

组合式细节特征增强的隔离段流场智能重构方法

吴京润¹, 邓 雪², 田 野^{1,2*}, 肖梦绮^{1,2}, 张 华¹

(1. 西南科技大学 信息工程学院, 四川 绵阳 621000; 2. 中国空气动力研究与发展中心 空天技术研究所, 四川 绵阳 621000)

摘要:针对超声速流场智能重构方法存在的复杂波系结构特征丢失、无法有效捕捉非定常流场的时间演化特性,以及共同导致的无法准确辨识激波串前缘位置(shock train leading edge, STLE)等问题,提出基于组合式细节特征增强的神经网络模型。基于稀疏压力数据实现密度梯度场的高精度预测,模型通过多层卷积网络串联建立流场的主要波系结构特征,利用残差网络通过跳跃连接将不同尺度感受野的特征进行融合,增强重构流场的细节特征表达能力。基于冲压发动机数值模拟计算构建的数据集进行验证,结果显示,与多层卷积神经网络相比,该方法在整个测试集上的平均峰值信噪比提升了9.5%。重构流场的STLE与数值计算结果高度吻合,进一步证明了所提方法的有效性。

关键词:冲压发动机;隔离段;流场重构;激波串前缘位置;深度学习

中图分类号:V235.21; TP183 **文献标志码:**A **文章编号:**1001-2486(2026)01-274-13

Intelligent reconstruction method of isolator flow field with combined detail feature enhancement

WU Jingrun¹, DENG Xue², TIAN Ye^{1,2*}, XU Mengqi^{1,2}, ZHANG Hua¹

(1. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621000, China;

2. Space Technology Research Institute, China Aerodynamics Research and Development Center, Mianyang 621000, China)

Abstract: Aiming at issues such as the loss of complex wave system structural features in intelligent reconstruction methods for supersonic flow fields, along with the inability to effectively capture the temporal evolution characteristics of unsteady flow fields, which together lead to the inaccurate identification of the STLE (shock train leading edge). A neural network model based on combined detail feature enhancement to address these issues was proposed. High-precision predictions of the density gradient field was achieved based on sparse pressure data. The main wave system structure features of the flow field was established by connecting multiple layers of convolutional networks in series. A residual network with skip connections was used to integrate features from receptive fields of different scales, enhancing the model's ability to express detail features in reconstructed flow fields. Validation was conducted using a data set constructed from numerical simulations of ramjet engines. Compared to multilayer convolutional neural networks, this method improves the average peak signal-to-noise ratio across the entire test set by 9.5%. Moreover, the reconstructed flow field's STLE position closely matches the numerical computation results, further demonstrating the effectiveness of the proposed method.

Keywords: ramjet engine; isolator; flow field reconstruction; shock train leading edge; deep learning

作为超声速飞行器的理想动力系统,冲压发动机已成为国内外研究热点之一^[1-2]。冲压发动机主要由进气道、隔离段、燃烧室和尾喷管等组成^[3]。其中,隔离段作为冲压发动机的重要部件,处于进气道与燃烧室之间,负责隔离燃烧产生的高压对进气来流的影响^[4]。激波串是超声速

气流在隔离段减速增压过程中出现的一种以激波/边界层干扰为主要特征的复杂流动现象。当激波串前缘位置(shock train leading edge, STLE)接近隔离段入口时,可能引起进气道不启动^[5-6]或燃烧室熄火^[7]等现象,严重影响发动机的工作性能。因此,对隔离段 STLE 进行高精度检测,为

收稿日期:2024-12-04

基金项目:国家自然科学基金资助项目(11902337);西南科技大学研究生创新基金资助项目(25yex2019)

第一作者:吴京润(2000—),男,四川遂宁人,硕士研究生, E-mail:641571508@qq.com

*通信作者:田野(1987—),男,吉林人,教授,博士,博士生导师, E-mail:tianye@carde.cn

引用格式:吴京润, 邓雪, 田野, 等. 组合式细节特征增强的隔离段流场智能重构方法[J]. 国防科技大学学报, 2026, 48(1): 274-286.

Citation: WU J R, DENG X, TIAN Y, et al. Intelligent reconstruction method of isolator flow field with combined detail feature enhancement[J]. Journal of National University of Defense Technology, 2026, 48(1): 274-286.

评估发动机运行状态提供可靠数据具有重要意义。

目前,已有众多学者对隔离段的流动特性进行了深入研究^[8-12],提出了多种 STLE 检测方法^[13],包括压升法、压力比法、标准差法、谱分析法、静压法和背压法。然而,这些传统方法都是基于离散压力传感器的测量来直接检测 STLE,计算成本过高,预测精度较低^[14-16]。同时,面对隔离段中的复杂流动特性,传统检测方法难以有效捕捉流场动态变化特性。

近年来,神经网络在图像分类^[17]、目标检测^[18]、语音识别^[19]和超分辨率重建^[20-21]等领域表现出强大的非线性拟合能力,因此,也被广泛应用于流体力学领域中。研究者们起初利用神经网络来建立隔离段流场信息与 STLE 之间的映射关系,然而,通过大量且复杂的流场信息直接辨识 STLE 会导致计算资源的巨大消耗^[22-23]。由于从流场结构中可以更直观且准确地获得 STLE 的位置,因此,通过神经网络实现隔离段流场的精准预测成为 STLE 高精度检测的重要前提。目前,大量研究已经证明了神经网络作为流场求解器的可行性和有效性。Li 等^[24]构建了一种对称式神经网络模型来重构超声速级联通道内流场结构,证明了深度学习能够有效捕捉复杂多变工况下的流场结构和对未知工况流场预测的强泛化能力。Kong 等^[25]构建卷积神经网络(convolutional neural networks, CNN)进行流场重构,并通过模型提供的流场结构对 STLE 进行检测,相比压力比法和压升法,该方法成功基于重构流场实现了对 STLE 的高精度检测。为进一步提高 STLE 检测精度,Chen 等^[26]提出了一种多层 CNN 进行隔离段流场重构并检测 STLE,与数值模拟相比,该方法得到的 STLE 均方根误差为 3.28 mm,实现了较低的检测误差。相比单路径网络,多路径神经网络架构可以从压力数据中捕捉更多流场信息,获得波系特征更丰富的流场图像。Kong 等^[27]提出了一种基于多路径融合的卷积神经网络结构,用于在不同马赫数和不同背压条件下的流场重构,Kong 等^[28]还提出了一种基于壁面压力序列的多路径流场预测模型,利用不同演化规律下的实验数据建立了实验数据集。虽然文献[27]和文献[28]均实现了流场的高精度重构,但是模型训练需要大量的先验知识,耗费大量的计算资源和时间。为了通过少量壁面压力数据实现流场高质量重构,Chen 等^[29]构建了一种基于多分支融合卷积神经网络(multi branch fusion convolutional neural network, MBFCNN),用于拟合上下壁面压

力与冲压发动机燃烧室流场的非线性耦合关系,随着压力测点的减少,重构流场从视觉上来看仍在可接受范围内,但重构精度有所下降。此外,Deng 等^[30]引入多头注意力机制^[31]提升模型的全局感知能力,利用注意力机制来提取不同的特征,结果表明该方法能有效重构出燃烧室流场波系结构。尽管上述方法在流场重构方面已经取得不错效果,但重构流场分辨率较低,波系结构细节特征存在较强的平滑现象,因此,有必要通过超分辨率重建网络来提升流场细节,以便更加直观分析流场波系结构。为了实现低分辨率流场图像的超分辨率重建,Liu 等^[32]提出了一种静态卷积神经网络以及一种多路径卷积神经网络。

上述多数方法利用多路径网络结构来提取流场特征信息,然而,多路径网络结构复杂,容易导致模型过拟合,从而丢失复杂波系结构特征,无法有效捕捉非定常流场的时间演化特性等问题。因此,如何通过一个简化的模型来降低计算成本,同时保持良好的特征提取能力,是目前需要解决的问题。对此,本文提出一种基于组合式细节特征增强的神经网络模型(neural network model based on combined detail feature enhancement, NNCDFE),以基于稀疏压力数据实现密度梯度场的高精度预测。模型首先通过多层卷积网络串联建立流场的主要波系特征,然后利用残差结构,通过跳跃连接将不同尺度感受野的特征进行融合,增强重构流场的细节特征表达能力。该方法将多层神经网络的特征提取能力与残差网络的细节增强能力有机地结合起来,有效提升隔离段流场重构精度,从而提高 STLE 的检测精度。

1 数据集

1.1 物理模型及工况条件

本次研究采用计算流体动力学(computational fluid dynamics, CFD)数值模拟软件 Fluent 模拟获取冲压发动机隔离段的上下壁面压力数据和流场图像,该软件采用有限体积法对基本控制方程进行离散。本文采用“凹腔+后向台阶”型的冲压发动机燃烧室,如图 1 所示,隔离段长 340 mm、宽 150 mm、高 30 mm。来流通过隔离段流入,并从出口流出。隔离段下游由燃烧室凹腔和扩张段构成,凹腔深 28 mm、长 278 mm,尾部后沿斜坡角为 43.6°。凹腔下游的扩张段由两部分组成,第一部分长 230 mm、带 1°扩张角,第二

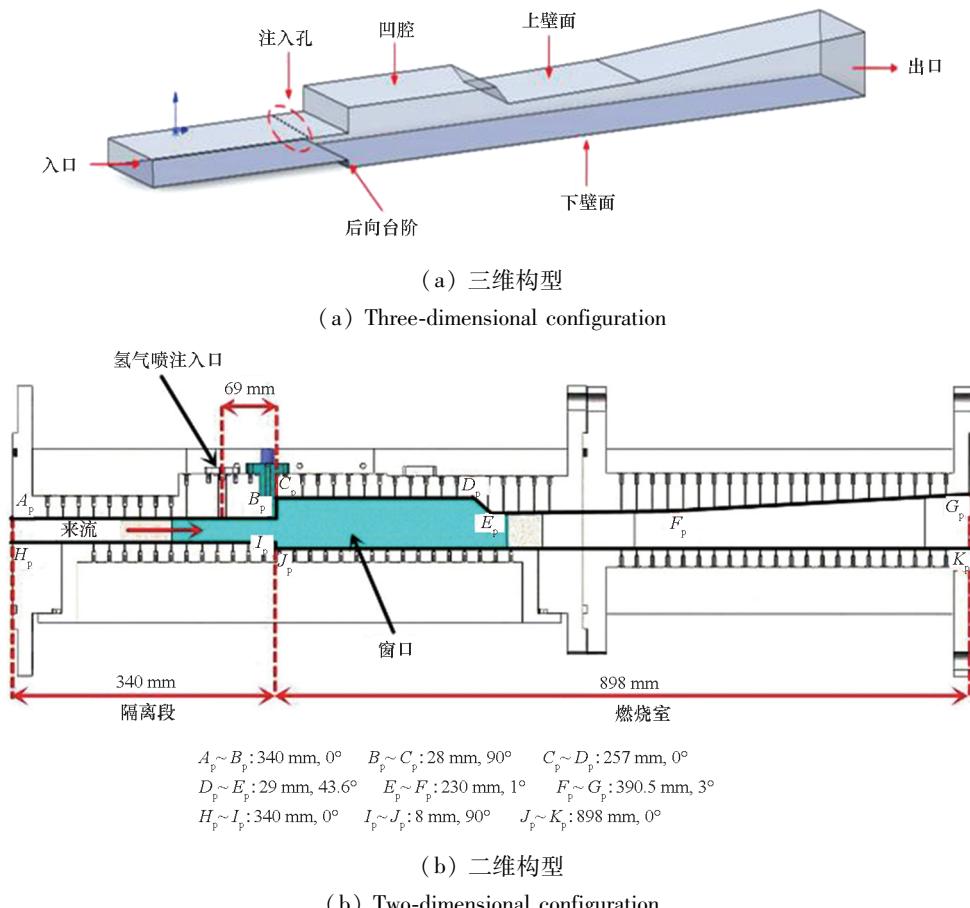


图1 吸气式发动机构型
Fig. 1 Air-breathing engine configuration

部分长390 mm、带3°扩张角。燃料由10个直径为1 mm的圆孔喷注进入燃烧室,喷注位置位于凹腔上游69 mm处。由喷注形成的激波和膨胀波在超声速混合和燃烧过程中起着至关重要的作用。

使用ANSYS ICEM软件对模型进行网格划分。该模型采用二维平面计算,为保证边界层网格划分精度,第一层网格高度为 1.06×10^{-3} mm,网格增长率为1.2。为验证网格无关性问题进行了三组网格划分,网格总量分别为90 000、130 000和180 000。通过分析壁面压力发现,采用不同网格尺寸进行数值计算的结果差异较小,如图2所示,为减少计算量和成本,采用网格总数为130 000的网格开展后续计算。

计算过程设定的气流为可压缩理想气体,黏度采用Sutherland公式进行计算。依据真实试验条件设定模拟来流条件,如表1所示。输入 Ma 为2.5,入口气流总压为1.75 MPa,总温为1 350 K。本研究以氢气为燃料,采用正弦型脉冲喷注技术,具体表示为:

$$Q = A \sin(2\pi f) + A \quad (1)$$

式中, Q 为质量流量, f 为喷注频率, A 为振幅。 Q 的值域为 $[0, 2A]$,周期为 $1/f$ 。为了使激波结构保留在隔离段内以便于观察和分析且不超过发动机的设计极限,一个周期内氢气平均当量比设置为0.7274,喷注频率为10.98 kHz,振幅为0.4205 kg/s。

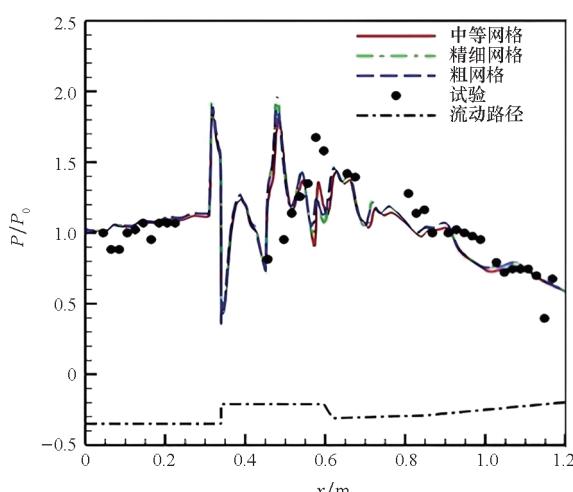


图2 网格无关性验证
Fig. 2 Grid independent validation

表1 来流条件

Tab. 1 Incoming condition

参数	空气	燃料喷口
总温 T_0/K	1 350	300
总压 P_0/MPa	1.75	
马赫数 Ma	2.5	1
氧气质量分数 $Y_{O_2}/\%$	20.09	0
水蒸气质量分数 $Y_{H_2O}/\%$	19.26	0
氮气质量分数 $Y_{N_2}/\%$	60.65	0
氢气质量分数 $Y_{H_2}/\%$	0	100

燃料开始喷注后,由于燃烧释热,燃烧室压力快速上升并前传,当出口压力逐渐增加到 5.5198×10^4 Pa 时,在隔离段内形成激波串。受正弦型脉冲喷注影响,隔离段出口压力稳定后呈类正弦变化,从开始出现激波串结构到停止计算,总时间为 41.5 ms,每 0.1 ms 采样一次数据,获得氢气燃烧状态下的非定常流场数据。隔离段出口压力随时间变化曲线如图 3 所示。

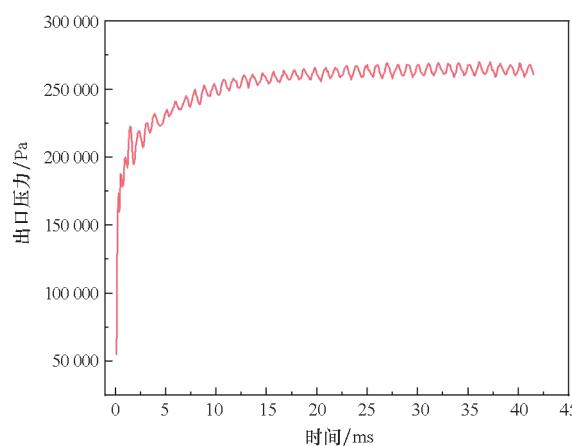


图3 隔离段出口压力随时间变化曲线

Fig. 3 Isolation section outlet pressure curve over time

为了进行燃烧过程中流场的波系演化分析,分别选取四个时刻的密度梯度场,如图 4 所示。由图 4 可知,当隔离段出口压力增加时,逆压梯度沿着隔离段附面层亚声速低动能流动区域向上游传播,导致分离区域向隔离段上游传播,从而导致激波串逐渐向上游移动。当隔离段出口压力增加时,逆压梯度沿着隔离段附面层亚声速低动能流动区域向上游传播,导致分离区域向隔离段上游传播,从而导致激波串逐渐向上游移动。在每一个激波串中,沿气流流动的方向,每一道激波的高度和跨度均减小,即激波强度逐渐减弱,激波与边界层的强干扰造成边界层严重分离并且其厚度迅速增加。

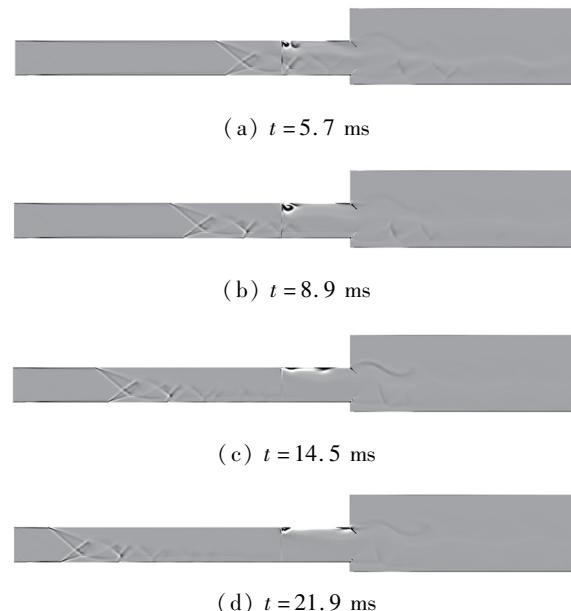


图4 不同时刻的密度梯度场

Fig. 4 Density gradient field at different times

1.2 数据预处理

通过数值模拟获得 415 组数据,本研究选取 t 从 3.3 ~ 22.2 ms,共 190 组数据作为数据集,这些数据位于激波串明显变化的区间,能够表征隔离段波系结构演化特性。

每组数据由 2 600 个上下壁面压力数据和对应时刻的流场图像组成。针对上下壁面压力数据过多导致网络难以拟合的问题,在随时刻移动且压力值呈现有典型特征变化的区间里,选取 30 个压力测试点作为每时刻的压力数据。同时,为了更好地训练,将压力数据归一化后作为网络模型的输入。

由于激波串前缘位置在燃料喷注点到隔离段入口处变化,在此区间进行重构流场可以直观获得激波串前缘位置,因此将密度梯度场进行裁剪,取燃料喷注点到隔离段入口处的部分,同时增加对比度和亮度,提高激波串波系结构特征。为了减少网络训练所需的计算时间和参数,流场图像的分辨率降低到 35 像素 \times 270 像素,图 4 中四个时刻预处理后的流场图像如图 5 所示。为了加速网络的收敛,将图像像素值从 0 ~ 255 归一化为 0 ~ 1。

最后,将这 190 组数据按照 8 : 2 的比例分为训练集和测试集,即训练集中有 152 组数据,测试集中有 38 组数据。在模型训练过程中,训练集用于更新模型的参数,而测试集不参与参数更新,仅用作评估模型的泛化能力。

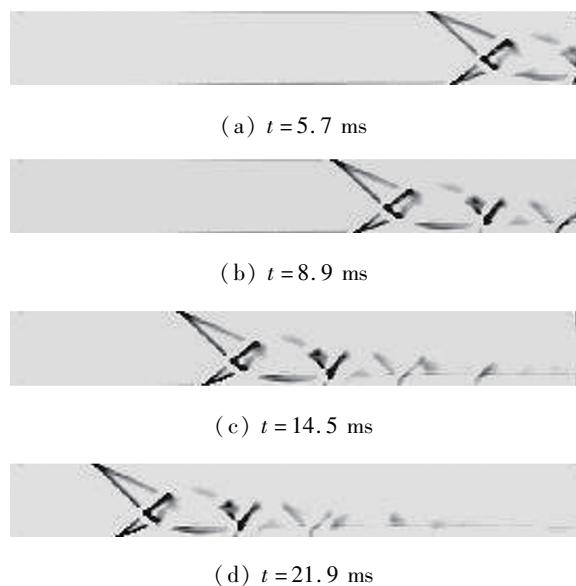


图5 四个时刻预处理后的流场图像

Fig. 5 Flow field image after four moments preprocessing

2 方法

2.1 组合式细节特征增强网络

本文提出一种基于隔离段流场重构的NNCDFE方法,由波系结构特征提取网络和波系细节特征增强网络组成,如图6所示,其中“Deconv”表示上采样层,“Conv”表示卷积层,“FC”表示全连接层,“Max pool”表示最大池化

层,“BN”表示批归一化层,“ReLU”表示激活函数。波系结构特征提取网络采用编码-解码的结构,利用多层次反卷积、卷积、最大池化和全连接等操作进行串联,提取高维非线性特征,建立流场的主要波系结构特征。其中,编码部分由反卷积层组成,从压缩的输入数据中逐渐重构出更高分辨率的特征图。由于输入压力数据的张量过小,利用全连接层将输入数据重塑成适合进行反卷积操作的形状。为充分提取压力的特征信息,网络的解码部分由卷积层组成,进一步处理和细化从反卷积层得到的特征图,并通过最大池化层进行下采样,在保留特征的同时,减少计算复杂度。利用全连接层对流场中的主要波系结构进行重塑。为了进一步增强模型对流场细节特征的重建性能,构建了基于残差网络的图像细节特征增强网络,用于波系结构图的细节增强,弥补多层次卷积网络在特征提取时忽略的流场细节。通过15组残差块串联并进行多次卷积操作,能够有效学习波系结构特征提取网络缺失的流场图像特征,使得流场图像的细节更加清晰,增加图像的表现力。同时,通过跳跃连接将不同尺度感受野的特征进行融合,提高网络的学习能力和精准度。最后,模型输出得到具有丰富波系结构细节特征的隔离段流场图像。此外,批归一化层在每个卷积和激活函数之间使用,以便稳定和加速训练过程。

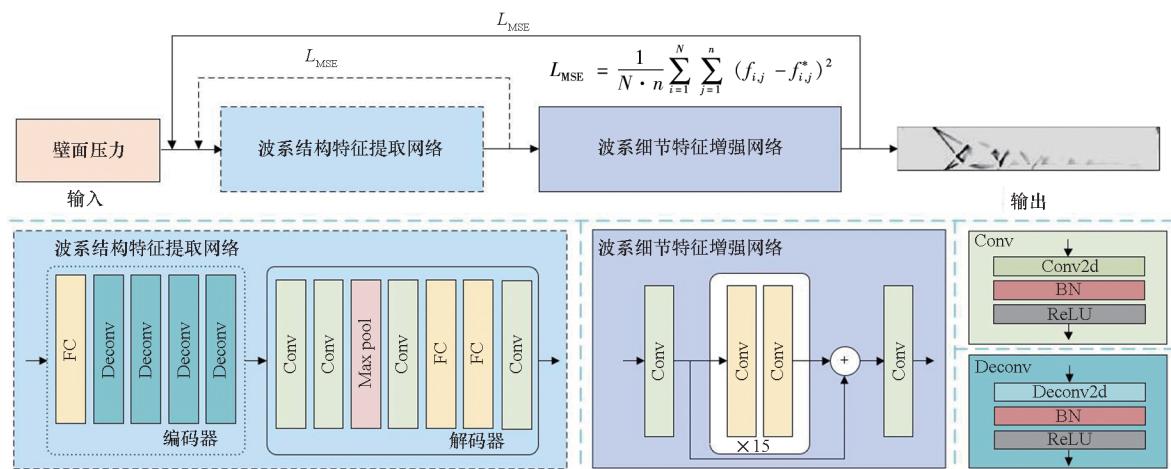


图6 基于组合式细节特征增强的神经网络结构

Fig. 6 The neural network architecture based on composite detail feature enhancement

通过两部分串联,建立隔离段上下壁面压力数据到激波串流场图像的映射关系:

$$Y = F(\theta, F_1(\theta_1, P)) \quad (2)$$

式中, Y 表示由模型重构的隔离段流场图像像素值, P 表示数值模拟获取的隔离段的上下壁面压强值, $F_1(\cdot)$ 和 $F(\cdot)$ 分别表示第一部分网络的

函数和整个网络的函数, θ_1 和 θ 分别表示第一部分网络的学习参数和整个网络的学习参数。输入参数 P 为经归一化处理的壁面压强数据,来源于上、下壁面各 15 个测点,其表达式为:

$$P = \begin{pmatrix} p_{1,1} & p_{1,2} & \dots & p_{1,15} \\ p_{2,1} & p_{2,2} & \dots & p_{2,15} \end{pmatrix} \quad (3)$$

式中, $p_{1,j}$ ($j=1, 2, \dots, 15$) 表示隔离段上壁面压力数据, $p_{2,j}$ ($j=1, 2, \dots, 15$) 表示隔离段下壁面压力数据。

2.2 卷积与激活函数

卷积层是深度学习模型中的核心组件, 通过在输入数据上应用多个卷积核, 提取局部特征等。

卷积操作的输出特征图 y_c 可表示为:

$$y_c(i,j) = \delta\left(\sum_{m=0}^{M-1} \sum_{n=0}^{N-1} y_{c-1}(i+m, j+n) \cdot k(m, n) + B_c\right) \quad (4)$$

式中: $y_{c-1}(i+m, j+n)$ 表示前一层特征图在位置 $(i+m, j+n)$ 处的值, 表示加性偏移量; $k(m, n)$ 表示卷积核在位置 (m, n) 的权重, B_c 表示第 c 层卷积的偏置项; δ 表示激活函数, 本文激活函数选择 ReLU 激活函数, 引入非线性特性, 提升模型的表达能力和训练稳定性。

2.3 上采样

由于压力数据尺寸较小且流场图像尺寸较大, 需要扩大压力数据尺寸, 以便后续卷积操作。本文采用转置卷积对压力数据进行上采样。转置卷积是一种通过逆向执行卷积操作来扩展特征图的方法, 转置卷积操作如图 7 所示。

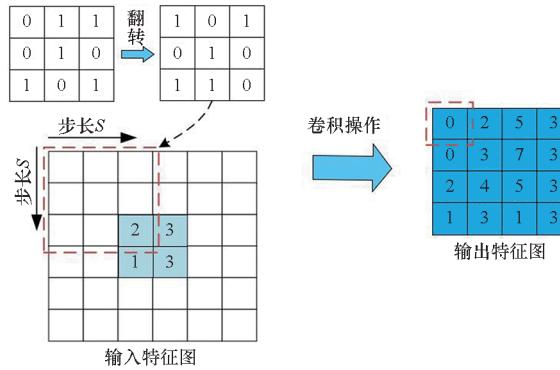


图 7 转置卷积过程

Fig. 7 Transposed convolution process

2.4 池化

池化操作是一种用于减小数据尺寸并提取主要特征的技术。常见的池化操作包括最大池化和平均池化。本文采用最大池化法, 假设输入张量为 X , 输出张量为 Y , 池化窗口大小为 $(2, 2)$, 步长为 2, 其公式为:

$$Y(i,j) = \max\{X(m,n)\} \quad (5)$$

式中, $m \in [2i, 2i+1]$, $n \in [2j, 2j+1]$, 输出张量 $Y(i,j)$ 包含输入张量 X 上从位置 $(2i, 2j)$ 到位置 $(2i+1, 2j+1)$ 的最大值。

2.5 全连接层

全连接层将每个输入特征与每个神经元连接, 使得网络能够学习到特征之间的复杂关系。全连接层的核心是线性变换, 通常会在线性变换之后应用一个 ReLU 非线性激活函数, 增加模型表达能力, 其公式为:

$$y = \delta(Wx + b) \quad (6)$$

式中, y 是输出向量, W 是权重矩阵, x 是输入矩阵, b 是偏置向量。

3 试验与分析

3.1 模型训练与测试

本次研究使用的计算平台为 Windows 10, CPU 为 16 GB 的 Intel 酷睿 i9-14900k, GPU 为 12 GB 的 RTX4090, 使用开源软件库 PyTorch 来训练模型。训练模型波系结构特征提取网络, 训练完成后保存权重, 再冻结其参数并加载权重, 加入波系细节特征增强网络进行训练与测试, 即只更新波系细节特征增强网络的参数权重。表 2 为波系结构特征提取网络结构参数, 表 3 为波系细节特征增强网络结构参数。其中, 输入、输出尺寸由通道数 \times 高度 \times 宽度表示。

表 2 波系结构特征提取网络结构参数

Tab. 2 Architectural parameters of the wave system structure feature extraction network

网络架构	输入尺寸	是否使用 ReLU	输出尺寸
FC1	$1 \times 2 \times 15$	是	$1 \times 2 \times 20$
Deconv1	$1 \times 2 \times 20$	是	$32 \times 4 \times 40$
Deconv2	$32 \times 4 \times 40$	是	$16 \times 8 \times 80$
Deconv3	$16 \times 8 \times 80$	是	$14 \times 16 \times 160$
Deconv4	$14 \times 16 \times 160$	是	$10 \times 32 \times 320$
Conv1	$10 \times 32 \times 320$	是	$8 \times 16 \times 160$
Conv2	$8 \times 16 \times 160$	是	$20 \times 8 \times 80$
Max pool	$20 \times 8 \times 80$	否	$20 \times 4 \times 40$
Conv3	$20 \times 4 \times 40$	是	$20 \times 4 \times 40$
FC2	$20 \times 4 \times 40$	是	3 200
FC3	3 200	否	35×270

两次训练均使用在回归问题中表现较好的均方误差 (mean square error, MSE) 函数, 其计算公式为:

$$L_{\text{MSE}} = \frac{1}{N \cdot n} \sum_{i=1}^N \sum_{j=1}^n (f_{i,j} - f_{i,j}^*)^2 \quad (7)$$

表 3 波系细节特征增强网络结构参数

Tab. 3 Wave system detail features enhance network structural parameters

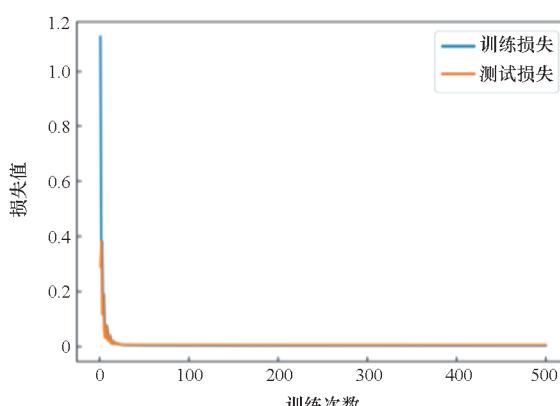
网络结构	输入尺寸	是否使用 ReLU	输出尺寸
波系结构特征提取网络	$1 \times 2 \times 15$		$1 \times 35 \times 270$
Conv1	$1 \times 35 \times 270$	是	$32 \times 35 \times 270$
残差块 -15	$32 \times 35 \times 270$	是	$32 \times 35 \times 270$
	$32 \times 35 \times 270$	否	$32 \times 35 \times 270$
Conv2	$32 \times 35 \times 270$	是	$1 \times 35 \times 270$

式中: L_{MSE} 表示均方误差损失函数; $f_{i,j}^*$ 为第 i 个样本的第 j 个像素点的 CFD 计算值; $f_{i,j}$ 为对应的模型预测值; N 表示每轮训练加载的数据组, 本研究设置为 256; n 为每张图像的总像素数, 由于预处理后的图像分辨率为 35 像素 \times 270 像素, 所以 $n=9450$ 。网络训练的优化器选择 Adam, batch size 设置为 256, 初始学习率设置为 0.001, 每 50 个轮次(epoch), 学习率下降 10%。

随着迭代的深入, 损失函数的下降速度逐渐减缓, 曲线变得更加平滑, 这表明模型开始精细调整参数, 以更好地拟合数据。波系结构特征提取网络训练和细节特征增强网络训练分别在 1 000 次和 500 次迭代后, 损失函数收敛至 0.001, 训练过程在此点终止。两部分训练集损失函数和测试集损失函数的变化如图 8 所示。

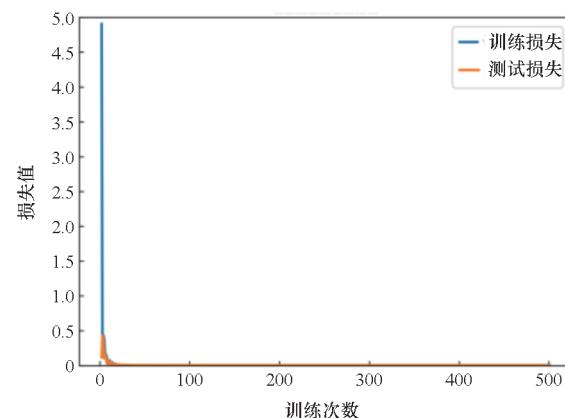
3.2 结果分析

本研究测试指标选用峰值信噪比 (peak signal-to-noise ratio, PSNR)、结构相似性系数 (structure similarity coefficient, SSIM) 和相关系数



(a) 波系结构特征提取网络训练与测试的损失函数变化曲线

(a) Change curve of loss function in training and testing of wave system structure feature extraction network



(b) 波系细节特征增强网络训练与测试的损失函数变化曲线图

(b) Change curve of loss function for training and testing of wave system detail feature enhancement network

图 8 损失函数变化曲线

Fig. 8 Loss function variation curve

(correlation coefficient, CORR)。PSNR 主要评估图像重构质量的误差, 通常以 dB 为单位表示。PSNR 值越大表示重构图像与原始图像越接近, 质量越好, 其计算公式为:

$$Q_p = 10 \cdot \lg \left(\frac{M^2}{L_{\text{MSE}}} \right) \quad (8)$$

式中, Q_p 表示 PSNR 的量化值, M 表示图像像素值的理论最大值, 本研究中 $M=255$ 。

SSIM 主要考虑图像结构的相似性, 旨在模拟人类视觉系统对图像质量的感知。SSIM 不仅考虑图像像素之间的误差, 还考虑了亮度、对比度和结构信息的相似性。SSIM 值的范围是 $[0, 1]$, 越接近 1, 表示重构图像与原始图像的相似度越高, 其计算公式为:

$$Q_s = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (9)$$

其中, Q_s 表示 SSIM 的量化值, μ_x 和 μ_y 分别是图像 x 和 y 的平均值, σ_x 和 σ_y 分别是图像 x 和 y 的方差, σ_{xy} 是图像 x 和 y 的协方差, C_1 和 C_2 是用于稳定计算的常数。

CORR 用于衡量两幅图像之间的线性相关程度, 反映了图像间的相似性。CORR 的取值范围是 $[-1, 1]$, 1 表示两幅图像完全正相关, -1 表示两幅图像完全负相关, 0 表示两幅图像无相关性, 其计算公式为:

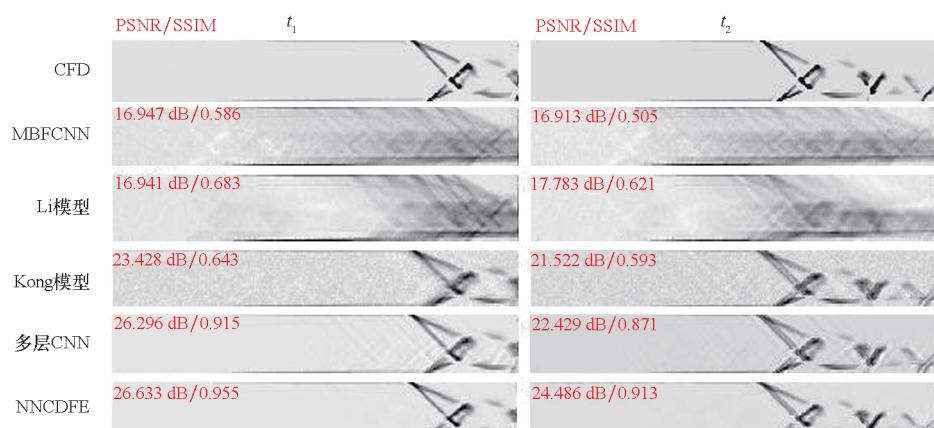
$$\rho(x, y) = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \cdot \sqrt{\sum (y_i - \bar{y})^2}} \quad (10)$$

式中, $\rho(x, y)$ 表示图像 x 和 y 的 CORR 值, x_i 和 y_i 分别是图像 x 和 y 的像素值, \bar{x} 和 \bar{y} 分别是图像 x 和 y 的平均值。

将 MBFCNN^[29]、Li 模型^[24]、Kong 模型^[27]和多层 CNN^[26]四个已提出的模型与本研究的 NNCDFE 进行对比。值得注意的是,多层 CNN 与 NNCDFE 波系结构特征提取网络结构相同,因此,可以作为去掉波系细节特征增强网络部分的 NNCDFE 与 NNCDFE 的模型性能对比。分别选取激波串前缘位于不同位置的流场重构结果,对应 $t_1 = 5.7$ ms、 $t_2 = 8.9$ ms、 $t_3 = 14.5$ ms 和 $t_4 = 21.9$ ms 四个不同时刻,与 CFD 计算结果进行对比,结果如图 9 所示。从图 9 可以看出,由于时刻往后激波逐渐稳定,变化不明显,神经模型对后面时刻流场图像足以拟合,五个模型在 t_4 时刻均能大致重构出激波结构。然而,MBFCNN 与 Li 模型在其他时刻的重构图像指标偏低,上壁面波系结

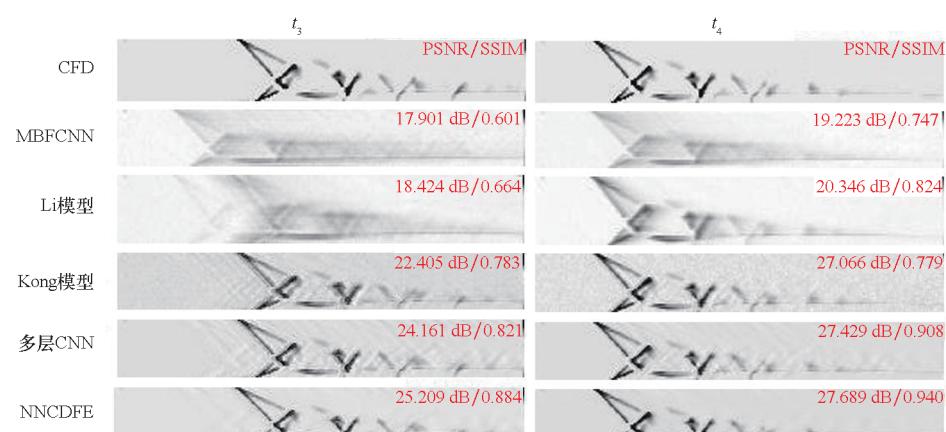
构不明显并且激波串有重影,重构质量较差。Kong 模型与多层 CNN 重构指标较好,激波串基本可以重构出来,但激波噪点较多。而 NNCDFE 重构的流场图像,PSNR 值均高于其他四种模型,且 NNCDFE 重构流场质量明显优于 MBFCNN 与 Li 模型,激波串波系结构细节清晰,更能体现激波结构演化规律,从而能够精准检测 STLE。

图 10 为五个模型重构流场图像在 t_1 、 t_2 、 t_3 和 t_4 四个不同时刻重构流场的绝对误差云图。由图 10 可知,MBFCNN 与 Li 模型明显误差较大, Kong 模型、多层 CNN 和 NNCDFE 的误差较小,误差主要分布在激波结构的内部区域,对整体结构的观察基本不构成影响,这表明 Kong 模型、多层 CNN 和 NNCDFE 都能有效地重构与隔离段流场的波系结构,而 NNCDFE 重构流场激波的主要特征和轮廓误差在所有模型中最小,因此,更能准确地预测出 STLE。



(a) t_1 与 t_2 时刻的重构指标对比

(a) Comparison of reconstruction indexes at t_1 and t_2



(b) t_3 与 t_4 时刻的重构指标对比

(b) Comparison of reconstruction indexes at t_3 and t_4

图 9 五个模型在四个不同时刻的重构指标对比

Fig. 9 Comparison of reconstruction metrics for five models at four different time points

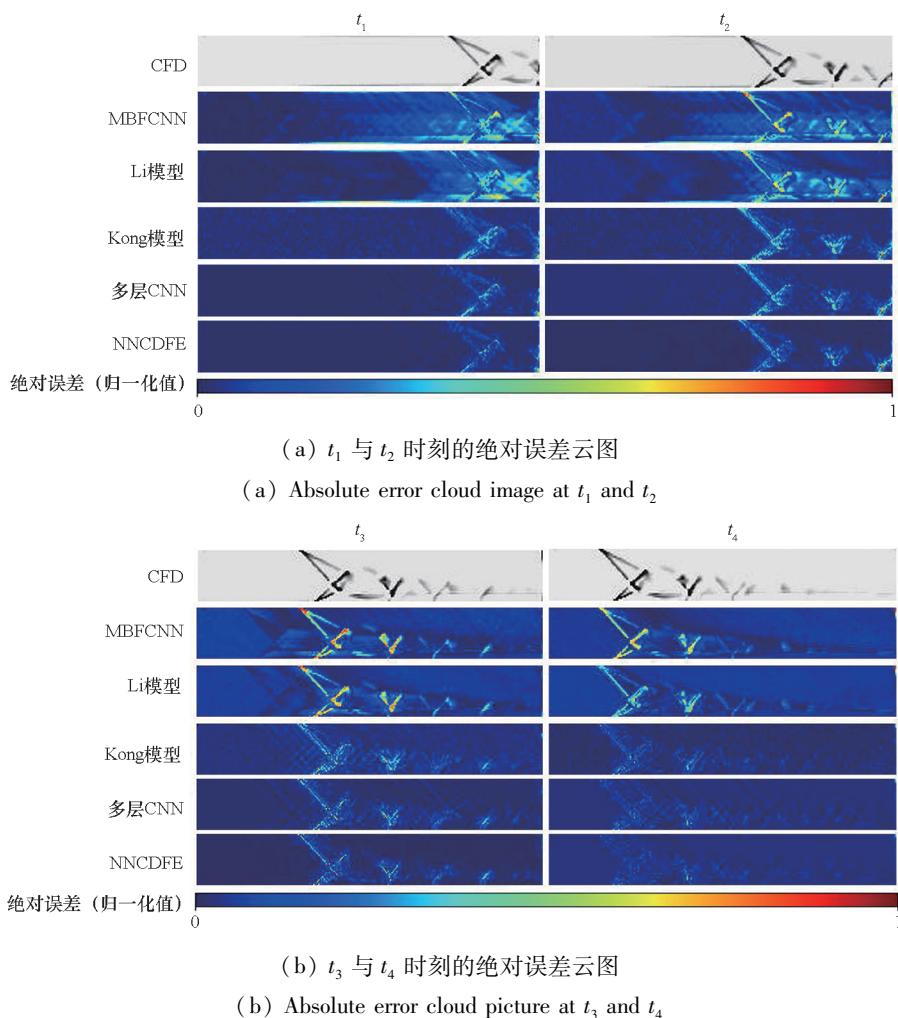


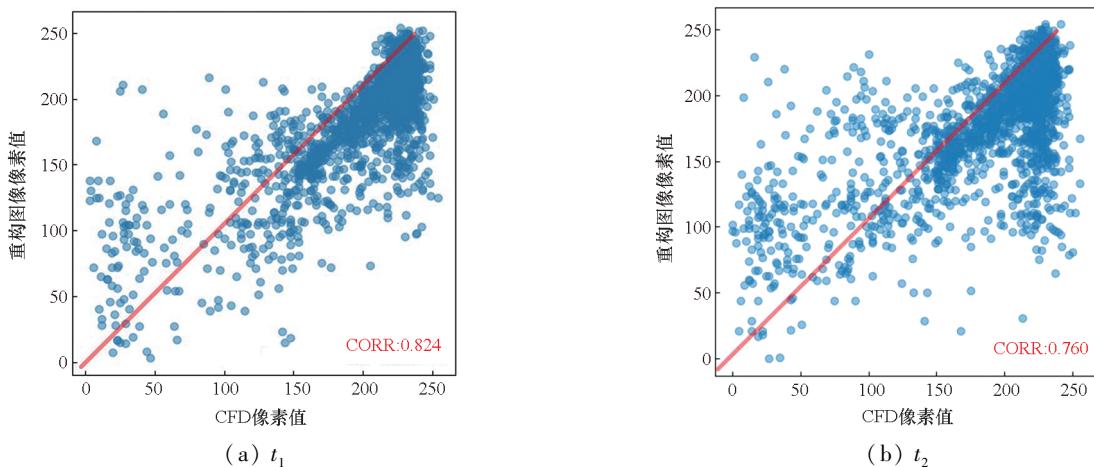
图 10 五个模型重构流场图像的绝对误差云图

Fig. 10 Absolute error cloud maps of reconstructed flow field images for five models

选取效果较好的 Kong 模型、多层 CNN 和 NNCDFE 进行进一步的像素散点分析和相关系数分析。图 11、图 12 和图 13 分别为三个模型重构流场图像在 t_1 、 t_2 、 t_3 和 t_4 四个时刻重构流场的像素散点分析和 CORR。散点图上的像素点在红线附近越密集排列表明两组数据的像素强度值越接近。可以直观得到, Kong 模型效果最差, NNCDFE 效果最好, 这说明基于 NNCDFE 的重构流场在数值上

与 CFD 计算结果一致性最高, 具有更丰富的波系结构特征, 同时相关系数能进一步量化预测流场与真实流场之间的线性相关程度。

为了客观评价五个模型的整体重构效果, 利用测试集计算五个模型的平均 PSNR 值、平均 SSIM 值和平均 CORR 值, 如表 4 所示。对表 4 中的平均指标进行分析可得, MBFCNN 模型的各项指标均最低, 模型性能最差。Li 模型在 SSIM 上



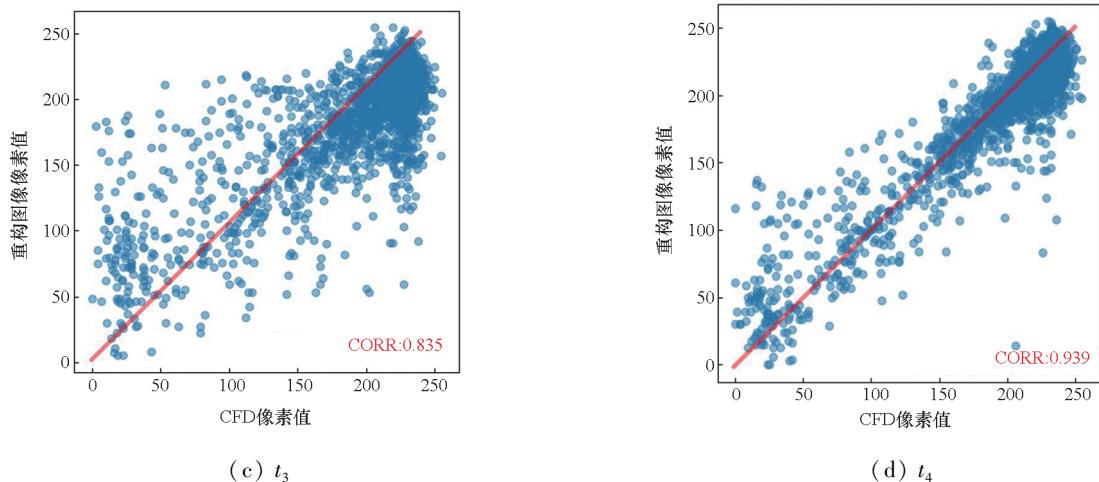


图 11 Kong 模型在四个时刻的像素散点图与相关系数

Fig. 11 Scatter plots of pixels and correlation coefficients of the Kong Model at four time points

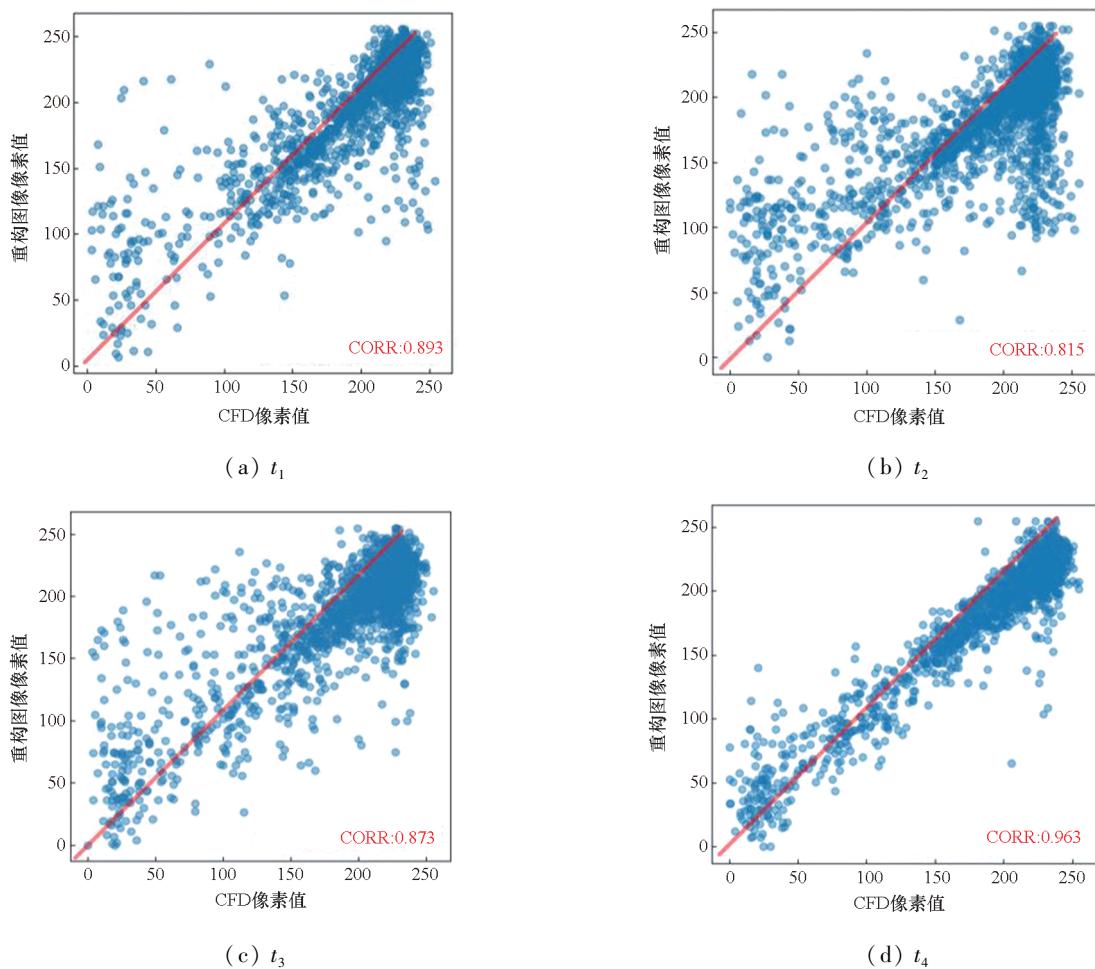


图 12 多层 CNN 在四个时刻的像素散点图与相关系数

Fig. 12 Scatter plots of pixels and correlation coefficients of multilayer CNN at four time points

略优于 Kong 模型,但其 PSNR 较低。Kong 模型与多层 CNN 则展现出较高的 PSNR 和 CORR 值,表明它们在像素误差控制和线性相关性方面表现更优。然而,NNCDFE 模型在三项评价指标上均

达到了最高值,与多层 CNN 相比,NNCDFE 在整个测试集上的平均 PSNR 提升了 9.5%。在五个模型中,NNCDFE 的平均指标最高,说明 NNCDFE 重构图像最清晰,模型性能最好。

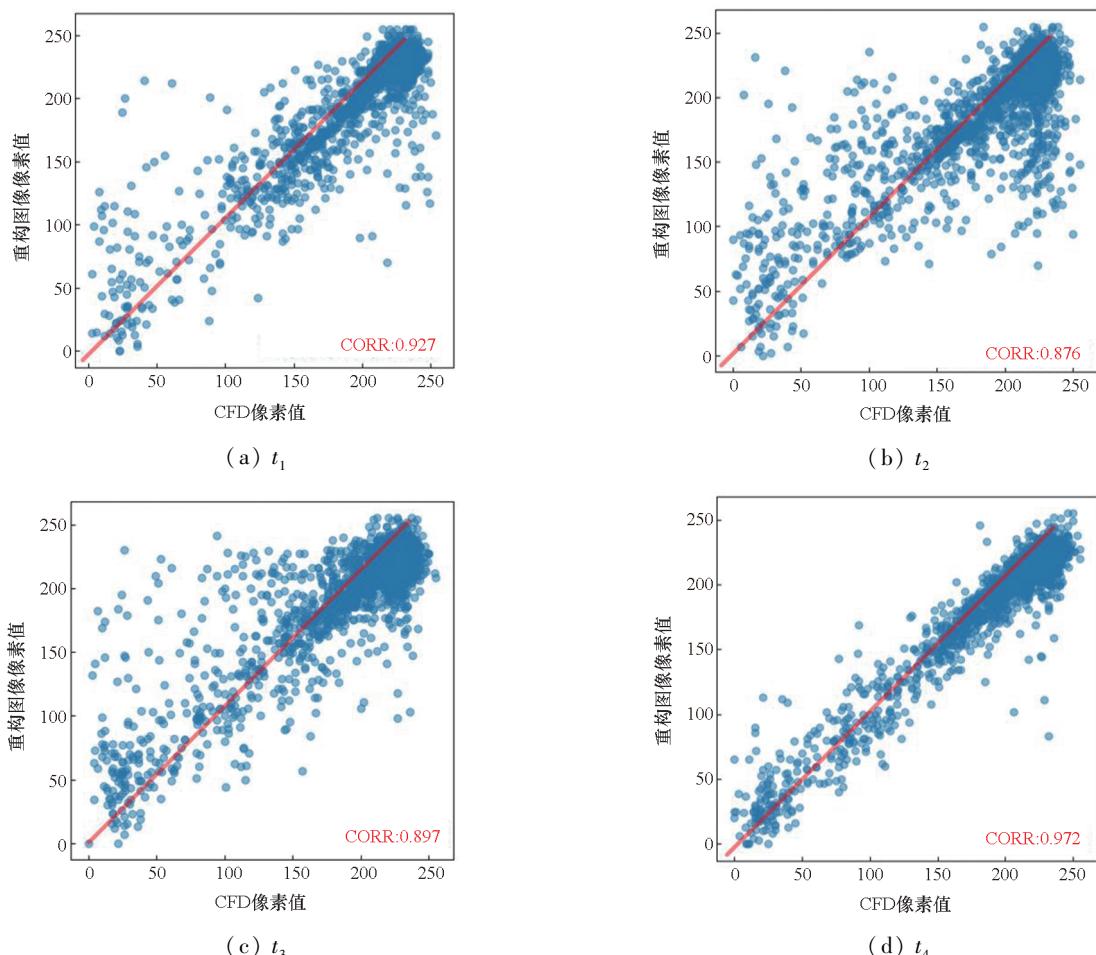


图 13 NNCDFE 在四个时刻的像素散点图与相关系数

Fig. 13 Scatter plots of pixels and correlation coefficients of NNCDFE at four time points

表 4 五个模型在测试集上的平均指标

Tab. 4 Average metrics on the test set for five models

模型	平均 PSNR/dB	平均 SSIM	平均 CORR
MBFCNN	17.508	0.594	0.390
Li 模型	18.052	0.671	0.500
Kong 模型	22.036	0.655	0.789
多层 CNN	22.529	0.833	0.830
NNCDFE	24.661	0.886	0.857

利用重构流场图像检测 STLE, 可以进一步验证模型重构效果。通过比较流场图像中上壁面和下壁面的激波分离点与进气道的距离, 确定 STLE, 并选取较短距离的分离点作为 STLE。由于从氢燃料喷注处开始出现激波串波形且进气道入口到氢燃料喷注长度为 269 mm, 流场重构图像的水平像素值为 270, 因此一个像素数约为 1 mm。STLE 如图 14 所示, 红圈表示 STLE, 与进气道的距离用 X 表示。

以此方式检测流场重构效果较好的 Kong 模



图 14 STLE 示意图

Fig. 14 Schematic diagram of STLE

型、多层 CNN 和 NNCDFE 重构图像中的 STLE, 并与数值模拟得到的 STLE 进行对比, 如图 15 所示。横坐标代表测试集中的 38 张流场图像数据, 纵坐标对应于通过图像检测得到的 STLE 水平像素值。可直观得到, 虽然三个模型在整体上都表现出不错的 STLE 预测效果, 但在个别数据, 例如第 6、第 8、第 21 组数据上, NNCDFE 预测的 STLE 与数值模拟之间的距离曲线吻合程度最高。

为了进一步验证模型的准确性, 计算三个模型的 STLE 平均误差精度。平均误差精度越小, 说明模型的预测性能和可靠性越高。对于流场图像 ($i = 1, 2, \dots, 38$), 平均误差精度 e_a 的计算公式为:

$$e_a = \left(\frac{\sum_{i=1}^{38} \left| \frac{X_s - X_d}{X_s} \right|}{38} \right) \times 100\% \quad (11)$$

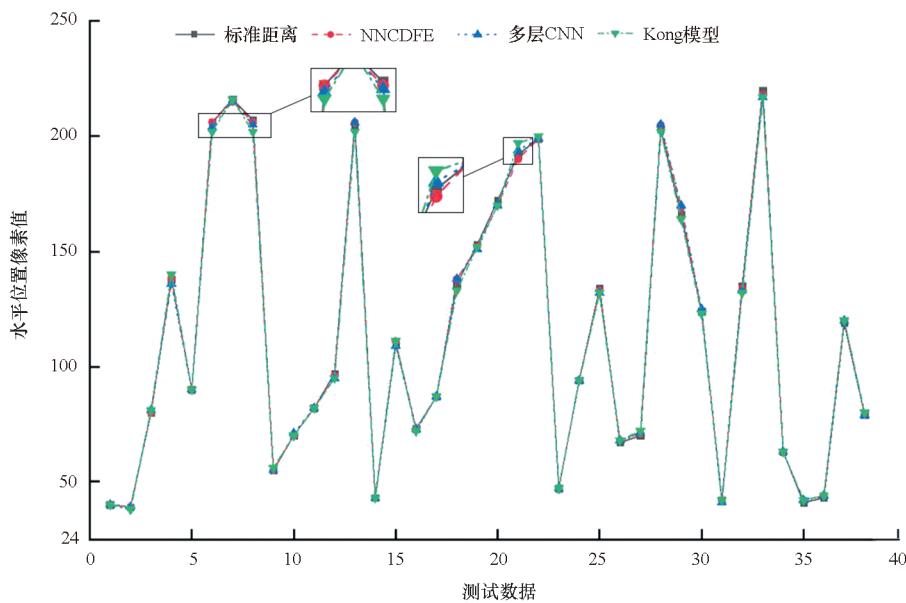


图 15 三个模型 STLE 与数值模拟结果对比

Fig. 15 STLE of the three models compared with numerical simulation results

式中, X_D 表示模型重构的 STLE, X_S 表示数值模拟的 STLE。

经计算, Kong 模型、多层 CNN 和 NNCDFE 的平均误差精度分别为 1.36%、1.08%、0.71%。在三个模型中, NNCDFE 的平均误差精度最小, 说明激波串前缘波系结构能被更准确地预测, 进而精准获取 STLE, 证明了本模型在流场重构任务上的出色表现。

为了研究不同上下壁面压力量对 NNCDFE 重构精度的影响, 进行稀疏压力量测试。分别将上下壁面压力量从 30 减少至 20、14、10, 并且这些压力量测点依然是从原来的 30 个压力量等间距选取。不同压力量重构测试集的平均结果指标如表 5 所示。可以直观看出, 随着压力量的减少, NNCDFE 模型平均 PSNR 指标依然保持在 23 dB 以上, 平均 SSIM 保持在 0.8 以上, 这证明 NNCDFE 具有较强的鲁棒性, 通过较少的压力量, 流场依然能实现较高质量的重构。

表 5 NNCDFE 模型不同压力量的重构结果平均指标

Tab. 5 Average index of reconstruction results of different pressure forces in NNCDFE model

压力量	平均 PSNR/dB	平均 SSIM	平均 CORR
30	24.661	0.886	0.857
20	23.564	0.837	0.831
14	23.461	0.878	0.845
10	23.354	0.859	0.802

4 结论

为解决超声速流场智能重构方法存在的复杂波系结构特征丢失、无法有效捕捉非定常流场的时间演化特性, 以及共同导致的 STLE 无法准确辨识等问题, 本文提出一种基于隔离段流场重构的 NNCDFE 方法, 将多层神经网络的特征提取能力与残差网络的细节增强能力有机地结合, 并利用数值模拟获取的隔离段流场数据集, 对该模型在稀疏压力量条件下的密度梯度场预测能力进行验证, 得到以下结论:

1) NNCDFE 模型通过组合式神经网络框架, 能够有效弥补多层卷积神经网络在特征提取时忽略的流场细节, 提高重构流场的细节, 从而提升 STLE 的检测精度。

2) 在隔离段流场数据集上的预测结果表明, 与其余四种方法相比, 本文所提出的 NNCDFE 方法的平均 PSNR、平均 SSIM 和平均 CORR 分别达到了 24.661 dB、0.886 和 0.857, 有着更高质量的重构精度, 体现了更加强大的模型性能。

3) 与数值模拟得到的 STLE 相比, NNCDFE 模型 STLE 的检测平均误差精度达到了 0.71%, 进一步证明模型重构波系细节清晰。

4) 随着输入压力量的减少, NNCDFE 性能没有明显下降, 证明了 NNCDFE 模型具有较强的鲁棒性, 能够基于稀疏压力量数据, 实现密度梯度场的高精度预测。

未来将通过集成更多流场特征和改进网络结构来进一步探索组合式网络学习方法在流场重构

方面的应用,进一步地提升流场重构的精度,以便对STLE进行直观检测。此外,还将拓展该方法在其他复杂流场环境中的应用,以验证其可扩展性,为冲压发动机的设计和控制提供更加精准和高效的解决方案。

参考文献(References)

- [1] HUTCHINSON R, LAWRENCE J, JOINER K F. Conceptual design and integration of a propulsion system for a supersonic transport aircraft [J]. Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, 2022, 236(3): 583–592.
- [2] HUBESCH R, MAZUR M, SELVAKANNAN P R, et al. Endothermic catalytic cracking of liquid hydrocarbons for thermal management of high-speed flight vehicles [J]. Sustainable Energy & Fuels, 2022, 6(7): 1664–1686.
- [3] PRISELL E. The scramjet: a solution for hypersonic aerodynamic propulsion[C]//Proceedings of the 41st AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit, 2005.
- [4] ZHI C, YI S H, ZHU Y Z, et al. Investigation on flows in a supersonic isolator with an adjustable cowl convergence angle[J]. Experimental Thermal and Fluid Science, 2014, 52: 182–190.
- [5] LEWIS M. X – 51 scrams into the future [J]. Aerospace America, 2010, 48(9): 26–31.
- [6] YU K K, XU J L, LIU S, ET AL. Starting characteristics and phenomenon of a supersonic wind tunnel coupled with inlet model[J]. Aerospace Science and Technology, 2018, 77: 626–637.
- [7] JI Y, HE M S, HUANG X B, et al. Influence of the rising rate of backpressure on the upstream motion characteristics of the shock train in a scramjet isolator[J]. Physics of Fluids, 2023, 35(4): 041708.
- [8] MATSUO K, MIYAZATO Y, KIM H D. Shock train and pseudo-shock phenomena in internal gas flows[J]. Progress in Aerospace Sciences, 1999, 35(1): 33–100.
- [9] GNANI F, ZARE-BEHTASH H, KONTIS K. Pseudo-shock waves and their interactions in high-speed intakes [J]. Progress in Aerospace Sciences, 2016, 82: 36–56.
- [10] WANG Z A, CHANG J T, LI Y M, et al. Oscillation of the shock train under synchronous variation of incoming Mach number and backpressure [J]. Physics of Fluids, 2022, 34(4): 046104.
- [11] LI N. Response of shock train to fluctuating angle of attack in a scramjet inlet-isolator[J]. Acta Astronautica, 2022, 190: 430–443.
- [12] CAI F C, HUANG G H, LIU X W. Investigation of shock wave oscillation suppression by overflow in the supersonic inlet[J]. Energies, 2022, 15(11): 3879.
- [13] HUTZEL J, DECKER D, COBB R, et al. Scramjet isolator shock train location techniques[C]//Proceedings of the 49th AIAA Aerospace Sciences Meeting Including the New Horizons Forum and Aerospace Exposition, 2011.
- [14] DONBAR J. Shock train position control in an axisymmetric scramjet combustor flowpath [C]//Proceedings of the 48th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit, 2012.
- [15] LE D B, GOYNE C P, KRAUSS R H. Shock train leading-edge detection in a dual-mode scramjet [J]. Journal of Propulsion and Power, 2008, 24(5): 1035–1041.
- [16] HUTZEL J R. Scramjet isolator modeling and control [D]. Ohio: Air Force Institute of Technology, 2011.
- [17] CHEN L Y, LI S B, BAI Q, et al. Review of image classification algorithms based on convolutional neural networks[J]. Remote Sensing, 2021, 13(22): 4712.
- [18] ZOU Z X, CHEN K Y, SHI Z W, et al. Object detection in 20 years: a survey [J]. Proceedings of the IEEE, 2023, 111(3): 257–276.
- [19] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups [J]. IEEE Signal Processing Magazine, 2012, 29(6): 82–97.
- [20] CHEN Y T, LIU L W, PHONEVILAY V, et al. Image super-resolution reconstruction based on feature map attention mechanism[J]. Applied Intelligence, 2021, 51: 4367–4380.
- [21] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2017.
- [22] MONFORT M, LUCIANI T, KOMPERDA J, et al. A deep learning approach to identifying shock locations in turbulent combustion tensor fields[M]// SCHULTZ T, ÖZARSLAN E, HOTZ I. Modeling, Analysis, and Visualization of Anisotropy. Cham: Springer, 2017: 375–392.
- [23] LIU Y, LU Y T, WANG Y Q, et al. A CNN-based shock detection method in flow visualization [J]. Computers & Fluids, 2019, 184: 1–9.
- [24] LI Y F, CHANG J T, KONG C, et al. Flow field reconstruction and prediction of the supersonic cascade channel based on a symmetry neural network under complex and variable conditions[J]. AIP Advances, 2020, 10(6): 065116.
- [25] 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.
- [26] CHEN H, TIAN Y, GUO M M, et al. Flow field reconstruction and shock train leading edge position detection of scramjet isolation section based on a small amount of CFD data[J]. Advances in Aerodynamics, 2022, 4: 28.
- [27] KONG C, CHANG J T, WANG Z A, et al. Prediction model of flow field in an isolator over various operating conditions[J]. Aerospace Science and Technology, 2021, 111: 106576.
- [28] KONG C, CHANG J T, WANG Z A, et al. Data-driven super-resolution reconstruction of supersonic flow field by convolutional neural networks[J]. AIP Advances, 2021, 11: 065321.
- [29] CHEN H, GUO M M, TIAN Y, et al. Intelligent reconstruction of the flow field in a supersonic combustor based on deep learning [J]. Physics of Fluids, 2022, 34: 035128.
- [30] DENG X, GUO M M, CHEN H, et al. Dual-path flow field reconstruction for a scramjet combustor based on deep learning[J]. Physics of Fluids, 2022, 34: 095118.
- [31] FENG Y, CHENG Y. Short text sentiment analysis based on multi-channel CNN with multi-head attention mechanism[J]. IEEE Access, 2021, 9: 19854–19863.
- [32] LIU B, TANG J P, HUANG H B, et al. Deep learning methods for super-resolution reconstruction of turbulent flows[J]. Physics of Fluids, 2020, 32: 025105.