上海:复旦大学,2023.(WANG Cong. Research on multi-process data-driven direct/inverse design method and its application in aero-engine component aerodynamic design[D]. Shanghai: Fudan University, 2023. (in Chinese))
- [7] HOLMES P, LUMLEY J L, BERKOOZ G. *Turbulence, Coherent Structures, Dynamical Systems, and Symmetry*[M]. Cambridge: Cambridge University Press, 1996.
- [8] WILLCOX K, PERAIRE J. Balanced model reduction via the proper orthogonal decomposition[J]. *AIAA Journal*, 2002, 40(11): 2323-2330.
- [9] TOAL D J J, BRESSLOFF N W, KEANE A J, et al. Geometric filtration using proper orthogonal decomposition for aerodynamic design optimization[J]. *AIAA Journal*, 2010, 48(5): 916-928.
- [10] SKINNER S N, ZARE-BEHTASH H. State-of-the-art in aerodynamic shape optimisation methods[J]. *Applied Soft Computing*, 2018, 62: 933-962.
- [11] 刘伟,徐一冰,王秋钧,等.压气机三维叶片代理辅助优化中无效样本点处理方法研究[C]//第六届空天动力联合会议暨中国航天第三专业信息网第四十二届技术交流会暨 2021 航空发动机技术发展高层论坛论文集.成都,2022:130-138.(LIU Wei, XU Yibing, WANG Qiujun, et al. Research on invalid sample points processing method in surrogate-assisted optimization of 3D compressor blades[C]//China Association for Science and Technology Aero Engine Industry-University Consortium. *Proceedings of the 6th Joint Conference on Aerospace Power and the 42nd Technical Exchange Conference of the Third Professional Information Network of China Aerospace*. Chengdu, 2022: 130-138. (in Chinese))
- [12] 郝书荣.压气机叶片气动力建模智能化方法研究[D].北京:北京工业大学,2021.(HAO Shurong. Study on the intelligent modeling of the blade aerodynamic force in compressor[D]. Beijing: Beijing University of Technology, 2021. (in Chinese))
- [13] YONDO R, ANDRÉS E, VALERO E. A review on design of experiments and surrogate models in aircraft real-time and many-query aerodynamic analyses[J]. *Progress in Aerospace Sciences*, 2018, 96: 23-61.

- [14] BARNHART S A, NARAYANAN B, GUNASEKARAN S. Blown wing aerodynamic coefficient predictions using traditional machine learning and data science approaches[C]//*AIAA Scitech 2021 Forum*. 2021.
- [15] GOODFELLOW I, BENGIO Y, COURVILLE A. *Deep Learning*[M]. Cambridge: MIT Press, 2016.
- [16] SUN G, WANG S. 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**: 5863-5872.
- [17] SECCO N R, DE MATTOS B S. Artificial neural networks to predict aerodynamic coefficients of transport airplanes[J]. *Aircraft Engineering and Aerospace Technology*, 2017, **89**(2): 211-230.
- [18] DU X, HE P, MARTINS J R. A B-spline-based generative adversarial network model for fast interactive airfoil aerodynamic optimization[C]//*AIAA Scitech 2020 Forum*. Orlando, 2020.
- [19] DU X, HE P, MARTINS J R R A. Rapid airfoil design optimization via neural networks-based parameterization and surrogate modeling[J]. *Aerospace Science and Technology*, 2021, **113**: 106701.
- [20] WANG X D, HIRSCH C, KANG S, et al. Multi-objective optimization of turbomachinery using improved NSGA-II and approximation model[J]. *Computer Methods in Applied Mechanics and Engineering*, 2011, **200**(9/10/11/12): 883-895.
- [21] LI J C, DU X S, MARTINS J R R A. Machine learning in aerodynamic shape optimization[J]. *Progress in Aerospace Sciences*, 2022, **134**: 100849.
- [22] 孙刚, 王聪, 王立悦, 等. 人工智能在气动设计中的应用与展望[J]. *民用飞机设计与研究*, 2021(3): 1-9. (SUN Gang, WANG Cong, WANG Liyue, et al. Application and prospect of artificial intelligence in aerodynamic design[J]. *Civil Aircraft Design & Research*, 2021(3): 1-9. (in Chinese))
- [23] HICKS R M, HENNE P A. Wing design by numerical optimization[J]. *Journal of Aircraft*, 1978, **15**(7): 407-412.
- [24] ZHOU S, ZHOU H, YANG K, et al. Research on blade design method of multi-blade centrifugal fan for building efficient ventilation based on Hicks-Henne function[J]. *Sustainable Energy Technologies and Assessments*, 2021, **43**: 100971.
- [25] 李正, 余华蔚, 尹红顺, 等. 椭圆前缘锐化度对亚声速压气机叶片性能的影响[J]. *燃气涡轮试验与研究*, 2018, **31**(3): 14-17. (LI Zheng, YU Huawei, YIN Hongshun, et al. The influence of ellipse leading edge sharpness on the performance of subsonic compressor blade[J]. *Gas Turbine Experiment and Research*, 2018, **31**(3): 14-17. (in Chinese))
- [26] 吕剑波. 前缘几何对高负荷压气机叶型气动性能影响研究[D]. 北京: 中国科学院大学, 2015. (LÜ Jianbo. The influence of leading-edge geometry on aerodynamics of high lift compressor cascades[D]. Beijing: University of Chinese Academy of Sciences, 2015. (in Chinese))
- [27] 胡南平, 周正贵. 平面叶栅流场非定常特性分析[J]. *科学技术与工程*, 2022, **22**(26): 11705-11714. (HU Nanping, ZHOU Zhenggui. Analysis of unsteady characteristics of planar cascade flow field[J]. *Science Technology and Engineering*, 2022, **22**(26): 11705-11714. (in Chinese))
- [28] 刘红波, 陆刚, 边宽江. 几种实验设计方法的比较[J]. *安徽农业科学*, 2007, **35**(36): 11738-11739. (LIU Hongbo, LU Gang, BIAN Kuanjiang. Comparison among several methods of experimental design[J]. *Journal of Anhui Agricultural Sciences*, 2007, **35**(36): 11738-11739. (in Chinese))
- [29] GIUNTA A A, WOJTKIEWICZ JR S F, ELDRED M S. Overview of modern design of experiments methods for computational simulations [C]//*In 41st Aerospace Sciences Meeting and Exhibit*. Reno, Nevada, 2003.
- [30] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, **18**(7): 1527-1554.
- [31] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, **313**(5786): 504-507.