

고주파 강조 필터링을 포함하는 마스킹의 조합을 이용한 DRAEM의 텍스처 불량 감지 성능 향상

시중욱^o, 김성영^{*}

^o금오공과대학교 컴퓨터·AI융합공학과,

^{*}금오공과대학교 컴퓨터공학과

e-mail: jwsi425@kumoh.ac.kr^o, sykim@kumoh.ac.kr^{*}

Improving Texture Defect Detection Performance in DRAEM Using Combinations of Masking with High-Pass Emphasis Filtering

Jongwook Si^o, Sungyoung Kim^{*}

^oDept. of Computer·AI Convergence Engineering, Kumoh National Institute of Technology,

^{*}Dept. of Computer Engineering, Kumoh National Institute of Technology

● 요약 ●

딥러닝 모델은 영상 처리와 불량 감지 등 다양한 분야에서 높은 성능을 발휘하여 산업적으로 매우 중요하고 필수적인 기술이 되었다. 특히, 불량 감지는 제조업 분야에서 제품 품질 향상과 생산성 향상에 핵심적인 역할을 하는 기술로써 큰 관심을 받고 있다. 본 논문에서는 재건축 방식의 대표적인 모델인 DRAEM에 대해 불량 감지 성능을 향상하는 방법을 제시합니다. 이를 위해 컬러 분포의 차이를 최소화하는 손실 함수와 마스킹에 고주파 필터링을 적용하여 노이즈를 제거하는 방법을 활용한다. 이러한 방법들을 통해 DRAEM 모델의 성능을 개선하고, 정확하고 효과적인 불량 감지를 실현할 수 있다.

키워드: 불량 감지(Defect Detection), 마스킹(Masking), 이상 감지(Anomaly Detection)

I. Introduction

딥러닝은 컴퓨터 비전, 자연어 처리 등의 다양한 분야에서 높은 성과를 보여주고 있으며, 이는 산업 분야에서도 중요한 영향력을 행사하고 있다. 특히, 제조 분야에서는 제품의 생산성 및 품질 향상을 위해 불량 감지 기술이 중요하다.

불량 감지는 이상 감지에 속하는 분야이며, 제조 공정에서 발생하는 제품의 결함을 빠르게 감지하여 조치함으로써 품질을 향상시키는 것이 목표이다. 전문가의 경험에 의존하는 방식을 사용했던 과거와는 달리, 최근에는 딥러닝 모델을 이용한 감지 방법이 주로 사용되고, 이에 따른 관련 연구도 진행중에 있다[1-2].

본 논문에서는 불량 감지를 할 수 있는 재건축 방식의 모델인 DRAEM[3]에 대하여 새로운 접근법을 제시하여 Texture의 불량 감지 성능을 향상하는 방법에 대해 소개한다. 이를 위해 컬러 분포의 차이를 최소화하는 손실 함수[2]를 딥러닝 네트워크에 적용을 한다. 그리고 여러 단계의 마스킹에 고주파 강조 필터링을 적용하여 노이즈를 제거하는 후처리 방법에 대해 제안한다. 이러한 방법을 통해 DRAEM의 모델 성능을 개선하고 효과적인 Texture의 불량 감지를 할 수 있다.

II. Enhancing Performance of DRAEM

본 논문에서 제안하는 방법은 재건축 방식의 DRAEM 모델에 컬러 분포를 최소화하는 손실 함수를 추가한 결과를 생성한다. 이를 통해 후처리 방식을 통해 성능을 향상하는 방식이다. 후처리 방식에는 마스킹에서 고주파 필터링을 다양한 크기에 따라 생성한 결과를 활용하고 점수 산출 방식을 상대적인 값으로 변경하여 성능을 향상시킨다.

DRAEM의 모델은 크게 재건축을 진행하는 Reconstructive sub-network와 검출하기 위한 Discriminative sub-network들로 구성되어 있다. Reconstruction을 위해 (1)과 같은 손실 함수를 추가하여 정의한다.

$$L_{rec}(I, I_r) = L_2 + L_s + \lambda_c L_c + \frac{1}{L_p} \quad (1)$$

L_c 는 각각의 색상 채널에 대한 히스토그램을 계산하여 분포의 차이를 최소화 하도록 정의한다. L_p 는 PSNR을 의미하며 값이 커질수록 차이가 작은 것을 의미하는데, 이를 역수 형태로 사용하여 일정

PSNR 값을 달성하면 학습 시에 가중을 덜 하도록 한다.

언사프 마스크는 (2)와 같이 원본 이미지(f)와 블러링된 이미지(\bar{f}) 간의 차이를 이용해 고주파 성분을 강조하는 방식의 결과(h)를 생성한다.

$$\begin{aligned} h(I) &= f(I) + \alpha(f(I) - \bar{f}(I)) \\ &= (1 + \alpha)f(I) - \alpha\bar{f}(I) \end{aligned} \quad (2)$$

본 논문에서는 언사프 마스크 구조에서 블러링된 이미지가 아닌 (3)과 같이 선명화된 이미지(\acute{f})와 원본 이미지 차이에 가중치를 적용해 저주파 성분을 강조한 결과(\acute{h})를 생성한다. 커널의 크기를 3과 5인 경우를 모두 활용하여 저주파 성분을 강조하고 Average Pooling한 원본 영상과 결합하여 이미지에서 노이즈를 제거하는 방향으로 결과를 생성한다. 모든 결과들에 대하여 Stride를 4로 주어 최종 이미지를 생성한다.

$$\acute{h}(I) = f(I) + \alpha(f(I) - \acute{f}_3(I)) + \beta(f(I) - \acute{f}_5(I)) \quad (3)$$

선명화된 이미지는 라플라시안 타입 선명화 필터링을 사용하여 모든 방향으로 이미지의 상세 정보를 강화하도록 한다. 이 때, \acute{f}_3 과 \acute{f}_5 에서 사용된 필터는 (4), (5)에 나타낸다. 또한, 모든 필터에는 가우시안 노이즈를 추가한다.

$$\acute{f}_3 = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{bmatrix} + G_\alpha \quad (4)$$

$$\acute{f}_5 = \begin{bmatrix} -1 & -4 & -6 & -4 & -1 \\ -4 & -16 & -24 & -16 & -4 \\ -6 & -24 & 476 & -24 & -6 \\ -4 & -16 & -24 & -16 & -4 \\ -1 & -4 & -6 & -4 & -1 \end{bmatrix} + G_\beta \quad (5)$$

기존 DRAEM은 최댓값을 나타내는 픽셀 하나만을 이용하여 점수를 산정한다. 하지만, 이는 카테고리 마다 값이 다르기 때문에 보정이 필요하다. 따라서, 점수 산정 방식을 이미지 생성 결과에서 최댓값에 대하여 최솟값으로 나누는 방향으로 수정한다.

DRAEM에서 평가에 사용한 MvTec-AD[4]에서 Texture만을 통해 성능 평가를 진행한다. $\lambda_c=0.1$, $\alpha=0.2$, $\beta=0.1$ 로 고정하고, 성능 평가에는 Ubuntu 18.04 LTS 환경에서 Geforce RTX 3090를 기반으로 한다. 성능 평가에 대한 결과는 표 1과 같다. 본 논문에서 제안하는 방법을 모두 사용하였을 때 99.4%로 0.3%의 성능 향상 결과를 보인다.

Table 1. Performance Evaluation

Category	DRAEM	Ours
Wood	99.1	97.7
Tile	99.6	99.6
Carpet	97.0	99.5
Grid	99.9	100.0
Leadther	100.0	100.0
AVG	99.1	99.4

III. Conclusions

본 논문에서는 DRAEM이라는 재건축 방식의 불량 감지 딥러닝 네트워크의 성능을 향상시키기 위해 색상 분포와 역수 형태의 PSNR 손실 함수를 도입하였다. 또한, 점수 산정 방식을 수정하고 마스크에 고주파 강조 필터링을 사용하여 노이즈를 제거하여 성능을 개선하였다.

ACKNOWLEDGEMENT

본 연구는 2021년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [S3174988]

REFERENCES

- [1] J. Si and S. Kim, "Surface Anomaly Detection of Wood Grain Image Using Fourier Transform : A Preliminary Study", Proc. Of KIIT, pp. 84-85, 2022.
- [2] J. Si and S. Kim, "Defect Detection of Reconstruction Methods with Color Histogram Loss Function", Proc. Of KIIECT, pp. 73-75, 2023.
- [3] V. Zavrtanik, M. Kristan, and D. Skočaj, "DRAEM - A Discriminatively Trained Reconstruction Embedding for Surface Anomaly Detection" Proc. Of the IEEE/CVF International Conference on Computer Vision, pp. 8330-8339, 2021.
- [4] Bergmann, Paul, et al. "MVTec AD—A comprehensive real-world dataset for unsupervised anomaly detection", Proc. Of the IEEE/CVF conference on computer vision and pattern recognition, pp. 9592-9600, 2019.