

# 하나로 원자로 노심에서의 딥러닝을 이용한 이미지 기반 이상검출

김민중, 신진원, 유용균\*

한국원자력연구원

kmj21@kaeri.re.kr, jwshin@kaeri.re.kr, \*ygyu@kaeri.re.kr

## Image-based Anomaly Detection using Deep Learning in the HANARO Reactor Core

Minjong Kim, Jin-Won Shin, Younggyun Yu

Korea Atomic Energy Research Institute

\* Corresponding author

### 요약

본 논문의 목적은 딥러닝을 활용한 시각적 모니터링 시스템을 통한 하나로 원자로의 심층방어 강화에 관한 연구이다. 특히, 원자로 노심 수조 안에서 기포발생 이상 현상을 검출하기 위해 크게 두 가지로 나누어 연구하였다. 첫째, 딥러닝 모델에 학습시키기 위해 가상의 합성데이터셋을 생성하였다. 원자로 노심 수조 내 기포는 다양한 크기와 투명도에 따라서 형상이 달라지기 때문에 이를 고려한 파라미터 설정을 통해 데이터셋을 구축하였다. 둘째, 딥러닝을 활용한 기포검출 알고리즘을 위해 Faster R-CNN 모델을 최적화시켰다. 기포 데이터셋의 최적화된 특징벡터를 추출하기 위해 모델의 파라미터 조절과 Feature Pyramid Network (FPN)을 적용하였다. 기포탐지 모델의 정확도는 검증용, 테스트 데이터셋에서 각각 85.3, 78.1 mAP 결과를 얻었으며, 테스트셋은 하나로 원자로 점검 기간에 생성된 기포 이미지를 활용하였다. 이를 통해 이미지 기반 이상 검출에 대한 원자로 심층방어 강화에 기여할 것으로 기대된다.

### I. 서론

하나로는 국내 유일의 고성능 중성자 이용시설로 첨단 소재 산업에 기여도가 높은 우리나라에 중요한 다목적 연구용 원자로이다. 일본의 후쿠시마 원전사고 이후, 원자력발전을 운영하는 국가들은 원전안전운동을 위한 더 높은 기준을 요구하고 있다. 하나로도 안전한 원자로 운영을 위해 인공지능을 활용한 심층방어(Defense in Depth) 강화 연구를 하고 있다. 특히, 원자로 노심에 대한 시각적 모니터링 시스템을 통해서 하나로 운영자의 오류와 피로를 줄이고 비정상적인 작동 감지에 대한 딥러닝 모델 개발이 이루어지고 있다. 이를 통해 원자로 제어봉의 운전 및 유지 보수에 의해 발생할 수 있는 원자로 노심 수조의 기포발생에 대해 신속하고 정확하게 대응할 수 있는 시스템을 기대할 수 있게 되었다. 이 논문의 기여도는 다음과 같다. 첫째, 이미지 기반 딥러닝 모델에 학습시키기 위한 기포 합성 데이터셋을 구축하였다. 둘째, 원자로 노심에서의 이미지 기반 이상 검출을 위한 딥러닝 모델을 개발하였다. 논문의 나머지 부분은 다음과 같이 구성되어 있다. 먼저 II에서 제안된 가상의 합성데이터셋을 설명하였고, III에서는 기포탐지를 위해 적용한 딥러닝 모델의 최적화된 파라미터를 제시하였다. 딥러닝 모델의 성능평가는 IV에서 이루어지며, 마지막으로 V에서 결론과 향후 작업에 관해 설명하였다.

### II. 데이터셋

원자로 노심 수조 안에서 기포가 생성되는 현상은 일반적이지 않기 때문에 딥러닝 모델 학습을 위한 비정상 데이터를 수집하기 어렵다. 그래서 정상 이미지에 가상의 기포 이미지를 합성하여 비정상 데이터셋을 구성하였



그림 1. 가상의 합성 데이터셋을 활용한 기포 이미지

다. 실제 원자로 노심 수조 안에서의 기포는 투명성이 포함된 다양한 크기로 이루어지기 때문에 이를 고려하여 그림 1을 기반으로 다양한 크기, 위치, 각도 및 투명도를 통해 2천 개의 가상 데이터셋을 생성하였다.

### III. Faster R-CNN을 활용한 기포탐지

딥러닝 모델은 2단계 대상 검출인 Faster R-CNN [1] 알고리즘을 적용하였다. Faster R-CNN 알고리즘은 크게 특징추출, 영역제한, ROI Head 세 부분으로 그림 2를 통해 전체 구조를 확인할 수 있다.

특징추출은 ImageNet-1K를 통해 학습된 ResNet-101 백본 네트워크를 사용하였다. ResNet [2]은 여러 개의 residual block을 쌓아 구축된다. 각 Residual block은 하나 이상의 레이어를 건너뛰고 이전 레이어의 출력을 다음 레이어에 추가하여 학습하게 된다. 이를 통해 깊은 네트워크 학습을 할 때 기울기 값이 사라지는 vanishing gradient problem과 학습속도를 개선시킬 수 있다. 또한, 다양한 기포 크기 검출을 위해 Feature Pyramid Network (FPN)을 적용하였다. [3]. ResNet-101의 각 단계에서 나온 1/4, 1/8, 1/16, 및 1/32 해상도 크기의 특징 벡터를 측면연결과 하향식 방법을

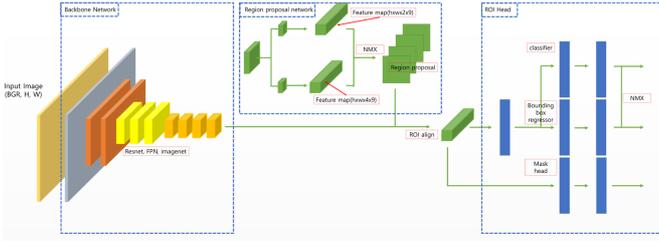


그림 2. 기포탐지 딥러닝 모델 구조도

통해 연결한다. 이를 통해 다양한 기포 크기를 고려한 객체 검출이 가능하게 되었다. 영역제한은 ResNet-101에서 뽑아낸 feature map 위에서  $N \times N$  window를 sliding window로 적용했다. 이 창의 anchor size는 이미지에서의 기포 크기를 고려한 32, 64, 128, 256 및 512로 하였고 aspect ratio는 0.5, 1.0 및 2.0으로 하였다. 이를 통해 anchor의 위치와 기포 유무에 따라 수많은 region proposal이 생성되며 Faster R-CNN의 영역제한 손실함수인 수식 (1)을 통해 계산된다. 여기서  $i$ 는 미니배치에서의 anchor 인덱스를 나타내며  $p_i$ 는 anchor가 기포 객체의 확률이다.  $p_i^*$ 는 ground truth를 나타내며 1이면 기포객체, 0이면 배경을 나타낸다.  $t_i$ 는 예측되는 기포 box의 4개 좌표를 말하며,  $t_i^*$ 는 예측되는 기포 box의 ground truth 값이다.

$$L(p_i, t_i) = \frac{1}{N_{ds}} \sum_i L_{ds}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

이후 Non Maximum Suppression (NMS)을 통해 confidence score가 높은 상위 1000개의 region proposal을 추출하게 된다. ROI Head에서는 Feature Pyramid Network에서 나온 각 기포 특징맵의 region proposal에 대해 ROIAlign을 적용한다. 이후 feature map을 flatten 시키고 fully connected layer들을 거쳐 기포 객체 분류와 위치를 학습시켜 딥러닝 모델을 만들게 된다.

#### IV. 실험

기포탐지 알고리즘의 성능 측정을 위해 PASCAL VOC Challenge에서 사용하는 방식을 채택 하였다. Intersection over Union (IoU)은 0.5 이상인 검출은 Positive, 그 이하는 Negative로 판단하며 수식 (2)를 통해 계산 된다. 이를 기반으로 Precision과 Recall은 수식 (3,4)를 통해 계산 후 그래프에 나열하여 선을 그은 후 Average Precision (AP)를 평가하게 된다. 모델은 Faster R-CNN에 Feature Pyramid Network 유무에 따른 모델을 비교하였고 검증용 데이터셋은 500장, 테스트 데이터셋은 300장으로 실험 하였다. 검증용 데이터셋은 가상의 합성데이터셋이며, 테스트용 데이터셋은 원자로 노심 구조안에서의 실제 기포 영상이다. 테스트결과는 표1을 통해 확인할 수 있다. FPN을 적용한 Faster R-CNN이 mAP가 각각, 검증용 데이터셋에서 3.6, 테스트셋에서는 2.9 높은 정확도를 나타내었다.

$$IOU = \frac{\text{area of overlap}}{\text{area of union}}, \quad (2)$$

$$\text{Precision} = \frac{TP}{TP+FP} = \frac{TP}{\text{all detections}}, \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} = \frac{TP}{\text{all ground truths}}. \quad (4)$$

표1. 딥러닝 모델 검증용 및 테스트 데이터셋 결과

Methods	Dataset	Bubble
Faster R-CNN	validation	81.7
Faster R-CNN	test	75.2
Faster R-CNN with FPN	validation	85.3
Faster R-CNN with FPN	test	78.1

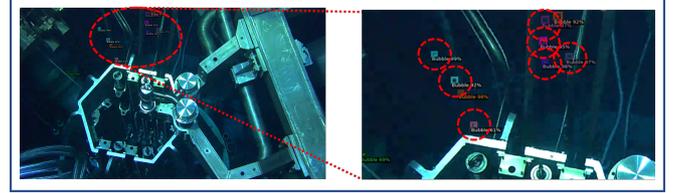


그림 3. 기포탐지 모델 결과 이미지

그림 3을 통해 실제 원자로 노심에서의 기포탐지된 이미지를 확인할 수 있다.

#### V. 결론

본 논문은 원자로 노심 구조 안에서 이미지 기반 이상탐지 알고리즘을 소개하였다. 가상의 합성 데이터셋을 통해 부족한 이상 데이터를 대체하였고 딥러닝 모델에서는 기포검출을 위한 파라미터와 하이퍼파라미터를 최적화시켰다. 향후 연구에서는, 더 많은 합성데이터 세트를 생성하고 더 빠르고 정확도가 높은 알고리즘을 적용하여 하나로 원자로의 심층방어 강화에 도움을 줄 수 있을 것이다.

#### ACKNOWLEDGMENT

본 논문은 한국원자력연구원 주요사업인 “하나로 및 연구시설 운영 지능화 플랫폼 구축”(과제번호: 524450-22)의 일환으로 수행되었습니다.

#### 참고 문헌

- [1] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- [2] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [3] Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).