doi:10.3969/j.issn.1672-1292.2026.02.002

基于机器学习的篦齿封严流动传热性能预测

高　峰[1],张敏慧[2],王春华[2],张居兵[1]

(1.南京师范大学能源与机械工程学院,江苏 南京 210023)
(2.南京航空航天大学能源与动力学院,江苏 南京 210016)

[**摘要**]　以光滑衬套直通式篦齿为研究对象,基于机器学习方法实现了篦齿封严流动传热性能的精细化和快速化预测. 遴选篦齿封严间隙、齿距、篦齿前倾角、入口总压和转速为机器学习模型输入,基于拉丁超立方抽样和计算流体力学(computation fluid dynamic,CFD)仿真方法建立机器学习所需的学习样本. 针对计算域划分独立的机器学习网格节点(其数量远小于 CFD 网格),把径向基函数神经网络独立建立在每个节点上并直接预测对应位置的总压、总温及速度. 将径向基函数神经网络与 CFD 计算结果对比分析,结果表明:对于总压、总温及速度,径向基函数神经网络预测的平均绝对百分比误差分别为 0.07%、0.17%和 0.14%,均方根误差分别为 1.18 kPa、1.8 K 和 6.45 m/s. 此外,对机器学习模型输入和输出参数之间的数值关联进行了详细分析. 研究成果为篦齿封严流动传热高效、低成本建模提供了一种新的技术途径.

[**关键词**]　航空发动机,篦齿封严,机器学习,径向基函数神经网络,泄漏系数
[**中图分类号**]V231.3　[**文献标志码**]A　[**文章编号**]1672-1292(2026)02-0009-12

Prediction of Flow and Heat Transfer Performance of Labyrinth Seals Based on Machine Learning

Gao Feng[1],Zhang Minhui[2],Wang Chunhua[2],Zhang Jubing[1]

(1.School of Energy and Mechanical Engineering,Nanjing Normal University,Nanjing 210023,China)
(2.College of Energy and Power Engineering,Nanjing University of Aeronautics and Astronautics,Nanjing 210016,China)

Abstract:The study focuses on the fine-grained and rapid prediction of the flow and heat transfer performance of labyrinth seals with smooth bushings using machine learning methods. Input parameters are selected for the machine learning model include the labyrinth seal clearance, tooth spacing, forward angle of the labyrinth tooth, inlet total pressure, and rotational speed. Learning samples required for the machine learning model are established based on Latin hypercube sampling and computation fluid dynamic(CFD) simulation methods. Radial basis function neural networks are independently constructed at each node of the machine learning grid(with a number of nodes significantly fewer than the CFD grid) to directly predict the total pressure, total temperature, and velocity at the corresponding locations. Comparison between the radial basis function neural network and CFD calculation results reveals that the mean absolute percentage errors for total pressure, total temperature, and velocity are 0.07%, 0.17%, and 0.14%, with root mean square errors of 1.18 kPa, 1.8 K, and 6.45 m/s, respectively. A detailed analysis of the numerical relationships between the input and output parameters of the machine learning model is conducted. The research findings provide a new technical approach for efficient and low-cost modeling of the heat transfer performance of labyrinth seals.

Key words:aircraft engine, labyrinth seals, machine learning, radial basis function neural network, leakage coefficient

篦齿封严是航空发动机中常见的非接触式密封结构. 当流体通过其节流间隙时,首先,上游流体的压力能转化为速度能,随后在齿腔内,速度能通过湍流旋涡的耗散作用进一步转换为热能,从而实现有效的密封功能. 其主要用于现代航空发动机压气机和涡轮级间封严、空气系统以及滑油系统,在高温高压下具有较高的可靠性和稳定性,易于维护[1-3]. 篦齿封严性能的准确评估对航空发动机优化设计起着至关重要的作用.

收稿日期:2024-09-29.
通讯作者:王春华,博士,副教授,研究方向:航空发动机热端部件冷却等. E-mail:chunhuawang@ nuaa.edu.cn

目前,国内外学者对于篦齿流动传热性能的研究主要采用热力学理论分析和数值模拟分析两种方法. 文献[4-8]利用热力学的一些理想过程推导计算篦齿封严泄漏量,建立了一系列篦齿封严相关计算的半经验模型. 半经验模型虽然具有快速化的优点,但仅能得到压力、温度等的零维或一维分布信息,无法满足现代航空发动机“精细化”设计的需求. 随着计算能力的不断提升,计算流体力学(computational fluid dynamic,CFD)方法在篦齿封严建模中得到了广泛应用,为流动传热机理的揭示和结构参数的优化提供支持[9-12]. Yan 等[13]研究了预旋和蜂窝结构参数对风阻温升效应的影响. 唐萌等[14]研究射流对不同封严篦齿齿顶间隙以及不同转速条件下的影响. 王鹏飞等[15]通过实验方法探讨了压比、雷诺数、转速和相对封严间隙对台阶型篦齿封严性能的影响. 孔晓治等[16]研究了不同齿型对压气机封严特性的影响. 陈志英等[17]研究了不同篦齿间隙对封严效率及齿尖碰撞的影响. 文献[18-19]研究了篦齿几何参数对泄漏流量的影响. Enache 等[20]研究了不同径向间隙和进口温度对篦齿泄露流动特性的影响. Nayak[21]研究了不同封严间隙和转速对篦齿泄漏以及风阻温升的影响. 然而,CFD 建模和计算的复杂性仍然使得设计过程耗时且繁琐,对于一些优化迭代问题尤为明显.

机器学习的发展为篦齿封严建模及性能预测提供了新的技术途径. 机器学习作为人工智能的重要分支,其核心在于使计算机系统能够从数据中识别模式与规律,进而具备自主学习和预测的功能. 近年来,研究者开始积极探索将机器学习方法运用于航空发动机内流传热问题的分析与解决. 刘一帆等[22]基于多层感知器机器学习模型进行了多参数气膜冷却性能的预测. 王振宇等[23]利用径向基神经网络建立优化代理模型,并通过遗传算法优化涡轮集气腔结构. Li 等[24]利用条件生成对抗神经网络模型预测平板气膜冷却壁温. Pazireh 等[25]针对压气机非均匀流场,提出了一种基于人工神经网络精确预测方法,对比分析了特定转子在均匀流、非均匀流及非定常雷诺数等情况下的复杂流场. Lee 等[26]使用卷积神经网络和生成对抗网络预测非定常流场,并利用物理损失函数对网络进行质量和动量守恒的改进. Wang 等[27]建立了一种用于平板膜冷却预测的反卷积神经网络模型,结果表明该模型预测精度优于支持向量机和半经验关联式.

本研究将径向基函数神经网络(radial basis function neural network,RBFNN)应用于篦齿结构的流动传热建模,以实现压力、温度及速度等“场分布”的精细化和快速化预测. 提出了一种数据压缩和 one-to-one grid 预测策略,即针对计算域内划分独立的机器学习网格节点(其数量远小于 CFD 网格),把径向基函数神经网络独立建立在每个节点上并直接预测对应位置的总压、总温及速度. 并对机器学习模型计算结果分析,获得了模型输入参数对输出参数的影响规律.

1　数值计算方法

1.1　计算模型及边界条件

本研究以光滑衬套直通式篦齿作为研究对象进行分析. 如图 1 所示,计算域由静止上壁面、旋转下壁面以及变截面流道组成. 流道入口段长度为 7.5 mm,出口段长度为 14.5 mm,流道中共有 5 个篦齿,齿宽 $t=0.3$ mm,齿高 $H=4$ mm,篦齿后倾斜角 $\beta=98°$. 研究发现,篦齿封严间隙、齿距以及前倾角对泄漏特性影响较为敏感,故选取封严间隙(c)、齿距(B)和篦齿前倾角(α)为设计变量. 下壁面绕 x 轴旋转,旋转半径(r_2)为 263 mm. 静止上壁面半径(r_1)为 r_2+H+c. 鉴于计算域的周期性特征,选取全环的 1/18 进行研究.

计算域入口的边界条件设定为压力入口类型,总压设置为 P_{in}^*,总温为 830 K. 出口采用压力出口边界条件,其静压值设定为 910 kPa. 两侧周期面设置为旋转周期性边界条件,其余壁面均被指定为绝热无滑

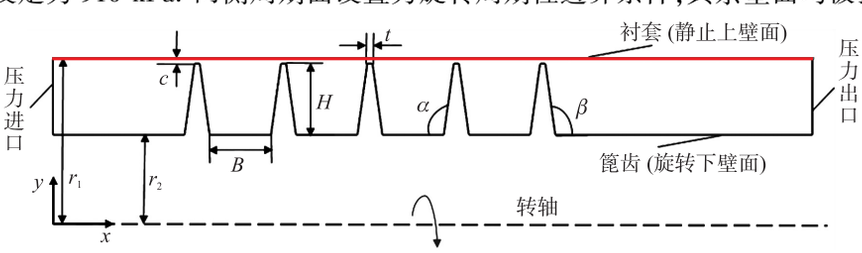


图 1　篦齿封严结构示意图

Fig. 1　Schematic diagram of labyrinth seals structure

移边界条件,同时将计算域设定为绕 x 轴旋转的旋转域. 流体设置为理想气体. 本研究选择封严间隙 c、齿距 B、篦齿前倾角 α、入口总压 P_{in}^* 和转速 N 为机器学习模型的输入,具体参数变化范围见表 1.

表 1　参数范围

Table 1　Range of parameters

参数	c/mm	B/mm	α/(°)	P_{in}^*/kPa	N/(r·min^{-1})	参数	c/mm	B/mm	α/(°)	P_{in}^*/kPa	N/(r·min^{-1})
下限	0.1	2	92	1 001	8 000	上限	0.5	5	104	1 365	14 000

1.2　数值方法及验证

计算模型和网格使用 Workbench 参数化生成. 采用 ANSYS Mesh 软件划分非结构网格,对近壁面等流动参数变化剧烈区域采用附面层网格进行加密,第一层高度设置为 0.06 mm,网格法向增长系数为 1.15. 经计算验证,转静壁面 y^+ 值均在 1 左右,满足重整化群(renormalization group,RNG)k-ε 湍流模型在近壁区使用增强壁面处理时对于 y^+ 的要求. 计算网格细节如图 2 所示.

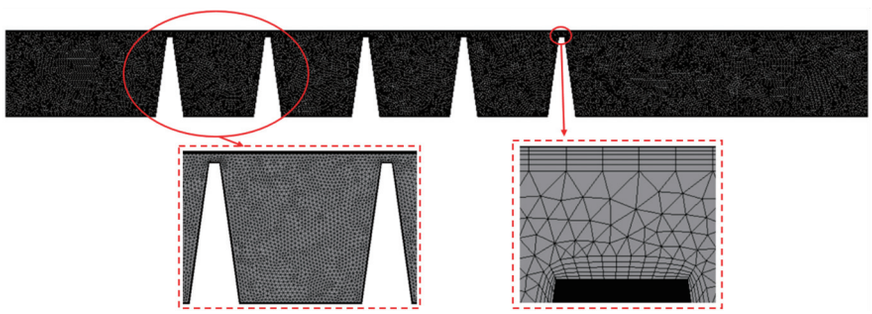


图 2　计算网格图

Fig. 2　Computational gird

选取某特定结构和工况(c=0.3 mm,B=3.5 mm,α=98°,P_{in}^*=1 183 kPa,N=11 000 r·min^{-1})进行网格独立性验证. 最终计算模型的网格数量确定为 334 万.

基于 ANSYS CFX 软件,本文开展了三维稳态数值模拟分析. 传热模型设置为 Total Energy,差分格式采用高阶迎风格式. 求解收敛的判据是:各物理量的残差均需小于 10^{-6},且监测的随机三点总压、总温、速度波动曲线趋于平直. 采用本文数值计算方法,建立文献[28]的篦齿封严模型为验证湍流模型,使用多种模型计算了泄漏系数,并与实验数据进行对比(如表 2 所示). 对比表明,RNG k-ε 模型的计算结果与实验误差最小,收敛性也最佳,因此被最终选用以进行湍流建模.

表 2　湍流模型验证

Table 2　Validation of turbulent model

	实验	SST 模型	k-ε 模型	k-ω 模型	RNG k-ε 模型
泄漏系数	0.023 1	0.021 9	0.021 8	0.021 5	0.022 7
相对误差	—	5.17%	5.58%	6.93%	1.61%

1.3　参数定义

压比 r_P 为:

$$r_P=\frac{P_{in}^*}{P_{out}}. \tag{1}$$

式中,P_{in}^* 为进口总压,P_{out} 为出口静压.

旋转比 γ 为:

$$\gamma=\frac{V}{\omega r}. \tag{2}$$

式中,V 为气流绝对周向速度,ω 为篦齿旋转角速度,r 为当地的旋转半径.

泄漏系数 φ 为:

$$\varphi=\frac{m_{real}\sqrt{T_{in}^*}}{P_{in}^*A}. \tag{3}$$

$$A = 2r_p Rc. \tag{4}$$

式中,m_{real}为通过篦齿的质量流量,T_{in}^*为进口总温,R 为篦齿齿尖半径,c 为封严间隙,A 为泄漏面积.

风阻温升 ΔT^* 为:

$$\Delta T^* = T_5^* - T_1^*. \tag{5}$$

式中,T_1^* 为气流进入第一个篦齿前的总温,T_5^* 为气流从第 5 个篦齿出口的总温.

2　基于机器学习的篦齿封严流动传热建模

2.1　机器学习建模流程

2.1.1　计算流程

Step1　基于 DOE(design of experiments)方法进行数值实验方案设计,DOE 是一种科学的统计方法,用于优化实验条件. 本研究的抽样工作基于拉丁超立方设计展开.

Step2　基于数值试验方案,结合 CFD 方法,对流动传热控制方程进行求解,构建用于机器学习的篦齿性能数据库. 该数据库包括篦齿结构参数和来流热力参数,以及与之相对应的总压、总温、速度分布.

Step3　利用机器学习算法对篦齿性能数据库内在数值关联进行挖掘,建立篦齿性能的精细化和快速化预测模型. 以缩减模型复杂程度、增强机器学习效能为目标,提出一种数据预处理策略(包括数据压缩和 one-to-one grid 预测).

Step4　对机器学习模型的泛化能力进行测试.

2.1.2　数据压缩

如图 3(a)所示,CFD 庞大的计算网格数量显著增加了机器学习建模的复杂性与时间成本. 为优化这一过程,采用数据压缩策略,即通过构建数量远少于 CFD 网格的机器学习网格来提取数据,直接针对机器学习网格节点数据进行分析,从而提升建模效率. 以计算域中截面为例,尽管不同样本中篦齿封严间隙、前倾角以及齿距发生变化,但机器学习网格数量保持不变. 如图 3(b)所示,将该截面划分为 12 个小部分,每个部分的机器学习网格数量一致,如 $n_1 = 33$,$n_2 = 6$,$n_3 = 40$,$n_4 = 30$,$n_5 = 30$,$n_6 = 30$,$n_7 = 30$,$n_8 = 60$,生成网格节点数 K 为 8550,相较于 CFD 网格,数量减少了 80.1%.

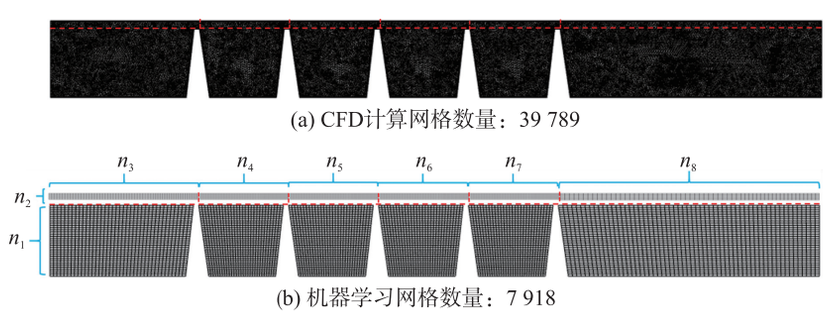


图 3　CFD 计算和机器学习网格数量对比

Fig. 3　Comparison of grid number for CFD calculation and machine learning

2.1.3　One-to-one grid 预测策略

如图 4 所示,该策略旨在为 K 个机器学习网格节点分别构建独立的机器学习模型. 每个模型负责预测其对应机器学习网格节点的压力、温度、速度等参数,从而减少了坐标参数的输入需求,实现了数据降维. 以中截面为例,训练样本数量为 N,机器学习网格节点数为 8 550,若不使用该策略,神经网络需处理 N×8 550 组数据. 使用该策略后,单个神经网络仅需要处理 N 组数据,极大地简化了建模复杂度.

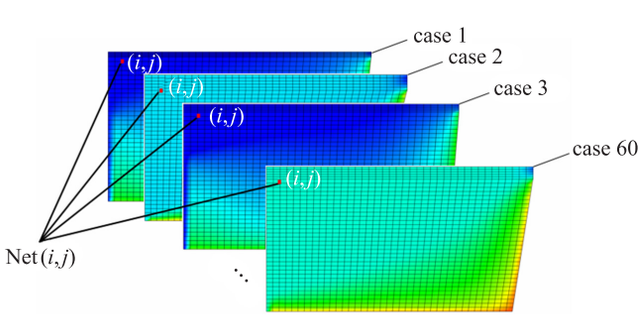


图 4　机器学习网格节点

Fig. 4　Machine learning grid node

2.2　数值实验设计

训练样本通过拉丁超立方抽样(Latin hypercube sampling,LHS)方法构建,该方法旨在实现多维空间的均匀采样. 其机制是将各维度划分为多个等距区间,并确保每个区间仅被抽取一次,据此保障了样本的均匀性. 此外,LHS 通过随机排列样本点,保证了不同维度间的独立性,有效避免了采样过程中的冗余或重复现象[29-31]. LHS 能够显著降低抽样需求,在资源有限的情况下,最大化地收集信息,从而有效提升机器学习建模的效率. 通过这种策略,能够在较少的抽样次数中,获取更广泛的数据分布,进而增强模型的泛化能力和预测准确性. 因此,这种抽样方法能够确保覆盖输入参数的范围.

本研究模型的输入参数为 c、B、α、P_{in}^{*}、N. 利用 LHS 抽样的方法生成了 60 组训练样本、20 组验证样本和 15 组测试样本,3 种样本之间互不重合. 测试样本参数如表 3 所示.

表 3　测试样本参数

Table 3　Test sample parameters

参数	c/mm	B/mm	α/(°)	P_{in}^{*}/kPa	N/(r·min^{-1})
Case 1	0.193	2.609	92.25	1 184	12 765.5
Case 2	0.390	2.813	101.2	1 275	12 253.4
Case 3	0.216	2.508	96.81	1 128	13 452.3
Case 4	0.283	4.552	94.88	1 111	9 326.0
Case 5	0.256	2.247	102.7	1 324	11 360.8
Case 6	0.364	4.648	102.2	1 241	10 084.3
Case 7	0.176	3.852	94.09	1 051	11 852.9
Case 8	0.469	4.051	98.27	1 263	11 117.6
Case 9	0.441	3.379	92.99	1 164	13 965.3
Case 10	0.412	3.064	103.3	1 345	12 891.2
Case 11	0.145	4.307	98.92	1 207	9 117.7
Case 12	0.494	3.758	96.25	1 030	9 844.7
Case 13	0.307	4.980	99.76	1 306	10 579.3
Case 14	0.103	2.035	100.4	1 091	8 308.4
Case 15	0.321	3.565	95.33	1 024	8 543.2

2.3　机器学习模型

本研究的核心在于应用 RBFNN,其网络结构如图 5 所示. RBFNN 的隐含层节点通过其作用函数(即基函数)对输入信号进行局部响应[32]. 具体来说,当输入信号位于基函数的中心区域附近时,隐含层节点会输出较大的值. 这种特性源自径向基函数的独特性质,使得 RBFNN 能够对输入变量产生选择性的响应,进而赋予网络局部调谐的能力. 若将隐含层的作用函数设定为高斯函数,那么隐含层的输出将表现为:

$$F_i(\boldsymbol{x})=\exp\left(-\frac{\|\boldsymbol{x}-\boldsymbol{C}_i\|}{2\sigma^2}\right),i=1,2,3,\cdots,h. \tag{6}$$

式中,h 为隐含层神经元数,$\boldsymbol{x}=(x_1,x_2,\cdots,x_n)$ 是 n 维输入向量,$\boldsymbol{C}_i$ 和 σ 分别是隐含层第 i 个径向基函数中心向量和宽度,$\|\cdot\|$ 表示 $\boldsymbol{x}$ 与 $\boldsymbol{C}_i$ 的欧拉距离,$F_i(\boldsymbol{x})$ 为第 i 个径向基神经元输出.

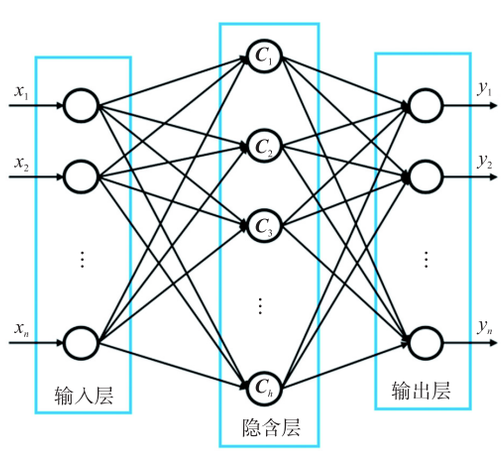


图 5　径向基函数神经网络结构

Fig. 5　Structure of RBFNN

整个 RBFNN 的输出为:

$$y_j=\sum_{i=1}^{h}w_{j,i}F_i(\boldsymbol{x})+b_j,j=1,2,\cdots,l;i=1,2,\cdots,h. \tag{7}$$

式中,y_j 为输出层第 j 个神经元输出,$w_{j,i}$ 为隐含层第 i 个神经元到输出层第 j 个神经元之间的连接权值,b_j

为偏置.

在本研究中,输入层中的神经元数量为 5,隐含层中的神经元数量等于训练样本的大小为 60,输出层中的神经元数量为 1. 通过内部编写的代码执行了 RBFNN. 网络使用聚类算法进行初始化. 采用学习率为 0.01 的梯度下降算法来优化连接权重和激活函数的中心,以最小化损失函数. 训练的最大迭代步数设置为 1 000. 采用试错法来确定每个 RBFNN 模型的最佳扩展系数(σ). 优化的目标是使验证集的预测误差最小化.

2.4　模型验证

本研究评估机器学习模型性能的指标为平均绝对百分比误差(mean absolute percentage error,MAPE)和均方根误差(root mean square error,RMSE),对于压力、温度和速度,MAPE 能够直观地反映预测值偏离真实值的百分比程度,RMSE 综合考虑了所有数据点的误差,能够全面地评估预测模型对于压力、温度和速度的整体准确性,这两种误差符合本研究所需的评判指标. 注意这里的 MAPE 和 RMSE 指的是单个样本的目标面上所有模型的平均误差.

$$\mathrm{MAPE}=\frac{1}{K}\sum_{i=1}^{K}\left|\frac{Y_1-Y_2}{Y_1}\right|\times 100\%, \tag{8}$$

$$\mathrm{RMSE}=\sqrt{\frac{\sum_{i=1}^{K}(Y_1-Y_2)^2}{K}}. \tag{9}$$

式中,Y_1 为 CFD 计算的真实值,Y_2 为机器学习模型的预测值,K 为建立机器学习模型的节点数量.

如图 6 所示,对比 RBFNN 的预测结果和 CFD 的计算结果. 通过分析 15 个测试样本,评估 RBFNN 在预测总压、总温和速度方面的性能. 对于总压的预测,RBFNN 的平均 MAPE 仅为 0.07%,显示出极高的预测精度. 此外,总压的平均 RMSE 为 1.18 kPa,进一步证实了 RBFNN 在捕捉总压变化方面的有效性. 同时,总温和速度的平均 MAPE 分别为 0.17%和 0.14%,总温和速度的平均 RMSE 分别为 1.8 K 和 6.45 m/s.

以样本 7 为例,对比 RBFNN 和 CFD 计算所得的总压、总温和速度分布结果,如图 7~图 9 所示. RBFNN 预测的总压、总温和速度分布与 CFD 计算结果一致,验证了本研究所提出的方法对“场分布”的预测能力.

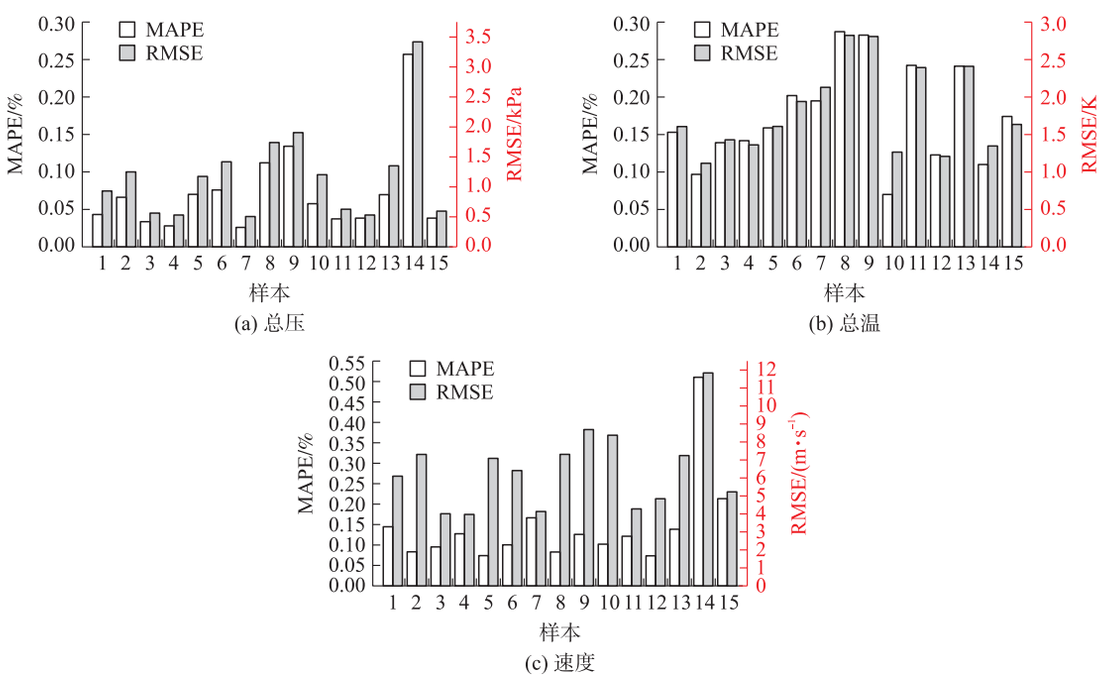


图 6　RBFNN 预测性能

Fig. 6　Prediction performances of RBFNN

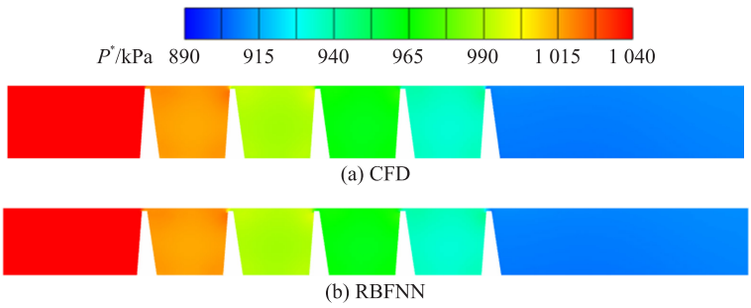


图 7　总压分布

Fig. 7　Distribution of total pressure

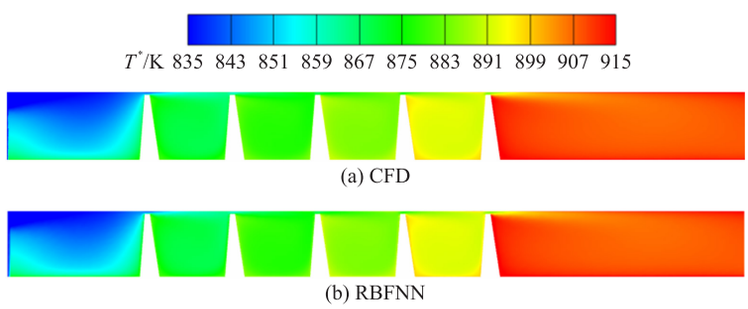


图 8　总温分布

Fig. 8　Distribution of total temperature

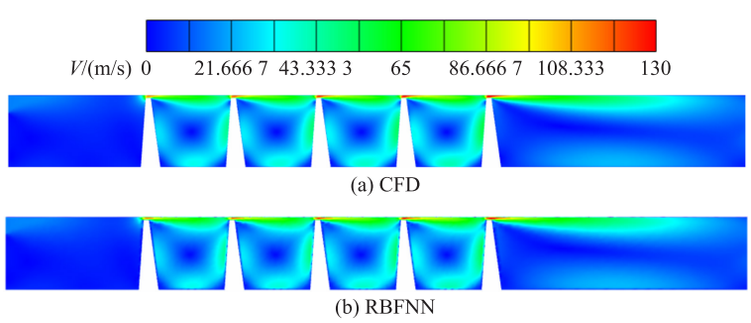


图 9　速度分布

Fig. 9　Distribution of velocity

3　基于机器学习的流动传热分析

本节采用已建立的 RBFNN 预测模型来快速获取篦齿封严在不同结构参数和热力学参数下的流动换热特性,以揭示输入变量与输出变量之间的复杂关联. 以 $c=0.3$ mm、$B=3.5$ mm、$\alpha=98°$、$P_{in}^{*}=1\ 183$ kPa、$N=11\ 000$ r·min^{-1}为基准结构和工况进行分析. 下文针对压比、转速和封严间隙进行分析.

3.1　压比的影响

图 10 为篦齿封严泄漏系数随压比的变化曲线. 篦齿泄露流主要受上下游压差驱动,随着压比的增大,泄露流量增加,泄露系数也随之增加. 例如,在转速为 9 000、11 000 和 13 000 r·min^{-1}的情况下,当压比从 1.1 增加至 1.5 时,泄露系数从 0.010 99 增加到 0.020 17,增大了 83.53%. 此外,从图中可以看出 RBFNN 预测结果与 CFD 计算结果相一致,能够正确反映压力变化对泄露系数的影响.

图 11 为压比对篦齿封严风阻温升特性的影响. 泄露流在流经高速旋转的篦齿时,转盘对流体做功,由于齿尖节流效应以及气流摩擦力引起的黏性耗散,这部分功转化为热力学能,使得泄露流总温升高. 随着压比的增加,泄露流量增加. 根据能量守恒定律,转盘对单位质量泄露工质做功量减小,泄露流温升也随之降低. 例如,在转速为 11 000 r·min^{-1}的工况下,当压比为 1.1、1.3 和 1.5 时,泄露流温升分别为 23.48 K、15.71 K 和 7.85 K. 同时,RBFNN 预测的温度值与 CFD 计算结果相一致,可以正确反映压力变化对温度的影响.

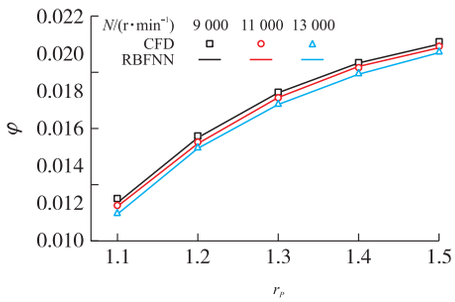


图 10　泄漏系数随压比的变化

Fig. 10　Variation of leakage coefficient with pressure ratio

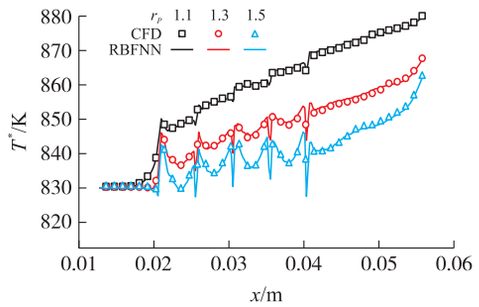


图 11　不同压比条件下总温沿流向分布

Fig. 11　Variation of total temperature with streamwise distance at different pressure ratios

篦齿封严内部的气流旋转速度起因于转子壁面的旋转作用,而这一旋流对其泄漏特性有直接影响. 图 12 为不同压比条件下,x=0.032 m(即第三齿腔中)流向位置处旋转比沿径向分布. 靠近转子壁面的气流旋转比较大. 这是由于气流通过篦齿时,转子对其做功较大,从而显著增加了气流的旋转比. 在转速为 11 000 r·min^{-1}的工况下,当压比从 1.1 增加到 1.5 时,旋转比逐渐降低,靠近转子壁面处的气流旋转比从 0.615 下降到 0.486,下降了 20.98%. 这是由于当压比增大时,泄漏流量增大,转盘对单位质量泄露流量做功减小,导致气流周向速度减小. 此外,RBFNN 预测值与 CFD 计算值相一致,机器学习模型可以正确反映压力变化对速度的影响.

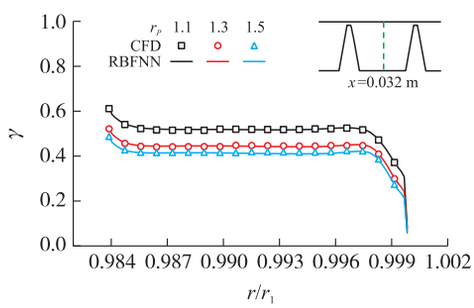


图 12　不同压比条件下的旋转比径向分布

Fig. 12　Radial distribution of swirl ratio at different pressure ratios

图 13 为不同压比条件下的总温云图和流线图(RBFNN 预测). 篦齿内部的流动模式以 3 种为主:齿尖节流流动、齿尖出流射流流动以及齿腔大尺度涡旋流动. 部分齿尖射流直接进入下一节篦齿间隙(透气效应),另有部分射流与下一节篦齿迎风面发生直接碰撞,并受大尺度涡旋卷吸进入齿腔. 机器学习模型结果可以正确地反映这一系列流动特征. 沿泄露流方向,转盘不断对流体做功并转化为热力学能,总温也在不断升高. 随着压比的减小,温升效应更加显著,与图 11 的结论相一致.

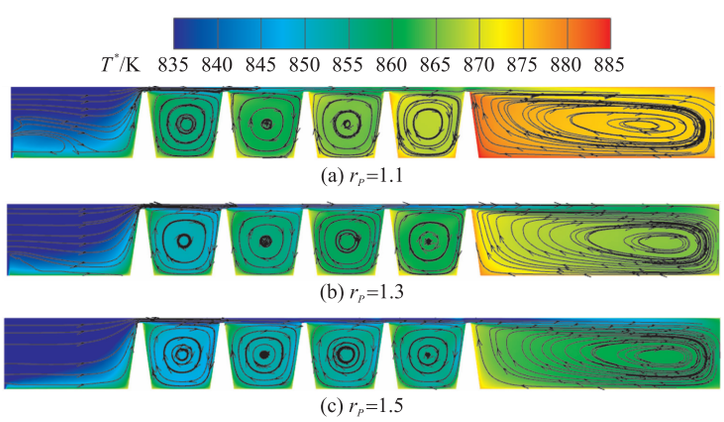


图 13　不同压比条件下的总温云图和流线图

Fig. 13　Total temperature cloud and flow chart at different pressure ratios

3.2　转速的影响

图 14 为转速对篦齿封严泄露系数的影响. 泄漏系数随转速的上升而呈现下降趋势. 例如,在 r_P=1.2、1.3 和 1.4 的工况下,当转速从 8 000 r·min^{-1}增加至 14 000 r·min^{-1},泄露系数分别降低了 5.66%、4.77%和 3.96%. 随着转速的增加,泄露流所受离心力也增加,齿尖射流与齿腔涡流之间的分界逐渐外移,这一方面使得泄露流有效流通面积降低,增加泄露流的总压损失. 另一方面,更多的齿尖射流被卷吸入齿腔,受壁

面摩擦力作用发生能量耗散,使得泄露系数降低.

图 15 为转速对篦齿封严风阻温升特性的影响. 随着转速的增加,风阻温升增加. 例如,在 $r_P=1.3$ 的工况下,当转速从 9 000 r·min^{-1}增加至 13 000 r·min^{-1},风阻温升从 8.66 K 增加到 24.72 K,增加了 185%. 转速对风阻温升的影响主要体现在两方面:随着转速的增加,流体内部速度梯度以及所受的剪切应力增加,转子对气流做功量以及气流与静子之间的摩擦热也随之增加,更多的动能转化为热力学能;由于转速增加,致使齿尖射流与齿腔涡流间的分界线逐渐外移,更多的齿尖射流被卷吸入齿腔,齿腔内流体受壁面摩擦生热.

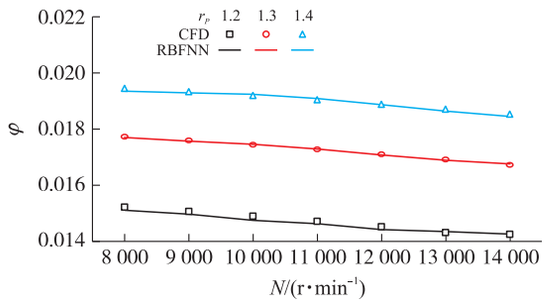


图 14　泄漏系数随转速的变化

Fig. 14　Variation of leakage coefficient with rotational speed

图 16 为 $x=0.032$ m 处转速对篦齿封严径向旋转比的影响. 当压比和封严间隙一定时,同一径向位置处的旋转比随转速的增加而增大. 因为随着转子转速的增大,转子对气流的摩擦做功增大,旋流增大. 在 $r_P=1.3$ 的工况下,当转速从 9 000 r·min^{-1}增加到 13 000 r·min^{-1}时,旋转比逐渐增大,靠近转子壁面处的气流旋转比从 0.501 增加到了 0.546.

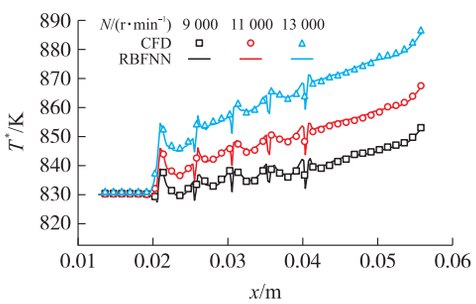


图 15　不同转速条件下总温沿流向分布

Fig. 15　Variation of total temperature with streamwsie distance at different rotational speed

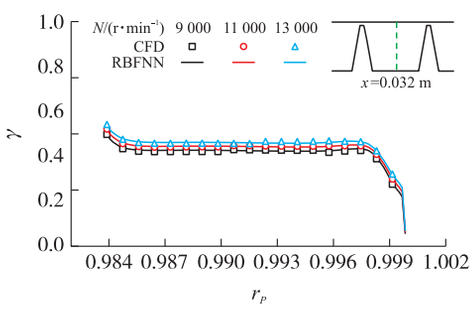


图 16　不同转速条件下的旋转比径向分布

Fig. 16　Radial distribution of swirl ratio at different rotational speed

图 17 为不同转速条件下的总温云图和流线图(RBFNN 预测). 随着转速的提升,气流总温相应升高,且靠近转子壁面的气流总温较高,原因是转子对气流做功. 同时,随着转速的增加,篦齿封严气流泄漏量会降低,也会使得温度增高. 转速对总温影响的规律和图 15 变化一致. 从流线图上看,转速改变对其影响不明显.

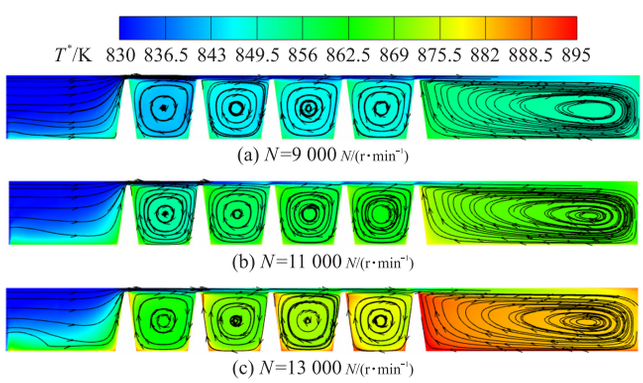


图 17　不同转速条件下的总温云图和流线图

Fig. 17　Total temperature cloud and flow chart at different rotational speed

3.3　封严间隙的影响

图 18 为篦齿封严泄漏系数随封严间隙的变化曲线. 从图中可以看出,压比一定时,减小封严间隙能降低泄漏系数,提高篦齿封严性能. 这是由于封严间隙减小,封严截面积减小,流体的突缩突扩效应增强. 同时,通过齿尖的射流速度增大,齿腔中的旋涡转速增快,从而导致泄漏量减小,封严效果增强. 例如,

在 r_p=1.2、1.3 和 1.4 的工况下,封严间隙从 0.5 mm 减小到 0.1 mm 时,泄漏系数分别减小了 33.42%、32.03%和 30.63%.

图 19 为封严间隙对篦齿封严风阻温升特性的影响. 在一定的压比和转速下,随着间隙的增大,泄漏流量增大,温升降低,间隙越大,温升减小幅度趋于平缓. 例如,在 r_p=1.3 和 N=11 000 r·min^{-1}的工况下,当封严间隙从 0.1 mm 增加到 0.5 mm 时,风阻温升从 54.86 K 下降到了 13.22 K.

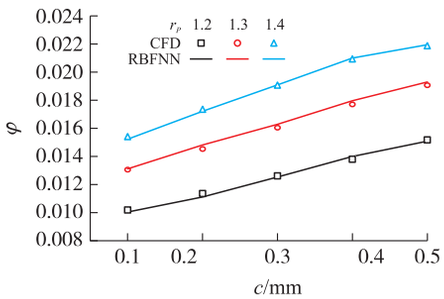


图 18　泄漏系数随封严间隙的变化

Fig. 18　Variation of leakage coefficient with seal clearances

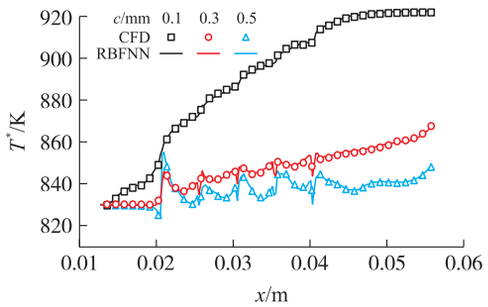


图 19　不同封严间隙条件下总温升沿流向分布

Fig. 19　Variation of total temperature with streamwsie distance at different seal clearances

图 20 为 x=0.032 m 处不同封严间隙对篦齿封严旋转比的影响. 在一定的压比与转速条件下,随着封严间隙的增大,同一径向位置处的旋转比逐渐减小. 在 r_p=1.3 和 N=11 000 r·min^{-1}的工况下,当封严间隙从 0.1 mm 增大到 0.5 mm 时,靠近转子壁面气流的旋转比从 0.695 降到了 0.461. 这归因于封严间隙增大所引起的气流流通面积增加,导致泄漏流量增大,转盘对单位质量泄露流量做功减小,故旋转比也在降低.

图 21 为封严间隙对沿程总压的影响. 从图中可以看出,篦齿封严内部气体压力沿轴向逐级降低,篦齿内部压降主要存在于齿尖和齿腔两处,齿尖压降远远高于齿腔压降,齿尖压降是篦齿封严中气体压力降低的主要原因. 同时,当封严间隙增大后,前后齿腔的压力变化效果减弱,这是由于在较小的封严间隙中,流体通过时会因为摩擦和湍流而产生能量损失,这些损失会导致压力波动,而当封严间隙增大时,能量损失减少,从而减少了压力变化幅度. 例如,在 r_p=1.3 和 N=11 000 r·min^{-1}的工况下,当封严间隙从 0.1 mm 增大到 0.5 mm 时,进出口压降从 0.27 MPa 降到了 0.25 MPa.

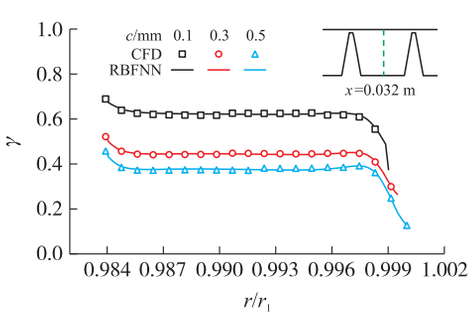


图 20　不同封严间隙条件下的旋转比径向分布

Fig. 20　Radial distribution of swirl ratio at different seal clearances

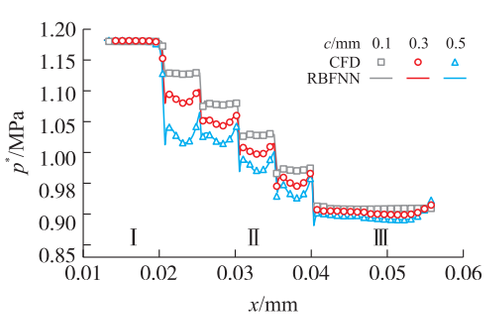


图 21　不同封严间隙条件下总压沿流向分布

Fig. 21　Variation of total pressure with streamwsie distance at different seal clearances

4　结论

针对光滑衬套直通式篦封严结构内流动传热性能展开机器学习建模研究,为篦齿封严和二次空气系统的建模与优化提供新的技术途径. 主要结论如下:

(1)建立了基于 RBFNN 机器学习模型的光滑衬套直通型篦齿快速化和精细化预测模型. 采用数据压缩和 One-to-one grid 策略,在计算域内划分独立的机器学习网格节点(其数量远小于 CFD 网格),把径向基函数神经网络独立建立在每个节点上. 能在较少的训练样本下实现多个目标的高精度预测,在很大程度上复现了总压、总温和速度云图.

(2)比较 RBFNN 预测值和 CFD 计算值,RBFNN 对总压、总温和速度的平均 MAPE 分别为 0.07%、

0.17%和0.14%,平均RMSE分别为1.18 kPa、1.8 K和6.45 m/s. 结果验证了RBFNN在总压、总温和速度分布预测上的高度的准确性、良好的稳定性和较强的泛化能力.

(3)针对输入变量与输出变量之间的关系进行了详细分析. 在本研究工况内,篦齿封严泄漏系数随压比和封严间隙的增大而增大,随转速增大而减小. 风阻温升与旋转比随压比及封严间隙的增大而减小,随转速的提高而增大.

(4)传统的建模方法更多依赖于CFD等方法,本研究提出的基于RBFNN的机器学习模型展示了一种新的建模途径,为本领域研究提供新的建模理论框架,体现了结合机器学习方法提升建模的效率和精度的可行性. 同时,本研究仅针对特定工况进行了分析,未来可以进一步扩展研究工况范围,以更全面地揭示光滑衬套直通式篦封严结构在各种工况下的流动传热性能,从而提高模型的通用性.

[参考文献](References)

[1] 聂顺鹏,刘高文,雷昭,等. 有无蜂窝的直通斜齿流动特性旋转实验研究[J]. 推进技术,2020,41(5):1015-1022.

[2] 任国哲,卢德正,孙丹,等. 结构参数对篦齿封严流动特性与最佳封严齿数影响研究[J]. 推进技术,2025,46(2):293-305.

[3] 陈礼顺,王彦岭,卢建红,等. 航空发动机封严技术的研究和应用进展[J]. 航空制造技术,2008(8):82-84,95.

[4] Denecke J,Dullenkopf K,Bauer H J. Dimensional analysis and scaling of rotating seals[C]//ASME Turbo Expo 2005:Power for Land,Sea,and Air. Reno,Nevada,USA,2005:1149-1160.

[5] Denecke J,Dullenkopf K,Wittig S. Experimental investigation of the total temperature increase and swirl development in rotating labyrinth seals[C]//ASME Turbo Expo 2005:Power for Land,Sea,and Air. Reno,Nevada,USA,2005:1161-1171.

[6] Millward J A,Edwards M F. Windage heating of air passing through labyrinth seals[J]. Journal of Turbomachinery,1996,118(2):414-419.

[7] 吴丁毅,刘振侠. 交错式篦齿封严特性的实验研究[J]. 推进技术,1997,18(2):87-90.

[8] Kulkarni D Y,Mare L D. Development of a new loss model for turbomachinery labyrinth seals[J]. Journal of Engineering for Gas Turbines and Power,2023,145(6):061016.

[9] Bermejo O,Gallardo M J,Sotillo A,et al. Numerical and experimental study of flutter in a realistic labyrinth seal[J]. International Journal of Turbomachinery,Propulsion and Power,2024,9(2):13.

[10] Xie L,Du Q,Liu G,et al. Investigation of flow characteristics in a rotor-stator cavity under crossflow using wall-modelled large-eddy simulation[J]. Journal of Zhejiang University:Science A,2023,24(6):473-497.

[11] 李驰,张勃,马壮,等. 台阶式斜篦齿封严压降与风阻温升数值分析[J]. 润滑与密封,2024,49(6):29-35.

[12] 李昶威,孙丹,赵欢,等. 静态篦齿封严温变效应产生机理数值研究[J]. 航空动力学报,2024,39(2):120-128.

[13] Yan X,Li J,Song L M,et al. Investigations on the discharge and total temperature increase characteristics of the labyrinth seals with honeycomb and smooth lands[J]. Journal of Turbomachinery,2009,131(4):041009.

[14] 唐萌,赵晨旭,翟世杰. 射流对不同封严篦齿特性的影响分析研究[J]. 机械制造与自动化,2022,51(3):130-134.

[15] 王鹏飞,郭文,张靖周. 典型阶梯篦齿高转速密封性能试验[J]. 航空动力学报,2017,32(12):3057-3063.

[16] 孔晓治,刘高文,雷昭,等. 齿型对压气机级间封严特性影响的实验研究[J]. 推进技术,2018,39(9):2085-2093.

[17] 陈志英,汪宇峰,刘勇,等. 基于封严间隙的涡轮盘篦齿综合优化设计[J]. 航空发动机,2019,45(5):19-25.

[18] Chun Y H,Ahn J. Effects of geometric parameters of a staggered labyrinth seal on leakage flow[J]. Journal of Mechanical Science and Technology,2023,37(6):2959-2968.

[19] Lee I S,Kang J Y,Kim J W,et al. Effects of tip clearance,number of teeth,and tooth front angle on the sealing performance of straight and stepped labyrinth seals[J]. Journal of Mechanical Science and Technology,2021,35(4):1539-1547.

[20] Enache M,Carlanescu R,Mangra A,et al. Investigation of flow through a labyrinth seal[J]. INCAS Bulletin,2021,13(2):51-58.

[21] Nayak C K. Effect of rotation on leakage and windage heating in labyrinth seals with honeycomb lands[J]. Journal of Engineering for Gas Turbines and Power,2020,142(8):081001.

[22] 刘一帆,王春华,张卓,等. 基于机器学习的全覆盖气膜冷却性能预测[J]. 中南大学学报(自然科学版),2024,55(6):2334-2347.

[23] 王振宇,王春华,张靖周. 涡轮集气腔结构参数优化研究[J]. 中南大学学报(自然科学版),2022,53(7):2756-2765.

[24] Li Y, Wei D, Yu R, 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.

[25] Pazireh S, Jeffrey J, Defoe 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): 5.

[26] Lee S, You D. Data-driven prediction of unsteady flow over a circular cylinder using deep learning[J]. Journal of Fluid Mechanics, 2019, 879(1): 217-254.

[27] Wang Y, Wang W, Tao G, et al. Two-dimensional film-cooling effectiveness prediction based on deconvolution neural network [J]. International Communications in Heat and Mass Transfer, 2021, 129: 105621.

[28] 张霞,张效伟,朱惠人,等. 直通型篦齿封严特性的试验[J]. 航空动力学报,2010,25(8):1753-1757.

[29] Ma Z, Gao J, Hu W, et al. Risk-adjustable stochastic schedule based on Sobol augmented Latin hypercube sampling considering correlation of wind power uncertainties[J]. IET Renewable Power Generation, 2021, 15(11): 2356-2367.

[30] Huy K D, Duc K T, Seung E K. Stochastic analysis of semi-rigid steel frames using a refined plastic-hinge model and Latin hypercube sampling[J]. Engineering Structures, 2023, 291: 116313.

[31] Hector C E, Erik C, Karla A, et al. An advanced initialization technique for metaheuristic optimization: A fusion of Latin hypercube sampling and evolutionary behaviors[J]. Computational and Applied Mathematics, 2024, 43: 234.

[32] 姜峰,洪林雄,李华聪. 基于自适应径向基函数模型的区间不确定性分析方法[J]. 航空动力学报,2024,39(11):73-82.

[责任编辑:陈　庆]