creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학전문석사 학위 연구보고서

다중입력 딥 네트워크를 이용한 금속 표면 디펙의 디포커스 디블러링에 관한 연구

Defocus Deblurring for Metal Surface Defect Using Multiple Inputs Deep Networks

2022년 2월

서울대학교 공학전문대학원
응용공학과 응용공학전공
김홍득

다중입력 딥 네트워크를 이용한 금속 표면 디펙의 디포커스 디블러링에 관한 연구

Defocus Deblurring for Metal Surface Defect Using Multiple Inputs Deep Networks

지도교수 최 진 영

이 프로젝트 리포트를 공학전문석사 학위
연구보고서로 제출함
2022년 2월

서울대학교 공학전문대학원
응용공학과 응용공학전공
김홍득

김홍득의 석사 학위 연구보고서를 인준함
2022년 2월

위원장 구 윤 모 (인)
위 원 한 훈 (인)
위 원 최 진 영 (인)

초 록

최근 딥러닝의 급속한 발전에 따라 산업계에서는 불량 검출, 불량 분류, 그리고 불량 분석 등 다양한 분야에 딥러닝 기술을 활용하고 있다. 2015년 발표된 ResNet의 경우 이미지 분류 정확도에서 인간을 뛰어 넘는 성능을 보여주었으며 이미지 분류의 기본 모델로 다양하게 사용되고 있다. 이러한 딥러닝의 뛰어난 성능은 대용량 데이터 분석 시 기존 엔지니어(Engineers)와 오퍼레이터(Operators)가 분석할 때보다 빠르고 정확하게 분석할 수 있게 하며 기업의 생산성 향상에 기여하고 있다.

본 논문에서는 광학 검사 중 발생할 수 있는 디포커스 블러(Defocus Blur) 상황에서 흐릿한 이미지를 선명하게 복원하고 복원된 이미지를 얼마나 정확히 분류 할 수 있는가에 대한 문제를 다룬다. 블러 필터(Blur Filter) 크기를 변화시키면서 디포커스 블러 이미지를 다양하게 생성하고 실 상황에서 강인한 분류 성능을 낼 수 있는 방안을 모색한다.

이미지 복원에서 사용되는 UNet 모델을 기초로 디포커스 디블러(Defocus Deblur) 완성도를 평가하며 보다 뛰어난 성능을 위해 새로운 블러 데이터셋을 구축하고 다중입력(Multiple Inputs) UNet (MIUNet)을 제안한다. 디포커스 디블러 성능에 대한 평가는 복원 전과 후의 이미지 분류 정확도를 이용해서 평가하며 이미지 분류 정확도 평가는 분류 성능이 뛰어난 ResNet을 이용한다. 블러 필터로 만들어진 디포커스 블러 디펙 이미지를 MIUNet으로 복원한 후 이미지 분류 정확도가 개선됨을 보인다.

본 연구를 통해 제조 현장에서 디포커스 디블러로 복원된 이미지의 사용 가능성과 디포커스 디블러 성능이 블러 정도에 따라 성능의 편차가 있다는 한계점을 동시에 확인한다. 실제 제조 현장 상황을 가정하여 선명

한 이미지와 흐릿한 이미지가 섞인 케이스별로 디포커스 디블러를 적용한 결과 적용하기 전보다 이미지 분류 정확도가 개선됨을 보인다. 본 연구 결과를 제조 현장에 적용함으로써 디포커스 블러로 인해 정확하게 분류하지 못했던 이미지를 정확하게 분류할 수 있을 것으로 기대하며 이는 제조 경쟁력을 확보하는데 기여할 것이다.

주요어 : 디포커스, 디블러링, 다중입력 딥 네트워크, 이미지 분류, 딥러닝.
학번 : 2020-22370

목 차

I. 서론 **1**

1.1 연구 동기 1

1.2 문제정의 및 연구 내용 2

1.3 논문의 구성 3

II. 관련 연구 **4**

2.1 관련 딥러닝 연구 4

2.1.1 이미지 분류 연구 현황 4

2.1.2 ResNet 8

2.1.3 UNet 10

2.2 블러 및 디블러 10

2.2.1 블러 종류 10

2.2.2 디포커스 블러 13

2.2.3 디포커스 디블러 15

III. 본문 **16**

3.1 Multiple Inputs UNet 16

3.1.1 Multi Blur Dataset 16

3.1.2 MIUNet Architecture 19

3.2 실험 데이터 구성 및 실험방법 22

3.2.1 실험 데이터셋 구성 22

3.2.2 실험방법 25

3.3 실험결과 27
3.3.1 디포커스 디블러 결과 27
3.3.2 디포커스 디블러 후 이미지 분류 결과 31

IV. 결론 **43**

참고 문헌 **45**

Abstract **49**

그 림 목 차

그림 1. 제조 현장에서 광학 검사 활용. 1
그림 2. 선명한 이미지[1]와 흐릿한 이미지. 2
그림 3. 사각형 분류를 위한 필터 예시. 5
그림 4. LeNet 네트워크 구조. 6
그림 5. 합성곱(Convolution) 연산. 7
그림 6. 잔차 블럭(Residual Block). 8
그림 7. UNet 네트워크 구조. 9
그림 8. 블러(Blur) 종류. 11
그림 9. 피사계심도와 착란원. 13
그림 10. 피사체 위치에 따른 착란원 크기 변화. 14
그림 11. Multi Blur(MB) Dataset. 17
그림 12. UNet과 MIUNet 네트워크 비교. 18
그림 13. MIUNet 실험결과 1. 19
그림 14. MIUNet 실험결과 2. 20
그림 15. MIUNet 실험결과 3. 21
그림 16. NEU-CLS 데이터셋. 23
그림 17. 블러 필터 크기에 따른 디포커스 블러 디펙 이미지. . 24
그림 18. 실험 방법. 25
그림 19. 클래스별 블러 필터 크기에 따른 블러 이미지. 26
그림 20. 디포커스 디블러 결과 - crazing. 28
그림 21. 디포커스 디블러 결과 - inclusion. 28
그림 22. 디포커스 디블러 결과 - patches. 29

그림 23. 디포커스 디블러 결과 - pitted surface. 29
그림 24. 디포커스 디블러 결과 - rolled-in scale. 30
그림 25. 디포커스 디블러 결과 - scratches. 30
그림 26. 디포커스 디블러 후 분류 성능 그래프. 32
그림 27. 디포커스 디블러 후 분류 성능 - crazing. 34
그림 28. 디포커스 디블러 후 분류 성능 - inclusion. 35
그림 29. 디포커스 디블러 후 분류 성능 - patches. 36
그림 30. 디포커스 디블러 후 분류 성능 - pitted surface. 37
그림 31. 디포커스 디블러 후 분류 성능 - rolled-in scale. 38
그림 32. 디포커스 디블러 후 분류 성능 - scratches. 39
그림 33. 디포커스 디블러 적용 전후 이미지 분류 정확도. . . . 42

표 목 차

표 1. MIUNet 실험 환경 정보. 22
표 2. 디포커스 블러 이미지 생성 과정. 24
표 3. MIUNet 실험 조건. 27
표 4. 디포커스 블러 및 디블러 분류 정확도. 31
표 5. 디포커스 디블러 평가 - 케이스별 데이터 구성. 40
표 6. 디포커스 디블러 전 케이스별 분류 정확도. 41
표 7. 디포커스 디블러 후 케이스별 분류 정확도. 41

제 1 장

서론

1.1 연구 동기

2000년대 이후 서비스 산업의 비율이 늘어나고 많은 발전을 하고 있다. 이와 함께 철강, 반도체, 화학 등 제조 산업에서도 다양한 변화와 발전이 이뤄지고 있다. 특히 과학과 IT기술의 발전은 제조 산업에도 큰 영향을 미치고 있다. 예를 들어 광학 기술과 컴퓨터의 발전 덕분에 제조 현장에서 발생하는 불량에 대한 분석 업무를 정량적으로 빠르고 정확하게 분석할 수 있게 됐다. 이는 제조 현장에서 발생하는 불량을 개선하고 기업의 수익성을 향상시키는데 기여하고 있다.

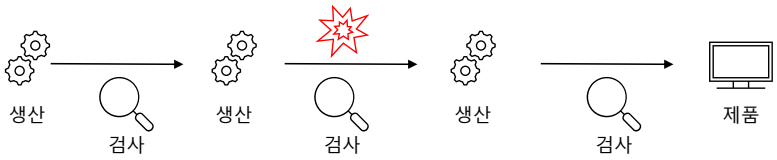

그림 1: 제조 현장에서 광학 검사 활용.

또한 2012년 이후 급속도로 발전한 딥러닝 분야 또한 제조 산업에서 다양한 방식으로 도움을 주고 있다[2, 3]. [그림 1]에서 보는 것처럼 대부분의 제조 산업에서는 광학 검사(AOI : Automatic Optical Inspectaion)로 제품의 이상 여부를 확인한다. 그리고 그 광학 검사 이미지로 불량을 분석하고 개선해서 생산성을 높인다. 하지만 이를 위해서는 제조 현장의 유지

관리가 매우 중요하다. 특히 광학 검사에서 불량 이미지를 촬영할 때는 선명한 이미지를 얻기 위해서 카메라의 흔들림이 없도록 설정하고 렌즈의 초점이 피사체에 정확히 맞도록 해야 한다. 하지만 생산 설비의 셋업 문제, 유지보수, 설비 고장, 사용자의 실수 등 다양한 원인으로 [그림 2]에서 보는 것과 같이 불량 이미지가 선명하지 않게 촬영되는 경우가 발생한다. 그러한 경우 대용량 데이터를 신속하고 정확하게 분류하는 딥러닝 이미지 분류 기술이 얼마나 효용이 있으며 문제가 있다면 해결할 수 있는 방법이 있는지에 대한 연구가 필요하다.

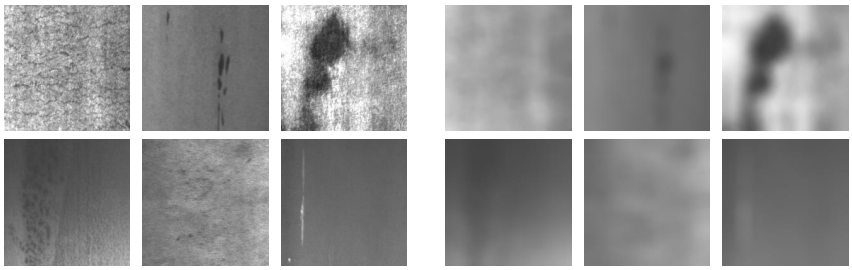

(a) 선명한 이미지 (b) 흐릿한 이미지

그림 2: 선명한 이미지[1]와 흐릿한 이미지.

1.2 문제정의 및 연구 내용

본 연구의 목적은 디포커스 블러 이미지의 분류 정확도를 확인하고 그 디포커스 블러 이미지를 최신 딥러닝 기술로 복원해서 복원된 이미지의 분류 정확도가 복원하기 전보다 얼마나 개선되는지 알아보는 것이다. 먼저, 선명한 이미지를 ResNet[4]에 입력해서 이미지 분류 성능을 측정한다. 그리고 블러 정도에 따라서 이미지 분류 성능이 어떻게 변하는지 확인한다. 그다음 UNet[5]과 MIUNet 모델로 디포커스 블러 이미지를 복원한

후 디포커스 디블러 모델별로 이미지 분류 정확도를 비교한다.

본 연구에서 사용되는 데이터셋은 NEU-CLS[1]라는 금속 표면 디펙(Steel Surface Defect) 데이터셋이다. 공개된 디펙(Defect) 데이터셋 중 가장 다양하게 연구[6, 7, 8, 9, 10, 11, 12, 13]되는 데이터셋이고 비교적 디펙 이미지의 특징이 확실해서 이미지 분류 성능을 비교하는데 가장 적절한 데이터셋이다. 그리고 가장 중요한 디포커스 블러 상태의 디펙 이미지를 얻는 것은 불가능하기 때문에 디포커스 이론을 바탕으로 블러 정도를 차별화하여 데이터셋을 구축한 후 연구를 진행한다.

1.3 논문의 구성

본 논문의 구성은 다음과 같다. 먼저 제 2장에서는 본 연구와 관련된 연구를 소개하여 본 연구의 목적과 결과를 이해하는데 도움이 될 수 있도록 한다. 다음으로 제 3장에서는 구체적인 실험 방법과 결과를 설명하고, 본 연구의 목적에 부합한 결과가 도출됐는지 검증 결과를 제시한다. 마지막으로 제 4장에서는 본 연구를 요약하고 연구 의의에 대해서 논의하고 향후 필요한 연구 내용과 방향에 대해서 고찰한다.

제 2 장

관련 연구

2.1 관련 딥러닝 연구

2.1.1 이미지 분류 연구 현황

이미지 분류 기술은 이미지 내의 사물이 무엇인지 분류하는 컴퓨터 비젼의 한 분야로 많은 연구자들이 관심을 갖고 연구해왔으나 좋은 성능을 얻기 어려운 분야였다. 처음에는 해당 사물의 특징을 필터로 만들고 분류하고자 하는 이미지에 필터가 매칭되는 정도를 계산해서 이미지를 분류했다. 예를 들어 [그림 3]과 같이 도형이 어떤 도형인지 분류하는 문제를 생각해보자. 도형이 사각형인지 확인하기 위해서는 직각의 모서리가 4 개 있는지 확인하면 된다. 즉, 사각형의 각 모서리를 필터로 만들어서 분류하면 되기 때문에 비교적 쉬운 문제라고 할 수 있다. 하지만 위와 같은 방법은 평면 위에 그려진 도형과 같이 단순한 이미지를 분류할 때는 활용할 수 있지만 현실에서는 다음과 같은 어려움이 있다.

- **Intra-class variation :** 호랑이, 치타, 표범, 고양이와 같이 비슷한 특징을 갖는 이미지를 분류하는데 한계를 가진다.
- **Viewpoint variation :** 동일한 사물을 다양한 각도에서 촬영하는 경우 이미지에 찍힌 모습이 크게 달라지기 때문에 모든 특징을 필터로 분류하기는 매우 어렵다.

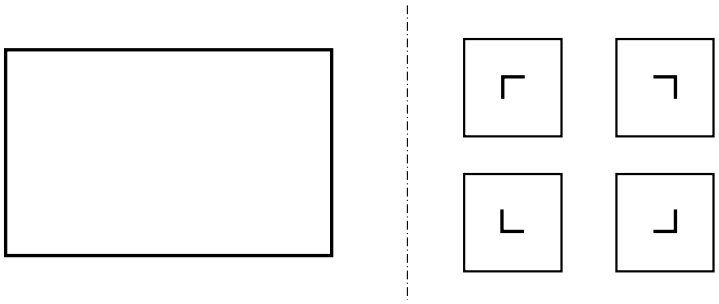

(a) 사각형 모양의 도형 (b) 사각형 분류 필터

그림 3: 사각형 분류를 위한 필터 예시.

- **Occlusion :** 모든 필터를 포함하고 있다고 하더라도 해당 이미지에서 그 특징을 표현하는 부분이 가려져 있다면 분류 정확도는 감소하게 된다.
- **Illumination :** 우리가 사물을 보는 것은 광원에서 나온 빛이 사물에 반사된 후 보이는 것인데 광원에 위치에 따라서 사물은 매우 다른 모습으로 보여질 수 있으며 그런 경우 주어진 필터로 이미지를 분류하는데 한계가 발생한다.

딥러닝의 발전은 이러한 어려움 해결에 큰 도움을 주었다. 딥러닝을 이용한 이미지 분류는 앞서 언급한 것과 같이 이미지 분류를 위해서 이미지 속 사물의 특징을 별도로 입력할 필요가 없다. 충분한 수의 이미지를 가지고 딥러닝을 이용해서 학습하면 딥러닝 모델 스스로 이미지를 분류하기 위한 적절한 필터를 만들게 된다. 딥러닝을 이용해서 이미지 분류 연구를 진행한 구체적인 사례로 우편번호 분류 시스템를 말할 수 있다.

Yann Lecun [14] 은 우정국과 함께 우편번호 자동 분류 시스템에 대한 연구를 진행했다. LeNet[14]이라 불리는 합성곱 신경망(CNN : Convolution Neural Networks)을 통해서 0 에서 9 사이의 숫자를 매우 정확하게 분류하는 연구를 성공적으로 이끌었다. LeNet은 [그림 4]와 같이 합성곱 레이어(Convolution Layer)와 풀링 레이어(Pooling Layer), 그리고 완전연결 레이어(Fully Connected Layer)로 구성되어 있다. 합성곱 레이어에서는 주어진 이미지의 특징을 추출하기 위해서 [그림 5]와 같이 합성곱 연산을 진행한다.

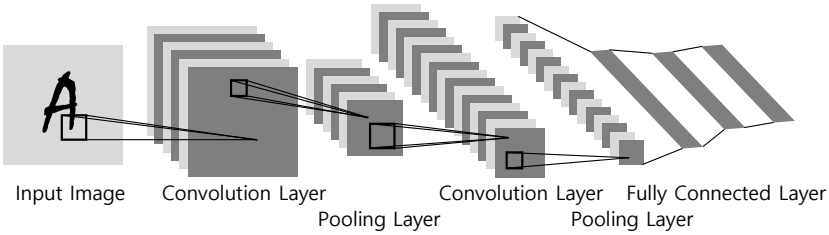

그림 4: LeNet 네트워크 구조.

이미지 분류 대회인 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에서 2012년 AlexNet[15]이 뛰어난 성능을 보여준 후 딥러닝에 기반한 CNN 이미지 분류에 다시 사람들이 관심을 갖기 시작했다. 이후 VGGNet[16], GoogLeNet[17], 그리고 ResNet[4]이 발표되면서 딥러닝은 많은 분야에서 다양하게 활용되기 시작했다. 특히 최근에는 자율주행 분야에서 차량이 사물을 인식하고 분류하는 것과 관련해서 많은 연구[18, 19, 20, 21]가 진행되고 있으며 실제 자동차 산업에서도 사용되고 있다.

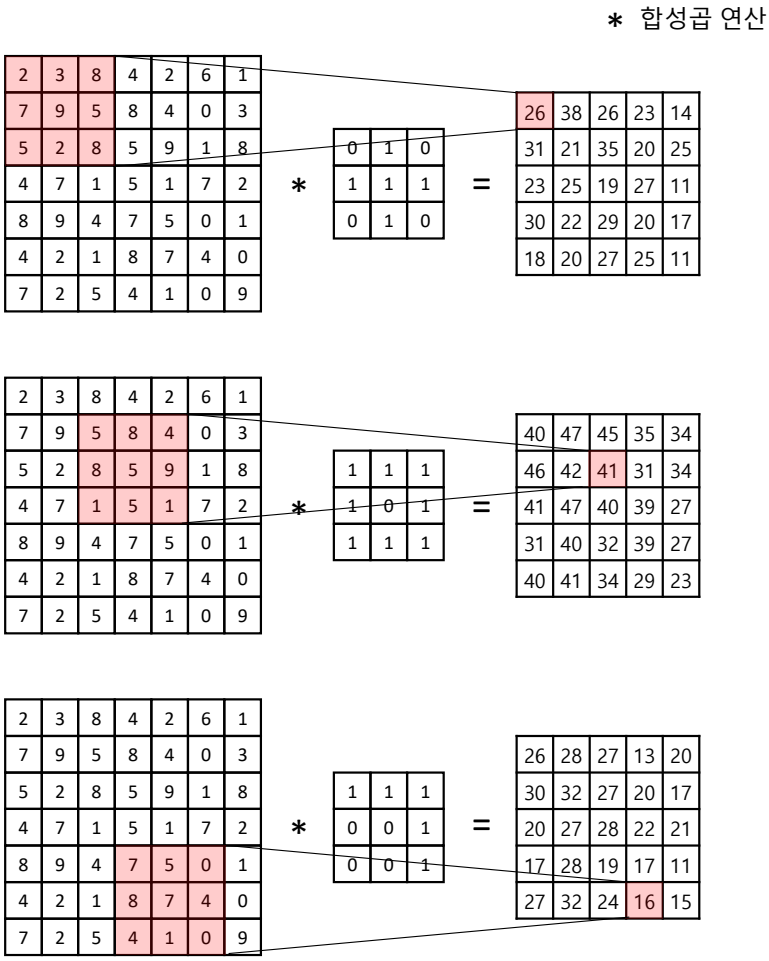

(a) input (b) filter (c) output

그림 5: 합성곱(Convolution) 연산.

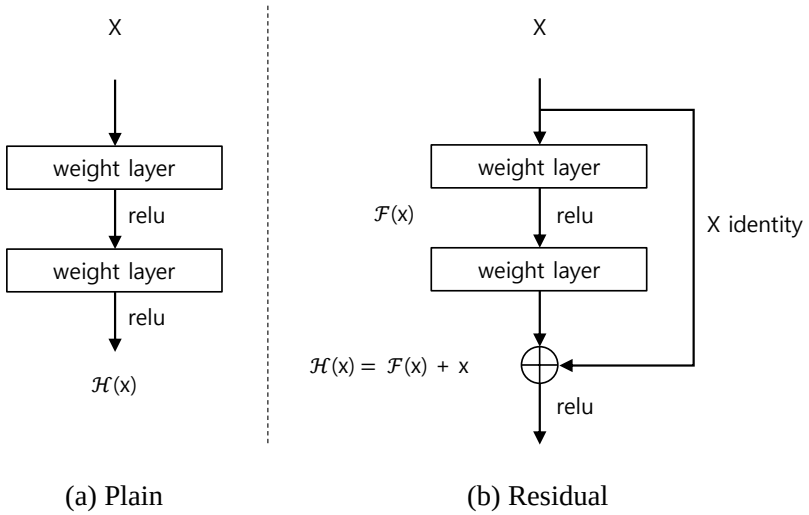

(a) Plain (b) Residual

그림 6: 잔차 블럭(Residual Block).

2.1.2 ResNet

이미지 분류 분야에서 8 Layer의 CNN으로 AlexNet이 뛰어난 성능을 보여준 후 합성곱 레이어를 점차 깊게 쌓아가면서 더 좋은 성능을 보여주는 딥러닝 모델이 지속적으로 발표됐다. ILSVRC 대회에서 VGGNet은 19 Layer로 7.3% 에러율(Error Rate)을 보여주었으며 GoogLeNet은 22 Layer로 6.7% 에러율을 보여주었다. 하지만 단순히 합성곱 레이어를 더 많이 쌓아가는 것이 항상 더 정확한 성능을 보여주는 것은 아니었다. 단순히 학습(Training) 진행 중 학습 데이터(Training Data)의 학습 손실값(Loss)은 떨어지는데 테스트 데이터(Test Data)의 학습 손실값이 올라가는 과적합(Overfitting)의 문제가 아니었다. CNN으로 이미지를 분류하는 네트워크의 구조는 기본적으로 학습을 한 후에 손실값을 계산해서 경사하강법(Gradient Descent) 방법으로 모델을 최적화해 나간다. 그런데 CNN

모델이 깊어짐에 따라 경사값이 작아지면서 경사값들의 곱이 0에 가까워지게 되고 학습이 더이상 되지 않는 기울기 소실 문제(Vanishing Gradient Problem)가 발생한다. 기존의 일반적인 CNN 모델(Plain)에서는 $H(x)$를 학습하지만 ResNet에서는 이를 극복하기 위해서 [그림 6]에서 보는 것과 같이 잔차 블럭(Residual Block)을 도입해서 $F(x) = H(x) - x$ 를 학습하게 된다. 이를 통해서 기울기 소실 문제를 해결하고 152 Layer의 CNN을 구성함으로써 기존 모델보다 약 8 배나 더 깊은 딥러닝 모델을 효과적으로 학습할 수 있게 했다. 그 결과 3.57%의 에러율로 ILSVRC에서 최고의 성능을 보여주었다. 이는 인간의 정확도로 알려진 5%의 에러율보다 뛰어난 결과를 기록한 것이다.

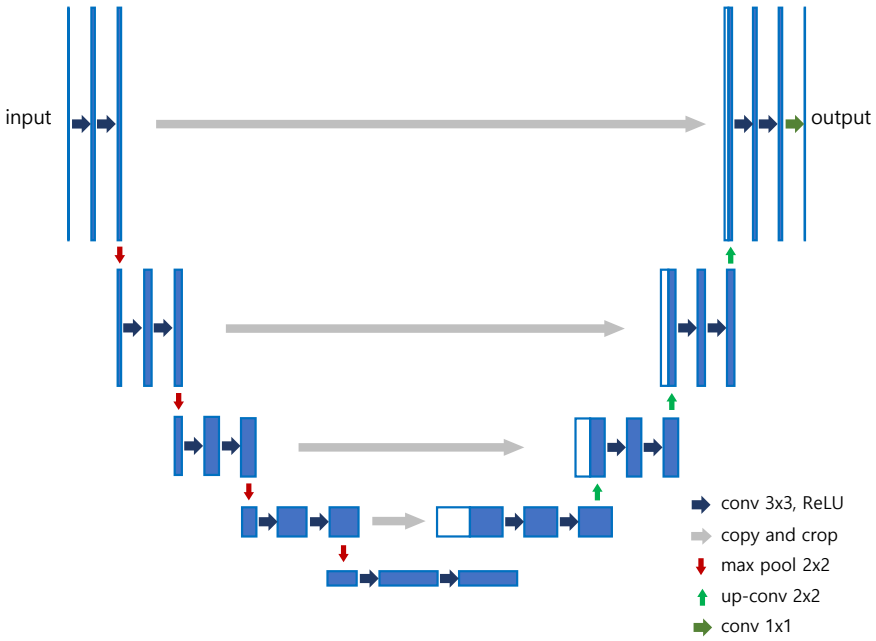

그림 7: UNet 네트워크 구조.

2.1.3 UNet

UNet은 2015년 생물의학(Biomedical) 이미지 분할(Segmentation)에서 뛰어난 성능을 보여준 논문이다. 일반적으로 딥러닝 네트워크가 좋은 성능을 내기 위해서는 많은 학습 데이터가 필요한데 UNet은 적절한 인자(Argumentation)를 사용하여 데이터셋 수가 부족한 환경에서도 좋은 성능을 보여 주었다. 그리고 기존 Sliding Window[22] 방식과 달리 중복되는 영역을 줄이고 네트워크에 완전연결레이어가 없어서 기존 방식보다 빠른 성능을 보여주었다. [그림 7]에서 보는 것처럼 UNet은 인코더(Encoder)라고 불릴 수 있는 Contracting Path가 네트워크 왼쪽에 위치하고 있고 디코더(Decoder)라고 불릴 수 있는 Expanding Path가 네트워크 오른쪽에 위치한 모습으로 구성되어 있다. Contracting Path는 Context를 캡쳐하는 역할을 하고 Expanding Path는 보다 뛰어나게 Localzation하는 역할을 한다. UNet은 기본적으로 이미지 분할을 위해서 발표된 딥러닝 모델이지만 노이즈 제거(Denoising), 슈퍼 해상도(Super Resolution) 등 이미지 복원에서도 빠르고 정확한 성능을 보여주었고 다양한 분야에서 기본 모델로 많이 활용되고 있다. 본 논문에서는 UNet을 기반으로 만들어진 MIUNet을 제시하고 UNet과 MIUNet의 디포커스 디블러 성능을 비교한다.

2.2 블러 및 디블러

2.2.1 블러 종류

우리는 주변에서 [그림 8]과 같이 안개(Haze), 디포커스 블러(Defocus Blur), 모션 블러(Motion Blur), 가우시안 블러(Gaussian Blur) 등 다양한 블러[23, 24]를 접할 수 있다. 그 중에서 공기 중 빛의 산란에 의해 뿌옇게

(a) 안개

(b) 디포커스 블러

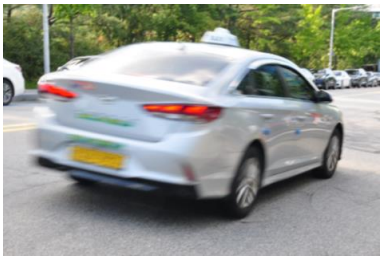

(c) 모션 블러

(d) 가우시안 블러

그림 8: 블러(Blur) 종류.

흐려져 보이는 안개는 우리 주변에서 쉽게 볼 수 있다. 안개 현상은 아래와 같은 수식으로 표현된다.

$$\text{안개} : I(x) = t(x)J(x) + (1 - t(x))A. \tag{2.1}$$

위 식에서 $I(x)$는 안개가 낀 이미지(Observed Haze Image), $t(x)$는 대기 투과율(Medium Transmission), $J(x)$는 안개가 없는 원본 이미지(Scene Radiance), 그리고 A는 대기 산란광(Airlight)을 지칭한다.

다음으로 사진을 촬영하면서 피사체를 강조하기 위해서 배경을 흐리게 하는 디포커스 블러가 있다. 디포커스 블러는 아래와 같은 수식으로

표현된다.

$$\text{디포커스 블러} : h(x,y) = \begin{cases} \dfrac{1}{\pi r^2} & \text{if}(x-k)^2+(y-l)^2 \le r^2, \\ 0 & \text{elsewhere} \end{cases} \quad . \qquad (2.2)$$

위 식에서 x과 y는 위치를 표현하고 r은 블러 필터 크기로 흐릿한 정도를 표현한다.

모션 블러는 피사체를 강조하기 위해서 빠르게 움직이는 피사체를 따라가면서 촬영해서 배경을 일정한 방향으로 흐리게 만드는 경우 또는 의도와 다르게 카메라가 흔들리는 경우 발생한다. 셔터스피드 속도에 따라서 다양하게 촬영될 수 있으며 모션 블러는 아래와 같이 표현될 수 있다.

$$\text{모션블러} : h(x,y) = \begin{cases} \dfrac{1}{M} & \text{if } x\sin(w)+y\cos(w)=0, x^2+y^2 \le \dfrac{M^2}{4} \\ 0 & \text{elsewhere} \end{cases} \quad .(2.3)$$

가우시안 블러는 가우시안 함수(Gaussian Function)를 사용해서 이미지를 흐릿하게 만드는 이미지 편집 기술이며 아래와 같은 식으로 표현될 수 있다.

$$\text{가우시안 블러} : h(x,\sigma) = \frac{1}{\sqrt{2\pi}\sigma}\exp(-\frac{x^2+y^2}{2\sigma^2}), x \in R. \qquad (2.4)$$

본 연구에서는 다양한 블러 중에 광학검사와 관련도가 높은 디포커스 블러에 대해서 다루도록 하겠다.

2.2.2 디포커스 블러

디포커스 블러는 사진을 촬영할 때 초점이 맞지 않아 흐릿하게 된 현상을 말하며 다른 말로 아웃포커스(Out-of-focus) 또는 보케(Bokeh)라고 표현하기도 한다. 일반적으로 디포커스 블러는 피사체를 강조하기 위해서 피사체를 선명하게 하고 배경을 흐릿하게 표현한다. 이렇게 하기 위해서는 렌즈를 투과해 굴절된 빛인 착란원(COC : Circle of Confusion)이 하나의 필셀에 모이지 않고 주변 픽셀로 분산되서 흐리게 보이도록 해야 한다. 구체적인 방법으로는 [그림 9]에서 보는 것처럼 피사체를 피사계심도(DOF : Depth of Field)에서 벗어난 곳에 위치시키거나 조리개를 보다 크게 열어 피사계심도 구간을 얕게 만드는 방법이 있다.

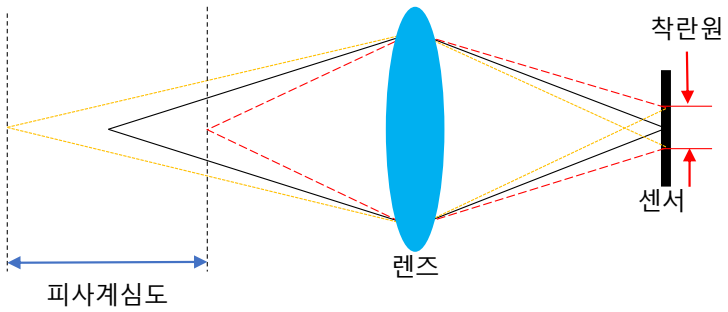

그림 9: 피사계심도와 착란원.

[그림 10]의 (b)와 같이 피사체에 반사된 빛이 렌즈를 통해서 하나의 이미지 센서 안에 들어오면 피사체는 선명하게 보인다. 하지만 [그림 10]의 (a)와 (c) 같이 피사체에서 반사된 빛이 렌즈를 투과한 후 픽셀 밖으로 벗어나는 경우 우리는 흐릿한 사진을 얻게 된다. 흐릿한 정도에 영향을 주는 요소로는 렌즈의 곡률, 조리개 크기, 카메라와 피사체 간의 거리 등 다양한 요소가 있다. 조리개를 크게 열면 피사계심도가 얕아져서 초점이

맞지 않는 범위가 늘어나며 흐릿한 이미지를 얻게 된다. 피사계심도 관점에서 보면 피사계심도 범위가 넓으면 피사계심도가 깊다고 표현하고 전체적으로 선명한 결과을 얻을 수 있다. 반면 피사계심도 범위가 좁으면 피사계심도가 얕다고 표현하고 초점을 맞춘 피사체 외에 사물은 흐릿하게 표현된다.

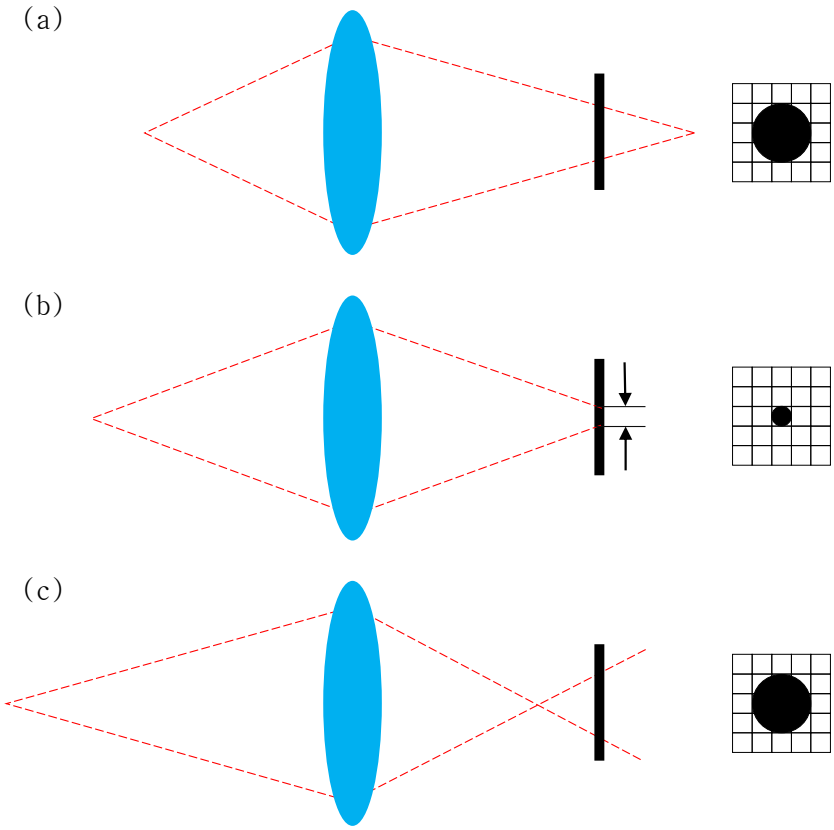

그림 10: 피사체 위치에 따른 착란원 크기 변화.

2.2.3 디포커스 디블러

피사체가 피사계심도를 벗어나 흐릿해진 이미지를 복원하는 디포커스 디블러는 다른 이미지 복원과 달리 2 가지 어려움이 있다. 첫째, 하나의 이미지 안에서도 피사체의 거리에 따라 착란원이 달라지기 때문에 하나의 사진(One Scene)에 다양한 블러가 포함된다. 디포커스 맵(Defocus Map)[25, 26, 27]을 통해서 위치에 따른 흐릿한 정도를 눈으로 확인할 수 있으며 그 정보를 활용해서 각기 다른 블러 정도를 계산해서 복원해야 한다. 블러 정도를 정확히 계산해서 복원하는 것은 현실적으로 제약이 많다. 각 위치 별로 블러 정도에 맞는 필터를 적용해서 복원을 해야하기 때문이다. 둘째, 카메라에 찍힌 피사체는 실제로 3차원 공간에 있기 때문에 피사체의 경계선 안쪽과 바깥쪽 사물의 위치가 연속적이지 않고 갑자기 변하는 경우가 발생한다. 그래서 그 경계선에 적합한 디블러 필터를 계산해서 적용해야 하는데 이를 계산하는 것은 매우 어렵다.

이러한 여러움 속에서 딥러닝을 사용해서 디포커스 디블러하는 연구가 다양하게 진행되고 있다. 2020년 딥러닝을 사용해서 디포커스 디블러를 연구한 예로 Abuolaim과 Brown의 연구[28]가 있다. 해당 연구는 Dual Pixel(DP)을 활용해서 디포커스 디블러 연구를 진행했다. 구글 스마트폰과 캐논 카메라에는 각 픽셀(Pixel)이 좌우 2개로 나뉘어 있는 DP가 있어서 추가 정보를 얻을 수 있다. 하나의 픽셀이 왼쪽 센서(Left Photodiode)와 오른쪽 센서(Right Photodiode)로 구성되어 있어서 추가 이미지를 추출할 수 있다. 추가 이미지를 각각 입력해서 디포커스 디블러 연구를 진행했으며 의미있는 결과를 얻었다.

제 3 장

본문

3.1 Multiple Inputs UNet

MIUNet은 UNet을 기반으로 해서 만든 디포커스 디블러 딥러닝 네트워크 모델이다. MIUNet은 3 가지 특징을 가지고 있다. 첫째, 디포커스 디블러 성능을 향상시키기 위해 테스트 데이터보다 피사계심도가 얕은 트레이닝 데이터로 딥러닝 네트워크를 학습했다. 이를 통해서 더 다양한 블러에 대해서 학습할 수 있었다. 둘째, 입력 이미지를 한 장이 아닌 두 장을 입력해서 입력 채널이 6 채널(6-channels)로 모델을 구성했다. 한 장의 입력 이미지를 받는 UNet보다 학습 시간은 오래걸렸지만 학습이 안정적으로 진행됐으며 디포커스 디블러 성능은 더욱 뛰어났다. 셋째, MIUNet은 새로운 디포커스 블러 데이터셋을 구축해서 연구를 진행했다. 새로운 데이터셋(Multi Blur Dataset)과 새로운 네트워크(MIUNet)에 대해서 더 자세히 알아보도록 하자.

3.1.1 Multi Blur Dataset

디포커스 디블러는 다른 이미지 복원보다 어렵다. 하나의 이미지에도 위치에 따라 다양한 블러가 존재하기 때문에 하나의 필터로 복원할 수 없다. 피사체가 피사계심도 구간 안에 있으면 선명하게 보이지만 피사체가 피사계심도에서 벗어나면 블러가 발생하기 시작한다. 그리고 피사체가 피사계심도에서 멀어질수록 블러 정도는 심해진다. 즉, 디포커스 블러 이

미지를 복원하기 위해서는 다양한 블러 상황에 맞는 다양한 종류의 필터가 필요하다. 다양한 블러가 존재하기 때문에 성능을 높이기 위해 기존과 다른 새로운 데이터셋을 구축했다.

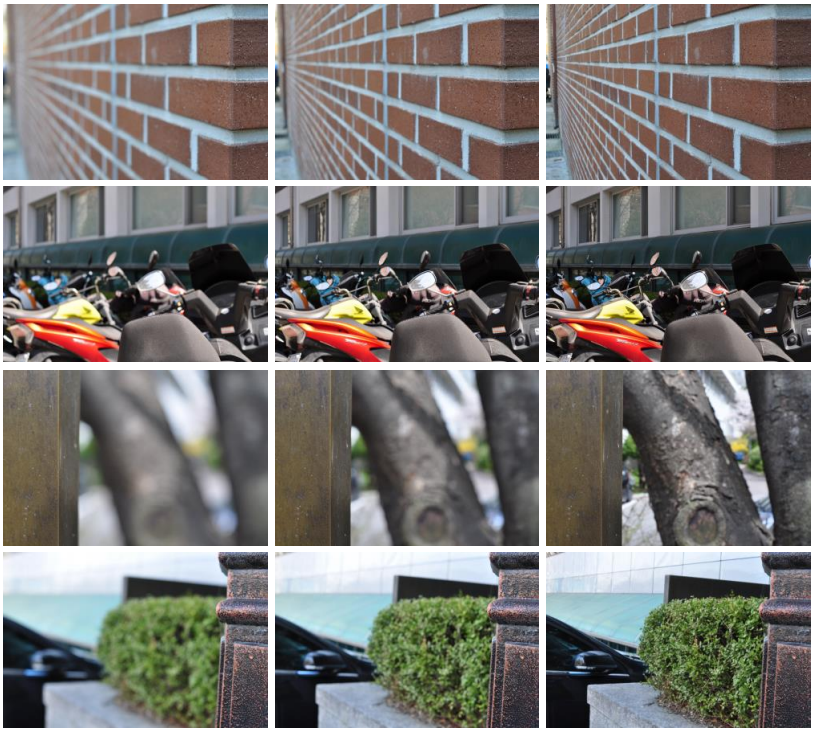

(a) 조리개 F4 (b) 조리개 F8 (c) 조리개 F22

그림 11: Multi Blur(MB) Dataset.

[그림 11]에서 보는 것처럼 조리개 F4로 촬영한 이미지가 블러 정도가 가장 심하고 조리개 F8로 촬영한 이미지는 블러 정도가 상대적으로 약하다. 그리고 마지막으로 조리개 F22로 촬영해서 전체적으로 선명한 이미지를 촬영했다. 해당 데이터셋은 앞으로 Multi Blur Dataset이라 부르고 MB Dataset이라고 쓰도록 하겠다.

MB Dataset 촬영을 위해 니콘 D90 카메라를 이용했으며 4288 x 2848의 해상도, ISO 200 그리고 초점거리 35㎜ 렌즈로 촬영했다. 총 500 장면(500 Scene)을 촬영했으며 하나의 장면을 조리개 F4, F8, 그리고 F22로 3회 촬영해서 총 1,500 장을 촬영했다. 500 세트 중 400 세트는 학습 데이터로 활용했으며 50 세트는 확인 데이터(Validation Data) 그리고 나머지 50 세트는 테스트 데이터로 활용했다.

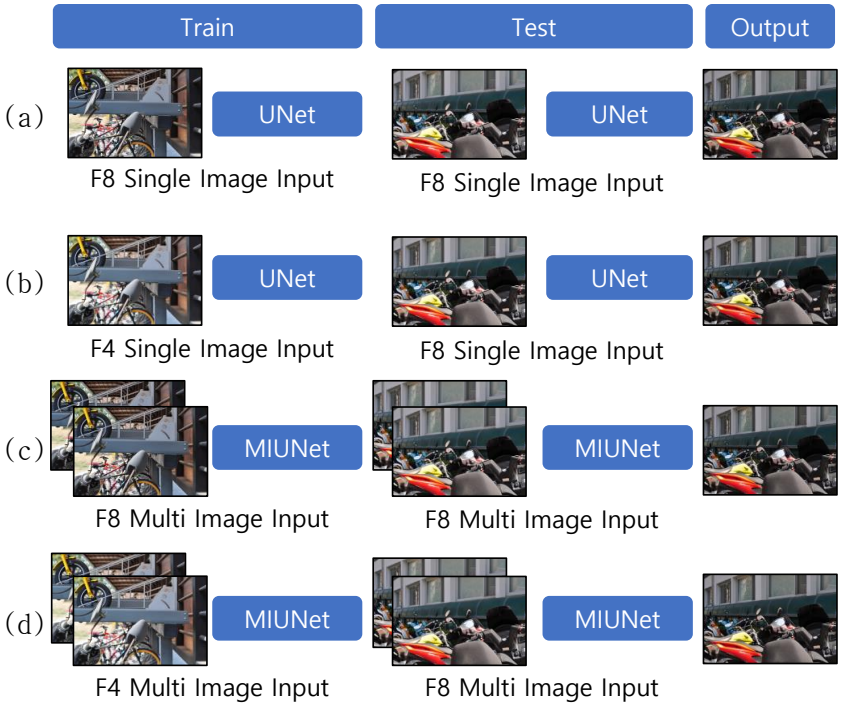

그림 12: UNet과 MIUNet 네트워크 비교.

3.1.2 MIUNet Architecture

MIUNet은 [그림 12]와 같이 입력 이미지를 하나의 이미지(Single Image)가 아닌 두 장의 이미지로 다중입력(Multiple Inputs)하는 딥러닝 모델이다. 일반적으로 입력 이미지는 적색, 녹색, 청색으로 구성된 3 채널인데 MIUNet의 경우 동일한 이미지를 두 장 입력해서 6 채널로 구성했다. 이렇게 구성함으로써 학습 속도는 기존보다 느려졌지만 학습 중 손실값의 산포는 줄어들어 학습의 안정성이 좋아졌고 테스트에서 디포커스 디블러 성능이 더 뛰어난 결과를 얻을 수 있었다. 그리고 일반적으로 딥러닝에서 학습을 하고 테스트를 할 때 학습 데이터와 테스트 데이터를 동일한 형태로 학습하고 테스트한다. 그러나 MIUNet에서는 블러 정도가 심한 데이터로 학습을 하고 일반적인 데이터로 테스트를 진행해서 학습 시 피사계심도가 다양한 데이터셋으로 학습할 수 있도록 네트워크를 구성했다.

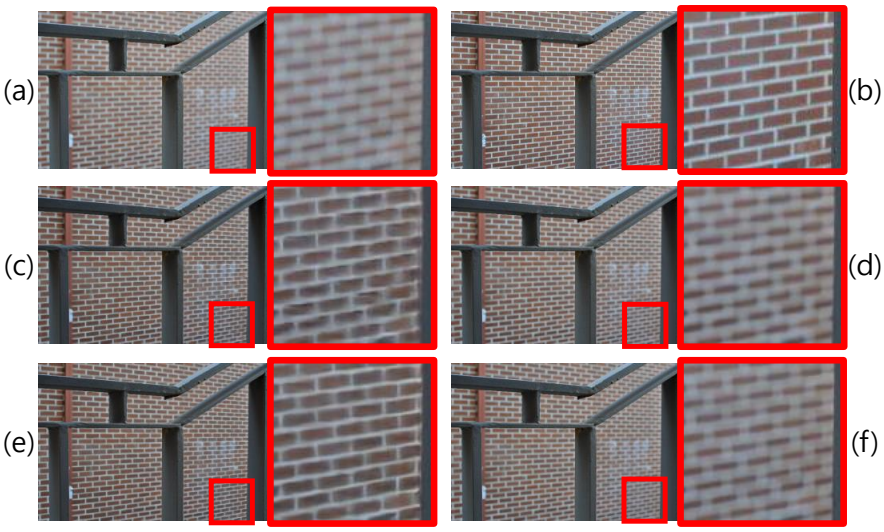

그림 13: MIUNet 실험결과 1.

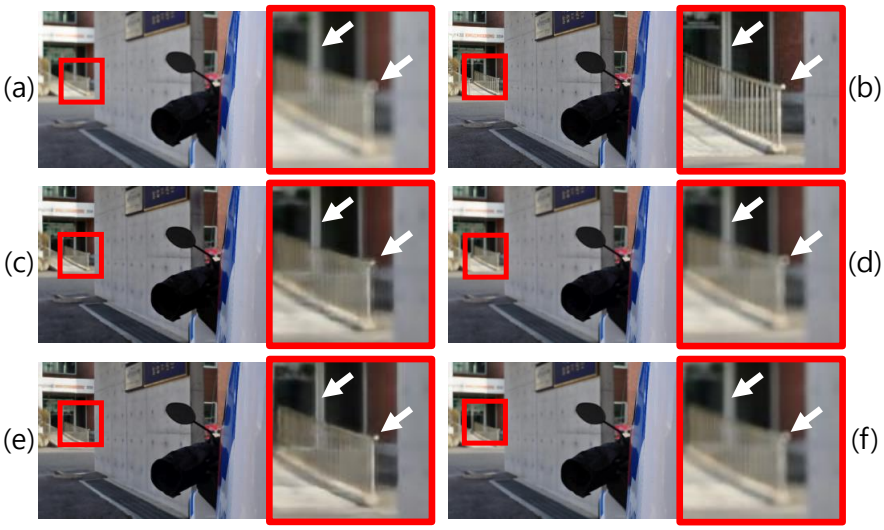

그림 14: MIUNet 실험결과 2.

MIUNet으로 디포커스 디블러를 진행한 결과 [그림 13]과 [그림 14]에서 보는 것처럼 기본적인 UNet보다 더욱 선명하게 디블러된 것을 확인할 수 있었다. [그림 13]과 [그림 14]에서 (a)는 조리개 F8로 촬영된 테스트 입력 이미지, (b)는 조리개 F22로 촬영된 선명한 이미지, (c)는 조리개 F4로 촬영된 이미지를 UNet으로 학습한 후 테스트한 결과, (d)는 조리개 F8로 촬영된 이미지를 UNet으로 학습한 후 테스트한 결과, (e)는 조리개 F4로 촬영된 이미지를 MIUNet으로 학습한 후 테스트한 결과, 그리고 (f)는 조리개 F8로 촬영된 이미지를 MIUNet으로 학습한 후 테스트한 결과이다. [그림 13]에서 조리개 F4로 촬영된 이미지를 MIUNet으로 학습한 후 테스트한 결과인 (e)가 이미지 끝부분(Edge)에서 가장 복원이 잘된 모습을 확인할 수 있다. 그리고 [그림 14]에서도 (e)가 도어와 도어 사이 경계선이 선명하게 보이고 펜스 끝에 원형 구조물도 잘 복원한 것을 확인할 수 있었다.

추가로 조리개 F22로 촬영된 선명한 이미지를 MIUNet에 입력했을 때 특이사항이 있는지 확인하기 위해서 추가 실험을 진행하였다. 실험결과 [그림 15]에서 보는 것처럼 조리개 F22로 촬영된 이미지(a)에서 피사계심도를 벗어난 일부 영역에 대해서도 선명하게 이미지가 복원되는 결과(b)를 확인할 수 있었다. 피사계심도 안에 있는 피사체에 대해서 이미지 선명도가 떨어지거나 깨지는 현상은 발생하지 않았다.

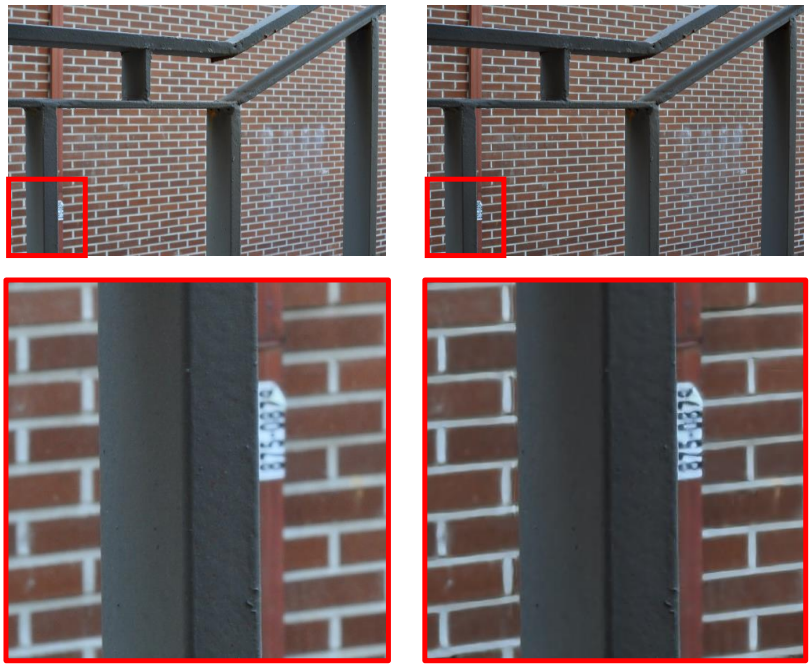

(a) 조리개 F22로 촬영한 이미지

(b) (a)이미지를 MIUNet에 입력해서 얻은 결과

그림 15: MIUNet 실험결과 3.

촬영된 원본의 해상도(4288 x 2848)는 학습시간이 오래 걸리고 많은 메모리를 필요로하는 등 학습 효율이 떨어지기 때문에 672 x 448로 리

사이즈(Resize) 진행 후 학습을 진행했다. 그리고 추가적으로 더 선명한 디포커스 디블러 진행을 위해 2016 x1344 해상도로 리사이즈해서 추가 학습을 진행했다. 연구에 사용된 하드웨어 및 소프트웨어 사양은 다음과 같다.

표 1: MIUNet 실험 환경 정보.

실험 환경	설명
CPU	Intel(R) Xeon(R) Silver 4214R CPU @ 2.40GHz
RAM	128 GB
GPU	GeForce RTX 3090
OS	Ubuntu 18.04.5 LTS
GPU API	CUDA Version 10.0.130 / cuDNN 7.6.5
Languages	Python 3.6.12
Framework	Pytorch 1.7.1

3.2 실험 데이터 구성 및 실험방법

3.2.1 실험 데이터셋 구성

제조 산업에서 디펙 데이터셋은 보안 등의 이유로 공개되지 않아 활용하는데 많은 어려움이 있다. NEU-CLS는 노스이스턴 대학(The Northeastern University)에서 금속 표면의 6 가지 종류의 디펙 이미지(Defect Image)를 활용해 만든 금속 표면 디펙 데이터셋이다. 해당 데이터셋의 종류는 crazing(Cr), inclusion(In), pitted surface(PS), rolled-in scale(RS) 그리고 scratches(Sc)로 구성되어 있으며 각 클래스(Class)는 300 장의 데이터를 가지고 있다. 데이터셋의 총 갯수는 1,800 장이다. 각각의 클래스 300 장은 240 장의 학습 데이터, 30 장의 확인 데이터, 그리고 30 장의 테스트 데이터로 구성했다.

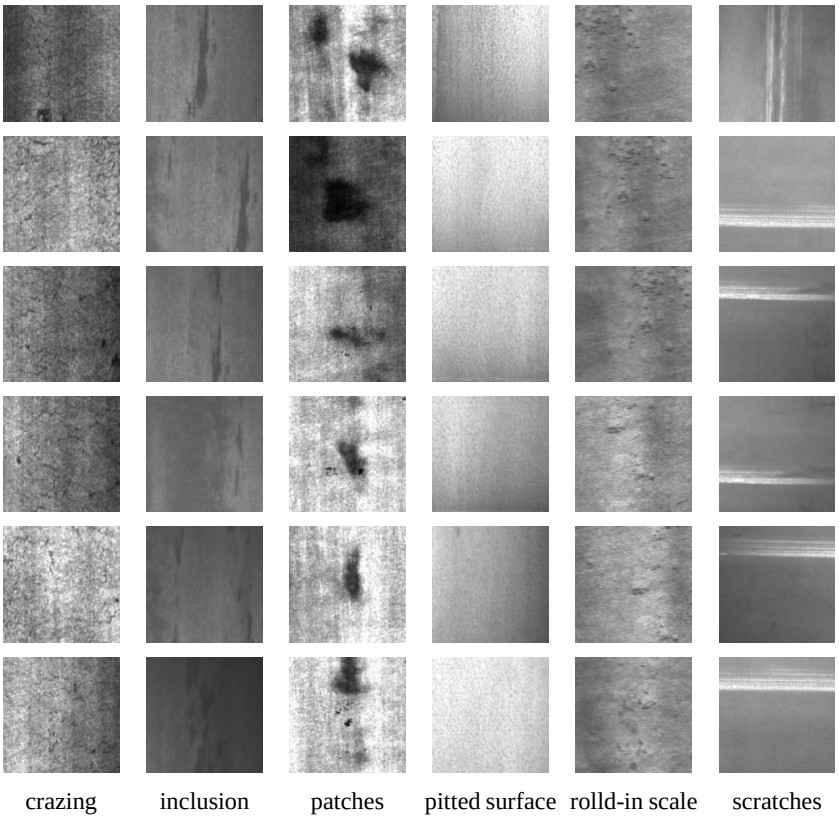

그림 16: NEU-CLS 데이터셋.

$$\text{디포커스 블러} : K(x,y) = \begin{cases} \dfrac{1}{\pi r^2} & \text{if}(x-k)^2 + (y-l)^2 \leq r^2, \\ 0 & \text{elsewhere} \end{cases} . \quad (3.1)$$

공개된 블러 디펙 이미지 데이터셋이 없기 때문에 NEU-CLS 디펙 데이터셋을 사용해서 디포커스 블러 데이터셋을 구축했다. 디포커스 블러

이론(식 3.1)을 바탕으로 블러 데이터셋을 구축했으며 구체적인 과정은 [표 2]에서 확인할 수 있다.

표 2: 디포커스 블러 이미지 생성 과정.

No	작업 내용
1	블러 정도에 따라 필터 사이즈를 정한다.
2	디포커스 블러에 맞는 필터를 만든다.
3	적절한 감마(Gamma) 값을 정한다.
4	선명한 이미지를 불러온다.
5	선명한 이미지에 감마 값을 적용한다.
6	감마 값이 적용된 이미지와 필터의 합성곱 연산을 한다.
7	LUT(Look Up Table)로 완성도를 높인다.
8	결과를 저장한다.

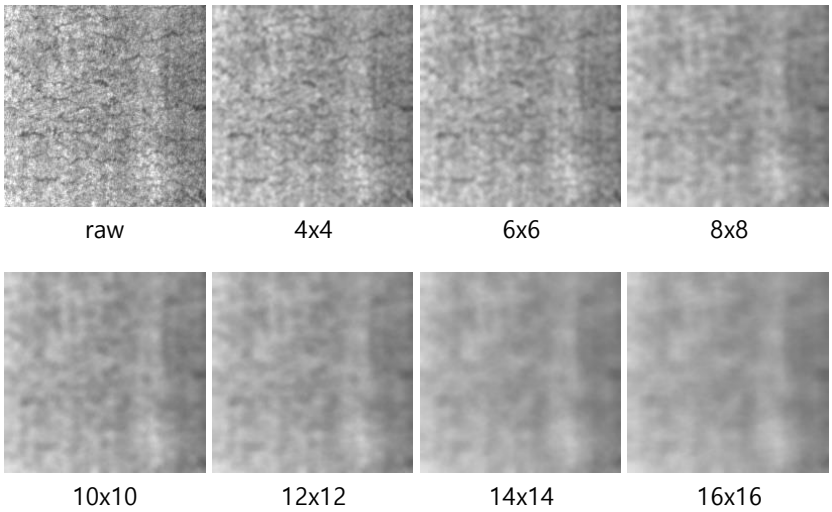

그림 17: 블러 필터 크기에 따른 디포커스 블러 디펙 이미지.

블러 필터 크기를 다양하게 구성해서 데이터셋을 만들었으며 [그림 17]에서 보는 것처럼 필터 크기가 커짐에 따라 블러 정도가 심해지는 모습

을 볼 수 있다. 비교적 디펙의 이미지가 크게 나타나는 patches, inclusion, 그리고 scratches의 경우 어느정도 블러가 진행되더라도 육안으로 분류가 가능했다. 하지만 디펙의 크기가 작은 crazing, pitted-surface, 그리고 rolled-in_scale의 경우 블러의 정도가 심해지는 경우 디펙을 구별하기 어려웠다. crazing의 경우 블러 필터 크기가 8x8 이상인 경우 육안으로도 구분이 거의 힘들었다.

3.2.2 실험방법

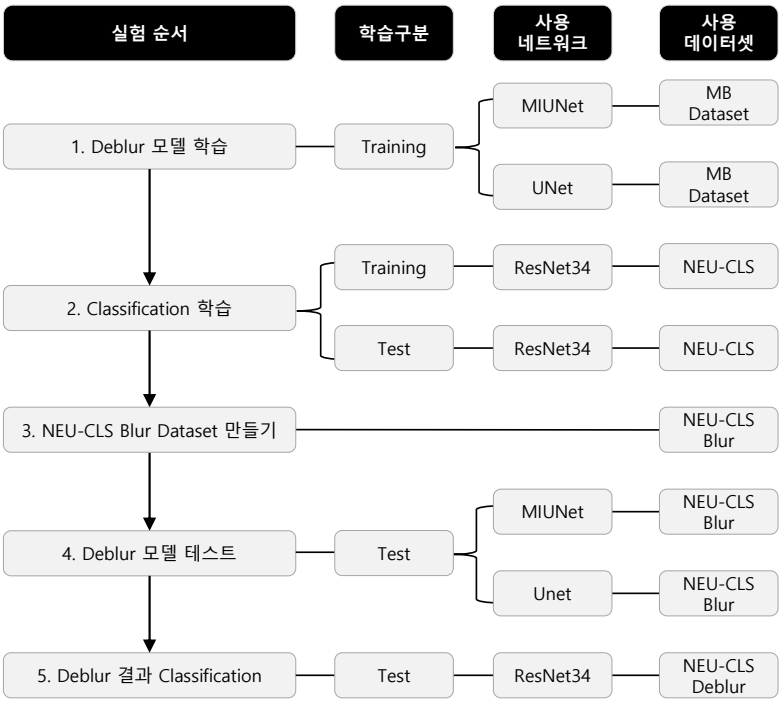

그림 18: 실험 방법.

전체적인 실험 프로세스는 [그림 18]에서 확인할 수 있다. 먼저, MB

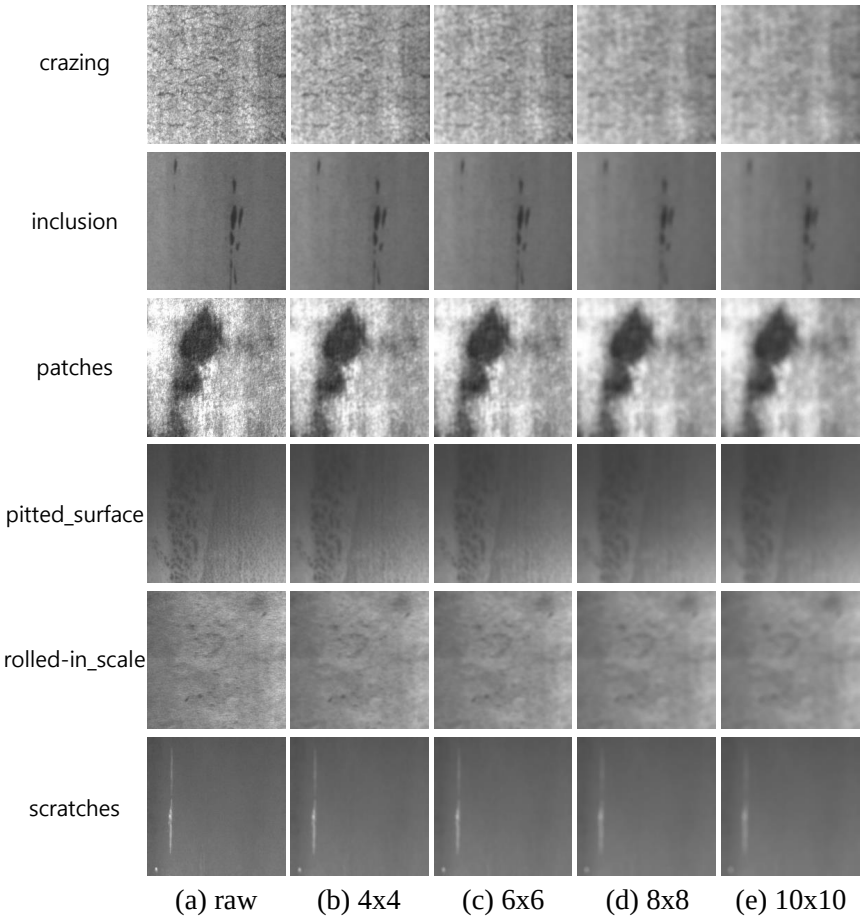

그림 19: 클래스별 블러 필터 크기에 따른 블러 이미지.

Dataset을 활용해서 디포커스 디블러를 위한 MIUNet와 UNet 네트워크를 학습했다. MIUNet의 특징대로 조리개 F4로 촬영한 블러 정도가 심한 이미지 2 장을 입력해서 학습을 진행했으며 세부적인 실험 조건은 아래 [표 3]에서 확인할 수 있다.

다음으로 이미지 분류는 네트워크 중 뛰어난 성능을 보여준 ResNet을 선정했다. 산업 현장에서 사용하기 위해서는 적절한 메모리 사용과 빠

표 3: MIUNet 실험 조건.

하이퍼 파라미터	내용	비고
학습율	0.0001	-
학습 횟수	500	-
손실 함수	MSE(Mean Squared error) Loss	-
옵티마이저	Adam	betas = (0.9, 0.999)
배치 크기	1	-

른 속도가 중요하기 때문에 ResNet34 네트워크를 이용해서 NEU-CLS 데이터셋을 학습하고 테스트를 진행했다. 다음으로 디포커스 블러 이론을 바탕으로 블러 필터 크기별로 NEU-CLS 블러 데이터셋을 만들었으며 결과는 [그림 19]에서 확인할 수 있다. 그리고 디포커스 디블러 성능 비교를 위해 앞서 학습했던 MIUNet과 UNet 네트워크를 이용했다. 마지막으로 디포커스 디블러 진행된 결과 이미지를 ResNet34로 학습했던 네트워크에 입력해서 분류 정확도를 비교 평가했다.

3.3 실험결과

3.3.1 디포커스 디블러 결과

NEU-CLS의 각 클래스별로 디포커스 디블러 진행된 결과를 [그림 20, 21, 22, 23, 24, 25]에서 확인할 수 있다. 결과에서 (a), (b), (c), 그리고 (d)는 블러 필터 크기별로 구분된다. 육안으로 확인 시 전체적으로 UNet으로 복원한 결과보다 MIUNet으로 복원한 결과에서 디펙의 경계선이 더 선명한 것을 확인할 수 있다. 다만 pitted surface의 경우 디펙의 패턴(Pattern)이 미세해서 디블러 진행 후에 디펙의 경계선이 또렷하게 보이지 않는 경향을 보여주었다.

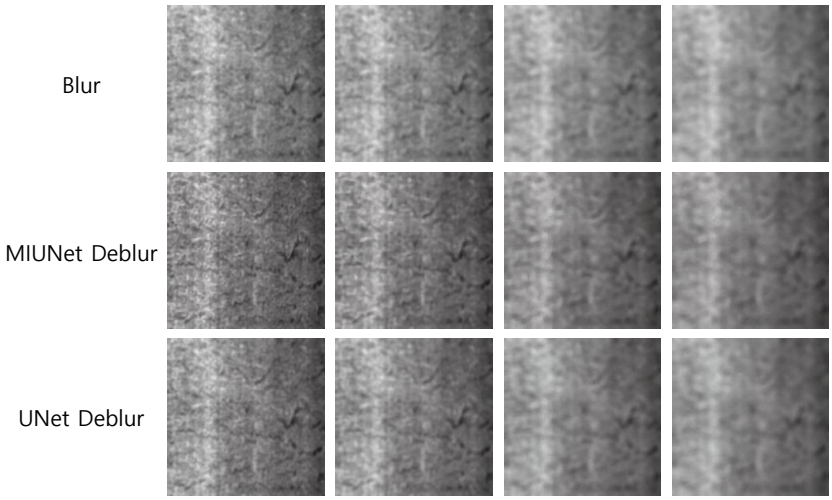

(a) 4x4 (b) 6x6 (c) 8x8 (d) 10x10

그림 20: 디포커스 디블러 결과 - crazing.

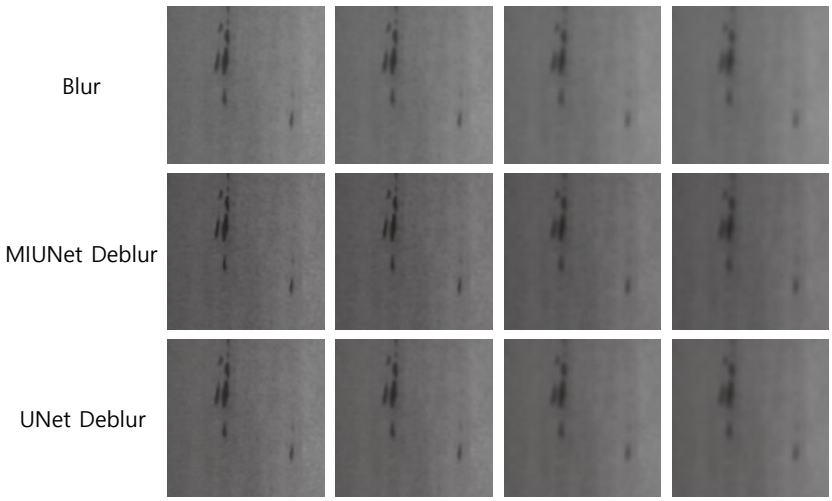

(a) 4x4 (b) 6x6 (c) 8x8 (d) 10x10

그림 21: 디포커스 디블러 결과 - inclusion.

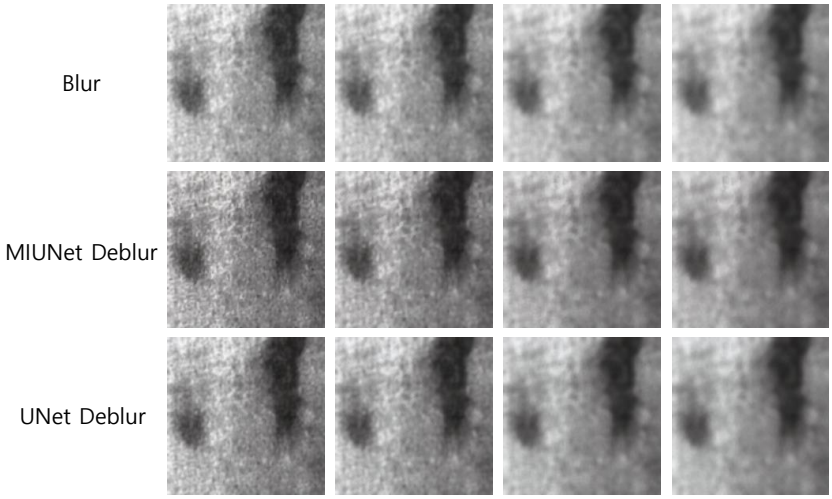

(a) 4x4 (b) 6x6 (c) 8x8 (d) 10x10

그림 22: 디포커스 디블러 결과 - patches.

(a) 4x4 (b) 6x6 (c) 8x8 (d) 10x10

그림 23: 디포커스 디블러 결과 - pitted surface.

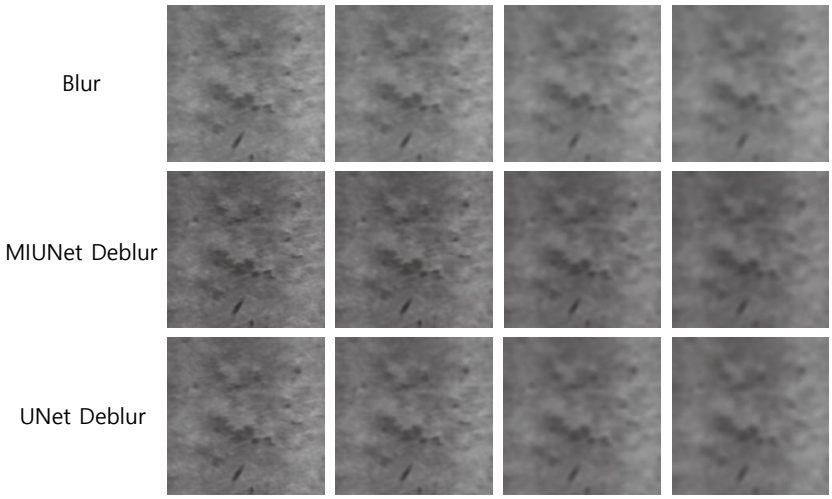

(a) 4x4 (b) 6x6 (c) 8x8 (d) 10x10

그림 24: 디포커스 디블러 결과 - rolled-in scale.

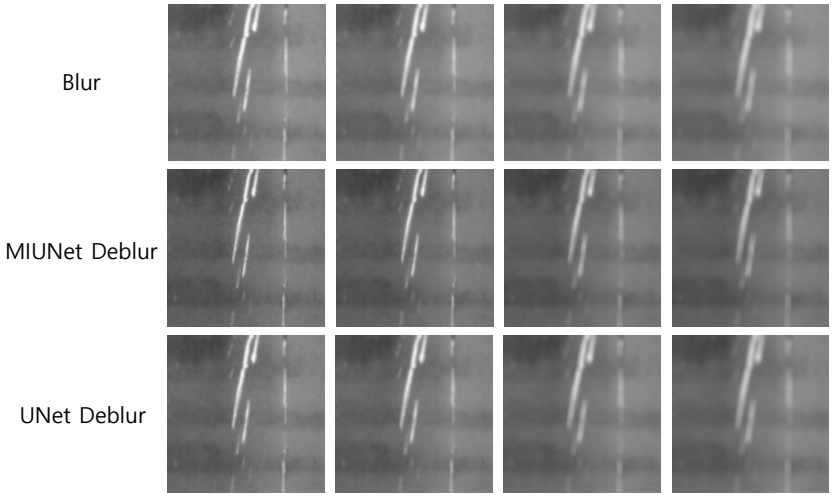

(a) 4x4 (b) 6x6 (c) 8x8 (d) 10x10

그림 25: 디포커스 디블러 결과 - scratches.

3.3.2 디포커스 디블러 후 이미지 분류 결과

디포커스 디블러 결과에 대한 이미지 분류 정확도를 [그림 26]에서 확인할 수 있다. 디포커스 디블러 실험을 진행하기 전에 ResNet34 딥러닝 네트워크 모델로 NEU-CLS 데이터셋을 학습했다. Epoch 500까지 학습했으며 분류 정확도는 97.8%를 확인했다. 클래스 종류가 6 개로 많지 않고 각각의 디펙의 유사성이 떨어지기 때문에 정확도가 높게 나온것으로 판단된다. NEU-CLS 데이터셋을 블러 필터를 사용해서 흐릿하게 만든 후 이미지 분류를 확인한 결과 블러 필터 크기를 4x4로 흐릿하게 만들었을 때 이미지 분류 정확도가 97.8%에서 86.1%까지 하락했으며 블러 필터 크기를 10x10으로 흐릿하게 만들었을 때에는 정확도가 48.3%까지 떨어지는 것을 확인했다. 특이한 점은 블러 필터가 4x4로 작은 경우에도 이미지 분류 정확도가 86.1%까지 하락했다는 점이다. 이 결과는 매우 중요한 의미를 갖는다. 광학 검사에서 디포커스 블러가 미세하게 일어나는 경우에도 이미지 분류 정확도가 크게 떨어질 수 있다는 결과이기 때문이다. 이는 디포커스 디블러 연구의 중요성을 보여주는 결과라고 말할 수 있겠다.

표 4: 디포커스 블러 및 디블러 분류 정확도.

블러필터크기	Blur	MIUNet	UNet
4x4	86.1%	98.9%	95.0%
6x6	75.0%	90.0%	76.7%
8x8	57.8%	70.0%	61.1%
10x10	48.3%	61.1%	52.8%

블러 필터 사이즈에 관계없이 MIUNet을 이용한 디포커스 디블러가 UNet보다 뛰어난 성능을 보여주었다. 특히, 블러 필터 사이즈가 4x4인 경우에는 이미지 분류 정확도가 86.1%에서 98.9%까지 상승하는 결과를

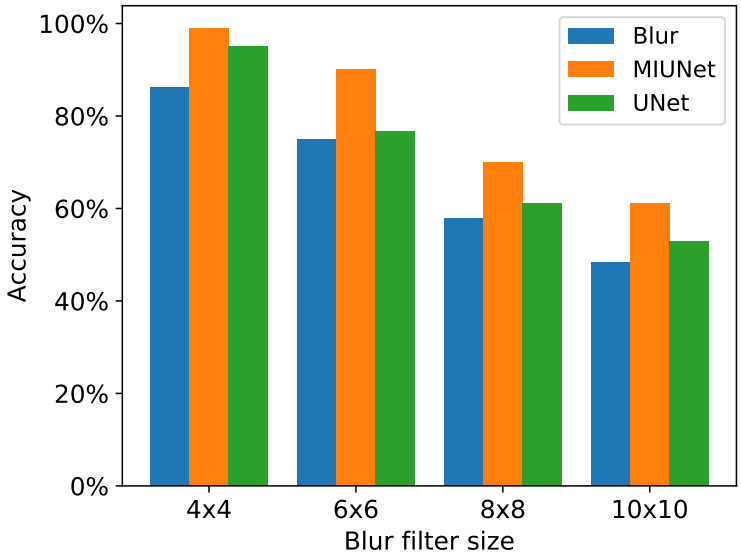

그림 26: 디포커스 디블러 후 분류 성능 그래프.

확인할 수 있었다. 하지만 블러 필터 사이즈가 10x10일 때에는 디포커스 디블러 진행 후 이미지 분류 정확도가 48.3%에서 61.1%로 상승하는 결과를 보여주어 블러 필터 사이즈가 4x4일 때보다는 부족한 결과를 확인했다. 세부적으로 각 클래스별로 블러 필터 크기에 따라 디블러 성능이 어떻게 되는지는 [그림 27, 28, 29, 30, 31, 32]에서 확인할 수 있다. 각 그림에서 파랑색 '*' 그래프는 블러된 이미지의 분류 정확도, 주황색 '+' 그래프는 MIUNet으로 복원한 후 이미지의 분류 정확도, 그리고 초록색 '×' 그래프는 UNet으로 복원한 후 이미지의 분류 정확도이다. 특이하게도 복원된 이미지 중 inclusion 클래스의 경우 육안으로 확인할 때에는 MIUNet으로 복원된 결과가 원본과 가장 비슷하게 보이는데 분류 정확도에서는 큰 차이가 없었다. 그외에 대부분 클래스에서 MIUNet으로 복원된 이미지가

UNet으로 복원된 이미지보다 더 뛰어난 이미지 분류 성능을 보여주었다.

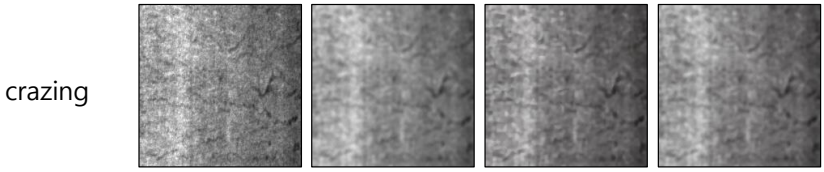

(a) raw (b) Blur (6x6) (c) MIUNet (d) UNet

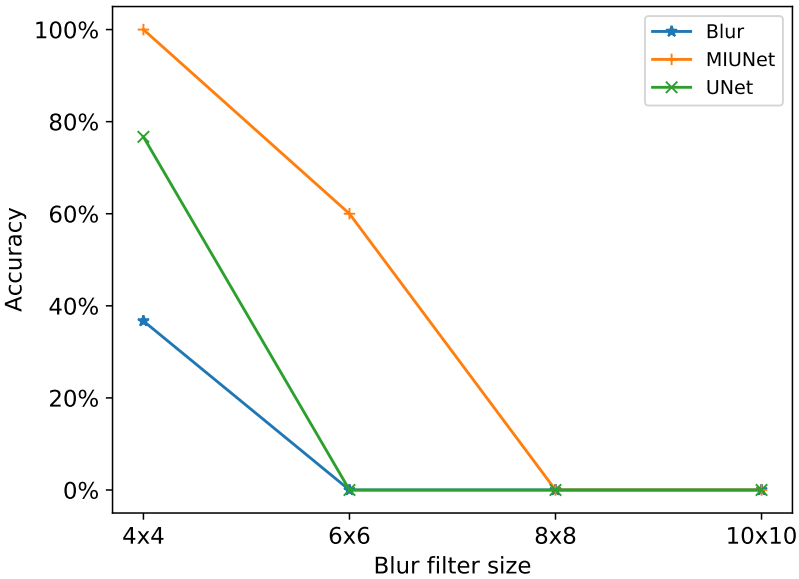

그림 27: 디포커스 디블러 후 분류 성능 - crazing.

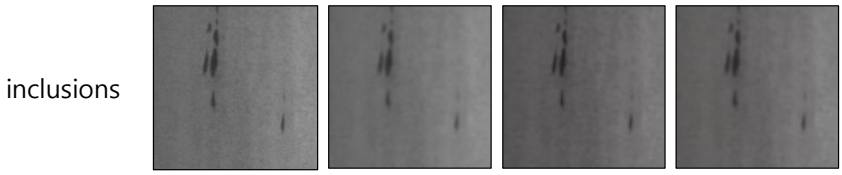

(a) raw (b) Blur (6x6) (c) MIUNet (d) UNet

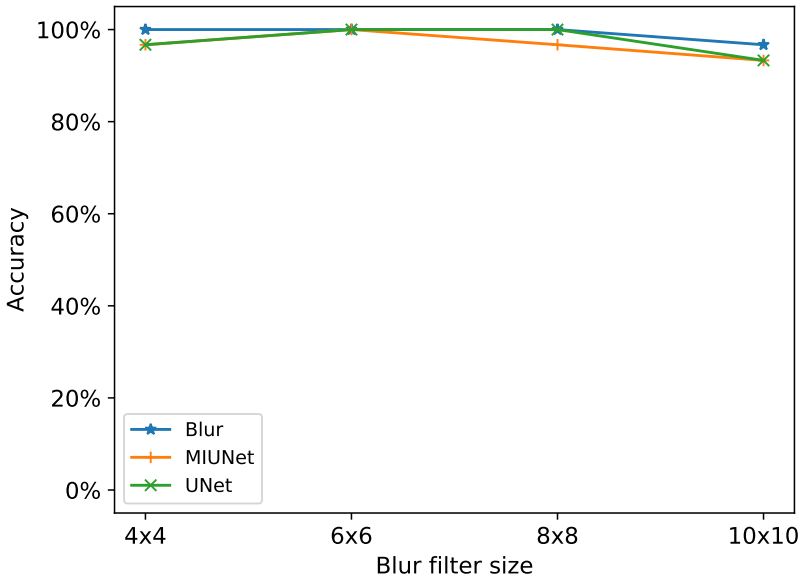

그림 28: 디포커스 디블러 후 분류 성능 - inclusion.

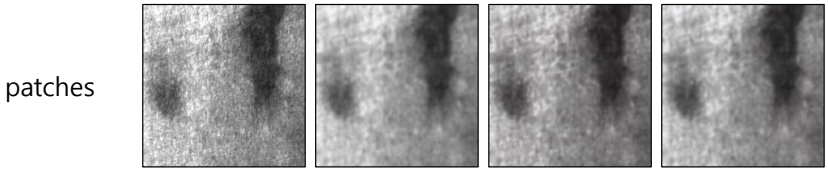

(a) raw (b) Blur (6x6) (c) MIUNet (d) UNet

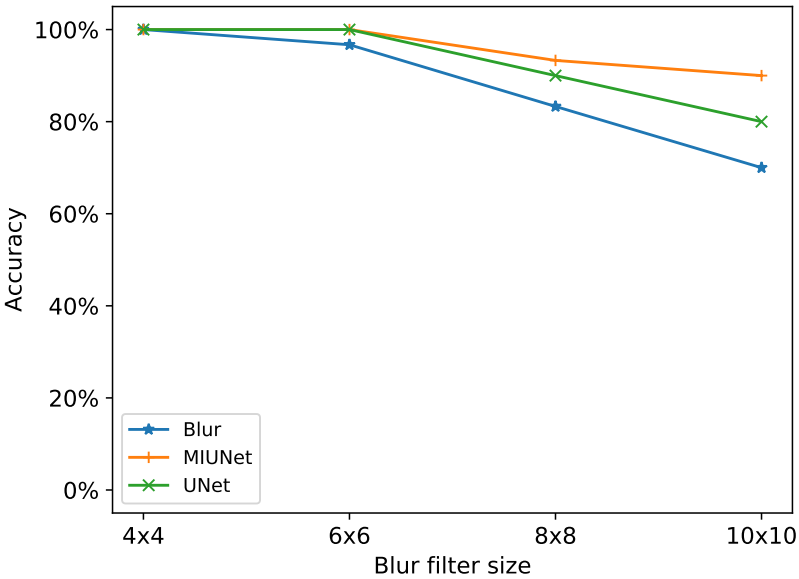

그림 29: 디포커스 디블러 후 분류 성능 - patches.

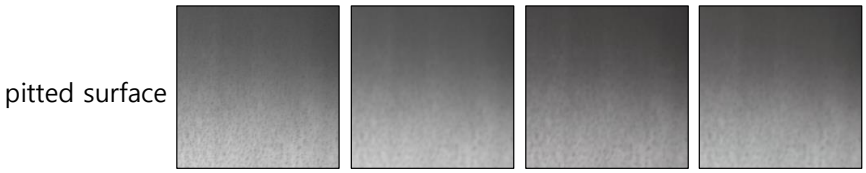

(a) raw (b) Blur (6x6) (c) MIUNet (d) UNet

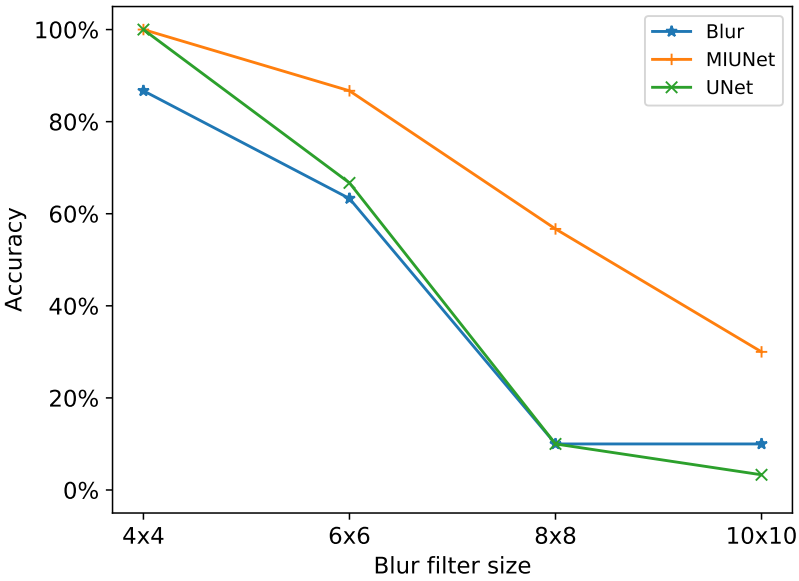

그림 30: 디포커스 디블러 후 분류 성능 - pitted surface.

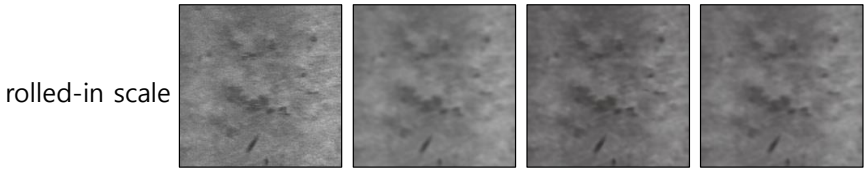

(a) raw (b) Blur (6x6) (c) MIUNet (d) UNet

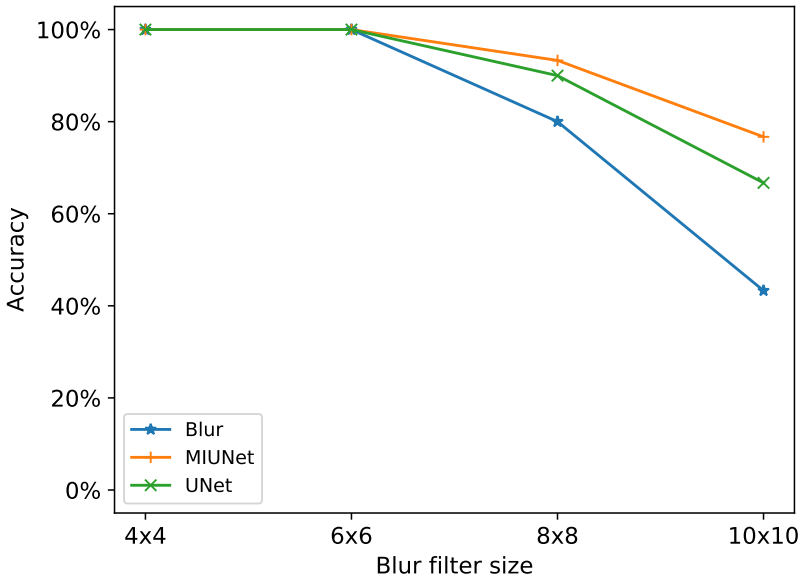

그림 31: 디포커스 디블러 후 분류 성능 - rolled-in scale.

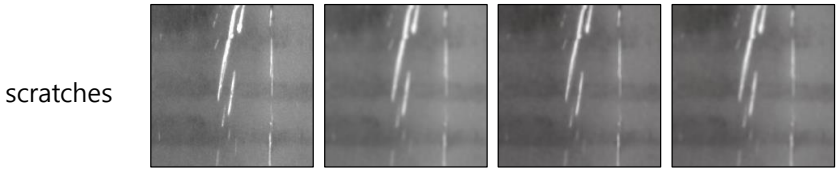

(a) raw (b) Blur (6x6) (c) MIUNet (d) UNet

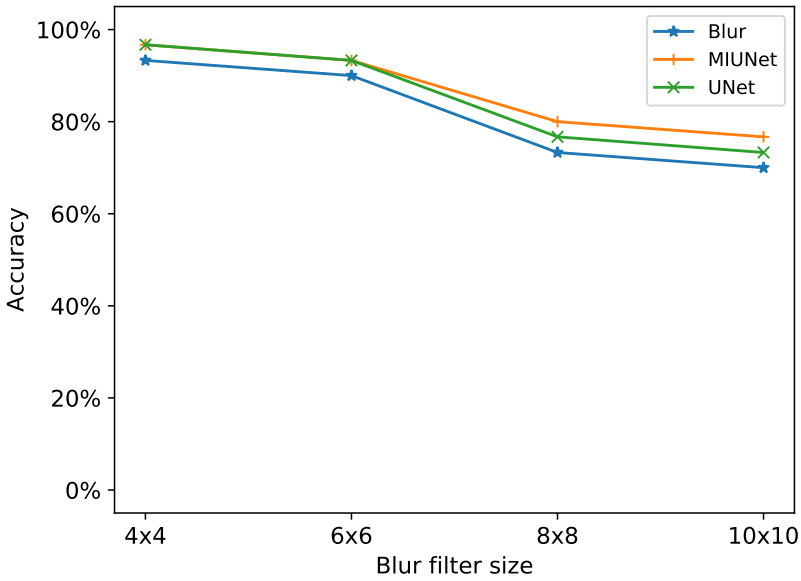

그림 32: 디포커스 디블러 후 분류 성능 - scratches.

마지막으로 제조 현장에서 제품 생산 중 발생할 수 있는 몇가지 케이스를 가정하고 MIUNet을 사용해서 디포커스 디블러 진행한 후 이미지 분류 정확도를 평가했다. 본 평가의 목적은 초점이 맞은 선명한 이미지가 디포커스 디블러 네트워크에 입력되서 복원됐을 때 이미지 분류 정확도에 문제가 생기는지 확인하기 위함이다. 세부 내용은 [표 5]에서 확인 할 수 있다. 필터 사이즈와 클래스별 이미지 분류 정확도를 이용해서 각 케이스별로 이미지 분류 정확도를 계산했다. 디포커스 디블러 적용하기 전에 확인한 이미지 분류 정확도는 81.3% ∼ 93.6% 분포를 보여주었다. 다음으로 케이스별 이미지를 MIUNet에 입력해서 디포커스 디블러를 진행했다. 디포커스 디블러 적용 후에는 88.6% ∼ 95.9%의 분포로 모든 케이스에서 이미지 분류 정확도가 2.3%에서 7.3%까지 개선되는 것을 확인할 수 있었다. 디포커스 디블러 적용 전후 디펙 클래스별 이미지 분류 정확도는 [표 6]과 [표 7]에서 확인할 수 있으며 이미지 분류 정확도 그래프는 [그림 33]에서 볼 수 있다. 이 결과를 통해서 선명한 이미지가 디포커스 디블러 네트워크에 입력되도 문제없이 정확도가 개선되는 것을 확인할 수 있었다.

표 5: 디포커스 디블러 평가 - 케이스별 데이터 구성.

구분	raw	4x4	6x6	8x8	10x10	합계
케이스1	26	1	1	1	1	30
케이스2	22	2	2	2	2	
케이스3	18	3	3	3	3	
케이스4	14	4	4	4	4	

표 6: 디포커스 디블러 전 케이스별 분류 정확도.

디펙 클래스	케이스1	케이스2	케이스3	케이스4
crazing	87.9%	75.8%	63.7%	51.6%
inclusion	94.1%	94.9%	95.7%	96.4%
patches	98.3%	96.7%	95.0%	93.3%
pitted surface	92.3%	84.7%	77.0%	69.3%
rolled-in scale	97.4%	94.9%	92.3%	89.8%
scratches	91.7%	90.2%	88.6%	87.1%
합계	93.6%	89.5%	85.4%	81.3%

표 7: 디포커스 디블러 후 케이스별 분류 정확도.

디펙 클래스	케이스1	케이스2	케이스3	케이스4
crazing	92.0%	84.0%	76.0%	68.0%
inclusion	96.7%	96.7%	96.7%	96.7%
patches	99.4%	98.9%	98.3%	97.8%
pitted surface	95.8%	91.6%	87.3%	83.1%
rolled-in scale	99.0%	98.0%	97.0%	96.0%
scratches	92.4%	91.5%	90.7%	89.8%
합계	95.9%	93.4%	91.0%	88.6%

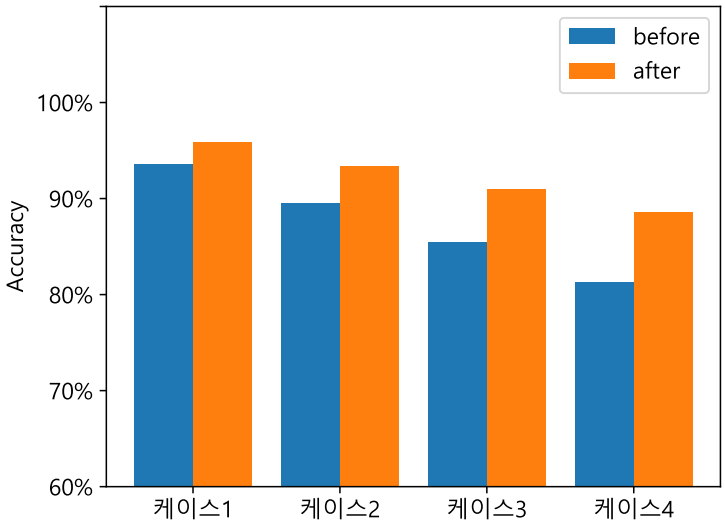

그림 33: 디포커스 디블러 적용 전후 이미지 분류 정확도.

제 4 장

결론

딥러닝의 발전은 산업계에도 큰 변화를 가져왔다. 제조 산업에서는 생산 제품의 품질을 향상시키고 수익을 개선하기 위해 광학 검사로 불량을 분석하고 있다. 딥러닝은 광학 검사 이미지를 신속하고 정확하게 분류하는데 큰 도움을 주고 있다. 하지만 광학 검사 중 카메라의 초점 설정에 문제가 생기거나 불량이 큰 경우 검사 이미지가 흐릿하게 되고 정확한 불량 분석에 제약이 생긴다.

본 연구에서는 이를 해결하기 위해서 새로운 디포커스 디블러 네트워크인 MIUNet을 제안하고 새로운 데이터셋인 MB Dataset을 구축했다. MIUNet과 MB Dataset을 통해서 UNet보다 뛰어난 디포커스 디블러 성능을 확인했다. 그리고 그 네트워크를 사용해서 금속 표면 디펙의 이미지 분류에 관한 연구를 진행했다. 연구를 위해서 NEU-CLS 데이터셋을 활용했으며 블러 디펙 데이터셋은 디포커스 블러 이론을 바탕으로 추가로 구축하였다. 4x4 블러 필터 기준으로 디포커스 디블러 적용 전 이미지 분류 정확도가 86.1%에서 디포커스 디블러 적용 후 98.9%까지 개선되는 것을 확인했다. 그리고 실제 제조 현장을 가정해서 선명한 이미지와 흐릿한 이미지가 함께 디포커스 디블러 네트워크에 입력되는 경우에도 케이스에 따라 정확도가 2.3%에서 7.3%까지 개선되는 것을 확인했다.

본 연구를 통해 제조 산업에서 사용중인 광학 검사 딥러닝 이미지 분류에서 미세한 디포커스 블러가 발생하는 경우 이미지 분류 성능이 사

용하기 불가능할 정도로 정확도가 낮아진다는 점을 알 수 있었다. 이 점을 통해 제조 산업에서 사용중인 광학 검사기의 초점 관리가 매우 중요하다는 것을 알 수 있었다. 다음으로 불가피하게 디포커스 블러가 발생한 경우 디포커스 디블러 모델을 사용해서 이미지 분류 성능을 개선할 수 있다는 것을 확인했다. 블러 필터가 4x4인 경우에는 복원 성능이 뛰어났지만 블러 필터가 6x6 이상인 경우에는 디포커스 디블러 성능은 다소 아쉬운 모습을 보여주었다. 하지만 실제 제조 산업을 가정한 케이스별로 디포커스 디블러 이미지 분류 성능을 평가한 결과 디포커스 디블러를 적용하기 전보다 적용 후에 이미지 분류 정확도가 향상되는 것을 확인했다. 이를 통해 디포커스 디블러 모델이 제조 현장에서 이미지 분류 정확도를 향상시키고 제조 경쟁력을 갖추는데 도움이 될 수 있을 것으로 기대된다.

딥러닝 기술의 발전과 함께 디블러 분야 또한 지속적으로 연구가 진행되고 있다. 하루 아침에 완벽한 이미지 복원 모델이 나올수는 없겠지만 지속해서 연구가 진행된다면 이미지 분류에서 ResNet과 같이 뛰어난 디블러 딥러닝 모델이 개발될 수 있을 것으로 기대된다. 구체적으로는 디포커스 디블러에 적절한 데이터셋을 지속적으로 구축하고 디포커스 블러 특징에 맞는 딥러닝 네트워크를 연구하는 것이 필요할 것이다.

참고 문헌

[1] K. Song and Y. Yan, "A noise robust method based on completed local binary patterns for hot-rolled steel strip surface defects," *Applied Surface Science*, vol. 285, pp. 858–864, 2013.

[2] J. Wang, Y. Ma, L. Zhang, R. X. Gao, and D. Wu, "Deep learning for smart manufacturing: Methods and applications," *Journal of manufacturing systems*, vol. 48, pp. 144–156, 2018.

[3] J. Yang, S. Li, Z. Wang, H. Dong, J. Wang, and S. Tang, "Using deep learning to detect defects in manufacturing: a comprehensive survey and current challenges," *Materials*, vol. 13, no. 24, p. 5755, 2020.

[4] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.

[5] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *International Conference on Medical image computing and computer-assisted intervention*, pp. 234–241, Springer, 2015.

[6] Y. Gao, J. Lin, J. Xie, and Z. Ning, "A real-time defect detection method for digital signal processing of industrial inspection applications," *IEEE Transactions on Industrial Informatics*, vol. 17, no. 5, pp. 3450–3459, 2020.

[7] R. Hao, B. Lu, Y. Cheng, X. Li, and B. Huang, "A steel surface defect inspection approach towards smart industrial monitoring," *Journal of Intelligent Manufacturing*, vol. 32, no. 7, pp. 1833–1843, 2021.

[8] Y. He, K. Song, Q. Meng, and Y. Yan, "An end-to-end steel surface defect detection approach via fusing multiple hierarchical features,"

IEEE Transactions on Instrumentation and Measurement, vol. 69, no. 4, pp. 1493–1504, 2019.

[9] A. Anvar and Y. I. Cho, "Automatic metallic surface defect detection using shuffledefectnet," *Journal of The Korea Society of Computer and Information*, vol. 25, no. 3, pp. 19–26, 2020.

[10] X. Lv, F. Duan, J.-J. Jiang, X. Fu, and L. Gan, "Deep active learning for surface defect detection," *Sensors*, vol. 20, no. 6, p. 1650, 2020.

[11] S. Youkachen, M. Ruchanurucks, T. Phatrapomnant, and H. Kaneko, "Defect segmentation of hot-rolled steel strip surface by using convolutional auto-encoder and conventional image processing," in *2019 10th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES)*, pp. 1–5, IEEE, 2019.

[12] R. Cohn and E. Holm, "Unsupervised machine learning via transfer learning and k-means clustering to classify materials image data," *Integrating Materials and Manufacturing Innovation*, pp. 1–14, 2021.

[13] S. Pan, T.-Y. Hung, and L.-T. Chia, "Using material classification methods for steel surface defect inspection," in *2016 IEEE 25th International Symposium on Industrial Electronics (ISIE)*, pp. 40–45, IEEE, 2016.

[14] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.

[15] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097–1105, 2012.

[16] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.

[17] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9, 2015.

[18] B. Huval, T. Wang, S. Tandon, J. Kiske, W. Song, J. Pazhayampallil, M. Andriluka, P. Rajpurkar, T. Migimatsu, R. Cheng-Yue, *et al.*, "An empirical evaluation of deep learning on highway driving," *arXiv preprint arXiv:1504.01716*, 2015.

[19] X. Chen, H. Ma, J. Wan, B. Li, and T. Xia, "Multi-view 3d object detection network for autonomous driving," in *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, pp. 1907–1915, 2017.

[20] B. Li, W. Ouyang, L. Sheng, X. Zeng, and X. Wang, "Gs3d: An efficient 3d object detection framework for autonomous driving," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 1019–1028, 2019.

[21] P. Li, X. Chen, and S. Shen, "Stereo r-cnn based 3d object detection for autonomous driving," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 7644–7652, 2019.

[22] M. Datar, A. Gionis, P. Indyk, and R. Motwani, "Maintaining stream statistics over sliding windows," *SIAM journal on computing*, vol. 31, no. 6, pp. 1794–1813, 2002.

[23] R. Wang, W. Li, R. Qin, and J. Wu, "Blur image classification based on deep learning," in *2017 IEEE International Conference on Imaging Systems and Techniques (IST)*, pp. 1–6, IEEE, 2017.

[24] E. J. McCartney, "Optics of the atmosphere: scattering by molecules and particles," *New York*, 1976.

[25] Y.-W. Tai and M. S. Brown, "Single image defocus map estimation using local contrast prior," in *2009 16th IEEE International Conference on Image Processing (ICIP)*, pp. 1797–1800, IEEE, 2009.

[26] S. Zhuo and T. Sim, "Defocus map estimation from a single image," *Pattern Recognition*, vol. 44, no. 9, pp. 1852–1858, 2011.

[27] S. Liu, F. Zhou, and Q. Liao, "Defocus map estimation from a single image based on two-parameter defocus model," *IEEE Transactions on Image Processing*, vol. 25, no. 12, pp. 5943–5956, 2016.

[28] A. Abuolaim and M. S. Brown, "Defocus deblurring using dual-pixel data," in *European Conference on Computer Vision*, pp. 111–126, Springer, 2020.

Abstract

Defocus Deblurring for Metal Surface Defect Using Multiple Inputs Deep Networks

Hongdeuk Kim
Graduate School of Practical Engineering
Seoul National University

With the recent rapid development of deep learning, the industry uses deep learning technology in various fields such as defect detection, defect classification, and defect analysis. In the case of ResNet, published in 2015, it showed performance that surpasses humans in image classification accuracy and is widely used as a basic model for image classification. Such excellent performance of deep learning enables faster and more accurate analysis than existing engineers and operators when analyzing large data, and contributes to the improvement of corporate productivity.

In this paper, we deal with the problem of how to clearly restore a blurred image and classify the restored image in a defocus blur situation that may occur during optical inspection. We create various defocus blur images while changing the blur filter size and research a method that can produce strong classification performance in actual situations.

Based on the UNet model used in image restoration, we evaluate the performance of the defocus deblur, build a new blur dataset for better performance, and propose a multiple inputs UNet (MIUNet). The defocus deblur performance is evaluated using the image classification accuracy before and after restoration, and the high-performance ResNet is used to evaluate the image classification accuracy. It shows that after restoring the defocus blur defect image created by the blur filter to MIUNet, the image classification accuracy improves.

In this study, we simultaneously confirm the usability of the image restored to the defocus deblur at the manufacturing site and the limit point that the defocus deblur performance varies depending on the degree of blurring. As a result of applying the defocus deblurring for each case where a clear image and a blurry image are mixed it is shown that the image classification accuracy is improved as compared with before the defocus deblurring. By applying the results of this research to the manufacturing site, it is expected that images that could not be accurately classified by the defocus blur can be accurately classified, which will contribute to ensuring manufacturing competitiveness.

Keywords : Defocus, Deblurring, Multiple Inputs Deep Networks, Image Classification, Deep Learning.

Student Number : 2020-22370