

高超声速进气道内收缩基准流场的残差网络智能预测方法

杨孔强,熊冰*,范晓樯,王翼,唐啸
(国防科技大学 先进推进技术实验室,湖南长沙 410073)

摘要:为了提高内转式进气道的设计效率,实现对内收缩基准流场的快速预测,采用准均匀B样条方法实现内收缩基准流场的参数化设计,提出了基于深度学习残差神经网络架构的流场预测模型。结合峰值信噪比、结构相似性指数等图像质量评估方法,对预测流场进行定量评价,并从中提取壁面特性分布、激波形态等关键流场特性,以实现基于基准流场几何参数快速获取流场云图和特性参数分布的目标。研究结果表明,所构建的流场快速预测模型精度较高,其整体平均峰值信噪比为42.51 dB,平均结构相似性指数为0.997 3,且能有效地从预测结果中提取流场的关键特性与参数分布,为内收缩基准流场的快速设计与优化提供有力支持。

关键词:高超声速;内收缩;基准流场;参数方法;流场预测;残差神经网络
中图分类号:V228.7 **文献标志码:**A **文章编号:**1001-2486(2026)01-028-12

Residual network intelligent prediction method for hypersonic inlet internal contraction basic flowfield

YANG Kongqiang, XIONG Bing*, FAN Xiaoqiang, WANG Yi, TANG Xiao
(Advanced Propulsion Technology Laboratory, National University of Defense Technology, Changsha 410073, China)

Abstract: To enhance the design efficiency of inward-turning inlet and enable rapid prediction of internal contraction basic flowfield, a parametric design of internal contraction basic flowfield was implemented using quasi-uniform B-spline methods, and a flow field prediction model based on deep learning residual neural network architecture was proposed. The predicted flowfields were quantitatively evaluated using image quality assessment methods including PSNR (peak signal-to-noise ratio) and SSIM (structural similarity index), from which key flow field characteristics such as wall property distributions and shock wave shape were extracted to achieve the goal of rapidly obtaining flow field contours and characteristic parameter distributions based on basic flowfield geometric parameters. Research result shows that the constructed flow field rapid prediction model is characterized by high accuracy, with an overall average PSNR of 42.51 dB and an average SSIM of 0.997 3. Key characteristics and parameter distributions are effectively extracted from the prediction results, providing strong support for the rapid design and optimization of the internal contraction basic flowfield.

Keywords: hypersonic; internal compression; basic flowfield; parametric approach; flow field prediction; residual neural network

高超声速进气道是高超声速飞行器推进系统中的关键供气部件^[1-2],其主要功能是捕获足量空气并对其进行高效压缩,为燃烧室提供特定流量、压比、温度和速度的气流,从而使发动机能够产生足够推力以实现高超声速飞行^[3-4]。其中,内转式进气道因其较高的总压恢复系数相比传统进气道更具优势,成为进气道研究中的热点^[5]。

高超声速三维内转进气道设计及性能优化的研究主要围绕着激波求解析理论、基本流场构建及内转进气道设计3个方向展开^[6]。目前研究表明,基于流线追踪内转式进气道的性能受基准流场的直接影响,通过优化基准流场性能可以有效提升进气道性能,因此基准流场的设计至关重要。李永洲等^[7]基于壁面马赫数分布规律的轴对称基准流场设计了方转圆高超声速内收缩进气道,并采用弥散反射激波中心体削弱了中心体反射激

波的强度,从而提升出口总压恢复系数。Xiong 等^[8]采用参数化设计方法,在对基准流场性能指标进行约束的前提下,深入分析几何参数与流场性能之间的关系,并进一步优化几何参数生成最优性能的基准流场。

随着机器学习算法的快速发展,其在处理复杂系统和高维非线性问题方面展现出了显著优势,已经在航空航天领域中得到广泛的应用。

一方面,深度学习^[9]能够实现流场的高精度重构。Kong 等^[10]基于流场壁面压力数据和纹影对应关系,构建了卷积神经网络模型,实现流场结构与激波串前缘位置的高精度预测。Guo 等^[11]提出了一种结合物理信息的金字塔池卷积神经网络模型,针对基准流场的流场分布预测性能达到较高水平,平均峰值信噪比为 36.427 dB,相关系数超过 97%。关开港等^[12]研究了高超声速乘波前体-进气道三维构型,构建了本征正交分解和反向传播神经网络的流场快速预测模型,在高马赫数和不同攻角条件下表现出较高的预测精度,但在激波串区域预测中仍存在误差。突建苗等^[13]建立基于 U-Net 架构的深度卷积神经网络实现跨声速流场的快速预测,并将流场预测误差控制在较小范围。胡伟杰^[14]选取某型号导弹模型作为研究对象,在 CFD 生成的模拟数据上采用深度学习代理模型,提出一套快速且精确的导弹气动性能和流场预测方案。李鑫等^[15]提出了一种基于卷积神经网络和残差连接的 U 型架构降阶模型,实现了三维非定常流场快速重构的预期目标。曹晓峰等^[16]基于 U-Net 神经网络模型通过模拟 RANS 方程对速度、压力和密度分布进行预测,预测结果流场趋势与真实流场趋势整体相同。吴跃腾等^[17]采用融合了注意力机制的对称卷积神经网络对静叶不同半径处静温、静压以及马赫数等流场参数进行重构,模型对叶型流场参数预测的平均相对误差不超过 1%,实现了对压气机静叶流场的快速、准确重构。

另一方面,深度学习还能够为飞行器设计提供优化指导。代春良等^[18]基于内转进气道的基准流场参数化灵敏度分析,结合神经网络近似模型与多目标遗传算法,实现了轴对称基准流场的多目标优化设计。何磊等^[19]提出了一种基于深度学习的翼型反设计方法对翼型曲面与压力分布图像特征进行拟合,实现了翼型曲线的高精度重构,大幅提升设计效率并保证了设计结果的精度和鲁棒性。柳家齐等^[20]建立了一种基于深度学习的翼型多目标气动优化框架,结果表明优化翼

型可以显著地提升高速直升机旋翼的气动性能。

基于物理和设计相关理念,使用深度学习方法准确预测轴对称基准流场特性参数分布对内收缩进气道设计至关重要。结合深度学习领域的残差连接网络构架,提出了一种针对二维内收缩基准流场具有快速预测能力的神经网络模型,以构建高超声速进气道基准流场的预测框架,旨在快速准确地获得其内部流场的结构与特性分布,为高超声速进气道的性能优化奠定基础。

1 基准流场参数化设计及数值方法

1.1 基准流场参数化方法

基准流场由压缩面型线与中心体组成。本文基于 Xiong 等^[8]提出的基准流场模型,替换等直中心体,针对压缩面进行参数化实现基准流场几何型面生成。基准流场参数化如图 1 所示,轴对称轴线表示为 x 。压缩面型线 CH ,包括 CE 、 EH 两段压缩面型线,其中 E 为预设分界点,位于预设唇口位置 D 的正上方。底部为中心体型线,在本研究中,中心体保持水平,即由一条等半径的直线 BI 组成。

图 1 展示了压缩面型线 CE 、 EH 的参数化方法,由两条准均匀 B 样条曲线表示,其中 C 、 E 、 H 为固定控制点, E 为两段准均匀 B 样条共用控制点,并包含 4 个柔性控制点 $F_1 \sim F_4$,其中 F_2 、 E 、 F_3 三点保持共线以控制曲线在 E 点的斜率。固定界面与控制点分别采用实线、黑色实心点表示,柔性界面与控制点分别采用虚线、绿色实心点表示。




图 1 基准流场参数化示意图

Fig. 1 Basic flowfield parameterized schematics

准均匀 B 样条^[21]用式(1)表示。

$$C(t) = \sum_{i=0}^n N_{i,k}(t) \cdot P_i \tag{1}$$

式中: $C(t)$ 为样条曲线; P_i 为控制点; $N_{i,k}(t)$ 为第 i 个基函数的值,阶数为 k ; t 为曲线参数,定义域在节点矢量范围之内; n 等于控制点数量减 1。

基函数 $N_{i,k}(t)$ 通过递归方式定义,如式(2)、式(3)所示。

1) 零阶基函数($k=1$):

$$N_{i,1}(t) = \begin{cases} 1 & t_i \leq t < t_{i+1} \\ 0 & \text{其他} \end{cases} \quad (2)$$

2) 高阶基函数($k > 1$):

$$\begin{cases} N_{i,k}(t) = f_1(t)N_{i,k-1}(t) + f_2(t)N_{i+1,k-1}(t) \\ f_1(t) = \frac{t - t_i}{t_{i+k-1} - t_i} \\ f_2(t) = \frac{t_{i+k} - t}{t_{i+k} - t_{i+1}} \end{cases} \quad (3)$$

其中: t_i 表示节点矢量中的第 i 个节点;分母中的数值若为 0,则对应项取值为 0。

基准流场入口半径 R_i 设置为单位 1,其余长度由 R_i 进行归一化。基准流场总长度为 L_i ,中心体半径为 r_i 。设计基准流场所涉及几何参数变量以七维向量进行表述,如式(4)所示。

$$\mathbf{X} = (\theta_1, \theta_2, \theta_3, x_{F1}, x_{F2}, x_{F3}, x_{F4})^T \quad (4)$$

其中: $x_{F1}, x_{F2}, x_{F3}, x_{F4}$ 均为柔性控制点坐标,用以调控准均匀 B 样条的具体形态。 θ_1 为初始压缩角,对前体激波的压缩角具有较大的影响。 θ_1 取值较大时,前体激波角较大,容易出现多道激波反射的情况,大幅度削弱基准流场的总压恢复系数。其计算如式(5)所示。

$$\tan\theta_1 = \frac{r_C - r_{F1}}{x_{F1} - x_C} \quad (5)$$

θ_2 为下洗角,即 CE 曲线在 E 点处切线与流向的夹角。若 θ_2 取值不合理,压缩面型线中段将发生一定程度的畸变,此时在压缩段末端产生一道斜激波,进一步削弱总压恢复系数,并对局部流场产生较大的影响。其计算如式(6)所示。

$$\tan\theta_2 = \frac{r_E - r_{F3}}{x_{F3} - x_E} = \frac{r_{F2} - r_E}{x_E - x_{F2}} \quad (6)$$

θ_3 为出口方向角,即 EH 曲线在 H 点处切线与流向的夹角,定义顺时针方向为正方向,计算如式(7)所示。

$$\tan\theta_3 = \frac{r_{F4} - r_H}{x_H - x_{F4}} \quad (7)$$

定义总收缩比为入口截面面积与出口截面面积之比,即:

$$R_{1,\text{basic}} = \frac{r_C^2 - r_B^2}{(r_H^2 - r_I^2) \cos\theta_3} \quad (8)$$

定义内收缩比为唇口截面面积与出口截面面积之比,即:

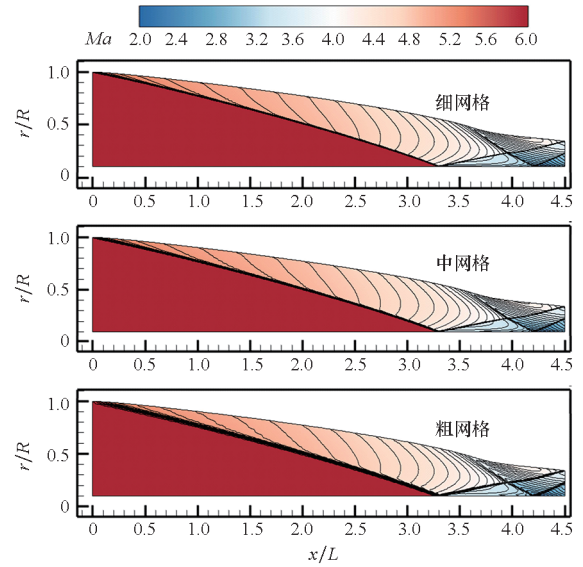
$$R_{\text{in,basic}} = \frac{r_E^2 - r_D^2}{(r_H^2 - r_I^2) \cos\theta_3} \quad (9)$$

1.2 网格无关性验证

基于 CFD 方法获得基准流场的解。采用基


于密度的有限体积法(finite volume method, FVM)进行数值求解,无黏性通量类型采用 Roe 通量差格式(Roe-FDS),空间离散采用二阶迎风格式,梯度设置为最小二乘网格。基准流场入口设置为压力-远场边界条件,出口设置为压力-出口边界条件,来流为理想气体。

为了进一步评估 CFD 方法的准确性,对网格无关性进行校验。基于 1.1 节所介绍的参数化方法生成用于参考的流场几何边界,并比较了三种不同网格尺度对 CFD 结果的影响,具体包括粗网格(155×30)、中网格(310×60)和细网格(930×180)。图 2 分别展示了基准流场的细网格、中网格和粗网格的马赫数云图与马赫数分布。在马赫



(a) 不同网格密度的马赫数云图

(a) Mach number cloud charts with different grid densities



(b) 不同网格密度的马赫数分布

(b) Mach number distribution with different grid densities

图 2 网格无关性检验

Fig. 2 Grid independence test

数等值线分布情况上,粗网格相对其余两种网格的差异较为明显,细网格和中网格相似性较高。在前体激波的精细化程度上,粗网格对比细网格与中网格略微粗糙。从中心体边界的马赫数分布来看,中网格与细网格的马赫数分布重合度较高,而粗网格的马赫数分布在前体激波间断处存在一定的差异。

网格比例对流场解算存在一定影响,但较为轻微。为了保证生成样本的精度与效率,综合考虑选用中网格对基准流场进行 CFD 计算,以获取流场数据样本。

1.3 样本生成

在上述基准流场参数化设计与数值方法验证之后,选定合适的设计点参数进行样本的生成。本文选定的进气道设计点参数与来流条件如表 1 所示。表 1 中, Ma_i 为来流马赫数, L_c 为预设唇口的相对位置。

表 1 基准流场设计点参数及来流条件

Tab.1 Design point parameters and incoming flow conditions for basic flowfield

Ma_i	L_i/R_i	L_c/R_i	r_i/R_i	$R_{t,basic}$	$R_{in,basic}$
6.0	4.50	3.60	0.1	9.40	2.05

由于压缩面型线对基准流场特性参数分布影响较大,对参数化方法的几何参数的取值范围进行限制,防止出现不符合设计需求的样本。表 2 展示了参数化方法中的几何设计参数。根据所设定的进气道几何参数范围,采用拉丁超立方体采样,并进行数值模拟,共计获得进气道基准流场样本 500 组。

表 2 基准流场几何设计参数

Tab.2 Geometric design parameters of basic flowfield

参数符号	物理含义	取值范围
θ_1	初始压缩角	$0 \sim 10^\circ$
θ_2	下洗角	$3^\circ \sim 8^\circ$
θ_3	出口方向角	$0 \sim 3^\circ$
x_{F1}		$0.5 \sim 1.5$
x_{F2}	准均匀 B 样条曲线	$2.5 \sim 3.5$
x_{F3}	柔性控制点坐标	$3.5 \sim 4.0$
x_{F4}		$4.0 \sim 4.5$

基于 ISIGHT 软件搭建样本生成流程,实现型面生成、网格划分、CFD 仿真计算以及仿真后处

理等关键环节集成的一体化设计流程。

本文所涉及的几何参数与流场特性数据包含多个维度,其单位、量纲和数量级均存在显著差异,易导致训练过程中的梯度更新不平衡,较大尺度的变量会主导损失函数的优化,掩盖较小尺度变量的贡献,从而降低模型的学习能力。因此引入 Z-Score 标准化,将各个维度数据转换为均值为 0、标准差为 1 的分布,公式为:

$$X' = \frac{X - \mu}{\sigma}$$

(10)

式中, X 为原始数据, μ 为变量均值, σ 为变量标准差。

2 ResNet 网络模型及评估方法

2.1 残差神经网络基本结构

全连接层是深度学习框架的基本组件,主要用于对输入特征进行线性变换,从而将输入映射到新的特征空间。公式如式(11)所示。

$$y = W \cdot x + b$$

(11)

式中: x 为输入向量,包含 n 个特征; W 为权重矩阵,包含输入到输出的连接权重; b 为偏置向量,用于调整输出值与真实值的偏差; y 为输出向量,包含 m 个输出向量。

图 3 所示为全连接神经网络的基本结构,包含输入层、隐藏层与输出层。隐藏层作为神经网络的核心组成部分,通过引入权重参数与非线性激活函数,如修正线性单元 (rectified linear unit, ReLU),实现对输入特征的高维映射与非线性转换,从而增强模型对复杂模式的表达能力,处理输入层信号并传递到输出层,帮助网络拟合复杂非线性关系。




图 3 全连接神经网络

Fig.3 Fully connected neural network

ReLU 是神经网络训练过程中一种常见的激活函数,其数学表达式为:

$$R(x) = \max(0, x)$$

(12)

通过针对输入参数的指定性激活,使网络结

构具有一定的非线性能力。

卷积层能从输入中提取局部特征,通过卷积核在输入数据上滑动,捕捉局部区域的模式,其公式为:

$$O(i,j) = \sum_m \sum_n J(i+m, j+n) \cdot K(m,n) \quad (13)$$

式中: $J(i,j)$ 为输入特征图在位置 (i,j) 处的取值, $K(m,n)$ 为卷积核的权重, m,n 分别表示卷积核行、列的索引值; $O(i,j)$ 为输出特征图在位置 (i,j) 处的取值。

残差连接是神经网络中的一种运用技巧。由于深层网络容易出现梯度消失或梯度爆炸的问题,通过残差连接的方式,将网络的深度扩展到数十层以上,从而提高模型的性能。残差连接将输入的信号直接连接到输出,从而在网络中引入“跨层连接”。残差连接如图 4 所示,输入信号不仅通过两次权重运算进行信号转换,同时通过旁路直接将信号传输到输出。




图 4 残差连接

Fig. 4 Residual connection

残差块由卷积层、批量归一化 (batch normalization, BN) 层组成,并加入残差连接与激活函数提升模型性能,其公式化表达为:

$$y = F(x, W_i) + x \quad (14)$$




图 5 流场预测模型的架构框图

Fig. 5 Architecture diagram of flowfield prediction model

通过 Reshape 层将卷积层的输出重塑为一维向量,进入全连接层阶段。通过全连接层 (FC3、FC4、FC5) 以匹配最终输出的需求。将

式中: x 为初始输入特征; W_i 代表残差模块权重; F 为残差映射,即通过卷积、激活等操作后的结果; y 为残差块的输出。

BN 层针对各层输出进行归一化处理,有效地稳定网络模型训练过程,并加速其收敛,一定程度上减少了梯度消失和梯度爆炸问题。具体操作如式 (15) 所示。

$$\begin{cases} \hat{z} = \frac{z - \mu}{\sqrt{\sigma^2 + \epsilon}} \\ z_{out} = a_1 \hat{z} + a_2 \end{cases} \quad (15)$$

其中: μ, σ^2 分别为小批量数据的均值和方差; a_1, a_2 均为可学习参数; z 为初始数据。

2.2 模型参数设置

采用基于残差连接的 ResNet 网络模型实现基于设计几何参数向量生成对应的流场特征的快速预测。采用的流场预测模型的架构框图如图 5 所示,图中只展示模块的大致组成,不区别具体模块。

输入的特征向量包括 7 个几何设计参数,用于描述基准流场的压缩面型线,通过 2 个全连接层 (FC1、FC2) 将输入数据映射到高维特征空间,随后将高维特征进行重塑 (Reshape) 作为卷积层的输入并紧接着应用 BN 以稳定训练过程。

网络包含 32 个重复的残差块 (ResBlock), 每个残差块内包含 2 个 3×3 的卷积层 (Conv2、Conv3), 每层之后均配备 BN 和 ReLU 激活函数。经过这些残差块的处理后,数据再通过第二个卷积层 (Conv4) 进一步提取特征,输出尺寸保持为 $32 \times 32 \times 32$,并同样应用 BN 和 ReLU 激活函数。

FC5 的输出重塑 (Reshape) 为流场特征分布的张量,生成最终的预测流场矩阵,对应于基准流场的密度场、压力场以及马赫数场。各层模型参

数选择如表 3 所示。

表 3 网络结构特定参数设置			
Tab. 3 Network structure specific parameter settings			
区域	层	核尺寸	输出尺寸
FC	FC1		1 × 256
	FC2		1 × 1 024
Reshapelayer1			1 × 32 × 32
Convlayer1	Conv1	3 × 3	32 × 32 × 32
	BN		32 × 32 × 32
ResBlock × 32	Conv2	3 × 3	32 × 32 × 32
	BN/ReLU1		32 × 32 × 32
	Conv3	3 × 3	32 × 32 × 32
	BN/ReLU2		32 × 32 × 32
Convlayer2	Conv4	3 × 3	32 × 32 × 32
	BN/ReLU3		32 × 32 × 32
Reshapelayer2			1 × 32 768
FC	FC3		1 × 8 192
	FC4		1 × 4 096
	FC5		1 × 55 800
Reshapelayer3			3 × 18 600

模型训练流程如图 6 所示,筛选后的样本按照比例划分为训练集(80%)和测试集(20%)。训练集用于模型训练,而测试集则用于模型性能的验证与评估。模型的训练与测试均在 NVIDIA 3090 显卡环境下基于 PyTorch 1.10 框架进行。训练过程中,采用自适应矩估计优化器(Adam)对模型参数进行优化,数据加载的批次大小为 16。同时,模型采用混合精度训练方式,以减少显存占用,提高计算效率。

损失函数选择预测矩阵与真实矩阵之间的均方误差(mean squared error, MSE),其计算公式为:

$$e = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \tag{16}$$

式中, \hat{y}_i 表示真实值, y_i 表示预测值, N 表示向量的维度。为优化模型性能,训练中使用梯度下降法降低损失函数值。初始学习率设为 0.000 1,每 100 个训练轮次将学习率衰减为原来的 50%,共计 500 个训练轮次。损失值和学习率的变化趋势如图 7 所示。随着训练轮次的增加,训练集和测试集的损失值逐渐降低,并最终趋于收敛。且两者之间差异较小,这表明模型的拟合效果较为理

想,未出现明显的欠拟合或过拟合现象。

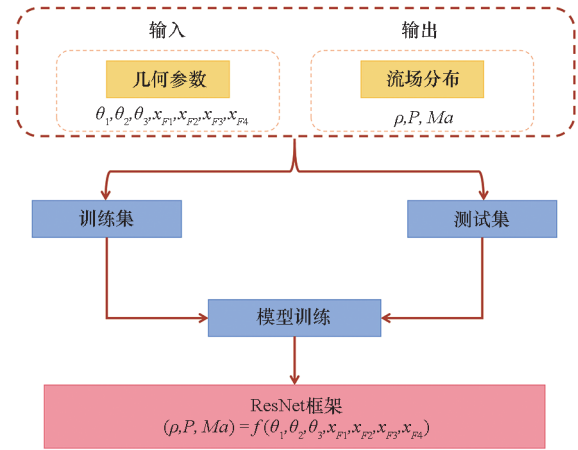


图 6 模型训练流程框图
Fig. 6 Model training process block diagram




图 7 模型训练过程损失值与学习率变化
Fig. 7 Loss and learning rate variation during model training process

2.3 评价指标

为了综合评估预测误差,避免单一指标可能带来的信息不完全问题,流场预测的误差通过多维度客观评价指标进行描述,包括峰值信噪比(peak signal-to-noise ratio, PSNR)、结构相似性指数(structural similarity, SSIM)和相关系数 R 。

2.3.1 峰值信噪比

PSNR 是图像处理和视频质量评价中常用的指标,用于衡量压缩图像或重建图像与原始图像之间的质量差异。具体而言,它通过计算两幅图像之间的像素差异来量化图像质量的变化程度,计算公式为:

$$P_{\text{SNR}} = 10 \cdot \lg \left(\frac{M^2}{e} \right) \tag{17}$$

式中: M 表示像素最大值,对于常见图像而言, M 取值为 255; e 定义为真实图像与预测图像所有像素值之间的均方差。一般来说,PSNR 高于 30 dB

表明预测图像的质量较高,与真实图像之间的像素分布差异较小。

2.3.2 结构相似性指数

SSIM 是用于衡量图像感知质量的重要指标,其从亮度、对比度和结构信息三个方面综合描述图像之间的相似性。SSIM 值介于 0 到 1 之间,值越接近 1 表示图像越相似。

$$\begin{cases} S_{\text{SIM}}(x,y) = I^\alpha \cdot c^\beta \cdot s^\gamma \\ I(x,y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \\ c(x,y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \\ s(x,y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \end{cases} \quad (18)$$

其中: I 反映图像亮度之间的相似性; μ_x, μ_y 分别表征两幅图像的均值; c 反映图像之间对比度的相似性; σ_x, σ_y 分别表征两幅图像的标准差; s 表示两幅图像的结构相关性; σ_{xy} 表示两幅图像的协方差; α, β, γ 分别表示三个部分的权重; c_1, c_2, c_3 均为防止分母为 0 的稳定项。

2.3.3 相关系数

R 是用来衡量两幅图像或两个变量之间线性相关性的指标。在图像处理或流场预测的评估中,相关系数用于定量描述预测结果与真实值之间的线性关系,反映了预测图像与真实图像是否在整体趋势上保持一致。

对于两幅图像 T (真实图像) 与 K (预测图像),相关系数的计算公式为:

$$R = \frac{\sum_{i=1}^n (T_i - \bar{T})(K_i - \bar{K})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 \cdot \sum_{i=1}^n (K_i - \bar{K})^2}} \quad (19)$$

式中: T_i, K_i 分别表示真实图像与预测图像第 i 个像素值; \bar{T}, \bar{K} 分别表示真实图像与预测图像的像素均值。

R 趋于 1 表明真实图像与预测图像像素值相关性较强。


3 结果分析

3.1 样本分析


基于 2.2 节所构建的网络模型,将划分的训练集代入 ResNet 网络模型进行训练,并使用训练后的模型加载测试集以检验模型性能。

图 8 展示了 50 个测试集样本的预测流场图像评价指标。以分图形式,分别展示了三类流场云图预测的评价指标分布。具体而言,马赫数云

图预测流场的 PSNR 在 30 ~ 45 dB 之间,压力云图预测流场的 PSNR 在 35 ~ 50 dB 之间,密度云图预测流场的 PSNR 在 38 ~ 53 dB 之间,三者均展现了较高的预测精度。其中,密度云图预测流场的 PSNR 表现相对更优。在结构相似性指数方面,马赫数云图与压力云图预测流场与真实流场的 SSIM 均处于 0.993 ~ 1.000 之间,而密度云图的 SSIM 均超过 0.997,进一步表明密度云图的预测效果相较于马赫数云图与压力云图更优,同时也展现了整体上三类云图预测结果的高准确性和可靠性。



(a) 峰值信噪比分布
(a) PSNR distribution



(b) 结构相似性指数分布
(b) SSIM distribution

图 8 图像生成质量指标

Fig. 8 Image generation quality indicators

表 4 展示了三种流场预测结果的平均指标,并从整体流场与局部关键流场两个区域对生成图像进行评价。从整体流场特性分析,三个流场的 PSNR 均值为 42.51 dB,SSIM 均值为 0.997 3,预测精度较高;针对局部关键流场,PSNR 均值为 39.37 dB,SSIM 均值为 0.993 9,相较整体区域略微下降,但仍保证了较高的精度。

表 4 预测结果评价指标

Tab.4 Evaluation indicators for prediction results

类别	整体区域		关键区域	
	PSNR/dB	SSIM	PSNR/dB	SSIM
ρ	47.77	0.998 4	43.78	0.995 9
P	41.57	0.997 2	37.22	0.992 1
Ma	38.18	0.996 4	37.10	0.993 7
平均	42.51	0.997 3	39.37	0.993 9

综上所述,测试集的整体图像质量评估指标表明,三类目标流场重构的 PSNR 取值均在 30 ~ 50 dB之间,说明模型在实现流场预测方面具有较高的精度。同时,SSIM 的取值均超过 0.99,说明真实流场与预测流场在结构相似性方面达到了较高水平。上述结果均验证了模型在不同类型流场云图预测中的优异性能。

为了进一步评估预测模型在单个样本中的表现,从马赫数预测云图的 PSNR 分布图中随机选取两个样本 Case A 与 Case B,展开深入研究。图 9展示了 Case A 的真实流场与预测流场的对比结果,同时记录了流场的 PSNR 与 SSIM。采用虚线框标注流场关键区域,并显示关键区域的 PSNR 与 SSIM 值。

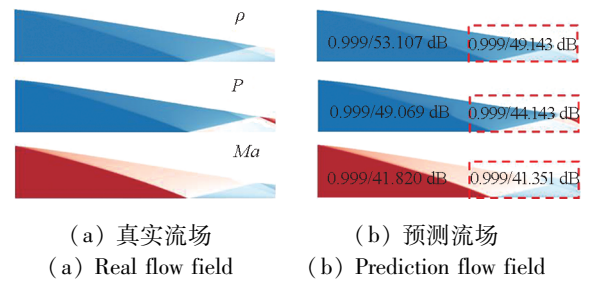



图 9 Case A 流场
Fig.9 Case A flow field


针对 Case A 的真实流场和预测流场进行对比分析,整体流场的预测结果表现优异,PSNR 和 SSIM 指数均处于较高水平,表明模型能够较好地还原目标流场的整体特征。在密度云图的重构中,整体的 PSNR 高达 50 dB,SSIM 接近 1。在关键区域的性能评估中,虽然 PSNR 相较于整体出现一定程度的下降,但其数值仍维持在较高水平,说明模型在关键区域的预测精度依然较高,能够有效捕捉流场的局部特性。

图 10 展示了马赫数预测流场与真实流场在三通道像素(R、G、B)上的分布值,并计算两者三通道像素分布的相关系数。从三个流场的像素值分布拟合曲线分析可以看出,相关系数均高于


0.999(图中取值仅保留三位小数),表明真实图像像素与预测图像像素整体上呈现出高度的线性



(a) R 通道像素分布
(a) R-channel pixel distribution



(b) G 通道像素分布
(b) G-channel pixel distribution



(c) B 通道像素分布
(c) B-channel pixel distribution

图 10 流场云图三通道像素分布
Fig.10 Three channel pixels distribution of flow field cloud map

相关关系,说明真实流场像素分布与预测流场像素分布的线性关系较强。然而,仍可观察到部分

离散像素值偏离真实值,与预测结果存在一定的偏差,表明模型在局部离散区域的预测仍存在改进的空间。

为了进一步探讨模型在不同样本中的表现,分析了 Case B 的真实流场与预测流场的对比情况。由图 11 可知,与图 9 类似,在图中对整体流场评价指标与关键流场评价指标进行标注。Case B 的整体流场相比 Case A 存在一定差距,其 PSNR 和 SSIM 值大多低于 Case A,但仍在高质量范围内,表明模型在该样本的整体流场预测中仍具备一定准确性。针对流场关键区域的性能评估显示,PSNR 和 SSIM 在关键区域均出现了明显下降,其中马赫数云图的重构 PSNR 降至 30 dB 以下,但整体分布趋势仍得到较好的保留。尽管关键区域的预测质量有所下降,模型仍能有效捕捉其局部的流场特征。

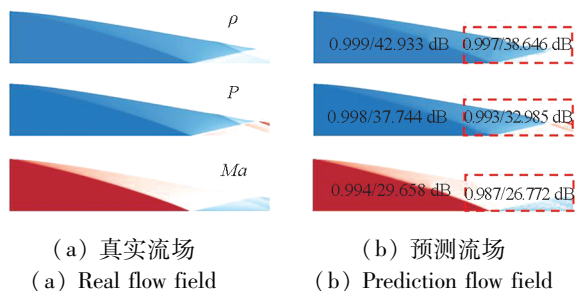



图 11 Case B 流场
Fig. 11 Case B flow field

3.2 关键特征提取


选取 Case A 对流场的关键特征进行提取,以检验模型的预测效果。以该样本的密度云图为例,从中截取一条虚线跨越基准流场的两波三区(入射激波、反射激波,入射激波上游、反射激波下游、中间区域),以探究真实流场与预测流场的像素值变化,如图 12(a)所示。

其像素值变化如图 12(b)所示,途经两道激波间断区域,其像素值相应发生两段突变。不难发现,在该虚线上三通道(R、G、B)像素值的预测结果均与真实结果吻合程度较高,仅在反射激波下游尾端存在小范围的差异。通过将像素值与图例对应能进一步反解出流场特征,实现基于预测图像的流场特性参数分布计算。

进一步针对基准流场中心体几何面与压缩面,对马赫数云图和压力云图的分布特性进行研究。图 13 和图 14 分别展示了马赫数和压比在中心体几何面与压缩面上的分布情况。对于中心体几何面分布而言,马赫数、压比均在激波反射位置出现较大的突变,符合实际流动规律。



(a) 划定虚线范围
(a) Define the dotted line range



(b) 虚线位置 RGB 像素值变化
(b) Change of RGB pixel at dotted line

图 12 密度云图局部分析
Fig. 12 Local analysis of density nephogram

在压缩面流动特性参数分布方面,马赫数在压缩段逐渐降低,并在下洗角曲率变化较为剧烈处出现较小范围的突跃,然后在反射激波与压缩面交点处骤降,最终来流经过膨胀波加速使马赫数回升;与之相反,压比随着压缩增强,出现了一定程度的上升,并于曲率变化较大处发生突跃,随后在反射激波与压缩面交点处骤升,最后经过尾部膨胀波使得压比小幅度降低。上述变化均符合流场特性参数分布规律。

总体而言,中心体几何面与压缩面上的预测流场特性参数分布拟合程度较高,仅在激波间断处存在一定误差,整体表现优异。

通过模型预测流场实现激波形状的捕捉。如图 15(a)所示,以径向步长 $\Delta r = 0.1$ 沿轴向方向分别截取多条马赫数分布曲线,并将其与真实流场的激波间断曲线进行对应。针对马赫数变化剧烈的区间,选取变化区间中点对应的轴向位置作为激波间断位置,绘制激波分段图像,并在真实流场中进行标注。从中提取不同径向对应的激波间

断位置,并与真实激波间断位置进行对比,结果记录如图 15(b) 所示。图中横坐标为径向距离,纵坐标为激波间断位置的轴向距离,分别作出真实激波、预测激波与 $\Delta r = 0.1$ 对应的离散点并进行

连线,进一步分析激波形状的捕获能力。
分析结果表明,该方法能够有效捕捉激波形状,并且预测结果与真实流场激波形态具有较高的匹配精度。




图 13 中心体几何面与压缩面的马赫数分布

Fig. 13 Mach number distribution of the central body geometric surface and the compression surface

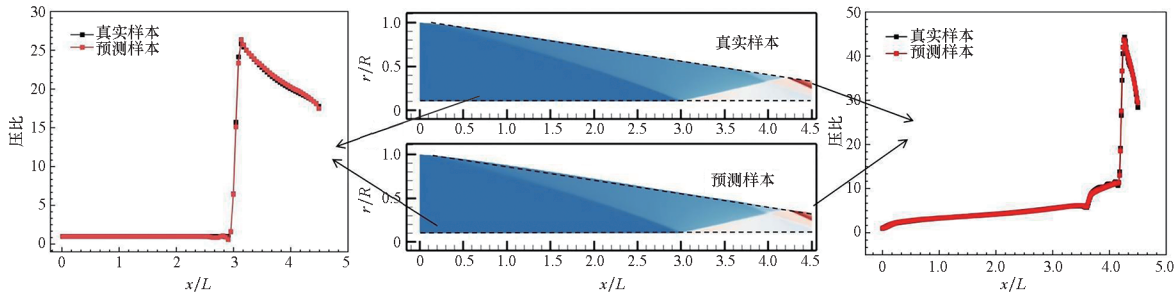



图 14 中心体几何面与压缩面的压比分布


Fig. 14 Pressure ratio distribution of the central body geometric surface and the compression surface

3.3 模型可解释性

从某测试样本中提取残差块结构前与结构后的特征图,如图 16 所示。对比图 16(a)、图 16(b)



(a) 激波间断位置
(a) Shock discontinuity position



(b) 激波位置对比
(b) Shock position contrast

图 15 激波形状捕捉
Fig. 15 Shock wave shape capture

可以看出,模型逐渐从捕捉局部特征向提取全局信息的方向转变。

图 16(a)是残差块前的特征图,呈现较为稀疏、离散的特征响应,反映出模型对输入的局部区域的边缘、纹理与局部变化等低维特征的提取能力。这种情况下特征图的响应较为分散,整体表

现“粗糙”，此时模型聚焦于流场输入的局部特征，例如小范围的马赫数变化或局部压力梯度的波动。图 16(b) 是残差块后的特征图，经过残差块的多层卷积操作与跳跃连接后，呈现更为平滑的特征，部分区域的响应值变得更加集中，反映出模型对输入流场的宏观特性与整体特点具有更加精确的描述。同时，这种平滑性也表明了残差块对局部特征进行了整合与过滤，去除部分冗余信息，进一步增强对关键区域的表达。此时模型对流场中的关键特性区域，如激波间断、反射激波依赖区的描述更为清晰。

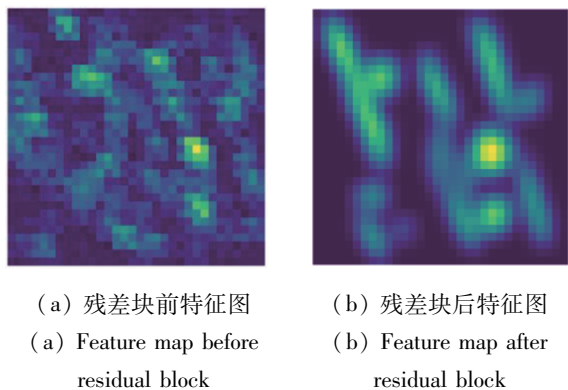


图 16 不同位置特征图

Fig. 16 Feature maps at different locations

前后两张特征图的变化表明了残差块有效提升了模型对流场的特征提取能力，前者保留更多细节信息，后者的高响应区域更能体现模型的注意力集中的区域，表明残差块对特征信息的融合符合流场特性预测的需求。

4 结论

针对高超声速内收缩基准流场的特性参数分布与性能进行快速预测，对其优化设计具有重要的意义与显著的工程应用价值。本文通过将深度学习的残差神经网络模型融入进气道参数化设计中，并结合图像质量评估方法对预测结果进行检验，主要结论如下：

1) 基于准均匀 B 样条实现了内收缩等中心体基准流场的参数化设计，该方法可对基准流场关键几何特征进行参数化表达，如初始压缩角、下洗角、总收缩比、内收缩比以及出口方向角等，为基准流场样本生成提供了有效工具。

2) 基于数据驱动的残差神经网络架构，搭建了高超声速内收缩基准流场的快速预测模型。该模型在流场特性和性能分布预测方面表现出较高的精度，整体流场平均峰值信噪比为 42.51 dB，平均结构相似性指数在 0.99 以上。对于设计几

何参数样本空间内的流场预测均具有良好的保真性。

3) 利用图像评估方法，对内收缩基准流场中的关键流场特征进行了评估。结果表明，预测模型能够准确捕捉激波形状、壁面参数分布等流场特性，整体趋势符合预期，展现了较好的特性提取与流场预测能力。

本文的研究方法也可推广应用到飞行器其他部件设计的相关领域。

参考文献 (References)

- [1] VARNER M O, MARTINDALE W R, PHARES W J, et al. Large perturbation flow field analysis and simulation for supersonic inlets; NAS 1.26:174676[R]. Washington, D. C.: National Aeronautics and Space Administration, 1984.
- [2] BIEDRON R T, ADAMSON T C, Jr. Unsteady flow in a supercritical supersonic diffuser[J]. AIAA Journal, 1988, 26(11): 1336–1345.
- [3] KOPASAKIS G, CONNOLLY J. Shock positioning controls design for a supersonic inlet[C]//Proceedings of the 45th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit. Denver: AIAA, 2009: 5117.
- [4] KOPASAKIS G, CONNOLLY J, PAXSON D, et al. Quasi 1D modeling of mixed compression supersonic inlets[C]//Proceedings of the 50th AIAA Aerospace Sciences Meeting Including the New Horizons Forum and Aerospace Exposition. Nashville: AIAA, 2012: 0775.
- [5] YOU Y C. An overview of the advantages and concerns of hypersonic inward turning inlets[C]//Proceedings of the 17th AIAA International Space Planes and Hypersonic Systems and Technologies Conference. San Francisco: AIAA, 2011: 2269.
- [6] 郑晓刚, 施崇广, 张加乐, 等. 高超声速三维内转进气道研究进展综述[J]. 航空学报, 2025, 46(8): 631245.
ZHENG X G, SHI C G, ZHANG J L, et al. Research progress review on hypersonic three-dimensional inward-turning inlet[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(8): 631245. (in Chinese)
- [7] 李永洲, 张堃元, 孙迪. 马赫数可控的方转圆高超声速内收缩进气道试验研究[J]. 航空学报, 2016, 37(10): 2970–2979.
LI Y Z, ZHANG K Y, SUN D. Experimental investigation on a hypersonic inward turning inlet of rectangular-to-circular shape with controlled Mach number distribution[J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(10): 2970–2979. (in Chinese)
- [8] XIONG B, FAN X Q, WANG Y. Parameterization and optimization design of a hypersonic inward turning inlet[J]. Acta Astronautica, 2019, 164: 130–141.
- [9] 陈皓, 郭明明, 田野, 等. 卷积神经网络在流场重构研究中的进展[J]. 力学学报, 2022, 54(9): 2343–2360.
CHEN H, GUO M M, TIAN Y, et al. Progress of convolution neural networks in flow field reconstruction[J]. Chinese Journal of Theoretical and Applied Mechanics, 2022, 54(9): 2343–2360. (in Chinese)
- [10] KONG C, CHANG J T, LI Y F, et al. Flowfield reconstruction and shock train leading edge detection in

scramjet isolators[J]. AIAA Journal, 2020, 58(9): 4068 – 4080.

[11] GUO M M, LE J L, DENG X, et al. Flow field reconstruction in inlet of scramjet at Mach 10 based on physical information neural network[J]. Physics of Fluids, 2023, 35(10): 105144.

[12] 关开港, 苏伟仪, 崔晟, 等. 高超声速乘波前体 – 进气道三维复杂流场的 POD-BPNN 快速预测方法[J]. 航空动力学报, 2025, 40(2): 20220536.

GUAN K G, SU W Y, CUI S, et al. POD-BPNN prediction on the three-dimensional complex flow field of hypersonic waverider forebody/inlet[J]. Journal of Aerospace Power, 2025, 40(2): 20220536. (in Chinese)

[13] 栾建苗, 邓枫, 覃宁, 等. 快速预测跨声速流场的深度学习方方法[J]. 航空学报, 2022, 43(11): 526747.

YI J M, DENG F, QIN N, et al. Fast prediction of transonic flow field using deep learning method[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43 (11): 526747. (in Chinese)

[14] 胡伟杰. 基于机器学习的导弹气动性能与流场预测研究[D]. 南京: 南京航空航天大学, 2021.

HU W J. Research on the prediction of missile aerodynamic performance and flow field based on machine learning[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021. (in Chinese)

[15] 李鑫, 韩仁坤, 刘子扬, 等. 基于卷积神经网络的三维流场重构研究[J]. 航空计算技术, 2023, 53(5): 11 – 14, 19.

LI X, HAN R K, LIU Z Y, et al. Research on three-dimensional flow field reconstruction based on convolutional neural networks[J]. Aeronautical Computing Technique, 2023, 53(5): 11 – 14, 19. (in Chinese)

[16] 曹晓峰, 李鸿岩, 郭承鹏, 等. 基于深度学习的二维翼型流场重构技术研究[J]. 航空科学技术, 2022, 33(7): 106 – 112.

CAO X F, LI H Y, GUO C P, et al. Research on two-dimensional airfoil flow field reconstruction based on deep learning[J]. Aeronautical Science and Technology, 2022, 33(7): 106 – 112. (in Chinese)

[17] 吴跃腾, 巴顿, 杜娟, 等. 基于深度注意力网络的压气机流场重构方法[J]. 航空学报, 2024, 45(24): 630580.

WU Y T, BA D, DU J, et al. Compressor flow field reconstruction method based on deep attention networks[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45 (24): 630580. (in Chinese)

[18] 代春良, 孙波, 张堃元. 马赫数 3 ~ 6 宽速域内转进气道优化设计[J]. 航空动力学报, 2019, 34(10): 2191 – 2202.

DAI C L, SUN B, ZHANG K Y. Optimization design of the inward turning inlet in the Mach number 3 – 6 wide velocity domain[J]. Journal of Aerospace Power, 2019, 34(10): 2191 – 2202. (in Chinese)

[19] 何磊, 钱炜祺, 刘滔, 等. 基于深度学习的翼型反设计方法[J]. 航空动力学报, 2020, 35(9): 1909 – 1917.

HE L, QIAN W Q, LIU T, et al. Inverse design method of airfoil based on deep learning[J]. Journal of Aerospace Power, 2020, 35(9): 1909 – 1917. (in Chinese)

[20] 柳家齐, 陈荣钱, 楼锦华, 等. 基于深度学习的高速直升机旋翼翼型气动优化设计[J]. 航空学报, 2024, 45(9): 529828.

LIU J Q, CHEN R Q, LOU J H, et al. Aerodynamic shape optimization of high-speed helicopter rotor airfoil based on deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(9): 529828. (in Chinese)

[21] 宋家欢. 四旋翼无人机轨迹规划方法研究及系统设计与实现[D]. 南京: 东南大学, 2022.

SONG J H. Research on UAV trajectory planning with system design and implementation [D]. Nanjing: Southeast University, 2022. (in Chinese)