

가전제품 도어 가스켓 불량검출 f-AnoGAN 학습시 손실 가중치 최적화를 위한 민감도 분석

장성수*¹, 유동휘*², 권재영*³, 이원희**⁴

Sensitivity Analysis of Loss Weight Optimization in f-AnoGAN Training for Defect Detection in Appliance Door Gaskets

Seongsu Jhang*¹, Donghwi Yoo*², Jaeyoung Kwon*³, and Wonhee Lee**⁴

이 논문은 2025년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원(KIAT)의 지원을 받아 수행된 연구임
(No.P0029861, 디지털전환 확산지원체계 구축 사업, 내역사업 : DX 실행모델 개발·적용),
이 연구는 2025년도 산업통상자원부 및 한국산업기술기술평가원(KEIT) 연구비 지원에 의한
연구임(RS-2025-25447560, 가전 제조 산업의 판금 공정에서 AI 기반 밸류체인 협업 기술개발)

요 약

생성형 인공지능의 발전과 제조 산업에서의 AI 도입 확산은 열악한 환경에서도 적용 가능한 고속 비지도 이상 탐지 시스템 수요를 높이고 있다. 특히, 비전 검사 AI 모델은 사람의 오류를 줄이고 속도를 높일 수 있으나, 실제 현장에서는 제품 수명 주기 단축과 다품종 소량 생산으로 인해 불량 데이터 확보와 라벨링에도 한계가 있다. 이에 따라, 정상 데이터만으로 학습 가능한 비지도 방식이 주목받고 있다. 본 연구에서는 실제 가전 부품 제조 공정 현장에서 수집한 고해상도 이미지를 활용해, 대표적 비지도 모델인 f-AnoGAN에 구조적 유사도 지수(SSIM)를 손실함수로 적용하여 실험적으로 검증하였다. 그 결과, 모델 학습 시 SSIM 손실을 적절한 가중치로 Feature Matching 손실과 함께 적용할 경우 이상 탐지 성능이 유의미하게 향상됨을 확인했다.

Abstract

The rise of generative AI and its growing adoption across manufacturing industries have fueled demand for robust unsupervised anomaly detection systems that are well-suited for real-world industrial environments. Vision-based inspection models reduce human error and boost efficiency, but limited defective data due to short product cycles and high-mix, low-volume production makes supervised learning difficult. This study applies f-AnoGAN to high-resolution grayscale images from a home appliance manufacturing site. Unlike previous approaches that use SSIM only for evaluation, we incorporate it as a loss function during training. We then analyze how detection performance varies with SSIM usage, weighting, and window size, providing a quantitative assessment of the trade-offs between anomaly sensitivity and structural robustness. Furthermore, our results confirm that applying SSIM loss with an appropriate weight in combination with Feature Matching loss significantly improves anomaly detection performance.

Keywords

unsupervised anomaly detection, f-AnoGAN, structural similarity index measure, industrial imaging, structural similarity loss, hyperparameter sensitivity analysis

* 한국전자기술연구원(*⁴ 교신저자)

- ORCID¹: <https://orcid.org/0000-0002-9725-7990>

- ORCID²: <https://orcid.org/0000-0003-0244-6914>

- ORCID³: <https://orcid.org/0009-0007-5628-2878>

- ORCID⁴: <https://orcid.org/0009-0006-9762-8583>

• Received: Jul. 25, 2025, Revised: Aug. 08, 2025, Accepted: Aug. 11, 2025

• Corresponding Author: Wonhee Lee

Dept. of Autonomous Manufacturing Research Center, KETI

Tel.: +82-31-759-8126, Email: zsed50@keti.re.kr

1. 서 론

제조 환경에서의 결함 검출은 제품 품질을 보장하고 운영 효율성을 유지하기 위한 핵심 과제이다. 최근 검사 정밀도와 고속, 고효율을 위한 자동화를 위한 검사 자동화 수요 증가에 따라 고해상도 이미징 기반의 비전 검사 기술의 현장 적용성 및 중요도가 크게 부각되고 있다. 하지만 실제 산업 현장에서는 다품종 소량 생산, 짧아진 제품 수명 주기, 다양한 생산 조건 등으로 인해 라벨링된 불량 데이터를 충분히 확보하기 어렵고, 그에 따라 전통적인 룰 기반 및 지도학습 방법론에는 한계가 따른다. 이러한 문제를 해결하기 위해 정상 데이터만을 활용하여 학습하는 비지도 또는 반지도 이상 탐지 기법이 주목받고 있다. 이러한 접근법은 불량 샘플의 확보가 어렵거나 불량 유형의 명확한 정의가 되지 않았을 때 유리하다. 그중에서도 f-AnoGAN은 대표적인 비지도 이상 탐지 모델로, 기존 AnoGAN의 한계를 극복하기 위해 설계된 생성적 적대 신경망(GAN, Generative Adversarial Network) 기반 구조이다. 기존 AnoGAN이 쿼리 이미지에 대한 잠재 공간 최적화를 반복적으로 수행해야 했던 것과 달리, f-AnoGAN은 별도의 인코더를 학습시켜 빠른 추론과 유연한 손실 함수 통합이 가능하게 한다. 최종 이상 점수는 이미지 재구성 오차와 판별기 피쳐 차이(Feature residual)를 결합하여 계산되며, 이는 주석이 제한적인 고해상도 영상(예: 의료 영상)에서의 미세 이상 검출에도 효과적임이 입증되었다[1]. 또한 f-AnoGAN은 실제 제조 환경에서도 빠른 추론 속도, 낮은 연산 요구, 제한된 자원에서도 실용적 이점을 보여주며[2][3], 이는 실시간 결함 탐지가 필요한 산업 응용에 적합함을 알 수 있는 사례이다. 그러나 기존 픽셀 기반 손실 함수는 지역적이거나 구조적인 이상을 잘 포착하지 못하는 경우가 많고, 특히 미세한 결함이 제품 품질과 고객 만족도(감성 공학적)에 큰 영향을 미치는 산업 환경에서는 한계가 있다. 하지만 본 논문에서 제안하는 손실함수로서의 SSIM(Structural Similarity), 피쳐 매칭 손실 및 이와 관련된 하이퍼파라미터 간의 상호작용 등 손실 함수 설계의 영향을 심층적으로 분석한 기존 연구는 드문 실정이다[1]-[5]. 이는 손실 함수 구성 및

파라미터 튜닝이 모델의 견고성과 불량률의 위치 탐지 정확도에 어떤 영향을 미치는지에 대한 연구사례가 부족함을 시사한다.

이러한 연구 공백을 해결하기 위해, 본 연구에서는 실제 가전 부품 생산라인에서 수집된 2448×2048 해상도의 흑백 영상 데이터를 활용하여 사례연구를 수행하였다. 이미지 내 작은 영역에 존재하는 미세 결함을 f-AnoGAN으로 탐지하고, 구조적 유사도 지수(SSIM) 기반의 손실과 피쳐 손실 함수 조합이 모델 성능에 미치는 영향과 경향성을 분석했다. 또한 SSIM 윈도우 크기에 따른 탐지 민감도의 변화도 분석하여, 질감이 풍부한 고해상도 영상에서의 탐지 정밀도를 최적화하고자 하였다.

일부 연구에서는 f-AnoGAN 성능 향상을 위해 피쳐 매칭 손실 가중치를 조정하거나[6], 피쳐 매칭 손실과 재구성 손실을 결합하는 방식으로 정확도를 향상시키고자 시도한 바 있으나[7], 구조적 유사도 지수(SSIM)의 역할을 본격적으로 다룬 연구는 거의 없다. 특히 기존 문헌에서는 SSIM을 평가 지표로만 활용할 뿐, 학습 손실 함수로서 직접 통합한 사례는 드물다[8][10]. 이에 본 연구는 다양한 손실 함수(SSIM, 피쳐 매칭)의 조합 및 하이퍼파라미터 설정이 모델 성능에 어떤 영향을 미치는지를 실험적으로 분석하였다. 또한 본 연구에서는 학습 epoch과 탐지 threshold 변화에 따른 f-AnoGAN 성능의 변화를 2D 히트맵 형태로 시각화하는 새로운 평가 접근법도 도입하였다. 고정된 threshold에만 의존하지 않고, F1-score와 AUC(Area Under the ROC Curve)의 변화 양상을 탐색함으로써 모델 학습 진행 정도와 이상 민감도 간의 관계를 더욱 직관적으로 파악할 수 있었고, 이를 통해 threshold 조정, 조기 종료(Early stopping), 산업 현장 적용 시의 안정적 배포에 대한 실질적인 가이드를 제시하였다. 실험 결과, SSIM 손실 항을 적절한 가중치로 Feature Matching 손실과 함께 적용할 경우 고해상도 산업용 이미지에서의 이상 탐지 성능이 유의미하게 향상됨을 확인하였다. 또한 SSIM 윈도우 크기를 결함 크기와 정합되게 조정할 경우 기존의 통상적 크기(11)뿐만 아니라 더 큰 크기에서도 유사하거나 더 우수한 성능을 구현할 수 있음을 검증하였다.

II. 데이터수집 및 분석방안 설계

본 연구는 실제 산업 환경에서 수집된 고해상도 비전 검사 데이터를 기반으로 실험을 수행하였다. 사용된 데이터셋은 국내 가전제품(냉장고) 도어 가스켓 사출 공정에 설치된 비전 검사 시스템을 통해 확보한 것으로, 해상도 2448×2048 픽셀의 흑백 이미지로 구성되어 있다. 총 400장의 이미지 중 360장은 정상으로, 40장은 가스켓의 변형 또는 압착 등 육안으로 식별 가능한 이상을 포함한 불량 이미지로 분류되었다. 그림 1은 (좌측) 사출 성형 공정 라인으로 검사 대상 제품인 가전 부품 도어 가스켓 검사를 위해 설치된 카메라와 (우측) 검사 시스템 시운전 결과를 나타낸다. 데이터 전처리에는 결함이 주로 발생하는 가스켓 외곽 영역에 집중하기 위해, 각 이미지의 경계 영역을 크롭한 후 1024×1024 픽셀로 리사이징하였다. 학습 샘플의 수가 제한적이라는 점을 고려하여, 모델의 일반화 성능을 향상시키기 위한 데이터 증강 기법을 적용하였다. 특히, 180도 회전과 수평 반전을 적용하여 학습 데이터의 양을 3배로 증가시켰으며, 이를 통해 총 1,200장의 이미지가 학습에 사용되었다. 기존 선행 연구[11][12]를 통하여 이미지의 기하학적 변형을 통한 데이터 증강은 라벨링된 데이터가 부족한 상황에서 모델의 강건성과 분류 정확도를 향상시키는데 효과적임이 입증되었다.




그림 1. 비전 검사장비 설치 및 데이터 수집
Fig. 1. Vision inspection setup and sample image

모델 아키텍처는 생성기(Generator), 판별기(Discriminator), 인코더(Encoder)의 세 구성요소로 이루어져 있다. 생성기는 네 개의 Conv2DTranspose 블

록으로 구성되어, 잠재 공간의 벡터를 점진적으로 업샘플링하여 원본 해상도의 이미지를 생성한다. 판별기 또한 네 개의 컨볼루션 블록으로 구성되며, 최종 출력뿐 아니라 중간 feature map도 반환하여 feature matching loss 계산에 사용된다. 인코더는 생성기와 유사한 구조를 가지며 입력 이미지를 잠재 공간으로 직접 투영하여 이상 점수 계산 속도를 크게 향상시킨다. 세 구성 요소는 독립적으로 학습되며 동일한 하이퍼파라미터 설정을 공유한다.

전체 손실 함수는 세 가지 성분(픽셀 기반 재구성 오차(L1), feature matching, SSIM)으로 구성되지만, 본 연구에서는 feature matching loss와 SSIM loss의 가중치만을 조정 대상으로 하였고, L1 loss의 가중치는 고정하였다. 이는 L1 손실이 이미지 생성의 기본적인 정합성을 보장하는 역할을 하며, 그 비중을 과도하게 줄이면 구조 자체가 재현되지 않고, 반대로 너무 높으면 구조적 또는 지각적 손실 항의 효과가 억제될 수 있기 때문이다. 따라서 SSIM과 feature 기반 손실 항의 영향을 독립적으로 분석하기 위해 L1 가중치를 고정하였다.

Feature matching loss는 생성기가 출력한 이미지가 판별기의 중간 feature 분포와 일치하도록 유도하여 구조적 일관성을 향상시킨다. 이때, 가중치 λ_{FM} 은 손실 항의 상대적 중요도를 조절하며, 값이 너무 작으면 구조 정합성이 부족해지고, 너무 크면 판별기의 feature 공간에 과적합될 우려가 있다.

SSIM은 평균, 분산, 공분산 통계를 기반으로 하는 지각 기반 유사도 지표로서, 학습시 손실함수로 적용할 경우, 전통적인 L1/L2 손실보다 구조적 이상 탐지에 유리할 수 있음을 상징하여 본 연구에 적용하였다. 특히 산업용 결함 검사에서 굵힘, 찢어짐 등 미세한 구조적 이상, 결함 등을 탐지함에 있어서 SSIM은 고정된 윈도우 크기를 기준으로 유사도를 계산하므로, 이 윈도우는 모델이 어느 정도의 공간적 범위에서 구조적 왜곡을 인식할지를 결정하는 핵심 하이퍼파라미터이다. 작은 윈도우 크기(예: 3×3, 5×5)는 국소적인 결함(예: 미세한 스크래치)에 민감하게 반응할 수 있으나, 반대로 노이즈에도 민감해 과잉반응(Overfitting)을 유발할 수 있다. 반면 큰 윈도우(예: 11×11, 15×15)는 보다 안정적인 통계

기반 비교가 가능해 잡음에 강건하지만, 국소적인 결함에 대한 탐지 감도가 낮아질 수 있다.

이러한 특성은 SSIM 기반 손실 함수가 실제 이미지에서 어느 범위의 이상징후를 학습하도록 유도할지를 결정하며, 윈도우 크기의 선택은 모델의 민감도와 견고성 간의 트레이드 오프를 내포한다. 본 연구에서는 다양한 윈도우 크기(예: 5, 7, 11)를 적용하여 민감도 실험을 수행하였고, 결함의 크기와 위치가 일정하지 않은 고해상도 산업 이미지에 적합한 최적의 윈도우 크기를 정량적으로 비교·분석하였다. 이를 통해 SSIM 기반 손실 항의 하이퍼파라미터가 모델 성능에 미치는 영향을 체계적으로 검토하였다. f-AnoGAN 학습은 재구성 정확도, 구조 일관성, 국소 유사도를 공동으로 최적화하는 복합 손실 함수를 기반으로 수행되었으며, 전체 손실 함수는 다음과 같이 정의된다. 식 (1)은 식 (2)~(4)의 가중치 및 손실함수로 구성된다.

$$\mathcal{L}_{total} = \lambda_{rec} \cdot \mathcal{L}_{rec} + \lambda_{FM} \cdot \mathcal{L}_{FM} + \lambda_{SSIM} \cdot \mathcal{L}_{SSIM} \quad (1)$$

식 (2)의 L1 손실 항은 입력 이미지 x 와 재구성 이미지 $G(E(x))$ 간의 절대 픽셀 차이를 측정하며, 전체적인 시각적 유사도를 계산한다. L2보다 L1을 사용하는 이유는 블러(Blurring effect) 현상을 줄이고, 보다 선명한 재구성을 유도하기 위함이다.

$$\mathcal{L}_{rec} = \|x - G(E(x))\|_1 \quad (2)$$

식 (3), Feature matching loss는 Discriminator의 각 레이어 l 에서 추출한 중간 특성 맵(feature map) f_l 을 기준으로, 입력 이미지와 복원 이미지 간의 지각적 차이(perceptual difference)를 계산한다. 이는 입력 이미지와 재구성 이미지 간의 차이를 측정하며, 구조적 일관성을 유지하는 데 기여한다:

$$\mathcal{L}_{FM} = \frac{1}{L} \sum_{l=1}^L \|f_l(x) - f_l(G(E(x)))\|_1 \quad (3)$$

SSIM(Structural Similarity Index Measure)은 밝기(Luminance), 대비(Contrast), 구조(Structure) 정보를 바탕으로 국소 윈도우 내에서 이미지 유사도를 측정한다. 그림 2는 학습에 사용된 이미지에 윈도우 사이즈별 상대적인 크기를 제시한 예시이다. $[0, 1]$ 범위의 값을 가지며, 1에 가까울수록 두 이미지가 시각적으로 유사함을 의미한다. 손실 함수로 사용하기 위해 $1 - SSIM$ 의 형태로 식 (4)와 같이 정의하였다.

$$\mathcal{L}_{SSIM} = 1 - SSIM(x, G(E(x))) \quad (4)$$

손실 함수 설계에 따른 가중치별 영향도 및 경향성 분석을 수행하기 위해, feature matching 및 SSIM 손실 항의 가중치, Window size를 체계적으로 조정하며 다양한 조합에 대해 학습을 수행하였다. 각 조건에 대해 여러 epoch 동안 훈련을 반복하고, 이상 점수 threshold를 달리하여 모델 성능을 평가하였다.




그림 2. SSIM 윈도우 사이즈별 이미지 내 적용 영역

Fig. 2. SSIM Window Size per Image

III. 분석 결과

모델의 학습 조건에 따른 성능 변화를 분석하기 위해, 세 가지 주요 하이퍼파라미터를 조정하여 각 성능에 대한 분석을 수행하였다. 1) Feature Matching 손실($\mathcal{L}_{FM}$)의 가중치(λ_{FM}), 2) SSIM 손실($\mathcal{L}_{SSIM}$)의 가중치(λ_{SSIM}), 3) SSIM 윈도우 크기. 이와 함께, 모델 성능이 학습 에폭(epoch) 및 이상 탐지 임계값(threshold)에 따라 어떻게 변화하는지를 모니터링하여, f-AnoGAN의 안정성과 민감도를 종합적으로 평가하였다. 성능 평가는 ISO/IEC TS 4213 및 ISO/IEC 24027에서 제시하는 AI 시스템 평가 기준을 따라 Precision, Recall, F1-score, AUC를 활용하였다. 이 평가지표는 실제 환경에서 AI의 정확성, 일반화 성능, 공정성 등을 측정하는 데 국제적으로 인정된 기준이다[13].

표 1은 모델 학습 시, Feature Matching 가중치, SSIM 가중치, SSIM 윈도우 크기에 따라 테스트 데이터 기반 모델의 성능 지표별 수치를 나타낸다.

표 1. 하이퍼파라미터 설정별 이상 탐지 성능 정량 평가 결과(Feature Matching 가중치, SSIM 가중치, SSIM 윈도우 크기 비교)

Table 1. Quantitative evaluation of anomaly detection performance under different hyperparameter settings (λ_{FM} , λ_{SSIM} and SSIM window size)

Lambda feat	0.1	0.3	0.5	
Precision	0.1048	0.1136	0.0611	
Recall	0.4583	0.2083	1.0000	
F1-Score	0.1705	0.1471	0.1151	
AUC	0.6021	0.4411	0.4293	
$\lambda_{SSIM} (\lambda_{FM}=0.3)$	0.1	0.3	0.5	
Precision	0.0692	0.0627	0.1333	
Recall	0.4583	1.000	0.1667	
F1-Score	0.1202	0.1179	0.1481	
AUC	0.4840	0.6702	0.4887	
Window size ($\lambda_{SSIM}=0.3$, $\lambda_{FM}=0.3$)	7	11	50	70
Precision	0.1463	0.0627	0.1167	0.0602
Recall	0.2500	1.000	0.2917	1.0000
F1-Score	0.1846	0.1179	0.1667	0.1135
AUC	0.5893	0.6702	0.6140	0.3909

위의 표 1에서 λ_{FM} , λ_{SSIM} , SSIM 윈도우 크기 등

의 핵심 하이퍼파라미터 설정에 따른 f-AnoGAN 모델의 이상 탐지 성능을 정량적으로 비교한 결과이다. 분석 결과, SSIM 기반 손실을 적용했을 때 특히 윈도우 크기를 11(선행연구 기준[14]-[16]) 또는 50(실제 결함의 공간 스케일 반영)로 설정한 경우 높은 F1-score와 AUC 값을 기록하였다. 이는 구조적 유사도와 국소 결함 민감도를 적절히 조합할 경우, 모델의 민감도와 정밀도를 동시에 향상시킬 수 있음을 시사한다. 반면, SSIM 윈도우 크기가 너무 작거나 너무 클 경우 성능 저하가 나타났으며, 이는 결함의 공간적 특성과 SSIM 윈도우 크기의 정합성이 중요하다는 점을 보여준다.

SSIM 관련 하이퍼파라미터가 이상 탐지 정확도와 민감도에 미치는 영향을 분석하기 위해, 2D Heatmap을 활용한 시각적 분석을 수행하였다. 이 Heatmap은 다양한 임계값(threshold) 및 에폭(epoch)에 따른 F1-score 분포를 시각화하여 모델의 민감도와 안정성의 경향을 직관적으로 파악할 수 있게 한다. 그림 3~5는 각각 Feature Matching Loss 가중치, SSIM Loss 가중치, SSIM 윈도우 사이즈에 대하여 모델의 학습 Epoch별 이상감지 Threshold에 따른 모델의 성능을 나타낸다.

그림 3은 Feature Matching Loss 가중치(λ_{FM}) 변화에 따른 탐지 성능을 나타낸 Heatmap이다. 가로축은 anomaly detection threshold, 세로축은 학습 epoch이며, 색상은 F1-score 값을 의미한다. $\lambda_{FM} = 0.1$ 에서는 비교적 넓은 영역에서 중간 수준의 F1-score가 유지되었으나, $\lambda_{FM} = 0.3$ 에서는 특정 threshold 부근에서만 제한적으로 높은 성능이 관찰되었다. 반면 $\lambda_{FM} = 0.5$ 에서는 threshold가 낮은 구간에서 밝은 색(높은 F1-score)이 두드러지며 성능 향상이 나타났다. 이는 Feature Matching Loss의 가중치가 지나치게 낮거나 높을 경우 안정성이 떨어질 수 있음을 시사하며, 적절한 가중치 설정이 탐지 민감도 최적화에 중요함을 보여준다.

그림 4는 SSIM Loss 가중치(λ_{SSIM}) 변화에 따른 탐지 성능을 보여준다. $\lambda_{SSIM} = 0.1$ 에서는 threshold 변화에 따라 성능 기록이 크고 전반적으로 낮은 F1-score를 보였으나, $\lambda_{SSIM} = 0.3$ 에서는 특정 epoch와 threshold 조합에서 성능이 개선되는 양상이 나타났다. 특히 $\lambda_{SSIM} = 0.5$ 에서는 낮은 threshold

조건에서 상대적으로 높은 F1-score 영역이 확인되었다. 이는 SSIM Loss가 일정 수준 이상으로 반영될 때 구조적 특성을 잘 포착하여 성능 개선에 기여함을 의미한다. 다만 지나친 가중치는 오히려 특정 구간에 과도하게 민감해질 수 있음을 보여준다.

그림 5는 SSIM 윈도우 크기 변화(4, 7, 14, 30, 50, 70)에 따른 F1-score Heatmap이다. 윈도우 크기가 4와 같이 매우 작은 경우, 세밀한 결함에는 민감하나 전반적인 성능 변동이 커 불안정성을 보였다. 반대로 70과 같이 지나치게 큰 경우, 지역적 결함을

놓치면서 성능 저하가 발생하였다. 윈도우 크기 11과 50에서는 비교적 안정적이고 높은 F1-score가 관찰되었으며, 이는 결함의 실제 크기와 SSIM 윈도우 크기가 정합될 때 성능이 최적화됨을 시사한다. 즉, 결함의 공간적 스케일에 맞춘 윈도우 크기 설정이 모델의 민감도와 강건성 균형을 확보하는 핵심 요인 중 하나임을 확인할 수 있다.

그림 3-5의 시각화를 통해 최적의 하이퍼파라미터 설정을 직관적으로 탐색할 수 있으며, 모델 성숙도와 이상 민감도 간의 관계를 보다 명확히 파악할 수 있다.




그림 3. Feature matching loss 가중치 변화에 따른 Heatmap(가로축: threshold, 세로축: epoch, 색상: F1-score)
Fig. 3. Epoch-wise threshold sensitivity heatmap (by feature matching loss) (x-axis: Threshold, y-axis: Epoch, color scale: F1-score, where brighter colors indicate higher values and darker colors indicate lower values)




그림 4. SSIM loss 가중치 변화에 따른 Heatmap(가로축: threshold, 세로축: epoch, 색상: F1-score)
Fig. 4. Epoch-wise threshold sensitivity heatmap (by SSIM loss) (x-axis: Threshold, y-axis: Epoch, color scale: F1-score, where brighter colors indicate higher values and darker colors indicate lower values)




그림 5. SSIM 윈도우 크기 변화에 따른 Heatmap(가로축: threshold, 세로축: epoch, 색상: F1-score)
Fig. 5. Epoch-wise threshold sensitivity heatmap (by SSIM window size) (x-axis: threshold, y-axis: epoch, color scale: F1-score, where brighter colors indicate higher values and darker colors indicate lower values)

IV. 결론 및 향후 과제

본 연구의 가장 주목할 만한 기여는 f-AnoGAN 모델의 학습 손실 함수에 구조적 유사도 지수 (SSIM)를 단순한 평가 지표가 아닌 핵심 손실 항으로 통합한 점이다. 이는 기존 연구들에서는 드물게 시도된 방식으로, 픽셀 기반 손실만으로는 놓치기 쉬운 미세하고 국소적인 결함을 보다 민감하게 포착할 수 있는 구조 민감 학습 (Structure-sensitive learning)을 가능하게 하였다. 실험 결과, SSIM 손실 항이 적절한 가중치로 Feature Matching 손실과 함께 적용될 경우, 고해상도 산업용 이미지에서의 이상 탐지 성능이 유의미하게 향상됨을 확인하였다. 또한, 손실 함수 내 각 구성 요소의 가중치 설정 및 SSIM 윈도우 크기에 따른 모델 성능의 변화를 체계적으로 분석하였으며, 이는 기존 GAN 기반 이상 탐지 연구에서 거의 다루지지 않았던 부분이다. 특히 실제 산업 현장 및 제조 공정에서 수집된 고해상도 데이터에 기반하여, 마이크로 결함 민감도와 구조적 강건성 간의 트레이드 오프를 실험적으로 규명함으로써, 저용량 산업 데이터 환경에서도 효과적인 하이퍼파라미터 튜닝과 모델 선택 전략을 제안하였다. 이를 통하여 결함 크기와 SSIM 윈도우 간의 정합성을 고려한 하이퍼파라미터 설계가 필요함을 확인할 수 있었다. 모델의 학습 측면에서도 에폭과 임계값에 따른 모델 성능(F1-score, AUC)을 시각화한 2차원 히트맵을 도입하여, 최적 임계값 및 조기 종료 시점을 직관적으로 파악할 수 있도록 하였다. 이러한 시각화 기법은 실제 제조 현장, 제조 공정에서의 모델 배포 전략 수립에 활용 가능성이 높다. 한편, 데이터셋 규모가 작아 결과의 일반화에는 한계가 있으며, 본 연구는 Generator 손실에만 초점을 맞추었다. 본 연구는 실제 산업 데이터셋을 기반으로 수행되었으나, 데이터 규모가 제한적이라는 점에서 일반화에는 한계가 있다. 특히 학습 epoch 및 anomaly detection threshold 변화에 따른 Heatmap 분석에서, 소규모 데이터셋으로 인해 F1-score와 Recall 값이 특정 구간에서 급격히 변동하는 불안정성이 관찰되었다. 예를 들어 Feature Matching Loss 가중치가 0.1일 때 Recall이 높으나 Precision이 낮아

F1-score 변동 폭이 컸으며, SSIM 윈도우 크기가 4 또는 70과 같이 극단적인 설정일 때 AUC 값이 불안정하게 감소하는 경향이 나타났다. 이러한 결과는 데이터 수가 충분하지 않은 조건에서 모델이 특정 파라미터나 threshold에 민감하게 반응할 수 있음을 의미하며, 향후 연구에서는 보다 대규모 데이터셋과 다양한 결함 유형을 포함한 검증이 필요하다. 향후 연구에서는 이러한 한계를 보완하기 위해 보다 대규모의 데이터셋과 다양한 결함 유형을 포함한 검증이 필요하다. 또한 Discriminator 구조의 개선 방향으로, 단순히 이진 판별만 수행하는 대신 다단계 feature pyramid 기반 판별기 설계나 attention 모듈을 결합한 지역적 결함 민감도 강화 구조를 고려할 수 있다. 이를 통해 미세한 결함을 보다 안정적으로 구분하고, Generator-Encoder와의 feature interaction을 강화하여 이상 탐지 성능의 일반화 가능성을 높일 수 있을 것으로 기대된다.

Acknowledgement

'2024년도 한국정보기술학회 추계종합학술대회에서 발표한 논문(Text 기반 조색사 암묵지 학습을 위한 경량화 모델 연구)[17]을 확장한 것임'

References

- [1] T. Schlegl, P. Seeböck, S. M. Waldstein, G. Langs, and U. Schmidt-Erfurth, "f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks", *Medical Image Analysis*, Vol. 54, pp. 30-44, May. 2019. <https://doi.org/10.1016/j.media.2019.01.010>.
- [2] Y. Zhang, J. Li, and H. Pan, "Unsupervised bearing raceway surface defect detection based on improved f-AnoGAN", *Measurement Science and Technology*, Vol. 36, No. 1, Oct. 2024. <https://doi.org/10.1088/1361-6501/ad8021>.
- [3] O. Sliti, M. Devanne, S. Kohler, N. Samet, J. Weber, and C. Cudel, "f-AnoGAN for non-destructive testing in industrial anomaly

- detection", Proc. 16th Int. Conf. Quality Control by Artificial Vision, Albi, France, pp. 297-304, Jul. 2023. <https://doi.org/10.1117/12.3000063>.
- [4] C. Park, S. Lim, D. Cha, and J. Jeong, "Fv-AD: F-AnoGAN based anomaly detection in chromate process for smart manufacturing", Applied Sciences, Vol. 12, No. 15, Jul. 2022. <https://doi.org/10.3390/app12157549>.
- [5] A. Zeiser, B. Özcan, B. van Stein, and T. Bäck, "Evaluation of deep unsupervised anomaly detection methods with a data-centric approach for on-line inspection", Computers in Industry, Vol. 146, Apr. 2023. <https://doi.org/10.1016/j.compind.2023.103852>.
- [6] J. Choi, S. Lee, and K. Kang, "Espresso crema analysis with f-AnoGAN", Mathematics, Vol. 13, No. 4, Feb. 2025. <https://doi.org/10.3390/math13040547>.
- [7] T.-Y. Kim and E. Park, "Detecting wireless signal noise in mobile radio communications using spatiotemporal AnoGAN-based approaches", IEEE Canadian Journal of Electrical and Computer Engineering, Vol. 46, No. 4, pp. 310-321, Nov. 2023. <https://doi.org/10.1109/ICJECE.2023.3320958>.
- [8] L. Yun, J. Wang, L. Yang, B. Hao, F. Zhang, and L. Gao, "Belt defect detection based on f-AnoGAN", International Conference on Advanced Electronic Materials, Computers, and Software Engineering, Shenyang, China, pp. 56-61, Aug. 2023. <https://doi.org/10.1117/12.3004875>.
- [9] D. Štepec and D. Skočaj, "Image-to-image translation as a pretext for unsupervised detection of cancerous regions in histology imagery", Uporabna Informatika, Vol. 29, No. 4, Dec. 2021. <https://doi.org/10.31449/upinf.136>.
- [10] Z. Zhang, B. Patel, B. Patel, and I. Banerjee, "Unsupervised generative approach for anomaly detection to enhance the quality of unseen medical datasets", Proc. IEEE Winter Conf. Applications of Computer Vision (WACV), Tucson, Arizona, pp. 287-296, Feb. 2025.
- [11] F. Quiroga, F. Ronchetti, L. Lanzarini, and A. F. Bariviera, "Revisiting data augmentation for rotational invariance in convolutional neural networks", Int. Conf. Modelling and Simulation in Management Sciences, Cham, Springer, Girona, Spain, pp. 127-141, Jan. 2018. https://doi.org/10.1007/978-3-030-15413-4_10.
- [12] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning", Journal of Big Data, Vol. 6, No. 1, pp. 1-48, Jul. 2019. <https://doi.org/10.1186/s40537-019-0197-0>.
- [13] J. Oviedo, M. Rodriguez, A. Trenta, D. Cannas, D. Natale, and M. Piattini, "ISO/IEC quality standards for AI engineering", Computer Science Review, Vol. 54, No. 100681, Nov. 2024. <https://doi.org/10.1016/j.cosrev.2024.100681>.
- [14] H. B. Golestani and M. Ghanbari, "Window size influence on SSIM fidelity", Proc. 7th Int. Symp. Telecommunications (IST'2014), Tehran, Iran, pp. 355-360, Jan. 2014. <https://doi.org/10.1109/ISTEL.2014.7000752>.
- [15] J. Nilsson and T. Akenine-Möller, "Understanding SSIM", arXiv preprint, arXiv:2006.13846, Jun. 2006. <https://doi.org/10.48550/arXiv.2006.13846>.
- [16] T. Zhao, K. Zeng, A. Rehman, and Z. Wang, "On the use of SSIM in HEVC", Proc. Asilomar Conf. Signals, Systems and Computers, IEEE, Pacific Grove, CA, USA, pp. 1107-1111, Nov. 2013. <https://doi.org/10.1109/ACSSC.2013.6810465>.
- [17] S. Jhang, D. Yoo, and J. Kwon, "A Study on Models for Tacit Knowledge Learning of Colorists Based on Text Data", Proc. KIIT Conference, Jeju, South Korea, pp. 286-288, Nov. 2024.

저자소개

장 성 수 (Seongsu Jhang)



2017년 2월 : 광운대학교

전기공학과(공학사)

2019년 2월 : 광운대학교

전기공학과(공학석사)

2019년 2월 ~ 2021년 1월 :

(주)HD현대일렉트릭 연구원

2021년 2월 ~ 현재 :

한국전자기술연구원 선임연구원

관심분야 : ICT융합, 제조데이터, 산업 인공지능

유 동 휘 (Donghwi Yoo)



2021년 2월 : 광주과학기술원

기계공학과(공학사)

2023년 9월 : 광주과학기술원

기계공학과(공학석사)

2023년 9월 ~ 현재 :

한국전자기술연구원 전임연구원

관심분야 : 기계 예지보전,

고장진단, 데이터분석

권 재 영 (Jaeyoung Kwon)



2018년 2월 : 영남대학교

전기공학과(공학사)

2024년 2월 : 경남대학교

기계공학과(공학석사)

2020년 9월 ~ 현재 :

한국전자기술연구원 선임연구원

관심분야 : 공작기계, 데이터 표준,

OPC UA, 제조 데이터, 산업 인공지능

이 원 희 (Wonhee Lee)



2010년 2월 : 숭실대학교

정보통신전자공학부(공학사)

2013년 9월 : 숭실대학교

정보통신공학과(공학석사)

2013년 10월 ~ 현재 :

한국전자기술연구원 선임연구원

관심분야 : Wired/Wireless

Fieldbus system, 자율제조