

doi: 10.11823/j.issn.1674-5795.2026.03.12

融合 RBF 插值与 CNN-LSTM 的分层物理约束 环形温度场重建方法

李书缘, 赵俭*

(中国航空工业集团公司北京长城计量测试技术研究所, 北京 100095)

摘要: 针对环形温度场存在的径向梯度异质性、环向周期性波动、局部温度反转等复杂分布特征, 以及传统重建方法难以适配环形结构、重建结果物理合规性不足的问题, 提出一种融合自适应径向基函数(Radial Basis Function, RBF)插值、卷积神经网络(Convolutional Neural Network, CNN)-长短期记忆(Long Short-Term Memory, LSTM)混合网络的分层物理约束的环形温度场重建方法。首先采用核参数随径向距离动态自适应的混合核 RBF 插值算法, 完成稀疏测点数据的初步插值, 构建初始温度场; 再利用 CNN-LSTM 混合网络提取温度场空间局部特征与环向周期特征, 实现初始温度场的残差修正; 最后结合热传导物理规律, 针对温度场不同区域的分布特性施加差异化分层物理约束, 有效提升重建结果的物理合理性与可信度。多工况试验结果表明: 本文方法在 500、1 000、1 750 K 典型工况下的重建误差均满足工程 5% 的误差阈值要求, 温度场空间分辨力可达 0.5 mm, 优于 2 mm 的工程设计指标。消融实验验证了 LSTM 模块可有效保障温度场环向分布连续性, 分层物理约束能够显著提升重建结果的物理可信度。该方法可为航空发动机环形温度场高精度重建、设备状态监测与性能优化提供可靠的技术支撑。

关键词: 环形温度场; CNN-LSTM 混合网络; 分层物理约束; RBF 插值; 网格化插值; 温度场重建; 深度学习; 数据融合

中图分类号: TB94; V21

文献标志码: A

文章编号: 1674-5795 (2026) 03-0109-12

A hierarchical physically constrained annular temperature field reconstruction method fusing RBF interpolation and CNN-LSTM

LI Shuyuan, ZHAO Jian*

(AVIC Changcheng Institute of Metrology & Measurement, Beijing 100095, China)

Abstract: Aiming at the complex distribution characteristics of annular temperature fields, including radial gradient heterogeneity, circumferential periodic fluctuation, and local temperature inversion, as well as the deficiencies of traditional reconstruction methods in annular structure adaptability and physical consistency, this paper proposes an annular temperature field reconstruction method combining adaptive Radial Basis Function (RBF) interpolation, a Convolutional Neural Network (CNN)-Long Short-Term Memory (LSTM) hybrid network, and hierarchical physical constraints. Firstly, a hybrid-kernel RBF interpolation with radially adaptive kernel parameters is adopted to construct the initial temperature

收稿日期: 2026-03-20; 修回日期: 2026-05-09; 录用日期: 2026-05-13; 发表日期: 2026-06-28

基金项目: 国家“十四五”计量技术基础科研项目(JSJL2024205XXXX)

引用格式: 李书缘, 赵俭. 融合 RBF 插值与 CNN-LSTM 的分层物理约束环形温度场重建方法[J]. 计测技术, 2026, 46(3): 109-120.

Citation: LI S Y, ZHAO J. A hierarchical physically constrained annular temperature field reconstruction method fusing RBF interpolation and CNN-LSTM[J]. Metrology & Measurement Technology, 2026, 46(3): 109-120.



field through sparse measurement data. Then, the CNN-LSTM hybrid network is utilized to extract spatial local features and circumferential periodic features to correct the residual error of the initial temperature field. Finally, according to the heat conduction law, differentiated hierarchical physical constraints are applied to different regions of the temperature field to improve the physical rationality and credibility of the reconstruction results. Multi-condition experimental results show that the reconstruction errors of the proposed method under typical working conditions of 500 K, 1 000 K, and 1 750 K all meet the engineering error threshold of 5%. The spatial resolution reaches 0.5 mm, which is better than the engineering index of 2 mm. Ablation experiments verify that the LSTM module ensures the circumferential continuity of the temperature field, and the hierarchical physical constraints significantly enhance the physical credibility of the reconstruction results. The proposed method can provide a reliable technical support for high-precision annular temperature field reconstruction, condition monitoring, and performance optimization of aero-engines.

Key words: annular temperature field; CNN-LSTM hybrid network; hierarchical physical constraints; RBF interpolation; grid interpolation; temperature field reconstruction; deep learning; data fusion

0 引言

航空发动机及燃气轮机燃烧室结构呈现显著的环形特征^[1-4], 实现环形温度场的高精度重建, 在航空发动机燃烧室、燃气轮机等高温设备的状态监测与性能评估中具有至关重要的意义。

环形温度场中温度沿径向分布可能呈现明显的梯度变化特征^[5]。现有研究显示, 全环燃烧室出口温度场特征参数的概率分布规律为: 径向温度梯度的标准差随半径增大呈指数衰减趋势, 且径向温度分布系数相对稳定, 不受燃烧室部分结构参数变化的影响。但温度在圆周方向上既有基于对称性的周期分布, 又因局部湍流与混合不均匀而产生随机波动。如燃烧室壁面冷却孔、支撑结构等非对称特征会破坏完美对称性, 形成固定相位的温度畸变^[6]。以某型号涡扇发动机为例, 其典型温度状态可划分为慢车、节流、最大三个阶段。慢车状态高温部分集中在下部温度, 节流到最大状态截面温度分布依旧不均匀(温度可达 200 ~ 1 000 °C)^[7]。基于径向基函数的声速法炉内测温实验结果显示: 周向温度波动的功率谱密度在低频段(对应喷嘴周期)呈现显著峰值, 而在高频段则符合湍流能量级串分布规律, 进一步验证了周向温度的复合分布特征^[8]。传统测量方式多采用环形分层与等角度布点的策略, 旨在通过有限的传感器捕捉环形截面的主要温度模态, 从而在有限测点基础上实现全场高保真重建。

在温度场重建算法领域, 目前已有多种基于

传统插值和深度学习的方法^[9]。在传统插值方法方面, 线性插值虽计算效率高使用最广泛, 但在梯度突变区域或存在温度反转的过渡区易产生较大误差, 难以刻画非线性温度分布特征^[10]。径向基插值方法相较于线性插值平均相对误差可降低 14.8%。固定参数的径向基函数(Radial Basis Function, RBF)插值通过基函数组合进行曲面拟合, 对非线性关系具有一定适应能力, 但其参数通常全局统一, 难以同时兼顾边缘区域的连续性与中心区域的精细细节, 易出现边缘断裂或中心模糊等问题, 且数据稀疏区域适应性差, 拟合效果依赖变异函数的合理选择^[11-12]。

随着人工智能技术的发展, 深度学习算法为温度场重建提供了新的途径。卷积神经网络(Convolutional Neural Network, CNN)能够有效提取空间局部特征, 长短时记忆网络(Long Short-Term Memory, LSTM)则擅长处理时序依赖关系, 二者在图像重建、序列预测中已得到广泛应用^[13-14]。然而, 纯数据驱动的CNN或LSTM模型在温度场重建中, 存在明显局限性: 模型过于依赖训练样本的分布, 缺乏对物理守恒律(如能量守恒、热传导方程)的显式约束, 因而可能生成虽在统计上合理却物理不符合实际的温度分布, 例如出现非单峰温度场梯度、局部能量不守恒的异常热点^[15]等问题; 同时, 纯数据驱动的深度学习模型通常局限于插值场景, 在工况外推(输入超出训练集范围)时会产生较大误差, 甚至出现预测失败的情况^[16]; 此外, 神经网络参数的训练是一个优化过程, 因此

每次模拟的结果可能会受到网络初始化随机性的影响, 网格计算的解误差最大可达 10%^[17]。在高温场景应用中, 基于 LSTM 深度学习神经网络建立的焊接温度场与仿真温度场的节点温度值均方误差为 39.5 °C, 相对误差达 4.8%^[18]。在涡轮叶片温度反演研究中, 已有学者指出, 忽略物理约束的深度学习模型, 在工况外推时易出现性能退化与失真现象。这类方法本质上属于数据驱动的纯数学拟合, 未结合温度场的物理机制, 因此在数据稀疏或噪声干扰下, 易产生违背热力学规律的反常结果。

总体而言, 现有温度场重建方法未能从设计上适配环形布局、解决梯度异质性匹配与保障物理合规性三大核心需求。因此, 本文提出一种在 RBF 插值的基础上, 融合 CNN-LSTM 的分层物理约束的环形温度场重建方法, 该方法充分利用测量数据并结合风洞测量经验数据, 且专为环形温度场特征设计。首先, 设计环形自适应的 RBF 插值框架, 通过测点旋转测量的方式得到环形坐标位置的温度数据, 构建径向基函数进行初步插值, 得到一个基本的温度场; 其次, 通过 CNN-LSTM 混合神经网络分层提取局部特征, 增强对复杂温度分布的建模能力; 最后, 在网格训练过程中, 嵌入分层物理约束有关的损失函数。实际工程项目中, 通常要求重建方法能够分辨相距 2 mm 以上的两个点局部温度差异, 因此本文设定空间分辨率不低于 2 mm 的指标。通过多模块融合设计, 旨在实现环形温度场的高精度、高可靠性重建, 为温度场状态监测提供有效的技术手段。

1 总体框架与各模块原理

本文所提温度场重建方法整体架构如图 1 所示, 其由 4 个核心模块依次串联构成, 形成从原始数据到物理合规温度场的完整重建流程。首先由旋转测量的方式得到原始数据, 通过 RBF 插值模块得到初步的温度场, 随后通过 CNN-LSTM 混合神经网络处理梯度特征, 物理约束模块作用于全局满足温度场分布物理规律, 有效提高温度场重建精度。



图 1 算法总体架构图

Fig.1 Overall algorithm framework diagram

1.1 数据预处理与网格化模块

环形温度场的原始数据来源于按特定布局分布的传感器网络。实验中采用环形分层布设方式, 在 4 个特征半径位置(对应 T1 ~ T4 层)沿圆周等角度布置传感器。设传感器总数为 N , 每个传感器的位置由极坐标 (r_i, θ_i) 表示, 其中, r_i 为径向距离, θ_i 为角度坐标。

为适配后续算法的统一处理需求, 首先将极坐标转换为笛卡尔坐标

$$\begin{aligned} x_i &= r_i \cos \theta_i \\ y_i &= r_i \sin \theta_i \end{aligned} \quad (1)$$

式中: $i = 1, 2, \dots, N$ 。

为构建连续温度场, 需在传感器覆盖区域构建规则网格。设重建区域半径的最大值为 R_{max} , 网格分辨率由用户指定参数 M 确定。本算法在笛卡尔网格上执行插值与网络推理, 环形结构的先验信息通过径向距离 R 和角度 θ 来引入。自适应 $\varepsilon(r)$ 的设计不仅考虑了温度梯度变化, 也隐含了对极坐标网格密度不均的补偿: 中心区域 ε 较大, 核函数影响范围小, 适应高分辨力; 边缘区域 ε 较小, 核函数平滑, 适应低分辨率。因此, 各分层网格上的插值有效性是一致的。网格点在极坐标系下

可表示为

$$\begin{cases} r_j = \frac{j}{M} R_{\max}, j = 0, 1, \dots, M-1 \\ \theta_k = \frac{2\pi k}{M}, k = 0, 1, \dots, M-1 \end{cases} \quad (2)$$

式中: j 为径向网格点序号, k 为环向网格点序号。

相应的笛卡尔坐标为

$$(x_{jk}, y_{jk}) = (r_j \cos \theta_k, r_j \sin \theta_k) \quad (3)$$

网格分辨率 Δs 为

$$\Delta s = \frac{2R_{\max}}{M-1} \quad (4)$$

当 $R_{\max} = 50 \text{ mm}$, $M = 200$ 时, $\Delta s = 0.5 \text{ mm}$, 满足分辨率指标要求。

1.2 自适应混合核 RBF 插值模块

传统 RBF 插值采用单一核函数, 难以同时兼顾环形温度场的径向异质性与环向连续性。为此, 本文设计了多二次核与高斯核的加权混合核函数 $\varphi(d)$, 公式为

$$\varphi(d) = \alpha \sqrt{\varepsilon(r) \cdot d^2 + 1} + (1 - \alpha) e^{(-\varepsilon(r) \cdot d^2)} \quad (5)$$

式中: d 为任意网格点与离散测点间的欧氏距离; α 为权重系数, 控制两种核函数的贡献比例(通常取 0.5), 本文取 $\alpha = 0.5$, 旨在均衡全域趋势拟合能力与局部温度细节捕捉能力, 相同比例的混合可避免单一核函数的过平滑或过振荡; $\varepsilon(r)$ 为随径向距离动态调整的核参数。

环形温度场中心区域温度梯度变化剧烈, 需要缩小核函数的影响范围以保留细节; 边缘区域梯度平缓, 需要扩大核函数的影响范围以保证平滑性。因此, 定义 $\varepsilon(r)$ 为

$$\varepsilon(r) = 0.6 + 0.2e^{\left(\frac{-r}{50}\right)} \quad (6)$$

式中: r 为当前网格点的径向距离。该函数确保在中心区域 $\varepsilon(r) \approx 0.8$, 在边缘区域 $\varepsilon(r) \approx 0.62$, 实现了从中心到边缘的平滑过渡。

对于任意网格点 p , 其初始温度估计 $T_{\text{init}}(p)$ 由所有传感器数据的加权求和得到, 即

$$T_{\text{init}}(p) = \sum_{i=1}^N w_i \varphi(\|p - p_i\|) \quad (7)$$

式中: p 为待插值网格点的坐标向量; p_i 为第 i 个传感器测点的坐标向量; w 为权重系数向量, $w = [w_1, w_2, \dots, w_N]^T$; w_i 为第 i 个传感器对应的权重系数; $\varphi(\cdot)$ 为径向基函数; $\|\cdot\|$ 为欧氏距离算子。

有以下数学关系

$$\Phi w = T_{\text{sensor}} \quad (8)$$

式中: Φ 为 $N \times N$ 阶核函数矩阵, 其元素为 $\Phi_{ij} = \varphi(\|p_i - p_j\|)$; $T_{\text{sensor}} = [T_1, T_2, \dots, T_N]^T$ 为传感器实测温度向量, T_i 为第 i 个测点的实测温度值。

1.3 CNN-LSTM 混合神经网络模块

网络输入为初始温度场 T_{init} 的网格数据, 本文采用笛卡尔均匀网格对半径 50 mm 的圆形重建区域进行离散化, 网格数量为 $M \times M$ 。为增强网络对环形结构的感知能力, 将 r 和 θ 作为附加特征通道, 形成 $M \times M \times 3$ 的输入张量。

网络输出为每个网格点的温度修正值, 最终修正温度 $T_{\text{corrected}}$ 为

$$T_{\text{corrected}} = T_{\text{init}} + \Delta T \quad (9)$$

CNN 模块负责提取温度场的空间局部特征, 特别是径向梯度与环向曲率信息。网络结构如下:

1) 第一卷积层

卷积核尺寸为 3×3 , 步长为 1, 对输入特征图进行填充处理, 输出通道 32, 使用线性修正单元 (ReLU) 作为激活函数。该层捕获基础的局部温度模式。

2) 第二卷积层

卷积核尺寸为 3×3 , 步长为 1, 对输入特征图进行填充处理, 输出通道 64, 使用线性修正单元 (ReLU) 作为激活函数。该层提取更高层次的空间特征。

3) 池化层

采用 2×2 最大池化, 步长为 2。池化操作在平衡计算量的同时保留关键特征, 特别注意在径向维度避免过度下采样, 防止环形分层特征丢失。

通过引入径向位置信息作为输入特征, CNN 能够显式区分不同半径层的温度分布差异。但卷积核的感受野有限, 难以直接捕获同一半径层上长距离(如角度相隔 180°)的环向依赖关系。为有效建模环形温度场固有的环向周期性, 本文算法将 CNN 输出的空间特征转换为序列数据输入双向 LSTM。该序列取自空间角度维度而非时间维度, 可规避时间过拟合风险, 其目的在于保障环向温度分布的平滑连续性。具体流程如下:

1) 将 CNN 输出的特征矩阵按半径层切片, 每

层对应的环向网格点按角度顺序排列,形成序列数据。设共有 L 个半径层,每层序列长度为 M (环向网格点数)。

2) 每个序列输入双向LSTM网络,隐藏层维度为64。前向LSTM捕捉顺时针方向温度变化趋势,后向LSTM捕捉逆时针方向温度变化趋势。

3) 将双向LSTM输出拼接,得到128维时序特征向量。

空间特征与时序特征的融合结果为 f_{fusion} ,采用特征级拼接方式得到,即

$$f_{\text{fusion}} = f_{\text{CNN}} : f_{\text{LSTM}} \quad (10)$$

式中: f_{CNN} 为64维空间特征向量, f_{LSTM} 为128维时序特征向量。拼接后得到192维融合特征。

融合特征通过全连接网络进行非线性变换:

①第一全连接层:输入192维,输出128维,ReLU激活;②第二全连接层:输入128维,输出64维,ReLU激活;③输出层:输入64维,输出1维温度修正值 ΔT 。

1.4 分层物理约束模块

根据环形温度场的物理特性,将径向区域划分为三个子区域,分别施加不同的约束:中心高温区($r \leq 17 \text{ mm}$)接近热源,温度应随半径增大而递减,反映热量从中心向外扩散的基本规律;过渡区($17 \text{ mm} < r \leq 28 \text{ mm}$)可能出现气流回流导致的局部温度反转,不施加单调性约束以保留真实物理现象;边缘冷却区($r > 28 \text{ mm}$):该区域受冷却气流影响,温度快速递减。

总损失函数 $\mathcal{L}_{\text{total}}$ 由数据拟合项 $\mathcal{L}_{\text{data}}$ 与物理约束项加权构成,即

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{data}} + \lambda_1 \mathcal{L}_{\text{monotonic}} + \lambda_2 \mathcal{L}_{\text{edge}} + \lambda_3 \mathcal{L}_{\text{smooth}} \quad (11)$$

式中: $\mathcal{L}_{\text{monotonic}}$ 为单调性约束损失函数, $\mathcal{L}_{\text{edge}}$ 为梯

度约束损失函数, $\mathcal{L}_{\text{smooth}}$ 为平滑性约束函数, λ_1 、 λ_2 、 λ_3 为系数。

1) 中心区单调性约束

对于中心高温区,温度应沿径向单调递减。

定义径向梯度

$$\frac{\partial T}{\partial r}(r, \theta) = \frac{T(r + \Delta r, \theta) - T(r, \theta)}{\Delta r} \quad (12)$$

单调性约束损失为

$$\mathcal{L}_{\text{monotonic}} = \frac{1}{N_{\text{center}}} \sum_{r \leq 17 \text{ mm}} \sum_{\theta} \max\left(0, \frac{\partial T}{\partial r}(r, \theta)\right) \quad (13)$$

该损失项仅在梯度为正时产生惩罚,强制模型学习符合热传导规律的温度分布。

2) 边缘区梯度约束

对于边缘冷却区($r > 28 \text{ mm}$),温度下降速率应不低于 -0.5 K/mm 。梯度约束损失函数为

$$\mathcal{L}_{\text{edge}} = \frac{1}{N_{\text{edge}}} \sum_{\theta} \max\left(0, \frac{\partial T}{\partial r}(r, \theta) + 0.5\right) \quad (14)$$

3) 平滑性约束

为消除局部突变,引入全变分正则化项

$$\mathcal{L}_{\text{smooth}} = \sum_{i,j} \sqrt{(T_{i+1,j} - T_{i,j})^2 + (T_{i,j+1} - T_{i,j})^2} \quad (15)$$

所有约束施加后,采用二维高斯滤波对重建温度场进行后处理,进一步保证温度场的连续性和平滑性。

2 试验系统搭建

2.1 试验测试系统组成

为客观评估本文提出的重建算法在实际工程场景下的性能,设计并构建了一套完整的环形温度场测试验证系统。

测试系统利用的仪器设备如表1所示。测试系统传感器分布依据燃烧室环形结构设计为环形分

表1 仪器设备一览表

Tab.1 List of instruments and equipment

序号	名称	型号	技术指标	数量
1	1 700 °C热校准风洞	RD-03	试验段直径为 $\Phi 100 \text{ mm}$, 气流温度为900 ~ 1 700 °C	1个
2	压力传感器	CYG1102	0.15级, 量程为100 kPa	1支
3	数字无汞气压计	BQY	最大允许误差为 $\pm 40 \text{ Pa}$	1台
4	电压采集卡	NI9205	测量范围为 $\pm 10 \text{ V}$, 最大允许误差为 $\pm 6.230 \text{ mV}$	1块
5	智能温度数据采集仪	iTDAS-16	K型误差为 $\pm 0.5 \text{ }^{\circ}\text{C}$, B型误差为 $\pm 4 \text{ }^{\circ}\text{C}$	1台

层传感器网络。智能温度数据采集仪连接使用的传感器,测点编号为1~7,其中,1~4号测点为重建核心测点,用于温度场模型重建;5~7号测点为独立验证测点,不参与模型训练,用于重建精度校验。如图2所示,7个测点分设于2支传感器探针,1~4号测点布置于0、13、26、39 mm四个特征径向位置(分别对应T4、T3、T2、T1层),5~7号测点布置于15、28、41 mm径向位置。转盘转速 $50(^{\circ})/\text{s}$,智能温度数据采集仪采样率20 Hz,旋转一周测量可得到一个反映环形结构特征、又具备验证冗余的稀疏观测阵列。总温传感器(K型和B型热电偶)如图3和图4所示。




图2 传感器分布示意图

Fig.2 Schematic diagram of sensor distribution




图3 总温传感器(K型热电偶)示意图

Fig.3 Schematic diagram of total temperature sensor (K-type thermocouple)

转盘旋转一周每一个测点得到141个数据,两支传感器是安装于同一圆周直径上,测试测点数据(T1~T4)与验证测点数据(T5~T7)在空间上起始位置相差 180° ,因此需要对验证测点数据按照空间分布排列至与测试测点数据位置相同起始角度。例如,13 mm(T3层)与15 mm(T5层)测点径向

间距为2 mm,通过计算T5层数据与重建温度场相同位置的数据的相对误差,即可验证算法是否符合2 mm空间分辨力性能。

试验工况的设计充分参考某型号发动机慢车状态、节流状态、最大状态的温度情况,选取500、1 000、1 750 K三个具有代表性的温度工况,涵盖了从低温到高温的范围,试验现场如图5所示。CNN-LSTM网络的结构参数及分层物理约束规则在整个试验中保持不变,以验证其普适性。




图4 总温传感器(B型热电偶)示意图

Fig.4 Schematic diagram of total temperature sensor (B-type thermocouple)



图5 总温传感器安装示意图

Fig.5 Schematic diagram of total temperature sensor installation

2.2 验证指标与对比设置

验证工作的核心目标为:严格检验算法能否在500、1 000、1 750 K工况下,稳定达成空间分辨力 ≥ 2 mm、全场重建相对误差 $\leq 5\%$ 的关键性能指标。

为量化各模块的有效性,本文采用基线对比与消融试验相结合的验证方案:一是以工程常用的固定参数传统RBF插值方法为基线,对比本文方法与传统方法的重建精度差异;二是设计两组模型变体(变体A和变体B)开展消融试验,分别禁

用CNN-LSTM模块、物理约束模块，控制试验数据与工况条件一致，验证各核心模块的增益效果。

试验采用独立验证测点数据完成精度评估，通过计算验证测点实测温度与重建温度场对应位置插值温度的平均相对误差、最大相对误差，量化重建精度；通过对比2 mm径向间距测点的温度还原精度，验证算法的空间分辨力性能。

3 试验结果分析

3.1 模型误差计算结果对比

本次实验重建区域半径为50 mm，插值网格划分为200×200，相邻网格节点距离为0.5 mm，优于2 mm的工程指标。为验证算法对2 mm空间细节的还原能力，选取半径13 mm(T3层)与15 mm(T5层)2个相距2 mm的圆周，对比T5层实测温度与重建场在对应位置的插值温度。结果表明：在所有工况下，T5层验证点的平均相对误差均小于5%，证明算法能够有效分辨2 mm间距的温度差异。

为比较模型误差计算结果，选取了RBF、RBF+物理约束、U-Net、CNN四种方法，对验证测点温度值与该位置的插值结果进行误差指标计算。其中，RBF插值是传统的空间插值方法，作为基线方法；另外，在RBF基础上，施加本文提出的分层物理约束比较效果；普通CNN为不含LSTM和物理约束的卷积神经网络，作为纯数据驱动的方法对比；U-Net为图像分割领域的经典深度学习方法，具有跳跃连接结构，同样作为一个比较方案。结果如表2所示。

由试验结果可知，本文方法在全工况下的综合重建精度均优于对比方法。500 K低温工况下，本文方法平均相对误差仅为0.22%，最大误差0.52%，相较纯CNN模型精度提升显著，证明CNN-LSTM模块可有效优化环向温度分布连续性，提升低梯度温度场重建精度。同时，试验结果体现出温度工况对重建精度的显著影响：随工况温度升高，各方法重建误差均呈上升趋势，500 K工况下各方法误差差异较小，1 000 K工况下误差普遍升至0.5%~1.0%，1 750 K高温高梯度工况下误差进一步增大至2.7%~3.6%。该现象源于高温工况下温度梯度剧烈、边界条件复杂，重建难度

表2 500、1000、1750K工况下各模型误差计算结果
Tab.2 Model error calculation results under 500 K, 1 000 K, and 1 750 K working conditions

工况/K	方法	平均相对误差/%	最大误差/%
500	RBF	0.49	0.55
	RBF + 物理约束	0.32	0.69
	U-net	0.51	0.84
	CNN	0.41	1.75
	本文方法	0.22	0.52
1 000	RBF	1.52	1.89
	RBF + 物理约束	0.45	1.48
	U-net	0.51	0.97
	CNN	0.85	1.57
	本文方法	0.48	1.45
1 750	RBF	3.56	3.96
	RBF + 物理约束	3.15	4.75
	U-net	3.21	4.75
	CNN	2.73	4.35
	本文方法	2.73	4.24

显著提升，而本文方法误差增长速率最为平缓，工况适应性最优。1 750 K工况下传统RBF插值最大误差相对较小，其原因是传统RBF为抑制高温梯度区域过拟合，默认采用大平滑参数，虽降低了局部极端误差，但过度平滑导致温度细节丢失、整体平均误差升高。后续研究可针对该问题优化算法，引入前置数据去噪处理，平衡细节保留与异常值抑制的关系。

各工况下本文方法重建的温度场分布如图6所示，不同工况温度场呈现出差异化的径向、周向分布特征，贴合燃烧室真实温度分布规律。

3.2 各误差模块消融分析

为探究本文方法中设计的CNN-LSTM模块和物理约束模块各自作用效果，本文设计了1 750 K工况下的消融实验，即在保持其他设置不变的前提下，分别禁止本文方法中的部分模块，观察模型输出结果的变化。训练样本由同一RBF插值模块得到，保持训练样本均为200个，训练轮数为20轮。

基于前文误差的设置，构建以下2个模型变体




图6 各工况下融合CNN-LSTM与分层物理约束的插值温度场

Fig.6 Interpolated temperature fields under various working conditions by integrating CNN-LSTM and hierarchical physical constraints

进行对比。①变体A: 移除CNN-LSTM模块, 仅保留RBF模块与物理约束模块; ②变体B: 移除物理约束模块, 仅保留RBF模块与CNN-LSTM模块。

各工况下变体A、变体B模型插值温度场如图7所示。三组模型在各工况下的重建误差对比如表3所示。多工况对比结果表明: 完整模型在各试验工况下的重建精度最优。移除CNN-LSTM模块的变体A在500、1 000 K工况下最大误差相较完整模型小幅变化, 增幅分别为0.85、-0.3 K, 平均相对误差波动均小于1 K, 整体误差变化幅度有限。在1 750 K高温工况下, 变体A平均相对误差升至3.15%, 最大误差为4.75%。该工况温度水平高, 在梯度较大的径向分层上, 相邻周向测点温度落差最高可达15 K, 温度突变特征显著。从温度场云图可见, 去掉CNN-LSTM后环向温度连续性被破坏, 周向分布呈现锯齿状波动、场域边缘平滑性变差, 上述问题在三个工况中均有不同程度体现。

500 K与1 000 K工况下, 去除物理约束的变体B平均相对误差、最大误差均高于变体A, 说明中低温工况下物理约束对重建精度的影响更为突出, 相较完整模型其最大误差分别升高6、3 K; 而1 750 K工况下变体B各项误差低于变体A、结果更贴近完整模型, 反映高温工况下温度场梯度与非均匀特征发生改变。云图结果显示, 无物理约束时温度场平滑区域易出现异常高低温斑块, 证明物理约束能够有效剔除违背物理规律的非物理解, 也与实测温度场天然存在不均匀分布的试验规律相符。

3.3 重建结果物理合规性分析

采用独立的验证数据集进行验证, 并结合定量指标和定性对比分析重建结果的物理合理性。验证数据集来源于试验中每一个工况下进行的多组重复性测量, 该部分数据没有参与模型训练仅作为重建结果合规性分析。

为确保验证的独立性, 采用与训练数据不同组试验获得的传感器数据进行验证。验证数据集包含3个工况(500、1 000、1 750 K), 试验系统与试验方法与2.1节完全一致。

对3个工况的插值温度场进行定性分析, 结果如图8所示。重建温度场等温线呈现典型分布特




图7 各工况下变体A、变体B模型插值温度场

Fig.7 Interpolated temperature fields of variant A and variant B models under various operating conditions

征：最高温区域不位于截面几何中心，径向存在温度反转现象，周向伴随局部波动。本文图4的重建结果也呈现出一致规律，即径向温度分布并非

完全单调递减、存在局部温度反转，同时具备周向周期性波动特征。相同工况下两类结果的温度分布形态高度吻合，间接验证了本文方法重建结

表3 三组模型在各工况下的重建误差对比
Tab.3 Comparison of reconstruction errors of three sets of models under various operating conditions

工况 / K	模型类别	平均相对误差 / %	最大误差 / %
500	完整模型	0.22	0.52
	变体 A	0.32	0.69
	变体 B	0.41	1.75
1 000	完整模型	0.48	1.45
	变体 A	0.45	1.48
	变体 B	0.59	1.71
1 750	完整模型	2.73	4.24
	变体 A	3.15	4.75
	变体 B	2.73	4.25

果的物理真实性。


表4为各工况下独立数据集插值温度场误差计算结果。计算结果表明，本文方法在3个工况下均取得了较好的重建精度。500 K和1 000 K工况下误差较小，1 750 K工况下误差有所增加，但仍保持在工程可接受范围内(< 5%)。

表4 各工况下独立数据集插值温度场
误差计算结果


Tab.4 Error results of interpolated temperature field with independent datasets under each working condition

试验工况 / K	平均相对误差 / %	最大误差 / %
500	0.18	0.41
1 000	0.26	1.72
1 750	3.15	4.61


综合定量和定性验证结果可知：本文方法在不同工况下均能取得较好的重建精度，平均相对误差低于3.5%；重建结果与独立实验数据具有良好的一致性，验证了方法的泛化能力。由于试验条件的限制，本文暂无法提供与训练工况完全相同的实测全场温度数据进行逐点对比。未来的研究中将进一步完善验证方案，采用更高密度的传感器阵列进行更全面的验证。



(a) 500 K插值温度场
(a) Interpolated temperature field under 500 K working condition



(b) 1 000 K插值温度场
(b) Interpolated temperature field under 1 000 K working condition



(c) 1 750 K插值温度场
(c) Interpolated temperature field under 1 750 K working condition

图8 各工况下单独数据集融合CNN-LSTM与
分层物理约束的插值温度场

Fig.8 Interpolated temperature field fusing CNN-LSTM and
layered physical constraints with separate datasets
under each working condition

4 结论

本文针对环形温度场重建问题,研究了传感器稀疏布局下温度场高精度重建技术。在深入分析环形温度场径向异质性与环向周期性特征的基础上,提出了一种融合自适应径向基函数插值、CNN-LSTM混合网络与分层物理约束的重建方法。围绕该方法进行原理阐述、系统搭建与试验验证和试验结果分析。

在算法设计层面,提出了由3个核心模块构成的环形温度场重建框架。首先通过自适应RBF模块对径向梯度变化的灵活适配形成一个初步的温度场;再通过CNN-LSTM混合网络通过空间特征提取与环向时序和温度场的局部细节与角度方向的周期性依赖,对温度场的梯度分布进行调整;最后通过分层物理约束模块依据热传导规律,对中心高温区、过渡区及边缘冷却区施加差异化约束,从根本上保障了重建结果的合理性。

在试验验证层面,搭建了基于环形分层传感布局的测试系统,覆盖典型工况500、1000、1750 K。本文提出的融合自适应RBF、CNN-LSTM与分层物理约束的方法,在3个工况下均实现了高精度重建。其中,1750 K高温高梯度工况的平均相对误差为2.73%,最大相对误差4.24%,插值点间距0.5 mm,与多种方法对比误差结果最优。为研究模块具体效果的消融实验表明移除LSTM模块(变体A)后,环向温度曲线出现锯齿状波动,平均误差升至3.15%;移除物理约束模块(变体B)后,相对误差和最大误差均变大。这验证了LSTM对环向连续性的保障作用以及物理约束对结果有正向作用。最后,通过某型号涡扇发动机的温度分布结果,验证插值结果的物理合规性。

该算法在航空发动机环形温度场重建中具有重要应用价值,可为发动机健康监测和性能优化提供精确的温度场数据。未来可进一步优化LSTM网络结构以提升高温场景的重建精度,探索自适应物理约束参数以适应不同工况,结合实时传感器数据实现动态温度场监测,并扩展到三维温度场重建,为发动机热状态监测提供更全面的技术支持。

参考文献

- [1] 彭拾义. 环形燃烧室出口热点和冷点的研究[J]. 燃气轮机技术, 1991(1): 30-36.
PENG S Y. Study on hot spots and cold spots at the exit of annular combustor [J]. Gas Turbine Technology, 1991 (1): 30-36. (in Chinese)
- [2] 张宝诚. 环形燃烧室出口温度分布系数的研究[J]. 航空动力学报, 1989(1): 70-72, 94.
ZHANG B C. Study on temperature distribution coefficient at the exit of annular combustor [J]. Journal of Aerospace Power, 1989(1): 70-72, 94. (in Chinese)
- [3] CAO Z, LI J, SONG W, et al. Experimental study on measurement of outlet temperature and component concentration in a aeroengine combustor [J]. Energy, 2025, 322: 135458.
- [4] ZHENG Q, CAI C, ZHANG H, et al. Prediction of engine combustion chamber outlet temperature field based on deep Learning: Application in aero-engine life extension control [J]. Applied Thermal Engineering, 2024, 254: 123911.
- [5] 张广岩, 张弛, 王柏森, 等. 全环燃烧室出口温度场特征参数概率分布研究[J]. 航空动力学报, 2025, 40(8): 86-95.
ZHANG G Y, ZHANG C, WANG B S, et al. Probability distribution study on characteristic parameters of outlet temperature field of full-annular combustor [J]. Journal of Aerospace Power, 2025, 40(8): 86-95. (in Chinese)
- [6] 郑剑文, 江立军, 刘涛, 等. 旋流器套筒扩张角对燃烧室出口温度分布的影响[J]. 航空动力学报, 2024, 39(10): 1-8.
ZHENG J W, JIANG L J, LIU T, et al. Influence of swirler sleeve expansion angle on combustor outlet temperature distribution [J]. Journal of Aerospace Power, 2024, 39(10): 1-8. (in Chinese)
- [7] 程鲁, 闫卫青, 张帅, 等. 某型航空发动机排气温度场测量[J]. 内燃机与配件, 2024(11): 22-24.
CHENG L, YAN W Q, ZHANG S, et al. Measurement on exhaust temperature field of a certain type aero-engine [J]. Internal Combustion Engine & Parts, 2024 (11): 22-24. (in Chinese)
- [8] 檀经考, 李娜, 陈乐航, 等. 基于径向基函数的声速法炉内测温实验研究[J]. 动力工程学报, 2025, 45(1): 28-36.
TAN J K, LIN, CHEN L H, et al. Experimental study on in

- furnace temperature measurement by sonic method based on radial basis function[J]. Journal of Chinese Society of Power Engineering, 2025, 45(1): 28-36. (in Chinese)
- [9] 高山, 熊新梦, 刘海龙. 基于红外辐射的发动机涡轮叶片温度测量方法综述[J]. 计测技术, 2024, 44(4): 1-28.
- GAO S, XIONG X M, LIU H L. Review of temperature measurement methods for engine turbine blades based on infrared radiation[J]. Metrology & Measurement Technology, 2024, 44(4): 1-28. (in Chinese)
- [10] 王高, 梁海坚, 魏艳龙, 等. 超高温极端环境下的超声测温技术研究进展[J]. 计测技术, 2024, 44(5): 1-13.
- WANG G, LIANG H J, WEI Y L, et al. Research progress of ultrasonic temperature measurement technology in ultra-high temperature extreme environment [J]. Metrology & Measurement Technology, 2024, 44(5): 1-13. (in Chinese)
- [11] 王兴杰, 陈东兴, 陈传法, 等. 顾及空间异质性的断裂地形区高精度DEM建模方法[J]. 武汉大学学报(信息科学版), 2025, 50(11): 2303-2310.
- WANG X J, CHEN D X, CHEN C F, et al. High-precision DEM modeling method for fractured terrain considering spatial heterogeneity [J]. Geomatics and Information Science of Wuhan University, 2025, 50(11): 2303-2310. (in Chinese)
- [12] 陈楚戈, 石顶峰, 丛洲洋, 等. 基于自适应区域权重混合模型的燃烧场温度和气体浓度二维重建方法[J]. 物理学报, 2025, 74(21): 123-135.
- CHEN C G, SHI D F, CONG Z Y, et al. Two-dimensional reconstruction method of combustion field temperature and gas concentration based on adaptive regional weight hybrid model [J]. Acta Physica Sinica, 2025, 74(21): 123-135. (in Chinese)
- [13] 陈薇, 赵军, 刘海军, 等. 基于CO预测模型的垃圾协同处置下分解炉出口温度控制[J]. 计算机测量与控制, 2025, 33(12): 89-95, 136.
- CHEN W, ZHAO J, LIU H J, et al. Temperature control of decomposition furnace outlet under garbage CO-disposal based on co prediction model [J]. Computer Measurement & Control, 2025, 33(12): 89-95, 136. (in Chinese)
- [14] 王桢, 赵起超, 王昊琦, 等. 法布里-珀罗游标光谱信号的深度学习解调[J]. 计测技术, 2025, 45(3): 70-77.
- WANG H, ZHAO Q C, WANG H Q, et al. Deep learning demodulation of Fabry-Perot vernier spectral signals [J]. Metrology & Measurement Technology, 2025, 45(3): 70-77. (in Chinese)
- [15] 彭浩然, 胡贵华. 基于物理信息深度学习算法的Flame D热流场重构研究[J]. 华东理工大学学报(自然科学版), 2024, 50(6): 878-887.
- PENG H R, HU G H. Reconstruction study of Flame D thermal flow field based on physics-informed deep learning algorithm [J]. Journal of East China University of Science and Technology (Natural Science Edition), 2024, 50(6): 878-887. (in Chinese)
- [16] MIN Z, HANDI Z, ANRAN J, et al. Reliable extrapolation of deep neural operators informed by physics or sparse observations [J]. Computer Methods in Applied Mechanics and Engineering, 2023, 412. DOI: 10.1016/j.cma.2023.116064.
- [17] CAI S, WANG Z, WANG S, et al. Physics-informed neural networks for heat transfer problems [J]. Journal of Heat Transfer, 2021, 143(6): 060801.
- [18] 黄浩浩. 基于深度学习的GMAW焊接温度场重构方法及应用[D]. 长沙: 中南大学, 2024.
- HUANG H H. Reconstruction method and application of GMAW welding temperature field based on deep learning [D]. Changsha: Central South University, 2024. (in Chinese)

(本文编辑: 刘宇轩 刘圣晨)



第一作者: 李书缘(1997—), 助理工程师, 硕士, 主要研究方向为高温气流温度测量校准。



通信作者: 赵俭(1973—), 男, 研究员, 博士生导师, 中国空天动力联合会试验测试与检测技术专委会委员。主要研究方向为气流温度测量与校准技术。主持科研项目20余项, 获省部级及一级学会科学技术奖15项, 发表论文70余篇, 主持出版专著1部, 主持编写标准规范6项, 获授权发明专利19项。