arXiv:2305.02622v1 [physics.flu-dyn] 4 May 2023

基于条件生成对抗网络的临界热流诊断

Na UngJin[a], Choi Moonhee[c], Jo HangJin[a, b,*]

[a]浦项科技大学（*POSTECH*）机械工程系，韩国庆尚北道浦项市南区清岩路*77*号，邮编*37673*[b]浦项科技大学（*POSTECH*）先进核工程学部，韩国庆尚北道浦项市南区清岩路*77*号，邮编*37673*[c]首尔国立大学核工程系，韩国首尔市冠岳区冠岳路*1*号，邮编*08826*

摘要

临界热流（CHF）是高热流密度热工水力系统中沸腾传热过程的一项重要安全界限。识别临界热流对于防止设备损坏并确保系统整体安全至关重要，但由于相关现象十分复杂，这一任务颇具挑战。为深入理解这些复杂现象，人们开发了多种方法，但获取高分辨率数据受到高昂资源消耗的限制。本研究提出一种数据驱动的图像到图像转换方法，利用条件生成对抗网络（cGAN）重建临界热流下沸腾系统的热数据。该监督学习过程依赖成对图像，包括流动沸腾实验中获得的全反射可视化图像和红外测温数据。所提出的方法不仅有望为相界面动力学与热分布之间的联系提供证据，还可简化红外热成像涉及的繁琐且耗时的实验装置搭建和数据处理流程，从而为临界热流诊断提供有效解决方案。

关键词： 临界热流 · 红外测温 · 条件生成对抗网络

1 引言

临界热流（CHF）代表核态沸腾过程中的最大热流，标志着表面温度骤然升高。作为高热流系统安全运行并防止系统损坏的关键因素，临界热流诊断已得到广泛研究，并由此发展出各种用于解释临界热流触发机制的机理模型 [1][2][3][4]。在这些模型中——例如流体动力学不稳定模型、宏观液层干涸模型和界面脱离模型——热点/干斑模型提出，不可逆干斑的形成会导致温度升高，据此推断，不可逆干斑温度的发展会妨碍供给液体润湿受热表面 [5]。干斑首先在高热流下形成，随后在残余气泡下再次合并并扩展，进而触发临界热流 [6]。

为验证和改进此类模型，研究人员开发了可视化观测方法 [7][8]。全反射可视化和红外测温（IR）被认为是观测干斑形成并同时测量液-汽系统温度演变的最重要技术 [9][10][11]。通过这些方法，研究人员观测了流动沸腾下气泡结构和干斑的行为，并分析了不可逆干斑的流体动力学机制。此外，研究人员还尝试根据干斑周边的温度确定临界热通量 [6][12]。

此外，随着卷积神经网络（CNNs）近期取得进展，并在捕捉视觉信息特征方面表现出色，神经网络有望简化红外热成像流程，因为该流程通常涉及繁琐的实验设置和大量数据缩减 [13]。特别是，生成对抗网络（GANs）的应用促进了图像生成，同时能够学习输入的风格

*通讯作者，jhj04@postech.ac.kr

表示，从而使图像处理中的许多挑战能够在统一框架内得到解决[14]。通过结合卷积神经网络和生成对抗网络，深度卷积生成对抗网络（DCGANs）能够更有效地捕捉视觉信息特征，同时稳定学习过程 [15]。此外，条件生成对抗网络（cGANs）借助卷积生成器-判别器架构，实现了自动图像到图像转换 [16]。

本研究提出了一种用于临界热流诊断的新方法，采用利用条件生成对抗网络的数据驱动图像到图像转换方法。该方法有望简化温度场的成像过程，并显著提高从大型数据集中提取有价值信息和生成可视化图像的速度。为开发可靠的方法，使用了包含全反射图像和红外图像的定义明确的实验数据，并采用改进的条件生成对抗网络架构，从原始图像生成模拟结果。实验测得的红外图像与生成的红外图像之间的比较表明，该方法能够将涉及物理现象的图像从灰度图像（全反射图像）转换为RGB图像（红外图像）。此外，还利用主成分分析对潜在空间进行了研究，该分析支持所提热分布分析方法的可靠性。

2 方法论

2.1 数据采集

本研究的数据集基于流动沸腾实验生成，该实验旨在获取全反射图像和红外图像。实验装置如下：主要测试段由一个方形通道构成，其四个侧面由三块透明聚碳酸酯板和一块蓝宝石板组成。实验中使用的主要加热表面为镀有氧化铟锡（ITO）的蓝宝石试样，因其透明度高且红外透射率低，可直接测量加热表面的温度。在蓝宝石板底部放置了一个三角棱柱形硅油浴，以设定沸腾表面的全反射入射角。实验涵盖了从离散气泡到临界热流条件的核态沸腾区域。通过同时观察全反射图像和红外图像，确定临界热流的发生判据。实验中使用的高速摄像机为 NAC公司制造的 Memrecam GX-3（彩色），以及用于红外热成像、采集沸腾温度信息的 FLIR X6903sc相机。实验详情见 [12]。

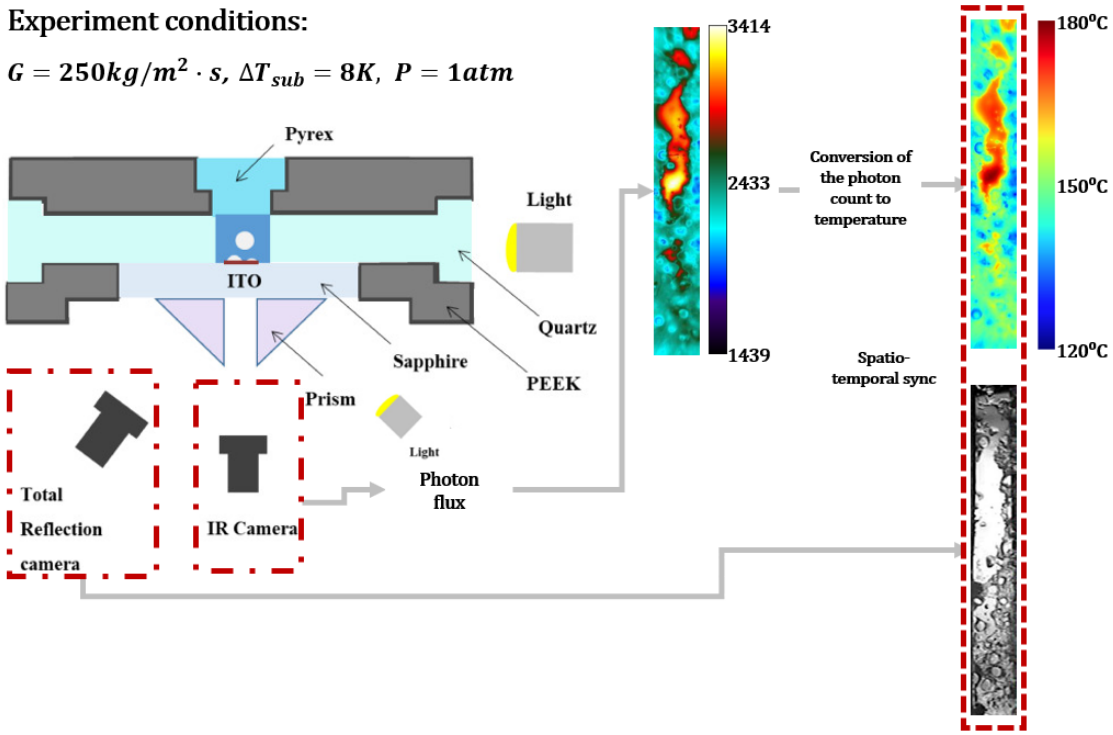

图1：可视化实验示意图

2.2 条件生成对抗网络的实现

Th将全反射图像转换为红外图像的过程可表述如下 :

$$G : X \to Y, \qquad X = \{x_i\}_{i=1}^{N}, \quad Y = \{y_i\}_{i=1}^{N} \tag{1}$$

其中， x 和 y 分别表示全反射图像和红外图像， i 表示图像的序列索引。该过程采用条件生成对抗网络进行处理，其中生成器（G）学习将输入图像转换为与目标相似的输出图像。这确保了给定输入时预测结果的条件概率趋近于给定输入时真实值的条件概率。与此同时，判别器（D）旨在区分真实图像与生成图像。

条件生成对抗网络的目标函数 $\mathcal{L}_{\mathrm{cGAN}}(D, G)$表示如下 [16]:

$$\mathcal{L}_{\mathrm{cGAN}}(D, G) = \mathbb{E}_{y \sim p_{\mathrm{data}}(y)}[\log D(y|x)] + \mathbb{E}_{\hat{y} \sim p_{\mathrm{data}}(\hat{y})}[\log(1 - D(G(\hat{y}|x)))] \tag{2}$$

公式中的第一项表示在给定条件（x）下，判别器正确分类真实图像（y）的对数概率期望。第二项表示在给定条件（x）下，判别器错误分类由生成器生成的图像（$\hat{}y$）的对数概率期望。条件生成对抗网络使用二元交叉熵损失函数进行训练，该函数用于衡量生成输出与真实值之间的相似度。

为优化条件生成对抗网络，求解以下鞍点优化问题:

$$G^* = \arg\min_G \max_D \left[\mathcal{L}_{\mathrm{cGAN}}(D, G) + \mathcal{L}_{L1}(G)\right] \tag{3}$$

如方程所示，cGAN 训练过程中，生成器旨在最小化目标函数，也就是说，生成器努力生成具有迷惑性的红外图像来欺骗判别器，而判别器则试图区分真实红外图像与生成的红外图像。在优化问题中加入 $\mathcal{L}_{L1}(G)$ 项有助于匹配真实值的细节，从而提高生成图像的质量。通过在这一优化过程中迭代更新生成器和判别器，该模型能够有效地学会生成逼真的图像，使其与真实值高度相似。

本研究采用改进的 U-Net 架构作为生成模型来合成图像。该架构的生成器部分由编码路径和解码路径组成。编码路径由一系列下采样模块构成，通过将全反射图像域 X 转换到潜在空间 z，提取输入图像的上下文信息和空间信息。解码路径由一系列上采样模块构成，通过将潜在变量 z 转换到红外图像域 Y，恢复细节信息并生成输出图像。两条路径中对应层之间的跳跃连接有助于保留输入和输出共有的低层信息。

该架构中的判别器部分旨在惩罚局部图像块中的高频信息结构。改进后的 PatchGAN 会将图像中的每个图像块分类为真实或伪造，并对所有响应取平均，以生成 D 的输出。通过将判别器的注意力限制在各个图像块上，它实际上将图像建模为马尔可夫随机场，以捕捉局部信息。

模型使用来自流动沸腾实验案例的成对图像进行训练，这些图像分别是光学可视化图像和红外测温结果，并作为真实值。使用了两个实验数据集，每个数据集包含 1650 张图像；图像经过随机打乱后，划分为训练集和测试集。模型使用 PyTorch 1.12 和 CUDA 11.3 实现，并在 Ubuntu 20.04 环境下通过 RTX 3070 Ti 显卡运行。

3 结果

3.1 生成图像快照与干斑行为

图 3 展示了全反射视图中捕捉到的三个不同时刻，以及由生成器转换得到的温度分布，并列出了临界热通量发生期间的真实值红外图像，分别标记为 TR、GAN 和红外图像。可以观察到干斑扩大，平均温度升高。残余干斑持续扩大，最终触发临界热通量。当再润湿失效发生时，最高温度持续升高，干斑面积不再减小。

根据生成的温度场，对运行 1 和运行 2 均采用 167°C 的阈值，并通过展示每次实验运行的等值线，识别温度场中的不可逆干斑

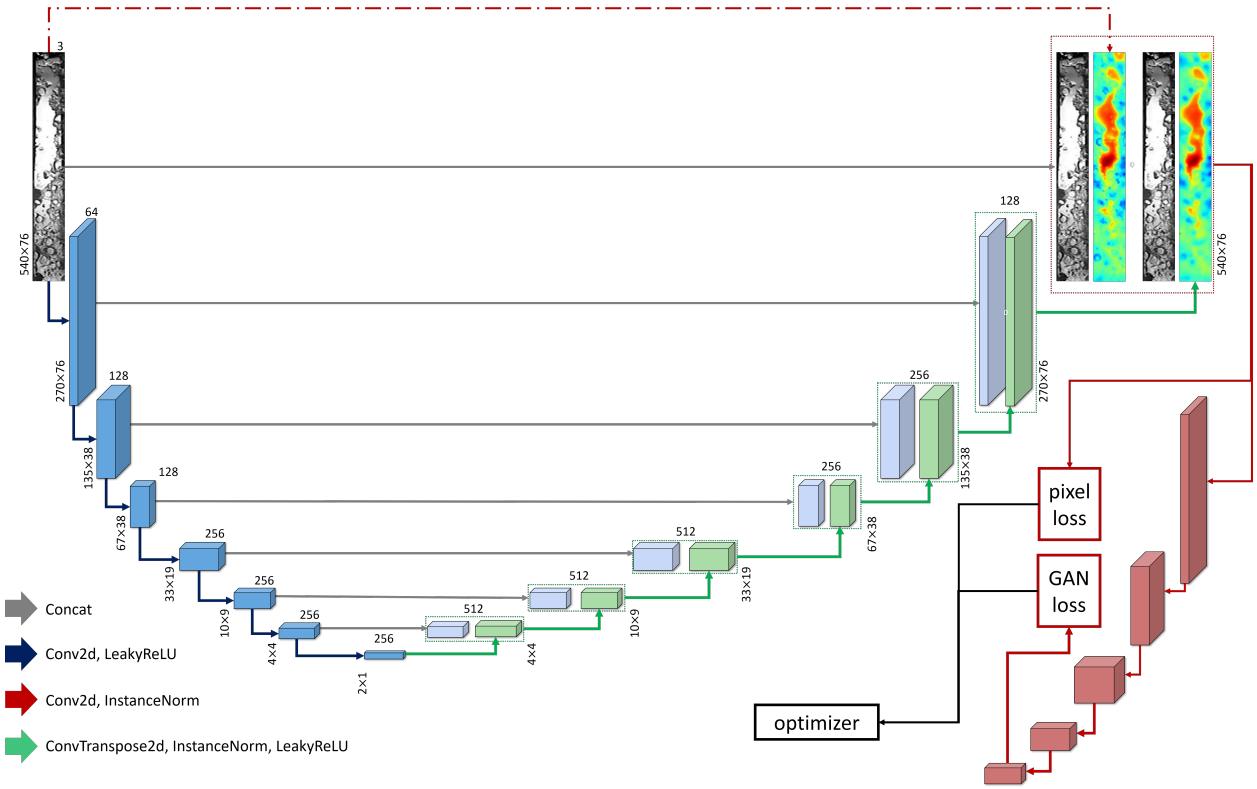

图 2：改进的条件生成对抗网络架构示意图

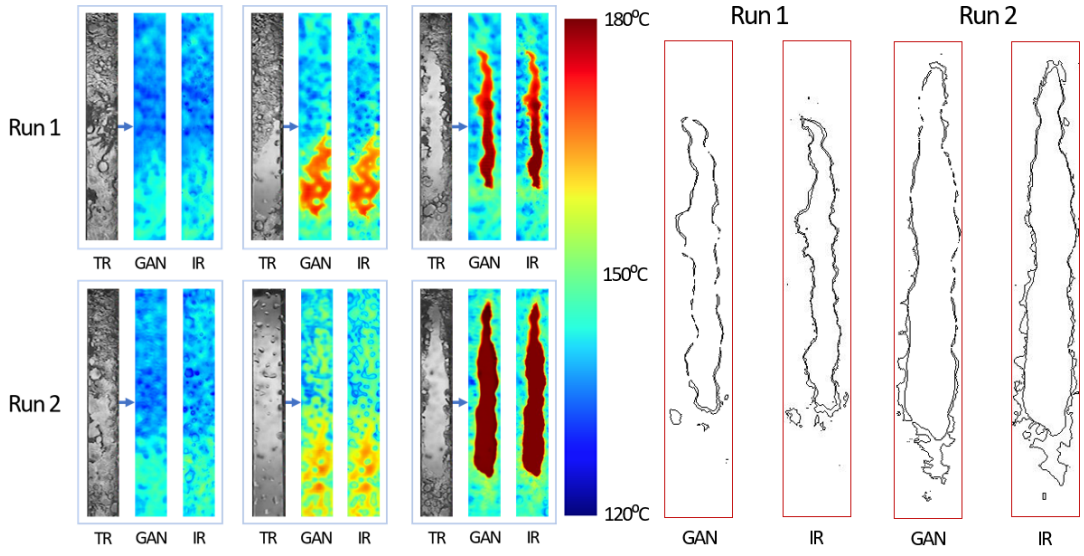

图 3：生成图像和干斑行为的快照

实验运行。尽管运行 1 和运行 2 之间存在差异，本研究的主要目标是学习干斑行为，而这一目标已成功实现。

为量化模型的准确性，采用 PSNR 和 SSIM。PSNR 的计算公式为：

$$PSNR = 10 \cdot \log_{10}\left(\frac{MAX_I^2}{MSE}\right), \quad MSE = \frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N}[I(i,j) - \hat{I}(i,j)]^2 \tag{4}$$

其中，MAX_I为图像的最大像素值，MSE为原始图像 (I) 与重建图像 (I) 之间的均方误差，其中 M 和 N 为图像的尺寸。

SSIM 指标用于衡量两幅图像之间的结构相似性，同时考虑亮度、对比度和结构信息。SSIM 的计算公式如下：[17]。

$$SSIM(I,\hat{I}) = \frac{(2\mu_I\mu_{\hat{I}} + C_1)(2\sigma_{I\hat{I}} + C_2)}{(\mu_I^2 + \mu_{\hat{I}}^2 + C_1)(\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2)} \tag{5}$$

其中 μ_I 和 $\mu_{\hat{I}}$ 分别为原始图像和重建图像的均值；σ_I^2 和 $\sigma_{\hat{I}}^2$ 分别为二者的方差；$\sigma_{I\hat{I}}$ 为原始图像与重建图像之间的协方差；且 $C_1 = (k_1 L)^2$ 和 $C_2 = (k_2 L)^2$，其中 L 为 255，且 $k_1 = 0.01$和 $k_2 = 0.03$。

各次运行的 SSIM 和 PSNR 值如下：

	运行 1	运行 2
PSNR	23.73	22.49
SSIM	0.7476	0.7277

表 1：Run 1 和 Run 2 的平均 PSNR 和 SSIM 对比

3.2 温度场演化

对 Run1 和 Run2 的输出层数据的温度场演化进行了分析。通过重建所用色条的查找表，将图像转换为温度值，从而对模型性能进行定量评估。图 4 展示了平均温度和最高温度的变化趋势。

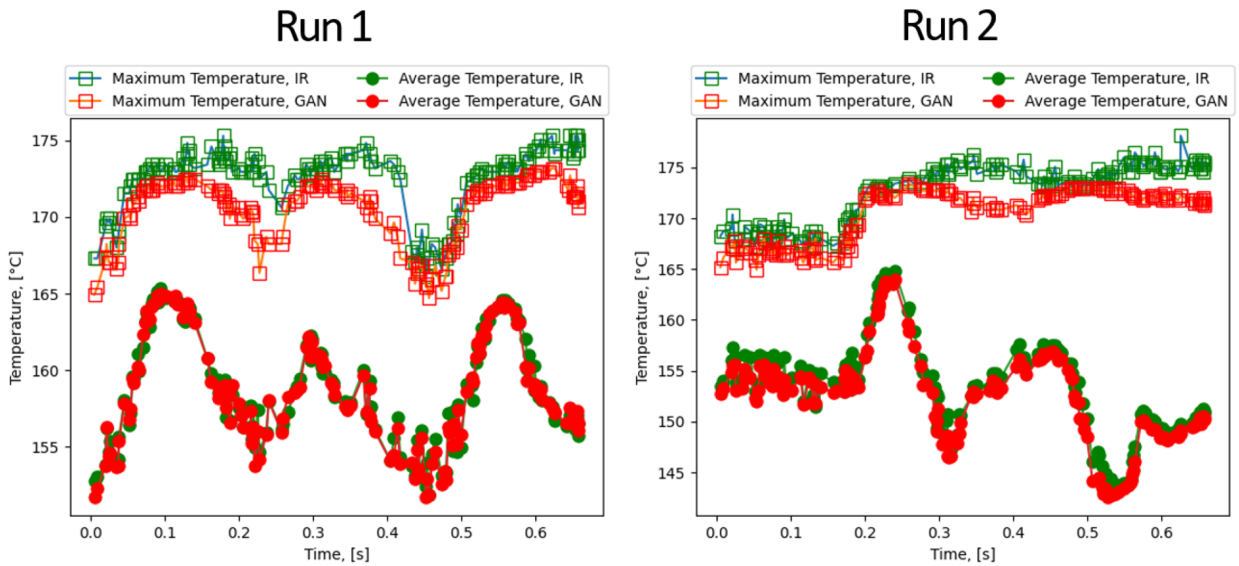

图 4：生成数据中的温度场演化

从温度场演化中观察到的首个显著现象是，对于两次运行，模型预测的平均温度值与实际值均吻合良好。这表明模型能够捕捉温度场的整体趋势和模式。对平均

温度的准确估算可归功于 U-Net 架构的应用。该架构使模型能够通过跳跃连接保留空间信息，从而增强其预测能力。此外，对于 Run1 和 Run2，最高温度的预测值分别低估了 3.5% 和 3.3%。这种低估可能源于模型捕捉极端值或局部现象的能力有限，而这可能受到架构选择、超参数或训练数据等因素的影响。尽管存在这种低估，考虑到问题的复杂性，模型仍能合理近似温度场演化，这一点值得肯定。

3.3 潜变量的主成分分析

虽然前几节展示了输出层的结果，但要研究生成器最深处（即编码器部分之后），还需要采用另一种方法。编码器实际上将信息压缩到 $z_i \in \mathbb{R}^{256\times1\times2}$维。为进一步分析这种潜在表示，我们对编码数据进行了主成分分析，并将其与温度演变一同展示；两者均使用最小-最大缩放归一化至 [-1, 1]范围内。

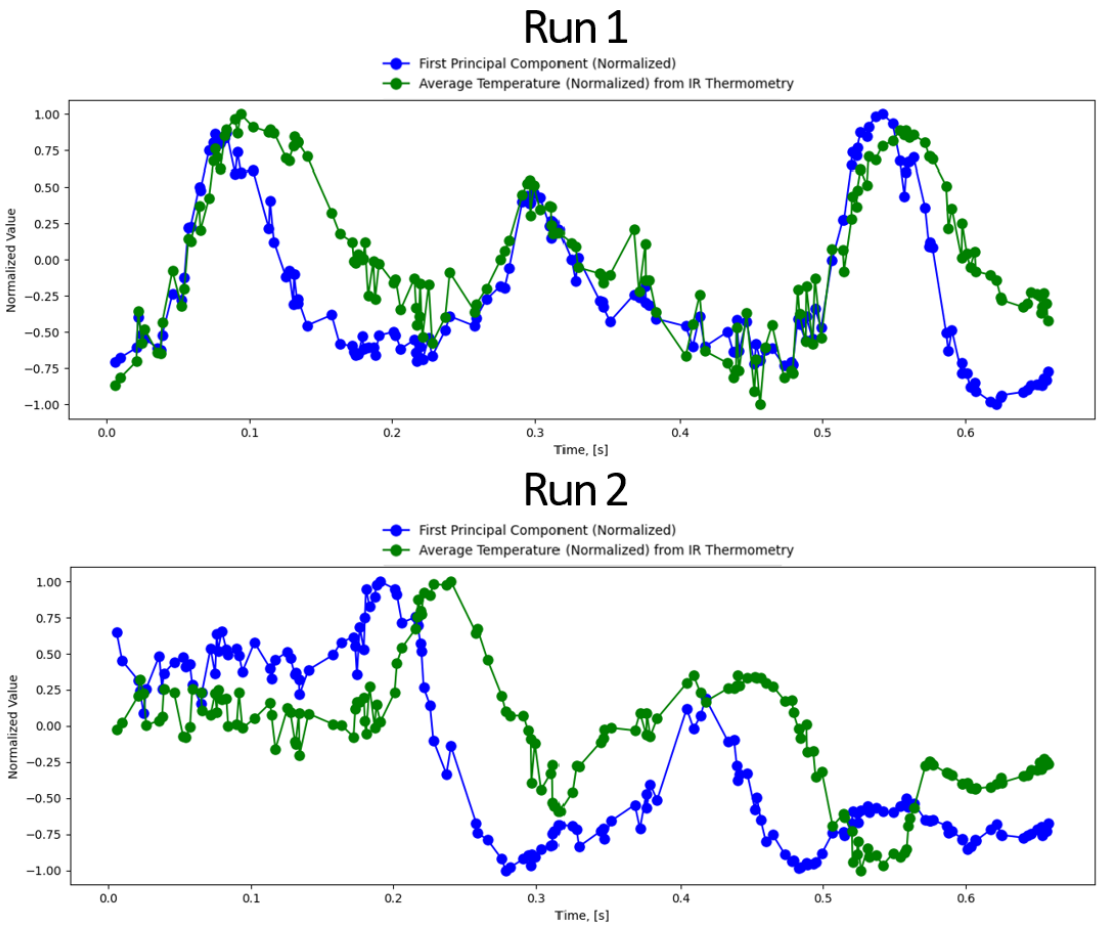

图 5：第一个主成分和平均温度

通过主成分分析（PCA），获得了最具代表性的第一主成分。该成分的变化趋势与实验数据的平均温度相似。比较运行 1 和运行 2 后发现，运行 1 更清楚地展现了第一主成分与平均温度变化趋势之间的相似性。这一观察有力地表明，作为神经网络学习层中最关键的要素，平均温度不仅可以从输出层识别出来，也可以从生成器的潜在空间中识别出来。利用这一信息，可以考察模型针对实验数据的学习表示。

4 讨论与结论

本研究提出了一种采用条件生成对抗网络、基于数据驱动的图像到图像转换方法进行临界热流诊断的新方法。该方法有望简化温度场生成过程，大幅提高从大型实验数据集中提取有价值信息以及在红外热成像中进行预测的效率。温度场演化结果表明，基于 U-Net 的生成模型能够较好地估算平均温度，但在预测最高温度值方面仍面临挑战。此外，通过对编码数据进行主成分分析，我们探索了生成器最深层的部分，发现作为神经网络学习层中最关键的要素，平均温度不仅可以从输出层识别和分析，也可以从生成器的各个潜在空间中识别和分析。这些发现揭示了该模型的优势与挑战。值得注意的是，该模型使用成对的输入和输出图像样本进行训练，输出图像的质量取决于输入图像的质量以及条件生成对抗网络学习两者映射关系的能力。如果输入图像质量较低，或无法代表数据分布，条件生成对抗网络可能会生成质量欠佳的输出，无法准确反映输入与输出之间的内在关系。未来的工作可以着重提高模型对极端温度值的诊断精度，例如加入更多特征或优化模型参数。

致谢

本研究由韩国水力与核电公司和地方政府（浦项）资助。（2023）

参考文献

[1] J. Weisman 和 B. S. Pei. 低含汽率下流动沸腾临界热流的预测。国际传热传质杂志，26(10):1463–1477，1983年。[2] Y. Haramura 和 Y. Katto. 一种新的临界热流流体动力学模型，广泛适用于饱和液体中浸没物体的池沸腾和强制对流沸腾。国际传热传质杂志，26(3):389–399，1983年。[3] C. H. Lee 和 I. Mudawwar. 基于局部主体流动条件的过冷流动沸腾临界热流机理模型。国际多相流杂志，14(6):711–728，1988年。[4] J. E. Galloway 和 I. Mudawar. 短加热壁面流动沸腾中的临界热流机制——II. 理论临界热流模型。国际传热传质杂志，36(10):2527–2540，1993年。[5] G. Liang 和 I. Mudawar. 池沸腾临界热流（CHF）——第1部分：机理、模型和关联式综述。国际传热传质杂志，117:1352–1367，2018年。[6] Byongug Jeon、Moonhee Choi、Donghyun Kam、YoungJun Youn 和 Sang-Ki Moon. 使用光学可视化和红外测温观测流动条件下核态沸腾的偏离。国际传热传质杂志，185:122417，2022年。[7] I. C. Chu、H. C. No、C. H. Song 和 D. J. Euh. 饱和水水平池沸腾临界热流机理的观测。核工程与设计，279:189–199，2014年。[8] S. H. Kim、I. C. Chu、M. H. Choi 和 D. J. Euh. 强制对流通道流动沸腾中核态沸腾偏离机理研究。国际传热传质杂志，126:1049–1058，2018年。[9] Shigeaki Nishio、Toshiaki Gotoh 和 Noriaki Nagai. 高热流沸腾中沸腾结构的观测。国际传热传质杂志，41:3191–3201，1998年。[10] Matteo Bucci、Andrew Richenderfer、Guan-Yuan Su、Thomas McKrell 和 Jacopo Buongiorno. 用于沸腾传热研究的机理性红外标定技术。国际多相流杂志，83:115–127，2016年。[11] M. Choi、I. C. Chu、S. Kim、B. Jeon 和 H. Jo. 不同过冷流动条件下临界热流再润湿失效机理的直接观测。国际传热传质杂志，163:120465，2020年。[12] Moonhee Choi. 流动沸腾中不可逆干斑机理的观测研究。博士论文，博士学位论文，2021年。[13] A. Krizhevsky、I. Sutskever 和 G. E. Hinton. 使用深度卷积神经网络进行ImageNet分类。*ACM*通讯，60(6):84–90，2017年。[14] I. Goodfellow、J. Pouget-Abadie、M. Mirza、B. Xu、D. Warde-Farley、S. Ozair 和 Y. Bengio. 生成对抗网络。*ACM*通讯，63(11):139–144，2020年。

[15] A. Radford、L. Metz 和 S. Chintala. 使用深度卷积生成对抗网络进行无监督表征学习。*arXiv*预印本 *arXiv:1511.06434*，2015年。[16] P. Isola、J. Y. Zhu、T. Zhou 和 A. A. Efros. 使用条件对抗网络进行图像到图像转换。载于*IEEE*计算机视觉与模式识别会议论文集，第1125–1134页，2017年。[17] Zhou Wang、Alan C. Bovik、Hamid R. Sheikh 和 Eero P. Simoncelli. 图像质量评估：从误差可见性到结构相似性。*IEEE*图像处理汇刊，13:600–612，2004年。[18] O. Ronneberger、P. Fischer 和 T. Brox. U-Net：用于生物医学图像分割的卷积网络。载于医学图像计算与计算机辅助干预——*MICCAI 2015*：第*18*届国际会议，慕尼黑，德国，*2015*年*10*月*5*日至*9*日，论文集，第三部分，第234–241页。Springer国际出版公司，2015年。

Su补充材料：改进的条件生成对抗网络架构的实现

生成器

生成器架构的前向传播包括依次将输入传递至各个下采样层，再传递至相应的上采样层，并在下采样层与上采样层之间设置跳跃连接，以保留空间信息 [18]。生成器的输出由最后一个顺序层生成，该层应用 Tanh 激活函数，确保生成图像的像素值介于 -1 到 1 之间。具体设计参数如下，包括通道数、卷积核大小、步幅、填充、归一化和丢弃率。

编码路径由七个下采样层组成，并采用二维实例归一化。每层之后均接一个阈值为 0.2 的 LeakyReLU。

层	输入通道	输出通道	卷积核大小	步幅	填充	归一化	丢弃率
1	3	64	(4, 3)	(2, 1)	0	No	-
2	64	128	(4, 4)	(2, 2)	1	Yes	-
3	128	128	(5, 3)	(2, 1)	1	Yes	-
4	128	256	(5, 4)	(2, 2)	1	Yes	0.5
5	256	256	(6, 3)	(3, 2)	0	Yes	0.5
6	256	256	(4, 3)	(2, 2)	0	Yes	0.5
7	256	256	(3, 4)	(1, 1)	0	No	0.5

解码路径由六个上采样层和一个最终的顺序层组成，均由二维转置卷积构成。每一层后面都接一个二维实例归一化层和一个阈值为 0.2 的 LeakyReLU。

层	输入通道	输出通道	卷积核大小	步幅	填充	丢弃率
1	256	256	(3, 4)	(1, 1)	0	0.5
2	512	256	(4, 3)	(2, 2)	0	0.5
3	512	256	(6, 3)	(3, 2)	0	0.5
4	512	128	(5, 4)	(2, 2)	1	0.5
5	256	128	(5, 3)	(2, 1)	0	-
6	256	64	(4, 4)	(2, 2)	1	-
7	128	3	(4, 3)	(2, 1)	1	-

判别器

判别器架构由四个判别器块层和一个卷积层组成，用于从生成图像中提取特征并降低其空间维度。每个块层后接一个阈值为 0.2 的 LeakyReLU。判别器的结构如下表所示：

层	输入通道	输出通道	卷积核大小	步幅	填充
1	3×2	64	(4, 3)	(2, 1)	1
2	64	128	(4, 4)	(2, 2)	1
3	128	256	(5, 3)	(2, 1)	1
4	256	512	(5, 4)	(2, 2)	1
5	512	1	(6, 3)	(3, 2)	0

在判别器的前向传播过程中，输入图像和生成图像沿通道维度进行拼接。拼接后的图像随后依次通过各个块层。对 patch 层的输出应用 sigmoid 激活函数，得到介于 0 和 1 之间的概率，从而生成概率图，指示输入图像是真实图像还是生成图像。