

# 基于可测数据的球床式高温气冷堆堆芯 温度场残差神经网络预测方法

刘 伟<sup>1</sup> 孟金星<sup>2</sup> 伍 钊<sup>2</sup> 单建强<sup>2</sup>

1(华能核能技术研究院有限公司 上海 200126)

2(西安交通大学 西安 710049)

**摘要** 高温气冷堆(High-Temperature Gas-Cooled Reactors, HTGR)堆芯温度场的实时精准监测对反应堆安全运行至关重要,但受限于极端环境,工程上仅能获取稀疏的边界测点与宏观工况数据。针对传统数值模拟耗时长、现有数据驱动模型物理感知能力弱且易在局部大温差区域失真的问题,通过引入残差连接机制,构建了面向高温气冷堆的改进型全连接网络模型。该模型利用可测量的宏观热力学参数及侧反射层离散温度数据,实现了堆芯稳态温度场的高保真反演。并且,在模型优化目标中引入了空间梯度损失函数,以约束相邻节点的温度连续性特征。基于高温气冷堆分析程序“华麒”生成的数据集验证表明,该模型单样本平均预测时间仅约 7.5 ms,总体平均绝对误差(Mean Absolute Error, MAE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)分别低至 0.51 °C 和 0.162%,预测精度与稳定性显著优于多层感知机(Multilayer Perceptron, MLP)与支持向量回归(Support Vector Regression, SVR)等基准模型。对比实验证实,空间梯度损失的引入有效降低了高温区域预测误差,使总体 MAE 降低了约 53%。研究结果表明,该方法可为高温气冷堆在线监测与数字孪生系统构建提供高效可靠的数据驱动技术路径。

**关键词** 高温气冷堆, 数据驱动, 人工神经网络, 堆芯温度场, 残差神经网络

**中图分类号** TL99

**DOI:** 10.3724/j.0253-3219.2026.hjs.49.260109

**CSTR:** 32193.14.hjs.CN31-1342/TL.2026.49.260109

## Residual neural network-based prediction method for core temperature field of pebble-bed high-temperature gas-cooled reactor using measurable data

LIU Wei<sup>1</sup> MENG Jinxing<sup>2</sup> WU Zhao<sup>2</sup> SHAN Jianqiang<sup>2</sup>

1(Huaneng Nuclear Energy Technology Institute, China Huaneng Group Co., Ltd., Shanghai 200126, China)

2(Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract** [Background] The real-time monitoring of the core temperature field in High-Temperature Gas-Cooled Reactors (HTGR) is crucial for reactor safety. However, extreme in-core environments prevent the deployment of dense sensor networks. Traditional numerical simulations are computationally expensive, while conventional data-driven models often lack spatial physical perception, leading to distortion in areas with severe temperature gradients.

华能集团总部科技项目“高温气冷堆燃煤替代示范工程方案设计”(No.HNKJ22-H07 HN-750)资助

第一作者: 刘伟, 男, 1989 年出生, 2020 年于中国核动力研究院设计院获博士学位, 研究领域为反应堆热工水力与安全分析

通信作者: 单建强, E-mail: jqshan@mail.xjtu.edu.cn

收稿日期: 2026-03-17, 修回日期: 2026-06-04

Supported by China Huaneng Group Headquarters Science and Technology Project "High-Temperature Gas-Cooled Reactor Coal Replacement Demonstration Project Scheme Design" (No.HNKJ22-H07 HN-750)

First author: LIU Wei, male, born in 1989, graduated from Nuclear Power Institute of China with a doctoral degree in 2020, focusing on thermal hydraulic and safety analysis of nuclear reactor

Corresponding author: SHAN Jianqiang, E-mail: jqshan@mail.xjtu.edu.cn

Received date: 2026-03-17, revised date: 2026-06-04

**[Purpose]** This study aims to develop a highly efficient and accurate data-driven surrogate model to reconstruct the high-fidelity 2D steady-state temperature field of the High Temperature gas-cooled Reactor Pebble-bed Module (HTR-PM) core using only sparse, measurable macroscopic operating conditions and side reflector temperatures. **[Methods]** Firstly, an improved Deep Residual Multilayer Perceptron (ResNet-MLP) model for HTR-PM was proposed by introducing residual connection mechanism. High fidelity inversion of core steady-state temperature field was realized by using measurable macro thermodynamic parameters and discrete temperature data of lateral reflector. Then, a novel spatial gradient-aware loss function was introduced into the optimization objective to constrain the thermodynamic continuity between adjacent spatial nodes. Finally, The model's performance was evaluated against traditional MLP and Support Vector Regression (SVR) baselines under the same verification criteria and dataset generated by the system analysis code HUAQI developed by Huaneng Nuclear Energy Technology Institute, China. **[Results]** Evaluation results show that the ResNet-MLP model achieves an overall Mean Absolute Error (MAE) of 0.51 °C and a Mean Absolute Percentage Error (MAPE) of 0.162%, significantly outperforming SVR and standard MLP. The average prediction time per sample is approximately 7.5 ms. Ablation studies demonstrate that the incorporation of the spatial gradient loss effectively eliminates the "over-smoothing" phenomenon, reducing the overall MAE by approximately 53% compared to pure Mean Squared Error (MSE) training. **[Conclusions]** The ResNet-MLP model proposed in this study constrained by spatial gradients, effectively overcomes the representation bottlenecks of shallow machine learning algorithms, providing a robust, ultra-fast, and highly accurate technical solution for the online condition monitoring and digital twin construction of advanced nuclear reactors.

**Key words** HTGR, Data-driven, Artificial neural network, Core temperature field, ResNet

高温气冷堆 (High Temperature Gas-Cooled Reactor, HTGR) 作为一种先进的核反应堆类型, 凭借其高温、高效率和高安全性等优势<sup>[1-2]</sup>, 在能源生产和工业应用中具有广阔的前景。我国建设了 250 MW 高温气冷堆示范工程 HTR-PM, 并于 2024 年实现了商业化运行<sup>[3-4]</sup>。在 HTGR 的日常运行与安全评估中, 堆芯温度场的空间分布是极其关键的安全参数, 直接关系到燃料元件的完整性、反应性的控制以及事故工况下的安全裕度<sup>[5]</sup>。然而, 由于反应堆堆芯内部面临极端的强辐射和高温环境, 现有的传感器技术难以在堆芯内部署密集的测温探头。在实际工程中, 操作人员通常只能获取堆芯外围侧反射层的离散测点数据以及宏观热力学工况参数 (如功率、压力、流量等)。如何利用这些极其有限的稀疏边界可测数据, 实时、精准地反演堆芯内部完整的稳态温度场, 已成为高级反应堆在线状态监测与数字孪生系统建设中的技术瓶颈。

近年来, 人工神经网络在核工程领域<sup>[6]</sup>的参数预测与状态反演中展现出巨大潜力。在球床式高温气冷堆研究中, 相关应用逐渐深入。在堆芯物理参数预测方面, 美国爱达荷国家实验室针对球床堆燃料耗计算中的微观截面生成问题, 开发了基于深度神经网络 (Deep Neural Network, DNN) 的降阶模型, 实现了截面库的高效构建与快速调用, 较传统多维插值方法在内存效率上提升数个数量级, 为堆芯高保真模拟提供了新途径<sup>[7]</sup>。在核材料衡算领域, 刘若

晴等<sup>[8]</sup>基于 10 MW 高温气冷实验堆, 构建了深度神经网络模型, 以易测核素活度为输入、难测超铀元素活度为输出, 实现了辐照后燃料中超铀元素的在线估算。在球床流动特性研究方面, Wu 等<sup>[9]</sup>基于卷积神经网络 (Convolutional Neural Network, CNN) 模型预测球床式高温气冷堆中燃料球的停留时间相关特征, 实现了对燃料球流动行为的快速识别。在热工水力参数预测方面, Chen 等<sup>[10]</sup>将本征正交分解 (Proper Orthogonal Decomposition, POD) 方法与神经网络结合, 建立了面向气冷堆堆芯热分析的降阶模型, 实现了温度场的快速预测。Zhang 等<sup>[11]</sup>基于循环神经网络 (Recurrent Neural Network, RNN) 建立了最高温度预测模型, 利用 8 个运行参数及探测器信息, 实现了对底部反射器温度的准确预测, 为高温气冷堆关键温度参数的实时监测提供了有效手段。Coppo Leite 等<sup>[12]</sup>提出了物理信息卷积神经网络 (Physics-Informed Convolutional Neural Network, PI-CNN) 模型, 利用冷却通道传感器数据重构了高温气冷堆燃料组件固体区域温度场, 为稀疏测点条件下的温度场监测提供了参考。

上述研究验证了人工神经网络在球床式高温气冷堆物理参数预测以及热工参数预测中的可行性。然而, 针对球床式高温气冷堆堆芯内部温度场的高保真重构问题, 现有研究仍主要集中于组件级特性或系统级参数预测, 如何利用有限边界测点实现堆芯大梯度温度场的实时反演, 仍是待解决的工程难

题。针对上述挑战,本研究旨在利用宏观工况参数(压力、功率、流量、进出口温度)以及位于堆芯外围的侧反射层离散温度测点数据等可测量数据,对HTR-PM堆芯温度场进行快速且精准的预测。为此,本文提出了一种改进的残差全连接网络多层感知器(Residual Network - Multilayer Perceptron, ResNet-MLP)架构,并在优化目标中引入了空间梯度损失函数,以专门应对和改善高温堆堆芯区域局部温差大的预测失真问题。

## 1 数据来源与生成

### 1.1 数值方法

HTR-PM的单个堆芯由压力容器、燃料球床、碳砖、内部空腔以及堆内其他支撑结构组成,其结构如图1所示<sup>[13]</sup>。其中燃料球床是一个由大量燃料球堆积而成的腔室,主体为圆柱体,下部接近出口处是漏斗状,球床四周布置了大量的碳砖,在这些碳砖中布置了24个控制棒孔道和用来辅助停堆的6组吸收球孔道,在反射层外还设置了30个冷氦流通孔道<sup>[14]</sup>,并且在侧反射层沿堆芯设置了6个温度测量点。

氦气作为冷却剂,在整个系统中的流动过程为:经过主氦风机后,通过同轴管道外侧的环形通道流入堆芯,进入堆芯后向下进入压力容器下部,流过堆芯底部支撑结构并对其进行冷却,然后通过侧反射层的冷氦通道向上流动,进入冷氦联箱,大部分穿过球床对球床进行冷却后继续向下穿过底反射层进入热氦联箱,一小部分经由控制棒通道和碳砖缝隙直接进入热氦联箱,这两部分氦气在热氦联箱中混合后通过同轴管道内侧通道进入螺旋管-直流式蒸汽发生器,与二次侧进行换热后向上流动,在此进入主氦风机,至此冷却剂完成一次循环<sup>[15]</sup>。

本研究采用华能核能技术研究院研发的高温气冷堆分析程序“华麒”<sup>[16]</sup>对HTR-PM稳态特性进行计算。“华麒”是一套面向球床式高温气冷堆的分析程序,能够对主回路在稳态及各类瞬态工况下的热工水力、核反应等行为进行模拟,可用于预测反应堆运行过程中的关键物理参数分布。在热工水力计算方




图1 HTR-PM结构示意图

Fig.1 Schematic diagram of HTR-PM structure

面,堆芯区域采用二维轴对称局部非热平衡多孔介质模型进行描述,流动控制方程为附加多孔介质阻力源项的准静态方程,并通过能量守恒方程分别求解冷却剂与固相球床的温度分布。在核物理计算方面,基于二维柱坐标系下的中子扩散方程,对堆内中子通量及反应堆功率进行求解。通过上述多物理场计算,“华麒”软件能够获得不同工况下堆内结构和氦气的物理场分布。

基于程序构建了HTR-PM一回路模型,涵盖反应堆压力容器、一回路、蒸汽发生器及主氦风机等部件。图2展示了堆芯建模和一维外回路模型图。程序在二维 $(r, z)$ 圆柱坐标系下建立堆芯模型,坐标原点设于球床自由表面对应平面与球床中心轴线的交点,堆芯与外回路通过进出口耦合连接。

为确保计算结果的准确性,须对程序输出进行验证。对HTR-PM进行稳态计算,基于HTR-PM的稳态设计参数进行验证,并将稳态计算结果与文献结果进行对比,如表1所示。结果表明,计算值与设计值的偏差小于1%。

此外,利用模型与HTR-PM实堆运行实验数

表1 HTR-PM设计参数验证<sup>[17]</sup>  
Table 1 Verification of HTR-PM design parameters<sup>[17]</sup>

| 参数 Parameters                                                  | 设计值 Design value | 计算值 Calculated value | 误差 Error / % |
|----------------------------------------------------------------|------------------|----------------------|--------------|
| 功率 Power / MW                                                  | 250              | 250.00               | —            |
| 一回路压力 Primary helium pressure / MPa                            | 7                | 7.00                 | —            |
| 一回路流量 Helium mass flow rate / $\text{kg} \cdot \text{s}^{-1}$  | 96               | 96.10                | 0.001        |
| 入口温度 Helium temperature at reactor inlet / $^{\circ}\text{C}$  | 250              | 250.03               | 0.000        |
| 出口温度 Helium temperature at reactor outlet / $^{\circ}\text{C}$ | 750              | 751.07               | 0.001        |




图2 堆芯和一维外回路计算模型图(彩图见网络版)  
Fig.2 Calculation model diagram for core and one-dimensional outer loop (color online)

据<sup>[17]</sup>对模型计算的侧反射层温度进行验证,侧反射层轴向温度测点数据由嵌入在球床外围垂直间隙内、沿轴向布置的热电偶获取。在每一轴向高度处设置两个相对布置的热电偶,并对其测量值取平均值,以获得该高度的温度。沿堆芯轴向方向共布置6个测量高度,形成6个轴向温度测点数据。根据表2中数据建立模型进行计算,对比结果如图3所示,其中最大温度偏差约为4%。由以上结果可得,该计算模型具有高度准确性与可靠性。

表2 HTR-PM运行参数<sup>[18]</sup>  
Table 2 Operational parameters of HTR-PM<sup>[18]</sup>

| 参数名称 Parameters                                              | 数值 Value    |
|--------------------------------------------------------------|-------------|
| 反应堆总功率 Reactor total thermal power / MW                      | 200         |
| 一回路压力 Primary helium pressure / MPa                          | 7           |
| 反应堆入口/出口氦气温度 Helium temperature at reactor inlet/outlet / °C | 246.7/577.7 |
| 氦气流量 Helium mass flow rate / kg·s <sup>-1</sup>              | 116.3       |

## 1.2 数据生成

研究基于高温气冷堆分析程序“华麒”对不同运行工况下的堆芯温度场进行数值模拟,堆芯区域在二维 $r$ - $z$ 坐标系下进行离散,节点划分为 $20 \times 5$ (轴向 $\times$ 径向),对应模型输出为100个离散温度节点,构




图3 侧反射层温度计算结果与实验数据的比较(彩图见网络版)

Fig.3 Comparison of temperature at lateral reflector between simulation data and experimental data (color online)

成堆芯温度场的离散表示。计算过程中,通过重新设定模型的运行参数(功率、压力、入口温度及流量)作为边界条件,独立开展稳态数值计算,得到对应工况的堆芯二维温度场分布数据。参考HTR-PM实际运行范围的数据,在4个参数的区间范围内进行拉丁超立方抽样生成了600组工况,参数的取值范围参考HTR-PM实际运行数据给出,如表3所示。将数据集的20%作为测试集,完全不参与神经网络模

型的训练过程；剩余 70% 分为训练集和验证集（例如 70% 训练集，10% 验证集）。

表 3 数据生成参数范围  
Table 3 Data generation parameter range

| 参数名称 Parameters                                 | 数值 Value |
|-------------------------------------------------|----------|
| 反应堆总功率 Reactor total thermal power / MW         | 0~250    |
| 一回路压力 Primary helium pressure / MPa             | 3~9      |
| 氦气入口温度 Inlet helium temperature / °C            | 25~300   |
| 氦气流量 Helium mass flow rate / kg·s <sup>-1</sup> | 5~120    |

## 2 模型方法

### 2.1 残差全连接网络模型设计

本研究采用了一种改进的残差全连接网络 (ResNet-MLP)<sup>[19-20]</sup>，网络结构如图 4 所示。该模型借鉴了计算机视觉中 ResNet 的核心思想，通过引入跨层恒等映射来打通深层网络的梯度传播路径。网络整体由输入投影层、深度残差块级联和输出映射层三部分组成。架构整体分为三个核心阶段：输入特征编码阶段、深度残差特征提取阶段，以及全局温度场解码与重构阶段。模型的输入为有限的离散测量点数据：具体为反映宏观热力学状态的 5 个工况参数（压力、功率、流量、入口温度、出口温度），以及反映堆内温度的侧反射层轴向温度测点数据，模型输出为对应工况下的堆芯的二维温度场分布。

#### 2.1.1 输入投影层

模型的输入  $X$  包含了侧反射层轴向温度分布和宏观工况参数。输入投影层的作用是将低维的物理特征映射到高维的隐层语义空间中，以提取更丰富的特征表示。

该过程可表示为：

$$H_0 = \sigma(\text{LayerNorm}(W_{\text{in}}X + b_{\text{in}})) \quad (1)$$

式中： $W_{\text{in}}$  和  $b_{\text{in}}$  分别为投影层的权重矩阵和偏置向量； $\text{LayerNorm}(\cdot)$  为层归一化操作，用于稳定输入数据的分布，加速网络收敛并增强模型对极端工况的鲁棒性； $\sigma(\cdot)$  为非线性激活函数； $H_0$  为输入投影层的输出特征向量。

#### 2.1.2 深度残差块级联

深度残差块 (Residual Blocks) 网络的核心是级联的  $L$  个残差块。针对全连接结构，本研究设计了包含两层线性变换的瓶颈结构，并在每个权重层之后动态引入了层归一化和 Dropout 正则化。对于第  $l$  个残差块，其前向传播过程分为两段变换与一次残差融合。

第一段特征非线性变换：

$$Z_1^{(l)} = W_1^{(l)}H^{(l-1)} + b_1^{(l)} \quad (2)$$

$$A_1^{(l)} = \text{Dropout}(\sigma(\text{LayerNorm}(Z_1^{(l)}))) \quad (3)$$

第二段特征线性对齐：

$$Z_2^{(l)} = W_2^{(l)}A_1^{(l)} + b_2^{(l)} \quad (4)$$

$$A_2^{(l)} = \text{LayerNorm}(Z_2^{(l)}) \quad (5)$$

残差跳跃连接与最终激活：

$$H^{(l)} = \sigma(A_2^{(l)} + H^{(l-1)}) \quad (6)$$

式中： $H^{(l-1)}$  和  $H^{(l)}$  分别为第  $L$  个残差块的输入和输出特征，维度始终保持不变。跳跃连接 ( $A_2^{(l)} + H^{(l-1)}$ ) 允许梯度在前向与反向传播时绕过非线性层直接传递，有效缓解了深层 MLP 训练中的梯度消失现象。Dropout 操作则在训练过程中随机置零部分神经元，有效防止了模型对特定训练数据的过拟合。

#### 2.1.3 映射层

输出映射层经过多个残差块的深度特征提取后，最后一层特征  $H^{(l)}$  将通过一个线性映射层，直接




图 4 ResNet-MLP 神经网络结构示意图 (彩图见网络版)

Fig.4 Structural diagram of ResNet-MLP neural network (color online)

回归到目标温度场的维度。

$$Y_{\text{pred}} = W_{\text{out}} H^{(l)} + b_{\text{out}} \quad (7)$$

式中:  $W_{\text{out}}$  和  $b_{\text{out}}$  为输出映射层的可学习解码权重矩阵与偏置参数;  $Y_{\text{pred}}$  为最终输出的离散化物理场状态目标向量, 即代表堆芯的径向与轴向二维空间温度场分布。

## 2.2 空间梯度感知损失函数

堆芯温度场预测的核心目标是准确捕获反应堆内温度工况的空间分布。在训练数据驱动的回归模型时, 往往仅关注温度数值误差, 容易出现预测结果过度平滑的问题, 而对局部结构趋势和变化不敏感。在高温气冷堆堆芯中, 温度分布存在显著的局部变化, 例如堆芯轴向的剧烈温度梯度和局部的功率峰值区。为此, 本文在损失函数中增加预测温度场与真实温度场在空间方向梯度上的差异约束, 使模型在最小化温度误差的同时保持温度场的空间变化趋势。

具体来讲, 该方法利用基于有限差分的惩罚项来量化局部空间梯度。通过分别计算轴向( $y$ )和径向( $x$ )相邻网格点温度的绝对差值, 获得温度场梯度图的离散表示。该损失项通过强制模型的预测梯度场与真实物理梯度场相匹配, 将相邻节点的热力学连续性作为先验约束注入到网络中。

所提出的空间梯度损失  $L_{\text{grad}}$  定义为两个空间维度上梯度误差的绝对值之和:

$$L_{\text{grad}} = |\nabla_y \hat{T} - \nabla_y T| + |\nabla_x \hat{T} - \nabla_x T| \quad (8)$$

轴向梯度分量计算为:

$$\nabla_y \hat{T} = |\hat{T}_{i+1,j} - \hat{T}_{i,j}| \quad (9)$$

径向梯度计算为:

$$\nabla_x \hat{T} = |\hat{T}_{i,j+1} - \hat{T}_{i,j}| \quad (10)$$

式中:  $\hat{T}$  为预测温度场;  $T$  为真实温度;  $i$  为轴向坐标;  $j$  为径向坐标。

## 3 实验设置与评价指标

### 3.1 实验设置

在数据驱动的物理参数预测研究中, 多层感知机(MLP)<sup>[20]</sup>与支持向量回归(SVR)<sup>[21]</sup>作为两种经典的机器学习基准模型被广泛应用。本文应用这两种模型进行性能对比, 本节给出三种模型的参数设置。

本研究中利用神经网络模型进行训练从而预测高温气冷堆堆芯温度场的流程图如图5所示。模型开发与预测在 CPU intel i7-12700 上运行, 采用 python 3.11 进行编程, 基于 pytorch 2.7 深度学习框架进行神经网络训练和验证。




图5 堆芯温度场预测模型训练流程图  
Fig.5 Flowchart of model training for prediction of core temperature field

模型的输入特征包含具有不同物理量纲和数值数量级的宏观物理量。若直接将这些异构物理数据送入神经网络, 数值绝对范围较大的特征将在反向传播时主导梯度的更新方向, 会导致模型收敛极其缓慢, 致使模型陷入局部最优。为了消除物理量纲的差异并加速网络收敛, 本研究采用了标准归一化方法对输入特征与输出目标进行预处理。其数学变换公式如下所示:

$$x'_i = \frac{x_i - \mu}{\sigma} \quad (11)$$

式中:  $x_i$  为某一维度的原始物理观测值;  $x'_i$  为标准化后的无量纲特征;  $\mu$  和  $\sigma$  分别表示该物理特征在整个训练集数据分布上的样本均值与标准差。

在模型训练之前, 需要对模型进行合理的超参数设置, 以提升模型性能。本研究在模型构建与训练过程中对各模型的关键超参数进行了系统化设置与优化, 三种模型的具体超参数配置如表4所示。其中, MLP 与 ResNet 同属于人工神经网络模型, 因此在激活函数、归一化策略以及随机失活率等方面采用相同的设置。

在训练策略上, 模型采用 AdamW 优化器进行参数更新, 初始学习率设定为  $1.0 \times 10^{-3}$ , 并结合余弦退火学习率衰减策略加速模型收敛, 设置总训练轮数为 3 600 轮, 批次为 64, 具体设置如表5所示。模型的训练迭代是通过最小化预测结果与实际温度之

表4 模型超参数设置  
Table 4 Model hyperparameter settings

| 模型类别<br>Model | 超参数名称<br>Hyperparameter           | 设定值<br>Value         |
|---------------|-----------------------------------|----------------------|
| ResNet        | 隐藏层维度 Hidden size                 | 128                  |
|               | 残差块数量<br>Num of ResBlocks         | 3                    |
|               | 激活函数 Activation function          | GELU                 |
|               | 归一化策略 Normalization               | Layer Normalization  |
|               | 随机失活率 Dropout rate                | 0.2                  |
|               |                                   |                      |
| MLP           | 隐藏层维度 Hidden size                 | 128                  |
|               | 隐藏层数量 Number of layers            | 2                    |
| SVR           | 核函数 Kernel function               | RBF                  |
|               | 正则化参数<br>Regularization parameter | 50.0                 |
|               | 不敏感损失 Insensitive loss            | 0.03                 |
|               | 核函数系数<br>Kernel coefficient       | Scale                |
|               | 收敛容差<br>Optimization tolerance    | $1.0 \times 10^{-3}$ |
|               |                                   |                      |
|               |                                   |                      |

间的误差来执行的,损失函数采用均方误差(Mean Squared Error, MSE)与空间梯度损失的联合损失,其计算公式被定义为:

$$\text{Loss} = \text{MSE} + L_{\text{grad}} \quad (12)$$

均方误差MSE计算公式为:

$$\text{MSE} = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (y_{ij} - \hat{y}_{ij})^2 \quad (13)$$

式中: $M$ 为样本数量; $N$ 为每个样本包含的空间网格节点数; $y_{ij}$ 为第*i*个样本在第*j*个空间节点上的真实温度值; $\hat{y}_{ij}$ 为对应的网络预测温度。

表5 训练参数设置  
Table 5 Training hyperparameter settings

| 参数名称 Hyperparameter      | 设定值 Value              |
|--------------------------|------------------------|
| 损失函数 Loss function       | MSE+梯度损失 Gradient loss |
| 优化器 Optimizer            | AdamW                  |
| 基础学习率 Base learning rate | $1.00 \times 10^{-3}$  |
| 权重衰减 Weight decay        | $1.00 \times 10^{-4}$  |
| 批次大小 Batch size          | 64                     |
| 最大训练轮数 Max epochs        | 3 600                  |

### 3.2 评价指标

为了定量评估模型由稀疏测量数据重构堆芯温度场的预测精度,本文选取平均绝对误差(Mean Absolute Error, MAE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)以及决定系数( $R^2$ )作为评价指标。MAE用于衡量预测值与真实值之间的绝对偏差,具有明确的物理意义;MAPE从相对误差角度刻画预测精度,能够消除不同温度区

间尺度差异的影响; $R^2$ 反映模型对温度场整体数据的拟合能力。各项指标的定义与物理意义如下:

#### 1) MAE

MAE衡量了预测温度与真实温度之间绝对误差的平均水平,其数学表达式为:

$$\text{MAE} = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N |y_{ij} - \hat{y}_{ij}| \quad (14)$$

#### 2) MAPE

MAPE表征了预测误差相对于真实值的偏离百分比:

$$\text{MAPE} = \frac{100\%}{M \times N} \sum_{i=1}^M \sum_{j=1}^N \left| \frac{y_{ij} - \hat{y}_{ij}}{y_{ij}} \right| \quad (15)$$

#### 3) $R^2$

$R^2$ 反映了模型预测值对真实温度场数据方差的解释程度。 $R^2$ 取值越接近1,说明模型预测值与真实分布的线性相关性越强。

$$R^2 = 1 - \frac{\sum_{i=1}^M \sum_{j=1}^N (y_{ij} - \hat{y}_{ij})^2}{\sum_{i=1}^M \sum_{j=1}^N (y_{ij} - \bar{y})^2} \quad (16)$$

## 4 结果和讨论

### 4.1 模型训练与验证

ResNet-MLP模型训练过程中的损失如图6所示,图6(a)表示MSE损失,图6(b)表示总损失。可以看到,训练和验证损失在训练开始阶段急剧下降,随后平缓下降,虽出现轻微波动,总损失最后依然趋于平稳,表明模型在训练过程中具有良好的收敛性和稳定性。

图7展示了不同评估指标在训练过程中的变化曲线。随着训练轮数的增加,MAE与MAPE均显著下降并逐渐趋于平稳,最终稳定在较低水平;同时, $R^2$ 随着训练过程的推进逐渐增大并趋近于1。这表明模型在训练过程中不断学习输入参数与目标物理量之间的映射关系,预测误差逐步减小,拟合能力持续提升,模型最终达到了较好的预测性能与稳定性。

### 4.2 模型预测结果与性能对比

为了客观评估本研究采用的ResNet-MLP模型的性能,本文在相同的数据集与验证准则下,将其与常规的MLP和SVR模型进行了横向对比。

表6汇总了测试集样本在不同模型下的MAE、MAPE、MSE以及 $R^2$ 。从宏观统计结果来看,对于全场合所有网格温度点,本文提出的ResNet-MLP模型展现出最优的预测精度:其总体MAE与MAPE分别低至0.51 °C与0.162%。常规MLP模型次之,其




图6 ResNet-MLP模型的训练与验证损失图(彩图见网络版)  
Fig.6 Training and validation loss of ResNet-MLP model (color online)




图7 不同评估指标在训练过程中的变化曲线(彩图见网络版)  
Fig.7 Variation curves of different evaluation metrics during the training process (color online)

MAE与MAPE分别为 $1.45^{\circ}\text{C}$ 与 $0.38\%$ 。相比之下,SVR的各项误差指标均大幅高于这两种基于人工神经网络的方法。此外,ResNet-MLP的 $R^2$ 达到 $0.999\ 95$ ,表明模型预测的温度场与真实温度场之间具有极高的一致性,能够准确反映堆芯稳态温度场的整体分布特征。

表6 不同模型评估指标  
Table 6 Evaluation metrics of different models

| 模型名称<br>Model name | MAE  | MAPE  | MSE   | $R^2$    |
|--------------------|------|-------|-------|----------|
| ResNet-MLP         | 0.51 | 0.162 | 0.61  | 0.999 95 |
| MLP                | 1.45 | 0.38  | 4.67  | 0.999 50 |
| SVR                | 3.33 | 0.90  | 22.12 | 0.997 55 |

图8进一步展示了三种模型预测误差(MAE、MAPE、MSE)在堆芯二维空间区域内的分布图。对比可知,ResNet-MLP在全域各个区域内的误差均显著小于另外两种基准模型。深入观察误差的空间分布特征可以发现,三种模型在堆芯底部中心区域的MAE均呈现出相对放大的趋势。该区域作为堆芯的高温核心区,内部存在局部复杂且剧烈的温度梯度。这种剧烈的非线性物理变化放大了所有数据驱动模型在特征外推时的不确定性,进而导致局部重构误差的增加。然而,即便在该极端区域,ResNet-

MLP依然保持了最高的预测精度。

为了更好地衡量模型在极端工况下的预测稳定性,本文针对单个测试样本引入了最大绝对误差(Max\_MAE)与最大绝对百分比误差(Max\_MAPE)两个评价指标。由图9的样本误差散点分布可以看出,ResNet-MLP模型的Max\_MAE和Max\_MAPE不仅整体远低于MLP与SVR模型,且在不同工况样本间保持着较小的波动范围。其中,ResNet-MLP预测的Max\_MAE绝大多数控制在 $3^{\circ}\text{C}$ 以下,极端最大误差仅为 $4.74^{\circ}\text{C}$ ;同时,所有样本的Max\_MAPE均在 $2\%$ 以下(最大值为 $1.9\%$ ),而MLP与SVR模型的误差分布呈现出极大的离散性与波动性,尤其是SVR模型在部分复杂工况样本上出现了较大预测偏差。这体现了ResNet\_MLP在高温气冷堆温度场预测任务中具备稳定性和良好的精度。

总体而言,SVR在高温气冷堆堆芯稳态温度场预测中表现出较差的适应性。这主要是因为SVR属于浅层机器学习方法,在面对高维工况输入与高维连续输出(全场温度网格)之间复杂的非线性映射关系时,其特征表达能力有限,难以充分捕捉温度场的空间耦合特性。相比之下,同为神经网络模型的传统MLP表现有所提升,但仍存在一定局限。由于网络深度受梯度消失问题限制,MLP在处理具有强




图8 三种模型预测误差在堆芯二维区域的分布图(彩图见网络版)  
Fig.8 Distribution map of three model prediction errors in the 2D core region (color online)




图9 样本最大绝对误差和百分比绝对误差散点图(彩图见网络版)  
Fig.9 Scatter plot of sample maximum absolute error and percentage absolute error (color online)

空间依赖性和局部温差显著的物理场时,其表达能力仍然不足,难以准确描述复杂的温度分布特征。ResNet-MLP通过引入跨层残差连接,有效缓解了深层网络训练中的梯度消失问题,使模型能够构建更深的网络结构,从而提升特征提取能力。因此在预测精度和稳定性方面均表现出明显优势。

在保证高精度预测的同时,模型的计算效率同样是工程应用中的关键指标。为此,统计了三种模型对测试集单样本进行预测所需的计算时间,结果表明,ResNet-MLP、MLP、SVR三种模型在CPU上完成单个样本平均预测时间分别为7.5 ms、7.25 ms和10 ms。这意味着在实际工程应用中,只需输入可测量的工况参数,训练完成的模型即可在极短时间内重构出堆芯温度场分布,为堆芯热工安全分析与实时监测提供高效可靠的技术手段。

### 4.3 空间梯度损失对比分析

为了验证空间梯度感知损失函数在复杂温度场预测中的有效性,本文在同等ResNet-MLP网络架构下,开展了纯MSE损失与“MSE+梯度损失”的对比实验。结果表明,仅依赖纯MSE损失进行训练时,模型在测试集上计算的MAE、MAPE和MSE分别为1.1 °C、0.3%和3.2。图10展示了基于纯MSE损失训练的总误差指标空间分布图。与前文(图8)中引入空间梯度损失的训练结果相比,纯MSE驱动模型在各项空间误差指标上均表现出明显偏大的现象。引入梯度损失进行联合优化后,模型的总体MAE由0.999 °C降低至0.51 °C,实现了约53%的显著精度提升。进一步从空间分布角度分析,在堆芯底部轴心的高温区域,纯MSE模型的平均绝对误差约为2.5 °C,而引入空间梯度损失后,该区域误差




图10 MSE训练模型预测误差在堆芯区域的分布(彩图见网络版)  
Fig.10 Distribution map of prediction error of the MSE training model in the core region (color online)

降低至约 1.1 °C。上述结果表明,空间梯度损失能够有效抑制高温梯度区域的预测误差。

进一步观察图 11 的样本误差散点分布可知,在采用梯度损失后,所有测试样本的最大绝对误差(Max\_MAE)不仅整体数值显著下降,其误差分布的离散程度也大幅降低。为了更直观地量化这一性能优势,图 12 详细统计了每个测试样本在引入梯度损失前后的最大绝对误差差值(无梯度损失误差减去有梯度损失误差)。对比数据表明,绝大多数样本的极端预测偏差得到了有效抑制:在全部测试集中,仅有 4 个样本的最大误差出现了轻微反弹(且增加的 MAE 均未超过 1 °C),而绝大部分样本的最大局部

误差实现了 30% 以上的误差缩减。

上述对比结果充分证明了在模型训练中加入空间梯度损失的必要性 with 优越性。纯 MSE 损失往往倾向于对全局数值误差进行平均化处理,这会导致模型在面对高温气冷堆堆芯的剧烈温差边界和局部热点时产生“过度平滑”现象,进而放大局部极值区域的预测误差。而“MSE+梯度损失”的联合约束,实质上将相邻节点温度连续性特征作为惩罚项注入优化目标中,这种机制迫使网络在拟合全局绝对温度的同时,敏锐地捕捉空间温度梯度的剧烈变化,从而有效消除了局部畸变误差,大幅提升了模型对堆芯局部高温区域的预测稳定性。




图 11 样本预测最大绝对误差与最大平均绝对百分比误差的散点图(彩图见网络版)

Fig.11 Scatter plot of the maximum sample prediction MAE and MAPE errors (color online)




图 12 引入和不引入梯度损失的最大绝对误差差值(彩图见网络版)

Fig.12 Difference in maximum absolute error between models with and without gradient loss (color online)

## 5 结语

本文针对 HTGR 堆芯内部温度场难以直接测量、传统物理数值计算耗时过长的问题,采用了一种结合空间梯度损失的深度 ResNet-MLP 预测模型。该模型仅利用有限的宏观工况与侧反射层离散测点数据,实现了对 HTR-PM 堆芯二维稳态温度场的高保真重构。研究结果表明,通过引入跨层恒等映射,

ResNet-MLP 有效克服了传统 MLP 与浅层 SVR 在处理强空间依赖性物理场时的特征表征瓶颈;同时,引入的空间梯度感知损失函数有效抑制了局部高温区域预测的误差,使得模型的总体 MAE 降低至 0.51 °C,相较于纯 MSE 训练大幅降低了约 53%。在保证极高预测精度的前提下,该模型对单样本的平均预测耗时仅约为 7.5 ms,不仅在极端工况下展现出较好的预测锐度与工程鲁棒性,还为反应堆的在线状态监测与数字孪生系统的构建提供了一种高效、可靠的数据驱动技术方案。

**作者贡献声明** 刘伟负责总体文章方案设计和模型计算;孟金星、伍钊负责数据结果处理;单建强提供理论、行政及技术支持并指导。

## 参考文献

- 1 吴宗鑫, 张作义. 先进核能系统和高温气冷堆[M]. 北京: 清华大学出版社, 2004.  
WU Zongxin, ZHANG Zuoyi. Advanced nuclear energy system and high temperature gas cooled reactor[M]. Beijing: Tsinghua University Press, 2004.
- 2 Zhang Z Y, Dong Y J, Shi Q, et al. 600-MWe high temperature gas-cooled reactor nuclear power plant

- HTRPM600[J]. Nuclear Science and Techniques, 2022, **33**: 101. DOI: 10.1007/s41365-022-01089-9.
- 3 吴宇轩, 王永平, 秦帅, 等. 球床式高温气冷堆物理热工计算程序 NECP-Panda 中子学计算模块研制[J]. 核技术, 2025, **48**(3): 030606. DOI: 10.11889/j.0253-3219.2025.hjs.48.230471. CSTR: 32193.14.hjs.CN31-1342/TL.2025.48.230471.  
WU Yuxuan, WANG Yongping, QIN Shuai, *et al.* Development of the neutronics calculation module of neutronics and thermal hydraulic calculation program NECP-Panda for pebble-bed high temperature gas-cooled reactor[J]. Nuclear Techniques, 2025, **48**(3): 030606. DOI: 10.11889/j.0253-3219.2025.hjs.48.230471. CSTR: 32193.14.hjs.CN31-1342/TL.2025.48.230471.
- 4 张作义, 吴宗鑫, 王大中, 等. 我国高温气冷堆发展战略研究[J]. 中国工程科学, 2019, **21**(1): 12 - 19.  
ZHANG Zuoyi, WU Zongxin, WANG Dazhong, *et al.* Development strategy of high temperature gas cooled reactor in China[J]. Strategic Study of CAE, 2019, **21**(1): 12 - 19.
- 5 刘嵩阳, 王朗, 李雪琳, 等. 基于 OTTO 模式下 HTR-PM 的 950 °C 冷却剂出口温度初步研究[J]. 核动力工程, 2025, **46**(S1): 41 - 51. DOI: 10.13832/j.jnpe.2025.S1.0041.  
LIU Songyang, WANG Lang, LI Xuelin, *et al.* Preliminary study on 950 °C coolant outlet temperature in HTR-PM under the OTTO scheme[J]. Nuclear Power Engineering, 2025, **46**(S1): 41 - 51. DOI: 10.13832/j.jnpe.2025.S1.0041.
- 6 Qiao H, Ma J, Wang B, *et al.* Application of Data-Driven technology in nuclear Engineering: Prediction, classification and design optimization[J]. Annals of Nuclear Energy, 2023, **194**: 110089. DOI: 10.1016/j.anucene.2023.110089.
- 7 Idaho National Laboratory. Generating an advanced cross-section library for HTGR pebble bed depletion calculations using reduced-order model generation techniques[R]. INL/RPT-24-80344, 2024.
- 8 刘若晴, 马涛, 张立国. 基于神经网络的球床堆在线核材料衡算方法[J]. 原子能科学技术, 2020, **54**(10): 1885 - 1891. DOI: 10.7538/yzk.2019.youxian.0639.  
LIU Ruqing, MA Tao, ZHANG Ligu. Online nuclear material accounting research based on neural network for pebble bed reactor[J]. Atomic Energy Science and Technology, 2020, **54**(10): 1885 - 1891. DOI: 10.7538/yzk.2019.youxian.0639.
- 9 Wu M Q, Liu X, Gui N, *et al.* Prediction of the remaining time and time interval of pebbles in pebble bed HTGRs aided by CNN via DEM datasets[J]. Nuclear Engineering and Technology, 2023, **55**(1): 339 - 352. DOI: 10.1016/j.net.2022.09.019.
- 10 Chen E, Zhang H, Yuan Y. POD-based reduced-order modeling study for thermal analysis of gas-cooled microreactor core[J]. Frontiers in Energy Research, 2023, **11**: 1155294. DOI: 10.3389/fenrg.2023.1155294.
- 11 Zhang Z, Sheng Z, Xia B, *et al.* Data-driven prediction of HTR-PM bottom reflector maximum temperature using recurrent neural networks[J]. Progress in Nuclear Energy, 2026, **193**(c): 106200. DOI: 10.1016/j.pnucene.2025.106200.
- 12 Coppo Leite V, Merzari E, Novak A, *et al.* Application of a physics-informed convolutional neural network for monitoring the temperature fields in high-temperature gas reactors[J]. Nuclear Science and Engineering, 2025, **199**(10): 1712 - 1732. DOI: 10.1080/00295639.2024.2443337.
- 13 Sun J, Zheng Y H, Li F. Various bypass flow paths and bypass flow ratios in HTR-PM[J]. Energy Procedia, 2013, **39**: 258 - 266. DOI: 10.1016/j.egypro.2013.07.212.
- 14 Chen F B, Han Z H. Steady-state thermal fluids analysis for the HTR-PM equilibrium core[J]. International Journal of Advanced Nuclear Reactor Design and Technology, 2021, **3**: 11 - 17. DOI: 10.1016/j.jand.2021.04.001.
- 15 孙世妍, 张佑杰, 郑艳华, 等. 高温气冷堆热工分析模型改进与堆芯温度场分析[J]. 原子能科学技术, 2021, **55**(8): 1376 - 1385. DOI: 10.7538/yzk.2020.youxian.0354.  
SUN Shiyan, ZHANG Youjie, ZHENG Yanhua, *et al.* Improvement of thermal hydraulic model and analysis of core temperature distribution of high temperature gas-cooled reactor[J]. Atomic Energy Science and Technology, 2021, **55**(8): 1376 - 1385. DOI: 10.7538/yzk.2020.youxian.0354.
- 16 华能核能技术研究院有限公司. 华麒(HUAQI)-球床式高温气冷堆事故分析软件[CP]. 登记号: 2024SR197879 3, 2024-12-04.  
Huaneng Nuclear Energy Technology Research Institute Co., Ltd. HUAQI - pebble bed high-temperature gas-cooled reactor accident analysis software[CP]. Registration No.: 2024SR1978793, 2024-12-04.
- 17 Zheng Y H, Wang Y, Shi L. Water ingress accident of 250 MW pebble-bed modular high-temperature gas-

- cooled reactor[J]. Atomic Energy Science and Technology, 2009, **43**(Suppl.2): 232 - 235. DOI: 10.7538/yzk.2009.43.suppl2.0232.
- 18 Liu W, Shi J, Yu S Z, *et al.* Three-dimensional numerical investigation on the heat transfer and bypass flow characteristics in a pebble-bed high temperature gas-cooled reactor[J]. International Journal of Heat and Fluid Flow, 2026, **117**: 110161. DOI: 10.1016/j.ijheatfluidflow.2025.110161.
- 19 He K M, Zhang X Y, Ren S Q, *et al.* Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016. Las Vegas, NV, USA. IEEE, 2016: 770 - 778. DOI: 10.1109/cvpr.2016.90.
- 20 Gardner M W, Dorling S R. Artificial neural networks (the multilayer perceptron): a review of applications in the atmospheric sciences[J]. Atmospheric Environment, 1998, **32**(14 - 15): 2627 - 2636. DOI: 10.1016/S1352-2310(97)00447-0.
- 21 Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, **20**(3): 273 - 297. DOI: 10.1007/BF00994018.