

光学学报

基于混合卷积的有限角度发射光谱层析重建

朱孙泳^{1,2}, 金莹^{2*}, 吴泉英^{1**}, 刘海山², 司徒国海²

¹苏州科技大学 物理科学与技术学院, 江苏 苏州 215009;

²中国科学院上海光学精密机械研究所信息光学与光电技术实验室, 上海 201800

摘要 为了解决传统迭代类重建算法在光学窗口有限和采样角度受限情况下火焰三维重建精度低的问题,提出了一种基于三维-二维卷积串联的混合卷积神经网络模型,作为空间特征提取器。该模型利用三维卷积同步提取多视角投影图的空间特征,并采用二维卷积进一步加快训练速度,减少计算损耗。与传统的迭代类重建算法和基于残差网络的重建算法相比,该网络模型具有重建精度高、时间成本低等特点,有望用于实际工况中火焰场的在线监控和快速重建。

关键词 机器视觉; 发射光谱层析; 重建算法; 混合卷积; 有限角度

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/AOS202242.1315002

Hybrid-Convolution-Based Reconstruction for Limited-View Emission Spectrum Tomography

Zhu Sunyong^{1,2}, Jin Ying^{2*}, Wu Quanying^{1**}, Liu Haishan², Situ Guohai²

¹College of Physical Science and Technology, Suzhou University of Science and Technology, Suzhou 215009, Jiangsu, China;

²Laboratory of Information Optics and Opto-Electronic Technology, Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Shanghai 201800, China

Abstract A hybrid neural network model based on 3D-2D convolution tandem is proposed as the spatial feature extractor to overcome the problem of low accuracy of conventional iteration reconstruction algorithm in the case of limited optical windows and projection views in practical flame reconstruction. In this model, 3D convolution is utilized to extract spatial features from multi-view projections simultaneously, and 2D convolution is used to further accelerate the training speed and reduce computational consumption. Compared with conventional iteration reconstruction algorithm and reconstruction algorithms based on residual networks, the proposed model has the advantages of high reconstruction accuracy and low time consumption. It shows potential in flame on-line monitoring and rapid reconstruction.

Key words machine vision; emission spectrum tomography; reconstruction algorithm; hybrid convolution; limited view

1 引言

近年来,随着能源危机及环境污染问题的日益严峻,提高对能源工程、交通运输、航空航天等领域中实际燃烧过程的认识并加强对燃烧污染物排放的控制变得日益重要。火焰发射光谱层析技术(FET)直接使用工业相机或光纤探测器获取火焰燃烧过程中的 CH^* 、 C_2^* 和 OH^* 自由基发射的特定波长光谱进行检测,借助计算层析方法,可以实现对燃烧场瞬态燃烧结构的三维(3D)重建,以及燃烧过程中组分、温度、速度等关键物理参量的非接触、无扰动的定量测量,成为燃烧

诊断领域中的关注热点^[1-2]。

在发射光谱层析技术研究中,火焰场投影数据的获取是后续得到三维重建结果的基础。对于对称性良好或燃烧状态非常稳定的火焰,通常使用一个工业相机,采集轴对称火焰单一方向的投影数据即可完成重建^[3-4]。对于非轴对称的火焰场,必须同时采集多方向的投影数据才能进行重建。在多方向投影采集装置方面,Ishino等^[5]以40个工业相机为基础建立了一个多方向投影采集装置;Floyd等^[6-7]将5个CCD相机等间隔布置在半圆实验台上并使被测火焰场位于半圆中心,通过反射镜的反射将投影采集方向由5个扩展为

收稿日期: 2021-11-19; 修回日期: 2021-12-13; 录用日期: 2022-01-13

基金项目: 江苏省研究生科研与实践创新计划项目(KYCX21_3014)

通信作者: *yingjin@siom.ac.cn; **wqcyh@mail.usts.edu.cn

10 个,建立了多方向投影采集装置;Mohri 等^[8-9]将 24 个黑白相机围绕被测场等间距半圆放置,组成了多方向投影测量系统;Jin 等^[10-11]也建立了围绕被测区域半圆等间距放置的 12 方向投影测量系统。他们均发展了以多个工业相机为基础的多方向投影采集装置,通过投影信息重建火焰场三维燃烧结构,但从装置的要求上来说,他们构建的实验装置装配要求和成本较高。此外,Hossain 等^[12]设计了一个由 2 台彩色相机构成、每个相机连接 4 组光纤束的多方向 FET 系统;Wan 等^[13]建立了由 4 个 CCD 相机构成、每个相机连接 1 个多光纤束的 FET 实验装置,分别对蜡烛火焰的发射系数和温度分布进行了重建;Yu 等^[14-15]基于内窥镜设计了多种多方向 FET 投影采集系统;Dong 等^[16]建立了 9 个内窥镜围绕着被测场的多方向 FET 投影采集系统。这些光纤和工业相机相结合的实验装置,也成为实现 FET 技术中多方向投影采集的一种方式。其中,基于内窥镜的方式虽然成本较低,但分辨率受到了内窥镜成像的限制。

在诸如炉膛内的燃烧监控、发动机燃烧室内物理参量的测量等实际工况中,燃烧现象通常发生在相对密闭的受限空间内,内部结构紧凑,光学窗口有限,难以通过在实验环境中搭建的开放场发射层析装置采集多方向投影信息进行高分辨重建。由于投影采集角度有限,代数重建技术(ART)^[17-18]等传统代数迭代类算法和通过添加先验信息约束发展而来的优化类算法^[19-21]难以获得火焰场高质量重建结果,同时,算法庞大的数据吞吐量和计算耗时也成为发射光谱层析技术应用在火焰监控与在线测量等实际工程中的瓶颈。

近年来,以深度学习为代表的人工智能技术得到了飞速发展,在自然语言处理、计算机视觉、医学诊断、计算光学成像等方面大放异彩^[22-27],在燃烧诊断领域

同样备受关注,目前已成功应用于火焰燃烧状态的监控^[28]和预测^[29]等研究中。在采集角度受限的层析问题求解方面,Wei 等^[30]基于神经网络方法重建被测火焰不同高度的二维(2D)温度场分布切片,由此通过“堆叠”方法获得甲烷火焰的三维温度场分布。然而,这种“堆叠”式的准三维重建方法忽略了火焰切片方向上的三维结构关联,且计算效率不高。

为了实现有限角度采集条件下火焰场的快速高质量三维重建,本文提出一种基于 3D-2D 卷积串联的混合神经网络(HNN)结构,在投影方向数据稀疏采样的情况下,与代数迭代重建算法和基于残差网络的重建算法相比,仍能保持良好的重建结果。

2 FET 重建原理

2.1 FET 模型

FET 重建原理如图 1 所示。被测区域在三维空间内被划分为若干体素,每一个体素经过成像系统成像,将在相机靶面上得到成像光斑。通过计算光斑与成像靶面上像素的相交面积,就能构建被测区域内体素和相机成像靶面上像素的映射关系。通过对每个体素分别成像,就能得到被测场相对于某个成像系统的权重矩阵^[11]。假设多方向层析系统由 q 个相机组成,每个相机的采样数为 p ,忽略火焰燃烧过程中的自吸收效应,那么在一个具有 $W \times H \times L$ 个体素、 $q \times p$ 条投影射线的层析系统中,火焰的三维被测场 F 与某个相机所得投影 I 之间的关系可以用公式表示为:

$$I_j = \sum_{i=1}^{W \times H \times L} w_{ij} f_i, \quad i \leq j \leq q \times p, \quad (1)$$

式中, i 为体素序号; j 为投影射线序号; f_i 为火焰三维被测场 F 中第 i 个体素所代表的值; I_j 为第 j 条投影射线的投影值。权重因子 w_{ij} 为被测场第 i 个体素对于第 j 条投影射线的贡献。




图 1 FET 重建原理

Fig. 1 Principle diagram of FET reconstruction

式(1)表示层析重建问题时可以转化为一组线性方程组:

$$\begin{cases} w_{1,1} \cdot f_1 + w_{2,1} \cdot f_2 + w_3 \cdot f_3 + \cdots + w_{W \times H \times L,1} \cdot f_{W \times H \times L} = I_1 \\ w_{1,2} \cdot f_1 + w_{2,2} \cdot f_2 + w_3 \cdot f_3 + \cdots + w_{W \times H \times L,2} \cdot f_{W \times H \times L} = I_2 \\ \vdots \\ w_{1,p \times q} \cdot f_1 + w_{2,p \times q} \cdot f_2 + w_{3,p \times q} \cdot f_3 + \cdots + w_{W \times H \times L,p \times q} \cdot f_{W \times H \times L} = I_{p \times q} \end{cases}, \quad 1 \leq j \leq q \times p. \quad (2)$$

式(2)也可以表示为矩阵形式:

$$I = WF, \quad (3)$$

式中, F 为待测区域; I 为相机采集到的火焰被测场光强信息; W 是被测区域内体素与对应像素的权重矩阵。

因此, 层析重建的问题也就可以等效为对式(3)的求解。

2.2 重建算法

FET 技术 的重建算法一直是燃烧诊断领域的研究热点之一。代数迭代重建算法的数学过程由 Kaczmarz^[31] 在 1937 年提出。Gordon 等^[32] 在 1970 年将这一方法首次应用到 X 射线图像的重建当中。加型迭代算法是代数迭代算法中最具代表性的算法之一, 其基本思想是把实验所得到的投影值与经过第 m 次迭代后所得到的投影值的差值, 以线性分配的方法分配到第 m 次迭代得到的值上, 以此来构成第 $m+1$ 次的迭代值。加型迭代算法公式可以表示为

$$\begin{cases} f^{(0,0)} = f^{(0)} \\ f_i^{(m,j+1)} = f_i^{(m,j)} + \lambda \frac{I_j - \sum_{i=1}^{W \times H \times L} w_{ij} f_i^{(m,j)}}{\sum_{i=1}^{W \times H \times L} (w_{ij})^2} w_{ij}, \\ f^{(m+1,0)} = f^{(m,q \times p)} \end{cases} \quad 1 \leq j \leq q \times p - 1, \quad (4)$$

其中设定的初始值为 $f^{(0)}$, 第 m 次迭代第 j 条投影射线为 $f_i^{(m,j)}$, λ 为迭代的松弛因子, 一般情况下 $\lambda \in (0, 2)$ ^[33], 在本文工作中取值为 0.8。松弛因子的选择对于代数

迭代算法来说是非常重要的。当松弛因子较小时, 迭代的精度高, 但收敛速度较慢; 反之, 当松弛因子较大时, 收敛速度较快, 但迭代精度较低。在此基础上, Zhou 等^[34] 将先验知识作为正则项融合到代数迭代算法中, 利用添加 Tikhonov 正则化的重建算法, 证明了其用在模拟重建和大型工业炉火焰温度场重建中的可行性。Yu 等^[35] 通过将总变分最小化加入到迭代算法中展开了对重建系统非线性的研究。

随着人工智能的发展, 深度学习方法同样在燃烧诊断中得到了应用。比较有代表性的是 Huang 等^[36] 提出的多层神经网络结构, 主要基于切片堆叠的思想, 虽然网络结构简单, 但对输入和输出都要进行预处理, 大大增加了重建工作量, 将重建问题复杂化。这种切片堆叠的做法, 没有考虑三维被测场在纵向上的特征, 只能称作被测场的“准三维重建”。他们还提出了基于 Res-Net 的 VT-Net2 网络模型^[37]。VT-Net2 网络模型利用层与层之间的跳跃连接, 增加了网络的深度和网络的学习能力, 使得网络的特征学习更快、更精确, 但与单纯的多层神经网络相比性能区别不大。

2.3 3D-2D 混合网络框架

卷积神经网络 (CNN) 是一种依靠卷积操作运行的神经网络。全连接神经网络需要先将图像进行扁平化的处理, 然后连接到全连接层处理。卷积神经网络与全连接神经网络相比, 不需要对图像做扁平化处理, 且权重参数更少, 训练速度更快, 成为了目前神经网络的重要研究方向之一。

如图 2 所示, 本文提出的混合网络结构主要由 3D-2D 串联空间特征提取器、下采样模块和上采样模块组成。




图 2 3D-2D 混合网络结构

Fig. 2 Structure of the 3D-2D hybrid network

3D-2D 串联空间特征提取器模块结构如图 3 所示, 以原始的投影数据组成的 $M \times M \times L$ 立方体数据块作为网络的输入, 首先采用步长为 1、卷积模式为 valid 的 $3 \times 3 \times 3$ 卷积核提取空间特征; 然后通过卷积模式为 valid 的 $1 \times 1 \times C$ 卷积核将尺寸为 $S \times S \times C$ 的

三维特征图转换为尺寸为 $N \times N$ 的二维特征图。

如图 2 所示, 网络输入是 48×48 大小的不含噪声的投影图, 数量即投影方向数, 经过网络后的输出为重建区域, 由 $48 \times 48 \times 48$ 个大小为 $0.1 \text{ mm} \times 0.1 \text{ mm} \times 0.1 \text{ mm}$ 的体素组成。下采样模块由步长为 2 的 5×5




图 3 3D-2D 串联结构

Fig. 3 3D-2D tandem structure

卷积核提取图像特征;经过 batch normalization(BN)层使网络更容易学习到图像的特征;下采样模块通道数从 16 开始倍增。上采样模块中上采样操作的作用是使图像恢复到原来的大小,通过上采样后经过一个步长为 1 的 5×5 的卷积核卷积,再经过 BN 层使网络更容易收敛;通过在每个上采样模块中添加 dropout 层来防止网络过拟合,之后经过 concatenation 层使数据与同样数据大小的下采样层相连,使得后面上采样的每

一层都能获得原始的图像信息,这样网络特征的学习就能进一步加快,最后用 leaky ReLU 层来进行非线性激活,保留特征信息。

3 数值模拟

3.1 模拟场

本文通过构建模拟三维场 F_s 来模拟实际火焰:

$$F_s(x, y, z) = 150 * (h_3 * 0.03 - z * 0.03) * \exp\left[-(x + \delta_x + n_x * C_{\text{tmp}})^2 / \sigma_1\right] * \exp\left[-(y + \delta_y + n_y * C_{\text{tmp}})^2 / \sigma_2\right], \quad (5)$$

式中, h_3 为火焰顶层网格高度; n_x, n_y 控制火焰偏折的方向; δ_x, δ_y 为火焰在 x, y 方向上的偏移量; C_{tmp} 控制火焰偏折的程度; σ_1 和 σ_2 控制 x, y 方向上火焰场的大小。

三维模拟场在 x, y, z 方向上被划分为 $48 \times 48 \times 48$ 个正方体网格,每个网格大小为 $0.1 \text{ mm} \times 0.1 \text{ mm} \times 0.1 \text{ mm}$ 。通过将火焰模拟场分层处理,对于上层扭曲火焰,使其超出顶层网格高度的网格设为 0,并使得上层火焰的底层位于合适的位置。火焰场的三维结构如图 4 所示。

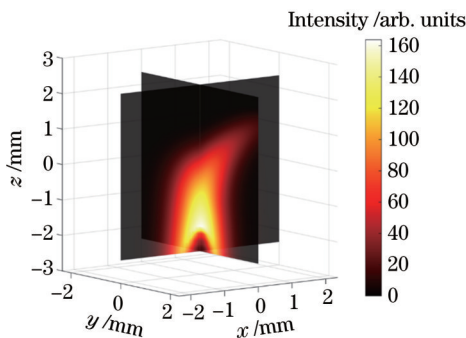


图 4 火焰模拟场三维结构图

Fig. 4 Three-dimensional structure of the fire simulation field

3.2 训练数据与测试数据的产生

神经网络训练数据应该包括火焰不同大小、不同偏折程度、不同偏折方向、不同高度的场分布。通过控制扭曲系数 C_{tmp} 使其从 0.3 变化到 0.6,以 0.1 为间隔,获得 4 个不同的扭曲变化;通过控制偏折方向 n_x, n_y 可以得到前后左右 4 个方向的偏折;通过控制 σ_1 和 σ_2 就可以得到从圆到椭圆的火焰场底层变化,本文一共模

拟了 25 种变化情况;通过控制 δ_x, δ_y 在 x, y 方向上获得了 5 种情况的偏移量。通过控制上述变量,本文一共获得了 2000 个火焰场样本数据。将其中 1440 个作为训练数据,360 个作为验证数据,200 个作为测试数据。样本数据通过程序随机打乱划分,确保样本数据的多样性。网络的输入采用如图 5 所示的实验装置图模拟得到,12 个相机中相邻 2 个相机的间距为 15° ,总采样角为 165° ,物距 340 mm。图 6 所示为模拟场 12 个采集方向的投影图^[11]。




图 5 实验装置图

Fig. 5 Diagram of the experimental setup

3.3 参数选择

本文通过 Python 的 keras 库来建立神经网络反演模型,网络结构确定后,对网络卷积层进行随机初始化,网络训练采用 Adam 优化器优化网络参数,损失函数设置为均方误差(MSE):

$$L_{\text{MSE}}(y_i, \hat{y}_i) = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2, \quad (6)$$

式中, m 为像素数; y_i 为真实值; \hat{y}_i 为预测值。




图 6 12 个相机模拟获取的投影图

Fig. 6 Projection images acquired by 12 camera simulations

设置评价函数为结构相似性(SSIM):

$$M_{SSIM}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (7)$$

式中, μ_x 是 x 的平均值; μ_y 是 y 的平均值; σ_x 是 x 的方差; σ_y 是 y 的方差; σ_{xy} 是 x 和 y 的协方差; c_1, c_2 是用来维持稳定的常数。设置网络训练轮数为 1000, batch size 为 32。学习率作为深度学习网络模型中最重要的超参数, 决定了损失函数能否收敛及何时收敛到最小值。本文数值模拟中采用取值为 0.0001 的学习率, 网络总参数量为 1655376。采用 Nvidia P6000 进行网络的训练加速, 每一轮训练所需时间为 3 s。

为了进一步说明网络结构参数选择的合理性, 本文对于网络的结构进行了消融实验, 在投影方向数为 12 的情况下得到网络训练的结果。如表 1 和图 7 所示, 本文分别从不同采样层数、不同通道数和不同卷积核大小三方面对网络结构的选择进行了分析。如表 1 前两行所示, 从网络层数来看, 本文提出的具有 4 层采

样层的 HNN 在评价指标上优于具有 3 层采样层的 HNN, 且训练每一周期所需时间基本相同。从图 7(a) 所示的损失曲线看, 训练中 4 层网络比 3 层网络损失下降得更快, 能更快地收敛。从通道数的选择上来看, 通道数越多, 网络可训练的参数就越多, 训练的结果也会越好。但从图 7(b) 所示的损失曲线变化来看, 本文提出的从 8 开始倍增的通道数适中, 训练时间花费较小, 且损失曲线下下降更快, 能够快速收敛。从卷积核大小的选择上可以看出, 参数的多少会直接影响网络训练的效果。从图 7(c) 可以看出, 本文选择的 5×5 卷积核在评价指标上达到了比较好的结果, 且相对于 3×3 和 7×7 卷积核来说, 训练损失下降得更快, 能够更快地收敛, 训练周期更短。表 1 中还比较了不同网络结构参数下重建的相关系数(CORR)、均方根误差(RMSE)和峰值信噪比(PSNR)。综合比较之后, 确定了一个采样层数为 4 层、通道数从 8 开始倍增且卷积核大小为 5×5 的 HNN 网络结构。

表 1 不同网络结构参数重建情况

Table 1 Reconstruction conditions with different network structure parameters

Network structure parameter	Parameter amount	SSIM	CORR	RMSE	PSNR	Training time/s
HNN (four layers, channels increased from 8, 5×5 convolution kernels)	1655376	0.9916	0.9997	0.0037	48.6140	3
Three-layer HNN	630480	0.9910	0.9996	0.0039	48.1682	3
Channels increased from 4	541280	0.9878	0.9994	0.0050	46.0712	3
Channels increased from 16	6424344	0.9958	0.9998	0.0028	50.9575	4
3×3 convolution kernels	598992	0.9790	0.9989	0.0063	43.9505	3
7×7 convolution kernels	3240912	0.9919	0.9997	0.0032	49.9400	3

3.4 模拟结果

为了验证本文提出的 HNN 对于火焰三维重建的可行性, 对传统的 ART 算法和提出的 HNN 算法进行了数值模拟。针对投影方向数的减少, 选取了 3、6、9、12 方向以及 3 方向有间隔(3-2)和 6 方向有间隔(6-2)这几种情况进行数值模拟, 其中 3、6、9、12 分别代表选取相机编号 1~3、1~6、1~9 和 1~12 这几种情况; 3 方向有间隔表示选取间隔为 1 的 1、3、5 这 3 个编号的相

机所得的投影图; 6 方向有间隔表示选取间隔为 1 的 1、3、5、7、9 和 11 这 6 个编号的相机所得的投影图。HNN 和传统 ART 算法的输入都是不含噪声的 12 个方向的投影图, 真值(GT)为通过数值模拟得到的三维模拟场。真值和通过 ART 及 HNN 得到的三维重建结果如图 8 所示。

结果对比如图 9 所示。本文从测试集中随机挑选了 5 个模拟场进行重建, 分别从 SSIM、RMSE、CORR

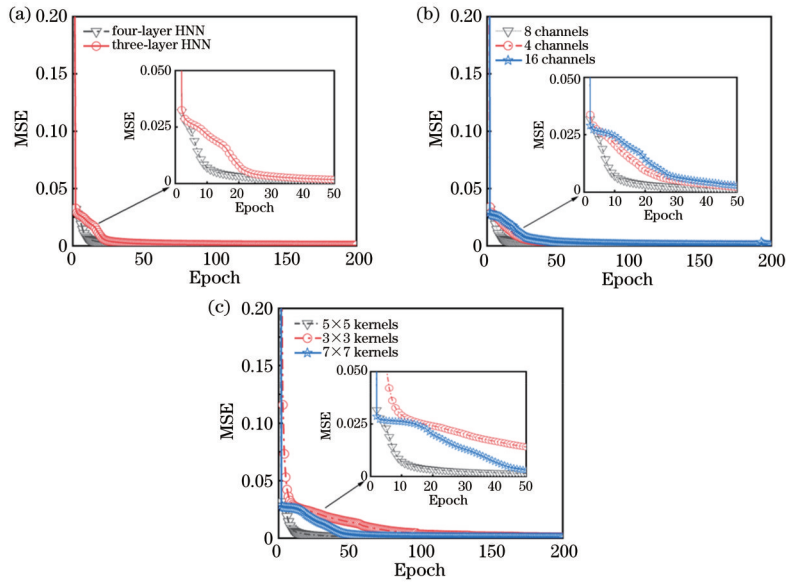


图 7 不同结构参数情况下的网络损失曲线。(a)不同层数;(b)不同通道数;(c)不同卷积核

Fig. 7 Network loss curves for different structural parameters. (a) Different sampling layers; (b) different numbers of channels; (c) different convolution kernels

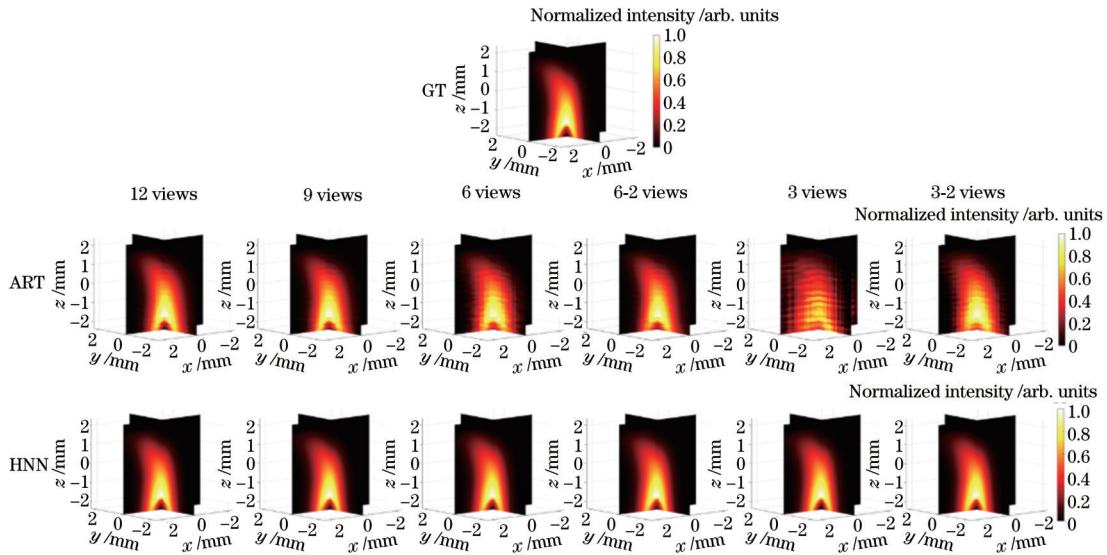


图 8 ART 和 HNN 三维重建结果

Fig. 8 3D reconstruction results of ART and HNN

和 PSNR 等 4 个方面取 5 个火焰场的平均值,对重建结果进行评价。其中 SSIM 公式如式(7)所示,其他评价函数公式分别为

$$E_{\text{RMS}}(y_i, \hat{y}_i) = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}, \quad (8)$$

式中, m 为像素数; y_i 为真实值; \hat{y}_i 为预测值。

$$C_{\text{CORR}}(x, y) = \frac{\sigma_{xy}}{\sqrt{\sigma_x \sigma_y}}, \quad (9)$$

式中, σ_x 是 x 的方差; σ_y 是 y 的方差; σ_{xy} 是 x 和 y 的协方差。

$$R_{\text{PSN}} = 10 \times \log_{10} \left(\frac{(2^n - 1)^2}{L_{\text{MSE}}} \right), \quad (10)$$

式中: $\text{MSE}(L_{\text{MSE}})$ 公式如式(6)所示。

对于传统的 ART 重建方法,随着投影方向数的减少,重建结果的精度不断下降。但是当选取有间隔的几幅投影图时,重建的结果相对于没有间隔的情况在评价指标上有一定的提升,这是由于选取有间隔的几张图,能够获得的总投影角度增大,进而获得更多的火焰空间信息。在投影方向数减少的情况下,本文提出的混合网络模型的重建结果仍能保持相对较高的水平,投影方向数的减少对于网络重建性能的影响不大。同样针对有间隔和无间隔的采集情况,从评价指标定量分析出网络的重建结果无明显差别。选取模拟场 $z=4$ 、 $z=24$ 、 $x=24$ 和 $y=24$ 这 4 个切片进行定性分析,如图 10 所示。从定性分析中同样可以看到:随着

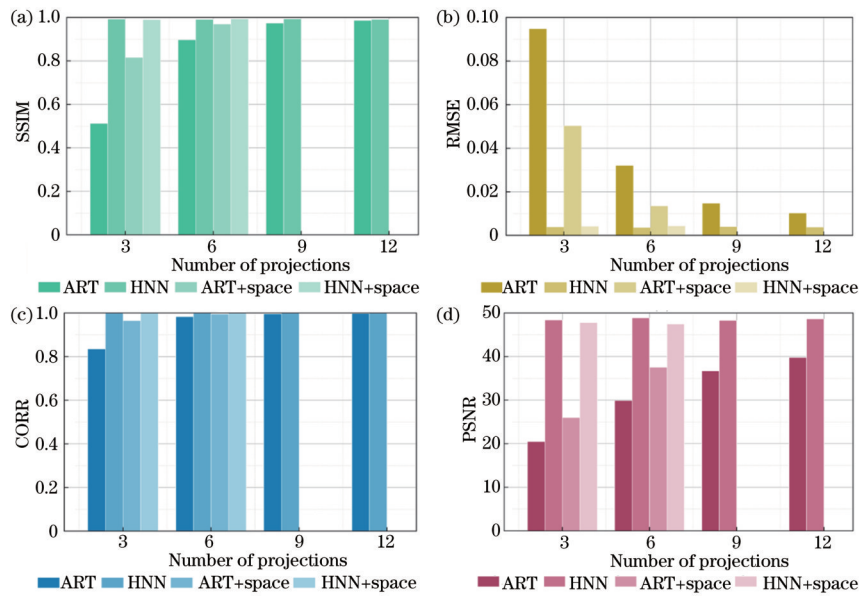


图 9 ART 和 HNN 重建结果对比。(a) SSIM; (b) RMSE; (c) CORR; (d) PSNR

Fig. 9 Comparison of ART and HNN reconstruction results. (a) SSIM; (b) RMSE; (c) CORR; (d) PSNR




图 10 ART 和 HNN 重建结果二维定性对比。(a) $z=4$; (b) $z=24$; (c) $x=24$; (d) $y=24$

Fig. 10 Two-dimensional qualitative comparison of ART and HNN reconstruction results.

(a) $z=4$; (b) $z=24$; (c) $x=24$; (d) $y=24$

投影方向数的减少, ART 算法重建的质量不断下降, 甚至出现线状伪影; 而对于 HNN 重建来说, 投影方向数的减少对于重建质量无显著影响, 仍能清晰重建出

模拟场的三维结构。从重建时间上来说, ART 算法重建单个模拟场需要 6 s, 而本文提出的混合网络模型的重建时间为 0.7 ms, 计算效率提升将近 10000 倍。

为了进一步说明本文提出的 HNN 的优势, 将其与 VT-Net2 进行比较^[37]。在保证与 VT-Net2 网络框架和通道数一致的前提下, 仅根据当前工作中数值模拟部分投影图及采样方向的维度, 修改了输入中投影图的大小和投影方向数以及输出中密集连接层的大小。以 12 个方向的重建结果为例, 从参数量上来说, 本文提出的 HNN 总参数量为 1655376, 而 VT-Net2 的总参数量为 560701024。从训练时间上来看, 本文提出的 HNN 每一步所需训练时间为 3 s, 而 VT-Net2 所需训练时间为 13 s。图 11 所示为训练过程中验证集的 SSIM 变化曲线, 可以看出本文提出的 HNN 与 VT-Net2 相比 SSIM 更高。因此, 与 VT-Net2 相比, 本文提出的 HNN 结构具有参数量少、训练时间短和重建结果更好等优点。

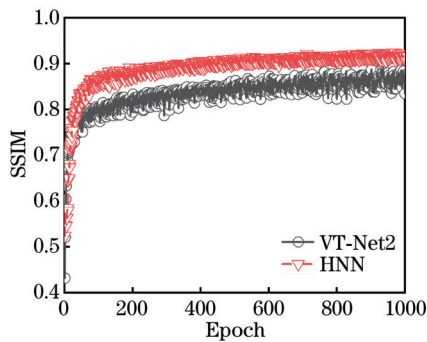


图 11 VT-Net2 和 HNN 在验证集上训练结果对比

Fig. 11 Comparison of training results between VT-Net2 and HNN on the validation set

4 实验结果与分析

为进一步验证本文提出的 HNN 对于真实火焰重建的适用性, 采用如图 5 所示的实验装置分别对两个火焰和三个火焰等更复杂的燃烧结构进行了真实火焰投影图数据的采集。通过将定制滤光片放置在镜头和 CCD 之间来获得火焰 C_2 组分 $[(516.5 \pm 10) \text{ nm}]$ 的发射光强信号。实验中在 $15 \mu\text{s}$ 的曝光时间条件下, 以 10 frame/s 的帧率对火焰 12 个方向的投影进行采集, 得到的 12 个方向火焰投影图如图 12 所示。对于两个火焰情况, 选取 250 个连续的瞬时数据, 将其按 0.72:0.18:0.1 的比例划分为训练集、验证集和测试集, 通过程序将其打乱随机划分。针对两个火焰实验过程中火焰投影图 256×128 的维度, 通过消融实验步骤选择采样层数为 5 层, 并将 3D-2D 串联部分的通道数改为 16, 选择下采样通道数从 16 开始倍增至 256, 然后使上采样通道数从前两层的 256 下降到后两层的 128, 卷积核大小为 5×5 。最终输出的重建结果为由 $96 \times 96 \times 128$ 个大小为 $0.55 \text{ mm} \times 0.55 \text{ mm} \times 0.55 \text{ mm}$ 的体素组成的重建区域。对于三个火焰的情况, 为了适应这一输入维度, 通过消融实验中参数选择的步骤, 选取的采样层数为 5 层, 通道数从 16 开始倍增, 卷积核大小为 5×5 , 并将 3D-2D 串联结构中 3D 卷积部分的步长改为 3。网络输入样本数为 200 个, 按 0.72:0.18:0.1 的比例划分为训练集、验证集和测试集, 通过程序将其打乱随机划分。网络输出数据维度与两个火焰的重建结果维度相同。




图 12 实验测量得到的 12 个方向火焰投影图。(a) 两个火焰; (b) 三个火焰

Fig. 12 Projection images of flames in 12 directions from experimental measurements. (a) Two flames; (b) three flames

在真实实验数据集下比较本文提出的 HNN 与 VT-Net2 的重建性能。考虑到本文所用计算机配置和 VT-Net2 网络框架庞大的参数量, 为了避免计算显存不足的情况, 对输入投影图和输出重建场进行

了降采样。针对两个火焰和三个火焰这两组数据集, 分别将输入投影图大小调整为 64×32 和 48×48 , 并将输出被测场大小均调整为 $48 \times 48 \times 64$ 。降采样后的输入投影图如图 13 所示。在上述数据维度和与

真实实验相同的网络结构条件下,分别通过 VT-Net2 网络框架和 HNN 网络框架对两组火焰数据进行三维重建,重建切片图如图 14 所示。通过对比重建结果中火焰周围区域和箭头指示区域,可以明显看出 VT-Net2 在重建结果中引入了更多噪声,这与文献[37]中的结论一致。而本文提出的 HNN 网络

框架,在重构出火焰燃烧结构的同时具有更好的抗噪性。此外,HNN 网络框架的参数量仅为 VT-Net2 框架参数量的 1/340,每周期训练效率是 VT-Net2 框架的 4 倍。综上所述,真实数据集的对比实验体现了 HNN 网络框架在重建效果和训练效率方面的优越性。

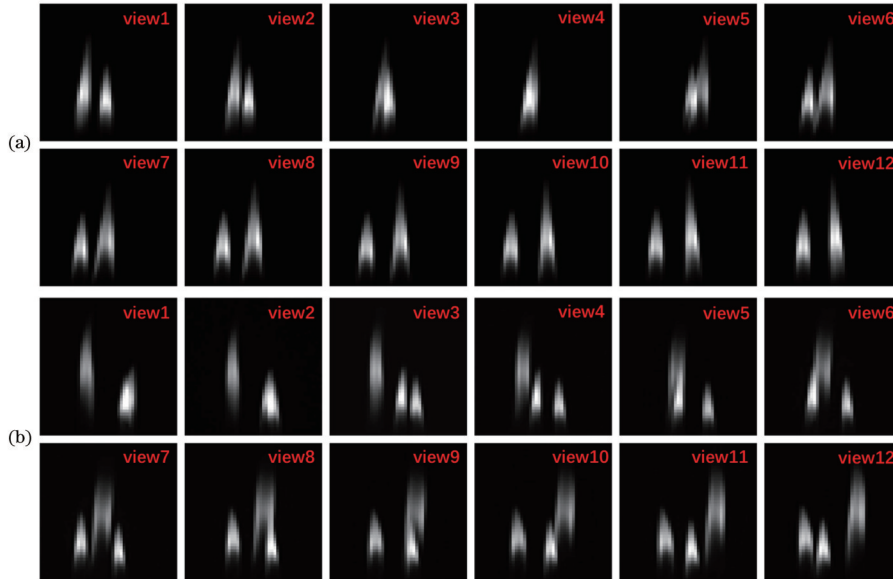


图 13 降采样后的投影图。(a)两个火焰;(b)三个火焰

Fig. 13 Projection images after downsampling. (a) Two flames; (b) three flames




图 14 实验火焰重建切片图。(a)两个火焰, $z=12$;(b)三个火焰, $z=14$

Fig. 14 Experimental flame reconstruction slices. (a) Two flames, $z=12$; (b) three flames, $z=14$

为了保证重建精度,在实验数据集原维度条件下,针对不同采样角度数量情况,分别比较了HNN网络模型与ART算法的重建结果。实验中网络框架训练次数均为 200 次,学习率以及其他超参数和模拟网络参数相同,得到的重建三维结果如图 15 所示。其中,图 15

(a)、(b)分别为两个火焰第 2 个时刻和第 186 个时刻火焰三维重建的结果;图 15(c)、(d)分别为三个火焰第 50 个时刻和第 100 个时刻火焰三维重建的结果。实验中的输入投影图 of 实际相机采集到的火焰投影图,GT 为传统 ART 算法在 12 个方向的条件下重建的结果。




图 15 ART 和 HNN 实验重建结果三维可视化对比。(a)两个火焰第 2 个时刻的三维重建结果;(b)两个火焰第 186 个时刻的三维重建结果;(c)三个火焰第 50 个时刻的三维重建结果;(d)三个火焰第 100 个时刻的三维重建结果

Fig. 15 Comparison of the 3D visualization of the reconstruction experiment results between ART and HNN. (a) 3D reconstruction of the 2nd moment of two flames; (b) 3D reconstruction of the 186th moment of two flames; (c) 3D reconstruction of the 50th moment of three flames; (d) 3D reconstruction of the 100th moment of three flames

对于两个火焰重建实验,本文在测试集的 25 个数据中选取 3 个被测场进行重建,同样将这 3 个火焰场从 SSIM、RMSE、CORR 和 PSNR 这 4 个评价指标进行评价。如图 16 所示,取均值发现,从 SSIM 来说,实验重建的火焰无论是 ART 还是 HNN 都能保持相对较高的水平;但从其他 3 个指标可以看出 ART 算法中有间隔的采样方式比无间隔的采样方式能获得更好的重建结果。通过重建指标的定量对比分析发现,HNN 重建的质量都能保持相对较高的水平,而 ART 算法随着采样数的减少,重建质量不断下降。

图 17 定量地描述了三个火焰情况下火焰重建的结果,此处是从测试集中随机选取了 3 个时刻的火焰进行重建。同样从 SSIM、RMSE、CORR 和 PSNR 这 4 个评价指标进行评价。结果发现,对于 ART 来说重建方向数的多少直接决定了重建质量的好坏,虽然从 SSIM 来看投影方向数的减少对于重建质量的影响并

不是很大,但从其他 3 个指标上可以明显看出重建投影方向数的决定性作用。与两个火焰情况一致的是,在增大投影角度的情况下,重建结果得到了一定的提升。但相对于 HNN 重建的结果来说,传统 ART 算法得到的结果并不令人满意,且投影方向数对于 HNN 的重建结果基本没有影响。

图 18 定性比较了两个火焰的火焰场在不同重建算法得到的火焰重建结果中 $z=40$ 和 $z=70$ 这两个横向的切片,从中可以明显发现随着采样数的减少,ART 算法得到的重建结果质量逐渐下降,而 HNN 算法可以更准确地重建真实火焰场的燃烧结构。图 20 定性比较了三个火焰情况下不同重建算法得到的火焰重建结果 $z=40$ 和 $z=70$ 这两个横向的切片,结果发现相对于 ART 重建噪声大且有伪影的情况,通过 HNN 重建的结果虽不可避免地引入了真值中的噪声,但也消除了大部分的噪声,且规避了线性伪影的出现。

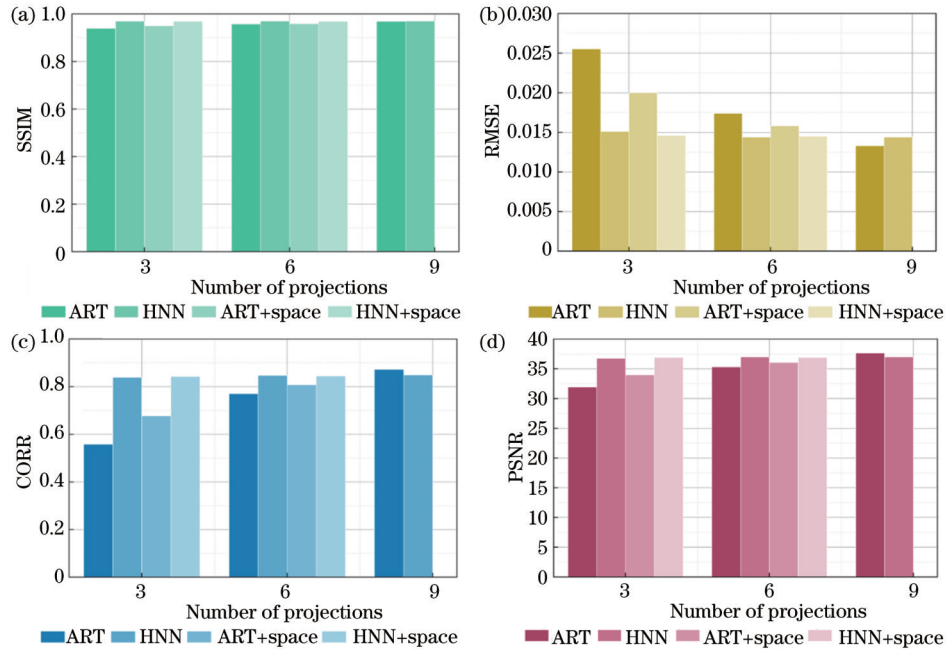


图 16 两个火焰 ART 和 HNN 实验重建结果对比。(a) SSIM;(b) RMSE;(c) CORR;(d) PSNR

Fig. 16 Comparison of reconstruction experiment results of two flames between ART and HNN. (a) SSIM; (b) RMSE; (c) CORR; (d) PSNR

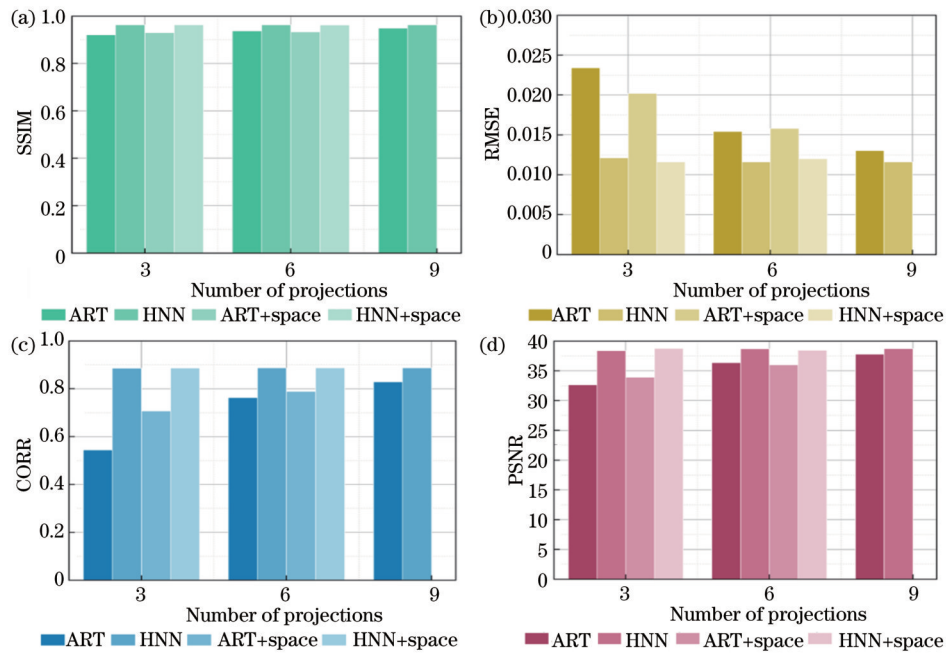


图 17 三个火焰 ART 和 HNN 实验重建结果对比。(a) SSIM;(b) RMSE;(c) CORR;(d) PSNR

Fig. 17 Comparison of reconstruction experiment results of three flames between ART and HNN. (a) SSIM; (b) RMSE; (c) CORR; (d) PSNR

5 结 论

实际工况中光学窗口有限导致投影采集角度受限。在此条件下,传统 ART 算法对于稀疏采样数据的重建精度较低。针对该问题,提出了结合 3D 卷积和 2D 卷积的 HNN 网络结构,在降低计算复杂度的同时

提高了重建精度。对模拟火焰场和真实火焰 C_2^* 自由基发射光谱数据进行重建,结果表明,与传统代数迭代算法和基于残差网络的 VT-Net2 相比,本文提出的 HNN 网络模型具有重建精度高、计算消耗低的优势,可将重建效率提升约 10000 倍,有望用于实际工况中火焰场的在线监控和物理参量的定量测量。




图 18 两个火焰实验 ART 和 HNN 重建结果可视化对比。(a) $z=40$; (b) $z=70$

Fig. 18 Visual comparison of two-flame reconstruction experiment results between ART and HNN. (a) $z=40$; (b) $z=70$




图 19 三个火焰实验 ART 和 HNN 重建结果可视化对比。(a) $z=40$; (b) $z=70$

Fig. 19 Visual comparison of three-flame reconstruction experiment results between ART and HNN. (a) $z=40$; (b) $z=70$

参 考 文 献

[1] Gupta A K, Bolz S, Hasegawa T. Effect of air preheat temperature and oxygen concentration on flame structure and emission[J]. Journal of Energy Resources Technology, 1999, 121(3): 209-216.

[2] Denisova N, Tretyakov P, Tupikin A. Emission tomography in flame diagnostics[J]. Combustion and Flame, 2013, 160(3): 577-588.

[3] Brisley P M, Lu G, Yan Y, et al. Three dimensional temperature measurement of combustion flames using a single monochromatic CCD camera[C]//Proceedings of the 21st IEEE Instrumentation and Measurement Technology Conference, May 18-20, 2004, Como,

Italy. New York: IEEE Press, 2004: 2166-2169.

[4] Jeong Y K, Jeon C H, Chang Y J. Evaluation of the equivalence ratio of the reacting mixture using intensity ratio of chemiluminescence in laminar partially premixed CH_4 -air flames[J]. Experimental Thermal and Fluid Science, 2006, 30(7): 663-673.

[5] Ishino Y, Ohiwa N. Three-dimensional computerized tomographic reconstruction of instantaneous distribution of chemiluminescence of a turbulent premixed flame[J]. JSME International Journal Series B, 2005, 48(1): 34-40.

[6] Floyd J, Kempf A M. Computed tomography of chemiluminescence (CTC): high resolution and instantaneous 3-D measurements of a matrix burner[J]. Proceedings of the Combustion Institute, 2011, 33(1): 751-758.

- [7] Floyd J, Geipel P, Kempf A M. Computed tomography of chemiluminescence (CTC): instantaneous 3D measurements and phantom studies of a turbulent opposed jet flame[J]. *Combustion and Flame*, 2011, 158(2): 376-391.
- [8] Mohri K, Görs S, Schöler J, et al. Instantaneous 3D imaging of highly turbulent flames using computed tomography of chemiluminescence[J]. *Applied Optics*, 2017, 56(26): 7385-7395.
- [9] Unterberger A, Kempf A, Mohri K. 3D evolutionary reconstruction of scalar fields in the gas-phase[J]. *Energies*, 2019, 12(11): 2075.
- [10] Jin Y, Zhang W Q, Song Y, et al. Three-dimensional rapid flame chemiluminescence tomography via deep learning[J]. *Optics Express*, 2019, 27(19): 27308-27334.
- [11] Jin Y, Song Y, Qu X J, et al. Three-dimensional dynamic measurements of CH^* and C_2^* concentrations in flame using simultaneous chemiluminescence tomography [J]. *Optics Express*, 2017, 25(5): 4640-4654.
- [12] Hossain M M M, Lu G, Yan Y. Optical fiber imaging based tomographic reconstruction of burner flames[J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(5): 1417-1425.
- [13] Wan X, Zhang Z M, Chen Q. Three-dimensional radiation thermometer combining near-infrared passband thermometry with optical fiber bundle tomography[J]. *Europhysics Letters*, 2013, 103(5): 50005.
- [14] Yu T, Liu H C, Zhang J Q, et al. Toward real-time volumetric tomography for combustion diagnostics via dimension reduction[J]. *Optics Letters*, 2018, 43(5): 1107-1110.
- [15] Yu T, Ruan C, Chen F E, et al. Measurement of the 3D Rayleigh index field via time-resolved CH^* computed tomography[J]. *Aerospace Science and Technology*, 2019, 95: 105487.
- [16] Dong R X, Lei Q C, Chi Y Q, et al. Analysis of global and local hydrodynamic instabilities on a high-speed jet diffusion flame via time-resolved 3D measurements[J]. *Flow, Turbulence and Combustion*, 2021, 107(3): 759-780.
- [17] Gordon R, Herman G T. Reconstruction of pictures from their projections[J]. *Communications of the ACM*, 1971, 14(12): 759-768.
- [18] 蒋敏, 曲芝萍, 孙怡. 基于 Mojette 频域最小冗余覆盖的有限角度计算机层析成像重建[J]. *光学学报*, 2019, 39(7): 0711001.
- Jiang M, Qu Z P, Sun Y. Limited-angle computed tomography reconstruction based on Mojette minimal redundancy coverage in frequency domain[J]. *Acta Optica Sinica*, 2019, 39(7): 0711001.
- [19] Xu C C, Yang B, Guo F P, et al. Sparse-view CBCT reconstruction via weighted Schatten p-norm minimization [J]. *Optics Express*, 2020, 28(24): 35469-35482.
- [20] 高红霞, 罗澜, 骆英浩, 等. 角度受限下稀疏投影数据的改进粒子群优化随机 CT 重建[J]. *光学学报*, 2018, 38(1): 0111003.
- Gao H X, Luo L, Luo Y H, et al. Improved stochastic CT reconstruction based on particle swarm optimization for limited-angle sparse projection data[J]. *Acta Optica Sinica*, 2018, 38(1): 0111003.
- [21] 李晓琳, 傅红笋, 宋博琳. 基于组稀疏正则化的荧光扩散层析成像重建[J]. *激光与光电子学进展*, 2021, 58(2): 0211002.
- Li X L, Fu H S, Song B L. Fluorescence diffuse optical tomography reconstruction based on group sparse regularization[J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 0211002.
- [22] Kim B, Han M, Shim H, et al. A performance comparison of convolutional neural network-based image denoising methods: the effect of loss functions on low-dose CT images[J]. *Medical Physics*, 2019, 46(9): 3906-3923.
- [23] 王飞, 王昊, 卞耀明, 等. 深度学习在计算成像中的应用[J]. *光学学报*, 2020, 40(1): 0111002.
- Wang F, Wang H, Bian Y M, et al. Applications of deep learning in computational imaging[J]. *Acta Optica Sinica*, 2020, 40(1): 0111002.
- [24] Wang F, Bian Y M, Wang H C, et al. Phase imaging with an untrained neural network[J]. *Light: Science & Applications*, 2020, 9: 77.
- [25] Lim J, Ayoub A B, Psaltis D. Three-dimensional tomography of red blood cells using deep learning[J]. *Advanced Photonics*, 2020, 2(2): 026001.
- [26] Zhou X, Jin Z B, Feng T, et al. Bone mineral density value evaluation based on photoacoustic spectral analysis combined with deep learning method[J]. *Chinese Optics Letters*, 2020, 18(4): 041701.
- [27] Dong D S, Shi K B. Solving the missing cone problem by deep learning[J]. *Advanced Photonics*, 2020, 2(2): 020501.
- [28] Qiu T, Liu M J, Zhou G P, et al. An unsupervised classification method for flame image of pulverized coal combustion based on convolutional auto-encoder and hidden Markov model[J]. *Energies*, 2019, 12(13): 2585.
- [29] Huang J Q, Liu H C, Cai W W. Online *in situ* prediction of 3-D flame evolution from its history 2-D projections via deep learning[J]. *Journal of Fluid Mechanics*, 2019, 875: R2.
- [30] Wei C Y, Schwarm K K, Pineda D I, et al. Deep neural network inversion for 3D laser absorption imaging of methane in reacting flows[J]. *Optics Letters*, 2020, 45(8): 2447-2450.
- [31] Kaczmarz S. Angenaher teauflosung von systemen linearer gleichungen[J]. *Bulletin de l'Academie Polonaise des Sciences et Lettres*, 1937, 35: 355-357.
- [32] Gordon R, Bender R, Herman G T. Algebraic reconstruction techniques (ART) for three-dimensional electron microscopy and X-ray photography[J]. *Journal of Theoretical Biology*, 1970, 29(3): 471-481.
- [33] Herman G T, Lent A, Lutz P H. Relaxation methods for image reconstruction[J]. *Communications of the ACM*, 1978, 21(2): 152-158.
- [34] Zhou H C, Lou C, Cheng Q, et al. Experimental investigations on visualization of three-dimensional

- temperature distributions in a large-scale pulverized-coal-fired boiler furnace[J]. Proceedings of the Combustion Institute, 2005, 30(1): 1699-1706.
- [35] Yu T, Cai W W. Benchmark evaluation of inversion algorithms for tomographic absorption spectroscopy[J]. Applied Optics, 2017, 56(8): 2183-2194.
- [36] Huang J Q, Liu H C, Dai J H, et al. Reconstruction for limited-data nonlinear tomographic absorption spectroscopy via deep learning[J]. Journal of Quantitative Spectroscopy and Radiative Transfer, 2018, 218: 187-193.
- [37] Huang J Q, Liu H C, Wang Q, et al. Limited-projection volumetric tomography for time-resolved turbulent combustion diagnostics via deep learning[J]. Aerospace Science and Technology, 2020, 106: 106123.