

Anomaly detection for small defect

2024년도 하계 세미나



Sogang University

Vision & Display Systems Lab, Dept. of Electronic Engineering



Presented By

이혜빈

Contents

- Paper review
 - Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)
 - An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

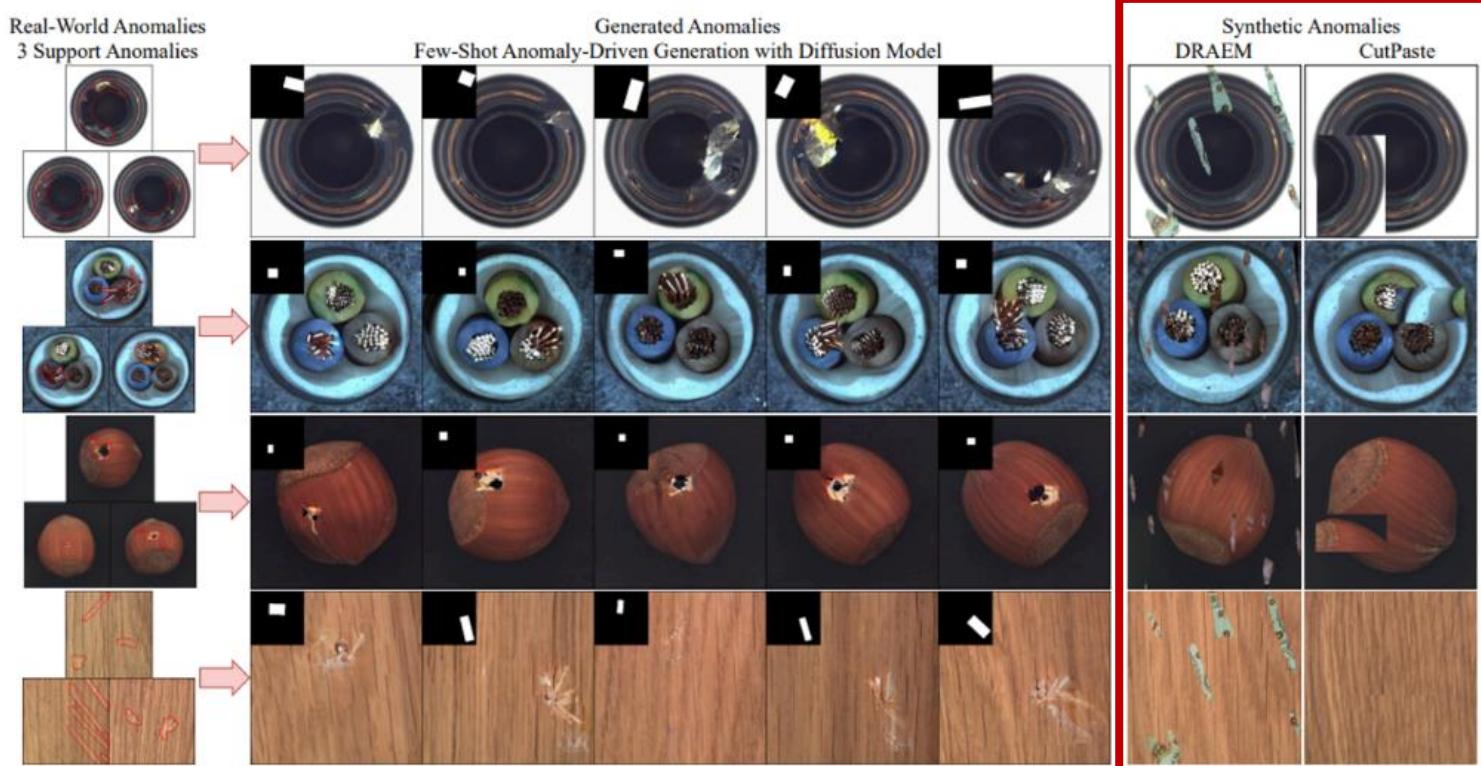
Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- 기존 방법들
 - 노이즈나 외부 데이터를 사용하여 anomaly image를 합성
 - 실제 anomaly와의 큰 semantic한 차이가 있어 anomaly detection의 성능이 약해짐
- 제안하는 방법
 - Diffusion model로 realistic anomaly 이미지를 생성
 - Few shot real anomaly 이미지들을 기반으로 anomaly distribution을 학습하고 학습된 지식을 임베딩에 주입
 - 임베딩과 주어진 바운딩 박스를 사용하여 target class에서 현실적이고 다양한 anomaly를 생성하도록 diffusion 모델을 guide
 - 생성된 anomaly image를 사용하는 weakly supervised anomaly detection model

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Introduction

- Bounding mask를 supervision으로 사용
- DREAM, DeSTSeg로 모델의 anomaly detection 성능을 향상



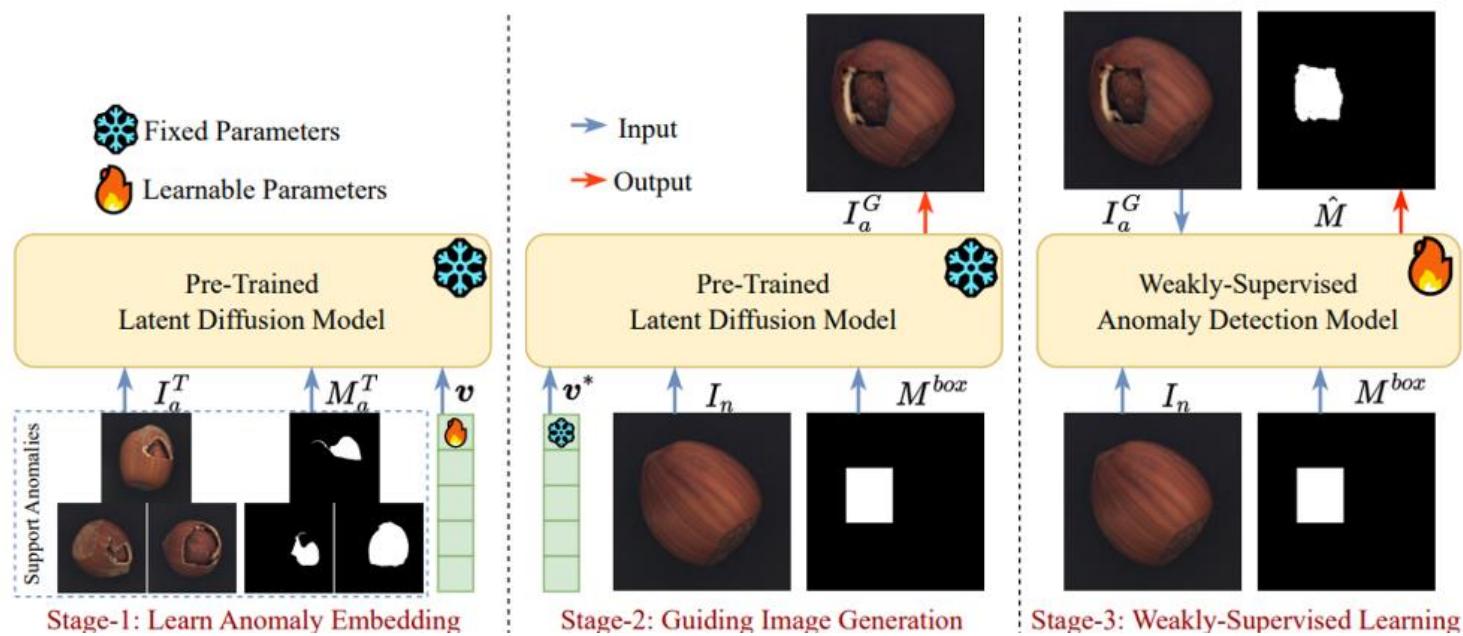
<논문의 방법으로 생성된 anomaly와 기존 방식의 합성 anomaly >

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Method

- 다음의 단계를 통해 모델을 학습

- Learn Anomaly Embedding
- Guiding Anomaly Generation
- Weakly-Supervised Anomaly Detection



Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Method

- Step-1: Learn Anomaly Embedding

- 실제 anomaly image의 semantic 특성을 효과적으로 포착하는 임베딩 학습에 초점을 맞춤
 - Pretrained LDM의 파라미터 고정, LDM의 conditional 임베딩을 대체할 임베딩 vector 초기화

$$\mathbf{v}^* = \arg \min_{\mathbf{v}} L_{LDM}(I_a^T, t, \mathbf{v}),$$

;; I_a^T : 실제 anomaly image

- ;; 임베딩 vector를 UNet의 middle layer에 cross-attention과 함께 넣음
 - 학습된 임베딩이 실제 anomaly image에 대한 분포 포착 → 이미지 생성 guide
 - Loss function

$$L'_{LDM} = \mathbb{E}_{\varepsilon(x), \epsilon, t, \mathbf{v}} [\| (\epsilon - \epsilon_\theta(\varepsilon(I_a^T), t, \mathbf{v})) \odot M_a^T \|_2^2],$$

- ;; 전체 이미지로 학습 시, anomaly가 너무 작아 편향이 일어날 수 있음
- ;; Anomaly image의 segment mask를 loss function에 통합하여 가이드

;; 마스크에 guided된 loss를 통해 object의 local detail 사항을 포착하는 데 중점

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Method

- Stage-2: Guiding Anomaly Generation

- Input image로 normal image I_n 을 샘플링
 - Bounding box mask를 사용하여 생성된 anomaly size와 위치를 regulate 하려고 했음
 - Stage-1에서 학습시킨 LDM embedding vector를 inference

- ;; Box 내 영역 유지, box 외부의 영역은 I_n 의 노이즈 버전으로 대체됨

- ;; Input image의 특정 영역에 생성된 anomaly defect가 위치할 수 있도록 제어 가능

$$z_t = z_n^t \odot (1 - M^{box}) + z_t' \odot M^{box},$$

- ;; z_n^t : time step t에서의 $\epsilon(I_n)$ 의 노이즈 버전

- ;; z_t' : z_{t+1} 의 디노이즈 버전

- ;; 해당 z_t 가 디노이징 프로세스를 거친 후, decoder를 거치면 anomaly image인 I_G^a 가 됨

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Method

- Stage-3: Weakly-Supervised Anomaly Detection

- Bounding box 내의 픽셀이 모두 anomalous한 pixel이 아닐 수 있으므로 supervision이 아닌 weakly supervision을 사용 → weakly supervised loss를 설계
 - Threshold값에 따라 매우 normal인 경우, loss를 0으로 설계, 나머지 박스 외 영역에는 focal loss 사용

$$L_{seg} = L_{Focal}(M, \hat{M}),$$

- Discriminative sub network의 전체 weakly supervised loss는 다음과 같음

;; M^{box} : anomaly 생성 시 주어진 박스 마스크

;; δ : normal인 확률값이 threshold 보다 큰 경우 1, 아니면 0

$$L'_{seg} = M^{box} \odot (1 - \delta) \odot L_{seg} + (1 - M^{box}) \odot L_{seg},$$

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Experiments

- Implementation Details

- Datasets

- ;; MVTec dataset

- Learning embeddings and generated images

- ;; "defect"를 CLIP text encoder를 통해 사용 → 초기화된 임베딩 v 얻음

- ;; v 학습하는 단계에서 실제 anomaly에서 3개의 이미지 random sampling

- ;; Anomaly 생성 단계: 각 object에 대해 2개의 마스크를 무작위 생성, 각 마스크 사용
→ 2개 이상의 이미지 생성

- Bounding box generation

- ;; GrabCut 사용해서 얻은 foreground 영역, bbox 교차영역이 최소 50% IoU 가지도록
위치 조절

- ;; 크기를 제어하기 위해 하이퍼파라미터를 설정

- ;; 다양한 anomaly 현상 생성 위해 bbox 무작위 생성

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Experiments
 - Implementation Details
 - Anomaly detection task
 - ;; Baseline: DRAEM, DeSTSeg
 - ;; 학습 시, 원본 anomaly와 논문 방법으로 합성한 anomaly를 0.5 확률로 무작위 샘플링
 - ;; 논문의 모델이 normal, anomaly class 간의 imbalance 개선 → metric 수치 향상
 - ;; DRAEM, DeSTSeg와의 비교 → 생성된 anomaly 이미지가 학습에 도움 되는지 검증

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Experiments

- Quantitative results

| Metrics | CS-Flow | PaDim | PatchCore | RD4AD | DRAEM | AnoGen | DeSTSeg | AnoGen |
|---------|---------|-------|-----------|-------|-------|--------|---------------------|--------|
| Image | AU-ROC | 97.5 | 91.2 | 97.8 | 98.7 | 97.1 | 98.7 (1.6 ↑) | 98.3 |
| | AU-PR | 97.7 | 94.2 | 98.8 | 97.8 | 98.5 | 99.5 (1.0 ↑) | 99.4 |
| Pixel | AU-ROC | 93.4 | 96.9 | 97.5 | 93.9 | 96.8 | 98.1 (1.3 ↑) | 98.2 |
| | AU-PR | 59.6 | 48.5 | 61.7 | 55.4 | 67.4 | 73.2 (5.8 ↑) | 76.6 |

- DRAEM의 image level AUROC가 1.6% 향상, DeSTSeg는 0.5% 향상

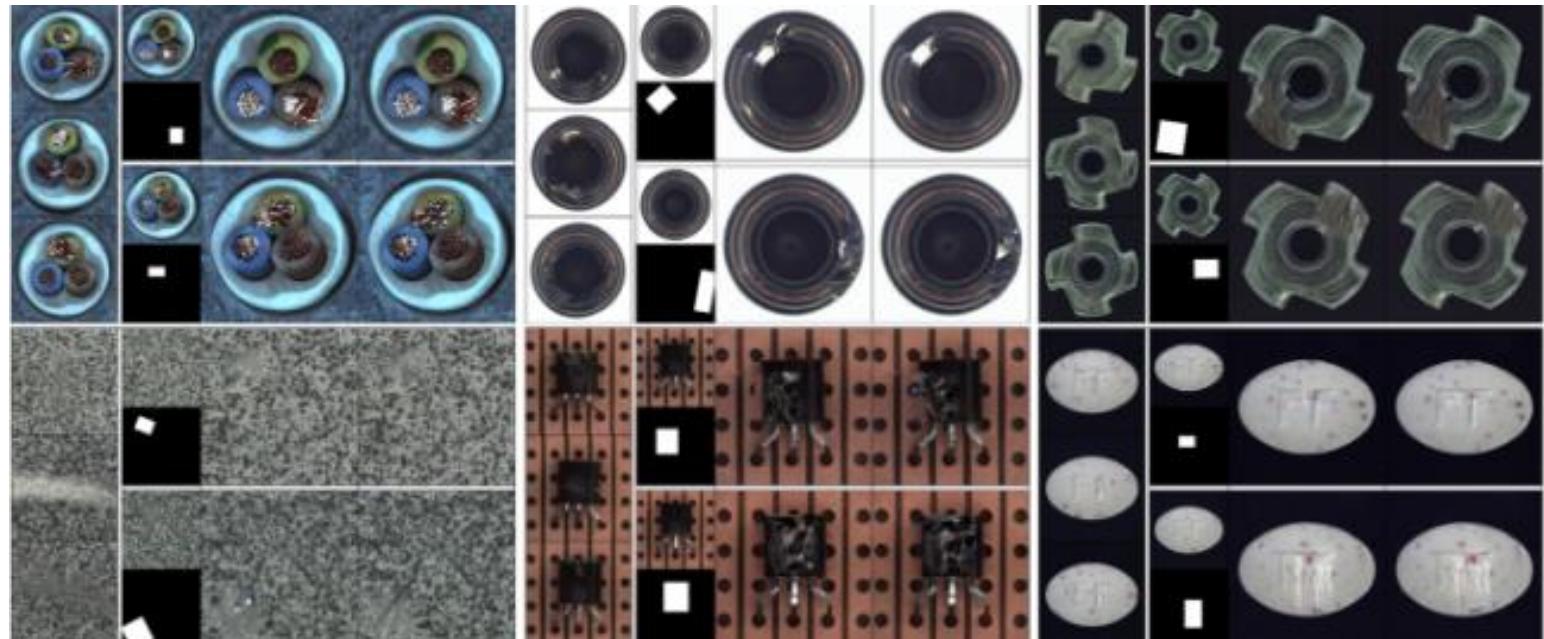
- 실제 anomaly와 일치하는 anomaly 제공 → anomaly segmentation model의 성능 향상

Few-Shot Anomaly-Driven Generation for Anomaly Classification and Segmentation (ECCV 2024)

- Experiments

- Qualitative results

- 합성된 anomalous image는 실제 anomalous image와 유사하며 다양성을 보여줌
 - 또한, 박스 조건을 적용함으로써 anomalous 영역의 위치와 크기를 제어 가능

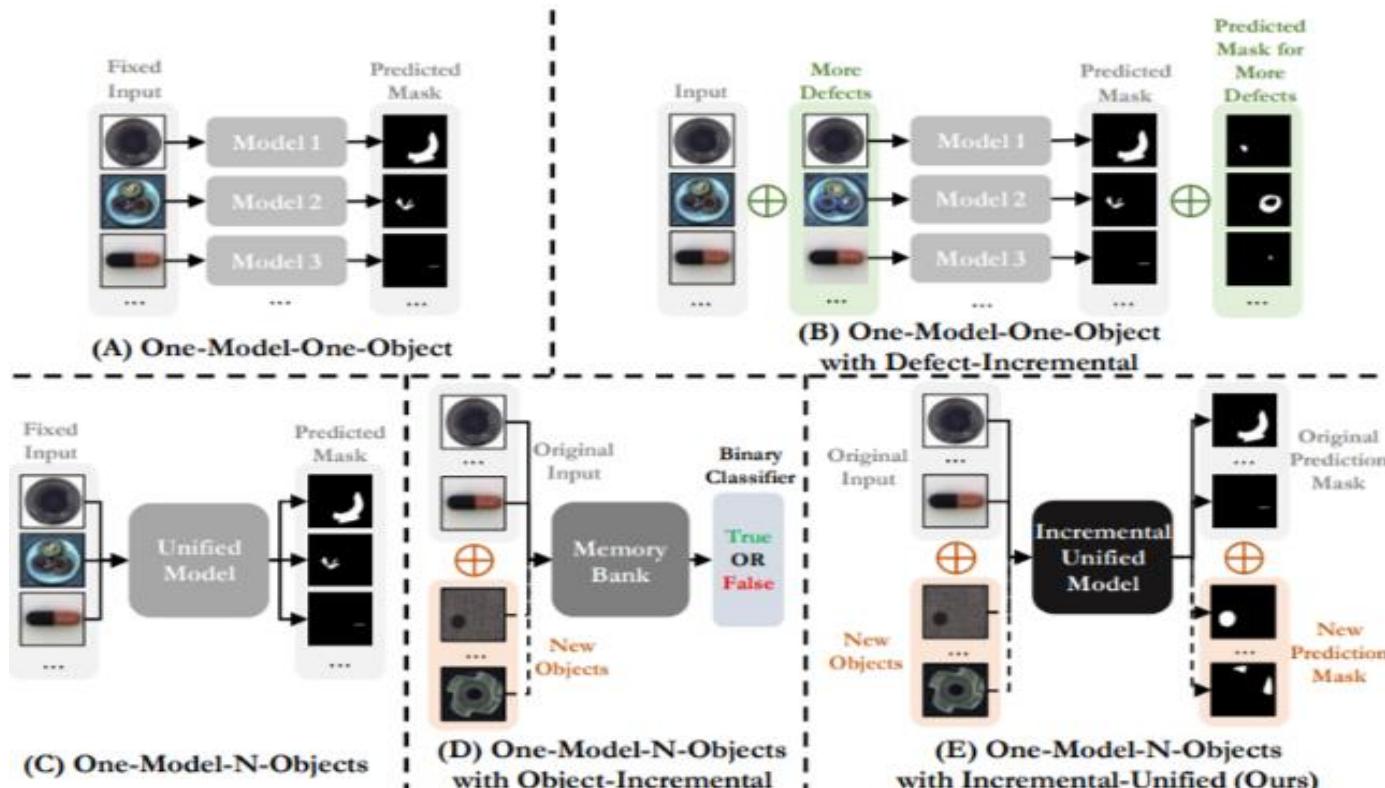


An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- 기존 방법들

- 그림의 D와 같이 memory bank와 binary classifier를 이용해 incremental learning을 하는 모델 존재

- object distribution 차이 → memory bank의 feature가 손상될 수 있음



An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- 제안하는 방법

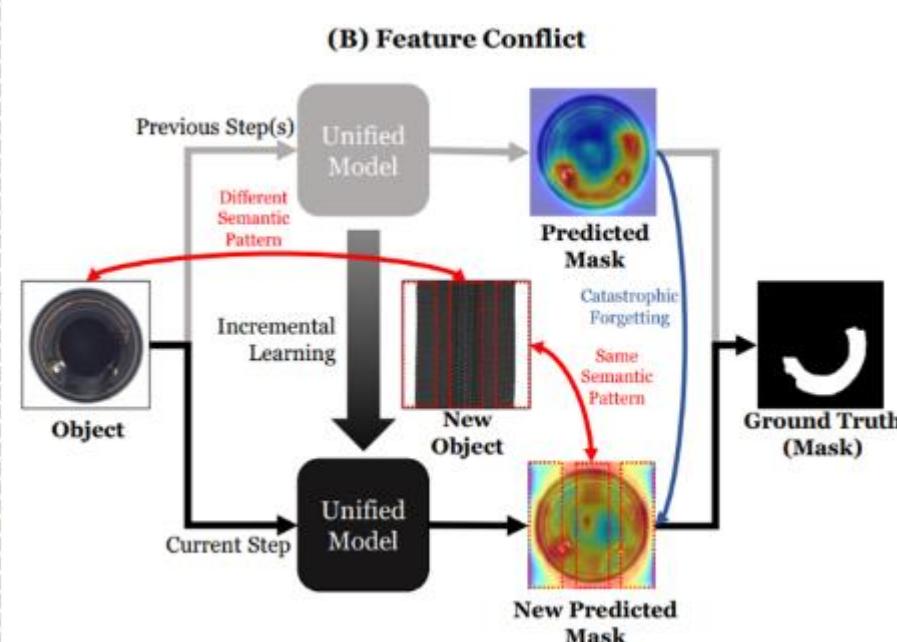
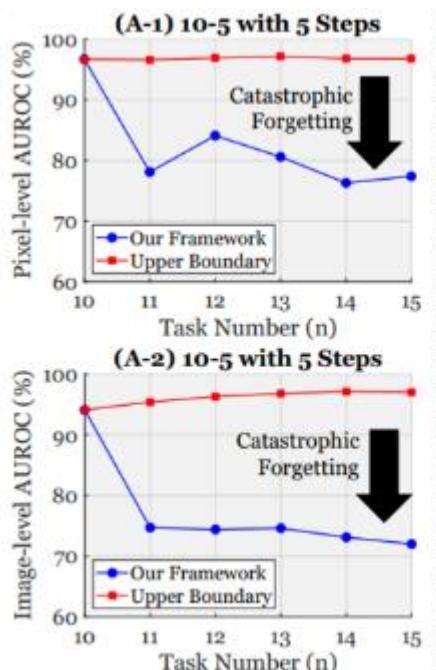
- Unified setting anomaly detection 모델과 object incremental learning 통합한 프레임워크
- Memory bank에 feature 저장할 필요 없이 다양한 object에 대해 pixel 수준의 정밀한 defect 검사 가능하게 함
- Object class feature 활용 → object들 간 semantic space 분리하는 OASA(Object Aware Self Attention)제안
- Semantic compression loss 도입 → 중요한 feature값에만 집중하도록 유도

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Background

- Catastrophic forgetting

- 새로운 object 이어서 학습 시, model이 이전 semantic pattern을 덮어쓰면서 심각한 feature 충돌 유발하는 것
 - 10-5 with 5 steps: 10개의 object에서 먼저 학습, 하나의 object를 추가하면서 5 step에서 과정 완료



An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

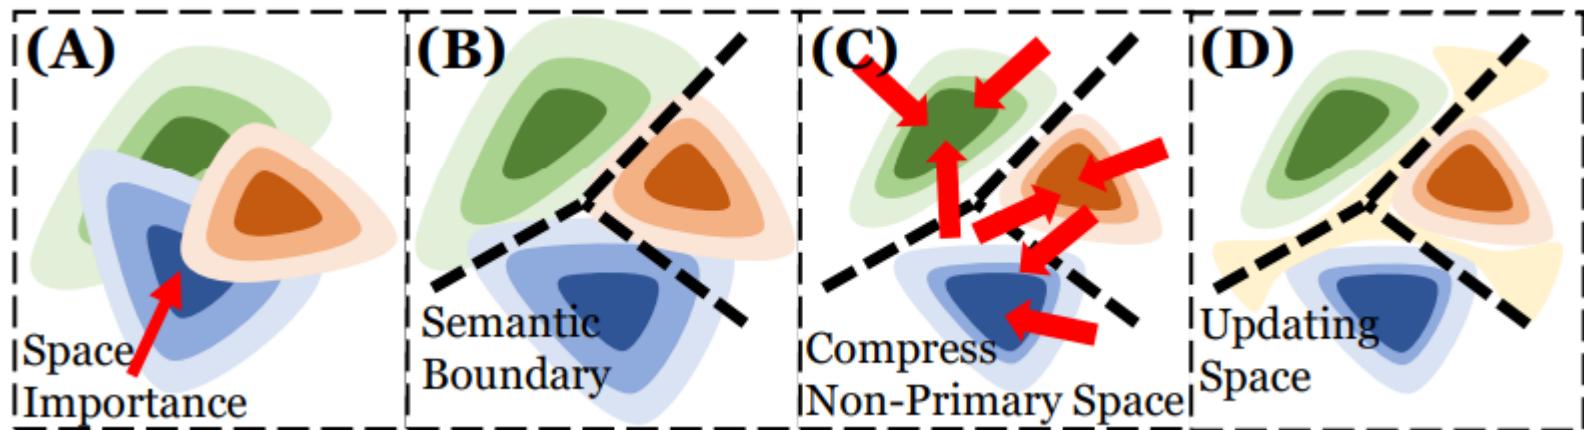
- Method

- Identifying Semantics Boundary

- 기존 unified setting anomaly detection은 하나의 auto-encoder로 모든 object를 직접 reconstruction

- ↳ Semantic space가 밀접하게 결합되어 기존 object의 feature space 구분 없이 업데이트

- ✓ “Catastrophic forgetting” 발생



An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Method

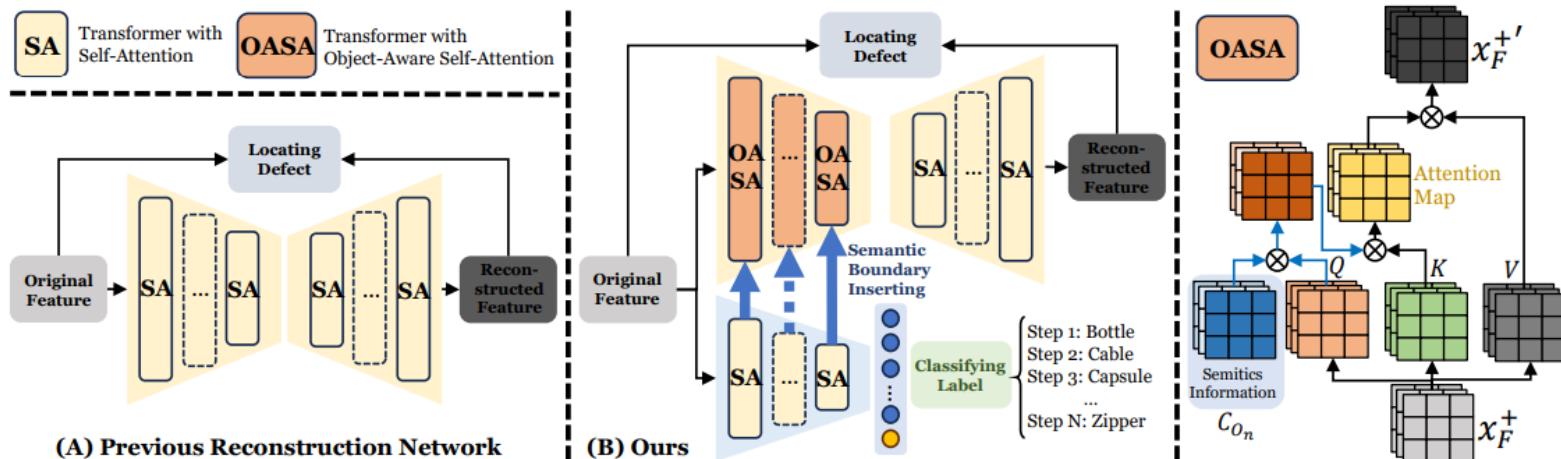
- Identifying Semantics Boundary

- Reconstruction network에 semantic boundary 도입 위해 OSOA(Object-Aware Self-Attention) 설계

$\cdot \cdot \cdot$: Hadamard product

C_{o_n} : 현재 step의 semantic feature

$\checkmark C_{o_n}$ 를 Q에 삽입 → reconstruction network는 semantic boundary 식별



An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Method

- Compacting Semantic Space

- Latent feature 를 SVD 분해하여 다음과 같이 표현

$$\hat{M} = USV^T$$

$$= \underbrace{\begin{bmatrix} u_{11} & u_{12} & u_{13} & \cdots & u_{1B} \\ u_{21} & u_{22} & u_{23} & \cdots & u_{2B} \\ u_{31} & u_{32} & u_{33} & \cdots & u_{3B} \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ u_{B1} & u_{B2} & u_{B3} & \cdots & u_{BB} \end{bmatrix}}_{\text{Batch Space}} \underbrace{\begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_C \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix}}_{\text{Channel Space}} \underbrace{\begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1C} \\ v_{21} & v_{22} & \cdots & v_{2C} \\ \vdots & \vdots & \ddots & \vdots \\ v_{C1} & v_{C2} & \cdots & v_{CC} \end{bmatrix}}_T, \quad (6)$$

- Eigenvalue의 크기와 의미 정보의 중요도가 비례 → 중요하지 않은 feature 정보들을 압축
- 새로운 object 학습 시, 업데이트 가중치를 이전 feature의 semantic space로 projection
- 이전 정보에 대해 semantic하게 중요한 가중치 update 규제

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Method

- Compacting Semantic Space

- Loss function

$$L = \lambda_0 L_1 + \lambda_1 L_{CE} + \lambda_2 L_{sc}$$

$$\therefore L_{sc} = \sum_{i=t}^C \sigma_i$$

- Reinforcing Primary Semantic Memory

- 이전 object와 새로운 object 간 중요한 feature space 겹침 → catastrophic forgetting 위험
 - 다음의 두 문제 해결이 중요

- ;; 가중치 update 시, 이전의 의미 정보 유지

- ;; 동시에 새로운 object에 대한 지식 습득하면서 이전 object와 관련된 semantic space에 크게 영향 안 미치는 방법 탐색

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Method

- Reinforcing Primary Semantic Memory

- 이전 semantic 정보 유지

$$\theta_j' \leftarrow \theta_j + \nabla \theta_j^* + \beta \theta_j^{old}.$$

↳ 기존 객체의 의미 유지 위해서 incremental 과정에서 기존 object의 weight를 지속적으로 통합해야 함 → 이전 weight를 지속적으로 복사

- Decreasing Rewriting of Prior Semantics

↳ 이전 semantic space에서의 가중치 update 억제

✓ 새로운 object가 의미 공간 사용할 수 있도록 제한 → feature 충돌 감소

$$\nabla \Theta_j = V_{old}^T \nabla \theta_j,$$

↳ 업데이트 가중치를 이전 object의 해당 채널 space로 projection

$$\Omega(k, c) = k \times \log(c),$$

↳ 업데이트 제약을 위해 위의 제약 함수 사용

↳ 채널 인덱스 c 가 작을수록 제약 함수의 결과는 0 → 0이 차원에서 업데이트 안 됨

$$\nabla \theta_j^* = (V_{old}^T)^{-1} \Omega(k, n) \odot \nabla \Theta_j,$$

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Experiments

- Quantitative results

- 단일 단계(single-step) 설정과 다단계(multi-step) 설정 모두에서 실험을 진행
 - 일부 baseline은 incremental learning protocol인 CAD와 통합
 - Metric

$$ACC = \begin{cases} \frac{1}{N} \sum_{i=1}^{N-1} A_{N,i}^{\text{pix}} \\ \frac{1}{N} \sum_{i=1}^{N-1} A_{N,i}^{\text{img}} \end{cases}, FM = \begin{cases} \frac{1}{N-1} \sum_{i=1}^{N-1} \max_{b \in \{1, \dots, N-1\}} (A_{b,i}^{\text{pix}} - A_{N,i}^{\text{pix}}) \\ \frac{1}{N-1} \sum_{i=1}^{N-1} \max_{b \in \{1, \dots, N-1\}} (A_{b,i}^{\text{img}} - A_{N,i}^{\text{img}}) \end{cases}$$

평균 정확도(ACC)

망각 측정(FM)

A^{pix} : Pixel level AUROC

A^{img} : Image level AUROC

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Experiments

- Quantitative results

- UniAD가 catastrophic forgetting 문제를 겪고 있는 것을 알 수 있음
- 다른 incremental learning 방법과 결합한 결과에서 완화되었지만, 논문에서 제안한 방법이 SOTA 달성

(A) Quantitative Performance in MvTec [3].

| | 14 – 1 with 1 Step | | 10 – 5 with 1 Step | | 3 × 5 with 5 Steps | | 10 – 1 × 5 with 5 Steps | |
|--------------------------|--------------------|-------------|--------------------|-------------|--------------------|-------------|-------------------------|-------------|
| | ACC(↑) | FM(↓) | ACC(↑) | FM(↓) | ACC(↑) | FM(↓) | ACC(↑) | FM(↓) |
| PaDim [10] | 57.5 / 77.1 | 23.1 / 20.2 | 64.4 / 81.4 | 9.1 / 14.1 | 60.0 / 76.16 | 22.6 / 20.3 | 53.9 / 68.4 | 18.1 / 24.1 |
| PatchCore [26] | 66.5 / 83.8 | 34.2 / 24.1 | 69.6 / 62.4 | 22.6 / 25.2 | 62.4 / 77.9 | 37.3 / 22.1 | 55.3 / 73.8 | 30.8 / 27.5 |
| DRAEM [35] | 51.1 / 61.2 | 8.2 / 8.2 | 58.0 / 63.2 | 11.8 / 3.9 | 54.9 / 57.6 | 2.6 / 9.8 | 52.3 / 59.0 | 13.8 / 8.8 |
| UniAD [34] | 85.7 / 89.6 | 18.3 / 13.3 | 86.7 / 91.5 | 14.9 / 10.6 | 81.3 / 88.7 | 7.4 / 10.6 | 76.6 / 82.3 | 21.1 / 17.3 |
| UniAD [34] + EWC [16] | 92.8 / 95.4 | 4.1 / 1.9 | 90.5 / 93.6 | 7.3 / 4.2 | 79.6 / 89.0 | 9.5 / 10.1 | 89.6 / 93.8 | 5.4 / 3.6 |
| UniAD [34] + SI [36] | 85.7 / 89.5 | 18.4 / 13.4 | 84.1 / 88.3 | 20.2 / 17.0 | 81.9 / 88.5 | 7.0 / 10.8 | 77.2 / 81.6 | 20.2 / 18.2 |
| UniAD [34] + MAS [2] | 85.8 / 89.6 | 18.1 / 13.3 | 86.8 / 91.0 | 14.9 / 11.6 | 81.5 / 89.0 | 7.2 / 10.2 | 77.9 / 82.0 | 19.5 / 17.7 |
| UniAD [34] + LVT [31] | 80.4 / 86.0 | 29.1 / 20.6 | 87.1 / 90.6 | 14.1 / 12.3 | 80.4 / 88.6 | 8.6 / 10.6 | 78.2 / 88.3 | 19.1 / 16.1 |
| CAD + DNE [18] | 84.5 / NA | -2.0 / NA | 87.8 / NA | 1.1 / NA | 80.3 / NA | 6.6 / NA | 77.7 / NA | 9.7 / NA |
| CAD [18] + CutPaste [17] | 84.3 / NA | -1.6 / NA | 87.1 / NA | -0.3 / NA | 79.2 / NA | 12.6 / NA | 70.6 / NA | 20.2 / NA |
| CAD [18] + PANDA [25] | 50.0 / NA | 6.0 / NA | 55.4 / NA | 8.9 / NA | 62.4 / NA | 36.8 / NA | 51.3 / NA | 10.3 / NA |
| Ours | 96.0 / 96.3 | 1.0 / 0.6 | 92.2 / 94.4 | 9.3 / 6.3 | 84.2 / 91.1 | 10.0 / 8.4 | 94.2 / 95.1 | 3.2 / 1.0 |

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Experiments

- Quantitative results

- VisA dataset에서의 결과

(B) Quantitative Performance in VisA [39].

| | 11 – 1 with 1 Step | | 8 – 4 with 1 Step | | 8 – 1 × 4 with 4 Steps | |
|--------------------------|--------------------|-------------|-------------------|-------------|------------------------|-------------|
| | ACC(↑) | FM(↓) | ACC(↑) | FM(↓) | ACC(↑) | FM(↓) |
| PaDim [10] | 59.7 / 84.3 | 20.6 / 14.2 | 60.3 / 84.2 | 21.8 / 14.0 | 54.3 / 83.4 | 21.1 / 9.7 |
| PatchCore [26] | 66.0 / 85.6 | 30.0 / 13.0 | 67.4 / 86.4 | 33.3 / 14.3 | 56.2 / 83.6 | 34.8 / 12.4 |
| DRAEM [35] | 48.4 / 60.5 | 30.6 / 15.8 | 63.6 / 49.6 | 17.7 / 29.7 | 51.8 / 63.4 | 25.9 / 10.5 |
| UniAD [34] | 75.0 / 92.1 | 22.4 / 11.4 | 78.1 / 94.0 | 14.7 / 8.4 | 72.2 / 90.8 | 16.6 / 9.2 |
| UniAD [34] + EWC [16] | 78.7 / 95.4 | 14.9 / 4.8 | 80.5 / 95.4 | 10.0 / 5.3 | 72.3 / 92.3 | 16.5 / 7.3 |
| UniAD [34] + SI [36] | 78.1 / 92.0 | 16.9 / 11.5 | 80.8 / 93.9 | 9.2 / 8.3 | 69.8 / 88.5 | 19.8 / 12.0 |
| UniAD [34] + MAS [2] | 75.4 / 91.8 | 21.5 / 11.9 | 78.4 / 94.0 | 14.1 / 8.4 | 72.1 / 90.6 | 16.7 / 9.4 |
| UniAD [34] + LVT [31] | 77.5 / 92.3 | 17.3 / 10.9 | 78.8 / 94.1 | 13.4 / 8.1 | 70.8 / 91.4 | 18.3 / 8.4 |
| CAD + DNE [18] | 71.2 / NA | -10.2 / NA | 64.1 / NA | 6.1 / NA | 58.6 / NA | 10.2 / NA |
| CAD [18] + CutPaste [17] | 65.8 / NA | 3.5 / NA | 63.2 / NA | 5.1 / NA | 56.2 / NA | 13.9 / NA |
| CAD [18] + PANDA [25] | 55.7 / NA | -1.7 / NA | 56.7 / NA | -3.3 / NA | 56.0 / NA | -0.3 / NA |
| Ours | 87.3 / 97.6 | 2.4 / 1.8 | 80.1 / 95.4 | 15.2 / 6.1 | 79.8 / 95.0 | 9.8 / 6.8 |

An Incremental Unified Framework for Small Defect Inspection (ECCV 2024)

- Experiments

- Qualitative results

- UniAD와 동일한 방법을 사용하여 히트맵 계산
 - Semantic feature 충돌을 줄일 수 있으며, 더 정확한 결함 위치를 출력 가능

