

## 高超声速圆锥边界层转捩气动热高效预测技术

顾翌阳<sup>1</sup>, 董昊<sup>1,2,3\*</sup>, 姜应磊<sup>1</sup>, 夏天宇<sup>1</sup>

(1. 南京航空航天大学 航空学院, 江苏 南京 210016; 2. 南京航空航天大学 航空航天结构力学及控制全国重点实验室, 江苏 南京 210016; 3. 南京航空航天大学 非定常空气动力学与流动控制工业和信息化部重点实验室, 江苏 南京 210016)

**摘要:** 为了实现不同自由来流下壁面转捩热流场的高效预测, 基于变分自编码器架构建立了生成式转捩热流预测模型。选取不同自由来流条件下的高超声速圆锥模型作为研究对象, 采用数值模拟方法构建转捩热流数据集。搭建变分自编码器模型, 在转捩热流数据集上进行了训练和验证, 结果分析表明变分自编码器模型能够有效提取热流场隐变量, 并精准重构了背风面流向涡转捩的热流场结构。搭建全连接神经网络模型, 构建了自由来流与热流场隐变量的非线性映射关系。串联全连接神经网络模型和变分自编码器模型解码器部分, 构建高超声速圆锥转捩热流预测模型, 预测结果表明, 该模型能够有效学习复杂转捩机制作用下的热流分布特征, 对不同自由来流下的热流预测精度较高, 误差不高于 0.024。

**关键词:** 热流预测; 深度学习; 计算流体力学; 转捩; 高超声速**中图分类号:** V211.79 **文献标志码:** A **文章编号:** 1001-2486(2026)01-217-10

## Efficient prediction method for aerodynamic heating in hypersonic cone boundary-layer transition

GU Yiyang<sup>1</sup>, DONG Hao<sup>1,2,3\*</sup>, JIANG Yinglei<sup>1</sup>, XIA Tianyu<sup>1</sup>

(1. College of Aerospace Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. State Key Laboratory of Mechanics and Control for Aerospace Structures, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China; 3. Key Laboratory of Unsteady Aerodynamics and Flow Control, Ministry of Industry and Information Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**Abstract:** To enable efficient prediction of transition heat flux fields under diverse freestream conditions, a generative transition heat flux prediction model based on variational autoencoder architecture was developed. The hypersonic cone configuration under different freestream conditions was selected as the research object, with numerical simulation method being employed to generate the transition heat flux dataset. A variational autoencoder model was constructed and was trained and validated on the transition heat flux dataset. The analysis of results demonstrates that the latent variables of the heat flux field can be effectively extracted by the variational autoencoder model, and the heat flux structure of the transition process induced by leeward-side streamwise vortices was accurately reconstructed. A fully connected neural network model was established to construct a nonlinear mapping relationship between the freestream conditions and the latent variables of the heat flux field. By connecting the fully connected neural network model with the decoder part of the variational autoencoder model, a hypersonic cone transition heat flux prediction model was developed. The prediction results indicate that this model effectively learns the characteristics of heat flux distribution under complex transition mechanisms, achieves high prediction accuracy for heat flux under various freestream conditions, with errors not exceeding 0.024.

**Keywords:** heat flux prediction; deep learning; computational fluid dynamics; transition; hypersonic

高超声速飞行技术是 21 世纪航空航天技术领域新的制高点, 也是世界各国的重大战略需求之一<sup>[1]</sup>。然而, 在高超声速飞行器的发展过程中

面临着诸多困难。美国国家航空航天局把转捩列为第一类急需解决的物理模型问题<sup>[2]</sup>。高超声速转捩是指高超声速边界层从层流向湍流的过

**收稿日期:** 2025-01-08**基金项目:** 江苏省杰出青年基金资助项目 (BK20230030)**第一作者:** 顾翌阳 (1998—), 男, 江苏苏州人, 博士研究生, E-mail: guiyiyang@nuaa.edu.cn**\*通信作者:** 董昊 (1983—), 男, 河南洛阳人, 教授, 博士, 博士生导师, E-mail: donghao@nuaa.edu.cn**引用格式:** 顾翌阳, 董昊, 姜应磊, 等. 高超声速圆锥边界层转捩气动热高效预测技术[J]. 国防科技大学学报, 2026, 48(1): 217-226.**Citation:** GU Y Y, DONG H, JIANG Y L, et al. Efficient prediction method for aerodynamic heating in hypersonic cone boundary-layer transition[J]. Journal of National University of Defense Technology, 2026, 48(1): 217-226.

渡,转捩伴随着飞行器表面气动热的陡增,有研究表明,转捩后的气动热通常为层流状态的 3 ~ 5 倍,这对热防护策略的设计提出了较高的要求。作为高超声速飞行器热防护策略设计的先决条件,精准且高效的高超声速转捩热流预测技术能够有效减少热防护系统设计的冗余度,降低飞行器的成本与质量,提高飞行器的设计效率和性能。

现有高超声速转捩热流预测技术主要以工程算法、风洞试验和数值计算为主<sup>[3-5]</sup>。工程算法主要通过边界层相似解并经过理论分析和合理的假设推导得到,或利用试验与数值模拟结果得到的半拟合公式获得。其具有预测效率高的优点,但存在泛化性差的缺点。风洞试验在高超声速风洞中开展模型表面气动热测量,获得的热流结果较为准确,但试验数据获取成本较高。随着计算机和数值模拟技术的快速发展,通过计算流体力学 (computational fluid dynamics, CFD) 求解 Navier-Stokes 方程,可获得飞行器表面热流分布特征,适用于复杂外形的热流数值预测,是获取高精度转捩气动热数据较为理想的手段之一。

在多年的数值模拟和风洞试验中积累了大量高超声速气动热结果,如何对这些数据进行有效融合和再利用,探索高超领域的“第四范式”,逐渐成为目前研究的前沿与热点<sup>[6-10]</sup>。随着数据驱动和深度学习方法的快速发展,国内外研究者尝试采用深度学习方法,基于积累的大量气动数据,搭建数据驱动的气动特性预示技术,取得了不少成果<sup>[11-16]</sup>。Wang 等<sup>[17]</sup>针对超临界翼型的复杂绕流场,建立了基于变分自编码器 (variational autoencoder, VAE) 的深度学习模型,对翼型周围的速度场和压力场进行了预测研究,预测模型能够准确捕捉激波区域的流动细节,并实现了比传统 CFD 方法快 1 600 倍的计算加速。在跨音速三维机翼的压力分布预测方面,Francés-Belda 等<sup>[18]</sup>建立了基于  $\beta$  - 变分自编码器与高斯过程回归 (Gaussian process regression, GPR) 的代理模型,结合主成分分析 (principle component analysis, PCA) 预处理数据,对不同飞行条件 (马赫数、攻角) 下的机翼压力场预测进行了研究,模型在激波区域和高攻角条件下能够高效高精度预测机翼表面压力场分布。

在气动热预测方面,Liu 等<sup>[19]</sup>构建了流 - 热 - 结构耦合的二维圆柱气动热数据库,采用本征正交分解 (proper orthogonal decomposition, POD) 技术,结合径向基函数构建不同来流条件下圆柱气动热流场的高效、高精度预测模型。袁佳

铨等<sup>[20]</sup>建立了基于卷积神经网络的预测模型,对钝锥、钝双锥、升力体和双椭球四类典型外形的表面热流分布进行了预测研究,预测模型对复杂外形预测精度较 U-Net 更高,且在较少训练样本时仍保持良好的性能。晏筱璇等<sup>[21]</sup>针对高超声速机翼表面气动热流场,采用 POD 方法对其进行特征降维,得到热流场 POD 基和基系数,基于 Chebyshev 多项式构建输入为来流参数、输出为 POD 基系数的代理模型,实现气动热的快速预测。陈鑫等<sup>[22]</sup>使用 POD 方法对 100 个 F104 机翼表面气动热流场进行特征降维,构建了输入为来流参数、输出为温度场 POD 基系数的代理模型,该方法在预测效率上相比于数值计算方法提高了 5 个量级。基于通过空间散点代表全局气动热分布的思想,张智超等<sup>[23]</sup>提出了基于径向基函数神经网络的气动热逐点快速预测代理模型,通过多个模型的协调训练与预测,高效获得飞行器表面热流场分布。Ding 等<sup>[24]</sup>利用直接 Monte Carlo 模拟数据构建稀薄流下圆柱表面气动热数据集,搭建输入为自由流参数、输出为圆柱表面 9 个位置气动热分布向量的人工神经网络。上述气动热特征空间降维建模和逐点建模两类预测方法因线性降维和缺失外形对热流分布的影响信息等特点,无法做到在不同自由来流参数条件下开展受复杂转捩机理控制的气动热流场高效高精度预测。

综上,本文以在不同自由来流条件下高超声速圆锥的壁面转捩热流场高效高精度预测为目标,采用具有非线性降维能力和耦合外形参数能力、基于变分自编码器架构的生成式深度学习方法,建立转捩复杂机制控制下的高超声速气动热高效高精度预测模型。采用数值模拟方法建立不同自由来流和几何参数下的转捩气动热数据集,利用生成式深度学习模型对气动热分布进行训练和预测,展示了预测模型的热流场重构能力和预测效果。

## 1 研究方法

### 1.1 基于变分自编码器的壁面热流预测模型

#### 1.1.1 主成分分析

主成分分析是一种统计分析方法,将多组具有一定相关性的样本数据,重新组合成一组新的线性无关向量的线性组合。这是一种最小均方意义上的最优变换,目的是去除输入随机向量之间的相关性,突出原始数据中的隐含特性。主成分分析方法的优势在于数据压缩以及对多维数据进

行降维,操作简单且没有参数限制,已被广泛应用于人脸识别、图像压缩和特征提取等领域,是在高维数据中寻找特征模式的一种技术。

主成分分析方法被用于确定变分自编码器模型最优隐变量空间维数,以实现特征空间的有效提取和高精度热流场重构。最优隐变量空间维数是从香农熵的概念中得出的,利用每个状态出现的可能性来确定保存最多有用信息所需的最小隐向量空间维数<sup>[25]</sup>,通过确定在主成分分析中保留主成分的数量实现。从数学上讲,当仅使用线性变换模块搭建自动编码器时,隐变量空间维数将近似为主成分分析的主成分模式<sup>[26]</sup>。基于上述考虑,本文通过主成分分析方法研究了不同隐变量空间维数对热流重构精度的影响。

### 1.1.2 变分自编码器模型

首先构建以卷积神经网络<sup>[27]</sup>为基础,包含残差卷积编码器<sup>[28]</sup>和解码器的变分自编码器<sup>[17]</sup>。所谓的“变分”,是指变分自编码器认为数据是由某些涉及连续随机变量的随机过程生成的<sup>[29-30]</sup>。因此,变分自编码器中的编码器作为推理模型,在训练过程中通过学习到的概率分布  $p(z|x)$  从输入  $x$  中分别推断  $k$  个隐变量对应的均值与标准差,并利用下式得到隐变量  $z$ :

$$z = \mu + r \odot \exp(\sigma) \quad (1)$$

式中,  $r$  是分量均在  $0 \sim 1$  之间的随机向量。从数学上看,  $k$  个隐变量的后验分布  $q(z|x)$  是均值  $\mu = (\mu_1, \dots, \mu_k)$ 、标准差  $\sigma = (\sigma_1, \dots, \sigma_k)$  的对角高斯分布;先验分布  $p(z)$  是均值  $\mu = 0$ 、标准差  $\sigma = 1$  的标准高斯分布。KL (Kullback-Leibler) 散度被用于描述先验分布与后验分布的差异程度,在此,KL 散度作为损失函数直接参与模型训练和参数学习过程。

$$L_{KL}(q(z|x) \| p(z)) =$$

$$\frac{1}{2} \sum_{i=1}^k [\exp(\sigma_i) - (\sigma_i + 1) + \mu_i^2] \quad (2)$$

解码器作为生成模型,基于给定的隐变量  $z$ ,在学习到的概率分布  $p(z)$  中随机采样,在训练过程中重构出与输入  $x$  尽可能接近的  $x^R$ 。因此,构建重构均方根损失  $(x, x^R)$ ,最小化输入  $x$  与重构输出  $x^R$  的区别:

$$L_{MSE}(x, x^R) = \frac{1}{N} \sum_{i=1}^N \left( \frac{1}{2} \|x_i - x_i^R\| \right) \quad (3)$$

变分自编码器网络训练过程中减小式(4)所示损失函数,每个训练迭代过程采用反向传播算法更新网络参数,整个训练过程结束后,变分自编码器网络能够精准重构输入  $x$ 。

$$L_{VAE} = L_{KL}(q(z|x) \| p(z)) + \alpha L_{MSE}(x, x^R) \quad (4)$$

综合编码器与解码器结构,变分自编码器模型结构如图 1 所示。

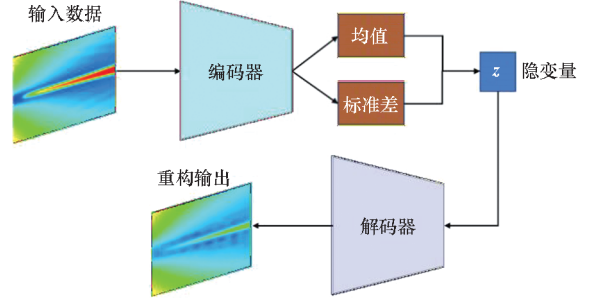


图 1 变分自编码器模型结构

Fig. 1 Structure of variational autoencoder model

输入数据  $x$  为真实壁面热流场,以三维张量  $1 \times 512 \times 512$  形式输入编码器,获得热流场有效特征编码,即隐变量  $z$ ;解码器基于隐变量  $z$  重构输出  $x^R$ ,同样以三维张量  $1 \times 512 \times 512$  形式输出。通过 Adam 优化算法减小以式(4)构建的损失函数,迭代训练模型参数,得到预训练变分自编码器模型。

### 1.1.3 全连接神经网络模型

根据预训练变分自编码器提取的壁面热流场有效特征编码(即隐变量  $z$ ),搭建全连接神经网络以构建自由来流参数与隐变量  $z$  之间的映射关系,全连接神经网络结构如图 2 所示。

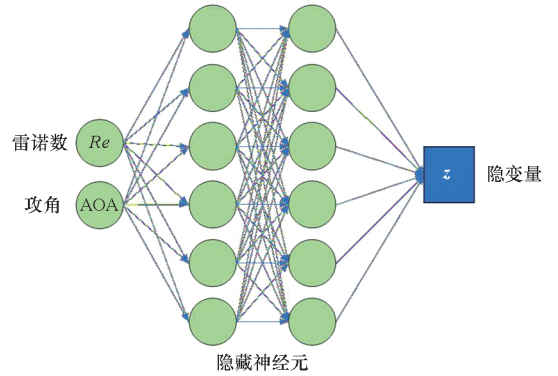


图 2 全连接神经网络模型结构

Fig. 2 Structure of fully-connected neural network model

全连接神经网络的优化目标为最小化预测隐变量  $z^p$  与真实隐变量  $z$  的均方根损失函数:

$$L_{mlp} = \frac{1}{M} \sum_{i=1}^M \left( \frac{1}{2} \|z_i - z_i^p\| \right) \quad (5)$$

式中,  $M$  为采样点数量。神经网络损失通过反向传播算法优化神经网络参数。全连接神经网络拥有 64 个隐藏神经元构成的 4 层隐藏层和对应的 4 层 Tanh 激活函数层。

完成变分自编码器模型与全连接神经网络模型的训练后,串联全连接神经网络模型与变分自编码器中的解码器部分,搭建转捩热流预测的预训练模型。给定自由来流参数,预训练模型中全连接神经网络生成对应的隐变量(特征向量),随后,隐变量通过解码器,得到高精度预测壁面热流场。转捩热流预测预训练模型结构如图 3 所示。

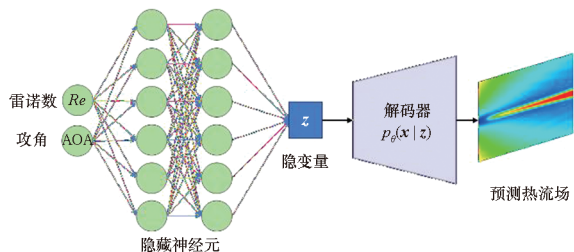


图 3 高超声速转捩热流预测预训练模型结构

Fig. 3 Pretraining model structure for predicting heat flux during hypersonic transition

## 1.2 高超声速转捩数值模拟

### 1.2.1 计算模型和条件

转捩热流预测模型训练、验证数据集均利用 Fluent 软件数值模拟生成。采用圆锥模型,头部钝度(圆锥前端球形钝头半径)为 0.05 mm,半锥角为  $7^\circ$ ,圆锥长为 0.55 m。计算模型示意图如图 4 所示。其中,  $(x, y, \theta)$  是圆锥坐标系。气体参考量选取参考温度为 52 K,来流马赫数为 6,单位雷诺数选取范围为  $4.0 \times 10^6 \sim 9.0 \times 10^6/\text{m}$ ,攻角  $\alpha$  选取范围为  $1^\circ \sim 9^\circ$ 。

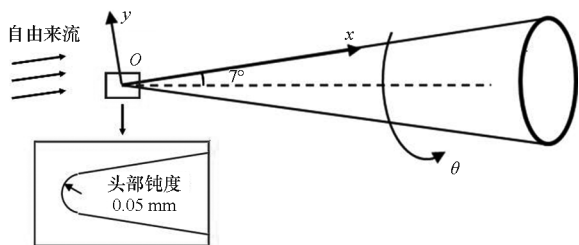


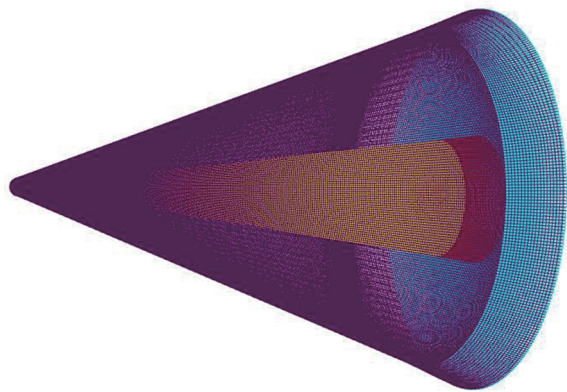
图 4 计算模型示意图

Fig. 4 Sketch map of computational model

圆锥计算域及网格如图 5 所示,采用 Pointwise 软件进行网格划分,圆锥流向网格间距为 1 mm,法向上一个边界层内至少布有 50 个点,第一层法向网格间距为 0.000 05 mm,保证第一层网格  $y^+$  小于 1。无黏通量采用 AUSM 格式,选用 SST 四方程湍流模型。

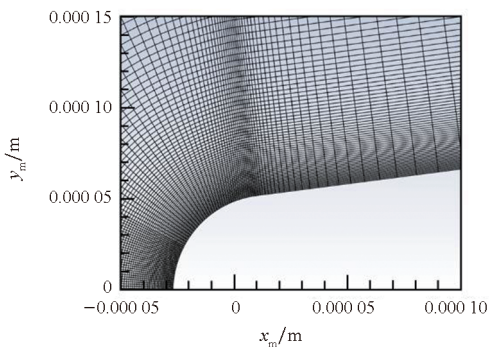
### 1.2.2 网格无关性验证

图 6 给出了 1 500 万、3 000 万、6 000 万三种规模网格在背风面中心线( $\theta = 180^\circ$ )的热流曲线,可以看出,三种网格模型计算得到的结果



(a) 整体网格

(a) Global mesh



(b) 近壁局部网格

(b) Local mesh near wall

图 5 高超声速圆锥计算网格

Fig. 5 Computational mesh of hypersonic cone

基本一致。为了平衡计算精度与计算效率,采用 3 000 万网格进行计算。

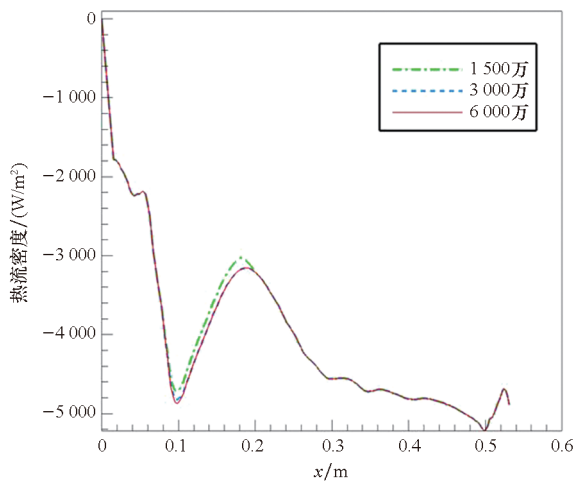


图 6 背风面中心线热流曲线

Fig. 6 Centerline heat flux curves on the leeward side

## 2 结果与讨论

### 2.1 数据集构建

数据集的构建是模型训练前最重要的步骤之一,数据集的好坏直接影响着预测模型训练

的成败。

2.1.1 数据准备

高超声速圆锥三维边界层转捩过程及机理较为复杂,导致不同来流参数下模型表面转捩阵面及热流分布差别较大。为保证数据集样本的可靠性与特征鲜明,在圆锥三维边界层转捩参数研究的基础上,对自由来流参数空间进行均匀采样,共获得 91 个圆锥三维边界层转捩热流分布样本,其中随机选取 77 个样本作为训练数据集,其余 14 个样本作为验证数据集,具体参数空间采样如图 7 所示。

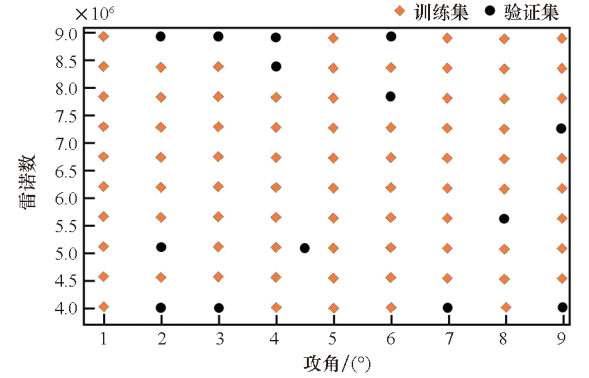


图 7 训练集和验证集样本对应的参数空间采样点  
Fig.7 Parameter space sampling points corresponding to training and validation datasets

2.1.2 数据预处理

首先,考虑到圆锥三维边界层转捩特征,数据集样本采用背风面转捩区热流分布。选取流向坐标  $x$  为  $0.1 \sim 0.5 \text{ m}$  和周向坐标  $\theta$  为  $45^\circ \sim 135^\circ$  的区域作为热流计算及预测区域。

其次,将圆锥壁面三维热流分布通过坐标变换,映射到二维坐标平面上。由于壁面热流在圆锥表面分布,即法向坐标  $y = 0$ ,则可忽略法向坐标,三维热流分布自动坍塌为二维热流分布,仅包含流向坐标  $x$  与周向坐标  $\theta$ 。为保证卷积操作的可行性,生成均匀结构网格  $(x^n, y^n) \in [0, 1]$ ,网格量为  $512 \times 512$ ,通过式(6)所示坐标变换将  $(x, \theta)$  热流分布线性插值到  $(x^n, y^n)$  结构网格上。

$$\begin{cases} x^n = (x - x_{\min}) / (x_{\max} - x_{\min}) \\ y^n = (\theta - \theta_{\min}) / (\theta_{\max} - \theta_{\min}) \end{cases} \quad (6)$$

最后,采用最小值-最大值归一化操作,使热流值均处于  $[0, 1]$  的范围内。

如图 8 所示,对所有壁面转捩热流样本开展以上数据预处理操作,构建生成式热流预测模型训练数据集,以提高模型训练过程的数值稳定性。

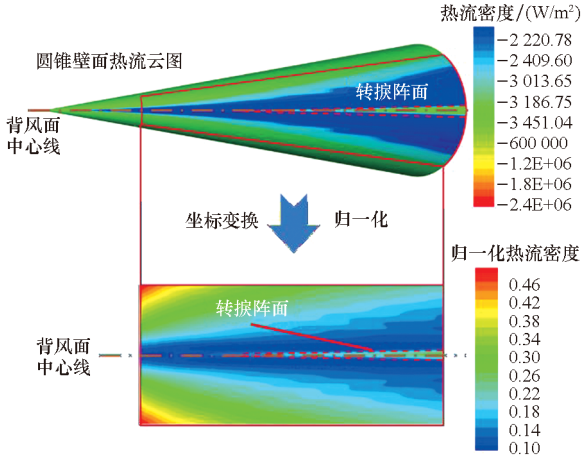


图 8 数据预处理示意图  
Fig.8 Diagram of data preparation

2.2 高超声速圆锥转捩热流预测模型

2.2.1 最优隐变量空间维数

图 9 所示为不同主成分数量下的可解释方差比。可解释方差比用于量化流场特征模态对原始流场总方差的贡献程度,定义为流场模态的特征值占总方差的比例。对于第  $k$  个主成分,可解释方差比为:

$$R_k = \frac{\lambda_k}{d} \quad (7)$$
$$\sum_{i=1}^d \lambda_i$$

式中: $\lambda_k$  是流场数据协方差矩阵的第  $k$  个特征值,对应第  $k$  个主成分的方差; $d$  为流场数据的总数量; $\sum_{i=1}^d \lambda_i$  是总方差,即协方差矩阵的迹——所有特征值之和。

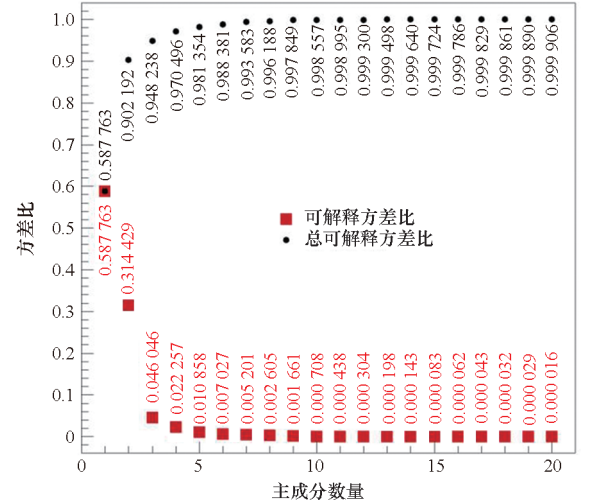


图 9 前 20 个主成分的可解释方差比  
Fig.9 Explained variance ratios of first 20 principle components

前 10 个主成分方差比能够达到 99.86%,而

16 个主成分方差比达到 99.98%, 热流场重构精度较高。随着主成分数量继续增多, 重构精度会随之提高。从重构精度角度考虑, 具有较高维度隐变量空间的模型训练效果更好, 但从物理特征分析的角度考虑, 较低维度的隐变量空间更有利于提取隐变量和热流场之间的联系。综合以上考虑, 主成分数量即隐变量空间维数选为 16。

### 2.2.2 训练过程

热流预测模型的训练、验证过程均在 PyTorch 架构下进行。下面简要介绍模型的超参数调节: 模型单步训练的样本数量定为 16; 模型隐变量空间维数为 16; 模型优化器采用 Adam 优化器; 利用学习率预热策略, 保证训练过程数值稳定, 在前 1 000 步中, 学习率预热过程使学习率从 0 逐渐增大到 0.004, 随后, 进入学习率衰减过程, 每 1 000 步学习率降低 50%。模型训练过程损失曲线如图 10 所示。

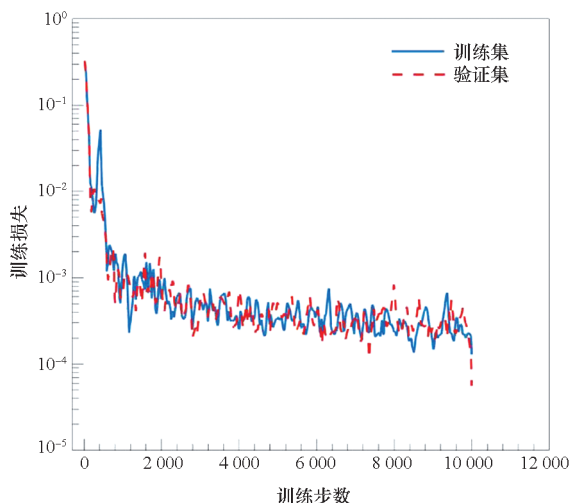


图 10 变分自编码器模型训练损失曲线

Fig. 10 Training loss curve of variational autoencoder

训练 4 000 步之后, 模型在训练集和验证集上同时具有良好的表现。

### 2.2.3 特征提取

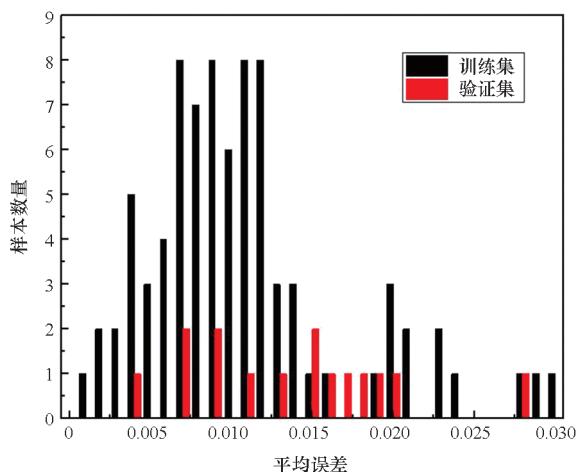
图 11 为热流场重构平均误差和最大误差统计分布。统计结果表明, 变分自编码器模型的重构平均误差在训练集均小于 0.03, 在验证集均小于 0.028, 表明模型具有良好的泛化性。模型平均误差和最大误差利用以下公式获得:

$$e_{MAE} = \frac{1}{n_g} \sum_{i=1}^{n_g} |\mathbf{x}^R - \mathbf{x}| \quad (8)$$

$$e_{MAXE} = \max |\mathbf{x}^R - \mathbf{x}| \quad (9)$$

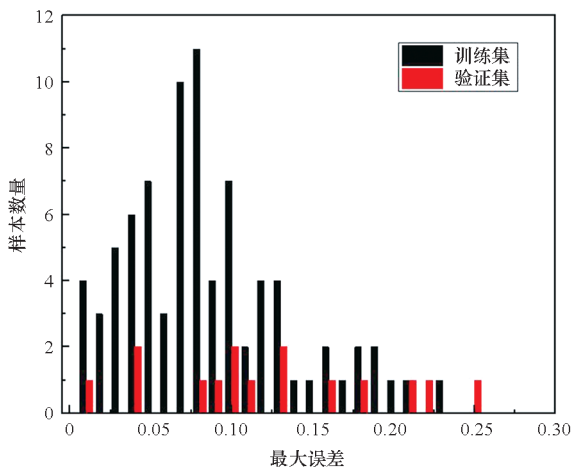
其中,  $n_g$  为网格数。

具体地, 选取了训练集与验证集中重构误差较小 (雷诺数  $5.67 \times 10^6$ 、攻角  $4^\circ$ ) 和较大 (雷诺数



(a) 变分自编码器在训练集及验证集上的平均误差

(a) Mean absolute error of variational autoencoder on training and validation datasets



(b) 变分自编码器在训练集及验证集上的最大误差

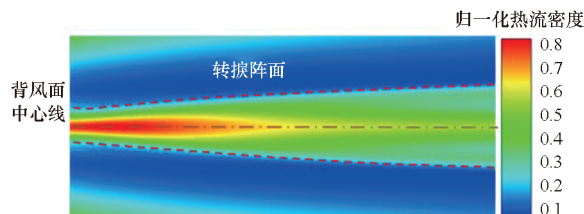
(b) Maximum absolute error of variational autoencoder on training and validation datasets

图 11 热流场重构平均误差和最大误差统计分布

Fig. 11 Distribution statistics of the mean absolute error and maximum absolute error for the reconstructed heat flux fields

$7.33 \times 10^6$ 、攻角  $5^\circ$ ) 的样本数据以作比较, 如图 12 和图 13 所示。

重构误差较小的样本中, 背风面流向涡转捩区热流场重构结果与真实结果基本一致; 重构误差较大的样本中, 背风面流向涡转捩阵面重构较



(a) 真实热流分布

(a) Truth heat flux field distribution

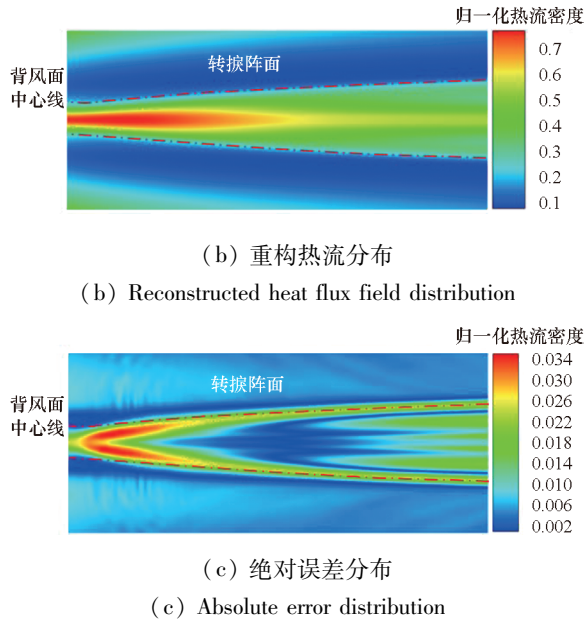


图 12 误差较小训练样本的热流场重构结果  
Fig. 12 Reconstruction results of heat flux field for training samples with small errors

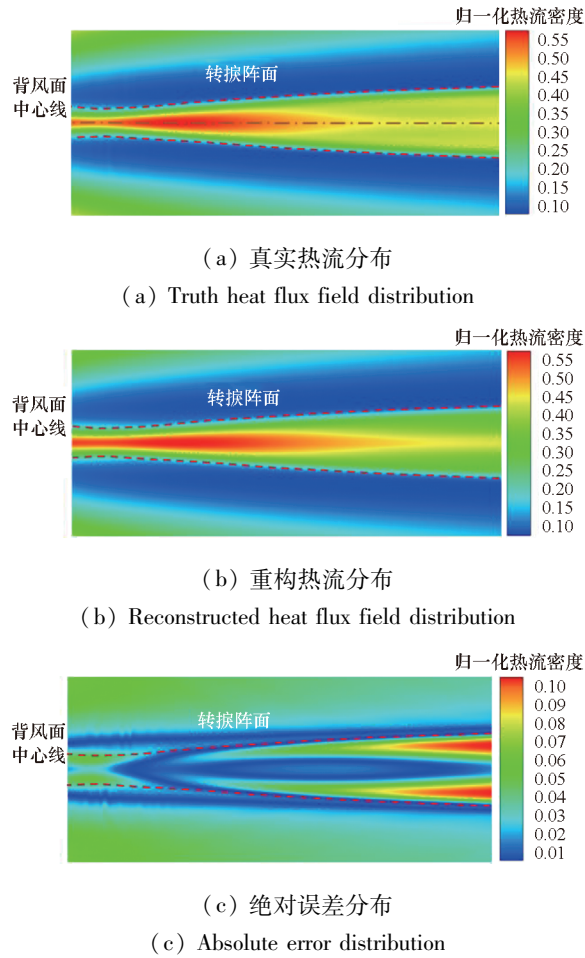


图 13 误差较大训练样本的热流场重构结果  
Fig. 13 Reconstruction results of heat flux field for training samples with large errors

总体来说,壁面重构热流场较为光滑,并不存在数值振荡等非物理解。转捩过程的涡破碎和猝发现象导致转捩狭小区域热流陡增,是变分自编码器模型重构误差集中分布在转捩区域的主要原因。

因此,图 14 展示了训练集与验证集中重构误差较小和较大的样本数据背风面中心线壁面热流曲线。重构热流曲线与真实曲线符合较好,转捩起止点预测有不错的精度,转捩区宽度与真实结果基本一致。重构误差集中在转捩阵面前缘,是转捩过程热流剧烈变化的主要表现。总体来说,变分自编码器模型能够高效、准确地重构高超声速圆锥转捩热流场。

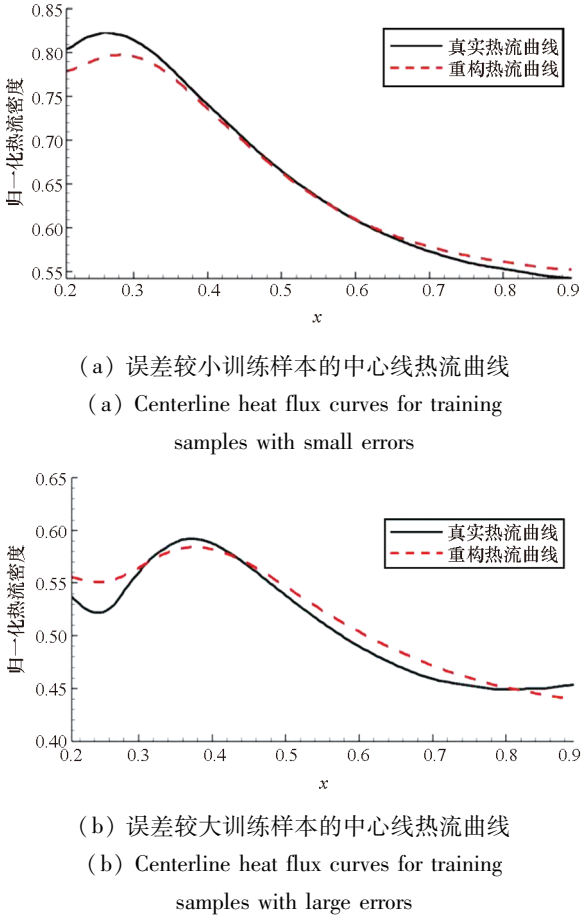


图 14 不同训练样本中心线热流曲线重构结果  
Fig. 14 Results of the reconstructed centerline heat flux curve for different training samples

#### 2.2.4 热流场预测

变分自编码器以特征提取得到的隐变量  $z$  为标签,监督学习全连接神经网络,构建自由来流参数与隐变量  $z$  的映射关系,通过串联预训练全连接神经网络预测模型和变分自编码器模型解码器部分,构建热流场预测模型。

其中全连接神经网络模型的训练损失曲线如图 15 所示。约 3 000 步后,训练残差逐渐收敛。

为准确,但转捩区热流场重构存在一定的误差。

热流场预测平均误差和最大误差统计分布见图 16,全连接神经网络在训练集和验证集表现基本一致,变分自编码器模型的重构损失在训练集均小于 0.024,预测误差在验证集均小于 0.022,表明该模型的泛化能力较为良好。

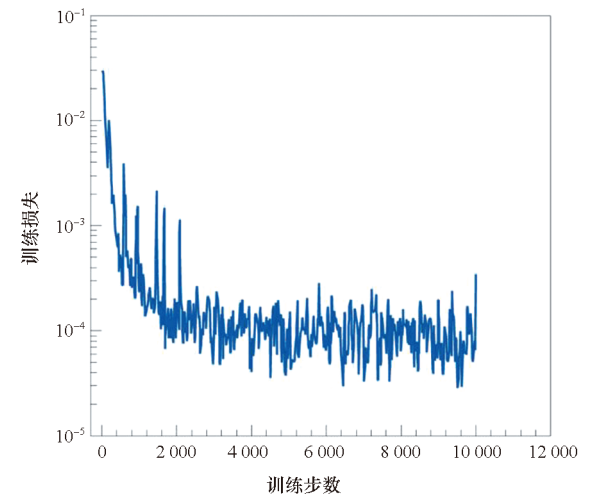
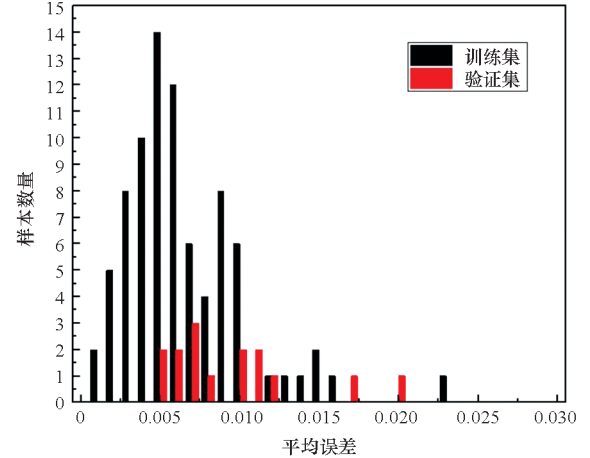


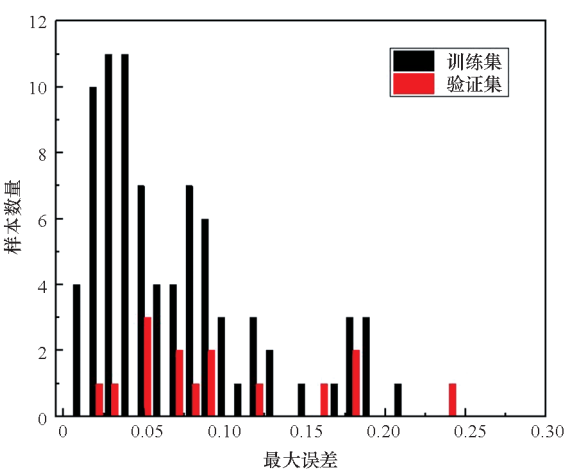
图 15 全连接神经网络模型训练损失曲线  
Fig. 15 Training loss curve of fully-connected neural network model

图 17 和图 18 分别是训练集和验证集中预测误差较小与较大的数据样本热流场预测结果。预测误差较小的样本中,转捩区热流场预测结果与真实结果具有较好的一致性,包括转捩阵面、热流陡增都得到很好的预测;预测误差较大的样本中,转捩阵面的预测结果与真实结果较为相似,但转捩区热流场预测存在一定的误差。总的来说,壁面预测热流场较为光滑,并不存在数值振荡等非物理解。转捩狭小区域热流的剧烈变化,是生成式热流预测模型预测误差集中分布在转捩区域前缘的主要原因。



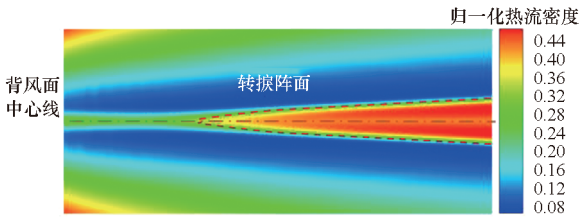
(a) 全连接神经网络模型在训练集及验证集上的平均误差

(a) Mean absolute error of fully-connected neural network model on training and validation datasets

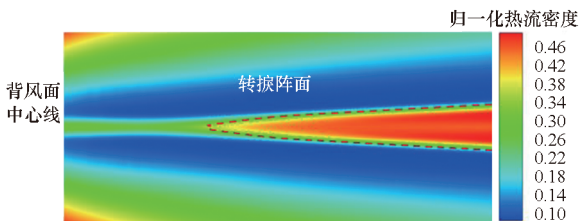


(b) 全连接神经网络模型在训练集及验证集上的最大误差  
(b) Maximum absolute error of fully-connected neural network model on training and validation datasets

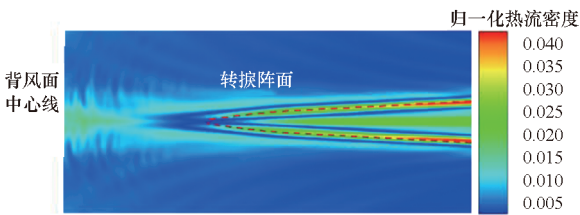
图 16 热流场预测平均误差和最大误差统计分布  
Fig. 16 Distribution statistics of the mean absolute error and maximum absolute error for the predicted heat flux fields



(a) 真实热流分布  
(a) Truth heat flux field distribution



(b) 预测热流分布  
(b) Predicted heat flux field distribution



(c) 绝对误差分布  
(c) Absolute error distribution

图 17 误差较小训练样本的热流场预测结果  
Fig. 17 Results of the predicted heat flux field for training samples with small errors

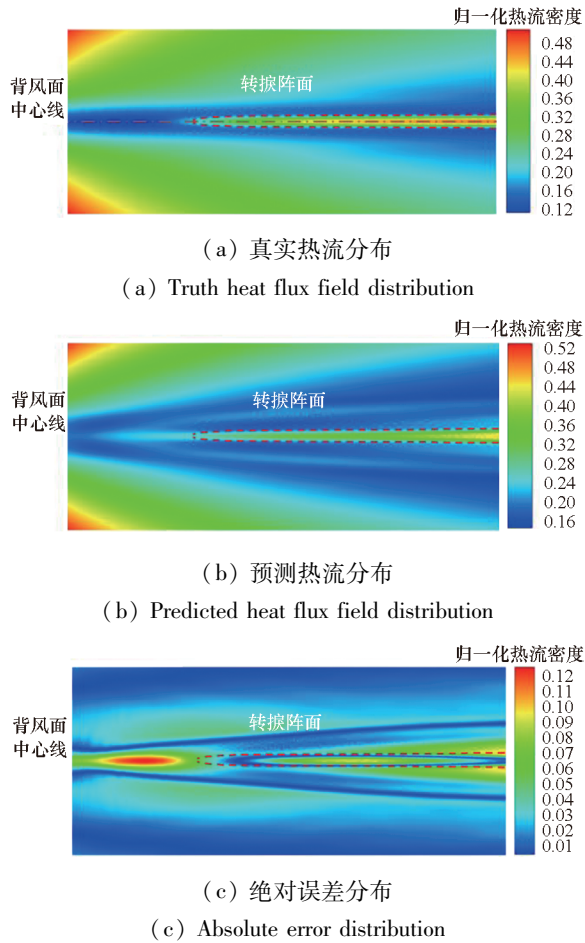


图 18 误差较大训练样本的热流场预测结果

Fig. 18 Results of the predicted heat flux field for training samples with large errors

3 结论

本文结合生成式深度学习方法,融合数值仿真平台转捩热流数据库,基于变分自编码器架构搭建了一套适用于高超声速圆锥转捩阵面及壁面热流场高效、精准预测的人工智能模型。训练数据集和验证数据集误差统计结果及流场重构和预测结果表明,该模型能够对不同自由来流条件下圆锥三维边界层转捩热流场进行精准、高效的重构及预测。主要结论如下:

- 1)采用主成分分析方法对高超声速圆锥转捩热流场进行了线性模态分解,获得了各模态对应的可解释方差比,确定了变分自编码器模型最优隐变量空间维数为 16。
- 2)经过超参数调节的变分自编码器模型具有较好的壁面热流场特征提取和重构能力。其从  $512 \times 512$  的高精度真实壁面热流场中提取 16 个隐变量。在训练过程中发现,隐变量  $z$  是自由来流参数的有效潜在特征,因此变分自编码器是有力的特征提取模型。变分自编码器在训练数据集

上热流场重构平均误差均小于 0.03,在验证数据集上的平均误差均小于 0.028,表现出较好的泛化性能。重构热流场分析表明,在转捩起止位置,热流的剧烈变化是重构误差集中在转捩前缘区域的主要原因。

3)经过超参数调节的全连接神经网络模型主要负责建立自由来流参数与热流场潜在特征之间的非线性映射关系。预训练的全连接神经网络模型与变分自编码器模型解码器部分串联构成高超声速圆锥壁面热流预测模型。统计数据表明,该模型能够高效且准确地预测高超声速三维圆锥背风面流向涡转捩区转捩阵面及壁面热流场分布,预测误差不超过 0.024。

参考文献 (References)

[1] LUO C X, LEI H M, LI J, et al. A new adaptive neural control scheme for hypersonic vehicle with actuators multiple constraints [J]. Nonlinear Dynamics, 2020, 100 (4): 3529 – 3553.

[2] SLOTNICK J P, KHODADOUST A, ALONSO J, et al. CFD vision 2030 study: a path to revolutionary computational aerosciences: NF1676L – 18332 [R]. Washington, D. C.: NASA Technical Reports Server, 2014.

[3] 王梓伊, 张伟伟, 刘磊. 高超声速飞行器热气动弹性仿真计算方法综述[J]. 气体物理, 2020, 5(6): 1 – 15.

WANG Z Y, ZHANG W W, LIU L. Review of simulation methods of hypersonic aerothermoelastic problems [J]. Physics of Gases, 2020, 5(6): 1 – 15. (in Chinese)

[4] 罗长童, 胡宗民, 刘云峰, 等. 高超声速风洞气动力/热试验数据天地相关性研究进展[J]. 实验流体力学, 2020, 34(3): 78 – 89.

LUO C T, HU Z M, LIU Y F, et al. Research progress on ground-to-flight correlation of aerodynamic force and heating data from hypersonic wind tunnels[J]. Journal of Experiments in Fluid Mechanics, 2020, 34(3): 78 – 89. (in Chinese)

[5] 彭治雨, 石义雷, 龚红明, 等. 高超声速气动热预测技术及发展趋势[J]. 航空学报, 2015, 36(1): 325 – 345.

PENG Z Y, SHI Y L, GONG H M, et al. Hypersonic aeroheating prediction technique and its trend of development[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(1): 325 – 345. (in Chinese)

[6] 王怡星, 韩仁坤, 刘子扬, 等. 流体力学深度学习建模技术研究进展[J]. 航空学报, 2021, 42(4): 225 – 244.

WANG Y X, HAN R K, LIU Z Y, et al. Progress of deep learning modeling technology for fluid mechanics [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42 (4): 225 – 244. (in Chinese)

[7] REN H J, WANG S, YUAN X X, et al. A flight test based deep learning method for transition heat flux prediction in hypersonic flow [J]. Physics of Fluids, 2022, 34 (5): 054106.

[8] MENG D Y, SHI M T, SHI Y P, et al. A machine learning method for transition prediction in hypersonic flows over a cone with angles of attack [J]. AIP Advances, 2022, 12(2): 025116.

[9] LI T, GUO L, YANG Z G, et al. An automatic shape-aware

- method for predicting heat flux of supersonic aircraft based on a deep learning approach [J]. *Physics of Fluids*, 2022, 34(7): 077103.
- [10] 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.
- [11] IMMORDINO G, DA RONCH A, RIGHI M. Steady-state transonic flowfield prediction via deep-learning framework [J]. *AIAA Journal*, 2024, 62(5): 1915–1931.
- [12] DU Q W, LIU T Y, YANG L K, et al. Airfoil design and surrogate modeling for performance prediction based on deep learning method [J]. *Physics of Fluids*, 2022, 34(1): 015111.
- [13] DENG Z W, WANG J, LIU H S, et al. Prediction of transonic flow over supercritical airfoils using geometric-encoding and deep-learning strategies [J]. *Physics of Fluids*, 2023, 35(7): 075146.
- [14] WANG J, XIE H R, ZHANG M, et al. Physics-assisted reduced-order modeling for identifying dominant features of transonic buffet [J]. *Physics of Fluids*, 2023, 35(6): 066124.
- [15] MONI A, YAO W G, MALEKMOHAMADI H. Data-driven reduced-order modeling for nonlinear aerodynamics using an autoencoder neural network [J]. *Physics of Fluids*, 2024, 36(1): 016105.
- [16] CANTERO-CHINCHILLA S, CROXFORD A J, WILCOX P D. A data-driven approach to suppress artefacts using PCA and autoencoders [J]. *NDT & E International*, 2023, 139: 102904.
- [17] WANG J, HE C, LI R Z, et al. Flow field prediction of supercritical airfoils via variational autoencoder based deep learning framework [J]. *Physics of Fluids*, 2021, 33(8): 086108.
- [18] FRANCÉS-BELDA V, SOLERA-RICO A, NIETO-CENTENERO J, et al. Toward aerodynamic surrogate modeling based on  $\beta$ -variational autoencoders [J]. *Physics of Fluids*, 2024, 36(11): 117139.
- [19] LIU J, WANG M, LI S. The rapid data-driven prediction method of coupled fluid-thermal-structure for hypersonic vehicles [J]. *Aerospace*, 2021, 8(9): 265.
- [20] 袁佳铖, 宗文刚, 曾磊, 等. 基于卷积神经网络的气动热预测方法 [J]. *空气动力学学报*, 2024, 42(1): 13–25.
- YUAN J C, ZONG W G, ZENG L, et al. CNN-based method for predicting aerodynamic heating [J]. *Acta Aerodynamica Sinica*, 2024, 42(1): 13–25. (in Chinese)
- [21] 晏筱璇, 韩景龙, 马瑞群. 高超声速气动热弹性分析降阶研究 [J]. *振动工程学报*, 2022, 35(2): 475–486.
- YAN X X, HAN J L, MA R Q. Reduced-order modeling research for hypersonic aerothermoelastic analysis [J]. *Journal of Vibration Engineering*, 2022, 35(2): 475–486. (in Chinese)
- [22] 陈鑫, 刘莉, 岳振江. 基于本征正交分解和代理模型的高超声速气动热模型降阶研究 [J]. *航空学报*, 2015, 36(2): 462–472.
- CHEN X, LIU L, YUE Z J. Reduced order aerothermodynamic modeling research for hypersonic vehicles based on proper orthogonal decomposition and surrogate method [J]. *Acta Aeronautica et Astronautica Sinica*, 2015, 36(2): 462–472. (in Chinese)
- [23] 张智超, 高太元, 张磊, 等. 基于径向基神经网络的气动热预测代理模型 [J]. *航空学报*, 2021, 42(4): 524167.
- ZHANG Z C, GAO T Y, ZHANG L, et al. Aeroheating agent model based on radial basis function neural networks [J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(4): 524167. (in Chinese)
- [24] DING D M, CHEN H, MA Z, et al. Heat flux estimation of the cylinder in hypersonic rarefied flow based on neural network surrogate model [J]. *AIP Advances*, 2022, 12(8): 085314.
- [25] PEARSON K. On lines and planes of closest fit to systems of points in space [J]. *Philosophical Magazine Series 6*, 1901, 2: 559–572.
- [26] OJA E. A simplified neuron model as a principal component analyzer [J]. *Journal of Mathematical Biology*, 1982, 15(3): 267–273.
- [27] FUKUSHIMA K. Neocognitron; a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position [J]. *Biological Cybernetics*, 1980, 36(4): 193–202.
- [28] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016: 770–778.
- [29] KINGMA D P, WELLING M. Auto-encoding variational Bayes [EB/OL]. (2022–12–10) [2024–11–15]. <https://arxiv.org/abs/1312.6114>.
- [30] HIGGINS I, METTHEY L, PAL A, et al.  $\beta$ -VAE: learning basic visual concepts with a constrained variational framework [C]//*Proceedings of the International Conference on Learning Representation (ICLR)*, 2017: 1–22.