

基于神经网络的扰流柱通道表面传热系数预测

姚广宇, 邱璐, 朱剑琴

(北京航空航天大学 能源与动力工程学院, 北京 100191)

摘 要: 针对扰流柱通道结构的流动传热过程进行了仿真研究, 构建了该结构内部表面传热系数的快速预测模型。该预测模型首先构建了若干流阻元件用于冷气质量流量预测, 之后根据质量流量预测结果计算通道内的流动雷诺数。将雷诺数与几何结构参数组合并输入基于遗传算法优化的反向传播神经网络, 分别预测通道内不同结构的平均表面传热系数。最后建立基于肋化传热模型的扰流柱导热等效表面传热系数换算方法, 以便将预测模型应用于实际双层壁涡轮叶片的冷效预测。经数值仿真验证, 该模型对通道内冷气质量流量和表面传热系数进行组合预测, 相对误差控制在 5% 以内。

关 键 词: 神经网络; 扰流柱通道; 表面传热系数; 肋化传热; 涡轮叶片冷却

中图分类号: V232.4

文献标志码: A

Convective heat transfer coefficient prediction of pin-fin channel based on neural network

YAO Guangyu, QIU Lu, ZHU Jianqin

(School of Energy and Power Engineering, Beihang University, Beijing 100191, China)

Abstract: The heat transfer process of pin-fin channel was studied by simulation, and a prediction model of the internal convective heat transfer coefficient was constructed. Firstly, several flow resistance elements were constructed to predict the cooling air flow rate, and then the Reynolds number in the channel was calculated according to the flow rate. Secondly, the Reynolds number and geometric parameters were combined and fed into a genetic algorithm and back propagation neural network to predict the average convective heat transfer coefficient of elements in the pin-fin channel respectively. Finally, a conversion method of equivalent heat transfer coefficient of pin-fin heat conduction was established based on ribbed heat transfer model, so as to apply the model to the cooling effect prediction of actual double-wall turbine blades. Numerical simulation results showed that the model can predict the flow rate of cool air and the convective heat transfer coefficient in the channel, and the relative error was controlled within 5%.

Keywords: neural network; pin-fin channel; convective heat transfer coefficient; ribbed heat transfer; turbine blade cooling

航空发动机涡轮前进口温度是影响发动机总体性能的重要指标, 同尺寸下涡轮前进口温度越高, 发动机推力越大^[1]。随着我国航空发动机的

快速发展, 逐年提高的涡轮前进口温度已经远远超过了金属材料的耐温极限^[2]。这对涡轮叶片冷却结构设计提出了极高的要求。

收稿日期: 2022-09-21

基金项目: 国家自然科学基金(51876005, 52122604)

作者简介: 姚广宇(1998—), 男, 博士生, 主要从事航空发动机涡轮叶片先进冷却设计方法研究。

通信作者: 朱剑琴(1983—), 女, 教授、博士生导师, 博士, 主要从事航空发动机涡轮叶片先进冷却设计方法研究。E-mail: zhujianqin@buaa.edu.cn

引用格式: 姚广宇, 邱璐, 朱剑琴. 基于神经网络的扰流柱通道表面传热系数预测[J]. 航空动力学报, 2023, 38(7): 1668-1674. YAO Guangyu, QIU Lu, ZHU Jianqin. Convective heat transfer coefficient prediction of pin-fin channel based on neural network[J]. Journal of Aerospace Power, 2023, 38(7): 1668-1674.

为了提升涡轮叶片的耐温能力, 全世界各地的研究者提出了各种各样的冷却结构^[3], 其中扰流柱通道结构简单、冷却效率较高, 已在涡轮叶片设计领域得到了广泛应用。目前国内外学者对于扰流柱机理研究多以圆柱形扰流柱为主, 通过数值仿真、实验等方法探究雷诺数及扰流柱几何参数对流动传热过程的影响规律^[4-9]。然而现有研究结论多为定性规律和经验公式, 难以针对扰流柱通道结构形成系统性的评估模型。这导致扰流柱通道的设计过程仍需依赖数值模拟和冷效实验的反复迭代, 设计效率受到了极大的影响。

另外, 人工智能算法已经广泛应用于航空发动机设计领域, 并已取得了丰硕的成果^[10]。Zhu 等使用神经网络实现了对叶片湍流黏度分布的预测^[11]。Li 等使用 U-net 模型成功预测了气膜冷效^[12]。Yang 等使用简单的卷积神经网络同样实现了平板气膜冷效预测^[13]。丁水汀等采用改进的反向传播神经网络实现了带直肋通道努塞尔数的预测^[14]。上述算法中, 人工智能在航空发动机领域的现有应用大多以简单几何模型为主, 且适用工况无法覆盖下一代先进航空发动机的实际工况。

本文首先基于 Fluent 软件建立了适应真实航空发动机工况的仿真数据集; 之后将传统流阻元件、遗传算法(GA)-反向传播(BP)神经网络和肋化传热理论模型进行组合, 构建了一整套针对扰流柱通道表面传热系数的预测模型; 最后在某型真实发动机工况下对该预测模型进行了评估和测试。

1 预测方法

1.1 BP 神经网络

BP 神经网络是若干神经元连接形成的有序网络结构, 是现阶段应用最广泛的人工智能预测算法之一。BP 神经网络的模型参数可以分为结构参数和神经元参数两大部分。

BP 神经网络的结构参数主要包括神经元的层数、不同层的神经元数量等。神经网络的输入层和输出层一般不包含多层神经元结构, 可以由预测模型的输入输出直接确定: 输入层的神经元数量等于输入参数的数量, 输出层的神经元数量等于输出参数的数量。而神经网络的隐藏层可根据问题的复杂程度选择不同层数, 每一隐藏层的神经元数量选取也没有明确的规定; 同时隐藏层

的拓扑结构对神经网络模型的预测性能有非常大的影响。因此确定隐藏层结构参数是神经网络结构设计的核心。

确定 BP 神经网络的结构参数后, 还需要确定模型的神经元参数。BP 神经网络的每个神经元包含权重、偏置和激活函数 3 个基本参数。对于回归类问题, 激活函数主要的作用是增强神经网络模型的非线性拟合能力, 一般可以根据经验选取。而神经元 j 的权重 ω_j^i 和偏置 b_j^i 变量是神经元输入 x_j^i 与神经元输出 y_j 间的直接纽带, 其计算公式为

$$y_j = \sum \omega_j^i x_j^i + b_j^i \quad (1)$$

式中 i 代表与神经元 j 连接的神经元 (j 所在的隐藏层前一层的神经元), $i=1, 2, \dots, n$, n 为神经元 j 所在隐藏层前一层的神经元总数。

神经网络训练过程的核心就是使用梯度下降方法更新不同神经元的权重和偏置。首先在神经网络的输出层计算正向传播输出值相对于标签值的误差, 之后通过反向传播算法计算中间层各神经元的误差, 并由此得到作为梯度下降法基础的神经元误差偏导数。权重 ω_j^i 和偏置 b_j^i 变量的更新公式分别为

$$\omega_{j_new}^i = \omega_j^i - \eta \frac{\partial L}{\partial \omega_j^i} \quad (2)$$

$$b_{j_new}^i = b_j^i - \eta \frac{\partial L}{\partial b_j^i} \quad (3)$$

其中 $\omega_{j_new}^i$ 为神经元 j 更新后的权重值, $b_{j_new}^i$ 为神经元 j 更新后的偏置值, L 为损失函数, η 为神经网络的学习率。

在预测扰流柱通道壁面和扰流柱面平均表面传热系数的过程中, 使用 Pytorch 框架构建了 2 个 BP 神经网络模型。这 2 个神经网络的结构参数均为 4-5-5-1, 隐藏层神经元使用 Relu 激活函数, 如图 1 所示。使用 Adam 优化器进行训练, 学习率设置为 0.001, 且每训练 30 步学习率减小为原来的 10%。

1.2 BP 神经网络优化方法

为了提高 BP 神经网络的预测性能, 可以将神经网络的预测过程与各种各样的智能优化算法结合^[15-17]。本文亦使用遗传算法(GA)对反向传播(BP)神经网络的初始化方案进行了优化, 形成了 GA-BP 神经网络预测模型, 其流程如图 2 所示。




图 1 神经网络拓扑结构

Fig. 1 Neural network topology architecture




图 2 遗传算法优化 BP 神经网络流程图

Fig. 2 Optimization of BP neural network flow chart by genetic algorithm

对文中第 1.1 节确定的 BP 神经网络拓扑结构进行 20 次初始化, 并分别进行训练。将这些初始化方案的权重和偏置分别编码为 GA 染色体, 便形成了遗传算法的初始种群。以不同初始化方案训练结束后的测试集误差作为适应度函数, 设置最大迭代轮次为 200, 调用遗传算法优化 BP 神经网络的初始化方案。最终得到优化后的 BP 神经网络预测模型。

2 训练数据集

2.1 通道结构质量流量预测数据集参数方案

为了更好地刻画通道结构的质量流量分布情况, 本文针对通道结构的质量流量预测问题开展了数据集积累工作。将叶背通道拆分为 3 种基础几何结构, 分别对应冲击孔、扰流柱通道、气膜孔, 具体几何模型如图 3 所示。

通过基础研究对比, 固定参数设置为对结构阻力系数影响较小的几何参数, 如冲击孔、气膜孔的夹层厚度、孔间距。而变化参数及其变化范围设置如下: 由于该数据集中变化参数之间存在函数关系, 并非独立变量, 因此不能表达成正交采样的参数空间表。

对于冲击孔, 变化参数为单变量冲击孔直径 D , 为 $0.6 \sim 1.3 \text{ mm}$; 对于扰流柱通道, 变化参数为通道平均厚度 H , 为 $0.6 \sim 1 \text{ mm}$ 、通道长度 L , 为 $0 \sim 70 \text{ mm}$; 对于气膜孔, 变化参数为气膜孔直径 D , 为 $0.4 \sim 0.8 \text{ mm}$, 气膜孔流动模式分为逆流和顺流。确定好变化参数空间之后, 按照如下步骤进行数据生成和后处理工作:

1) 使用 Fluent 软件进行流固耦合的仿真计算。不断改变进出口压差。计算收敛后直接在 Fluent 软件内读取冷气进口质量流量。

2) 根据公式 $\dot{m}/A = \mu \sqrt{2\rho \cdot \Delta p} + C$ 计算通过特定结构的质量流量, 其中 $\dot{m}$ 为质量流量, A 为通道的最小流通面积, ρ 为冷气密度, Δp 为通道进出口压力差, μ 为结构阻力系数, C 为结构决定的常数。拟合过程采用 Origin 软件对固定几何结构的 $\sqrt{2\rho \cdot \Delta p}$ 和 $\dot{m}/A$ 进行拟合, 得到 μ 和 C 。

3) 重复步骤 2), 使用 Origin 软件对不同几何结构的 μ 和 C 进行拟合。图 3 中的 μ 和 C 的下标 1、2、3 分别表示元件 1、元件 2、元件 3。

最终, 将参数空间中的变化参数作为数据集




图 3 通道结构质量流量预测数据集几何模型示意图

Fig. 3 Schematic diagram of geometric model of channel structure mass flow prediction dataset

的输入参数, 而最终由 μ 和 C 代表的流量拟合关系作为输出, 存储入层板结构流量预测数据集中, 最终获得 128 组结构流量数据, 供后续预测通道结构表面传热系数时调用。

2.2 通道结构内部表面传热系数数据集参数方案

针对通道内部表面传热系数分布情况进行了数据集积累工作, 具体研究模型的几何特征如图 4 所示, 是共包含 4 排扰流柱的通道, 模拟仿真时只考虑流体域部分。采用的湍流模型为切应力输运 (SST) $k-\omega$ 模型, 边界层网格为 10 层。




图 4 通道结构几何模型示意图

Fig. 4 Schematic diagram of geometric model of channel structure

其中, 固定不变的参数包括: 扰流柱直径为 1 mm, 冷气温度为 800 K, 通道上下壁面及扰流柱表面的温度 1 100 K。变化参数包括雷诺数、长径比、无量纲横向间距以及无量纲流向间距(通过 D 进行无量纲化)。采样方式采用正交采样方式。具体的参数变化范围如表 1 所示。

表 1 数据集参数方案

Table 1 Parameter scheme of dataset

参数	取值
雷诺数/ 10^3	2, 5, 10, 15, 20, 25
高径比	0.8, 1.0, 1.2
无量纲流向间距	3, 4, 5
无量纲横向间距	3, 4, 5

确定好变化参数空间之后, 按照如下步骤进行数据生成和后处理工作:

1) 使用 Fluent 软件进行流体域的仿真计算。分别统计通道上下表面和扰流柱圆柱面的平均传热量。

2) 统计通道出口的平均温度 T_{out} , 取参考温度 $T_{ref} = (T_{out} + T_{in})/2$, T_{in} 为通道进口的平均温度。

3) 计算通道壁面和扰流柱面的平均表面传热系数。

最终, 将输入参数设置为变化参数, 输出参数则设置为最终得到的通道平均表面传热系数, 最终得到 162 组数据, 供后续预测通道结构表面传热系数时调用。

2.3 网格划分及边界条件

本文使用 Fluent 商业软件进行网格划分和数值仿真。为了保证数值计算方法的可靠性、可行性和准确性, 本文对训练数据集中的所有模型都进行了网格无关性验证, 并最终选取各模型的网格目标尺寸为 0.1 mm。

参照先进航空发动机的涡轮前进口温度、总压比等信息^[18], 依照工程经验确定训练数据集各模型参数的变化范围, 从而使预测模型的可预测范围覆盖新一代先进航空发动机的常用工况。训练数据集中包含的所有算例均使用 SST $k-\omega$ 湍流模型进行计算。

按照文中第 2.1 节和第 2.2 节确定的参数方案进行数值仿真, 即可得到完整的训练数据集。

3 基于 GA-BP 神经网络的表面传热系数预测

综合使用传统流阻元件、GA-BP 神经网络和肋化传热理论模型, 搭建扰流柱通道内部表面传热系数的预测模型并进行测试。具体的技术路径如图 5 所示。




图 5 表面传热系数预测流程

Fig. 5 Process for predicting convective heat transfer coefficient

3.1 冷气质量流量快速预测

扰流柱通道冷却结构在双层壁叶片叶背区域应用十分广泛, 其在叶片中所处的位置和结构如图 6 所示。根据出口结构的不同, 扰流柱通道大体可分为气膜孔出口和劈缝出口两种。

调用通道结构质量流量预测数据集中的 3 个流阻元件, 使用公式 $\dot{m}/A = \mu \sqrt{2\rho \cdot \Delta p} + C$ 进行质量流量计算。




图6 扰流柱通道冷却结构

Fig. 6 Pin-fin channel cooling structure

扰流柱通道冷却结构涉及多个原件的串联: 对于气膜孔出口, 需要元件1、元件2、元件3串联; 对于劈缝出口, 需要元件1、元件2串联。以单一元件质量流量计算公式为基础, 结合气体连续方程可以得到串联原件质量流量计算的解析式如下:

$$\dot{m} = \frac{P_{\text{ara}2} - \sqrt{P_{\text{ara}2}^2 - P_{\text{ara}1}P_{\text{ara}3} + 2P_{\text{ara}1}\rho \cdot \Delta p}}{P_{\text{ara}1}} \quad (4)$$

其中 $P_{\text{ara}1} = \sum (\mu_r A_r)^{-2}$, $P_{\text{ara}2} = \sum \frac{C_r}{\mu_r^2 A_r}$, $P_{\text{ara}3} = \sum \left(\frac{C_r}{\mu_r} \right)^2$, 对于气膜孔出口叶背通道 $r=1 \sim 3$, 对于劈缝出口叶背通道 $r=1 \sim 2$ 。对 $P_{\text{ara}1}$ 、 $P_{\text{ara}2}$ 、 $P_{\text{ara}3}$ 这3个参数进行数量级分析可知 $|P_{\text{ara}2}| \gg |P_{\text{ara}1}| \gg |P_{\text{ara}3}|$, $P_{\text{ara}2}$ 的浮点误差将极大影响 $\dot{m}$ 的结果。这导致了该解析式难以在程序中直接使用。

为了得到更加可靠的流量计算结果, 对上述流量解析进行了适量简化, 得到的简化计算式为

$$\dot{m} = \frac{\sqrt{2\rho \cdot \Delta p} + \sum C_r}{\sqrt{P_{\text{ara}1}}} \quad (5)$$

使用实际叶片的仿真计算结果作为对照组, 检验扰流柱通道冷却结构质量流量分配预测模型的效果, 通道质量流量的预测误差在1%左右, 如表2所示。

表2 质量流量预测效果测试

Table 2 Mass flow prediction test

结构	质量流量/(kg/s)		相对误差/%
	预测结果	仿真结果	
气膜孔出口	0.005 197	0.005 143	1.04
劈缝出口	0.052 43	0.052 01	0.81

3.2 基于神经网络的表面传热系数预测

通道壁面及扰流柱面也需要确定表面传热系数的参考温度。分别提取冲击孔进口和通道出口处质量平均的冷气温度 T_{in} 和 T_{out} , 设 $T_{\text{ref}} = (T_{\text{in}} + T_{\text{out}})/2$ 。对大量算例进行统计后发现提取出的表面传热系数比较稳定, 因此认为此参考温度选取方法合理。

统计扰流柱通道壁面和扰流柱面的平均表面传热系数, 发现在固定几何和通道进口雷诺数后, 通道内不同位置的表面传热系数差距不大。因此可分别将内壁面和扰流柱面的平均表面传热系数值作为预测输出量。

调用通道结构内部表面传热系数数据集训练2个神经网络模型: 神经网络的输入参数均为雷诺数、长径比、无量纲横向间距以及无量纲流向间距; 输出参数分别为内壁面和扰流柱面的平均表面传热系数。以预测壁面平均表面传热系数的神经网络为例, 按7:3的比例划分训练集和测试集, 训练100轮的均方误差(MSE)损失变化如图7所示。

针对这2个BP神经网络预测模型, 分别将它们初始化和训练过程重复20次, 将神经网络的初始化方案编码为GA染色体, 如图8所示。

使用GA算法优化BP神经网络, 寻找使得神经网络测试集误差最小的初始化方案, 并最终得到GA-BP神经网络预测模型。经过GA算法优化, 2个预测模型的最佳测试集误差均小于优化前20个BP神经网络的最低值: 壁面表面传热系




图7 训练损失下降曲线

Fig. 7 Training loss decline curve




图8 GA染色体编码方案

Fig. 8 GA chromosome coding scheme

数的测试集误差从 5.6% 降低到了 3.9%; 扰流柱面表面传热系数的测试集误差从 5.9% 降低到了 4.2%。

测试优化后的 BP 神经网络模型。固定扰流柱通道的几何参数, 对 2 组全新的雷诺数进行扰流柱面平均表面传热系数预测。预测结果相对仿真结果的误差如表 3 所示。

表 3 表面传热系数预测效果测试
Table 3 Convective heat transfer coefficient prediction test

$Re/10^4$	表面传热系数/(W/(m ² ·K))		相对误差/%
	预测结果	仿真结果	
1.1	3 451	3 596	4.2
1.9	6 170	6 466	4.8

由表 3 可得, 本节训练的 GA-BP 神经网络可以预测通道壁面和扰流柱面的平均表面传热系数, 平均预测误差在 5% 以内。

3.3 扰流柱等效表面传热系数换算

因为双层壁内壁向冷气传递的热量全部由扰流柱导热提供, 因此可以将内壁面和扰流柱面的传热等效到外壁与扰流柱的交界面上。这样在后续的导热计算中便可只考虑外壁面传热, 提高导热计算效率。

双层壁涡轮叶片的扰流柱导热简化模型如图 9 所示。其中 0 面为扰流柱与外壁面的接触面, M 面为双层壁内壁的外表面, N 面为扰流柱面。




图 9 扰流柱导热简化模型

Fig. 9 Simplified model of heat conduction of pin-fin

首先对 M 面进行分析: 假设 M 面与冷气的总传热量为 Q_M , 则这部分热量完全由扰流柱导热决定。将 M 面看作中心热源的肋化散热模型, 则 Q_M 可以通过肋化散热效率与导热过程建立联系。由此得到如下方程组:

$$\begin{cases} Q_M = \frac{\lambda}{\delta} A_0 (T_0 - T_M) \\ Q_M = h_M \eta_M A_2 (T_M - T_\infty) \\ h_{01} = \frac{Q_M}{A_0 (T_0 - T_\infty)} \end{cases} \quad (6)$$

其中 δ 为扰流柱高度, A_0 为扰流柱截面积, λ 为使用设计点温度对应的热导率, h_M 为 M 面的表面传热系数, A_2 为 M 面的表面积, η_M 为圆盘肋的肋效率, 有解析式, T_0 为 0 面的温度, T_M 为 M 面与扰流柱体交界面的温度, T_∞ 为气体温度, h_{01} 为 M 面的表面传热系数等效到 0 面的表面传热系数。

同理对 N 面进行分析, 可以得到如下方程组:

$$\begin{cases} Q_N = h_N \eta_N A_1 (T_0 - T_\infty) \\ h_{02} = \frac{Q_N}{A_0 (T_0 - T_\infty)} \end{cases} \quad (7)$$

其中 Q_N 为 N 面与冷气的总传热量, h_N 为扰流柱表面传热系数, A_1 为扰流柱表面积, η_N 为针状肋的肋效率, 有解析式, h_{02} 为 N 面的表面传热系数等效到 0 面的表面传热系数。联立上述两个方程组中的各个公式, 适当化简后可分别得到

$$\begin{cases} h_{01} = \frac{h_M \eta_M \lambda k_{02}}{h_M \eta_M \lambda k_{02} + \lambda} \\ h_{02} = h_N \eta_N k_{01} \end{cases} \quad (8)$$

其中 $k_{02} = A_2/A_0$, 为 M 面与 0 面的面积比, $k_{01} = A_1/A_0$, 为 N 面与 0 面的面积比, 均需要针对每一个扰流柱进行单独计算。

假设 M 面和 N 面的等效过程互不干涉, 便得到了 0 面等效表面传热系数的计算解析式

$$h_{\text{equal}} = h_{01} + h_{02} = f(h_M, h_N) \quad (9)$$

3.4 预测模块综合测试

综合使用 3 个预测模块, 测试它们应用于实际叶片时的组合预测效果。以 NASA C3X 叶型为基础建立如图 6 所示的直叶片模型, 其叶背区域采用扰流柱通道冷却结构: 冷却气体从叶背的中部进入, 前半段以气膜孔为出口, 后半段以尾缘劈缝为出口。

参照 F119 发动机的性能参数^[18] 设置边界条件: 设主流进口的总温为 2 000 K, 总压为 2 800 kPa; 冷气进口的总温为 800 K, 总压为 3 000 kPa。之后依次调用质量流量、表面传热系数预测模块及扰流柱等效表面传热系数的换算模块, 得到该涡轮叶片在本工况下的吸力侧内表面的表面传热系数分布如图 10 所示。

从数值仿真结果中提取双层壁涡轮叶片外壁面的内外第 3 类边界条件, 然后将提取的内边界条件替换为表面传热系数分布的预测结果。重新计算导热, 由此得到的涡轮叶片叶背区域综合冷效相对仿真结果的误差仅为 3%。




图10 表面传热系数分布预测结果

Fig. 10 Prediction results of convective heat transfer coefficient distribution

4 结 论

本文使用传统流阻元件、BP神经网络和肋化传热理论模型组合的方式搭建了扰流柱通道内表面传热系数的预测模型。该模型预测结果可靠,所有预测子模块相对仿真结果的误差均在5%以内;同时外表面综合冷效的预测误差约为3%。预测模块的预测效率极高,可在0.1 s内得到通道内表面传热系数的二维分布。

使用本预测模型辅助航空发动机涡轮叶片冷却结构设计,可以缩短设计周期,极大地提高了冷却结构评估效率。

参考文献:

- [1] 卫海洋,徐敏,刘晓曦.涡轮叶片冷却技术的发展及关键技术[J].飞航导弹,2012(2): 61-64.
WEI Haiyang, XU Min, LIU Xiaoxi. Development and key technology of turbine blade cooling technology[J]. Flying Missiles, 2012(2): 61-64. (in Chinese)
- [2] 倪萌,朱惠人,裘云,等.航空发动机涡轮叶片冷却技术综述[J].燃气轮机技术,2005(4): 25-33, 38.
NI Meng, ZHU Hui ren, QIU Yun, et al. Review of aero engine turbine blade cooling technology[J]. Gas Turbine Technology, 2005(4): 25-33, 38. (in Chinese)
- [3] 郭文,王鹏飞.涡轮叶片冷却技术分析[J].航空动力,2020(6): 55-58.
GUO Wen, WANG Pengfei. Analysis of turbine blade cooling technology[J]. Aerospace Power, 2020(6): 55-58. (in Chinese)
- [4] CHYU M K, SIW S C, MOON H K. Effects of height-to-diameter ratio of pin element on heat transfer from staggered pin-fin arrays[R]. Orlando, US: ASME Turbo Expo: Power for Land, Sea, and Air, 2009.
- [5] WON S Y, MAHMOOD G I, LIGRANI P M. Spatially-resolved heat transfer and flow structure in a rectangular channel with pin fins [J]. International Journal of Heat and Mass Transfer, 2004, 47(8/9):

- 1731-1743.
- [6] LEE H L, CHOU H M, YANG Y C. The function estimation in predicting heat flux of pin fins with variable heat transfer coefficients[J]. Energy Conversion and Management, 2004, 45(11/12): 1749-1758.
- [7] MONTELPARE S, RICCI R. An experimental method for evaluating the heat transfer coefficient of liquid-cooled short pin fins using infrared thermography[J]. Experimental Thermal and Fluid Science, 2004, 28(8): 815-824.
- [8] LAWSON S A, THRIFT A A, THOLE K A, et al. Heat transfer from multiple row arrays of low aspect ratio pin fins[J]. International Journal of Heat and Mass Transfer, 2011, 54(17/18): 4099-4109.
- [9] BAILEY J C, BUNKER R S. Heat transfer and friction in channels with very high blockage 45° staggered turbulators[R]. Atlanta, US: ASME Turbo Expo 2003, Collocated with the 2003 International Joint Power Generation Conference, 2003.
- [10] 人工智能已嵌入航空发动机产业全流程[J].计测技术, 2019, 39(1): 33.
- [11] ZHU Linyang, ZHANG Weiwei, KOU Jiaqing, et al. Machine learning methods for turbulence modeling in subsonic flows around airfoils[J]. Physics of Fluids, 2019, 31: 015105.1-015105.14.
- [12] LI Zuobiao, SU Liangjun, WEN Fengbo. Deep learning method for fast prediction of film cooling performance[J]. Physics of Fluids, 34: 047111.1-047111.21.
- [13] YANG Li, MIN Zheng, YUE Tianwei, et al. High resolution cooling effectiveness reconstruction of transpiration cooling using convolution modeling method[J]. International Journal of Heat and Mass Transfer, 2019, 133: 1134-1144.
- [14] 丁水汀,魏霞,陶智,等.基于神经网络的带肋回转通道换热性能的预测[J].北京航空航天大学学报,2007,33(4): 401-404.
DING Shuiting, WEI Xia, TAO Zhi, et al. Prediction of heat transfer performance of ribbed rotary channel based on neural network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2007, 33(4): 401-404. (in Chinese)
- [15] 吴丁杰,温立书.一种基于哈里斯鹰算法改进的BP神经网络[J].网络安全技术与应用,2022(1): 38-40.
WU Dingjie, WEN Lishu. An improved BP neural network based on Harris eagle algorithm[J]. Network Security Technology and Application, 2022(1): 38-40. (in Chinese)
- [16] 惠阳,王永岗,彭辉,等.基于优化PSO-BP算法的耦合时空特征下地铁客流预测[J].交通运输工程学报,2021,21(4): 210-222.
HUI Yang, WANG Yonggang, PENG Hui, et al. Subway passenger flow prediction based on optimized PSO-BP algorithm[J]. Journal of Transportation Engineering, 2021, 21(4): 210-222. (in Chinese)
- [17] 李松,刘力军,解永乐.遗传算法优化BP神经网络的短时交通流混沌预测[J].控制与决策,2011,26(10): 1581-1585.
LI Song, LIU Lijun, XIE Yongle. Short-term traffic flow chaotic prediction based on BP neural network optimized by genetic algorithm[J]. Control and Decision, 2011, 26(10): 1581-1585. (in Chinese)
- [18] 陈磊.F119发动机的设计特点与关键技术[J].航空发动机,2011,37(3): 65.
CHEN Lei. Design characteristics and key technologies of F119 engine[J]. Aero Engine, 2011, 37(3): 65. (in Chinese)

(编辑:秦理曼)