



基于深度迁移学习的池沸腾瞬时状态快速识别方法

张轩¹, 洪敏¹, 古江杭¹, 莫冬传^{4,5}, 衡益^{1,2,3*}

1. 中山大学计算机学院, 广州 510006;

2. 中山大学国家超级计算广州中心, 广州 510006;

3. 中山大学广东省计算科学重点实验室, 广州 510006;

4. 中山大学材料学院, 深圳 518107;

5. 广东省先进热控材料及系统集成工程技术研究中心, 广州 510275

* E-mail: hengyi@mail.sysu.edu.cn

收稿日期: 2022-12-12; 接受日期: 2023-08-18; 网络版发表日期: 2024-06-07

广东省重点领域研发计划(编号: 2021B0101190003)和广东省自然科学基金面上项目(编号: 2022A1515011514)资助

摘要 沸腾过程高效传热的同时也面临着沸腾危机, 而沸腾状态的瞬时识别与预测是维持“高功率密度电子器件”高效散热与延长生命周期的关键问题之一. 得益于人工智能的快速发展, 智能监测与快速识别技术逐渐被用于开发高效的沸腾状态检测器. 传统机器学习方法作为纯数据驱动方法难以摆脱对数据的过度依赖, 而在实际沸腾应用场景下, 模型会因为工况改变与数据稀缺面临泛化瓶颈. 基于此, 本文提出了一种基于深度迁移学习的池沸腾瞬时状态快速识别方法. 首先基于卷积神经网络构建状态识别器OrigCNN, 并利用自行开展的池沸腾实验获取沸腾瞬时状态数据集Dataset A训练源模型, 测试准确率为100%; 针对源模型的泛化瓶颈, 本文以自有数据集Dataset A为源域, 公开数据集Dataset B和Dataset C为目标域, 在源模型OrigCNN中引入迁移学习技术构建深度迁移模型TLCNN, 并分别使用目标域数据集的10%, 5%, 2.5%和1%构建小样本数据集用于迁移训练. 测试结果表明, 迁移训练样本数据量越多, TLCNN的测试准确率越高, 以使用5% Dataset B(132张)进行迁移训练为例, TLCNN测试准确率达99.83%, 临界状态检测假阴性率(false negative rate, FNR)为0.38%, 证明该模型在实际场景切换时迁移应用的有效性与可靠性. 此外, 本文提出的深度迁移学习模型的识别效率在单机设备上即可达到毫秒级, 对开发实时沸腾瞬态状态识别器及相应的数字孪生工具软件有重要的意义.

关键词 沸腾危机, 状态识别, 实时检测, 卷积神经网络, 迁移学习

1 引言

沸腾传热作为高效的传热方式之一, 被广泛应用于冶金、核反应堆、电加热锅炉、高性能电子设备和数据中心的浸没式冷却系统以及集成电路的冷却系统

等工业过程中^[1-7]. 沸腾过程根据不同阶段的气泡状态可分为自然对流、核态沸腾、过渡沸腾和膜态沸腾四个阶段, 其中核态沸腾阶段气泡可以快速脱离, 因此具备高效传热能力. 临界热流密度(critical heat flux, CHF)点作为沸腾过程的转折点^[8], 即沸腾过程可达到

引用格式: 张轩, 洪敏, 古江杭, 等. 基于深度迁移学习的池沸腾瞬时状态快速识别方法. 中国科学: 技术科学, 2024, 54: 1057-1068

Zhang X, Hong M, Gu J H, et al. Fast recognition of instantaneous states of pool boiling based on deep transfer learning (in Chinese). Sci Sin Tech, 2024, 54: 1057-1068, doi: [10.1360/SST-2022-0444](https://doi.org/10.1360/SST-2022-0444)

的最高表面热流密度. 达到CHF点之后, 沸腾过程由核态沸腾向过渡沸腾、膜态沸腾转变, 加热面逐渐被蒸汽膜覆盖, 导致设备的温度急剧上升. 膜态沸腾的发生对传热过程具有极强的破坏性. 例如, 在锅炉和蒸汽发生器中, 未及时散去的热负荷会使设备发生严重故障, 导致锅炉的蒸发管和蒸汽发生器的传热管被烧毁. 因此, 在工业应用场景下高效识别沸腾瞬时状态、检测及预测膜态沸腾的发生对于保障设备操作安全以及辅助设计相关设备具有重要意义.

实验研究中沸腾状态的检测可由加热面附近温度的变化特征来确定. 实验测定的方式需要将温度传感器放置于靠近加热表面的位置进行介入观察, 具有滞后性和灵敏度低等缺点. 可视化技术已应用到池沸腾过程中, 用于检测自然对流、核态沸腾、过渡沸腾与膜态沸腾之间的转化. 例如, 用于测量CHF的Zuber模型是基于对沸腾过程进行可视化研究开发的^[9], 研究者基于可视化技术对核态沸腾与膜态沸腾的机理也进行了相关研究^[10,11]. 池沸腾过程高速可视化技术的实现使得开发基于气泡形态的高效沸腾瞬时状态识别器成为可能.

近年来, 机器学习方法与计算机视觉技术的发展为解决沸腾瞬时状态识别问题提供了新的思路. 研究者基于沸腾过程中传感器测得的温度、压力、热流密度等数据, 开发了可有效预测流动状态、压降、CHF等信息的机器学习模型^[12~18]. 例如, Hobold和da Silva^[15]借助可视化图像开发相应的机器学习工具, 使用支持向量机(support vector machine, SVM)与多层感知器神经网络(multilayer perceptron neural networks, MLPNN)对池沸腾实验图像进行分类, 其对间接获取的可视化图像分类准确度达到93%, 但距离实际应用要求仍有差距. 目前, 深度学习^[19]领域主流的分类算法之一——卷积神经网络(convolutional neural networks, CNN), 在提取图像特征方面拥有公认的出色性能^[20,21]. CNN除了在人脸识别、图像分类^[22]领域成功实践, 也在生物医学影像分析^[23~25]、机械性能预测^[26]与故障诊断^[27]、空气动力学^[28,29]等领域被广泛应用. Hobold和da Silva^[16,18]结合贝叶斯统计开发CNN用于检测膜态沸腾. 相较于传统机器学习模型(如SVM, MLPNN等), 该模型对于膜态沸腾的检测准确率达到99%, 检测性能更优. 但是, 该模型忽略了实际应用场景下工况改变与数据稀缺引起的泛化瓶颈问

题. 为此, 本文致力于开发一种在多个工况下均可迁移的池沸腾瞬时状态识别算法及工具.

目前的相关实验与测试都是在沸腾工况(加热器表面形态、沸腾流体类型、操作参数等)固定的条件下获取的数据集上完成的, 而任意工况发生改变均会引起沸腾气泡形态、密度的变化. 若是在新数据集上重新进行学习调整, 则无法避免收集制作新数据集以及训练学习过程带来的巨大成本, 这也限制了识别器在新场景下的迁移应用. 迁移学习技术的发展为我们提供了新的思路, 即可将源数据集视为源域, 新数据集视为目标域^[30~32]. 迁移学习方法将深度学习模型的所有层在源域进行预训练, 而使用目标域在最后的分层进行微调, 从源域获取的知识将有助于提升在目标域的任务性能. 目前迁移学习已在医学成像^[33~36]等领域得到了广泛应用, 但在池沸腾研究领域鲜有尝试. 考虑到沸腾瞬时状态识别的重要性以及区分各类沸腾状态的可行性, 本文提出了一种基于深度迁移学习的池沸腾瞬时状态识别方法, 使用自有沸腾数据集构建模型, 并利用公开数据集模拟小样本数据测试, 测试结果展示了该方法在不同沸腾场景下的应用潜力.

2 基于深度迁移学习的识别方法

卷积神经网络作为目前主流的深度学习方法之一, 在图像识别分析领域拥有独特的优势. 本文基于CNN搭建基础识别器模型OrigCNN, 利用少量数据开展预实验, 对模型的网络层数、超参数进行设置. 图像经归一化预处理后输入模型. OrigCNN的结构如图1(a)所示, 由若干卷积层(卷积核大小为 3×3)、最大池化层(池化核大小为 2×2)及dropout层(rate=0.25)构成, 卷积核和池化核的尺寸较小主要考虑获取和保留更多局部细节特征^[37,38], 同时适度加深模型深度、设置dropout比例避免模型过拟合^[39]. 卷积层与池化层中均采用整流线性单元(rectified linear unit, ReLU)作为激活函数, 模块01与模块05的卷积层采用边缘填充. ReLU的计算公式如式(1)所示. 在特征提取模块后, 采用全局池化层^[40]将特征压缩传递给全连接层将预测结果映射输出.

$$\text{ReLU}(\cdot) = \max(\cdot, 0). \quad (1)$$

网络参数的优化通过最小化交叉熵损失函数

实现:

$$L = -\frac{1}{N} \sum_{j=1}^N \sum_{i=1}^n [y_{i,j} \ln \hat{y}_{i,j} + (1 - y_{i,j}) \ln (1 - \hat{y}_{i,j})], \quad (2)$$

其中, L 是损失函数值, N 是样本数量; n 代表预测值的维度, 即池沸腾状态分类的类别数; $y_{i,j}$ 和 $\hat{y}_{i,j}$ 分别代表独热编码表示的真实值与预测值; 交叉熵刻画的是概率分布之间的距离, 因此需要将网络前向传播的结果转化成概率分布, 采用Softmax回归(见式(3))输出图像在3种沸腾状态下的概率分布. $\hat{y}_i$ 是预测值, u_i 表示全连接层在 i 节点的输出值.

$$\hat{y}_i = \text{Softmax}(u_i) = \frac{e^{u_i}}{\sum_{j=1}^n e^{u_j}}. \quad (3)$$

训练过程中采用梯度下降法最小化损失函数, 采用反向传播算法^[41]计算梯度, 参数更新过程中采用Adam优化算法^[42].

作为一种数据驱动方法, 深度学习对数据具有较强的依赖性. 将基于源域训练得到的源模型应用于新场景下的目标域时, 模型的预测性能会下降. 解决此类问题一般需要在新工况下收集制作数据集并重新对模型进行训练测试, 但这种方案的可行性较差, 主要由于: (1) 重新学习将放弃此前模型学习到的知识; (2) 新数据集进行训练需满足训练所需的样本量, 数据获取成本高. 这些情况均不利于该方法在工程中的实际应用.

迁移学习技术的发展为解决此类泛化性瓶颈提供了一种新方案^[43]. 本文引入迁移学习构建深度迁移模型TLCNN, 保留源模型OrigCNN在源域学习到的部分沸腾状态特征, 并在目标域的小样本数据集上训练微调, 完成目标域的识别任务; 具体方法如下: 冻结源模型OrigCNN(共37987个参数)的前3个模块参数(19392个参数, 51.05%), 在后3个模块(18595个参数, 48.95%)利用目标域的小样本数据进行更新学习. 图1(b)展示了TLCNN模型的具体结构.

3 池沸腾过程数据集的构建

沸腾传热性能与气泡动力学过程密切相关, 不同

阶段的沸腾状态具有不同的气泡特征. 目前, 随着可视化技术的发展, 高速摄像机可以捕捉到沸腾的全过程, 开展沸腾实验可生成大量不同阶段的气泡状态图像, 这为开发数据驱动型深度学习分类器奠定了基础. 基于沸腾传热机理相关的前期研究基础^[44], 本课题组自行设计、开展了相关池沸腾实验, 收集、处理、制作了池沸腾过程图像数据集Dataset A.

在实际应用场景中沸腾过程的图像特征与源模型所学习到的特征有所差异, 在新场景下收集、制作新数据集成本巨大. 本文利用公开视频构建新数据集Dataset B¹⁾和Dataset C²⁾, 使用不同比例的Dataset B与Dataset C构造小样本数据集案例, 引入迁移学习技术对源模型在新数据集上构建的模型进行泛化性能测试, 模拟实际应用场景中数据稀缺的情况.

3.1 实验设置与视频获取

Dataset A是对本课题组自行设计开展的池沸腾实验中由高速摄像机拍摄的沸腾视频进行逐帧提取所得. 池沸腾测试的实验装置如图2所示^[44]. 实验装置由4部分构成: 加热系统、数据采集系统、视频采集系统与沸腾测试系统. 加热系统的主加热器内含有6根陶瓷加热棒. 测试表面是通过电沉积法制备的蜂窝状微纳多孔铜材料. 沸腾测试实验在1个大气压下开展, 测试工质为水; 数据采集系统中的T型热电偶用来采集温度数据; 视频采集系统采用高速摄像机Vision Research Phantom V21拍摄整个沸腾过程, 视频帧的分辨率为1280×848像素, 采集帧率为2000帧/s.

Dataset B¹⁾和Dataset C²⁾的数据从公开视频网站获取, 2个沸腾测试均在微孔涂层铜制成的加热器表面开展, 工作流体为水, 获取的视频分辨率分别为1280×720像素和512×480像素.

3.2 数据集准备

借助Python的imageio库对Dataset A, Dataset B和Dataset C获取的池沸腾视频分别进行逐帧读取, 并统一调整图像尺寸为128×128. 由于高速摄像机采集帧率极高, 沸腾过程发生迅速, 为避免数据集中图像重复, 提升模型训练鲁棒性, 本文对初步获取的数据进

1) Minseok H, Bertina B, Graham S. Pool Boiling Experiment. Youtube. 2014. <https://www.youtube.com/watch?v=GA9MBdePwmo>

2) You S M. Visualization-Pool Boiling. <https://msht.utdallas.edu>




图 1 (a) 基于CNN的OrigCNN基本结构; (b) 基于迁移学习技术的TLCNN基本结构

Figure 1 (a) Basic structure of the CNN-based OrigCNN; (b) basic structure of the TLCNN using transfer learning technology.




图 2 实验装置: 加热系统、数据采集系统、视频采集系统与沸腾测试系统

Figure 2 Experimental setup (heating system, data acquisition system, video acquisition system, and boiling test system).

行质量控制, 以连续图像之间的结构相似性指数 (structure similarity index measure, SSIM)^[45]来衡量二者之间的差异, 其中SSIM值高于0.9995的图像会被删除. SSIM的计算公式如下:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (4)$$

其中, x 和 y 代表两张输入图像, μ_x 和 μ_y 代表图像 x 和 y 的平均亮度, σ_x 和 σ_y 代表图像 x 和 y 的亮度标准差, σ_{xy} 代表

图像 x 和 y 的亮度协方差, C_1 和 C_2 是用于稳定分母不为0的常数, 与图像的最大亮度有关.

3.3 数据集描述

整个沸腾过程由4个阶段组成, 其中自然对流阶段无气泡产生, 易于直接观察. 当热流密度较高时, 核态沸腾和过渡沸腾的气泡状态相似. 为了更直观描述全过程的气泡状态, 本文以气泡形态特征作为各阶段的标签, 主要对传热充分发生的3类沸腾状态的气泡特

征进行研究(如图3): (1) 孤立气泡, 对应沸腾曲线中低热流密度下的核态沸腾阶段; (2) 气泡聚合, 对应高热流密度下的核态沸腾阶段; (3) 临界状态, 呈现发生膜态沸腾的迹象, 膜态沸腾逐渐占据主导.

Dataset A 主要根据实验中采集的温度与热流密度信息以及气泡形态自行标注; Dataset B 和 Dataset C 所采用的原视频已自行标注. 根据第2.2节提出的图像质量控制方案对数据集进行删减, Dataset A 未发现高度相似图像, Dataset B 和 Dataset C 中原有图像4612和3880张, 分别删除相似图像1272和824张; 最终使用的 Dataset A, Dataset B 和 Dataset C 分别含有12768, 3340 和3056张图像, 表1列举了3个数据集中各类沸腾状态的具体图像数量.

4 分析与讨论

本节对基于深度迁移学习方法所搭建的OrigCNN 与TLCNN模型在池沸腾瞬时状态识别任务中的准确性、鲁棒性和泛化性能进行测试与分析. OrigCNN-A, OrigCNN-B 和 OrigCNN-C 是分别使用 Dataset A, Data-

set B 和 Dataset C 训练得到的源模型(数据集以80%为训练集, 10%为验证集, 10%为测试集); 所有迁移学习模型均基于OrigCNN-A 在由不同比例 Dataset B 和 Dataset C 构成的目标域小样本数据集上微调.

各模型所使用的具体训练数据(含训练集与验证集)如表2所示. OrigCNN 各训练超参数设置: 批大小(batch-size, 每次迭代训练中使用的样本数量)为32, 学习率(learning rate, 优化算法迭代步长)为0.001, 遍历轮次(epoch, 遍历整个训练集的次数)为60(OrigCNN-C 训练轮次为80); TLCNN 各模型训练超参数设置: 批大小为32, 学习率为0.001, 遍历轮次为2000(TLCNN-5/6/7/8 遍历轮次设置为3000).

模型训练超参数设置考虑如下: 批大小的设置主要考虑计算资源的限制, 设置为32可保证充分利用GPU加速训练过程, 且不会出现内存溢出; 学习率与遍历轮次的设置主要考虑模型所使用训练数据样本的数量以及实际训练过程中各模型的收敛表现. 为保证模型稳定收敛, OrigCNN 选取适当的学习率(0.001)和遍历轮次(60或80)即可使模型充分收敛, 而TLCNN 模型使用的训练数据极为有限, 因此需要较大的遍历轮次




图3 (a) Dataset A 中各沸腾状态的代表图像; (b) Dataset B 中各沸腾状态的代表图像; (c) Dataset C 中各沸腾状态的代表图像
Figure 3 (a) Representative images of each boiling state in Dataset A; (b) representative images of each boiling state in Dataset B; (c) representative images of each boiling state in Dataset C.

表 1 Dataset A, Dataset B和Dataset C各沸腾状态图像数量

Table 1 Number of each boiling state images in Dataset A, Dataset B, and Dataset C

沸腾状态	Dataset A (张)	Dataset B (张)	Dataset C (张)
孤立气泡	3648	693	949
气泡聚合	4560	1331	1131
临界状态	4560	1316	976

表 2 模型训练、验证、测试数据信息汇总

Table 2 Summary of training data, validation data, and test data information used by specific models

模型名称	数据源 (张)	训练集 (张)	验证集 (张)	测试集 (张)
OrigCNN-A	Dataset A (12768)	10214	1277	1277
OrigCNN-B	Dataset B (3340)	2672	334	334
OrigCNN-C	Dataset C (2841)	2271	285	285
TLCNN-1	Dataset B (3340)	266	67	3007
TLCNN-2	Dataset B (3340)	132	33	3208
TLCNN-3	Dataset B (3340)	65	17	3258
TLCNN-4	Dataset B (3340)	25	7	3308
TLCNN-5	Dataset C (3056)	243	61	2752
TLCNN-6	Dataset C (3056)	120	31	2905
TLCNN-7	Dataset C (3056)	60	15	2981
TLCNN-8	Dataset C (3056)	23	6	3027

才可使得模型收敛、充分学习任务域图像的特征，具体到不同的迁移任务中，相应参数的设置仍需根据实际训练情况进行调整。

本文所有实验均在Nvidia GeForce GTX 1080显卡上完成，显卡内存为8 GB，其余计算配置信息如下：Intel (R) Core(TM) i7-8700K CPU@3.70 GHz, 16 GB RAM. 模型搭建基于Python 3.10, 以TensorFlow 2.9.1与Keras 2.9.0深度学习框架为基础。

4.1 基础识别器OrigCNN的性能测试

本文采用的深度学习模型会将图像经过训练后输出的3类沸腾状态中最高概率作为预测值，相关测试图像均未在训练数据集中出现。基于卷积神经网络搭建分类器模型OrigCNN，进行如下5类对比实验：(1) 在Dataset A上训练OrigCNN-A并在其源数据集上进行测试；(2) 在Dataset B上训练OrigCNN-B并在其源数据集上进行测试；(3) 在Dataset C上训练OrigCNN-C并在其源数据集上进行测试；(4) 将OrigCNN-A模型在Dataset B上进行跨数据集测试；(5) 将OrigCNN-A模型在Data-

set C上进行跨数据集测试。

图4展示了实验测试案例的实际应用状况，选取OrigCNN-A在源数据集Dataset A和新数据集Dataset B下的识别片段作为代表。训练得到的识别器识别单张图像的响应时间约为0.9 ms，具备在线识别潜力。上述5类对比实验的具体测试结果的混淆矩阵如图5所示(混淆矩阵中0代表临界状态，1代表气泡聚合，2代表孤立气泡)。

图5(a)~(c)显示OrigCNN模型在Dataset A, Dataset B和Dataset C上经过训练后均可达到100%的测试准确率，表明基于深度卷积神经网络搭建的识别器在池沸腾状态识别任务中具有优异的性能。图5(d)和(e)显示基于Dataset A训练的OrigCNN-A模型直接在Dataset B和Dataset C上进行分类测试的准确率仅为39.31%和34.06%，表明基于源域数据集训练的模型很难直接在新场景下应用。

除识别准确率外，池沸腾临界状态的识别也是本文关注的重点。临界状态对应到沸腾过程中即CHF点，是核态沸腾进入膜态沸腾的标志。检测膜态沸腾对实




图 4 深度学习模型池沸腾状态识别案例概览(未引入迁移学习). (a) OrigCNN-A在Dataset A上的检测性能展示; (b) OrigCNN-A在Dataset B上的检测性能展示

Figure 4 Overview of deep learning model pool boiling state recognition cases (transfer learning technology is not introduced). (a) Demonstration of OrigCNN-A detection performance on Dataset A; (b) demonstration of OrigCNN-A test performance on Dataset B.




图 5 (a) OrigCNN-A在Dataset A的测试结果混淆矩阵; (b) OrigCNN-B在Dataset B的测试结果混淆矩阵; (c) OrigCNN-C在Dataset C的测试结果混淆矩阵; (d) OrigCNN-A在Dataset B的测试结果混淆矩阵; (e) OrigCNN-A在Dataset C的测试结果混淆矩阵

Figure 5 (a) The confusion matrix of the test result by OrigCNN-A in Dataset A; (b) the confusion matrix of the test result by OrigCNN-B in Dataset B; (c) the confusion matrix of the test result by OrigCNN-C in Dataset C; (d) the confusion matrix of the test result by OrigCNN-A in Dataset B; (e) the confusion matrix of the test result by OrigCNN-A in Dataset C.

际工业控制具有重要意义, 如在核能领域, CHF是反应堆的重要安全运行限值, 为反应堆棒束建立精确的预测模型将有助于反应堆的合理设计以及安全运

行^[46-48]. 因此, 本文对实验过程中“临界状态”预测的结果进行分析, 该阶段若出现假阳性判断, 则表明孤立气泡与气泡聚合状态被误判为临界状态, 而如果出现假

表 3 TLCNN测试结果汇总

Table 3 Summary of test results by TLCNN

迁移训练及测试数据源	模型名称	迁移训练样本比例 (%)	平均准确率 (%)	最高准确率 (%)	最低准确率 (%)	临界状态FNR (%)
Dataset B	TLCNN-1	10	99.99	100	99.96	0.01
Dataset B	TLCNN-2	5	99.83	100	99.11	0.38
Dataset B	TLCNN-3	2.5	99.5	99.93	97.57	1.24
Dataset B	TLCNN-4	1	98.49	99.54	97	3.37
Dataset C	TLCNN-5	10	98.5	99.52	97.2	0.34
Dataset C	TLCNN-6	5	96.9	98.58	93.01	0.85
Dataset C	TLCNN-7	2.5	93.53	95.4	90.74	5.66
Dataset C	TLCNN-8	1	83.66	87.08	80.34	18.31

阴性, 则表明膜态沸腾状态未被识别. 显然, 假阴性判断对于实际工况的损害更大. 因此, 本文以假阴性率 (false negative rate, FNR) 作为衡量临界状态检测性能的指标, FNR 为被误判为其余 2 类状态的样本数在临界状态总样本数中的比例, FNR=0 时表明池沸腾识别器能够 100% 正确识别膜态沸腾状态.

由图 5 可直接计算求得 OrigCNN-A、OrigCNN-B 和 OrigCNN-C 在各自数据集上关于“临界状态”检测的 FNR=0, 而将 OrigCNN-A 直接在 Dataset B 和 Dataset C 上测试时, “临界状态”分别有 7 帧和 26 帧被误检为其他状态, FNR 分别为 0.53% 和 2.66%, 表明源域数据集训练得到的模型在新场景下检测“临界状态”的性能也随整体识别准确率的大幅降低出现下滑.

以上实验结果与分析表明, 基于自有源域数据训练所得的模型在新场景下的识别准确率、临界状态检测能力均出现下滑, 而在新场景下获取足量数据重新训练的方法成本过高且在部分场景下难以获取足量数据, 因此, 下节将讨论本文提出的一种可低成本迁移源模型的方案.

4.2 迁移学习模型 TLCNN 的性能测试

复杂多变的池沸腾工况对识别器的泛化性能提出较高的要求, 且实际应用场景下模型经常面临数据稀缺的困境, 这对数据驱动型的深度学习方法提出了挑战. 本节对本文提出的迁移学习模型 TLCNN 在由 Dataset B 构造的小样本数据集上的测试性能表现进行分析.

TLCNN 载入预训练完成的模型 OrigCNN-A, 冻结其中模块 01 到模块 04 的参数, 只在最后 2 个模块, 利用

不同比例的 Dataset B 和 Dataset C 数据微调得到对应的识别器模型. 一定比例的任务域数据 (10%, 5%, 2.5%, 1%) 构成了训练样本, 其中的 80% 作为训练集, 20% 作为验证集, 未加入训练样本的数据作为测试集使用. 表 1 列举了具体的数据信息. 迁移学习模型 TLCNN 所使用的训练数据有限, 以 2.5% 的 Dataset B 为例, 其中仅包含: 孤立气泡 16 张, 气泡聚合 33 张, 临界状态 32 张, 这为交叉训练验证带来难度. 为了测试模型的鲁棒性, 本文在构建各模型的训练样本时进行 10 次分层随机采样, 分别进行实验, 获得平均识别测试结果.

表 3 展示了各迁移学习模型 10 次分层随机抽样实验的表现: 各模型在 Dataset B 上的迁移识别准确率均达到 98% 以上; 迁移模型利用 10%, 5%, 2.5% Dataset C 微调训练后的识别准确率均超过 93%, 而采用 1% Dataset C 训练的 TLCNN-8 平均识别准确率降至 83.66%. 综合来看, 迁移模型预测准确率随迁移训练使用数据数量减少呈现降低趋势. 在使用 1% Dataset C 微调训练 TLCNN-8 时 (对应训练数据仅 23 张), 模型难以捕捉新场景下池沸腾各阶段的全部特征, 测试准确率大幅下降, 但仍远超无迁移学习策略下 OrigCNN-A 模型在目标域 Dataset C 上的识别性能 (34.06%). 另外, 表 3 还展示了各 TLCNN 模型 10 次实验检测临界状态的 FNR 平均值, FNR 随训练样本量的减少而增大; 虽然在使用极小比例 (2.5%, 1%) 进行迁移训练时, 模型的 FNR 较高, 但在使用 10% 和 5% 的小样本数据迁移训练后, TLCNN-1/2 与 TLCNN5/6 的表现仍优于 OrigCNN-A 在 Dataset B 和 Dataset C 上直接检测的结果 (0.53% 与 2.66%), 证明了该迁移策略的有效性, 同时也说明一定数量的新场景数据是保证模型优异识别性能的




图 6 深度迁移学习模型池沸腾状态识别案例概览: TLCNN-3在Dataset B上的检测性能展示

Figure 6 Overview of pool boiling states recognition cases using deep transfer learning model: TLCNN-3 detection performance on Dataset B.

基础.

分析实验结果可知, 迁移学习模型在仅使用小样本数据的条件下, 微调源模型参数, 在新场景下保持了较好的识别准确率. 实验结果验证了本文提出的基于深度迁移学习的识别策略的有效性, 说明该方法具备利用小样本数据在全新池沸腾场景下完成全过程快速识别的潜力.

图6展示了TLCNN模型的测试案例情况(以TLCNN-3为例), 与OrigCNN类似, 其单张图像的识别时间约为0.92 ms. 池沸腾实验中常用采集设备拍摄速度约0.5~1.5 ms/帧^[49], 证明本文提出的识别器响应速度可满足高速摄像机采集速率要求, 而常规监测设备的采集速率仅为30~120帧/s(约8~33 ms/帧), 远低于本文开发的识别器的响应速度. 考虑到本实验仅在普通单机上运行, 若采用算力和图像处理能力更优的GPU, 训练与测试时间将进一步缩短, 这也充分说明本方法具备应用于实际场景下池沸腾全过程实时识别的能力.

5 结论与展望

本研究提出了一种基于深度迁移学习的池沸腾瞬

时状态快速识别方法. 首先, 自行设计获取池沸腾瞬时状态数据集, 并基于卷积神经网络搭建沸腾状态识别器OrigCNN, 在自建数据集与2个公开数据集上的训练测试结果证明其具备识别瞬时沸腾状态的能力; 此外, 使用深度迁移学习方法构建TLCNN, 并利用小样本数据模拟实际应用场景中数据稀缺的情况, 稳定优异的识别性能证明该方法具备在实际沸腾场景下突破泛化性瓶颈的能力; 同时, 本文提出的方法在识别速度上表现优异, 证明其具备在线识别的潜力, 可在实际沸腾设备如核反应堆、数据中心的冷却装置中为控制人员或自动控制程序提供及时准确的沸腾瞬时状态信息, 进一步优化设备控制, 减少“沸腾危机”对传热与设备带来的破坏.

在实际工业应用场景下, 监督识别沸腾状态需要构建一个稳定且通用的识别器, 本文提出的基于深度迁移学习的策略在检测准确率、泛化性和识别速度等方面具有优异的性能. 未来, 该方法将在更广泛的沸腾场景下进行测试, 并逐步建立更为全面的池沸腾通用数据集, 包含各种实际应用场景下的沸腾过程, 以此为基础优化现有模型结构, 利用高性能处理器提升识别器的响应速度, 开发相应的池沸腾数字孪生工具软件, 推动本文提出的识别器在实际池沸腾场景中应用.

参考文献

- 1 Birbarah P, Gebrael T, Foulkes T, et al. Water immersion cooling of high power density electronics. *Int J Heat Mass Transfer*, 2020, 147: 118918
- 2 El-Genk M S. Immersion cooling nucleate boiling of high power computer chips. *Energy Convers Manage*, 2012, 53: 205–218
- 3 Kandlikar S G. Review and projections of integrated cooling systems for three-dimensional integrated circuits. *J Electron Packag*, 2014, 136: 4027175
- 4 Carey V P. Liquid-vapor Phase-change Phenomena: An Introduction to the Thermophysics of Vaporization and Condensation Processes in Heat Transfer Equipment. Boca Raton: CRC Press, 2020

- 5 Sun X Z, Li Q, Li W X, et al. Enhanced pool boiling on microstructured surfaces with spatially-controlled mixed wettability. *Int J Heat Mass Transfer*, 2022, 183: 122164
- 6 Huang Y, Sun Q, Yao F, et al. Experimental study on the thermal performance of a finned metal foam heat sink with phase change material. *Heat Transfer Eng*, 2021, 42: 579–591
- 7 Gao S, Qu J, Liu Z, et al. Nanoscale thin-film boiling processes on heterogeneous surfaces. *Langmuir*, 2022, 38: 6352–6362
- 8 Fenech H. *Heat Transfer and Fluid Flow in Nuclear Systems*. Amsterdam: Elsevier, 2013
- 9 Zuber N. Hydrodynamic aspects of boiling heat transfer. Technical Report. United States Atomic Energy Commission, Technical Information Service, 1959
- 10 Dhillon N S, Buongiorno J, Varanasi K K. Critical heat flux maxima during boiling crisis on textured surfaces. *Nat Commun*, 2015, 6: 1–2
- 11 Demiray F, Kim J. Microscale heat transfer measurements during pool boiling of FC-72: Effect of subcooling. *Int J Heat Mass Transfer*, 2004, 47: 3257–3268
- 12 Alimoradi H, Shams M. Optimization of subcooled flow boiling in a vertical pipe by using artificial neural network and multi objective genetic algorithm. *Appl Thermal Eng*, 2017, 111: 1039–1051
- 13 Liu Y, Dinh N, Sato Y, et al. Data-driven modeling for boiling heat transfer: Using deep neural networks and high-fidelity simulation results. *Appl Thermal Eng*, 2018, 144: 305–320
- 14 Hassanpour M, Vaferi B, Masoumi M E. Estimation of pool boiling heat transfer coefficient of alumina water-based nanofluids by various artificial intelligence (AI) approaches. *Appl Thermal Eng*, 2018, 128: 1208–1222
- 15 Hobold G M, da Silva A K. Machine learning classification of boiling regimes with low speed, direct and indirect visualization. *Int J Heat Mass Transfer*, 2018, 125: 1296–1309
- 16 Hobold G M, da Silva A K. Automatic detection of the onset of film boiling using convolutional neural networks and Bayesian statistics. *Int J Heat Mass Transfer*, 2019, 134: 262–270
- 17 Ravichandran M, Bucci M. Online, quasi-real-time analysis of high-resolution, infrared, boiling heat transfer investigations using artificial neural networks. *Appl Thermal Eng*, 2019, 163: 114357
- 18 Hobold G M, da Silva A K. Visualization-based nucleate boiling heat flux quantification using machine learning. *Int J Heat Mass Transfer*, 2019, 134: 511–520
- 19 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521: 436–444
- 20 Valueva M V, Nagornov N N, Lyakhov P A, et al. Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. *Math Comput Simul*, 2020, 177: 232–243
- 21 Pinaya W H L, Vieira S, Garcia-Dias R, et al. Convolutional neural networks. In: Mechelli A, Vieira S, eds. *Machine Learning: Methods and Applications to Brain Disorders*. London: Academic Press, 2020. 173–191
- 22 Zhang X J, Lu Y F, Zhang S H. Multi-task learning for food identification and analysis with deep convolutional neural networks. *J Comput Sci Technol*, 2016, 31: 489–500
- 23 Gao F, Wu T, Li J, et al. SD-CNN: A shallow-deep CNN for improved breast cancer diagnosis. *Computized Med Imag Graph*, 2018, 70: 53–62
- 24 Havaei M, Davy A, Warde-Farley D, et al. Brain tumor segmentation with deep neural networks. *Med Image Anal*, 2017, 35: 18–31
- 25 Esteva A, Kuprel B, Novoa R A, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 2017, 542: 115–118
- 26 Ye S, Li B, Li Q, et al. Deep neural network method for predicting the mechanical properties of composites. *Appl Phys Lett*, 2019, 115: 5124529
- 27 Chen Z, Gryllias K, Li W. Mechanical fault diagnosis using convolutional neural networks and extreme learning machine. *Mech Syst Signal Process*, 2019, 133: 106272
- 28 Ye S, Zhang Z, Song X, et al. A flow feature detection method for modeling pressure distribution around a cylinder in non-uniform flows by using a convolutional neural network. *Sci Rep*, 2020, 10: 4459
- 29 Bhatnagar S, Afshar Y, Pan S, et al. Prediction of aerodynamic flow fields using convolutional neural networks. *Comput Mech*, 2019, 64: 525–545
- 30 Talo M, Baloglu U B, Yildirim Ö, et al. Application of deep transfer learning for automated brain abnormality classification using MR images. *Cogn Syst Res*, 2019, 54: 176–188
- 31 Pan S J, Yang Q. A survey on transfer learning. *IEEE Trans Knowl Data Eng*, 2010, 22: 1345–1359
- 32 Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning. *J Big Data*, 2016, 3: 1–40

- 33 Wang K, Patel B K, Wang L, et al. A dual-mode deep transfer learning (D2TL) system for breast cancer detection using contrast enhanced digital mammograms. *IJSE Trans Healthcare Syst Eng*, 2019, 9: 357–370
- 34 Huynh B Q, Li H, Giger M L. Digital mammographic tumor classification using transfer learning from deep convolutional neural networks. *J Med Imag*, 2016, 3: 034501
- 35 Gao F, Yoon H, Wu T, et al. A feature transfer enabled multi-task deep learning model on medical imaging. *Expert Syst Appl*, 2020, 143: 112957
- 36 Zeng T, Ji S. Deep convolutional neural networks for multi-instance multi-task learning. In: *Proceedings of the IEEE International Conference on Data Mining*. Atlantic City, 2015. 579–588
- 37 Luo W, Li Y, Urtasun R, et al. Understanding the effective receptive field in deep convolutional neural networks. In: *Proceedings of the 30th International Conference on Neural Information Processing Systems*. Barcelona, 2016
- 38 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv: [1409.1556](https://arxiv.org/abs/1409.1556)
- 39 Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting. *J Mach Learn Res*, 2014, 15: 1929–1958
- 40 Lin M, Chen Q, Yan S. Network in network. arXiv: [1312.4400](https://arxiv.org/abs/1312.4400)
- 41 LeCun Y, Boser B, Denker J S, et al. Handwritten digit recognition with a back-propagation network. *Adv Neural Inf Proc Syst*, 1997, 2: 396–404
- 42 Kingma D P, Ba J. Adam: A method for stochastic optimization. arXiv: [1412.6980](https://arxiv.org/abs/1412.6980)
- 43 Zhuang F, Qi Z, Duan K, et al. A comprehensive survey on transfer learning. *Proc IEEE*, 2021, 109: 43–76
- 44 Hong M, Lu H, Luo J, et al. Model-based experimental analysis of enhanced boiling heat transfer by micro-nano porous surfaces. *Appl Thermal Eng*, 2021, 192: 116809
- 45 Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: From error visibility to structural similarity. *IEEE Trans Image Process*, 2004, 13: 600–612
- 46 Liu Y, Liu W, Shan J, et al. A mechanistic bubble crowding model for predicting critical heat flux in subchannels of a bundle. *Ann Nucl Energy*, 2020, 137: 107085
- 47 Liu Y, Yin Q, Shan J, et al. Assessment of a theoretical model for predicting forced convective critical heat flux in rod bundles. *Front Energy Res*, 2019, 7: 137
- 48 Liu W, Peng S, Jiang G, et al. Development and assessment of a new CHF mechanistic model for subcooled and low quality flow boiling. *Int J Heat Mass Transfer*, 2021, 165: 120641
- 49 Lu S, Heng Y, Mhamdi A. A robust and fast algorithm for three-dimensional transient inverse heat conduction problems. *Int J Heat Mass Transfer*, 2012, 55: 7865–7872

Fast recognition of instantaneous states of pool boiling based on deep transfer learning

ZHANG Xuan¹, HONG Min¹, GU JiangHang¹, MO DongChuan^{4,5} & HENG Yi^{1,2,3}

¹ School of Computer Science and Engineering, Sun Yat-sen University, Guangzhou 510006, China;

² National Supercomputing Center in Guangzhou (NSCC-GZ), Sun Yat-sen University, Guangzhou 510006, China;

³ Guangdong Province Key Laboratory of Computational Science, Sun Yat-sen University, Guangzhou 510006, China;

⁴ School of Materials, Sun Yat-sen University, Shenzhen 518107, China;

⁵ Guangdong Engineering Technology Research Centre for Advanced Thermal Control Material and System Integration (ATCMSI), Guangzhou 510275, China

The boiling process is an efficient heat transfer method that creates a boiling crisis. Instantaneous recognition and prediction of the boiling state are necessary to maintain efficient heat dissipation and prolong the life cycle of high-power-density electronic devices. Benefiting from the rapid advancements in artificial intelligence, intelligent monitoring and rapid recognition technologies have been gradually applied to develop efficient boiling-state detectors. Traditional machine learning methods, such as pure data-driven methods, encounter difficulties in avoiding their excessive dependence on data. However, in practice, models frequently experience generalization bottlenecks due to changes in working conditions and data scarcity. To resolve these issues, an instantaneous boiling-state recognition method based on deep transfer learning is proposed in this paper. First, a state recognizer OrigCNN is constructed based on the convolutional neural network and subsequently trained using Dataset A, obtained from our pool boiling experiments. The accuracy of the test is up to 100%. Considering the generalization bottleneck of the source model OrigCNN, the transfer learning technology is applied to further improve OrigCNN by constructing a deep transfer model TLCNN, with “Dataset A” as the source domain and the publicly available “Dataset B” and “Dataset C” as the target domain. 10%, 5%, 2.5%, and 1% of Dataset B and Dataset C are used to construct small sample datasets for transfer training. The test results show that the amount of sample data for transfer learning positively correlates with the prediction accuracy of TLCNN. The TLCNN test accuracy reached 99.83% when 5% Dataset B (132 photos) was used for transfer training, and the false negative rate of critical state detection was 0.38%, demonstrating the effectiveness and reliability of the TLCNN models in actual scene switching. Furthermore, the deep transfer learning method TLCNN proposed in this research exhibits high identification efficiency on the millisecond scale using a single computer device, which is of considerable importance for developing real-time boiling transient state recognizer and digital twin software tools.

boiling crisis, state recognition, real-time detection, convolutional neural networks, transfer learning

doi: [10.1360/SST-2022-0444](https://doi.org/10.1360/SST-2022-0444)