

模糊决策在流体不稳定性中的应用：自动编码器重建 结合规则基础异常分类

Bharadwaj Dogga¹[0009-0002-5915-1367], Gibin Raju²[0000-0003-2559-6931], Wilhelm Louw³[0009-0009-8683-1932], and Kelly Cohen⁴[0000-0002-8655-1465]

¹ Ph.D. Student, AI Bio Lab, Digital Futures, University of Cincinnati,
Cincinnati, OH 45221, USA e-mail: doggabj@mail.uc.edu

² Postdoctoral Researcher, Department of Multidisciplinary Engineering, TA&M University,
College Station, TX 77843, USA e-mail: gbinraju@tamu.edu

³ Research Associate AI Bio Lab, Digital Futures, University of Cincinnati,
Cincinnati, OH 45221, USA e-mail: louw@ucmail.uc.edu

⁴ Director AI Bio Lab, Digital Futures, University of Cincinnati,
Cincinnati, OH 45221, USA e-mail: cohenky@ucmail.uc.edu

摘要 激波分类在阴影图成像中具有挑战性，由于标记数据有限且流结构复杂。本研究提出了一种结合无监督自动编码器模型与模糊推理系统的混合框架，用于生成和解释异常地图。在评估的方法中，带有模糊规则系统的混合 β -VAE 自动编码器最有效地捕捉到了连贯的激波特征，并通过整合空间上下文来增强异常分类。该方法使得流中断的可解释无监督分类成为可能，并为实验和工业流体应用中的实时物理信息诊断奠定了基础。

Keywords: 混合模糊系统 · 异常分类 · 流体诊断

1 介绍和相关工作

阴影图和谢勒成像中的图像分类在研究不稳定可压缩流、边界层相互作用和动态流体现象中起着关键作用，特别是在高速空气动力学和工业诊断 [2] 中。传统图像处理方法通常依赖于边缘检测技术——如 Canny、隔离森林或 Sobel——从实验可视化中提取激波特征 [1][7][6]。虽然在理想条件下有效，这些方法需要仔细的预处理，对阈值选择敏感，并且经常在有噪声或复杂的激波几何结构下表现不佳。为了解决这些问题，最近的研究探索了提高鲁棒性和泛化性的深度学习方法。例如，卷积神经网络（CNN）已经被训练用于从原始阴影图图像中直接识别激波区域，在非结构化的设置中表现出色 [5]。同时，使用自编码器的无监督学习方法，特别是变分自编码器

(VAE), 通过建模数据分布并通过重构误差标记偏差在异常检测方面显示出潜力——有效跨越工业检查和医学成像等领域 [4]。尽管有这些进步, 深度模型为分类异常类型或严重程度提供的支持有限, 这对于基于物理系统的系统来说是至关重要的, 其中决策依赖于可解释的输出。结合神经网络与模糊逻辑的混合模型已被提出以填补这一空白, 在视频监控和不确定性感知的异常检测中尤为如此 [3]。这些系统提供了类似人类的决策规则, 但很少被应用于物理分类任务。为克服这些限制, 本研究提出了一种将自编码器变体与模糊推理系统集成的混合框架, 以增强流体阴影图图像中的异常分类。目标是实现对流体诊断中激波相关结构的无监督、可解释的分类。这种方法为压缩流动中的自动编码器误差解释贡献了模糊推理的新应用, 通过针对性规则设计实现了无需地面真实标签的无监督激波概率分类。

2 方法论

所提出的混合框架集成了基于图像的自编码器与 Mamdani 样式的模糊推理系统 (FIS), 以实现阴影图图像中冲击异常的无监督检测和分类。自编码器重构输入图像, 而 FIS 评估重构和空间误差, 将检测到的异常分类为具有物理可解释性的冲击概率。

2.1 自动编码器架构和图像质量度量

本研究评估了两种无监督自编码器模型: 去噪自编码器 (DAE) 和 β -变分自编码器 (β -VAE)。这两种模型均被训练以重建灰度阴影图图像, 目标是通过重构误差来识别流动异常。为了评估性能, 计算了三个图像质量指标: 均方误差 (MSE)、结构相似性指数测量 (SSIM) 和误差图的香农熵。MSE 量化了原始图像与重构图像之间的平均像素差异, 而 SSIM 考虑了亮度、对比度和结构, 提供了感知相似性的衡量标准。熵捕捉了重构误差的空间复杂性, 作为异常分散的一个代理指标。这些指标共同为模型保真度和异常定位提供了定量见解。

2.2 误差图计算与模糊规则系统

尽管前面描述的重建指标为比较模型性能提供了定量基础, 但仍需要额外的参数来在空间上解析和分类阴影图图像中的异常。这些参数定义如下:

1. 像素误差：这定义为重建图像与输入图像在像素处按最大值归一化的绝对误差值
2. 邻域误差：上述像素误差值首先使用最小-最大规范化技术进行标准化，然后使用大小为 $kernel_size = 5$ 的均匀滤波器进行空间平均。

Algorithm 1 模糊推理系统用于异常分类

1: 定义输入变量和隶属函数：

像素误差 ($pixel_err$) 具有定义域 $[0, 1]$:

$$\mu_{low}(x) = \text{trimf}(x; 0, 0, 0.3)$$

$$\mu_{medium}(x) = \text{trimf}(x; 0.2, 0.5, 0.8)$$

$$\mu_{high}(x) = \text{trimf}(x; 0.7, 1, 1)$$

邻域误差 ($neigh_err$) 具有定义域 $[0, 1]$:

$$\mu_{low}(x) = \text{trimf}(x; 0, 0, 0.3)$$

$$\mu_{medium}(x) = \text{trimf}(x; 0.2, 0.5, 0.8)$$

$$\mu_{high}(x) = \text{trimf}(x; 0.7, 1, 1)$$

2: 定义输出变量和隶属函数：

异常 ($anomaly$) 具有定义域 $[0, 1]$:

$$\mu_{none}(x) = \text{trimf}(x; 0, 0, 0.3)$$

$$\mu_{strong}(x) = \text{trimf}(x; 0.2, 0.5, 0.8)$$

$$\mu_{possible}(x) = \text{trimf}(x; 0.7, 1, 1)$$

3: 模糊规则：

1. 如果 $pixel_err$ 是高并且 $neigh_err$ 是高，那么 $anomaly$ 是强。
 2. 如果 $pixel_err$ 是介质并且 $neigh_err$ 是介质，那么 $anomaly$ 是可能的。
 3. 如果 $pixel_err$ 是高并且 $neigh_err$ 是低，那么 $anomaly$ 是可能。
 4. 如果 $pixel_err$ 是低并且 $neigh_err$ 是高，那么 $anomaly$ 是可能的。
 5. 如果 $pixel_err$ 是低并且 $neigh_err$ 是低，那么 $anomaly$ 是无。
-

使用两种类型的错误，采用三角隶属函数实现了一个 Mamdani 型模糊系统，如算法 1 中所述。在此公式中，较高的异常可能性被分配给中间误差值（例如，0.2 – 0.8），这反映了结构化偏差区域而不是极端噪声或完美重建。

3 实验设置

实验在辛辛那提大学的加热喷气噪声设施中进行，使用了跨越 15 种流动条件的 15,000 帧 [8]。干燥空气从储罐调节后供应到圆形喷嘴，喷嘴压力比为 3.6，温度比为 1.0。高速阴影成像采用 Z 型设置，配备了 12 英寸抛物面镜、ORIEL 紫外线光源和 Phantom v1610/v1210 相机，每轮捕捉 1000 帧，以 25,000 fps 的速度拍摄，并具有 $1.5\text{-}2.0\mu\text{s}$ 曝光。然后将随机图像部分导入作为框架的测试平台。




图 1: 测试段阴影图中的各种激波现象

4 结果与讨论

本节展示了使用经典基线方法以及第 2 节所述的所提出的自编码器-模糊混合框架对冲击异常分类进行定量和定性评估。

为了定量基准测试基于自动编码器的方法，我们评估了三种传统方法：Canny 边缘检测、孤立森林和 Sobel 梯度幅度。如表 1 所示，所有基线模型的均方误差较高，结构相似性指数较低，相比之下深度学习模型表现更好。Canny 和孤立森林容易过度敏感并且缺乏全局上下文，而 Sobel 提供了更平滑的梯度但语义意识有限。它们缺乏连续性和上下文推理强调了需要一种结合自动编码器和模糊逻辑的更为稳健的混合方法。

4.1 自动编码器模型性能和 FIS 后处理

深度学习方法在异常定位和图像结构保留方面表现出显著更好的效果。去噪自动编码器 (DAE) 在所有指标上都取得了平衡的结果，而 β -变分自编码器 (β -VAE) 记录了最佳的 SSIM (0.1676) 和最高的熵 (10.3085)，捕捉到了与冲击区域相关的广泛结构异常。尽管在 SSIM 上稍逊一筹，但 DAE 在误差集中方面得益于空间锐度的优势。这些结果验证了自编码器在捕获流体异常方面的实用性，其准确性超过了手工制作的特征。

方法	均方误差	结构相似性指数	熵
Canny Edge Detection	0.2722	0.0833	6.7004
Isolation Forest	0.2830	0.0833	7.7785
Sobel Gradient Magnitude	0.2499	0.1332	9.9844
Denoising AE	0.2579	0.0791	10.0010
β -Variational AE	0.2241	0.1676	10.3085

表 1: 异常检测方法的定量评估

图 2 定性比较了五种通过误差映射进行激波检测的方法。经典方法如 Canny 和 Isolation Forest 产生的输出要么是破碎的，要么是过度饱和的，而 Sobel 则提供更平滑的梯度，但缺乏语义过滤。相比之下，DAE 定位到与激波对齐的尖锐、狭窄异常，而 β -VAE 捕捉到更广泛且连贯的结构。这些自编码器映射为下游分类提供了更可靠的基础。




图 2: 误差图，从左到右：Canny，Isolation Forest，Sobel，DAE， β -VAE

为了利用这些增强的误差表示进行基于区域的分类，应用了模糊推理系统（FIS）到 AE 误差图上。这些结果如图 3 所示。DAE 的模糊图明显隔离了与流场中高曲率点相匹配的尖锐、离散异常。然而， β -VAE 模糊图则在整个激波柱上平滑延伸，并具有高的异常置信度（ > 0.7 ），以更高的物理一致性对激波区域进行分类。




图 3: 模糊规则基础冲击异常图，从左到右：DAE， β -VAE。

模糊增强的异常地图揭示了模型行为的不同之处。DAE 识别出与个别冲击对齐的尖锐、局部破坏，但容易因背景噪声而产生误报。相比之下， β -VAE 提供了更平滑、连贯的异常场，这些异常场与完整的冲击结构紧密对齐。模糊推理系统有效地整合了空间和重建误差，抑制噪声并突出主要特征，且无需标注数据。这使得 β -VAE 混合方法非常适合用于流体流动诊断中的无监督异常分类。

未来的工作将重点放在提高计算效率和减少时间成本上。模糊系统可以通过微调隶属函数或采用 Sugeno 推理来进一步优化，以实现实时执行。基于 Transformer 的架构可能为复杂的流场提供更强大的特征提取能力。此外，结合湍流建模和流体条件来增强 FIS 参数调整将提高对复杂激波-湍流相互作用的分类准确性。

5 结论

本研究提出了一种结合无监督自动编码器与模糊推理系统的混合框架，用于流体阴影图像中的异常分类。在评估的模型中， β -VAE 在捕捉连贯激波结构方面表现出最佳性能，相较于标准基准方法和去噪 AE 变体。模糊规则

系统通过将空间上下文纳入异常评分过程中，提高了可解释性。这些组件共同实现了无需标记数据的无监督且具有物理意义的异常分类，使其非常适合实验流体诊断。该框架为复杂流动现象的实时、基于物理知识的分析奠定了基础。

Disclosure of Interests. 作者声明与本文内容无关的任何利益冲突。

参考文献

1. Zheng, L., Lawlor, B., Katko, B., McGuire, C., Zanteson, J. & Eliasson, V. Image processing and edge detection techniques to quantify shock wave dynamics experiments. *Exp. Tech.* **45**, 483-495 (2021,8)
2. Maharjan, S., Bjerketvedt, D. & Lysaker, O. Processing of high-speed videos of shock wave boundary layer interactions. *Signal Image Video Process.* **15**, 607-615 (2021,4)
3. Muhammad, K., Obaidat, M., Hussain, T., Ser, J., Kumar, N., Tanveer, M. & Doctor, F. Fuzzy logic in surveillance Big Video Data analysis. *ACM Comput. Surv.* **54**, 1-33 (2022,4)
4. Baur, C., Denner, S., Wiestler, B., Navab, N. & Albarqouni, S. Autoencoders for unsupervised anomaly segmentation in brain MR images: A comparative study. *Med. Image Anal.* **69**, 101952 (2021,4)
5. Liu, J., Xie, G., Wang, J., Li, S., Wang, C., Zheng, F. & Jin, Y. Deep industrial image anomaly detection: A survey. *Mach. Intell. Res.* **21**, 104-135 (2024,2)
6. Znamenskaya, I., Doroshchenko, I. & Tatarenkova, D. Edge detection and machine learning approach to identify flow structures on schlieren and shadowgraph images. *Proceedings Of The 30th International Conference On Computer Graphics And Machine Vision (GraphiCon 2020). Part 2*. pp. aper15-1 – paper15 – 14 (2020,12)
7. Li, G., Kontis, K. & Fan, Z. Automatic shock detection, extraction, and fitting in schlieren and shadowgraph visualization. *AIAA J.* **59**, 2312-2317 (2021,6)
8. Raju, G., Baier, F., Mora, P. & Gutmark, E. Shock-cell spacing analysis in heated jets using shadowgraph technique. *Conference: International Conference on Jets, Wakes and Separated Flows*. (2017,10)