



基于条件扩散的变形结构气动热预测方法

何纪云 吕宏强 李旭东 虞建 许冉 张俊龙 刘学军

An aeroheating prediction method for deformed structures based on conditional diffusion model

HE Jiyun, LYU Hongqiang, LI Xudong, YU Jian, XU Ran, ZHANG Junlong, LIU Xuejun

引用本文:

何纪云, 吕宏强, 李旭东, 等. 基于条件扩散的变形结构气动热预测方法[J]. 空气动力学学报, 2025, 43(8): 22–35. DOI: 10.7638/kqdlxxb-2024.0176

HE Jiyun, LYU Hongqiang, LI Xudong, et al. An aeroheating prediction method for deformed structures based on conditional diffusion model[J]. *Acta Aerodynamica Sinica*, 2025, 43(8): 22–35. DOI: 10.7638/kqdlxxb-2024.0176

在线阅读 View online: <https://doi.org/10.7638/kqdlxxb-2024.0176>

您可能感兴趣的其他文章

Articles you may be interested in

考虑机身累积热变形的高速飞机气动布局稳健优化

Robust optimization of aerodynamic layout for high-speed aircraft considering cumulative thermal deformation of fuselage

空气动力学学报. 2024, 42(10): 98–109 <https://doi.org/10.7638/kqdlxxb-2024.0129>

一种数据驱动的气动热预示模型

A data-driven aeroheating prediction model

空气动力学学报. 2023, 41(5): 12–19 <https://doi.org/10.7638/kqdlxxb-2022.0010>

基于卷积神经网络的气动热预测方法

CNN-based method for predicting aerodynamic heating

空气动力学学报. 2024, 42(1): 13–25 <https://doi.org/10.7638/kqdlxxb-2023.0072>

高速飞行器结构/气动/推力耦合动力学建模方法

Dynamic modeling of a hypersonic vehicle with structure, aerodynamic and propulsion coupling

空气动力学学报. 2024, 42(10): 19–29 <https://doi.org/10.7638/kqdlxxb-2023.0180>

考虑机身累积热变形的高速飞机气动布局稳健优化

Robust optimization of aerodynamic layout for high-speed aircraft considering cumulative thermal deformation of fuselage

空气动力学学报. 2024, 42(10): 98–109 <https://doi.org/10.7638/kqdlxxb-2024.0129>

地址: 四川省绵阳市二环路南段8号11信箱9分箱

电话: 0816-2463375

Email: kqdlxxb@163.com



关注微信公众号

获得更多资讯信息

文章编号: 0258-1825(2025)08-0022-14

基于条件扩散的变形结构气动热预测方法

何纪云¹, 吕宏强², 李旭东³, 虞建¹, 许冉¹, 张俊龙¹, 刘学军^{1,*}

(1. 南京航空航天大学 人工智能学院, 脑机智能技术教育部重点实验室, 南京 211106;

2. 南京航空航天大学 航空学院, 南京 210016;

3. 北京航天长征飞行器研究所, 北京 100071)

摘要: 伸缩变形结构飞行器外形复杂, 气动热数据分布差异较大, 代理模型难以准确捕获其物面气动热数据的分布。为了对变形结构飞行器物面气动热进行准确预测, 本文基于条件扩散模型提出了一种变形结构气动热预测方法 (heating-MLP diffusion, HMD)。该方法包括前向扩散与逆向去噪两个过程。在前向扩散过程中, 对原始气动热数据进行逐步加噪, 直至成为纯高斯噪声; 在逆向去噪过程中, 将变形结构外形和工况参数作为条件, 利用全连接神经网络预测扩散过程中每步添加的噪声, 从而学习隐含的气动热数据分布特性, 最终实现飞行器伸缩变形机翼物面网格点的气动热预测。基于数值仿真数据的模型验证结果表明, 相较于高斯过程、神经过程和全连接神经网络, 基于条件扩散模型的气动热预测方法能够取得更好的预测效果, 平均绝对百分比误差在 10% 左右。该方法可为伸缩变形结构高速飞行器机翼物面气动热计算提供一种精确预测模型。

关键词: 条件扩散; 代理模型; 高速; 气动热; 伸缩变形结构; 全连接神经网络

中图分类号: TP181; V211.3 **文献标识码:** A **doi:** 10.7638/kqdlxxb-2024.0176

An aeroheating prediction method for deformed structures based on conditional diffusion model

HE Jiyun¹, LYU Hongqiang², LI Xudong³, YU Jian¹, XU Ran¹, ZHANG Junlong¹, LIU Xuejun^{1,*}

(1. The Key Laboratory of Brain-Machine Intelligence Technology, Ministry of Education,

College of Artificial Intelligence, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;

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

3. Beijing Aerospace Long March Vehicle Research Institute, Beijing 100071, China)

Abstract: The shape of aircraft with telescopic deformed structures is complex, and the distribution of aerothermal data varies significantly. Traditional surrogate models to capture the aerothermal heating distribution of telescopic structures, hindering effective prediction struggle on structural surfaces. Based on the conditional diffusion model, the Heating-MLP Diffusion (HMD) method for deformable structures was proposed, comprising two processes: forward diffusion and reverse denoising. In the forward diffusion process, the original aerothermal data is gradually corrupted until it becomes pure Gaussian noise. In the reverse denoising process, using the shape and operating conditions of the deformed structure as conditional inputs, a fully connected neural network predicts the noise added at each diffusion step, thereby learning the implicit distribution characteristics of aerothermal heating data, thus enabling the prediction of aerothermal heating on the surface grid points of aircraft telescopic deformed wings. Numerical simulation data validated the proposed model. Experimental results demonstrate that compared with Gaussian processes, neural processes, and neural networks, the conditional

收稿日期: 2024-11-12; 修订日期: 2024-12-09; 录用日期: 2025-02-18; 网络出版时间: 2025-03-28

基金项目: 国家自然科学基金面上项目 (12472236)

作者简介: 何纪云 (1994—), 男, 安徽人, 硕士研究生, 研究方向: 机器学习与人工智能. E-mail: hejiyun@nuaa.edu.cn

通信作者: 刘学军 (1976—), 女, 教授, 研究方向: 机器学习. E-mail: xuejun.liu@nuaa.edu.cn

引用格式: 何纪云, 吕宏强, 李旭东, 等. 基于条件扩散的变形结构气动热预测方法[J]. 空气动力学学报, 2025, 43(8): 22–35.

HE J Y, LYU H, LI X D, et al. An aeroheating prediction method for deformed structures based on conditional diffusion model[J]. Acta Aerodynamica Sinica, 2025, 43(8): 22–35(in Chinese). doi: 10.7638/kqdlxxb-2024.0176

diffusion model-based aerothermal prediction method achieves higher accuracy, with a mean absolute percentage error of $\sim 10\%$. This evidence proves its effectiveness in predicting aerothermal heating on high-speed aircraft wings with telescopic deformed structures providing an accurate prediction model for engineering applications.

Keywords: conditional diffusion; surrogate models; high speed; aeroheating; telescopic deformed structure; fully connected neural network

0 引言

飞行器高速飞行时, 由于激波和黏性的作用, 其周围空气温度急剧升高, 气动加热现象严重, 即所谓热障。飞行器的热防护设计与精准有效的气动热预测技术息息相关。一方面, 若飞行器表面热流预测值偏低, 会严重危及飞行器的安全, 甚至导致飞行器烧毁; 另一方面, 若预测值偏高, 会造成热防护系统的设计冗余, 从而增加成本。目前高速飞行器气动热环境的准确预测仍面临诸多难题^[1]。

传统的气动热预测方法包括飞行试验、风洞试验、工程算法和计算流体力学 (computational fluid dynamics, CFD) 模拟等。飞行试验和风洞试验虽然可以精准测量飞行器的气动热, 但是受成本限制, 难以作为常规预测手段^[2]。随着 CFD 技术的迅猛发展, 数值模拟方法可以精准刻画流场, 成为气动热预测的重要研究手段^[3]。但数值格式和网格划分会影响气动热的数值计算精度^[4-6]。例如, Klopfer 和 Yee^[7] 在 1988 年发现钝体驻点热流值依赖于网格以及格式选取, 要得到准确的热流值, 网格雷诺数要求小于 3。此外, 数值模拟方法对于复杂外形飞行器的网格质量要求极高, 存在计算复杂度高、收敛困难等问题, 仍难以满足工程设计中气动热的快速精准预测需求^[8]。传统解决方法是基于试验或数值模拟数据, 通过回归预测方法逼近真实模型, 得到飞行器气动参数的解析表达式^[9]。对此, Dowell^[10] 和 Silva^[11] 提出了基于 CFD 数值模拟构造飞行器流场降阶代理模型 (reduced-order model, ROM) 的思想。传统 ROM 代理模型的常用方法包括响应面、Kriging^[12] 及本征正交分解 (proper orthogonal decomposition, POD)^[13] 等。

如今人工智能技术发展迅速, 在各个领域都发挥着举足轻重的作用, 许多学者开始尝试将机器学习及深度学习应用于气动热预测模型构建。杨帆等^[14] 提出了一种针对高速飞行器双曲率前缘气动热分布的快速预测方法, 通过数值计算获取前缘驻点区气动热分布作为训练集数据, 并基于多层分块算法给出热流分布预测的显式表达式。寇家庆和张伟伟^[15] 研究了基函数宽度对递归径向基 (radial basis function, RBF) 神经网络气动热模型精度的影响。张智超等^[16] 提出了一种基于径向基神经网络的气动热快速预示

代理模型方法, 以来流参数为输入, 输出各网格节点热流预测值。袁佳铖等^[17] 提出了基于卷积神经网络的气动热预测方法, 将飞行器的外形以及来流条件参数化为特征矩阵, 利用卷积神经网络^[18] (convolution neural networks, CNN) 和 U-net^[19] 进行特征提取实现预测。但针对三维飞行器机翼伸缩变形结构物面气动热预测, 由于数据分布差异大、样本稀疏等问题, 仍面临较大挑战。

扩散模型 (diffusion model, DM) 是来源于非平衡热力学的一种生成式模型, 其思想最早于 2015 年提出^[20], 并在 2020 年去噪扩散概率模型 (denoising diffusion probabilistic model, DDPM)^[21] 中广受关注。该模型和其他生成式模型类似, 实现从噪声 (例如高斯分布) 生成目标数据样本。扩散模型包括两个过程, 分别是前向扩散和逆向去噪。这两个过程都是一个参数化的马尔科夫链 (Markov Chain), 其独特的加噪/去噪结构使得它相比其他主流生成式模型更容易学习到样本数据隐含的分布信息。DDPM 的逆向去噪过程可以看作是一个马尔科夫链蒙特卡罗 (Markov Chain Monte Carlo, MCMC) 采样过程, 其中每一步的迭代都可以看作是从随机噪声往数据分布的梯度方向推进, 该梯度方向由神经网络拟合得到。整个扩散模型生成样本的过程就可以视为一个迭代递进的过程, 模型的初始输入是随机噪声, 经过固定轮数的迭代后输出符合样本分布规律的数据。然而, DDPM 仅能生成符合样本空间分布的随机样本, 无法根据指定特征条件生成符合该条件的样本数据。鉴于气动热回归预测需根据指定的来流条件与外形条件输出对应的飞行器表面气动热数据, 需要条件约束扩散模型引导去噪过程, 以构建气动热回归预测代理模型。

条件扩散模型目前主要分为两种: 分类器引导^[22] 和无分类器引导^[23]。分类器引导的条件扩散模型在无分类器引导的基础上引入一个分类器网络用于改变去噪过程的梯度方向, 而无分类器引导条件扩散模型通过隐式分类器替代显式分类器, 直接将条件加入训练过程中。由于分类器难以基于有限训练数据进行充分学习, 因此使用误差较大的分类器模型来引导生成条件扩散模型并不能取得理想的效果。无分类器引导的条件扩散模型解决了这一问题, 已在图像/视频生成等领域广泛应用, 但在气动热回归预测领域

尚未有相关应用。针对变形结构飞行器气动热预测需建立外形/工况参数与物面热流映射关系的特点,本文采用无分类器引导条件扩散模型作为解决方案。

综上所述,本文提出了一种基于条件扩散模型的伸缩变形结构气动热预测方法(heating-MLP diffusion, HMD),其将无分类器引导的条件扩散模型与多层感知器(multilayer perceptron, MLP)相结合,以来流/外形参数等特征作为扩散模型中的条件,设计基于全连接神经网络的扩散模块为主体的噪声预测结构,构建气动热回归预测模型。传统扩散模型方法主要应用于生成图像/视频等高维数据,采用CNN预测其中的噪声,对于机翼物面气动热这类低维数据,本文选择全连接神经网络来预测添加的噪声。

1 问题描述

本文的主要目的是构建一个深度学习代理模型来模拟外形/来流参数与相应物面网格点气动热之间的映射关系,验证训练后的模型能够根据新的外形/来流参数在一定误差范围内预测对应的机翼表面热流值。由于真实的气动热数据无法准确获取,因此本文以数值仿真数据代替试验数据,对文章所提出的代理模型方法的有效性加以验证。

本文研究的可伸缩变形机翼伸缩偏转角 σ 分别为 0° 、 10° 、 20° 、 30° 、 40° 、 44° ,不同偏转角下的飞行器外形如图1所示。所有数据集下的机翼物面网格划分一致,均为19361个网格点,如图2所示。




图1 飞行器机翼不同偏转角下的外形

Fig. 1 The shape of the wing of the aircraft at different deflection angles




图2 机翼网格划分

Fig. 2 Wing meshing

为了验证模型能够有效捕获来流条件与外形条件,数据集共包括6种偏转角和7种工况组合的42个样本,为不失一般性,从其中随机划分36个数据作为训练集,其余6个作为测试集。工况参数包括高度、速度、迎角,外形参数包括偏转角、飞行器机翼三维坐标,将工况参数和外形参数共七维数据作为特征,以机翼表面热流(一维)为预测目标构建代理模型。

本文数据集共8个维度,其中7个维度作为特征数据,分别为偏转角(σ)、高度(H)、速度(v)、迎角(α)以及机翼网格三维坐标(x, y, z),以物面网格点热流值(q)为预测目标,偏转角及工况参数参考值如表1所示。

数据集中所有数据按照统一热流值进行归一化处理(将数据值范围映射到一个较小的空间),以便

表 1 数据集参数参考值
Table 1 Parameters reference value in our dataset

序号	偏转角 $\sigma/(^{\circ})$	高度 H/km	速度 $v/(\text{m}\cdot\text{s}^{-1})$	迎角 $\alpha/(^{\circ})$
1	0	27.2	1820	-8.4
2	0	30.1	2980	15.0
3	0	53.1	2800	-10.0
4	0	29.4	2650	16.0
5	0	30.7	2200	8.4
6	0	26.8	1500	9.2
7	0	25.4	1250	11.7
8	10	27.2	1820	-8.4
9	10	30.1	2980	15.0
10	10	53.1	2800	-10.0
11	10	29.4	2650	16.0
12	10	30.7	2200	8.4
13	10	26.8	1500	9.2
14	10	25.4	1250	11.7
15	20	27.2	1820	-8.4
16	20	30.1	2980	15.0
17	20	53.1	2800	-10.0
18	20	29.4	2650	16.0
19	20	30.7	2200	8.4
20	20	26.8	1500	9.2
21	20	25.4	1250	11.7
22	30	27.2	1820	-8.4
23	30	30.1	2980	15.0
24	30	53.1	2800	-10.0
25	30	29.4	2650	16.0
26	30	30.7	2200	8.4
27	30	26.8	1500	9.2
28	30	25.4	1250	11.7
29	40	27.2	1820	-8.4
30	40	30.1	2980	15.0
31	40	53.1	2800	-10.0
32	40	29.4	2650	16.0
33	40	30.7	2200	8.4
34	40	26.8	1500	9.2
35	40	25.4	1250	11.7
36	44	27.2	1820	-8.4
37	44	30.1	2980	15.0
38	44	53.1	2800	-10.0
39	44	29.4	2650	16.0
40	44	30.7	2200	8.4
41	44	26.8	1500	9.2
42	44	25.4	1250	11.7

模型训练与加快模型收敛：

$$q' = \frac{q}{q_r}$$

(1)

其中： q' 表示归一化热流值， q 表示原始热流值， q_r 表示统一的热流值(266 kW/m²)。

2 模型原理

飞行器机翼伸缩变形结构物面气动热数据分布

差异大，不同工况的数据样本稀疏，使得气动热预测存在较大难度，考虑到无分类器引导的条件扩散模型具有较高的数据分布拟合能力，本文提出了 HMD 方法，本节将对相关模型原理进行介绍。

2.1 全连接神经网络

全连接神经网络 (fully connected neural network, FCNN) 是一种基础的人工神经网络结构。在 FCNN 中，每个神经元都与前一层和后一层的所有神经元相连接，形成一个密集的连接结构，能够学习数据的复杂特征并进行回归、分类等任务。FCNN 模型结构如图 3 所示，其包括一个输入层、一个输出层以及若干隐藏层，每层包含若干个网络节点，通过反向传播实现网络中节点权值更新。




图 3 全连接神经网络
Fig. 3 Fully connected neural network

反向传播神经网络 (back propagation neural network, BPNN) 是一种建立在梯度下降算法基础上的多层前馈神经网络，用输出层的神经元预测误差反向估计上一层隐藏层神经元的预测误差，继而逐层将误差从输出层反向传播到隐藏层，最后到输入层，从而实现对连接权值的调整。权重调整差值为：

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i}$$

(2)

式中：负号表示梯度下降， η 为学习率， E 为误差， w_i 为节点权重。使用链式法则可以求出误差对于每个神经元权重的偏导，由该公式得到新的权值，继续正向传播进行下一次权值调整，直到网络的输出误差小于既定值，或者训练次数达到预设的训练次数为止。

2.2 扩散模型

扩散模型可以分为前向扩散与逆向去噪两个推理方向。前向扩散是一个不断往原始数据中加入高斯噪声的过程，该过程使数据逐渐接近高斯分布，最终加噪成为高斯分布。逆向去噪过程从加噪成高斯分布的数据中不断去噪，使其逐渐还原为原始数据。模型通过训练可以学习加噪/去噪过程隐含的数据分

布特性。

2.2.1 前向扩散

前向扩散过程可以视为一个马尔科夫链,该过程采用重参数化技巧,常见于变分自编码器(variational auto-encoder, VAE)^[24]等生成式模型中。重参数化的关键在于此过程中的数学表示和梯度的计算。在正向过程中, y_t 的生成依赖于 y_{t-1} 和噪声 ε_t 。为了能够计算梯度并进行模型的训练,需要一种方法或函数(如公式(3)即为重参数化)来表述 y_{t-1} 以便能够将梯度从 y_t 传回 y_{t-1} 和模型参数。其中第 t 次加入噪声后的数据 y_t 可以由以下公式得到:

$$y_t = \sqrt{\alpha_t}y_{t-1} + \sqrt{1-\alpha_t}\varepsilon_t \quad (3)$$

其中: α_t 为超参数,用于控制扩散(加噪)的速率; ε_t 是一个高斯噪声。同时我们可以得到 y_t 的条件概率分布 $q(y_t|y_{t-1})$:

$$q(y_t|y_{t-1}) \sim N(\sqrt{\alpha_t}y_{t-1}, 1-\alpha_t) \quad (4)$$

因为高斯分布的和仍然是高斯分布,因此可以递推得到 y_t 关于 y_0 的公式与分布:

$$y_t = \sqrt{\bar{\alpha}_t}y_0 + \sqrt{1-\bar{\alpha}_t}\varepsilon_t \quad (5)$$

$$q(y_t|y_0) \sim N(\sqrt{\bar{\alpha}_t}y_0, 1-\bar{\alpha}_t) \quad (6)$$

其中: $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$, $\varepsilon_t \sim N(0, I)$ 。前向扩散过程中随着步数的增加,加入的噪声也更多,当迭代步数足够多时, y_t 的分布将无限接近于标准高斯分布。

2.2.2 逆向去噪

逆向去噪与前向扩散类似,每一步去除的噪声都可以近似为一个高斯噪声,使用神经网络预测该噪声的过程可以表示为:

$$p_\theta(y_{t-1}|y_t) \sim N(y_{t-1}; \mu_\theta(y_t, t), \sigma_\theta(y_t, t)) \quad (7)$$

其中: μ_θ 和 σ_θ 为高斯分布的均值与方差,由训练后的神经网络确定。另一方面,由贝叶斯公式可以推导出:

$$\begin{aligned} q(y_{t-1}|y_t, y_0) &= \frac{q(y_t|y_{t-1}, y_0)q(y_{t-1}|y_0)}{q(y_t|y_0)} \\ &\propto N\left(y_{t-1}; \frac{\sqrt{\alpha_t}(1-\bar{\alpha}_{t-1})y_t + \sqrt{\bar{\alpha}_{t-1}}(1-\alpha_t)y_0}{1-\bar{\alpha}_t}, \frac{(1-\alpha_t)(1-\bar{\alpha}_{t-1})}{1-\bar{\alpha}_t}I\right) \end{aligned} \quad (8)$$

综合公式(7)与公式(8),并代入公式(5)中 y_t 关于 y_0 的公式,可以得到均值:

$$\mu_\theta(y_t, t) = \frac{1}{\sqrt{\alpha_t}}y_t - \frac{1-\alpha_t}{\sqrt{1-\alpha_t}\sqrt{\alpha_t}}\varepsilon_\theta \quad (9)$$

其中方差只是与超参数 α_t 有关的定值。由于在某些

去噪步数中 y_t 与 y_{t-1} 的差别较小,直接学习 y_{t-1} 容易引起恒等映射导致模型学习失败,因此在 DDPM 中选择预测噪声 ε_θ 以提高预测精度。

扩散模型选取优化目标时,所取最大变分下界为:

$$\begin{aligned} E[-\ln p_\theta(y)] &\leq E_{q(y_1|y_0)}[\ln p_\theta(y_0|y_1)] + \\ &D_{KL}(q(y_T|y_0)||p(y_T)) + \\ &\sum_{t=2}^T E_{q(y_t|y_0)}[D_{KL}(q(y_{t-1}|y_t, y_0)||p_\theta(y_{t-1}|y_t))] \end{aligned} \quad (10)$$

由于同方差的高斯分布之间 KL 散度即为均值的均方误差,因此可以直接使用均方差(mean square error, MSE)作为噪声预测的损失函数。

2.2.3 条件扩散模型

条件扩散模型目前主要分为分类器引导和无分类器引导。由于扩散模型的迭代去噪可以看作是从随机噪声往数据分布的梯度方向前进,有分类器的条件扩散去噪梯度如式(11)所示:

$$\begin{aligned} \nabla \ln p(y_t|x) &= \nabla \ln \left(\frac{p(y_t)p(x|y_t)}{p(x)} \right) \\ &= \nabla \ln p(y_t) + \nabla \ln p(x|y_t) \end{aligned} \quad (11)$$

其中: y_t 是第 t 轮迭代后的预测值, x 是条件标签。 $\nabla \ln p(y_t)$ 是来自无条件扩散模型的梯度, $\nabla \ln p(x|y_t)$ 是来自分类器的梯度。分类器的梯度可以表示为如下形式:

$$\begin{aligned} \nabla_{y_t} \ln p(x|y_t) &= \nabla_{y_t} \ln p(y_t|x) - \nabla_{y_t} \ln p(y_t) \\ &= -\frac{1}{\sqrt{1-\bar{\alpha}_t}}[\varepsilon_\varphi(y_t, t, x) - \varepsilon_\varphi(y_t, t)] \end{aligned} \quad (12)$$

将公式(12)代入公式(11)可以得到:

$$\begin{aligned} \bar{\varepsilon}_\varphi(y_t, t, x) &= \varepsilon_\varphi(y_t, t, x) - \sqrt{1-\bar{\alpha}_t}\omega \nabla_{y_t} \ln p(x|y_t) \\ &= \varepsilon_\varphi(y_t, t, x) + \omega(\varepsilon_\varphi(y_t, t, x) - \varepsilon_\varphi(y_t, t)) \\ &= (\omega+1)\varepsilon_\varphi(y_t, t, x) - \omega\varepsilon_\varphi(y_t, t) \end{aligned} \quad (13)$$

公式(13)为无分类器引导的条件扩散模型的梯度,它将显式分类器转变为隐式分类器,在模型训练时就将条件信息引入其中,因此也被称为事前训练。其中 $\varepsilon_\varphi(y_t, t, x)$ 为条件扩散模型梯度, $\varepsilon_\varphi(y_t, t)$ 为无条件扩散模型梯度,基于此可以使用条件扩散模型生成 $p(y_t|x)$, 构建气动热回归预测模型预测真实值。

3 气动热预测模型

高速飞行器伸缩变形机翼物面气动热数据在不同工况、不同偏转角下数据分布差异较大,且单个样

本数据网格点数量就很大(19361个), 基于数据具有强非线性且单个样本数据量大等特点, 本文将机翼物面气动热预测建模为一个低维回归问题。一方面, 利用扩散模型较好的数据分布学习能力, 引入条件扩散模型建立气动热回归预测模型; 另一方面, 针对数据维度低的特点, 选择以全连接神经网络预测扩散模型每步添加的噪声。扩散模型导向图如图4所示。




图4 扩散模型导向图

Fig. 4 Diffusion model guided diagram

3.1 模型框架

在基于条件扩散的气动热预测模型中, 前向扩散过程采用重参数化技巧直接计算得到, 逆向去噪使用迭代的方式生成预测结果, 模型逆向去噪的总体框架图如图5所示。由于每一步的预测结果都依赖于前一步的预测结果, 总体框架图中训练与预测部分都是扩散模型过程其中的一步(每一步类似), 结合图4则可构成整个代理模型逆向去噪过程的框架。

其中模型预测部分: 模型的输入为第 t 步预测值 y_t 、时间步 t 以及七维条件参数 c , 其中条件参数包括偏转角(σ)、高度(H)、速度(v)、迎角(α)以及空间三维坐标(x, y, z), 初始的预测值(即逆向过程第一步)为随机噪声(图4中 y_T), 由于3个输入特征的维度不同, 因此需要经过全连接神经网络进行特征维度对齐。将对齐后的特征 C, T, Y_t 输入扩散模块(包含若干个)得到高维中间特征(高维噪声) Z , 再将 Z 高维噪声输入全连接神经网络进行降维得到预测噪声 ε_t , 然后经过扩散模型逆向去噪(由公式(9)计算得到)产生第 $t-1$ 步的预测值 y_{t-1} , 随后进行下一步迭代直到生成 y_0 , 即模型根据特征条件预测出机翼物面气动热。其中每个扩散模块均包含两个维度不变的全连接神经网络对特征进行非线性变换, 以增强模型的非线性拟合能力, 在两个神经网络中间对三个特征进行特征融合。

模型训练部分: 针对模型中的第 t 步, 以均方误差损失函数 L_{MSE} 作为目标优化函数, 不断降低第 t 步预测噪声 ε_t 与真实噪声 ε 的误差, 直至 L_{MSE} 收敛为止, 提高扩散模型逆向去噪的精度。

图中扩散模型包含两个相反的过程, 分别为前向扩散与逆向去噪, 前向扩散在原始的机翼物面气动热数据中不断加入噪声, 经若干步加噪后成为纯高斯噪声。逆向去噪从加噪成高斯分布的数据中不断去除所添加的噪声, 使之还原为原始气动热数据, 模型通过训练获得加噪/去噪过程中隐含的气动热数据分布特性。

3.2 基于全连接神经网络的噪声预测

由于物面网格点气动热根据位置坐标建模为低维预测问题, 本文设计了一个基于全连接神经网络的噪声预测模型, 其结构如图6所示。

为了适应伸缩变形机翼物面气动热这类低维且非线性强的样本数据, 设计扩散模块作为噪声预测模型的主体模块。将传入的对齐特征 C, T, Y_t 输入全连接神经网络中进行非线性特征变换, 然后经特征融合得到组合特征, 再经过非线性变换后输出中间特征 Z 。为了增强网络的非线性拟合能力, 扩散模块可以进行多次堆叠, 堆叠后的扩散模块接收前一模块输出的中间特征 Z 作为新的 Y_t , 同时继续将已有的 C, T 作为输入特征以加强模型对条件和时间步特征的捕获能力。每一个扩散模块都对3个特征做非线性变换, 以保证堆叠模块可以提高网络的非线性拟合能力。每一个扩散模块都保留 C, T 的原始特征, 可防止模型过于复杂而样本量较低产生过拟合现象。

由于扩散模块的输出是高维的中间特征(噪声), 为了预测一维的噪声, 因此需要使用全连接层将高维特征进行降维。

3.3 基于条件扩散的气动热代理模型训练方法

条件扩散模型与 DDPM 相似, 模型在训练时每轮迭代随机选取步长 t 进行加噪得到加噪后的数据 y_t , 由于高斯分布的和仍然为高斯分布, 所以加噪过程可以合并为一步, 将加噪后的气动热数据 y_t 、特征条件 C 与加噪步长 t 作为模型的输入得到预测噪声 ε_t , 训练该模型逼近真实噪声 ε , 算法流程如图7所示。经模型训练, 条件扩散模型能够模拟训练数据得




图 5 HMD 模型框架图

Fig. 5 Model framework diagram of heating-MLP diffusion

到高斯噪声的加噪/去噪过程,从而间接获得训练数据内在的分布特性。

损失函数用于指导模型训练,若噪声真实值(即图 7 中生成随机噪声)与预测值存在较大误差,模型会调整参数从而达到纠正预测值分布的效果。

根据模型原理,同方差的高斯分布之间 KL 散度即为均值的均方误差,因此可以直接使用 MSE 作为噪声预测的损失函数:

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (14)$$

其中: y_i 表示第 i 个样本的真实值, $\hat{y}_i$ 表示第 i 个样本的

预测值。

本文采取 SiLU 激活函数,其公式如下:

$$f(x) = \frac{x}{1 + e^{-x}} \quad (15)$$

SiLU 是 Sigmoid 和 ReLU 的改进版函数。具备无上界有下界、平滑、非单调等特性。SiLU 在深层模型上效果优于 ReLU, 可视为平滑的 ReLU 激活函数。SiLU 函数图像如图 8 所示。

4 结果及讨论

本文采用数值仿真构建数据集,验证 HMD 模型的有效性。首先给出基于条件扩散模型的训练损失




图 6 基于全连接神经网络的噪声预测结构图

Fig. 6 Noise prediction structure diagram based on fully connected neural network




图 7 条件扩散模型训练过程

Fig. 7 Conditional diffusion model training process




图 8 SiLU 函数

Fig. 8 SiLU function

收敛曲线以及气动热数据逆向去噪过程，验证模型正确收敛；其次通过与不同代理模型的对比实验证明所提方法的有效性；最后进行了扩散模块消融实验，验证所设计的扩散模块提高了气动热预测精度。为了

验证模型的泛化性能，不失一般性，测试集数据选择不同偏转角、不同工况参数的样本数据。测试集数据工况参数参考值如表 2 所示，数据集中其他数据作为训练集。

表 2 测试集参数参考值
Table 2 The reference value of the test set parameters

样本序号	偏转角 $\sigma/(^{\circ})$	高度 H/km	速度 $v/(\text{m}\cdot\text{s}^{-1})$	迎角 $\alpha/(^{\circ})$
1	0	30.7	2 200	8.4
2	10	53.1	2 800	-10
3	20	26.8	1 500	9.2
4	30	27.2	1 820	-8.4
5	40	30.1	2 980	15
6	44	29.4	2 650	16

4.1 模型设置

- 1) 高斯过程模型参数设置。高斯过程核函数为 RBF，核的长度尺度 1.5，其上下界为 $(1\times10^{-4}, 1\times10^4)$ 。
- 2) 神经过程模型参数设置。神经过程模型的结构参数设置如表 3、表 4 所示。其中输入为特征向量 7 维以及预测目标 1 维。中间表征向量 32 维，全局隐变量 32 维，上下文节点以及目标节点都设置为 100 个。该模型包括一个编码器和一个解码器。模型训练超参数设置为：批大小 1024，训练周期 1000，学习率 0.001。

表 3 神经过程模型编码器结构参数设置
Table 3 Parameters settings of encoder structure

层	网络	激活函数	输入维度	输出维度
1	Linear	Mish	7, 1	32
2	Linear	Mish	32	64
3	Linear	Mish	64	128
4	Linear	Mish	128	64
5	Linear	—	64	32

表 4 神经过程模型解码器结构参数设置
Table 4 Parameters settings of decoder structure

层	网络	激活函数	输入维度	输出维度
1	Linear	Mish	3, 32, 32	128
2	Linear	Mish	128	256
3	Linear	Mish	256	128
4	Linear	Mish	128	64
5	Linear	—	64	1

- 3) 全连接神经网络模型参数设置。神经网络模型的结构参数设置如表 5 所示。模型的输入向量为 7 维，输出向量为 1 维。模型训练超参数设置为：批大小 512，训练周期 1000，学习率 0.001。
- 4) 条件扩散模型参数设置。HMD 模型的结构参数设置如表 6 所示。输入向量包括初始预测值，即一

表 5 全连接神经网络模型结构参数设置

Table 5 Parameters settings of FCNN model structure

层	网络	激活函数	输入维度	输出维度
1	Linear	SiLU	7	64
2	Linear	SiLU	64	128
3	Linear	SiLU	128	256
4	Linear	SiLU	256	512
5	Linear	SiLU	512	128
6	Linear	SiLU	128	64
7	Linear	—	64	1

表 6 HMD 模型结构参数设置

Table 6 Parameters settings of HMD model structure

层	网络	激活函数	输入维度	输出维度
对齐层	Linear	SiLU	7, 64, 1	512
DB1	Linear	SiLU	512	512
DB2	Linear	SiLU	512	512
DB3	Linear	SiLU	512	512
降维层	Linear	SiLU	512	256
降维层	Linear	SiLU	256	64
降维层	Linear	—	64	1

维随机噪声, 时间步 t 经过 time embedding 映射成 64 维向量, 以及 7 维特征条件参数。经过特征对齐层将三个输入向量统一为 512 维, 随后经过 3 个堆叠的 512 维扩散模块进行非线性变换, 其中扩散模块维度不变, 分为三部分: 线性变换层(2 层)、特征组合层(1 层)、线性变换层(2 层), 最后经过特征降维输出一维预测值。模型训练超参数设置为: 批大小为 512, 训练周期为 5000, 学习率为 0.00001。

4.2 评估标准

本文使用决定系数 R^2 、平均绝对误差(mean absolute error, MAE)以及平均绝对百分比误差(mean absolute percentage error, MAPE)作为模型的评估标准。

R^2 系数是一种用于评估回归模型拟合程度的指标, 它表示模型能够解释数据方差的比例, 反映预测结果与真实值的相关性:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

其中: y_i 表示第 i 个样本的真实值, $\hat{y}_i$ 表示第 i 个样本的预测值, $\bar{y}$ 表示所有样本真实值的平均值, R^2 越接近 1 代表模型拟合程度越高。

MAE 用于衡量模型预测的平均误差, 在预测新数据时可用 MAE 评估预测的期望偏差, 反映预测结

果的绝对误差:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (17)$$

MAPE 用于衡量预测的平均百分比误差, 该指标可以消除数据归一化的影响, 反映预测结果的绝对值百分比误差:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (18)$$

由于使用的数据经过归一化处理, MAPE 更能反映真实的物面气动热值的预测精度, 而其他两个评价指标可用于模型评估的参考。

4.3 实验结果

4.3.1 模型收敛验证

首先验证所提出的气动热预测模型正确收敛, 能有效应用于低维机翼物面气动热预测问题。模型训练阶段损失函数的收敛曲线如图 9 所示, 从图中可知, 训练损失随着训练周期的推进, 在一定训练误差范围内趋于稳定, 即前向扩散添加噪声与噪声预测模块预测噪声的误差趋于稳定, 模型收敛到最优解。




图 9 条件扩散模型训练损失函数收敛曲线

Fig. 9 Convergence curve of the training loss function for the conditional diffusion model

随机选取测试集中样本验证模型逆向去噪过程, 如图 10 所示。其中 1 号样本对应的七维条件参数为: 偏转角 0° 、高度 30.7 km、速度 2200 m/s、迎角 8.4° 以及三维空间坐标; 4 号样本对应的七维条件参数为: 偏转角 30° 、高度 27.2 km、速度 1820 m/s、迎角 -8.4° 以及三维空间坐标。

图中第一步($t = 1000$)为高斯噪声采样, 此后逐步利用训练的去噪模块预测加噪过程中所增加的噪声, 并逐步去除该噪声, 当最后一步($t = 0$)所有噪声均去除时, 得到物面网格点气动热数据。从图中可以看到, 随着去噪时间步的推进, 样本数据均从高斯噪

声逐步去噪并在一定精度范围内预测出气动热数据，因为模型经训练后，能够学习到来流条件、外形条件与相应物面网格点气动热数据之间的映射关系，该关系反映在不同的条件与不同时间步下对应的去噪过程。

实验结果表明，该方法可在一定精度范围内实现不同条件、不同时间步噪声的预测，即模型能够学习到条件与气动热之间的映射关系，证明该模型能够应用于物面网格点气动热预测。




图 10 随机选择样本在不同步骤的去噪结果

Fig. 10 Denoising results of the randomly selected samples at different steps

4.3.2 模型精度验证

为了验证基于条件扩散气动热预测代理模型能够准确地预测气动热，我们将其与其他 3 种代理模型进行对比，这 3 种分别为高斯过程(Gaussian process, GP)、神经过程(neural process, NP)^[25]和神经网络，其中后续实验结果中 HMD 与扩散模型同义。在所有测

试数据上不同模型预测散点图如图 11 所示，图中横坐标表示真实值(CFD 数据)，纵坐标表示模型预测值，数据点越靠近对角线则表示预测越准确。由该图可见，本文所提方法获得的散点图中大部分数据集中于对角线附近，而其他 3 种对比方法数据点分布更为分散，显示了较大气动热预测误差。




图 11 不同模型预测散点图对比

Fig. 11 Comparison of scatter plots predicted by different models

测试集数据在不同模型下的预测评价指标如表 7 所示。由于数据经过归一化处理，而 R^2 系数与 MAE 会因此无法真实反映未经归一化的数据预测结果，因此将这两个指标作为参考，MAPE 指标作为百分比误差，无论数据有未归一化，该评价指标的值都一致。测试集数据各样本在不同模型下的 MAPE 如表 8 所示。

由表 7 与表 8 的结果可知，基于条件扩散模型的气动热预测代理模型相比高斯过程、神经过程和神经网络，在 3 个评价指标下均能取得更为准确的预测结果。在 MAPE 指标下，基于条件扩散模型的预测方法与基于深度学习的预测方法相比，从 0.13332 提升至 0.10175。

表 7 测试集在不同模型下评价指标结果

Table 7 The results of the evaluation index of the test set under different models

模型	R^2	MAE	MAPE
高斯过程	0.941 31	0.019 37	0.156 51
神经过程	0.971 32	0.017 13	0.143 93
神经网络	0.969 71	0.016 86	0.133 32
扩散模型	0.987 56	0.014 90	0.101 75

表 8 测试集各样本在不同模型下的 MAPE 值

Table 8 The MAPE values of each sample in the test set under different models

样本序号	高斯过程	神经过程	神经网络	扩散模型
1	0.152 10	0.135 36	0.142 76	0.108 77
2	0.121 14	0.171 91	0.142 21	0.095 97
3	0.201 75	0.113 81	0.104 04	0.111 36
4	0.133 79	0.142 35	0.110 27	0.072 28
5	0.150 90	0.135 10	0.140 75	0.115 94
6	0.179 39	0.165 07	0.159 89	0.106 20
总计	0.156 51	0.143 93	0.133 32	0.101 75

高斯过程是使用高斯过程先验对数据进行回归分析的非参数化模型,它根据先验和观测值推断出后验。神经过程是一种能够将输入映射到输出的回归函数模型,其直接建模函数分布而不是单一函数,能够根据少量的上下文观测数据预测目标函数的分布。但伸缩变形结构气动热数据样本稀疏、分布差异大,这两种模型难以根据先验信息推断出准确后验。全连接神经网络依据反向传播梯度下降的方法更新

网络中节点的权值,获得一个单一的非线性模型,而不同工况、不同偏转角下数据分布差异较大,单一的非线性函数仍然不足以拟合特征条件与物面网格点气动热之间的映射关系。而扩散模型通过学习不同特征条件下相应气动热数据加噪/去噪过程,可分步拟合不同特征条件与相应物面网格点气动热之间的映射关系,因而能取得更为准确的预测效果。

测试集数据 4 号样本数据对应的气动热数据预测如图 12 所示。该样本数据的百分比误差如图 13 所示。百分比误差针对样本数据中每个网格点的气动热数据而言,即预测数据和真实数据(CFD 数据)之差与真实数据之比。图中颜色条上限设置为 0.3 (30%)、下限设置为-0.3(-30%)。由图 13 可见,扩散模型获得了整体最低的百分比误差,而其他对比方法在各个样本的局部区域都存在较大预测误差。这些对比结果表明本文方法在气动热预测中能够获得更为准确的结果。

4.3.3 扩散模块消融实验

为了验证扩散模块提高了 HMD 模型对气动热预测的精度,本文设计扩散模块消融实验,将引入扩散模块的气动热代理模型与未引入扩散模块的气动热代理模型进行对比,消融实验中不同模型训练损失函数收敛过程如图 14 所示。从图 14 中可知,引入扩散模块的代理模型训练损失收敛速度快于未引入扩散模块的代理模型,且收敛后的损失低于后者,即噪




图 12 不同模型预测云图对比
Fig. 12 Comparison of prediction maps of different models




图 13 不同模型预测百分比误差云图

Fig. 13 Prediction percentage error contour plots for different models





图 14 消融实验中不同模型的训练损失变化

Fig. 14 Changes in training loss for different models in ablation experiments

声预测比后者更为准确。

气动热预测散点图对比如图 15 所示。测试集数据在不同模型下的预测评价指标如表 9 所示。结合图 15 以及表 6 的结果可知，引入扩散模块模型在 3 种评价指标下，能取得更为准确的气动热预测结果。

不同模型在不同训练周期(轮数)下测试集数据预测结果(MAPE)如图 16 所示。图中横坐标表示不同训练周期得到的模型，纵坐标表示在该模型下预测



(b) 引入扩散模块模型散点图


图 15 消融实验散点图对比

Fig. 15 Comparison of scatter plots of ablation experiments

表 9 测试集评价指标结果

Table 9 The results of the evaluation index of the test set

模型	R^2	MAE	MAPE
未引入扩散模块	0.98203	0.01554	0.11816
引入扩散模块	0.98756	0.01490	0.10175



(a) 未引入扩散模块模型散点图




图 16 不同训练周期的模型预测结果 MAPE 值

Fig. 16 The MAPE value of the model prediction results for different training periods

结果 MAPE 值。可见在不同训练周期下,引入扩散模块的模型均能取得更低的预测误差。这是因为引入扩散模块能够更好地捕获时间步与条件特征,提升噪声预测模块对噪声预测的准确度。

综上所述,引入扩散模块可以在训练阶段提高模型收敛速度、在测试阶段提高模型预测精度。

5 结 论

本文针对样本稀疏、数据分布差异较大的伸缩变形结构飞行器机翼物面网格点气动热数据构建气动热回归预测模型 HMD,在条件扩散模型中引入全连接神经网络预测前向扩散过程中添加的每步噪声,通过加噪/去噪过程学习数据隐含的分布特性。本文采用数值仿真数据对所提模型有效性进行验证,通过模型收敛验证、模型精度验证以及扩散模块消融实验等,主要得到以下结论:

1) 基于条件扩散方法建模气动热回归预测模型,利用全连接神经网络预测添加的噪声,可以通过前向扩散与逆向去噪过程学习到气动热数据隐含的分布特性,在一定精度范围内预测出不同条件下伸缩变形结构机翼物面网格点气动热数据。

2) HMD 相对高斯过程、神经过程、神经网络等方法,具有更高的非线性拟合能力,对于样本稀疏、分布差异较大的气动热数据预测更为准确。

3) 扩散模块能够有效地捕获时间步与特征条件信息,提升噪声预测的精度,使得引入扩散模块的条件扩散模型预测气动热的准确性高于未引入扩散模块的模型。

本文为变形结构物面气动热预测提供了一种新的构建代理模型思路,即以条件扩散模型与全连接神经网络相结合建立气动热预测代理模型。然而本文实验中数据样本较少,难以保证模型的泛化能力,并且较少的训练样本导致未能分析何种输入特征对于气动热预测目标敏感度更高。因此,获得更为有效的输入特征与构建高质量的数据样本以保证模型的泛化性是需要进一步改善的工作。

参 考 文 献:

- [1] 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).
- [2] 罗长童,胡宗民,刘云峰,等.高超声速风洞气动/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).
doi: 10.11729/syltx20200006
- [3] 喻成璋,刘卫华.高超声速飞行器气动热预测技术研究进展[J].航空科学技术,2021,32(2):14-21.
YU C Z, LIU W H. Research status of aeroheating prediction technology for hypersonic aircraft[J]. Aeronautical Science & Technology, 2021, 32(2): 14-21 (in Chinese).
- [4] 阎超,禹建军,李君哲.热流 CFD 计算中格式和网格效应若干问题研究[J].空气动力学学报,2006,24(1):125-130.
YAN C, YU J J, LI J Z. Scheme effect and grid dependency in CFD computations of heat transfer[J]. Acta Aerodynamica Sinica, 2006, 24(1): 125-130 (in Chinese).
doi: 10.3969/j.issn.0258-1825.2006.01.023
- [5] ZHAO R, WEN C Y, TIAN X D, et al. Numerical simulation of local wall heating and cooling effect on the stability of a hypersonic boundary layer[J]. International Journal of Heat and Mass Transfer, 2018, 121: 986-998.
doi: 10.1016/j.ijheatmasstransfer.2018.01.054
- [6] LEE J H, RHO O. Accuracy of AUSM+ scheme in hypersonic blunt body flow calculations[R]. AIAA Aerospace Research Central, 1998.
doi: 10.2514/6.1998-1538
- [7] KLOPFER G, YEE H. Viscous hypersonic shock-on-shock interaction on blunt cowl lips[C]//26th Aerospace Sciences Meeting, Reno, NV, USA. AIAA, 1988: AIAA 1988-233.
doi: 10.2514/6.1988-233
- [8] 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).
- [9] 陶阳,宗群,曾凡林.高超声速飞行器气动热模型数据拟合方法研究[C]//第三十一届中国控制会议论文集.北京:中国自动化学会控制理论专业委员会,2012:1275-1278.
TAO Y, ZONG Q, ZENG F L. Research on data fitting method of aerodynamic model of hypersonic vehicle[C]//Proceedings of the 31st Chinese Control Conference. Beijing: Technical Committee on Control Theory, Chinese Association of Automation, 2012: 1275-1278 (in Chinese).
- [10] DOWELL E H. Eigenmode analysis in unsteady aerodynamics - reduced-order models[J]. AIAA Journal, 1996, 34(8): 1578-1583.
doi: 10.2514/3.13274
- [11] SILVA W A. Identification of linear and nonlinear aerodynamic impulse responses using digital filter techniques[C]//22nd Atmospheric Flight Mechanics Conference, New Orleans, LA, USA. AIAA, 1997: AIAA 1997-3712.
doi: 10.2514/6.1997-3712
- [12] SIMPSON T W, KORTE J J, MAUERY T M, et al. Kriging models for global approximation in simulation-based multidisciplinary design optimization[J]. AIAA Journal, 2001, 39(12): 2233-2241.
doi: 10.2514/2.1234
- [13] 聂春生,黄建栋,王迅,等.基于 POD 方法的复杂外形飞行器热环境快速预测方法[J].空气动力学学报,2017,35(6):760-765.
NIE C S, HUANG J D, WANG X, et al. Fast aeroheating prediction method for complex shape vehicles based on proper orthogonal decomposition[J]. Acta Aerodynamica Sinica, 2017, 35(6): 760-765 (in Chinese).
- [14] 杨帆,林明月,胡宗民,等.基于机器学习的高超声速飞行器双曲率前

- 缘气动热预测方法[J]. 北京航空航天大学学报, 2024, 50(9): 2826–2834.
- YANG F, LIN M Y, HU Z M, et al. Prediction method of aero-heating of hypersonic vehicle bi-curvature leading edge based on machine learning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(9): 2826–2834 (in Chinese). doi: [10.13700/j.bh.1001-5965.2022.0746](https://doi.org/10.13700/j.bh.1001-5965.2022.0746)
- [15] 寇家庆, 张伟伟. 基函数宽度对递归 RBF 神经网络气动热模型精度的影响研究[J]. 航空工程进展, 2015, 6(3): 261–270.
- KOU J Q, ZHANG W W. Research on the effects of basis function widths of aerodynamic modeling based on recursive RBF neural network[J]. Advances in Aeronautical Science and Engineering, 2015, 6(3): 261–270 (in Chinese). doi: [10.3969/j.issn.1674-8190.2015.03.001](https://doi.org/10.3969/j.issn.1674-8190.2015.03.001)
- [16] 张智超, 高太元, 张磊, 等. 基于径向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 network[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 524167 (in Chinese).
- [17] 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). doi: [10.7638/kqdlxxb-2023.0072](https://doi.org/10.7638/kqdlxxb-2023.0072)
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84–90. doi: [10.1145/3065386](https://doi.org/10.1145/3065386)
- [19] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[EB/OL]. (2015-05-18)[2024-08-18]. <https://arxiv.org/abs/1505.04597v1>
- [20] SOHL-DICKSTEIN J, WEISS E A, MAHESWARANATHAN N, et al. Deep unsupervised learning using nonequilibrium thermodynamics[C]// Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37, Lille, France. ACM, 2015: 2256–2265. doi: [10.5555/3045118.3045358](https://doi.org/10.5555/3045118.3045358)
- [21] HO J, JAIN A, ABBEEL P, et al. Denoising diffusion probabilistic models[C]// 34th International Conference on Neural Information Processing Systems, Vancouver, BC, Canada. ACM, 2020: 6840–6851. doi: [10.5555/3495724.3496298](https://doi.org/10.5555/3495724.3496298)
- [22] DHARIWAL P, NICHOL A, DHARIWAL P, et al. Diffusion models beat GANs on image synthesis[C]// 35th International Conference on Neural Information Processing Systems, ACM, 2021: 8780–8794. doi: [10.5555/3540261.3540933](https://doi.org/10.5555/3540261.3540933)
- [23] HO J, SALIMANS T. Classifier-free diffusion guidance[EB/OL]. (2022-07-26)[2024-11-08]. <https://doi.org/10.48550/arXiv.2207.12598>
- [24] KINGMA D P, WELING M. Auto-encoding variational bayes[EB/OL]. (2013-12-20)[2024-08-23]. <https://doi.org/10.48550/arXiv.1312.6114>
- [25] GARNELO M, SCHWARZ J, ROSENBAUM D, et al. Neural processes[EB/OL]. (2018-07-04)[2024-07-04]. <https://doi.org/10.48550/arXiv.1807.01622>
- (本文责编: 徐燕)