

应用不同深度学习代理模型的灯笼型扰流柱通道 换热性能分布预测方法比较

高尚鸿, 张韦馨, 杨克峰, 汪翔宇, 丰镇平

(西安交通大学能源与动力工程学院, 710049, 西安)

摘要: 为提高对灯笼型扰流柱通道端壁面的换热分布预测能力, 构建并比较了几种深度学习代理模型的预测性能。应用数据驱动的思想, 建立了多项式响应面模型(RSM)、径向基函数模型(RBF)、径向基神经网络模型(RBFNN)、Kriging模型和总体平均近似模型(Ensemble)共5种传统代理模型以及5种基于生成对抗网络的深度学习代理模型, 包括有残差网络的pix2pix模型、pix2pixHD模型、CycleGAN模型、StarGAN模型以及单一无残差网络的pix2pix模型, 以扰流柱截面参数为设计变量, 通过拉丁超立方抽样分别得到了样本数为50、25、12、6和3的训练集, 并根据扰流柱尾迹高换热区分布特点, 将训练样本数为50的数据集分为宽样本数据集和窄样本数据集, 比较了不同代理模型对端壁面换热性能的预测精度、计算成本和泛化能力。结果表明: 有残差网络的pix2pix模型相比于无残差网络的pix2pix模型, 预测精度得到有效提高, 在样本数为50的情况下, 面平均值预测误差从0.68%降低到0.32%, 平均相对误差从6.89%降低到6.41%, 而且当训练样本数减少时, 有残差网络的模型预测能力更加突出; 传统代理模型的时间成本可忽略不计, 但深度学习模型的单卡训练时间较长, 且增加残差网络后的模型计算成本更高; 当训练样本数为50时, 传统代理模型和深度学习模型之间预测精度差异不大; 当训练样本数逐渐减少时, 深度学习代理模型展示出更高的预测精度和泛化能力; Kriging模型虽然泛化能力强, 但是预测结果趋同; RSM模型、RBF模型和Ensemble模型泛化能力最差, 训练样本数较少时, 预测结果严重失真。可见在换热性能预测方面, 深度学习模型在预测精度与泛化能力上均有显著优势, 尤其适合于小样本问题, 对提高灯笼型扰流柱截面设计效率具有参考价值。

关键词: 燃气轮机; 代理模型; 深度学习; 扰流柱; 换热性能预测

中图分类号: TK474.7 **文献标志码:** A

DOI: 10.7652/xjtub202402004 **文章编号:** 0253-987X(2024)02-0031-12

Comparison of Different Prediction Methods for Heat Transfer Distribution of Lantern-Shaped Pin-Fin Channel with Different Deep Learning Surrogate Models

GAO Shanghong, ZHANG Weixin, YANG Kefeng, WANG Xiangyu, FENG Zhenping

(School of Energy and Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: In order to improve the prediction ability of heat transfer performance on lantern-shaped pin-fin endwall, several deep learning surrogate models are constructed and their prediction performance compared. Based on data-driven thinking, five traditional surrogate models,

namely polynomial response surface model (RSM), radial basis function model (RBF), radial basis function neural network (RBFNN), Kriging model and ensemble of surrogate model (Ensemble) are proposed. Additionally, five generative adversarial network surrogate models based on deep learning, namely pix2pix model, pix2pixHD model, CycleGAN model, StarGAN model all with residual network, and another pix2pix model without residual network are proposed. The training sets with various sample numbers of 50, 25, 12, 6 and 3 were obtained by Latin hypercube sampling, respectively, using the pin-fin cross-sectional shape as the design variables. According to the distribution characteristics of high heat transfer zone, the dataset with a training sample number of 50 is divided into a wide sample dataset and a narrow sample dataset. On this basis, the various heat transfer performance of different surrogate models are compared in terms of prediction accuracy, computational cost and generalization ability. The results show that, compared with the pix2pix model without residual network, the prediction accuracy of the pix2pix model with residual network is effectively improved, and the prediction error of the surface mean is reduced from 0.68% to 0.32%, and the averaged relative error is reduced from 6.89% to 6.41% when the sample number is 50. When the number of training samples decreases, the prediction performance of the models with residual network becomes more prominent. The time cost of traditional surrogate models is negligible, but the training time of deep learning models is long especially for models with residual network. When the number of training samples is 50, there is little difference in prediction accuracy between the traditional surrogate models and deep learning models. With gradual decrease in the number of training samples, deep learning surrogate models show higher prediction accuracy and generalization capabilities. Although the Kriging model has strong generalization ability, the prediction results tend to be similar. RSM model, RBF model, and Ensemble model have the lowest generalization ability, and the prediction results are severely distorted when there are fewer training samples. For the heat transfer distribution prediction of the pin-fin endwall, the deep learning models possess significant advantages in terms of both prediction accuracy and generalization ability, which are more suitable for small batch sample problems. This study has important reference value for improving the cross-sectional shape design efficiency of lantern-shaped pin-fin.

Keywords: gas turbine; surrogate model; deep learning; pin-fin; prediction of heat transfer performance

近年来,随着现代燃气轮机透平入口温度不断升高,当前透平进口总温已经远高于叶片基体材料的耐温极限^[1],不仅对叶片冷却结构设计提出更加苛刻的要求,而且冷却单元设计周期更长、成本更高。透平叶片尾缘和双层壁中常采用扰流柱所组成的阵列,这是因为扰流柱非常有利于提高透平叶片内部冷却空气的湍流度,增强叶片金属部分与冷却空气的对流换热强度,进而降低叶片热负荷。同时,多排扰流柱还能起到支撑作用,增强叶片强度。目前,国内外学者已经对扰流柱阵列分布^[2]、扰流柱对劈缝气膜冷效的影响^[3]、扰流柱通道内的涡系结构^[4]、空气/汽雾工质^[5]和扰流柱对双层壁换热特性的影响^[6]等进行了广泛和深入的研究。

随着燃气轮机数字化和优化设计水平的提高,为降低实验和计算成本,研究者们提出了基于数据驱动的代理模型方法。基于数据驱动的代理模型是以数据为基础,以数理统计和机器学习等技术为手段,通过建立复杂的函数映射关系来计算预测值的方法^[7],是一种包含数据空间采样和预测方法的综合建模技术^[8]。传统的代理模型基于统计学理论和机器学习方法来构建预测模型,如多项式响应面模型^[9]、径向基神经网络模型^[10]、Kriging 模型^[11]和人工神经网络^[12]等。

对传统代理模型,本研究团队(TurboAero 团队)开展了相关研究工作。刘战胜等^[13-15]分别用径向基函数模型和 Kriging 模型对透平叶型、端壁和

气膜孔进行优化;张韦馨等^[16]利用径向基神经网络代理模型和杜鹃搜索优化算法对平板气膜孔进行了优化。但是,目前的传统数学统计和机器学习方法过多依赖于人工特征提取,而深度学习可自适应地逐层挖掘特征,更适于高维、海量和非线性问题。

随着深度学习技术的发展与成熟,生成对抗网络(generative adversarial networks, GAN)^[17]已经被国内外不少学者应用到燃气轮机透平叶片的冷却性能预测和优化设计当中。Yang 等^[18]研究了基于生成对抗网络的发散冷却效率分布预测;戴维等^[19]研究了基于生成对抗网络的透平端壁气膜冷却建模方法;李左颀等^[20-21]研究了生成对抗网络对气膜冷却的预测;Jiang 等^[22]研究了多尺度 pix2pix 网络对透平叶片前缘气膜冷却的预测。

综上所述,目前尚未有相关文献系统比较深度学习代理模型和传统代理模型在扰流柱通道端壁面换热分布预测方面的优劣。因此,本文针对本研究团队杨克峰等提出的灯笼型扰流柱通道结构^[23],经过拉丁超立方抽样得到 7 个不同训练数据集,构建了多项式响应面模型(RSM)、径向基函数模型(RBF)、径向基神经网络模型(RBFNN)、Kriging 模型、总体平均近似模型(Ensemble)^[24]、有/无残差网络模块的 pix2pix 模型^[25]、pix2pixHD 模型^[26]、CycleGAN 模型^[27]和 StarGAN 模型^[28]。最后,从预测精度、计算成本和泛化能力 3 个方面系统评估了各代理模型对灯笼型扰流柱端壁面换热性能分布的预测能力。

1 数据集及评价指标

1.1 数据集及数据处理

灯笼型扰流柱通道模型的几何特征如图 1 所示,共包含 8 排扰流柱,扰流柱根部直径 D 为 25.4 mm。




图 1 扰流柱通道几何示意

Fig. 1 The geometry of lantern-shaped pin-fin channel

灯笼型扰流柱的原型是圆柱与球体的合并,圆柱和球体同心,球体直径为 $1.7D$ 。灯笼型扰流柱的截面采用 B 样条曲线旋转而成,B 样条曲线由 9 个数据点插值而成,包括 4 个固定数据点和 5 个可变数据

点,数据点对称分布,因此只选择其中 3 个可变数据点为截面参数,如图 2 所示。截面参数均沿扰流柱径向平移一段距离作为变量空间,3 个截面参数的变化范围为 $0.1D$ 。具体地: $z_1 \sim z_3$ 的变化范围分别为 $-2.54 \sim 0$ 、 $-1.27 \sim 1.27$ 、 $-1.27 \sim 1.27$ mm;负号方向表示沿径向向扰流柱外侧移动,正号方向表示沿径向向扰流柱内侧移动。




图 2 扰流柱截面轮廓示意

Fig. 2 The geometry of lantern-shaped pin-fin cross section

详细的物理边界条件和 CFD 数值计算过程可参考文献^[23]。本文通过拉丁超立方抽样得到 50 个训练样本参数和 10 个测试样本,为了比较代理模型在不同训练样本数下的泛化能力,又通过拉丁超立方抽样分别得到样本数为 25、12、6 和 3 的数据集。为进一步研究代理模型对不同数据特征的泛化能力,本文还根据换热云图展向分布特点,将所有样本分为两份:24 个宽样本和 26 个窄样本,如图 3 所示。宽样本表示扰流柱后一段区域展向换热较强,表现为白色区域宽短。窄样本表示流向换热较强,表现为白色区域细长。




图 3 宽样本和窄样本的特点

Fig. 3 Features of wide and narrow samples

在数据处理模块中对所有数据进行归一化和灰度化,并插值为长宽均为 256 的方形矩阵,深度学习模型的数据处理流程如图 4 所示。在计算设备上,传统代理模型采用 6 核 i5-9400F CPU 计算,深度学习代理模型采用一颗 12 GB 显存的 NVIDIA GeForce RTX 2060 独显计算。




图 4 深度学习代理模型的数据预处理流程
Fig. 4 Data preprocessing flow for deep learning

本文共有 10 个测试样本,但由于篇幅有限,本文仅展示 5 个测试样本的预测结果分布,从上到下依次按 Test 1~Test 5 排列,各个样本的截面参数如表 1 中所示。

表 1 5 个测试样本的截面参数

Table 1 Cross-sectional parameters for five test samples

测试样本	z_1/mm	z_2/mm	z_3/mm
1	-1.856 8	-0.222 5	0.990 0
2	-0.359 0	0.307 9	1.075 1
3	-1.441 8	-1.102 9	0.146 3
4	-1.196 6	1.110 7	-0.570 5
5	-2.040 8	-0.902 8	-1.054 9

1.2 预测精度的评价指标

本文在 CFD 后处理过程中采用 Nu 来表示换热性能,计算公式为

$$Nu = \frac{hD_c}{\lambda} \tag{1}$$

式中: h 为换热系数; D_c 为通道的水力直径; λ 为流体热导率。本文基于 Nu 云图进行数据处理,预测云图中的 Nu 的范围为 0~200。

为了评估真实云图和预测云图之间的差异,本文对云图中的像素值进行简单处理,公式为

$$y = \begin{cases} 0, & p = 0 \\ Nu, & 0 < p < 255 \\ 200, & p = 255 \end{cases} \tag{2}$$

式中: y 为真实云图每个像素点的评估值; p 为像素灰度,取值范围为 0~255; Nu 的上限为 200。

本文将代理模型的预测精度指标分为面平均值的预测精度和分布的预测精度。面平均值的精度用相对误差来衡量,公式为

$$E_r = \left| \frac{\bar{\hat{y}} - \bar{y}}{\bar{y}} \right| \tag{3}$$

式中: $\bar{\hat{y}}$ 为预测云图的面平均值, $\hat{y}$ 为预测云图每个像素点的评估值; $\bar{y}$ 为真实云图的面平均值。

换热分布的预测精度用云图上所有点的平均相

对误差来衡量,公式为

$$\bar{E}_r = \frac{1}{q} \sum_{i=1}^q \left| \frac{\hat{y}_i - y_i}{y_i} \right| \tag{4}$$

式中: q 为云图上的像素点数。

均方误差也可以衡量 Nu 分布预测精度,本文统一对所有点进行归一化后计算其均方误差,公式为

$$I_{\text{MSE}} = \frac{1}{q} \sum_{i=1}^q \left(\frac{\bar{y}_i - \hat{\bar{y}}}{200} \right)^2 \tag{5}$$

2 深度学习代理模型介绍及构建

2.1 有/无残差网络的 pix2pix 模型

基于生成对抗网络的 pix2pix 模型可以方便实现图-图翻译和多域转换。pix2pix 模型包括生成器、判别器和识别器 3 个神经网络,其生成器为 U-Net 结构^[29],将几何轮廓图作为条件输入生成器,即可输出对应图像。图 5 为本文所用的 pix2pix 网络结构, z 为扰流柱的截面参数, z' 为预测值。




图 5 pix2pix 网络结构
Fig. 5 Network structure of pix2pix

本文的生成器主要有两种,一种采用普通卷积层,另一种采用残差网络。图 6 展示了本文采用的残差神经网络单元(residual network, ResNet)^[30],其由 I 个普通卷积层组成,输入数据通过卷积层后再与输入相加。




图 6 残差网络结构
Fig. 6 Residual network structure

判别器的作用是判断生成器输出结果的真假。识别器的作用是通过云图识别其对应的截面形状参数,保证生成结果的多样性。其结构的前半部分与判别器基本相同,后半部分采用全连接层。

pix2pix 的损失函数由生成器和判别器的对抗损失、预测云图和目标云图的 L_1 损失以及预测截面形状参数和目标截面形状参数的 L_1 损失构成。

2.2 pix2pixHD 模型

本文所用的 pix2pixHD 网络结构如图 7 所示。




图 7 pix2pixHD 网络结构
Fig. 7 Network structure of pix2pixHD

2.3 CycleGAN 模型

本文所用的 CycleGAN 模型的基本组成结构如图 8 所示,包含 A、B 两个生成器,实现了输入和输出的互相转换。循环一致损失为图中黑色箭头标注的过程,生成器 B 生成的几何特征经过生成器 A 生成对应的云图(即循环输出),并与目标云图计算 L_1 损失。同理,生成器 A 生成的云图也要经过生成器 B 生成对应的几何特征(即循环输入),并与目

标的输入参数计算 L_1 损失。

2.4 StarGAN 模型

本文所用的 StarGAN 仅用来实现几何特征到云图的映射部分,通过两个编码器对输入参数进行进一步编码再输入生成器进行预测,整个网络的结构如图 9 所示。两个编码器共同对几何参数提取特征,进一步提高了深度学习的特征提取能力。




图 8 CycleGAN 网络结构
Fig. 8 Network structure of CycleGAN




图 9 StarGAN 网络结构
Fig. 9 Network structure of StarGAN

3 不同模型预测能力的对比分析

3.1 训练样本数为 50 时的预测性能对比

3.1.1 整体的预测能力对比

表 2 对所有测试样本的预测结果进行了评价并统计了各个指标的样本平均值。结果表明,对于面平均值的相对误差 E_r ,所有代理模型都非常小。无残差模块的 pix2pix 模型的面平均值相对误差 E_r 最大为 0.68%,有残差模块的 pix2pix 模型 E_r 明显降低为 0.32%,RSM 模型的 E_r 最小,为 0.20%。对于换热云图上所有像素点的平均相对误差 $\bar{E}_r$,RBF 模型较大,达到 8.71%,RSM 模型最小,为 5.76%,其他模型均在 6%~7%之间,而且 pix2pix 模型在增加残差网络后, $\bar{E}_r$ 从 6.89%降低到 6.41%。

表 2 各代理模型评价指标的样本平均值
Table 2 The sample mean of evaluation metrics for various surrogate models

代理模型	$E_r/\%$	$\bar{E}_r/\%$	$I_{MSE}/\%$
无残差 pix2pix	0.68	6.89	0.37
残差 pix2pix	0.32	6.41	0.33
pix2pixHD	0.31	6.29	0.31
CycleGAN	0.42	6.50	0.34
StarGAN	0.41	6.24	0.31
RSM	0.20	5.76	0.25
RBF	0.28	8.71	0.59
RBFNN	0.33	6.33	0.30
Kriging	0.36	6.96	0.36
Ensemble	0.35	6.24	0.27

3.1.2 细节的预测能力对比

限于篇幅,本文仅对前 5 个测试样本的 Nu 云图和差值图进行展示。本小节以有/无残差网络模块的 pix2pix 为例,展示真实值 y 和预测值 $\hat{y}$ 的分布,其他模型仅统计真实值与预测值的差 $y-\hat{y}$,如图 10 和图 11 所示。





图 10 有/无残差网络单元的 pix2pix 模型预测结果对比
Fig. 10 Comparison of pix2pix prediction results with and without residual network elements






图 11 其他模型的 $y-\hat{y}$ 图
Fig. 11 $y-\hat{y}$ plots for other models

从 $y-\hat{y}$ 可发现,在扰流柱通道的中后段,尤其是展向分布的两个扰流柱之间,所有代理模型的局部误差均急剧变化,这是因为该区域受上一排扰流柱尾迹、当地涡系等非定常流动现象影响较大,代理模型较难学习到该分布特征。

同一代理模型对不同测试样本的预测精度也不相同。例如,深度学习代理模型对测试样本 4、5 的预测误差较大,但 RSM 模型仅对测试样本 1 误差较大,在其他测试样本上预测效果好。这对代理模型的整体预测能力有直接影响。

此外,在扰流柱边缘区域,深度学习模型预测误差较大,这是由于图像缩放导致数据失真。

3.1.3 时间成本对比

表 3 展示了各代理模型的建模时间和预测时间。从时间成本来看,传统代理模型的建模时间可忽略,但是深度学习代理模型的训练时间成本较高。无残差 pix2pix 模型训练时间最少,训练仅耗时 2.08 h;由于残差网络及训练参数的增加,其他深度学习代理模型训练时间也逐渐增加,StarGAN 训练时间甚至可达 34.2 h。代理模型的预测时间均非常短,主要的时间成本在于模型的构建和训练阶段。

表 3 各代理模型的时间成本

Table 3 The time cost of surrogate models

模型	建模	预测	模型	建模	预测
	时间/ s	时间/ ms		时间/ h	时间/ ms
RSM	0.86	0.9	无残差 pix2pix	2.1	13.9
RBF	12.88	33.5	残差 pix2pix	17.5	18.2
RBFNN	47.08	139.8	pix2pixHD	18.3	20.9
Kriging	6.75	1.9	CycleGAN	25.8	18.0
Ensemble	71.10	285.1	StarGAN	34.2	33.9

3.2 训练样本数为 50 时的流向和展向 Nu 分布

图 12 为展向和流向的位置标记,流向距离总长记为 L ,展向距离标记为 S 。本小节以测试样本 1




图 12 流向和展向位置标记

Fig. 12 Flow direction and span direction position

和测试样本 4 为例,进一步分析各代理模型对局部细节的预测能力。

3.2.1 测试样本 1 的预测能力对比

如图 13 所示,在换热云图的流向分布上,深度学习代理模型预测结果基本一致,因此仅展示了有/无残差网络的 pix2pix 模型的对比。对前两排扰流柱,传统代理模型基本与真实值一致;对后 6 排扰流柱,深度学习代理模型对波峰和波谷的预测精度更高。






图 13 各个代理模型的流向分布对比(样本 1)

Fig. 13 Comparison of flow direction distribution between different models (sample 1)

展向分布如图 14 所示,各残差网络模型之间相差不大,无残差 pix2pix 模型在 $0.75S \sim S$ 之间比残差 pix2pix 模型更接近真实值。传统代理模型无法准确预测波峰波谷的位置,其预测误差远远大于残差 pix2pix 模型。测试样本 1 的展向分布真实值基本呈现对称分布,深度学习代理模型与 RSM 模型的预测结果基本符合对称分布的规律,但其他传统代理模型预测规律并不对称。




(a) 无残差 pix2pix、RSM 与 RBF



(b)RBFNN,Kriging 与 Ensemble

图 14 各个代理模型的展向分布对比(样本 1)

Fig. 14 Comparison of span direction distribution between different models (sample 1)



(b)RBFNN,Kriging 与 Ensemble

图 16 各个代理模型的展向分布的对比(样本 4)

Fig. 16 Comparison of span direction distribution between different models (sample 4)

3.2.2 对测试样本 4 的预测能力对比

从流向分布来看,测试样本 4 的预测中,各个代理模型的预测结果与真实值基本一致,如图 15 所示。





图 15 各个代理模型的流向分布的对比(样本 4)

Fig. 15 Comparison of flow direction distribution between different models (sample 4)

图 16 展示了各个代理模型的展向分布。可见各代理模型预测精度均不好,尤其是在 $0.25S \sim 0.375S$ 和 $0.75S \sim 0.875S$ 两个区间,预测结果均远远低于真实值。残差 pix2pix 模型预测精度略高于无残差 pix2pix 模型;传统代理模型之间的区别较为明显,RSM 模型的预测结果与真实值较为接近,也优于残差 pix2pix 模型。整体上,测试样本 4 的展向分布依然呈对称分布,但是只有 RSM 模型的预测结果符合对称规律,其他代理模型的预测规律较为相似,但均不是对称分布。




(a)无残差 pix2pix,RSM 与 RBF

值得注意的是,各代理模型在流向上的预测分布精度高,但在展向上预测分布很难与真实分布一致,这与流向和展向上的换热特征复杂度息息相关。在流向分布中需要计算的是 S 方向 $\bar{y}$,而 S 方向仅有两列扰流柱且换热特征基本对称,需要学习的特征较少;展向分布中需要计算的是 L 方向的 $\bar{y}$,该方向有 8 排扰流柱,且每排后的换热分布都不尽相同,需要学习的特征非常多。流向分布上,预测较差的区域位于左右两排扰流柱之间,换热分布较为复杂;展向分布上,预测较差的是上下两列扰流柱之间的区域,该区域换热分布剧烈变化,为预测带来较大困难。

3.3 泛化能力对比分析

3.3.1 训练样本数对预测精度的影响

图 17 给出了平均相对误差 $\bar{E}_r$ 随训练样本数的变化。可以看出,深度学习代理模型 $\bar{E}_r$ 随样本数的变化趋势平缓。当训练样本数减少到 12 时, $\bar{E}_r$ 基本没变化;当训练样本数为 6 时, $\bar{E}_r$ 开始增加;当训练样本数为 3 时, $\bar{E}_r$ 最大,可达到 11%左右。无残差 pix2pix 误差增加较快,进一步说明残差网络在提高模型精度方面的作用。

图 17 不同样本数 $\bar{E}_r$ 曲线Fig. 17 $\bar{E}_r$ curves for different sample sizes

虽然在传统代理模型中,Kriging 模型的变化趋势较为平缓,泛化能力较强。但是,在预测精度方

面,当训练样本数大于 12 时,Kriging 模型的预测精度并不占优势,平均相对误差 $\bar{E}_r$ 略大;当训练样本数小于 6 时,预测精度甚至优于深度学习模型,最大误差为 10% 左右。

RBFNN 模型的预测精度随样本数的变化较大, $\bar{E}_r$ 最大可达 13% 左右。RSM、RBF 和 Ensemble 模型的泛化能力最差。对于 RSM 模型和 Ensemble 模型,当样本数减小到 6 时,其预测结果的 $\bar{E}_r$ 急剧增加,Ensemble 模型达到 46%,RSM 模型甚至达到 70%。对于 RBF 模型,其 $\bar{E}_r$ 的变化趋势与其他模型不同,随着样本数的减少呈现先减小后急剧增大的变化趋势。当样本数为 6 时, $\bar{E}_r$ 最小,为 6.7%;当训练样本数为 3 时, $\bar{E}_r$ 甚至达到 72%。

在不同训练样本数条件下,各个代理模型的预测能力会发生非常明显的变化。例如,当训练样本数从 50 减少为 25 时,RSM 模型误差大幅增加,在预测精度上失去优势;当训练样本数从 50 减少到 12 时,RBF 模型误差降到最低值,明显优于其他代理模型。但是,有残差网络的深度学习模型的预测误差一直保持在较低水平。

图 18 和图 19 以残差 pix2pix 模型和 RSM 模型为例,展示了不同的训练数据集情况下的换热分布云图,训练集样本情况详见 1.1 小节。可以看出:残差 pix2pix 模型随样本数减小,预测结果没有突兀的变化,但是当预测样本数为 3 时,其预测结果几乎已经变为 3 种固定分布,出现过拟合现象;RSM 模型在样本数为减小到 25 时,已经有局部区域出现




图 18 残差 pix2pix 模型在不同训练数据集条件下的预测结果
Fig. 18 Prediction results under different training datasets for pix2pix with residual modules

重影,并随样本数减小逐渐明显,当样本数为 6 时,预测结果严重失真。




图 19 RSM 模型在不同训练数据集条件下的预测结果
Fig. 19 Prediction results under different training sample count for RSM

图 20 展示了训练样本数为 3 时,其他传统代理模型的换热分布预测结果。可以看出,Kriging 模型和 RBFNN 特征学习能力弱,所有测试样本的预测结果均趋于一致,类似于机器学习领域的模式崩溃现象;RBF 模型和 Ensemble 模型有严重的失真现象,可见 Ensemble 的加权平均思想容易受子模型的干扰。因此,在样本数较少时:深度学习代理模型预测精度和泛化能力均较强;Kriging 模型和 RBFNN 模型虽然泛化能力强,但预测结果趋同;RSM、RBF 和 Ensemble 模型严重失真。




图 20 训练样本数为 3 时其他传统代理模型的预测结果
Fig. 20 Prediction results for other traditional surrogate models of 3 training samples

3.3.2 训练样本特征对预测精度的影响

各模型受训练样本特征的影响也很大,在图 18 和图 19 中已经展示了宽样本和窄样本换热分布图,可见 RSM 模型的预测图像出现失真,残差 pix2pix 模型预测良好,但两种模型得到的分布特征都并不准确。图 21 将不同样本特征得到的预测结果进行了对比,可见训练样本分为宽样本和窄样本后,其平均相对误差 $\bar{E}_r$ 均比 25 个训练样本时有所增加,大多数代理模型在宽样本条件下误差最大,但 Kriging 模型在宽样本和窄样本条件下, $\bar{E}_r$ 基本相同,为 8% 左右,泛化能力较强,这与其特征学习能力弱,预测结果趋同有较大关系。总之,有残差网络的深度学习模型和 Kriging 模型泛化能力较好;RSM 和 RBFNN 模型泛化能力较弱。由此可见,代理模型的预测结果与训练样本特征息息相关,因此在数据采样时必须严格遵循全局抽样方法。




图 21 样本特征变化对预测精度的影响

Fig. 21 The effect of sample features on prediction accuracy

4 结 论

本文针对灯笼型扰流柱阵列通道,以扰流柱面上的 3 个点位置为设计变量,通过拉丁超立方抽样形成了不同的训练数据集和测试数据集,基于数据驱动思想,构建了 RSM、RBF、RBFNN、Kriging、Ensemble 等 5 种传统代理模型和无残差 pix2pix、残差 pix2pix、pix2pixHD、CycleGAN 和 StarGAN 等 5 种深度学习模型,以预测精度、计算成本和泛化能力为预测能力的评价指标,详细分析了各代理模型在全局整体预测和局部细节预测方面的优势与不足,得到的主要结论如下。

(1) 残差网络可提高预测精度,在训练样本数为 50 的条件下,换热云图的面平均值的相对误差 E_r 从 0.68% 降低到 0.32%,所有像素点的平均相对误差 $\bar{E}_r$ 从 6.89% 降低到 6.41%。而且,当训练样本

数减少时,残差网络的深度学习代理模型的预测误差一直较低,而无残差 pix2pix 模型的预测误差则明显增大。

(2) 当训练样本数为 50 时,RSM 模型的预测能力较高,有残差网络的深度学习代理模型次之,RBF 模型预测能力较差。

(3) 从局部细节来看,不同测试样本上各代理模型表现不同,对于测试样本 1,深度学习代理模型预测能力最高,对于测试样本 4,RSM 模型预测效果最好。对于扰流柱边缘,深度学习代理模型存在一定误差,仍需要对数据处理方法进行改进。

(4) 在泛化能力方面,深度学习代理模型和 Kriging 模型平均相对误差 $\bar{E}_r$ 随训练样本数变化平缓,泛化能力最好;Kriging 模型泛化能力强,但特征提取能力弱,生成结果特别单一;RBFNN 的泛化能力次之;RSM、RBF 和 Ensemble 模型在训练样本数减少到 6 和 3 时,预测误差大幅增加,预测结果严重失真。

(5) 当训练样本数和样本特征不同时,各个代理模型的预测能力规律会发生很大变化。当样本数减少后,RSM 模型不再占优势,有残差网络的深度学习代理模型预测精度一直较高。Kriging 模型仅在样本数小于 6 时才表现出更强的预测能力,但此时预测结果非常单一。

(6) 通过对 10 种基于数据驱动的代理模型分别在 7 种训练数据集条件下的预测精度、计算成本和泛化能力的全面比较可知,相比于传统代理模型,有残差网络的深度学习代理模型因其强大的特征提取能力,无论在预测精度还是泛化能力上较其他代理模型均有显著优势,因此更加适合于小样本问题,将大大降低数据集积累成本。

(7) 由于条件限制,本文所采用的数据集仅包含 3 个设计变量。为了充分比较各模型的差异,挖掘深度学习代理模型的潜力,未来应开展高维度和复杂几何条件下的比较研究。此外,本文比较的泛化能力仅限于训练样本数,未来还需考虑不同几何和物理条件等因素。

参考文献:

- [1] 刘钊,杨星,丰镇平. 燃气轮机透平叶片传热和冷却研究: 气膜冷却 [J]. 热力透平, 2014, 43(1): 1-9.
LIU Zhao, YANG Xing, FENG Zhenping. Study on heat transfer and cooling in gas turbine blade: film cooling [J]. Thermal Turbine, 2014, 43(1): 1-9.

- [2] METZGER D E, BERRY R A, BRONSON J P. Developing heat transfer in rectangular ducts with staggered arrays of short pin fins [J]. *Journal of Heat Transfer*, 1982, 104(4): 700-706.
- [3] HORBACH T, SCHULZ A, BAUER H J. Trailing edge film cooling of gas turbine airfoils: external cooling performance of various internal pin fin configurations [J]. *Journal of Turbomachinery*, 2011, 133(4): 041006.
- [4] OTTO M, GUPTA G, TRAN P K, et al. Investigation of endwall heat transfer in staggered pin fin arrays [J]. *Journal of Turbomachinery*, 2021, 143(2): 021009.
- [5] 周子杰, 王新军, 费昕阳. 燃机透平静叶尾缘柱肋通道内的汽雾/空气冷却流动与换热特性数值研究 [J]. *西安交通大学学报*, 2016, 50(11): 21-27.
ZHOU Zijie, WANG Xinjun, FEI Xinyang. Numerical investigation for flow and heat transfer characteristics of air and air/mist cooling in gas turbine stator trailing edge path [J]. *Journal of Xi'an Jiaotong University*, 2016, 50(11): 21-27.
- [6] 韦宏, 祖迎庆. 冲击+扰流柱双层壁冷却结构的强化换热性能及流阻特性 [J/OL]. *航空动力学报*[2023-07-01]. <https://doi.org/10.13224/j.cnki.jasp.20220489>.
WEI Hong, ZU Yingqing. Enhanced heat transfer performance and flow resistance characteristics of the double-wall cooling structures with jet impingement and pins [J/OL]. *Journal of Aerospace Power* [2023-07-01]. <https://doi.org/10.13224/j.cnki.jasp.20220489>.
- [7] 刘文彪. 基于深度学习的旋转设备故障预测方法研究 [D]. 北京: 中国石油大学(北京), 2021.
- [8] 穆雪峰, 姚卫星, 余雄庆, 等. 多学科设计优化中常用代理模型的研究 [J]. *计算力学学报*, 2005, 22(5): 608-612.
MU Xuefeng, YAO Weixing, YU Xiongqing, et al. A survey of surrogate models used in MDO [J]. *Chinese Journal of Computational Mechanics*, 2005, 22(5): 608-612.
- [9] LI Ping, KIM K Y. Multiobjective optimization of staggered elliptical pin-fin arrays [J]. *Numerical Heat Transfer: Part A Applications*, 2008, 53(4): 418-431.
- [10] MOON M A, KIM K Y. Analysis and optimization of fan-shaped pin-fin in a rectangular cooling channel [J]. *International Journal of Heat and Mass Transfer*, 2014, 72: 148-162.
- [11] MOON M A, HUSAIN A, KIM K Y. Shape optimization of a rotating rectangular channel with pin-fins by Kriging method [C]//2010 14th International Heat Transfer Conference. New York, NY, USA: ASME, 2010: 169-176.
- [12] OSTANEK J K. Improving pin-fin heat transfer predictions using artificial neural networks [J]. *Journal of Turbomachinery*, 2014, 136(5): 051010.
- [13] LIU Zhansheng, YANG Kefeng, FENG Zhenping. Aero-thermal coupled design optimization of a turbine vane and the effect on heat load of endwall [C]//ASME Turbo Expo 2020: Turbomachinery Technical Conference and Exposition. New York, NY, USA: ASME, 2020: V02DT38A024.
- [14] LIU Zhansheng, YAGN Xing, GAO Chun, et al. Aero-thermal coupled design optimization of the non-axisymmetric endwall for a gas turbine blade [C]//ASME Turbo Expo 2018: Turbomachinery Technical Conference and Exposition. New York, NY, USA: ASME, 2018: V02DT46A018.
- [15] LIU Zhansheng, YANG Kefeng, YANG Xing, et al. Optimization of fan-shaped film cooling holes for enhancing cooling effectiveness under variable coolant inlet pressure ratios [C]//ASME Turbo Expo 2020: Turbomachinery Technical Conference and Exposition. New York, NY, USA: ASME, 2020: V07BT12A039.
- [16] ZHANG Weixin, LI Feng, JIA Zhe, et al. Experimental study on performance verification test of optimized film cooling holes in a linear cascade [J]. *Applied Thermal Engineering*, 2022, 212: 118574.
- [17] GUI Jie, SUN Zhenan, WEN Yonggang, et al. A review on generative adversarial networks: algorithms, theory, and applications [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 3313-3332.
- [18] YANG Li, DAI Wei, RAO Yu, et al. Optimization of the hole distribution of an effusively cooled surface facing non-uniform incoming temperature using deep learning approaches [J]. *International Journal of Heat and Mass Transfer*, 2019, 145: 118749.
- [19] 戴维, 杨力, 饶宇. 基于生成对抗网络的涡轮端壁气膜冷却建模方法 [J]. *工程热物理学报*, 2020, 41(10): 2420-2424.
DAI Wei, YANG Li, RAO Yu. Modeling method of film cooling of turbine endwall based on generative adversarial networks [J]. *Journal of Engineering Thermophysics*, 2020, 41(10): 2420-2424.
- [20] LI Zuobiao, SU Liangjun, WEN Fengbo, et al. Deep learning method for fast prediction of film cooling performance [J]. *Physics of Fluids*, 2022, 34(4): 047111.
- [21] 李左飙, 温风波, 唐晓雷, 等. 基于深度学习的单排孔气膜冷却性能预测 [J]. *航空学报*, 2021, 42(4): 307-318.

- LI Zuobiao, WEN Fengbo, TANG Xiaolei, et al. Prediction of single-row hole film cooling performance based on deep learning [J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(4): 307-318.
- [22] JIANG Chiju, ZHANG Weihao, LI Ya, et al. Multi-scale Pix2Pix network for high-fidelity prediction of adiabatic cooling effectiveness in turbine cascade [J]. *Energy*, 2023, 265: 126381.
- [23] YANG Kefeng, SUI Yongfeng, WANG Xiangyu, et al. Study on flow and heat transfer characteristics in rectangular channels with lantern-shaped pin fin array: part I effect of sphere diameter [J/OL]. *Numerical Heat Transfer; Part A Applications*[2023-07-01]. <https://doi.org/10.1080/10407782.2023.2251085>.
- [24] GOEL T, HAFTKAR T, SHYY W, et al. Ensemble of surrogates [J]. *Structural and Multidisciplinary Optimization*, 2007, 33(3): 199-216.
- [25] ISOLA P, ZHU Junyan, ZHOU Tinghui, et al. Image-to-image translation with conditional adversarial networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 5967-5976.
- [26] WANG Tingchun, LIU Mingyu, ZHU Junyan, et al. High-resolution image synthesis and semantic manipulation with conditional GANs [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 8798-8807.
- [27] ZHU Junyan, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2017: 2242-2251.
- [28] CHOI Y, CHOI M, KIM M, et al. StarGAN: unified generative adversarial networks for multi-domain image-to-image translation [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 8789-8797.
- [29] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C]//2015 Medical Image Computing and Computer-Assisted Intervention (MICCAI). Cham, Germany: Springer International Publishing, 2015: 234-241.
- [30] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 770-778.

(编辑 陶晴)