

文章编号: 1000-8055(2024)12-20230071-08

doi: 10.13224/j.cnki.jasp.20230071

# 基于深度学习的湍流火焰三维羟基浓度场的时间超分辨率成像

钟 越<sup>1,2</sup>, 蔡敏男<sup>1</sup>, 徐文江<sup>1</sup>, 杨 帆<sup>1,2</sup>

(1. 厦门大学 航空航天学院, 福建 厦门 361005;

2. 厦门大学 厦门市大数据智能分析与决策重点实验室, 福建 厦门 361005)

**摘 要:** 针对火焰三维羟基浓度场的高速测量难度大、成本昂贵的问题, 提出一种基于深度学习的帧重建模型 Cycle-3D-CNN, 用于连续时间的湍流火焰三维羟基浓度场数据。使用基于循环一致性的三维卷积神经网络(3D-CNN), 以数值驱动的方式实现了更高的时间分辨率。在实验分析中使用该模型分别实现了三维羟基浓度场时间序列的 2 倍和 3 倍时间分辨率提升, 验证了其良好的重建性能。在两种实验结果中, 峰值信噪比(PSNR)均值分别达到了 33.57 dB 和 30.37 dB, 结构相似性(SSIM)指数分别达到了 0.899 和 0.813, 均优于传统的帧重建方法。

**关 键 词:** 湍流燃烧; 羟基自由基; 时间超分辨率; 循环一致性模型; 深度学习

中图分类号: V231; TK12

文献标志码: A

## Temporal super-resolution imaging of 3D OH concentration field in turbulent flame based on deep learning

ZHONG Yue<sup>1,2</sup>, CAI Minnan<sup>1</sup>, XU Wenjiang<sup>1</sup>, YANG Fan<sup>1,2</sup>

(1. School of Aerospace Engineering, Xiamen University, Xiamen Fujian 361005, China;

2. Xiamen Key Laboratory of Big Data Intelligent Analysis and Decision,

Xiamen University, Xiamen Fujian 361005, China)

**Abstract:** In response to the difficulty and high cost of high-speed measurement of flame hydroxyl concentration field, a Cycle-3D-CNN model based on deep learning was proposed for temporal reconstruction of three-dimensional (3D) hydroxyl concentration fields in turbulent flames. It achieved a higher temporal resolution by utilizing a data-driven approach with a 3D convolutional neural network (3D-CNN) based on cycle consistency. In the experimental analysis, the model was used to achieve a two-fold and three-fold increase in temporal resolution of the 3D hydroxyl concentration field time series, respectively. In both experimental results, the mean peak signal-to-noise ratio (PSNR) reached 33.57 dB and 30.37 dB, respectively, the structural similarity (SSIM) indices reached 0.899 and 0.813, respectively, outperforming traditional frame reconstruction method.

**Keywords:** turbulent combustion; OH radical; temporal super-resolution; cycle-consistent model; deep learning

收稿日期: 2023-02-13

基金项目: 国家自然科学基金面上项目(62173282); 国家自然科学基金青年基金(52006184);

厦门市自然科学基金面上项目(3502Z20227180); 科技部科技创新 2030—“新一代人工智能”重大项目(2021ZD0112600)

作者简介: 钟越(1999—), 女, 硕士生, 主要从事基于深度学习的流场重建研究。

引用格式: 钟越, 蔡敏男, 徐文江, 等. 基于深度学习的湍流火焰三维羟基浓度场的时间超分辨率成像[J]. 航空动力学报, 2024, 39(12): 20230071. ZHONG Yue, CAI Minnan, XU Wenjiang, et al. Temporal super-resolution imaging of 3D OH concentration field in turbulent flame based on deep learning[J]. Journal of Aerospace Power, 2024, 39(12): 20230071.

湍流火焰三维结构的分析有助于对湍流-化学等相关基础物理现象的理解。其中,羟基(OH)自由基作为碳氧反应中常见的中间产物之一,其三维分布对燃烧过程中的火焰结构特征的分析具有重要意义。对 OH 自由基的研究主要集中为二维平面测量。例如,何赞等利用平面激光诱导荧光技术(PLIF)对直流燃烧室内乙烯和氢气的燃烧场进行 OH-PLIF 测量<sup>[1]</sup>,探究了该直流式燃烧室环境下火焰得以稳定燃烧的原因。陈晓丽等在对同轴射流火焰的 OH-PLIF 信号进行测量时<sup>[2]</sup>,结合火焰自发光信号分析了射流火焰中热释放速率(HRR)的分布特征,探究了射流火焰的结构特征。由于火焰反应过程中的高度动态变化,丰富且连续变化的结构信息有助于对燃烧场的瞬态化学反应进行分析。但是受实际光学成像系统成像时间分辨率的限制,以及存储和传输大容量数据所带来的困难,所获得的 OH 自由基测量结果的时间分辨率常常不高。因此需要一种新的方法,不仅能实现 OH 自由基组分浓度(质量分数)的三维测量,也能提升其时间分辨率,进而在三维空间和时间层面实现对 OH 自由基组分浓度的双重分析。

近年来,基于深度学习的图像重建技术在解决复杂三维重建问题方面取得重要的进展<sup>[3-5]</sup>,并开始被应用于湍流火焰的燃烧诊断工作中。例如,Xu 等将深度学习技术应用到湍流火焰三维层面的研究,基于生成对抗网络(GAN)提出射流火焰的三维超分辨率重建网络(3D-SRGAN)<sup>[6]</sup>,实现了射流火焰三维温度场在空间各方向上 2 倍即总体素数 8 倍的提升。Guo 等人在实现湍流火焰的 OH 平面成像时,基于卷积长短时记忆网络(CONV-LSTM)加速了湍流火焰中 OH-PLIF 信号的高速平面成像<sup>[7]</sup>,利用数值驱动的方式提高了平面光学测量过程的时间分辨率。然而,上述深度学习算法在燃烧诊断中的应用只解决了三维空间分辨率的提升和二维 PLIF 数据的帧重建问题,并未涉及到三维结构的时间分辨率提升。

为进一步探究湍流火焰的高频结构特征,本文提出一种基于循环一致性<sup>[8]</sup>的三维卷积神经网络(3D-CNN)<sup>[9]</sup>,称为 Cycle-3D-CNN,并在实验中实现了三维 OH 浓度场的 2 倍和 3 倍时间分辨率提升,验证了其有效性。


## 1 数据样本库的准备

本文使用数值模拟的湍流火焰三维结构并提

取其 OH 浓度场来生成训练所需要的数据集。虽然直接使用物理实验数据是最为理想的方式,但由于物理实验条件严格,获取相应的二维 OH-PLIF 数据并将其复原至精确的三维结构需要较复杂的步骤,难度较大。同时,本文研究的核心问题是验证所提出的深度学习算法用于湍流火焰三维 OH 浓度场帧重建的可行性,已有研究表明使用数值模拟数据也可验证<sup>[10-12]</sup>。

本研究使用大涡模拟(LES)对 CH<sub>4</sub>/空气扩散火焰进行数值模拟来生成三维湍流火焰数据<sup>[13-14]</sup>,随后提取相应的 OH 自由基三维组分浓度场。之所以选择这种模拟火焰,是因为其不仅多用于计算流体力学(CFD)的模拟与实验,而且具有强烈的湍流-化学反应和较明显的温度梯度,其可行性已得到前人的阐述与证明<sup>[15-16]</sup>。该火焰的燃烧过程描述如下:部分预混的甲烷/空气流从直径 7.2 mm 的中心喷嘴射出,同时周围环绕引燃火焰和空气共流,根据实验测量相应地确定模拟过程中主射流、引燃火焰和空气共流的边界条件。控制方程是基于 16 组分骨架的 CH<sub>4</sub>/空气化学反应机理的 Navier-Stokes(N-S)方程,并通过有限体积法进行求解<sup>[17]</sup>,在数值模拟过程中使用 Smagorinsky-Lily 子网格比例模型封闭控制方程,火焰雷诺数为 8 200。为了能够捕捉到火焰的动态特性,增量时间步长设置为  $1 \times 10^{-5}$  s。另外,采用涡耗散概念(EDC)模型来考虑湍流-化学反应的相互作用,该模型假设分子混合后的燃烧反应发生于小涡中<sup>[18]</sup>。

图 1 为模拟的三维 OH 浓度场的可视化展示,其中 X、Y、Z 轴的坐标单位均为体素(voxel)。图 1(a)~图 1(d)的( $V_0, V_1, V_2, V_3$ )表示 5 个连续序列时刻的三维 OH 浓度场,时间间隔为  $1 \times 10^{-3}$  s。可以看出所模拟的湍流火焰数据具有明显的纹理细节,可以为深度学习提供足够的特






图 1 湍流火焰三维 OH 浓度场可视化渲染

Fig. 1 3D OH concentration field of turbulent flame

征信息。所模拟的火焰数据共计 300 个时刻, 按照 7 : 1 : 2 的比例划分为训练集、测试集和验证集。训练集和验证集用于训练过程中网络参数的更新, 测试集则用于评测网络性能。

## 2 Cycle-3D-CNN 网络结构

3D-CNN 本身能够实现不同倍数时间分辨率的帧重建功能。但为了进一步提升帧重建质量, 本文参考了 Liu、Reda 等关于循环一致性架构用于视频帧重建的工作<sup>[19-20]</sup>, 采用两阶段训练的方式将 3D-CNN 嵌入到循环一致性架构中。这种两阶段训练的模型架构可以有效保障神经网络训练的稳定性, 本文称之为 Cycle-3D-CNN。

图 2 展示了用于三维 OH 浓度场帧重建的 3D-CNN 模块的详细结构, 其中不同颜色的矩形代表不同的操作。首先, 将两个相邻时间序列的低时间分辨率的三维 OH 浓度场数据输入模型中, 通过三维卷积层(Conv3D)来提取数据的深度特征。其中,  $k=3$  表示卷积核大小固定为  $3 \times 3 \times 3$ , 步长  $s$  固定为 5, 输出通道数量  $c$  由 32 增加至 64 来提取数据的深度特征。在激活函数的选择上, 本文采用了 PReLU, 该激活函数通过引入自适应可变参数, 在几乎不增加计算量的前提下, 可有效改善过拟合问题, 并加快网络的收敛速度<sup>[21]</sup>。在经过两层通道数为 64 的三维卷积操作后, 减少卷积输出通道数量至 32, 将数据映射至低维空间。接下来, 使用了 8 层相同的三维卷积层来进一步提取特征, 步长  $s=3$ , 输出通道数量  $c=32$ 。最后, 通过改变输出通道的数量来决定输出不同倍数时间分辨率的帧重建结果。当输出通道数为 1 时, 实现双倍时间分辨率帧重建(记为 3D-CNN-1);




图 2 3D-CNN 模块网络结构

Fig. 2 Network structure of 3D-CNN model

当输出通道数为 2 时, 实现 3 倍时间分辨率帧重建(记为 3D-CNN-2)。

为了避免上述模型所输出的帧重建结果过于平滑, 本文进一步引入了循环一致性架构。该架构使用递归的方式重建帧, 能够使重建结果更加贴近真实数据<sup>[19]</sup>。训练过程分为两个阶段: 在第 1 阶段中, 使用 3D-CNN 网络训练 100 个 epoch, 目的是使网络具备一定的帧重建能力; 在第 2 阶段中, 使用了镶嵌循环一致性架构的 3D-CNN(即 Cycle-3D-CNN)训练 100 个 epoch, 进一步优化网络的帧重建效果。相比仅使用原始数据进行单次帧重建的第 1 阶段, 第 2 阶段采用递归的方式重建帧, 其包含两个过程: 首先将原始的三维 OH 浓度场数据输入模型中, 得到中间帧的重建结果; 再将上一步得到的中间帧重建结果再次输入到模型中, 得到原始输入帧的重建结果, 该重建结果将被用于计算循环一致性损失。

针对图 2 中的两种 3D-CNN 模块(3D-CNN-1 和 3D-CNN-2), 在应用循环一致性架构后, 可以得到两种 Cycle-3D-CNN 模型, 分别用于实现双倍时间分辨率帧重建和 3 倍时间分辨率帧重建。图 3 (a)和图 3 (b)分别对应双倍和 3 倍时间分辨率的帧重建流程。如图所示, 在每个重建流程中, 第 1 列表示原始的输入帧; 第 2 列为 1 次帧重建得到的中间帧重建结果; 而第 3 列即为经过 2 次

帧重建得到的原始输入帧的重建结果。以双倍时间分辨率帧重建过程为例,在图 3(a)所示的重建流程中,  $(V_0, V_1, V_2, V_3, V_4)$  表示 5 个连续序列时刻的三维 OH 浓度场, 首先将  $(V_0, V_2)$  和  $(V_2, V_4)$  分别输入到 3D-CNN-1 模块中, 得到中间帧  $V'_1$  和  $V'_3$ , 随后将  $(V'_1, V'_3)$  再次输入到 3D-CNN-1 模块中, 进而求得原始输入帧的重建结果  $V''_2$ 。




图 3 Cycle-3D-CNN 完整流程图

Fig. 3 Structure of Cycle-3D-CNN model

由于采取了两阶段的训练方式, 不同阶段使用的损失函数也不相同。在第 1 阶段中, 仅执行对原始三维 OH 浓度场序列的单次帧重建任务, 损失函数  $L_{1\text{-stage}}$  包括重建损失  $L_r$  和感知损失  $L_p$  两部分。第 2 阶段的损失函数  $L_{2\text{-stage}}$  在第 1 阶段的基础上增加了循环一致性损失  $L_c$ 。两个阶段所使用的损失函数如式(1)和式(2)所示, 其中  $\alpha$ 、 $\beta$ 、 $\gamma$  为可调参数, 在本文实验中为简便起见均设为 1。

$$L_{1\text{-stage}} = L_r + \alpha L_p \quad (1)$$

$$L_{2\text{-stage}} = L_r + \beta L_p + \gamma L_c \quad (2)$$

以图 3(a)展示的双倍时间分辨率帧重建流程为例, 其重建损失  $L_r$ 、感知损失  $L_p$  以及循环一致性损失  $L_c$  可以通过如下公式计算:

$$L_r = \|V_1 - V'_1\|_1 + \|V_3 - V'_3\|_1 \quad (3)$$

$$L_p = \|g(V_1) - g(V'_1)\|_1 + \|g(V_3) - g(V'_3)\|_1 \quad (4)$$

$$L_c = \|V_2 - V''_2\|_1 \quad (5)$$

其中  $g(\cdot)$  表示经过预训练的三维 VGG19 模型<sup>[22]</sup>, 用于提取特征计算损失。同理, 参考图 3(b), 设单次循环一致性训练的数据为 7 个连续序列时刻的三维 OH 浓度场  $(V_0, V_1, V_2, V_3, V_4, V_5, V_6)$ , 定义 3 倍时间分辨率帧重建任务的 3 种损失如下:

$$L_r = \|V_1 - V'_1\|_1 + \|V_2 - V'_2\|_1 + \|V_4 - V'_4\|_1 + \|V_5 - V'_5\|_1 \quad (6)$$

$$L_p = \|g(V_1) - g(V'_1)\|_1 + \|g(V_2) - g(V'_2)\|_1 + \|g(V_4) - g(V'_4)\|_1 + \|g(V_5) - g(V'_5)\|_1 \quad (7)$$

$$L_c = \|V_2 - V''_2\|_1 + \|V_3 - V''_{3.1}\|_1 + \|V_3 - V''_{3.2}\|_1 + \|V_4 - V''_4\|_1 \quad (8)$$

### 3 结果与讨论

本节从定量和定性的角度评估了所提出的 Cycle-3D-CNN 的帧重建性能, 并将重建结果与其余 4 种常见的帧重建方法对比来证明其优越性。

#### 3.1 定量评估指标

本节使用的评估指标包括均方差(MSE, 记为  $e_{ms}$ )、峰值信噪比(PSNR, 记为  $R_{psn}$ )、插值误差(IE, 记为  $e_i$ )和结构相似性(SSIM, 记为  $M_{ssi}$ )<sup>[23-24]</sup>。其中, MSE 由各体素点一一对应计算其差值:

$$e_{ms} = \frac{1}{XYZ} \sum_{i=0}^{X-1} \sum_{j=0}^{Y-1} \sum_{k=0}^{Z-1} \|V_t - V_f\| \quad (9)$$

其中  $V_t$  代真实样本,  $V_f$  代表网络重建结果。MSE 越小, 代表两者之间误差越小, 即重建质量越高。PSNR 定义如下所示:

$$R_{psn} = 10 \cdot \lg \left( \frac{V_{\max}^2}{e_{ms}} \right) \quad (10)$$

其中  $V_{\max}$  表示三维 OH 浓度场数据的最大体素值。显然, PSNR 与 MSE 负相关, PSNR 越大, 帧重建质量越高。IE 与 MSE 呈正相关, 定义如下:

$$e_i = \sqrt{\frac{\sum_{i=0}^{X-1} \sum_{j=0}^{Y-1} \sum_{k=0}^{Z-1} (V_t - V_f)^2}{XYZ}} \quad (11)$$

SSIM 指标可从感知的角度衡量重建结果与

原始数据之间的相似程度,其定义如下:

$$M_{\text{ssi}}(V_t, V_f) = \frac{(2\mu_1\mu_2 + m)(2\sigma_{12} + n)}{(\mu_1^2 + \mu_2^2 + m)(\sigma_1^2 + \sigma_2^2 + n)} \quad (12)$$

其中  $\mu$  和  $\sigma$  分别表示帧重建结果和原始样本的平均值和方差,  $m$  和  $n$  为两个常量,其作用为保证计算时的稳定性。在实际计算中,SSIM 首先在子窗口上计算,然后平均到全尺度上形成全局值。

### 3.2 对比算法

本节引入 4 种常见的帧重建方法,并与所提出 Cycle-3D-CNN 模型进行对比。4 种对比方法如下所述: 平均法(averaging method),该方法简单直接,通过对首尾两帧加权求和的方式来计算中间帧; 光流法(super SloMO)<sup>[25]</sup>: 通过估算体素点的位移关系来计算中间帧,常用于解决二维数据的时间分辨率问题,首先通过编码器将输入序列压缩为一个隐藏的张量,然后通过解码器将其展开,计算并细化相邻帧之间的双向光流,然后预估中间帧和邻帧之间的光流,进而计算得到中间帧结果; 残差光流法(RRIN)<sup>[26]</sup>,其核心是使用残差网络结合光流法合成中间帧,并加入自适应权重来改善重建质量; 注意力机制帧重建法(CAIN)<sup>[27]</sup>,

利用 PixelShuffle 来完成特征提取工作,使用注意力机制取代光流计算模块,将特征信息拉伸到多个维度,进而实现中间帧的合成。

### 3.3 重建结果定量与定性分析

上述 4 种方法均使用与本文提出的 Cycle-3D-CNN 基于相同的训练数据集和相同的迭代步数来完成训练工作,并使用相同的测试集来评测。图 4 展示了在 30 个测试数据上,双倍时间分辨率帧重建结果的定量指标评估。可以看出,在 5 种重建结果中, Cycle-3D-CNN 的重建结果明显优于其他 4 种模型的结果,有着最高的 PSNR 和 SSIM 分布,其均值分别为 33.57 dB 和 0.899; 同时,有着最低的 IE 和 MSE 分布,其均值分别为  $2.1 \times 10^{-2}$  和  $4.6 \times 10^{-4}$ 。而在 4 种对比方法中重建结果最好的 CAIN 模型对应的 PSNR、SSIM、IE、MSE 指标均值分别为 31.1 dB、0.83、 $2.8 \times 10^{-2}$  和  $7.9 \times 10^{-4}$ , 差异显著。

图 5 展示了在 30 个测试数据上 3 倍时间分辨率帧重建结果的定量指标评估。与上述的双倍时间分辨率帧重建结果一致, Cycle-3D-CNN 优于其他 4 种方法,有着最高的 PSNR 和 SSIM 分布,




图 4 30 个测试数据的双倍时间分辨率帧重建结果定量评估

Fig. 4 Quantitative evaluation of the frame reconstruction results of double temporal resolution for 30 test data




图 5 30 个测试数据的 3 倍时间分辨率帧重建结果定量评估

Fig. 5 Quantitative evaluation of the frame reconstruction results of triple temporal resolution for 30 test data

其均值分别为 30.37 dB 和 0.813; 有着最低的 IE 和 MSE 分布, 其均值分别为  $3 \times 10^{-2}$  和  $9.4 \times 10^{-4}$ 。而在 4 种对比方法中重建结果最好的 CAIN 模型对应的 PSNR、SSIM、IE、MSE 指标均值分别为 29.4 dB、0.781、 $3.4 \times 10^{-2}$  和  $1.2 \times 10^{-3}$ , 差异显著。另外, 可以看出, 与双倍时间分辨率帧重建相比, 3 倍时间分辨率的重建质量略有下降, 这是由重建时间分辨率升高所带来的正常现象。

为了更加直观地展示重建结果, 除 Cycle-3D-CNN 之外, 选取定量评估结果中较好的 CAIN 和平均法的重建结果进行视觉对比。图 6(a)~图 6(d) 从三维视角呈现出 3 种方法的双倍时间分辨率帧重建结果, 其中图 6(a) 为真实数据, 图 6(b)~图 6(d) 分别为 3 种方法的重建结果。三维绘图受角度和遮挡的限制, 无法清晰地辨别出几种重建结果的区别, 因此提取其相应的二维中心切片并且进行二值化处理, 以进行更直观的比较。如图 6(e)~图 6(h) 所示, 相比于 CAIN 和平均法, Cycle-3D-CNN 模型的帧重建结果在视觉上更接近于原始数据, 例如在图 6(e)~图 6(h) 中红色矩形所在的顶部区域, 可以明显地观察到

Cycle-3D-CNN 模型可以更加精细地恢复出原始数据的纹理特征, 而 CAIN 和平均法的重建结果均与真实样本存在相当程度的误差, 无法恢复出流动细节。




图 6 双倍时间分辨率帧重建结果视觉对比

Fig. 6 Visual comparison of the frame reconstruction results of double temporal resolution

图 7 展示了 3 倍时间分辨率帧重建结果的可视化对比。采用相同的策略, 图 7(a)~图 7(d) 和图 7(e)~图 7(h) 分别从二维视角展示了 3 种方法的重建结果与真实样本的视觉比较。同样地, 在火焰顶部的红色矩形所示区域, 可以明显观察到 Cycle-3D-CNN 模型相比于 CAIN 和平均法可以更加准确地恢复出湍流火焰的纹理细节。至此, 本文从定性分析的角度展示了 Cycle-3D-CNN 模型相比于传统帧重建方法的优越性。

图 8 进一步从一维视角对 3 种方法的重建结果进行补充验证。图 8(a)~图 8(b) 和图 8(c)~图 8(d) 分别展示了在双倍时间分辨率和 3 倍时间分辨率的重建结果中真实数据与 3 种重建结果沿着  $Z=120$  voxel 和  $Z=160$  voxel 两处位置的强度分布, 对应于图 6(e)~图 6(h) 和图 7(e)~图 7(h) 中两条红色水平线所示的位置。图 8 的横坐标 voxel number 表示该水平线上的坐标值, 纵坐标 intensity 表示在该位置 OH 组分的分布强度。对比结果显示, 在两种情况下, Cycle-3D-CNN 模型的帧重建结果均呈现出了更贴合原始数据的强度分布, 而其余两种方法的重建结果偏




图 7 3 倍时间分辨率帧重建结果视觉对比

Fig. 7 Visual comparison of the frame reconstruction results of triple temporal resolution




图 8 双倍和 3 倍时间分辨率帧重建结果的强度分布对比

Fig. 8 Intensity comparison of the frame reconstruction results of double and triple temporal resolution

差更显著。

## 4 结 论

本文通过结合 3D-CNN 与循环一致性架构,建立了湍流火焰三维 OH 浓度场的帧重建模型,以每两个连续帧的三维 OH 浓度场为基底来预测中间帧,分别实现了 2 倍和 3 倍的时间分辨率提升。通过对 Cycle-3D-CNN 与传统方法重建结果的一系列定性与定量的比较,可发现 Cycle-3D-CNN 模型具有最高的 PSNR 和 SSIM,最低 MSE 和 IE。此外,在二维视觉效果与一维强度曲线分布的对比中,也可观察到 Cycle-3D-CNN 重建结果与原始数据保持更高的一致性,这表明本文所提方法相比于传统帧重建方法有着更高的精度,有望在未来降低实际燃烧诊断中高速成像系统的硬件成本和技术难度,以高时间分辨率揭示湍流燃烧过程中 OH 自由基的超快速演变。

## 参考文献:

- [1] 何赞, 乐嘉陵, 田野, 等. 超燃燃烧室中燃烧反应区域变化情况试验[J]. 航空动力学报, 2023, 38(10): 2370-2382.  
HE Zan, LE Jialing, TIAN Ye, et al. Experiment on variation of combustion reaction region in a scramjet combustor[J]. Journal of Aerospace Power, 2023, 38(10): 2370-2382. (in Chinese)
- [2] 陈晓丽, 金川, 苏秋成, 等. 基于激光诱导荧光法的同轴射流火焰中羟基自由基、甲醛、发热率与一氧化氮的二维可视化测量[J]. 分析测试技术与仪器, 2021, 27(3): 182-188.  
CHEN Xiaoli, JIN Chuan, SU Qiucheng, et al. Two-dimensional visualization measurement of hydroxyl radical, formaldehyde, heat release rate and nitric oxide in co-flow jet flame based on planar laser induced fluorescence technology[J]. Analysis and Testing Technology and Instruments, 2021, 27(3): 182-188. (in Chinese)
- [3] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521: 436-444.
- [4] JIN K H, MCCANN M T, FROUSTEY E, et al. Deep convolutional neural network for inverse problems in imaging[J]. *IEEE Transactions on Image Processing*, 2017, 26(9): 4509-4522.
- [5] 孙安泰. 基于深度学习的火焰三维温度场层析重建及预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.  
SUN Antai. Tomography reconstruction and prediction of three-dimensional temperature field of flame based on deep learning[D]. Harbin: Harbin Institute of Technology, 2021. (in Chinese)
- [6] XU Wenjiang, LUO Weiyl, WANG Yu, et al. Data-driven three-dimensional super-resolution imaging of a turbulent jet flame using a generative adversarial network[J]. *Applied Optics*, 2020, 59(19): 5729-5736.
- [7] GUO Hao, ZHANG Wei, NIE Xiangyu, et al. High-speed planar imaging of OH radicals in turbulent flames assisted by deep learning[J]. *Applied Physics B*, 2022, 128(3): 52.
- [8] ZHU Junyan, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE International Conference on Computer Vision. Piscataway, US: IEEE, 2017: 2242-2251.
- [9] TRAN D, BOURDEV L, FERGUS R, et al. Learning spatiotemporal features with 3D convolutional networks[C]//2015 IEEE International Conference on Computer Vision. Piscataway, US: IEEE, 2015: 4489-4497.
- [10] FUKAMI K, FUKAGATA K, TAIRA K. Super-resolution reconstruction of turbulent flows with machine learning[J]. *Journal of Fluid Mechanics*, 2019, 870: 106-120.
- [11] FUKAMI K, FUKAGATA K, TAIRA K. Machine-learning-based spatio-temporal super resolution reconstruction of turbulent flows[J]. *Journal of Fluid Mechanics*, 2021, 909: A9.
- [12] KIM H, KIM J, WON S, et al. Unsupervised deep learning for super-resolution reconstruction of turbulence[J]. *Journal of Fluid Mechanics*, 2021, 910: A29.
- [13] BARLOW R S, FRANK J H. Effects of turbulence on species mass fractions in methane/air jet flames[J]. *Symposium (International) on Combustion*, 1998, 27(1): 1087-1095.
- [14] LYSENKO D A, ERTESVÅG I S, RIAN K E. Numerical simulations of the Sandia flame D using the eddy dissipation concept[J]. *Flow, Turbulence and Combustion*, 2014, 93(4): 665-687.
- [15] JONES W P, PRASAD V N. Large eddy simulation of the Sandia flame series (D-F) using the Eulerian stochastic field method[J]. *Combustion and Flame*, 2010, 157(9): 1621-1636.
- [16] NIK M B, YILMAZ S L, GIVI P, et al. Simulation of Sandia flame D using velocity-scalar filtered density function[J]. *AIAA Journal*, 2010, 48(7): 1513-1522.
- [17] 李人宪. 有限体积法基础[M]. 北京: 国防工业出版社, 2005.  
LI Renxian. Fundamentals of finite volume method[M]. Beijing: National Defense Industry Press, 2005. (in Chinese)
- [18] MINOTTI A, SCIUBBA E. LES of a meso combustion chamber with a detailed chemistry model: comparison between the flamelet and EDC models[J]. *Energies*, 2010, 3(12): 1943-1959.
- [19] LIU Yulun, LIAO Y T, LIN Yenyu, et al. Deep video frame interpolation using cyclic frame generation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 8794-8802.
- [20] REDA F, SUN Deqing, DUNDAR A, et al. Unsupervised video interpolation using cycle consistency[C]//2019 IEEE/CVF International Conference on Computer Vision. Piscataway, US: IEEE, 2019: 892-900.
- [21] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//2015 IEEE International Conference on Computer Vision. Piscataway, US: IEEE, 2015: 1026-1034.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2023-01-15]. [http://www.robots.ox.ac.uk/~vgg/research/very\\_deep/](http://www.robots.ox.ac.uk/~vgg/research/very_deep/).
- [23] WANG Zhou, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [24] YANG C Y, MA Chao, YANG M H. Single-image super-resolution: a benchmark[C]//European Conference on Computer Vision. Cham: Springer, 2014: 372-386.
- [25] JIANG Huaizu, SUN Deqing, JAMPANI V, et al. Super SloMo: high quality estimation of multiple intermediate frames for video interpolation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, US: IEEE, 2018: 9000-9008.
- [26] LI Haopeng, YUAN Yuan, WANG Qi. Video frame interpolation via residue refinement[C]//2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway, US: IEEE, 2020: 2613-2617.
- [27] CHOI M, KIM H, HAN B, et al. Channel attention is all you need for video frame interpolation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 10663-10671.

(编辑: 陈 越)