

机器学习在沸腾传热过程中的应用进展

褚雯霄¹, 唐巍峰¹, 毕晓龙¹, 周晨捷¹, Anton Sergeevich SURTAEV²,
王秋旺¹, Alexander Nikolaevich PAVLENKO²

(1. 西安交通大学热流科学与工程教育部重点实验室, 710049, 西安;

2. 俄罗斯科学院库塔拉泽热物理研究所, 630090, 俄罗斯新西伯利亚)

摘要: 沸腾传热广泛存在于锅炉水冷壁、核反应堆蒸发器等能源动力装备, 是系统高效运行的关键, 对其进行准确预测可有效避免装备局部过热、蒸干、超温等问题。传统预测模型存在难以突破复杂多物理场耦合的瓶颈, 而机器学习方法可通过数据驱动建模和智能分析, 为解决该问题提供新思路。首先, 综述了人工智能技术在沸腾传热预测中的应用, 总结了近年来采用机器学习算法在传热系数预测、气泡动力学参数提取等方面的工作, 结果表明虽然人工智能在沸腾传热中展现出显著优势, 但仍面临数据依赖性高、模型“黑盒”特性强和计算资源需求大等挑战。然后, 阐述了机器学习在沸腾传热中的未来研究方向, 包括但不限于快速及低成本的多相流仿真、跨场景的泛化模型开发和传热系统的实时动态控制。最后, 指出融合物理定律与数据驱动、构建数据集及开源算法将成为推动人工智能在沸腾过程深度应用的关键, 从而进一步助力高效能源动力系统开发。该研究可为机器学习方法在沸腾传热过程中的智能预测、优化设计与安全控制提供参考。

关键词: 沸腾传热; 机器学习; 传热系数预测

中图分类号: TK124 **文献标志码:** A

DOI: 10.7652/xjtuxb202606010 **文章编号:** 0253-987X(2026)06-0118-14

Advances in the Application of Machine Learning to Boiling Heat Transfer

CHU Wenxiao¹, TANG Weifeng¹, BI Xiaolong¹, ZHOU Chenjie¹,
Anton Sergeevich SURTAEV², WANG Qiuwang¹,
Alexander Nikolaevich PAVLENKO²

(1. MOE Key Laboratory of Thermo-Fluid Science and Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. Kutateladze Institute of Thermophysics, Siberian Branch of the Russian Academy of Sciences, Novosibirsk 630090, Russia)

Abstract: Boiling heat transfer, widely applied to energy and power equipment, such as boiler water-cooled walls and nuclear reactor evaporators, is critical to their efficient operation. Accurate prediction of boiling heat transfer is therefore essential to prevent such equipment from local overheating, dry-out, over-temperature, and other abnormalities effectively. While traditional prediction models have been constrained by the challenge of coupling complex multi-physical fields, machine learning offers new ideas for addressing this challenge through data-driven modeling and intelligent analysis. First of all, the application of artificial intelligence (AI) techniques to boiling heat transfer prediction is reviewed, with recent years of work using machine learning algorithms for heat

收稿日期: 2025-10-04。 作者简介: 褚雯霄(1987—), 男, 教授, 博士生导师。 基金项目: 国家自然科学基金国际(地区)合作资助项目(W2412082)。

网络出版时间: 2026-01-02

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20251231.1139.004>

transfer coefficient prediction and bubble dynamics parameter extraction summarized. The results indicate that, although notable advantages of AI in boiling heat transfer have been demonstrated, challenges remain, including strong dependence on data, obvious “black box” nature of models, and substantial computational resource requirements. Furthermore, future research directions for machine learning in boiling heat transfer are identified, including but not limited to rapid and low-cost multiphase flow simulation, development of generalized models across different scenarios, and real-time dynamic control of heat transfer systems. Finally, it is promisingly expected that the integration of physical laws with data-driven modeling, together with the building of datasets and the provision of open-source algorithms, will be pivotal in deepening the application of AI to boiling processes, further empowering the development of efficient energy and power systems. This study can provide a reference for the application of machine learning methods to intelligent prediction, optimal design, and safety control of boiling heat transfer processes.

Keywords: boiling heat transfer; machine learning; heat transfer coefficient prediction

在以核反应堆蒸发器为代表的能源与动力装备中,沸腾过程构成了能量转换与传递的关键环节,对于系统安全和效率提升至关重要。然而,由于传统池沸腾理论、数值仿真和实验结果存在较大差异,当前系统多采用保守控制策略,避免因对沸腾过程认知不足而导致的系统安全隐患及运行风险。沸腾传热的危害主要体现在以下两个方面:①局部蒸干可能引发传热面过热,甚至导致锅炉爆炸等灾难性事故;②不稳定的过热度易造成材料承受周期性热应力,引发热疲劳损伤,显著缩短设备服役寿命。目前,对于沸腾传热的研究集中于传热系数、气泡动力学和流态识别等方面。然而,沸腾传热过程涉及液体相变、气液两相流动、复杂的热边界层等多种物理现象。经典沸腾曲线和传热关联式虽为工程设计提供了一定指导,但大多基于理想化假设,难以准确预测微纳尺度表面、非稳态工况或复杂工质下的传热性能。虽然众多研究学者已对上述经典公式进行了修正并提出新公式^[1-4],但至今仍缺乏一个能够准确描述该过程的理论公式。这一现状不仅给理论研究带来了挑战,也使得工程应用中对沸腾传热性能的预测和控制面临不确定性,限制了其在实际散热系统中的广泛应用。

近年来,人工智能技术的迅猛发展为解决传统预测方法适用范围小、预测准确性低等难题提供了新的思路。人工智能在流态识别、数据预测等领域展现出显著的优势,能够通过大量数据训练复杂系统的映射模型,实现对复杂物理过程的有效描述和预测。本文统计了2001—2025年Web of Science数据库中以“人工智能”“机器学习”“深度学习”“沸腾传热”作为关键词的文献数量,结果如图1所示。




图1 Web of Science 数据库中以“人工智能”“机器学习”“深度学习”“沸腾传热”作为关键词检索得到的文献数量(2001—2025年)

Fig.1 Number of documents with “artificial intelligence”, “machine learning”, “deep learning” and “boiling heat transfer” as keywords retrieved from Web of Science database (2001—2025)

早在1996年,Jambunathan等^[5]就已使用人工神经网络预测对流换热系数。在这一趋势下,机器学习和深度学习技术逐渐被引入沸腾传热领域。Liu等^[6]首次将人工神经网络用于沸腾传热,发现算法对不同添加剂分子的沸腾传热中沸腾热通量的预测准确度高达90%,并通过构建基于数据驱动模型,弥补了传统物理模型在预测精度上的不足。由此可见,机器学习能够通过挖掘大量实验数据中的内在规律,建立预测模型。进一步地,深度学习则利用多层神经网络的强大学习能力,自动提取高维数据中的深层特征,从而实现对沸腾传热过程中各项参数变化的精准预测。

此外,对于气泡动力学研究和流态识别,人工智能算法也有其应用。Guo等^[7]利用神经网络识别壁管内沸腾的两相,其准确度高达90%以上。Zhou等^[8]不仅实现了气泡的识别,还进一步使用人工智能预测了气泡的运动,简化了空隙率、气泡寿命和成核位点密度等参数的提取。可见,视觉识别技术在提高气泡识别的精确度同时,也快速实现了以往需要人工计算多帧气泡直径的任务,极大地减少了科研人员的识别时间。因此,近5年来,将人工智能应用于沸腾传热的文章数量急剧增加。

然而,在预测和识别过程中,人工智能算法需要大量的数据集训练模型以确保其准确性;同时,参数的选择对于算法准确性而言至关重要,可避免过拟合和欠拟合情况。为此,本文综述了机器学习在沸腾传热研究中的应用情况。首先,简要介绍了机器学习的基本原理,涵盖其主要算法分类、代表性方法和深度学习的核心概念。其次,重点回顾了近年来机器学习在沸腾传热领域的具体应用,主要包括复杂现象识别(如流态识别、气泡动力学分析等)和关键参数预测(如传热系数、临界热通量等)两个核心方面,尤其关注了其在自动化数据提取及高效建模预测方面的进展,对代表性研究成果进行了梳理与评述。最后,深入探讨了当前机器学习应用于沸腾传热所面临的主要挑战,展望了其未来发展前景。

1 机器学习策略分类

机器学习是人工智能的重要分支,其核心在于利用数据和统计学方法,使计算机系统无需明确编程指令的情况下,自动学习并从中提取规律,实现预测、分类、决策等多种任务^[9]。机器学习的基本思想是利用历史数据构建数学模型,基于数据训练不断优化模型参数,从而在面对新数据时能够做出较为准确的判断和预测。

1.1 机器学习的基本分类

机器学习算法大致可分为监督学习(SL)、无监督学习(UL)和强化学习(RL)^[10-11]。在沸腾传热背景下,SL是最常用的方法,其基本步骤包括人工标记数据集、模型训练和输出结果,可广泛应用于分类问题和回归问题。由于沸腾传热过程中的传热系数预测问题在本质上属于回归问题,因此监督学习作为最常用的方法,可在带标签的数据集上训练模型,以获取结果。常用的沸腾传热机器学习算法包括支持向量回归(SVR)^[12]、随机森林(RF)^[13-15]和人工神经网络(ANN)^[16-18]等。SVR算法通过引入核函

数,将低维非线性沸腾数据映射至高维空间以寻找最优超平面,在处理小样本沸腾实验数据的回归和分类问题中表现出极强的鲁棒性,有效避免了过拟合风险。RF算法通过构建多个决策树,显著降低了沸腾传热关联式拟合中的方差与偏差,特别是在处理多变量耦合的临界热通量预测中,表现优于单一的回归模型。

回归问题的开展依赖于数据集,特别是监督学习,主要依靠实验或模拟数据来学习模式和关系。因此,数据集的准确性和涵盖范围至关重要,数据集数量过少或人工标记有误,都会对结果产生不可预期的影响。

1.2 深度学习的基本分类

深度学习是机器学习的一个子集,侧重于具有多层(通常超过两层)的神经网络。这些网络旨在自动学习数据的分层表示,例如图像、时间序列信号或结构化数据集。深度学习的核心在于多层次的神经网络结构(通常被称为输入层、隐藏层和输出层)^[19]。早期的神经网络主要包括单层或少量隐藏层的感知机,但由于计算能力和数据规模的限制,这类网络难以捕捉到数据中深层次的抽象信息。随着硬件性能(尤其是图形处理器)的提升和大数据时代的到来,多层隐藏层的神经网络得到了广泛应用,这也被称为深度学习^[20-21]。

深度学习是实现机器学习算法的强有力支撑,其与另外几种机器学习算法的关系如图2所示。由图可见,无论是监督学习还是无监督学习,抑或是强化学习,深度学习都可与之相结合。常见的深度网络结构包括卷积神经网络(CNN)、循环神经网络(RNN)、长短期记忆(LSTM)网络以及近年来兴起




图2 机器学习几种概念之间的关系

Fig. 2 Relationship between several concepts in machine learning

的 Transformer 结构。CNN 利用卷积核,适合处理沸腾气泡图像中的空间拓扑结构;改进型的架构如 U-Net 和 Mask R-CNN 通过引入跳跃连接,进一步实现了像素级的气泡语义分割与实例追踪。RNN、LSTM 网络通过引入门控机制,有效解决了长序列训练中的梯度消失问题,被广泛用于沸腾温度场的时间序列预测和瞬态临界热通量预警。为了突破传统网络的局限,基于自注意力机制的 Transformer 模型开始被引入以并行处理长程依赖关系;而融合物理定律的物理信息神经网络(PINN)则尝试将质量、能量守恒方程嵌入损失函数,旨在解决纯数据驱动模型的“黑盒”解释性不足问题,并成为当前该领域的重要发展方向。

深度学习的引入,有效提高了热流密度、温度等物理参数的预测能力和效率^[22]。此外,深度学习也被广泛用于视觉识别领域,提高了物体检测任务的精度和速度。在沸腾传热中,深度学习的视觉识别算法,也被用于气泡动力学研究中^[23],与红外或高速摄像技术结合,分析沸腾气泡的生长趋势。该方法

在满足识别精度的前提下,显著优于人工识别,且便于实时获取气泡速率等参数。该方法若与回归算法相结合,还能预测气泡位置^[8],为后续实时控制的发展奠定了基础。

2 机器学习在沸腾传热中的应用

沸腾传热是一个涉及多尺度气液交互、界面追踪和热质传递耦合的复杂非线性物理过程。传统的理论模型和经验关联式往往基于理想化假设或特定工况拟合,难以全面表征不同表面结构、工质物性及流动条件下的复杂传热特性。近年来,人工智能技术凭借其强大的特征提取与高维数据映射能力,为解决上述难题提供了新的范式。鉴于池沸腾与流动沸腾在物理机制、影响参数及工程应用背景上存在显著差异,分别从“智能提取”和“建模预测”两个维度出发,系统综述机器学习算法在池沸腾与流动沸腾两种典型场景下的应用进展,并深入分析不同算法在处理特定物理问题时的适用性与局限性。表 1 对典型应用研究文献做了汇总。

表 1 机器学习在沸腾传热中典型应用的研究文献总结

Table 1 Summary of research literature on typical applications of machine learning in boiling heat transfer

参考文献	输入参数	输出参数或功能	模型	训练数据集	关键参数	评价指标
[24]	图像	气泡位置、直径等参数	StarDist-CNN	高速相机获取的 520 张图片	未提及	平均精度
[25]	图像	气泡位置、直径等参数	Mask R-CNN、OC-SORT	公开文件及高速相机获取的 1 659 张图片	未提及	平均精度
[26]	图像 (低分辨率)	流态分类 (核态沸腾/ 膜态沸腾)	CNN	84 096 张照片	CNN: 4 层结构, 200 个神经元; MLPNN: 1 层结构, 500 个神经元	平均精度
[27]	沸腾 图像	热通量、识别 基底材料	CNN	开源图像数据, 54 607 张图像	4 层结构(神经元分别为 512、512、216、1), 学习率为 0.001, 每 20 个时期降低 10%	均方误差、均方根误差、平均绝对误差、决定系数、给定误差范围内绝对误差和相对误差满足要求的测试样本比例
[28]	声谱图	沸腾流态分类、 临界热通量	CNN	8 550 条记录 (每个记录 1 s)	学习率为 3×10^{-4} , 每 20 个时期降低 10%	准确度
[29]	图像	气泡流态、 空隙率	U-Net CNN	高速相机获取的 4 010 张图片	未提及	Dice 系数

续表

参考 文献	输入 参数	输出参数 或功能	模型	训练数据集	关键参数	评价指标
[30]	图像	气泡位置、 直径等参数	YOLOv8-CNN、 MOT	高速相机获取的 200 张图片	图像色调、饱和度、 亮度增强的取值分别 为 0.015、0.7、0.4	平均精度
[31]	图像、 物理特性	热通量	HyPR(混合物 理增强模型): VGG16 + MLP	实 验 获 取 的 25 000张照片	5 层结构,每层 70 个 单元,学习率为 0.001	平均绝对百分比 误差
[32]	6 个 参数	沸腾曲线	DNN、RF	实验测试及公开 文献共计 13 063 个数据点	DNN 采用 5 层结构 (隐藏层神经元为 291), 学习率为 0.003 48	决定系数
[33]	5 个 参数	传热系数	DNN、GA	公开文献的 2 501 个数据点	DNN 采用 6 层结构 (隐藏层神经元为 298), 学习率为 0.001	均方误差
[34]	6 个 无量纲 参数	努塞尔数	DNN、1D-CNN、 RF、NG、BNN	公开文献的 1 241 个数据点	1D-CNN 采用 2 层卷积 层、2 层全连续层结构; BNN 采用 4 层密集层 结构;RF 采用 27 棵 决策树	平均绝对百分比 误差
[35]	9 个 参数	传热系数	PSO-MLPN	公开文献的 5 232 个数据点	MLPN 采用 2 层隐藏层 (神经元为 112 个)	平均绝对误差、 均方根误差、决定 系数
[36]	30 个 参数	传热系数	DNN、GPR	沸 腾 流 水 平 流 数 据 的 数 据 库, 共 5 694 个数据点	未提及	标准差、均方误差
[37]	5 个 参数	传热系数	迁移学习	公 开 文 献 的 约 211 000 个数据点	9 层结构(神经元分别 为 5、3 200、2 200、 1 200、520、360、180、 60、1),学 习 率 为 0.000 01	决定系数
[38]	4 个或 5 个参数	临界热通量	ANN、CNN、 Transformer	公 开 数 据 库 的 24 579 个数据点	针对于 3 种模型得出 最佳的模型参数	根均方百分比误差、 归一化均方根 误差、平均绝对 百分比误差
[39]	5 个 参数	临界热通量	结合经验公式 的 DNN、BNN、 DGP 模型	公 开 文 献 的 25 000 个 实 验 数据	DNN 采用 7 层隐藏层	均方误差、相对 均方根误差、决定 系数

注:OC-SORT 为以观测为中心的排序算法;MOT 为多目标跟踪算法;DNN 为深度神经网络;GA 为遗传算法;NG 为自然梯度法;BNN 为贝叶斯神经网络;PSO-MLPN 为结合粒子群优化的多层感知机网络;GPR 为高斯过程回归法;DGP 为深度高斯过程。


2.1 数据智能提取

气泡动力学参数(如脱离直径、频率、成核密度)和流态演变是理解沸腾微观机制的关键。长期以来,基于传统计算机视觉的相变特征提取方法,主要依赖二值化、边缘检测及形态学滤波等基础图像处理算法,以获取气泡或液滴的尺寸分布等基本物理参数^[40]。Maurus 等^[41]构建了一套自动化算法,通过图像平均、背景相减和伪影去除等预处理步骤,成功提取了气泡数量、尺寸分布、气泡质心至最近相邻气泡的距离以及局部空隙率等信息,进一步量化了热通量对气泡行为的影响。然而,尽管此类传统方法相较于人工测量显著提高了效率,但其本质仍属于基于规则的特征工程,严重依赖复杂的图像预处理与阈值调试过程。在应对气泡重叠严重或光照条件变化的复杂工况时,传统算法往往因鲁棒性不足而失效。近年来,随着人工智能技术的发展,CNN 模型被广泛引入视觉识别领域^[42]。相较于传统方法,CNN 能够自动提取图像的高维特征,大幅降低了对人工参数调试的依赖,表现出更强的泛化能力与识别精度,已成为当前沸腾可视化研究的新热点。


2.1.1 池沸腾

池沸腾作为最基础的相变传热形式,其核心研究难点在于加热表面气泡的成核、生长、脱离行为及其对传热性能的非线性影响。在低热通量下,气泡较为稀疏,传统图像处理方法尚可应对;然而,随着热通量增加,尤其是接近临界热通量时,气泡急剧增多并发生剧烈聚并,导致气泡边界模糊且相互遮挡,使得基于人工特征的传统算法难以对其进行精确分割。

针对这一难题,深度学习首先在复杂气泡形态的精准实例分割上取得了突破。Zhao 等^[24]提出了一种结合 StarDist 实例分割模型与 U-Net 语义分割网络的混合框架,利用多边形预测机制,有效克服了传统算法在处理高重叠度气泡时的过分割问题。如图 3 所示,后处理程序通过关联连续帧中气泡的位置和尺寸变化,成功地从侧视高速摄影图像中提取了成核密度及气泡脱离直径随热通量的演变规律。在此基础上,为了进一步捕捉气泡的瞬态行为,Dunlap 等^[25]构建了 BubbleID 框架,将 Mask R-CNN 实例分割网络与 OC-SORT 多目标追踪算法相结合。该方法不仅能以 94.96% 的准确率识别气泡的附着与脱离状态,还能通过追踪连续帧中的气泡轮廓,量化气泡界面的速度矢量,揭示临界热通量前、后气泡界面速度分布的显著差异。



(a) 气泡及接触线直径随时间的变化



(b) 单气泡生命周期生长侧面实拍照片

图 3 单个气泡生长过程中直径和接触线的演变^[24]

Fig. 3 Evolution of diameter and contact line during single bubble growth^[24]

除了对微观气泡参数进行精细提取,深度学习在宏观流态识别与表面特征分析方面也展现出强大的泛化能力。Hobold 等^[26]的研究表明,利用 CNN 对沸腾流态(如核态沸腾、膜态沸腾)的分类并不一定依赖于昂贵的高速摄影设备,即使采用低帧率、低分辨率的图像,甚至在去除加热表面视觉信息的“间接观测”模式下,CNN 仍能通过捕捉气泡群的统计特征,实现超过 90% 的流态识别准确率。这种对图像纹理特征的深层挖掘能力在 Wu 等^[27]的工作中得到了进一步延伸,他们开发了一种多任务深度学习模型,利用注意力增强模块共享特征提取主干,不仅能获得清晰的沸腾图像,还能同时反向推断加热表面的材料属性和热通量水平,实现了对表面微结构纹理与传热机理之间深层关联的智能解析。

值得注意的是,视觉识别虽为主流,但受限于光

路遮挡和视场限制,单纯的图像分析在极端工况下存在局限性。为此,Sinha等^[28]引入声发射信号作为新的识别模态,利用CNN对沸腾声音的声谱图进行特征学习。研究发现,沸腾声音信号的频率特征与气泡动力学行为高度相关,特别是到达临界热通量时,声信号峰值频率从核态沸腾期的200~250 Hz显著偏移至400~500 Hz。这种基于声学的识别方法不仅能准确分类沸腾流态,还能在视觉信息缺失的情况下实现对沸腾危机的提前预警,为多模态融合识别提供了新的思路。

可见,人工智能在池沸腾识别领域的应用已从单一的几何参数测量向多尺度、多模态的智能感知发展。基于StarDist和Mask R-CNN的视觉分割算法,在处理微观气泡重叠和动态追踪方面具有显著优势,能够提供详尽的动力学参数;而基于CNN的流态分类与声学识别方法,则在宏观状态监控和实时预警方面表现出更强的鲁棒性与更高的计算效率。然而,现有模型多基于特定实验台的侧视观测数据训练,且多模态数据的融合机制尚处于起步阶段,未来如何通过迁移学习提升模型在不同工质、不同观测视角(如底视)和不同物理场下的泛化能力,将是该领域亟待解决的关键问题。

2.1.2 流动沸腾

与池沸腾相比,流动沸腾涉及气液两相在受限通道内的快速运动与强剪切作用,其界面拓扑结构随工况变化极为剧烈(如从泡状流向弹状流、环状流的快速演变)。因此,该领域的研究重点在于对瞬态复杂流型的实时分类,以及对高速运动气泡生命周期的精准追踪。

针对微通道流动沸腾中流态边界模糊、难以量化的问题,Schepperle等^[29]提出了一种基于改进U-Net架构的语义分割方法。传统的计算机视觉算法,如自适应阈值法,在处理光照不均或气液界面复杂的过渡流态时,误分割率往往高达15%以上。而该研究通过深度卷积神经网络提取图像的深层语义特征,不仅能精准分割气液两相、自动计算空隙率,还能实现对泡状流、弹状流和环状流等7种细分流态的端到端分类,准确率达到91%。这种像素级的分割技术为理解微通道内的气液两相分布提供了高精度的量化数据。

对于更微观的过冷流动沸腾过程,气泡历经成核、生长、冷凝及溃灭的快速演变,单纯的静态检测难以捕捉其完整的动态寿命特征。为此,Zhou等^[30]开发了一种结合目标检测与多目标追踪的AI

框架,采用YOLOv8模型进行气泡识别,并集成StrongSORT追踪算法在高速视频流中锁定气泡身份。与传统方法仅关注气泡尺寸统计不同,该“检测+追踪”框架能够重构气泡在过冷液体中的完整时空轨迹,从而自动提取出索特平均直径、气泡寿命及生长/冷凝速率等关键热工水力参数。验证结果显示,该方法在不同热通量和质量流速工况下均能捕捉到约90%的冷凝气泡,且提取的参数规律与经典经验关联式吻合良好。

目前,针对流动沸腾的识别问题可分为流态分类和气泡追踪两个方面,其算法选型高度依赖于具体的分析需求。例如,在侧重流型演变的研究中,基于U-Net的语义分割方法优势明显,能够精准识别出气液两相的复杂边界,从而准确计算空隙率等实时参数。相比之下,若研究人员聚焦于气泡成核、生长与脱离周期的微观动力学分析,则采用YOLO结合追踪算法的架构更合适,因为这种组合能有效处理气泡在时空维度上的连续性问题。然而,跨场景的精度不足依然是制约该技术广泛应用的原因。受限于通道几何结构的差异和壁面反光等原因,基于单一实验台数据训练的模型往往很难直接移植到新环境中。为解决这一问题,可考虑引入迁移学习策略,以削弱模型对特定实验数据集的过度依赖。

2.2 高效建模预测

通过解析气泡动力学行为和流态的演变,智能识别技术能够实现沸腾过程的可视化与参数化,为微观机制的研究积累大量高质量数据。然而,获取微观参数仅仅只是第一步,工程应用的根本目的在于建立这些多维参数与传热系数、临界热通量等性能参数之间的定量联系。传统的经验关联式大多依赖量纲分析或特定工况下的拟合,很难完整捕捉到沸腾过程中的非线性特征和多物理场耦合效应,导致其在跨工况场景下的预测精度较低。相比之下,机器学习回归模型具备优越的非线性拟合和泛化能力,能够将工质物性、表面微结构以及流动参数等参数之间的交互作用纳入统一考量,可作为沸腾传热特性建模的有效手段。

本小节将探讨人工智能在传热系数预测、沸腾曲线重构和临界热通量预警方面的应用现状,并重点分析不同算法在处理性能参数预测与动态时序预测任务时的适用性差异。


2.2.1 池沸腾

池沸腾的传热性能受加热面微纳结构、工质物性以及润湿性等多种因素的共同影响。面对复杂表


面或新型工质,传统的经验关联式因物理假设过于简化,预测结果往往存在较大偏差。

为了突破这一局限,研究人员开始采用人工智能技术来构建高精度回归模型。Hobold 等^[26]采用 CNN 处理低分辨率的沸腾图像预测热通量,不仅简化了数据处理,还能避开复杂的物理建模环节,但在物理一致性和模型可解释性方面存在明显短板。针对这一局限,Suh 等^[31]开发了一种名为 HyPR 的物理增强混合框架,结合 CNN 提取的纹理特征,构建 Mask R-CNN 模型,用以提取气泡尺寸、数量等参数。这种融合了视觉特征和物理参数的建模策略,可成功将热通量的预测误差控制在 6% 以内,并提升了模型在变工况下的可靠性。随后,Sajjad 等^[32]采用物理与经验关联式导向的思路,通过将经典关联式的计算结果植入深度神经网络,实现了对全沸腾曲线的精确重构,克服了单一模型难以同时覆盖多个沸腾区间的问题。


随着研究的深入,学者们开始尝试利用机器学习从高维数据中筛选主导参数,以辅助揭示沸腾传热的内在机理。Ravichandran 等^[43]采用最小冗余最大相关(MRMR)算法,对红外热像数据进行了特征排序,发现成核密度、气泡生长时间和足迹半径是预测沸腾危机的 3 个最关键参数,且缺一不可。Sajjad 等^[32-33]提出了一种融合深度神经网络(DNN)与遗传算法(GA)的方法,基于 2 501 组实验数据,通过梯度提升回归树(GBRT)优化 DNN 超参数,构建了包含 6 个隐藏层的深度模型,并进一步优化了各制冷剂的关键参数。此外,其还尝试采用 DNN 算法,利用贝叶斯代理模型优化超参数(如学习率、激活函数),预测不同表面-液体组合各阶段(如核态沸腾、临界热通量、过渡沸腾等)的池沸腾曲线,用以生成沸腾曲线。针对微结构表面传热预测中普遍存在的数据噪声和模型可信度问题,Mehdi 等^[34]首次引入概率机器学习方法,如贝叶斯神经网络(BNN)和自然梯度提升(NG-Boost)算法,其用于训练和测试的数据点分别占总数据点的 80% 和 20%,得到的研究结果如图 4 所示。由图可见,与传统确定性机器学习模型(如 RF 模型)不同,概率机器学习方法能同时输出预测均值和置信区间,实现了对努塞尔数 Nu 的高精度预测,其平均绝对百分比误差也在较低水平,且还能识别出数据稀疏区域的认知不确定性,为模型的安全应用提供了重要保障。



(a) RF 模型



(b) NG-boost 模型



(c) BNN 模型

图 4 采用不同模型得到的 Nu 预测值与实验值的对比^[34]
Fig. 4 Comparison of predicted and experimental values of Nusselt number using different models^[34]

池沸腾传热的预测研究正经历着从单纯数值拟合向物理融合与可信计算的变化。相较于传统的经验关联式,以物理经验为基础(例如物理关联式)的混合模型,在面对跨工质及复杂几何结构时,表现出了更优越的可靠性。目前的学术关注点已不再局限于提升预测精度,而是致力于通过特征,筛选出主导变量,或借助概率方法量化不确定性,从而解析模型内部的运作机理。这意味着人工智能已从单纯的高精度非线性拟合器,转变为辅助科研人员揭示沸腾物理机制(例如解析临界热通量触发条件)的关键手段。针对目前模型对训练数据高度依赖的问题,未

来的突破口在于如何在小样本条件下引入物理约束,从而构建真正具备跨场景通用能力的预测框架。

2.2.2 流动沸腾

相比于池沸腾,流动沸腾涉及更复杂的几何边界限制与流体动力学耦合,其传热性能受通道结构(如微翅片、微通道)及工质流动状态(如超临界、两相流)的影响显著。针对复杂几何结构内的传热系数(HTC)预测,传统的单一神经网络模型往往难以在小样本下达到最优性能,因此结合智能优化算法与混合回归策略成为当前的研究热点。

韩莎莎等^[35]针对蒸发器内的流动沸腾过程,开发了一种结合粒子群优化(PSO)的多层感知机网络(PSO-MLPN),通过智能算法自动寻优隐藏层结构与超参数,实现了对 R134a 等工质在不同管径下传热系数的高精度回归($R^2=0.984$)。为了进一步解决微翅片管等复杂表面在非线性区域的预测残差问题,Kinjo 等^[36]提出对深度神经网络(DNN)与高斯过程回归(GPR)结合模型进行微调,利用 GPR 对 DNN 的预测残差进行补偿,不仅显著提升了小样本数据下的预测精度,还通过沙普利加性解释(SHAP)分析,定量揭示了表面张力和质量流速对微翅片传热增强的主导作用。其研究结果如图 5 所示,不同算法的误差结果如表 2 所示。由图 5(c)和表 2 可知,该微调 GPR 模型在测试集上有 96.7% 的数据点预测偏差在 $\pm 30\%$ 以内,均方误差仅为 2.3,优于单一模型。针对超临界 CO_2 在拟临界点附近复杂的传热恶化与增强行为,Shi 等^[37]提出了一种基于多保真度数据的迁移学习框架。该研究首先利用低保真度的经验关联式与数值模拟数据对模型进行预训练,随后利用少量高保真实验数据进行微调,成功解决了纯数据驱动模型在极端物性变化区域泛化能力差的难题。





图 5 采用不同模型得到的平均传热系数预测值与实验值的对比^[36]

Fig. 5 Comparison of predicted and experimental values of average heat transfer coefficient using different models^[36]

表 2 不同算法下平均传热系数的误差结果对比
Table 2 Comparison of error results of average heat transfer coefficient under different algorithms

模型	标准差/ %	均方 误差	偏差 $\pm 20\%$	偏差 $\pm 30\%$
			内数据点 占总数据点 的比例/%	内数据点 占总数据点 的比例/%
DNN	21.9	5.1	88.2	94.5
DNN+GPR	19.8	2.4	93.0	96.2
微调 GPR	18.7	2.3	93.5	96.7

在临界热通量这一关键安全限值的预测上,Zhou 等^[38]首次评估了基于自注意力机制的 Transformer 模型在流动沸腾中的应用潜力。研究发现,Transformer 架构凭借其捕捉长程依赖关系的能力,在处理大规模临界热通量数据库时的表现

优于传统 ANN 与 CNN 模型,可通过迁移学习成功地将圆管内训练的模型知识迁移至环形通道与板状燃料组件的预测中,大幅降低了对异构几何实验数据的依赖。尽管纯数据驱动模型在精度上屡创新高,但其物理一致性的缺失始终是工程应用的隐忧,因此融合物理机制的混合建模代表了未来的发展方向。Furlong 等^[39]提出了一种基于物理的混合机器学习策略,用于预测管内流动沸腾的临界热通量。该方法并未完全摒弃传统经验公式,而是将经典的物理关联式作为基准模型,采用深度神经网络专门学习了物理公式理论值与实验值之间的偏差。研究结果表明:该混合模型不仅在数据密集区域保持了机器学习的高精度,更在数据稀疏区域继承了物理公式的鲁棒性,有效避免了纯黑盒模型在未知工况下的非物理预测行为。

综合来看,流动沸腾的预测研究正从单纯的算法竞赛转向对物理机理与数据价值的深度挖掘。然而,有以下两点需要注意:①在不同工况条件下,各种算法的性能表现各异,不存在普适性的最优算法;②模型的预测范围受限于训练数据库的覆盖度,未来若要拓展其适用性,关键在于纳入更多样化的训练数据,并通过增大有效数据量或研发新型预测模型,持续提升预测的准确性和泛化能力。

3 关键瓶颈与发展方向

就现阶段而言,人工智能在沸腾传热方面的应用主要集中在气泡识别和参数预测,但这些工作大多比较分散,缺乏系统性。现有的模型在面对工况变化、物理机制解释及小样本数据时,表现往往不够稳定。未来的研究不应停留在单纯比拼算法精度,重点应在于实现物理机理与数据驱动模型的深度融合。只有通过这种方式构建的工具,才能兼顾通用性与可靠性。

3.1 当前面临的深层瓶颈

机器学习在沸腾传热中的应用已不再局限于单纯的参数预测,目前的尝试正拓展至系统优化控制和物理机理的解释。Chu 等^[21]的研究结果表明,机器学习擅长捕捉大规模数据中的非线性规律。利用这一特长,研究者能够从新视角解析复杂的传热机制,从而显著提高对沸腾传热行为预测的准确度。

尽管理论潜力巨大,但目前的实际应用效果尚未达到预期,其最主要的问题在于模型的泛化能力受限。现有的算法大多依赖于特定实验台产出的单一数据集,一旦改变工质物性(如从水变为制冷剂)、

几何结构或者观测视角,模型的预测精度往往会大幅下降。Zhou 等^[38]在研究中发现,传统的 CNN 模型很难直接从圆管工况迁移到环形通道来预测临界热通量,通常需要依赖新数据进行重新校准。这种对特定数据源的过度依赖,严重阻碍了这些模型在复杂工业热工系统中的广泛应用。

此外,当前的应用多局限于对现象的观测,缺乏对系统的反向控制。虽然在图像识别和参数回归方面已有较多积累,但仍缺少针对闭环控制及实时优化的研究。Huang 等^[44]建议,后续工作应尝试将 AI 融入到实时反馈环节中,通过快速识别状态来即时调整实验参数。这种改进能够简化决策步骤,在提升效率的同时减少资源消耗。

当前,实验和数值模拟依然占据主导地位,机器学习更多是作为一种补充手段,尚未成为核心方法。这也导致其在沸腾传热领域的实际影响力受限,因而暂时无法改变现有的研究模式。其中,最大的阻碍来自算法本身的黑盒性质以及对数据的高度依赖。与传统的经验关联式相比,机器学习虽然拟合得更准,但物理可解释性的缺失令其在实际应用中面临信任问题^[45],特别是在那些对物理推导要求极高的工程设计场景中。

模型训练的效果直接受限于数据的丰富程度,若数据覆盖面不够,模型极易出现过拟合,一旦换个环境就无法工作。想要获得高质量且普适性强的数据,往往需要投入大量的实验工作,且后续的数据标注也非常耗时耗力。此外,深度学习这类复杂算法对算力要求极高,通常需要配备昂贵的高性能计算设备,这对许多硬件资源有限的研究人员来说也是一个不小的门槛。

3.2 未来发展方向与技术路线

基于上述文献的系统梳理,本文归纳出 4 个值得关注的研究方向,期望能够促进人工智能与沸腾传热的结合。

(1)机器学习在优化问题中的应用。除了常规的预测任务,机器学习目前也开始介入更复杂的优化环节,比如针对加热表面的结构设计或是寻找最佳工况参数。目前常见的做法是将进化算法、贝叶斯优化等方法与机器学习模型结合使用,以提升系统性能。Lyu 等^[46]利用随机森林算法分析冷却剂参数对沸腾散热的影响,并进一步通过神经网络反推最大热通量,实现了基于仿真数据的参数优化。然而,目前的优化过程还做不到完全自动化,在设定优化目标和约束条件时,依然高度依赖研究人员的

物理经验。随着后续智能算法的迭代,机器学习在设计高效传热设备方面有望发挥更核心的作用。

(2)采用机器学习加速仿真。传统的数值模拟虽然一直是沸腾传热研究的主流手段,但其计算成本较高,特别是在面对高分辨率或多物理场耦合的复杂场景时,耗时往往极长。深度学习的出现恰好能缓解这一问题。Jalili 等^[47]利用物理信息神经网络对两相膜态沸腾开展模拟,证实了该方法既能摆脱对大规模数据的过度依赖,又能绕开传统计算流体力学中棘手的网格依赖问题。后续如果能进一步结合高性能计算资源,这类混合驱动的仿真模式将变得更加高效,真正成为工程应用中可靠的计算工具。

(3)迁移学习在沸腾传热研究中的应用。面对数据匮乏和泛化能力弱这两个长期困扰沸腾传热建模的问题,迁移学习提供了一个非常有价值的解题思路。其通过迁移已有的成熟模型,在面临新工况时只需进行简单微调,即可大幅降低对数据数量的依赖。Zhu 等^[48]采用这一策略构建框架,专门用于预测微针翅片微通道的流动沸腾传热系数。研究结果证实,仅需引入极少量数据,模型就能有较好的预测效果。未来,迁移学习很可能会成为不可或缺的技术手段。

(4)结合深度强化学习实现智能控制。机器学习除了应用在识别和预测方面,还应进一步应用于对系统的智能控制。深度强化学习(DRL)是实现这一目标的工具,其能根据实时反馈系统动态调整操作参数。DRL 在沸腾传热的探索才刚刚起步,例如 Raut 等^[49]设计了一种双网格策略,将 DRL 与计算流体动力学耦合,增强了核态池沸腾的效果。随着传感器硬件与实时算法的配合日益成熟,利用 DRL 打造一套高效稳定的智能控制系统将变为可能。

4 总 结

沸腾传热本质上是一个涉及多物理场交互的复杂过程,而处理这类高度非线性的难题恰好是机器学习的强项,本文综述了机器学习在沸腾传热领域取得的研究进展,涵盖了识别、预测和控制等方面,指出其不仅能够识别沸腾传热的核心参数,还能构建高精度预测模型揭示其内在物理规律。机器学习在沸腾传热问题中的应用越来越多,主要归因于以下几个关键因素。

(1)快速发展的算法。近年来开源工具与框架的大量涌现,尤其是以深度学习为代表的技术突破,为

处理复杂场景下的图像识别与性能预测问题提供了可行路径。CNN、RNN、LSTM 以及 Transformer 等多种先进算法的出现,使得研究人员能够快速构建并训练模型,无需深究其底层逻辑。这种技术的易用性一定程度上降低了机器学习在沸腾传热研究领域中的应用门槛。此外,计算机视觉识别技术的进步也为沸腾传热过程中的气泡动力学研究带来了巨大的便利性。

(2)快速分析与预测能力。面对实验产生的海量数据(尤其是气泡图像),单纯依靠传统的人工处理复杂且低效。机器学习的引入大大提升了处理速度,也让实验过程的实时动态监测和反馈控制成为可能。在性能预测方面,传统的经验关联式对实验条件要求比较苛刻;相比之下,机器学习在处理非线性关系上展现出了天然优势。其能综合考虑工质物性、表面特性和流动条件等复杂因素,从而构建出精度更高、适应面更广的预测模型。

(3)广阔的发展空间。尽管机器学习在沸腾传热领域的应用前景广阔,但现阶段的推广仍受制于多重因素,如对高质量、大规模训练集的依赖,高昂的算力成本,算法本身缺乏物理可解释性的黑盒特征等。目前,许多研究人员尝试对算法进行改进,如引入迁移学习以减少对数据的依赖,利用贝叶斯优化来增强模型的鲁棒性与准确度等。未来,相信机器学习将不局限于参数预测,而是逐渐向系统的智能调控发展。随着强化学习与物理驱动方法的结合,在实现传热系统实时优化与能效提升方面,人工智能将会发挥关键作用。

参考文献:

- [1] FANG Xiande, ZHUANG Fengting, CHEN Chuang, et al. Saturated flow boiling heat transfer: review and assessment of prediction methods [J]. *Heat and Mass Transfer*, 2019, 55(1): 197-222.
- [2] GUNGOR K E, WINTERTON R H S. A general correlation for flow boiling in tubes and annuli [J]. *International Journal of Heat and Mass Transfer*, 1986, 29(3): 351-358.
- [3] FANG Xiande. A new correlation of flow boiling heat transfer coefficients based on R134a data [J]. *International Journal of Heat and Mass Transfer*, 2013, 66: 279-283.
- [4] 曹建明. Nukiyama-Tanasawa 型雾化液滴尺寸分布函数的引申 [J]. *中国公路学报*, 1999, 12(S1): 108-113.
CAO Jianming. An extension of the Nukiyama-Tanasawa

- droplet size distribution function in sprays [J]. China Journal of Highway and Transport, 1999, 12(S1): 108-113.
- [5] JAMBUNATHAN K, HARTLE S L, ASHFORTH-FROST S, et al. Evaluating convective heat transfer coefficients using neural networks [J]. International Journal of Heat and Mass Transfer, 1996, 39(11): 2329-2332.
- [6] LIU Tianqing, SUN Xiangyu, LI Xiangqin, et al. Neural network analysis of boiling heat transfer enhancement using additives [J]. International Journal of Heat and Mass Transfer, 2002, 45(25): 5083-5089.
- [7] GUO Lei, ZHANG Shusheng, CHEN Yaqun, et al. Identification of boiling two-phase flow regimes based on two kinds of neural networks [J]. Applied Mechanics and Materials, 2010, 29-32: 54-60.
- [8] ZHOU Wen, MIWA S, Okamoto K, et al. Development of the AI-assisted thermal hydraulic analysis method for condensing bubbles in vertical subcooled flow boiling [C]//2024 31st International Conference on Nuclear Engineering. New York, USA: ASME, 2024: V011T15A011.
- [9] JAHANBANI H, AHMED K, GU B. Data-driven artificial intelligence-based streamflow forecasting, a review of methods, applications, and tools [J]. Journal of the American Water Resources Association, 2024, 60(6): 1095-1119.
- [10] 周匀茜, 焦鹏, 邓正万, 等. 大数据分析中的机器学习算法应用 [J]. 集成电路应用, 2025, 42(1): 292-293.
- ZHOU Yunxi, JIAO Peng, DENG Zhengwan, et al. Application of machine learning algorithms in big data analysis [J]. Application of IC, 2025, 42(1): 292-293.
- [11] 李茹杨, 彭慧民, 李仁刚, 等. 强化学习算法与应用综述 [J]. 计算机系统应用, 2020, 29(12): 13-25.
- LI Ruyang, PENG Huimin, LI Rengang, et al. Overview on algorithms and applications for reinforcement learning [J]. Computer Systems & Applications, 2020, 29(12): 13-25.
- [12] PARVEEN N, ZAIDI S, DANISH M. Comparative analysis for the prediction of boiling heat transfer coefficient of R134a in micro/mini channels using artificial intelligence (AI)-based techniques [J]. International Journal of Modelling and Simulation, 2020, 40(2): 114-129.
- [13] 杨博皓, 焦炜, 毕景良, 等. 基于机器学习的气液相变换热反演及应用 [J]. 工程热物理学报, 2023, 44(12): 3341-3347.
- YANG Bohao, JIAO Wei, BI Jingliang, et al. Gas-liquid transformation thermal inversion based on machine learning and its application [J]. Journal of Engineering Thermophysics, 2023, 44(12): 3341-3347.
- [14] SAJJAD U, HUSSAIN I, HAMID K, et al. Liquid-to-vapor phase change heat transfer evaluation and parameter sensitivity analysis of nanoporous surface coatings [J]. International Journal of Heat and Mass Transfer, 2022, 194: 123088.
- [15] ZHANG Junfeng, ZHONG Dawen, SHI Haopeng, et al. Machine learning prediction of critical heat flux on downward facing surfaces [J]. International Journal of Heat and Mass Transfer, 2022, 191: 122857.
- [16] GALICIA E S, MATAMOROS A H, MIYARA A. Prediction of heat transfer coefficient and pressure drop of flow boiling and condensation using machine learning [J]. Journal of Physics: Conference Series, 2024, 2766(1): 012152.
- [17] KUMAR R, DUBEY S, SEN D, et al. A machine learning based approach for predicting pool boiling heat transfer coefficient of CNT + GO nanoparticle coated surfaces [J]. International Communications in Heat and Mass Transfer, 2024, 154: 107455.
- [18] ZHANG Songyuan, LI Yuexiwei, XU Zheng, et al. Intelligence modeling of the flow boiling heat transfer of nanorefrigerant for integrated energy system [J]. Frontiers in Energy Research, 2024, 12: 1412538.
- [19] 汪奇, 杨力, 饶宇. 深度学习方法在涡轮冷却中的应用综述 [J]. 工程热物理学报, 2022, 43(3): 656-662.
- WANG Qi, YANG Li, RAO Yu. A review of deep learning methods in turbine cooling [J]. Journal of Engineering Thermophysics, 2022, 43(3): 656-662.
- [20] HERRMANN L, KOLLMANNSEBERGER S. Deep learning in computational mechanics: a review [J]. Computational Mechanics, 2024, 74(2): 281-331.
- [21] CHU Huaqiang, JI Tianxiang, YU Xinyu, et al. Advances in the application of machine learning to boiling heat transfer: a review [J]. International Journal of Heat and Fluid Flow, 2024, 108: 109477.
- [22] SUH Y. Bridging the gap: vision-inspired two-phase heat transfer analysis [D]. Irvine, USA: University of California, 2022.
- [23] LEE H, LEE G, KIM K, et al. Multimodal machine learning for predicting heat transfer characteristics in micro-pin fin heat sinks [J]. Case Studies in Thermal Engineering, 2024, 57: 104331.
- [24] ZHAO Yanwei, WANG Zhibo, LIU Qi, et al. Bubble behavior parameters extraction and analysis during

- pool boiling based on deep-learning method [J]. *International Journal of Multiphase Flow*, 2024, 180: 104979.
- [25] DUNLAP C, LI C, PANDEY H, et al. BubbleID: a deep learning framework for bubble interface dynamics analysis [J]. *Journal of Applied Physics*, 2024, 136(1): 014902.
- [26] HOBOLD G M, DA SILVA A K. Machine learning classification of boiling regimes with low speed, direct and indirect visualization [J]. *International Journal of Heat and Mass Transfer*, 2018, 125: 1296-1309.
- [27] WU Mengqi, GUI Nan, YANG Xingtuan, et al. Multi-task image-based deep learning for boiling analysis: material recognition and heat flux prediction [J]. *International Communications in Heat and Mass Transfer*, 2025, 163: 108763.
- [28] SINHA K N R, KUMAR V, KUMAR N, et al. Deep learning the sound of boiling for advance prediction of boiling crisis [J]. *Cell Reports Physical Science*, 2021, 2(3): 100382.
- [29] SCHEPPERLE M, JUNAID S, WOIAS P. Computer-vision-and deep-learning-based determination of flow regimes, void fraction, and resistance sensor data in microchannel flow boiling [J]. *Sensors*, 2024, 24(11): 3363.
- [30] ZHOU Wen, MIWA S, TSUJIMURA R, et al. Bubble feature extraction in subcooled flow boiling using AI-based object detection and tracking techniques [J]. *International Journal of Heat and Mass Transfer*, 2024, 222: 125188.
- [31] SUH Y, BOSTANABAD R, WON Y. Deep learning predicts boiling heat transfer [J]. *Scientific Reports*, 2021, 11(1): 5622.
- [32] SAJJAD U, YAN W M, HUSSAIN I, et al. Physics and correlations informed deep learning to foresee various regimes of the pool boiling curve [J]. *Engineering Applications of Artificial Intelligence*, 2024, 136(Part A): 108867.
- [33] SAJJAD U, RAZA W, HUSSAIN I, et al. On the prediction and optimization of the flow boiling heat transfer in mini and micro channel heat sinks [J]. *Progress in Nuclear Energy*, 2024, 177: 105466.
- [34] MEHDI S, BORUMAND M, HWANG G. Accurate and robust predictions of pool boiling heat transfer with micro-structured surfaces using probabilistic machine learning models [J]. *International Journal of Heat and Mass Transfer*, 2024, 226: 125487.
- [35] 韩莎莎, 李兴涛, 何畅, 等. 基于数据驱动的蒸发器中流体流动沸腾传热性能预测方法 [J]. *高校化学工程学报*, 2024, 38(4): 636-643.
- HAN Shasha, LI Xingtao, HE Chang, et al. A data-driven approach for predicting fluid flow boiling heat transfer performance in an evaporator [J]. *Journal of Chemical Engineering of Chinese Universities*, 2024, 38(4): 636-643.
- [36] KINJO T, SEI Y, GIANNETTI N, et al. Prediction of boiling heat transfer coefficient for micro-fin using mini-channel [J]. *Applied Sciences*, 2024, 14(15): 6777.
- [37] SHI Xinhuan, LIU Yongji, XUE Longxian, et al. Prediction of supercritical CO₂ heat transfer behaviors by combining transfer learning and deep learning based on multi-fidelity data [J]. *International Journal of Heat and Mass Transfer*, 2024, 218: 124802.
- [38] ZHOU Wen, MIWA S, WANG Hanyu, et al. Assessment of the state-of-the-art AI methods for critical heat flux prediction [J]. *International Communications in Heat and Mass Transfer*, 2024, 158: 107844.
- [39] FURLONG A, ZHAO Xingang, SALKO R K, et al. Physics-based hybrid machine learning for critical heat flux prediction with uncertainty quantification [J]. *Applied Thermal Engineering*, 2025, 279 (Part A): 127447.
- [40] JIN Yue, SHIRVAN K. Study of the film boiling heat transfer and two-phase flow interface behavior using image processing [J]. *International Journal of Heat and Mass Transfer*, 2021, 177: 121517.
- [41] MAURUS R, ILCHENKO V, SATTELMAYER T. Study of the bubble characteristics and the local void fraction in subcooled flow boiling using digital imaging and analysing techniques [J]. *Experimental Thermal and Fluid Science*, 2002, 26(2/3/4): 147-155.
- [42] SUH Y, CHANDRAMOWLISHWARAN A, WON Y. Recent progress of artificial intelligence for liquid-vapor phase change heat transfer [J]. *npj Computational Materials*, 2024, 10(1): 65.
- [43] RAVICHANDRAN M, SU Guanyu, WANG Chi, et al. Decrypting the boiling crisis through data-driven exploration of high-resolution infrared thermometry measurements [J]. *Applied Physics Letters*, 2021, 118(25): 253903.
- [44] HUANG Mingming, LUO Jiu, MO Dongchuan, et al. FIND BEAR: an explainable artificial intelligence platform for stages automatic recognition in pool boiling [J]. *Applied Thermal Engineering*, 2025, 261: 125117.
- [45] LIN Lingnan, GAO Lei, KEDZIERSKI M A, et al. A

- general model for flow boiling heat transfer in microfin tubes based on a new neural network architecture [J]. *Energy and AI*, 2022, 8: 100151.
- [46] LYU Peizhao, AN Zhenhua, LI Menghan, et al. Artificial intelligence algorithms optimize immersion boiling heat transfer strategies to mitigate thermal runaway of lithium-ion batteries [J]. *eTransportation*, 2025, 24: 100395.
- [47] JALILI D, MAHMOUDI Y. Physics-informed neural networks for two-phase film boiling heat transfer [J]. *International Journal of Heat and Mass Transfer*, 2025, 241: 126680.
- [48] ZHU Guangya, LIU Shirui, ZHANG Dalin, et al. Transfer learning model to predict flow boiling heat transfer coefficient in mini channels with micro pin fins [J]. *International Journal of Heat and Mass Transfer*, 2024, 220: 125020.
- [49] RAUT H S, BHATTACHARYA A, SHARMA A. A dual grid-based deep reinforcement learning and computational fluid dynamics method for flow control and its application to nucleate pool boiling [J]. *International Journal of Heat and Mass Transfer*, 2024, 227: 125561.
- (编辑 李慧敏)