



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](#)

2023년 2월
석사학위 논문

생성적 적대 신경망(GAN)을 이용한 광학렌즈 결함판정 모델 개발

조선대학교 대학원

산업공학과

이 상 현

생성적 적대 신경망(GAN)을 이용한 광학렌즈 결함판정 모델 개발

Development of an Optical Lens Defect Detection Model using
Generative Adversarial Networks

2023년 2월 24일

조선대학교 대학원

산업공학과

이 상 현

생성적 적대 신경망(GAN)을 이용한 광학렌즈 결함판정 모델 개발

지도교수 신 종 호

이 논문을 공학 석사학위신청 논문으로 제출함

2022년 10월

조선대학교 대학원

산업공학과

이 상 현

이상현의 석사학위논문을 인준함

위원장	조선대학교 교수	<u>김성준 (인)</u>
위원	조선대학교 교수	<u>신종호 (인)</u>
위원	조선대학교 교수	<u>백정우 (인)</u>

2022년 12월

조선대학교 대학원

목차

목차.....	i
표 목차.....	iv
그림 목차.....	v
ABSTRACT.....	viii
제 1장 서론.....	1
제 1절 연구배경.....	1
1. 스마트 팩토리와 인공지능.....	1
2. 제조 분야 인공지능.....	2
제 2절 연구 목적.....	4
1. 광학렌즈 결함 판정의 한계.....	4
2. 제조 현장에서의 인공지능.....	5
제 3절 연구 구성.....	6
제 2장 데이터 수집 및 변환.....	7
제 1절 광학렌즈 데이터.....	7
1. 광학렌즈 개요.....	7
2. 광학렌즈 데이터 수집.....	8
제 2절 이미지 변환 및 엣지 추출.....	11
1. 극좌표 변환.....	11
2. Sobel filter.....	13
3. Laplacian filter.....	15
4. Canny edge.....	17

제 3장 CNN 기반 결함 검출.....	19
제 1절 Convolution Neural Network.....	19
제 2절 CNN Model.....	22
1. VGG Net.....	23
2. ResNet.....	24
3. DenseNet.....	26
제 3절 Transfer Learning.....	27
제 4절 구현 및 평가	28
1. 성능 평가 지표.....	28
2. Dataset.....	29
3. 실험 환경.....	31
4. 성능 평가 및 분석.....	31
제 4장 Anomaly Detection.....	42
제 1절 Anomaly detection.....	42
제 2절 AnoGAN.....	44
제 3절 GANomaly.....	45
제 4절 Skip-GANomaly.....	46
제 5절 구현 및 평가.....	47
1. Dataset.....	47
2. 성능 평가 및 분석.....	48
제 5장 Ensemble Model.....	52
제 1절 Ensemble Learning.....	52
제 2절 비정상 검출기.....	54

제 3절 적용 및 평가.....55
제 6장 결론 및 토의.....63
참고문헌.....64

표 목차

표 1. 산업별 사업기능별 인공지능 도입률.....	3
표 2. 광학렌즈 종류별 이미지 데이터 수.....	8
표 3. FA21BW Top 데이터셋.....	29
표 4. FA21BW Bottom 데이터셋.....	30
표 5. LF1A02W Top 데이터셋.....	30
표 6. FA21BW Top 데이터셋.....	30
표 7. LF2P01X Top 데이터셋.....	30
표 8. LF2P01X Bottom 데이터셋.....	30
표 9. PC 실험 환경.....	31
표 10. Anomaly Detection의 종류 및 데이터에 따른 분류.....	43
표 11. GAN 기반 모델 데이터 셋.....	47
표 12. GAN 모델 별 AUC 성능.....	48
표 13. 모델 별 AUC 성능 FA21BW Top.....	55
표 14. 모델 별 AUC 성능 FA21BW Bottom.....	55
표 15. 모델 별 AUC 성능 LF1A02W Top.....	56
표 16. 모델 별 AUC 성능 LF1A02W Bottom.....	56
표 17. 모델 별 AUC 성능 LF2P01X Top	56
표 18. 모델 별 AUC 성능 LF2P01X Bottom	56

그림목차

그림 1. 글로벌 스마트 팩토리 시장규모.....	2
그림 2. 인공지능 기반 결함 탐지 모델 개발 방법론 개요.....	4
그림 3. 구면 렌즈와 비구면 렌즈.....	7
그림 4. FA21BW 모델 상측 하측 이미지.....	9
그림 5. L1F1A02W 모델 상측 하측 이미지.....	9
그림 6. LF2P01X 모델 상측 하측 이미지.....	9
그림 7. 광학렌즈의 비정상 유형.....	10
그림 8. 극좌표 변환 예시.....	12
그림 9. LF2P01X 모델 상측 극좌표 변환 정상 이미지.....	12
그림 10. LF2P01X 모델 상측 극좌표 변환 비정상 이미지.....	12
그림 11. 수직 Sobel filter와 수평 Sobel filter 이미지.....	13
그림 12. Sobel filter 수직 방향 적용 예시.....	13
그림 13. Sobel filter 구현 단계별 이미지.....	14
그림 14. LF2P01X 모델 상측 Sobel filter 정상 이미지.....	14
그림 15. LF2P01X 모델 상측 Sobel filter 비정상 이미지.....	14
그림 16. Laplacian filter 이미지.....	15
그림 17. LF2P01X 모델 상측 Laplacian filter 정상 이미지.....	16
그림 18. LF2P01X 모델 상측 Laplacian filter 비정상 이미지.....	16
그림 19. 히스테리시스 엣지 트래킹 과정.....	17
그림 20. Canny edge 구현 단계별 이미지.....	18
그림 21. LF2P01X 모델 상측 Canny edge 비정상 이미지.....	18
그림 22. LeNet-5 Architecture.....	19
그림 23. Convolution layer 합성 곱 연산.....	20
그림 24. Average Pooling 적용 예시.....	21

그림 25. Fully connection layer.....	21
그림 26. ILSVRC Top 5 Error.....	22
그림 27. VGGNet Architecture.....	23
그림 28. Layer 깊이 별 오차율.....	24
그림 29. Residual Block.....	25
그림 30. ResNet Architecture.....	25
그림 31. Resnet residual plain 모델 성능.....	25
그림 32. DenseNet Architecture.....	26
그림 33. 종류별 Transfer Learning 방법.....	27
그림 34. ROC AUC.....	28
그림 35. AUC별 TN, TP분포.....	29
그림 36. Normal AUC.....	32
그림 37. Polar 변환 AUC	32
그림 38. sobel filter 적용 AUC	33
그림 39. Laplacian filter 적용 AUC.....	33
그림 40. Canny filter 적용 AUC	34
그림 41. CNN 모델 및 이미지 변환 별 AUC.....	34
그림 42. Sobel filter 적용 ResNet 모델 AUC	35
그림 43. FA21BW Top 히스토그램.....	36
그림 44. FA21BW Bottom 히스토그램.....	37
그림 45. LF1A02W Top 히스토그램.....	38
그림 46. LF1A02W Bottom 히스토그램.....	39
그림 47. LF2P01X Top 히스토그램.....	40
그림 48. LF2P01X Bottom 히스토그램.....	41
그림 49. AnoGAN Architecture.....	44
그림 50. GANomaly Architecture.....	45
그림 51. Skip-GANomaly Architecture.....	46

그림 52. 광학렌즈 이미지 별 AnoGAN 히스토그램.....49

그림 53. 광학렌즈 이미지 별 GANomaly 히스토그램.....50

그림 54. 광학렌즈 이미지 별 Skip-GANomaly 히스토그램.....51

그림 55. 보팅과 배깅 방식의 앙상블 학습.....52

그림 56. 부스팅 방식의 앙상블 학습.....53

그림 57. 하드 보팅과 소프트 보팅.....53

그림 58. 비정상 비율별 히스토그램 FA21BW Top.....57

그림 59. 비정상 비율별 히스토그램 FA21BW Bottom.....58

그림 60. 비정상 비율별 히스토그램 LF1A02W Top.....59

그림 61. 비정상 비율별 히스토그램 LF1A02W Bottom.....60

그림 62. 비정상 비율별 히스토그램 LF2P01X Top.....61

그림 63. 비정상 비율별 히스토그램 LF2P01X Bottom.....62

ABSTRACT

Development of an Optical Lens Defect Detection Model using Generative Adversarial Networks

Sang Hyun Lee

Advisor : Prof. Jongho Shin, Ph.D.

Department of Industrial Engineering

Graduate School of Chosun University

Currently, the defect determination of the optical lens is performed by a method through an inspection personnel. This not only consumes a lot of time and money during the inspection process, but also adversely affects the production quality of products due to continuous detection errors. To solve this problem, we tried to develop a defect detection model based on convolutional neural networks, but the performance of the deep learning model could not be secured due to the data imbalance problem. Therefore, in this paper, a defect determination model of optical lenses was developed using generative adversarial neural networks and convolutional neural networks. Three types of upper and lower images of optical lenses were used for development, and polar coordinate conversion, Canny edge, Sobel filter, and Laplacian filter were combined and used as image preprocessing methods. The convolutional neural network model conducted transfer learning using vggNet, ResNet, and DenseNet structures, and performance evaluation was conducted for each model, image conversion, and abnormal image ratio. The semi-supervised Anomaly detection models used AnoGan, Ganormaly, and skip-Ganormaly, and the optimal model was selected through performance evaluation of each model. After that, the performance was evaluated by implementing a weight-based ensemble model of the two models.

제 1 장 서론

1. 연구 배경

1.1 스마트팩토리와 인공지능

2016년 다보스포럼에서 클라우스 슈바프 세계경제포럼(World Economic Forum: WEF) 회장이 4차 산업혁명의 시대를 선언한 이후, 제조산업에서는 공정 개선 및 생산성 향상 더 나아가 전사적인 혁신을 위한 방법으로 빅데이터, 인공지능, 사물인터넷(IoT:Internet of things), 모바일 등, 정보 통신 기술 (ICT:Information & Communications Technology)를 활용한 스마트제조(Smart Manufacturing)·스마트팩토리(Smart Factory)의 도입을 추진하고 있다. 이를 증명하듯 관련 시장의 규모는 매년 평균적으로 9.3%씩 증가하고 있으며, 글로벌 리서치 회사 마켓앤드마켓(MarketsandMarkets)은 2024년까지 2,448억 달러 규모로 성장할 것으로 전망하고 있다[22](그림 1 참조). 이러한 추세로 볼 때 제조산업의 스마트화는 필연적이라 할 수 있다. 이에 정부에서는 2019년부터 2022년까지 스마트팩토리 3만 개 보급, 스마트 산업단지 10개 조성을 목표로 스마트팩토리의 양적 보급을 확대하였고 [23], 2020년에는 제11차 비상경제 중앙대책본부 회의 겸 제1차 한국판 뉴딜 관계장관회의를 개최하여 인공지능·데이터 기반 중소기업 제조혁신 고도화 전략을 발표하였다. 중소기업 제조혁신 고도화를 위한 전략의 핵심은 마이제조데이터를 위한 기반 마련 및 인공지능 중소벤처 제조 플랫폼(KAMP, Korea AI Manufacturing Platform) 구축이다[24]. 동 전략에서 인공지능 중소벤처 제조 플랫폼의 역할은 인공지능 기술개발을 위한 데이터 인프라 구축과 산·학·연 네트워크 구성을 통한 제조산업에서의 인공지능 기반 솔루션 개발 지원으로, 인공지능 기술 활용을 위한 기반 마련에 초점을 두고 있다. 이러한 글로벌 스마트팩토리 시장의 수요와 정부의 정책들을 종합해볼 때, 제조산업 분야에서 스마트팩토리와 인공지능 기술에 대한 국내외의 관심이 높아지고 있는 것으로 확인할 수 있다.

SMART FACTORY MARKET, BY REGION (USD BILLION)




그림 1. 글로벌 스마트 팩토리 시장규모

[출처, MarkestandMarkes Analysis, 2019]

1.2 제조 분야 인공지능

인공지능 기반의 솔루션을 개발하기 위해서는 일반적으로 다음과 같은 일련의 과정들이 필요하다. 가장 먼저 인공지능으로 해결하고자 하는 문제를 정의해야 한다. 이 과정에서는 해결의 어려움이 있는 문제를 인식하는 것뿐만 아니라 인공지능 기반 솔루션 개발에 필요한 시간, 비용 대비 얻어지는 이익과 기대효과 등을 고려해야 한다. 때에 따라서는 인공지능의 적용이 어렵거나, 다른 해결책을 사용할 때 더 효율성이 좋은 경우도 존재할 수도 있다. 앞선 상황 등을 고려하여 문제를 정의하였다면 다음으로는 데이터를 수집해야 한다. 데이터 수집 과정은 인공지능 기술 적용에 있어 가장 중요도가 높다고 할 수 있다. 대부분의 머신러닝, 딥러닝 알고리즘의 성능은 데이터의 양과 질에 따라 좌우될 수 있기 때문에 양질의 데이터를 수집하는 것이 중요하다. 양질의 데이터를 수집하기 위해서는 체계적인 데이터 수집과 지속적인 관리를 위한 시스템 구축이 선행되어야 한다. 하지만 시스템 구축 과정은 많은 시간과 비용이 필요로 한다. 이에 따라 규모가 작은 기업에서는 인공지능 기술의 개발 속도가 더디어지고 있는 것이 현실이다. 앞서 언급한 중소벤처 플랫폼(KAMP)과 같은 소규모 기업들의 데이터 인프라 구축을 위한 정책

들이 증가하고 있는 이유도 이러한 이유 때문이다. 데이터 수집 이후부터는 실질적인 인공지능 모델의 개발이 이루어지는데, 개발의 첫 단계는 데이터 분석에서부터 시작된다. 데이터를 분석하는 방법에는 여러 방법론이 존재하지만, 최근 머신러닝, 딥러닝 분야에서는 탐색적 데이터 분석(EDA:Exploratory Data Analysis)을 사용하는 것이 지배적이다. 탐색적 데이터 분석은 데이터를 다양한 시선에서 관찰하고 이해하는 모든 과정을 의미한다. 이후 탐색적 데이터 분석을 통해 습득한 데이터의 패턴 및 인사이트 등과 같은 유의미한 정보들을 토대로 인공지능 모델을 모델링하고, 학습을 진행한다. 학습 이후에는 성능 평가와 검증, 튜닝, 재학습 과정을 반복적으로 거쳐 모델의 성능과 안정성을 확보한다. 모델의 성능과 안정성이 확보되면 단계적으로 실제 현장에 적용하게 된다.

제조 분야에서 인공지능 기술은 인공지능의 활용 목적과 기대효과에 따라 광범위하게 적용될 수 있다. 대표적인 방법으로는 공정 설비의 이상 신호 감지 및 수명 예측을 통한 설비 건전성 예측·관리, 생산·수요 예측을 통한 생산성 향상 및 재고관리, 제품 결함 탐지 및 제품의 품질관리, 최적 의사결정 등이 있다. 인공지능 기술을 활용하면 지금까지 해결하지 못한 문제들의 솔루션을 도출할 수 있다. 하지만 제조 분야에서 인공지능의 도입 과정에는 어려움이 따른다. 인공지능의 법적·윤리적 책임부터 신기술 도입에 대한 반발, 고용과 노사 문제, 개발인력 및 기술 부족 등 다양한 문제를 마주하게 되는데 이러한 이유로 제조 분야에서 인공지능은 타 산업에 비해 도입률이 떨어지는 것을 확인할 수 있다. 2020년 맥킨지 앤 컴퍼니(Mckinsey & Company)에 따르면 생산·제조 영역에서의 인공지능 도입률은 12%에 불과하며, 제품·서비스 개발과 서비스 운영 과정에서 이보다 높은 21%의 도입률을 보이고 있다[21].

산업	HR	제조	마케팅, 영업	제품/서비스 개발	위험관리	서비스 운영	전략, 재무	SCM
전산업	8%	12%	15%	21%	10%	21%	7%	9%

표 1. 산업별 사업기능별 인공지능 도입률

2. 연구 목적

2.1 광학렌즈 결함 판정의 한계

광학렌즈의 품질검사는 정밀한 작업을 필요로 하여 숙련된 작업자에 의해 수작업으로 진행되고 있으며, 이로 인해 높은 품질 비용과 잦은 검측 오류 등과 같은 다양한 문제가 발생한다. 그중에서도 광학렌즈 품질검사에 있어 가장 문제가 되는 것은 검수 인력의 부족이다. 이러한 문제를 해결하기 위해 광학렌즈를 생산하는 기업에서는 양질의 검수 인력확보에 많은 시간과 비용을 들이고 있지만, 광학렌즈를 활용한 제품이 증가함에 따라 늘어나는 수요에 비하면 검수 인력이 턱없이 부족한 실정이다.

2.2 제조 현장에서의 인공지능

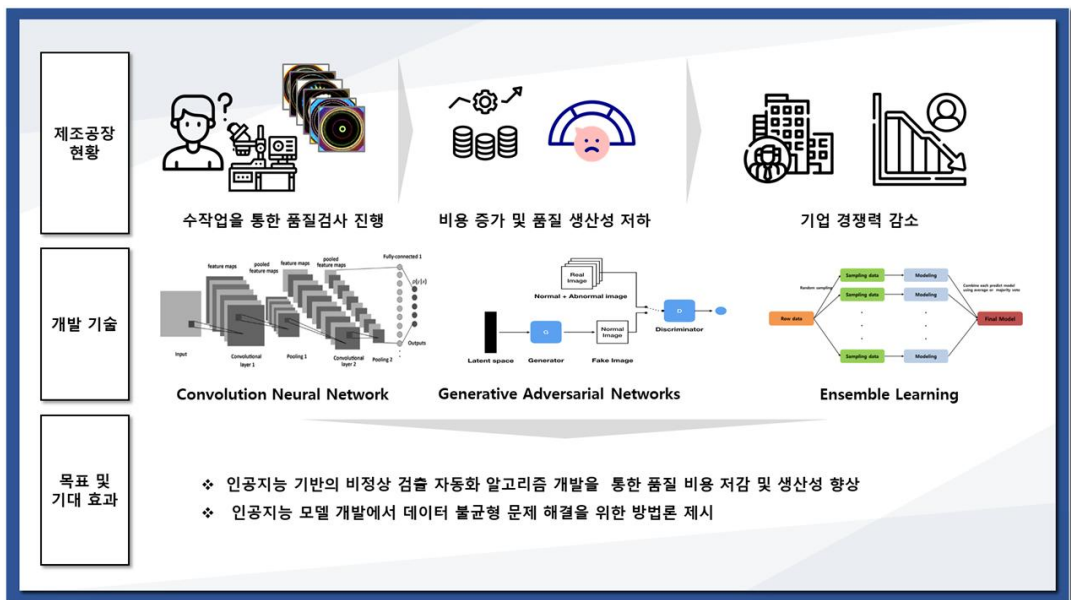


그림 2. 인공지능 기반 결함 탐지 모델 개발 방법론 개요

최근 산업현장에서는 제품의 생산, 수요, 품질, 서비스 등 산업현장에서 발생하는 문제에 대한 솔루션으로 인공지능 기술을 도입하고 있으며 일부 분야에서는 인공지능 기술의 적용을 통해 우수한 성과를 도출하였다. 하지만 실제 산업현장에

서 인공지능 기술의 적용까지의 과정에는 많은 제약이 존재하며 특히, 제조업 분야에서 이러한 제약은 더 큰 비중을 차지한다. 그중에서도 가장 문제가 되는 것은 데이터이다. 인공지능에서 데이터는 인공지능 모델의 도입 성공 여부에 지대한 영향을 미치며 일부 사람들은 양질의 데이터를 확보하는 것이 구조적으로 뛰어난 인공지능 모델을 개발하는 것보다 더 나은 결과를 얻어낼 수 있다고 말한다. 그러나 제조 현장에서 양질의 데이터를 구하는 것은 많은 시간과 비용을 투자해야 하기에 데이터 수집에 어려움이 있으며 이중 가장 문제가 되는 것이 비정상 데이터이다. 이는 제품과 설비의 안정성을 중요시하는 산업현장과 연관이 있으며 이러한 이유로 산업현장에서 수집되는 데이터는 정상과 비정상 데이터의 불균형 문제가 발생하는 경우가 많다. 이를 해결하기 위해 인공지능을 연구하는 연구자들은 다양한 모델 구조를 도입하거나 비정상 데이터를 증강 시키는 방법을 사용하였다. 하지만 이 같은 방법은 많은 시간과 비용이 필요할 뿐 아니라 적용에도 어려움이 있어 규모가 작은 기업에서는 위 같은 방법의 사용이 제한적일 수 있다. 하여 본 논문에서는 기존의 개발된 생성적 적대 신경망(GAN) 기반 모델과 CNN 기반 모델을 활용하여 데이터 불균형 문제를 극복할 수 있는 앙상블 형태의 모델 개발을 통해 광학 렌즈의 결함 판정모델을 개발하고자 한다.

3. 연구 구성

본 연구의 구성은 다음과 같다. 2장에서는 광학렌즈의 데이터의 개요와 다양한 이미지 변환 및 엣지 추출 방법을 설명하고, 변환 이미지를 나열한다. 이후 3장에서 Convolution Neural Network와 여러 종류의 Convolution Neural Network 모델 구조에 대해 논하고, VGGnet, Resnet, Densenet 구조를 활용한 Transfer Learning 을 통해 이미지 변환과 비정상 이미지 수에 따른 성능을 비교 분석하여 최적 이미지 변환과 CNN 모델의 조합을 도출한다. 4장에서는 Generative Adversarial Networks 기반의 Semi-supervised Anomaly Detection 모델에 관하여 설명한 후 Generative Adversarial Networks 기반의 모델인 AnoGAN, GANomaly, Skip-GANomaly 모델의 학습을 통해 앞서 3장에서 구현한 Convolution Neural Network 기반의 모델과 성능을 비교 분석한다. 이후 5장에서 Generative Adversarial Networks 기반의 모델과 Convolution Neural Network 기반 모델의 Anomaly score를 이용하여 비정상 검출기 개발 및 검출기 기반의 앙상블 모델을 구현하고, 앙상블 모델의 성능 평가 및 유효성을 분석한다. 마지막으로 6장에서는 연구의 결론 및 향후 연구 방향에 관하여 서술한다.

제 2 장 데이터 수집 및 변환

본 장에서는 연구 대상이 되는 광학렌즈에 대해 논하고, 광학렌즈 이미지 데이터의 수집 및 고장 유형을 나열한다. 이후 다양한 이미지 변환 및 엡지 추출 방법론에 대하여 설명하고, 광학렌즈 이미지를 변환하여 학습용 데이터 셋을 구성한다.

1. 광학렌즈 데이터

1.1 광학렌즈 개요

광학렌즈는 빛의 초점을 제어할 수 있도록 만든 렌즈로 스마트폰, 의료 분야, 전장용 전후방 카메라, 머신비전 등 다양한 분야에서 폭넓게 사용되고 있으며, 최근에는 자율주행 자동차와 빛을 이용한 광통신 분야에까지 활용되어 4차 산업혁명 시대의 제품개발의 중요한 요소로 자리매김하고 있다. 광학렌즈는 사용 용도와 목적에 따라 여러 종류로 구분되며, 본 논문에서는 광통신에 사용되는 비구면 렌즈를 대상으로 하였다. 비구면 렌즈는 구면 렌즈와 달리 일정한 곡률을 지니지 않고 렌즈의 중앙 부분과 가장자리 부분이 서로 다른 곡률을 가지는 렌즈로 기존 렌즈의 문제점이었던 초점이 일정하게 맺히지 않는 구면 수차 문제를 보완하기 위해 만들어졌다(그림 3. 참조).



그림3. 구면 렌즈와 비구면 렌즈

[출처, <https://www.wikiwand.com/ko/%EA%B5%AC%EB%A9%B4%EC%88%98%EC%B0%A8>]

비구면 렌즈는 구면 렌즈에 비해 얇고 가벼운 특징을 가지고 있으며, 좀 더 선명한 상을 얻을 수 있다는 장점이 있다. 그러나 인위적으로 곡률을 조절하여 초점을 맞추어야 하는 비구면 렌즈의 특성상 설계의 어려움이 있고 제작 비용 또한 일반 구면 렌즈에 비해 높아 위성용 렌즈나 광통신 같은 특수한 분야나 높은 수준의 수차 보정이 필요한 경우에 주로 사용된다.

1.2 광학렌즈 데이터 수집

본 연구에서 사용한 광학렌즈의 크기는 약 4.7mm x 5mm로 렌즈 검사장비를 통해 렌즈의 상측부와 하측부의 이미지를 촬영하여 데이터를 수집하였다. 데이터 수집을 위해 사용된 광학렌즈 모델은 FA21BW, L1F1A02W, LF2P01X 모델로 총 6종류 (FA21WBW 상측, FA21WBW 하측, L1F1A02W 상측, L1F1A02W 하측, LF2P01X 상측, LF2P01X 하측)의 렌즈 이미지 데이터를 사용하였다(그림 4-6 참조). 광학렌즈의 이미지는 모델에 따라 다른 형태를 보이며, 동일 모델이라 할지라도 이미지 촬영 시 빛과 측정 장치의 영향으로 색과 중심점의 편차가 존재한다. 광학렌즈 종류별 수집 데이터의 수는 정상 이미지와 비정상 이미지를 각각 500여 장씩, 한 종류당 1000여 장의 광학렌즈 이미지 데이터를 수집하였다.

	Top			Bottom		
	FA21BW	L1FA02W	LF2P01X	FA21BW	L1FA02W	LF2P01X
Normal	500	504	500	518	504	516
Abnormal	428	472	501	463	500	509
Total	928	976	1001	981	1004	1025

표 2. 광학렌즈 종류별 이미지 데이터 수




그림 4. FA21BW 모델 상측 하측 이미지




그림 5. LF1A02W 모델 상측 하측 이미지




그림 6. LF2P01X 모델 상측 하측 이미지

광학렌즈의 비정상 유형은 크게 파손, 이물, 스크래치로 나눌 수 있다(그림 7 참조). 렌즈의 불량 검수 과정에서 파손과 스크래치 유형의 경우 정상 이미지와 극명한 차이가 존재하여, 쉽게 정상과 비정상의 분류가 가능하지만, 이물로 인한 비정상 유형의 경우 이물의 크기와 정도에 따라 구분이 어려워 검수 과정에서도 난해한 경우가 많다. 이러한 문제를 해결하기 위해서는 명확한 검수 기준과 일관성 있는 판정이 필요하지만, 인력을 통한 검수 과정에서 일관성을 유지하기란 쉽지 않은 문제이다.



그림7. 광학렌즈의 비정상 유형

2. 이미지 변환 및 엣지 추출

앞서 언급했듯 일반 이미지에서는 이물 유형의 비정상 이미지는 정도에 따라 구분
 이 어려운 경우가 존재한다. 이를 위해 이번 절에서는 여러 종류의 이미지 변환 및
 엣지 추출 기법을 활용하여 비정상 이미지의 비정상 영역을 강조하고자 한다.
 이미지 변환에 사용되는 이미지는 변환 별 차이를 비교하기 위해 LF2P01X 모델의
 상측부 이미지를 사용하였다.

2.1 극좌표 변환

일반적으로 평면상의 위치를 나타낼 때 2차원 데카르트 좌표계를 사용한다. 2차
 원 데카르트 좌표계는 좌표평면이라고도 하며, 좌표평면은 서로 수직인 x 축과 y 축
 으로 이루어진 xy 평면을 사용하여 정의한다. 좌표평면상의 위치를 각도와 거리를
 이용하여 나타내면 극좌표계로 변환이 가능하다(그림 8. 참조). 극좌표 변환 시
 원점에서부터 점까지의 거리 r 은 피타고라스 정리에 의해 $\sqrt{x^2+y^2}$ 로 나타낼 수
 있으며, 사이 각 θ 는 삼각함수의 성질을 사용하여 $\arctan \frac{x}{y}$ 형태로 표현할 수 있
 다. 연구에서 수집한 광학렌즈의 이미지를 좌표평면상의 이미지로 보았을 때, 이
 이미지의 극좌표 변환 시 그림 9과 그림 10과 같은 형태로 표현할 수 있다. 이때 극
 좌표 변환 이미지의 행 방향은 중심과의 거리 r , 열 방향은 사이 각 θ 가 된다.

$$x = r \cos \theta, \quad y = r \sin \theta$$

$$r = \sqrt{x^2 + y^2}, \quad \theta = \arctan \frac{y}{x}$$

LF2P01X 모델의 상측부 이미지를 놓고 보았을 때, 이물 유형 비정상 이미지에서
 대부분의 이물은 중심으로부터 첫 번째 원과 두 번째 원 사이 영역과 두 번째 원
 과 세 번째 원 사이의 영역에 분포한다. 이 영역을 극좌표 변환 이미지에서 확인
 하면 그림8-9의 붉은색 박스 내부의 영역 볼 수 있어 변환 전 이미지에 비해 좀
 더 직관적으로 이물 여부의 확인이 가능하다.




그림 8. LF2P01X 모델 상측 극좌표 변환 이미지




그림 9. LF2P01X 모델 상측 극좌표 변환 정상 이미지




그림 10. LF2P01X 모델 상측 극좌표 변환 비정상 이미지

2.2 Sobel filter

Sobel filter는 1968년 Irwin Sobel이 고안한 edge 검출 알고리즘으로[17] 일반적으로 3x3 크기의 y축을 기준으로 x값을 변화시키는 수직 필터와 x축을 기준으로 y 값을 변화시키는 수평 필터를 사용한다(그림 11. 참조). sobel filter의 수직 방향 계산은 그림 12과 같이 이미지와 필터의 합성곱 연산을 통해 진행된다. 연산 과정에서 결괏값이 입력 범위를 벗어나는 경우가 발생할 수 있으므로 Scale과 offset 조정하여 출력값의 범위를 지정해야 한다. 그림 12에서는 Scale과 offset 을 각각 0.4와 128로 지정하였다. 이 과정을 광학렌즈 이미지에 적용하면 그림 13 과 같은 이미지를 얻을 수 있다. 그림 13는 좌측부터 Gray scale, 수직 필터 적용, 수평 필터 적용, 수직 수평 병합 이미지이다. 수직 필터 이미지와 수평 필터 이미지의 병합은 L1 norm 또는 L2 norm을 사용한다. 본 연구에서는 L1 norm을 적용하였다.




그림 11. 수직 Sobel filter와 수평 Sobel filter 이미지




그림 12. Sobel filter 수직 방향 적용 예시




그림 13. Sobel filter 구현 단계별 이미지




그림 14. LF2P01X 모델 상측 Sobel filter 정상 이미지




그림 15. LF2P01X 모델 상측 Sobel filter 비정상 이미지

2.3 Laplacian filter

2차 미분 필터는 점차 변화하는 영역까지 민감하게 edge를 검출하여 다량의 edge가 추출되는 1차 미분 필터의 단점을 보완하기 위해 사용되며, edge의 중심 부분을 검출할 수 있다는 장점이 있다. 대표적인 2차 미분 필터로는 Laplacian filter와 Laplacian of Gaussian filter가 있다. Laplacian filter의 수식은 다음과 같다. $\nabla^2 f(x,y) = \frac{\delta^2 f}{\delta x^2} + \frac{\delta f}{\delta y^2}$ 이 식을 아래와 같이 정리하면, 그림 16의

Laplacian 1과 같은 필터로 표현이 가능하다. 그림 17과 그림 18은 Laplacian filter를 광학렌즈 이미지에 적용한 이미지로 Laplacian filter 이미지는 앞서 변환한 sobel filter 이미지에 비해 얇고 부드러운 형태의 edge 검출이 가능하지만, 비정상 영역에서 edge의 검출력이 떨어지는 것으로 나타났다.

$$\nabla^2 f(x,y) = \frac{\delta^2 f}{\delta x^2} + \frac{\delta f}{\delta y^2}$$

$$\nabla^2 f(x,y) = 2f(x,y) - f(x-1,y) - f(x+1,y) + 2f(x,y) - f(x,y-1) - f(x,y+1)$$

$$\nabla^2 f(x,y) = 4f(x,y) - f(x-1,y) - f(x+1,y) - f(x,y-1) - f(x,y+1)$$

0	-1	0
-1	4	-1
0	-1	0

Laplacian 1

-1	-1	-1
-1	8	-1
-1	-1	-1

Laplacian 2

그림 16. Laplacian filter 이미지




그림 17. LF2P01X 모델 상측 Laplacian filter 정상 이미지




그림 18. LF2P01X 모델 상측 Laplacian filter 비정상 이미지

2.4 Canny edge

Canny edge 검출기는 1986년 John F. Canny가 제시한 방법[3]으로 낮은 에러율과 높은 정확도 가진다는 장점에서 현재까지도 Edge Detection 분야에서 가장 사용 빈도가 높은 검출기법이다. Canny edge 검출기는 4단계의 과정을 통해 edge를 검출한다[10]. 첫 단계에서는 이미지의 노이즈를 제거하는 단계로 일반적으로 5x5의 가우시안 필터(Gaussian Filter)를 사용한다. 그림 20의 좌측 상단 이미지는 가우시안 필터를 통한 노이즈 제거 후 이미지이다. 두 번째 단계에서는 이미지에 Sobel 커널을 수평과 수직 방향으로 적용하여 각각의 gradient G_x , G_y 값을 계산하고, 각각의 gradient 값을 활용하여 이미지 픽셀의 gradient의 크기 G 와 방향 θ 를 구한다. 이때 각도 θ 는 0, 45, 90, 135도로 근사하여 처리한다. 그림 20의 우측 상단 이미지는 수평과 수직 방향으로 Sobel 커널 적용 후 결합한 이미지이다. 세 번째 단계는 비최대 억제(Non-maximum Suppression) 단계로 비최대 억제단계에서는 gradient의 크기가 국소 최대(local Maximum)인 edge 픽셀을 제외한 주변 픽셀을 제거한다. 그림 20의 좌측 하단 이미지는 비최대 억제 후 이미지이다. 네 번째 단계는 히스테리시스 엣지 트래킹(Hysteresis edge tracking) 단계로 edge 검출을 위해 최소, 최대 임계값을 사용한다. 히스테리시스 엣지 트래킹은 gradient 크기가 최대 임계값을 초과할 경우 해당 부분을 edge로 보고 추적을 시작한다. 이 과정에서 gradient 크기가 최소 임계값 이하인 부분은 edge가 아니라고 판단한다(그림 19. 참조). 그림 19의 우측 하단 이미지는 Canny edge 검출 결과이다.

$$G = \sqrt{G_x^2 + G_y^2}, \theta = \tan^{-1} \frac{G_y}{G_x}$$




그림 19. 히스테리시스 엣지 트래킹 과정




그림 20. Canny edge 구현 단계별 이미지

본 연구에서는 Canny edge 검출 시 최소 임계값과 최대 임계값을 100과 200으로 지정하였다. 그림 21은 Canny edge를 이용한 edge 이미지이다. Canny edge 이미지에서는 원본 이미지에서 잘 보이지 않던 비정상 영역의 확인이 가능했다. 하지만 이를 위해서는 전체 이미지에 적합한 포괄적인 최소, 최대 임계값을 찾는 것이 선행되어야 한다.




그림 21. LF2P01X 모델 상측 Canny edge 비정상 이미지

제 3 장 CNN 기반 결함 검출

본 장에서는 앞서 2장에서 변환한 이미지와 합성곱 신경망(CNN:Convolution Neural Network) 구조를 활용하여 전이학습(transfer learning)을 적용하고, 성능 평가 및 비교를 통해 광학렌즈의 결함판정에 적합한 CNN 모델과 이미지 변환 방법을 도출한다.

1. Convolution Neural Network

합성곱 신경망(CNN:Convolution Neural Network)은 인공지능 분야의 한 분야인 딥러닝 구조 중 하나로 이미지와 영상 분야에서 주로 활용되는 알고리즘이다. 합성곱 신경망[8]은 1989년 Yann LeCun에 의해 처음 소개되었으며, 1998년 Yann LeCun의 LeNet-5[9] 구조를 시작으로 다양한 형태의 CNN 모델 구조로 발전되었다.




그림 22. LeNet-5 Architecture[9]

LeNet-5 구조는 Input Layer와 3개의 Convolution Layer, 2개의 Subsampling Layer, Fully Connected Layer, Output Layer로 구성된다. Convolution Layer에서는 이미지와 커널의 합성곱 연산을 통해 이미지의 특징을 추출한다. 합성곱 연산은 그림 23과 같이 이미지 행렬에 $N \times M$ 크기의 커널을 겹쳤을 때, 동일 위치의 원소들의 곱의 합으로 나타낼 수 있다. 이러한 연산 과정을 커널의 위치를 이동시키면서 반복적으로 수행하면 feature map을 도출해낼 수 있다. 이때 feature map

의 크기는 커널의 크기 K_h, K_w , 패딩의 크기 P , 커널의 이동 보폭 S 을 통해 조절이 가능하다. 만약 입력 이미지의 채널이 여러 개일 경우 입력 채널 수에 맞는 커널을 생성하여 합성곱 연산을 진행하고, 채널 별 출력 행렬을 합하여 단일 채널의 feature map을 생성한다. 이 과정에서 입력 채널 수와 같은 커널 집합의 수를 증가시키면 다채널의 feature map을 만들어 낼 수 있다.

$$(0 \times 1) + (0 \times 0) + (0 \times 0) + (0 \times 1) + (1 \times 0) + (1 \times 1) + (0 \times 0) + (1 \times 1) + (0 \times 0) = 2$$

$$(0 \times 1) + (0 \times 0) + (0 \times 0) + (1 \times 1) + (1 \times 0) + (1 \times 1) + (1 \times 0) + (0 \times 1) + (2 \times 0) = 2$$

$$O_h = \text{floor}\left(\frac{I_h - K_h + 2P}{S} + 1\right), \quad O_w = \text{floor}\left(\frac{I_w - K_w + 2P}{S} + 1\right)$$

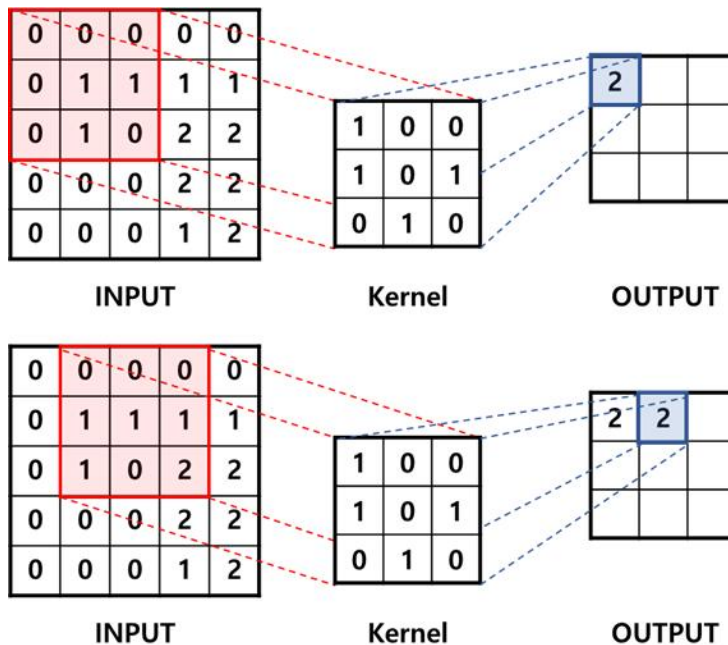


그림 23. Convolution layer 합성곱 연산

Subsampling Layer는 합성곱 연산의 출력 행렬의 크기를 줄이기 위해 사용된다. 현대에는 Subsampling 대신 Pooling이라는 이름으로 불리고 있으며 출력 행렬의 크기를 줄이기 위한 방법으로는 Max Pooling, Average Pooling, Min Pooling 등이 있다. LeNet-5 구조에서는 Average Pooling을 사용하였다. Average Pooling은 커

널과 이미지 행렬을 겹쳤을 때 해당 영역의 값들을 평균으로 나타낸다(그림 24. 참조). 이때 2×2 커널에 보폭을 2로 하면 입력 이미지의 크기를 절반으로 줄일 수 있다.




그림 24. Average Pooling 적용 예시

Fully Connected Layer는 다음 Layer의 노드들과 완전연결된 Layer로 이전 Layer가 다차원 행렬일 경우 그림 25와 같이 1차원 벡터로 평탄화하는 과정을 거쳐 연결된다. Fully Connected Layer는 일반적으로 CNN 모델의 끝단에 위치하여 분류를 결정하는데 Class의 수에 따라 Softmax 함수나 Sigmoid 함수 등의 활성화 함수를 연결하여 사용한다. LeNet-5에서는 활성화 함수를 사용하지 않고, 고정된 가중치의 유클리드 방사형 기저 함수(Gaussian connection)를 통해 10개의 Class로 분류하였다.




그림 25. Fully connection layer

2. CNN Model

LeNet-5 구조 이후 다양한 구조의 CNN 모델이 개발되었으며, CNN 모델들은 빅데이터와 GPU의 발전과 더불어 컴퓨터 비전 분야의 성장에 큰 역할을 하였다. CNN 모델의 발전에 있어 중요한 매개체로 작용한 것은 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)이다. ILSVRC는 대용량의 이미지 셋을 활용한 이미지 분류 알고리즘의 성능을 평가하는 대회로 2010년부터 2017년까지 개최되었다. 이 중 2010년과 2011년을 제외한 나머지 대회에서 CNN 기반 영상 인식 모델이 우승을 차지하며 CNN 기반 영상 인식 모델 성능의 신뢰도를 높여 나갔다.




그림 26. ILSVRC Top 5 error

[출처, https://www.researchgate.net/figure/Algorithms-that-won-the-ImageNet-Large-Scale-Visual-Recognition-Challenge-ILSVRC-in_fig2_346091812]

ILSVRC 대회에서 CNN 기반의 영상 인식 모델이 우승한 2012년 AlexNet[7] 이후 CNN에 관한 연구가 매년 진행되면서 모델의 성능을 높이기 위한 시도로 확산하였고, ZFNet[20], GoogLeNet[19], VGGNet[16], ResNet[5] 등 다양한 CNN 기반의 모델들이 제안되었다(그림 26. 참조). 모델 제안 과정에서 성능 향상에 도움이 되는 방법들 또한 함께 제안되었으며, ReLu[12], Drop-out[18], Data Augmentation, 3×3 커널 등 일부 방법론들은 현대까지도 CNN 모델 개발의 필수 요소로 사용되고 있다.

2.1 VGGNet

VGGNet은 2014년 ILSVRC에서 준우승을 차지한 모델로 layer 수에 따라 VGG16과 VGG19로 구분되는데, 이는 VGGNet의 연구 목적과 연관이 있다. VGGNet 연구의 목적은 CNN의 깊이에 따른 이미지 분류의 영향을 알아보기 위한 것으로 16개의 layer와 19개의 layer를 사용하였다. VGGNet 모델에서 주로 사용되는 VGG16은 그림 26과 같이 13개의 Convolution Layer와 3개의 Fully Connected Layer로 구성되며, 3×3 커널과 2×2 Max Pooling을 사용한다는 구조적인 특징이 있다.




그림 27. VGGNet Architecture

[출처, <https://neurohive.io/en/popular-networks/vgg16/>]

일반적으로 CNN 모델에서 깊이를 증가시키면 모델의 비선형성을 높일 수 있어 비약적인 성능 향상이 가능하다. 하지만 깊이가 깊어질수록 파라미터의 수가 증가하여 overfitting의 위험과 연산량 또한 증가한다. 그 때문에 CNN 모델의 성능을 개선하기 위해서는 전체 파라미터 수를 줄이면서 모델의 깊이를 증가시키는 것이 필요하다. VGGNet은 이러한 딜레마를 해결한 모델이다. VGGNet 이전의 CNN 모델을 활용한 이미지 분류 모델은 비교적 큰 수용영역을 갖는 11×11 커널이나 7×7 커널을 사용하였다. 그러나 VGG 모델은 3×3 크기의 커널을 반복적으로 사용하여 layer를 더 깊이 쌓음과 동시에 학습 파라미터의 수를 획기적으로 감소시켰다. 이를 통해 이미지 분류 모델의 정확도를 개선 시킬 수 있었다.

2.2 ResNet

VGGNet 이후 CNN 모델의 layer 깊이와 성능의 관계에 관한 연구들이 진행되면서 CNN을 연구하는 연구자들은 layer를 깊게 쌓을수록 성능이 점진적으로 증가할 것으로 예상했다. 하지만 실제 모델에서는 layer의 깊이가 20층을 넘어가게 되면 정확도가 포화상태에 도달하여, 성능이 저하되는 Degradation 문제가 발생하였다 (그림 28. 참조). 이를 두고 일부 연구자들은 이 문제의 원인을 layer가 깊어졌을 때 최적화가 제대로 되지 않아 발생하는 것으로 생각하였다. 최적화 문제를 해결하기 위해서는 Optimizer를 새로 개발하거나 새로운 구조의 모델을 만들어야 했는데, Optimizer를 만드는 것은 매우 어려운 문제였기 때문에 대부분의 연구자들은 CNN 모델의 구조 개발 연구에 초점을 두었다[5].




그림 28. Layer 깊이 별 오차율[5]

ResNet 모델에서는 layer를 깊게 쌓았을 때 발생하는 Degradation 문제를 해결하기 위해 Residual Learning Framework를 도입하였다. 이 방법은 일반적인 신경망에서 $H(x) = x$ 가 되도록 학습했던 것과 달리 출력값에 입력값을 제거하여 잔차를 줄이는 방향으로 학습하는 $F(x) = H(x) - x$ 형태의 구조를 사용한다. 이를 다시 전개하면 $H(x) = F(x) + x$ 로 표현할 수 있는데, 이는 결과적으로 $F(x)$ 를 최소화하여 $H(x) = x$ 가 되는 것으로 목표로 한다. 이렇게 하면 $F(x) = 0$ 이라는 목표값을 갖게 되어 학습이 더 쉬워지는 효과를 얻을 수 있다. 이때 입력값 x 를 출력값에 더해주기 위해 Skip Connection 구조를 사용한다. Skip Connection 구조는 입력값이 하나 이상의 layer들을 건너뛰어 출력에 더해주는 역할을 한다. 그림 29는 Skip Connection을 통해 생성된 Residual Block의 구조이다.




그림 29. Residual Block[5]

ResNet 모델은 VGGNet 구조를 기반으로 만들어졌다. 그림 30은 ResNet 34-layer 모델로 기존의 VGGNet-19 구조에 컨볼루션 블록을 추가하여 모델을 깊게 만든 후 Skip Connection을 더해 만들어졌다. 이렇게 만들어진 34-layer residual 모델은 34-layer plain 모델보다 더 높은 성능을 보이는 것을 확인할 수 있다(그림 31. 참조).

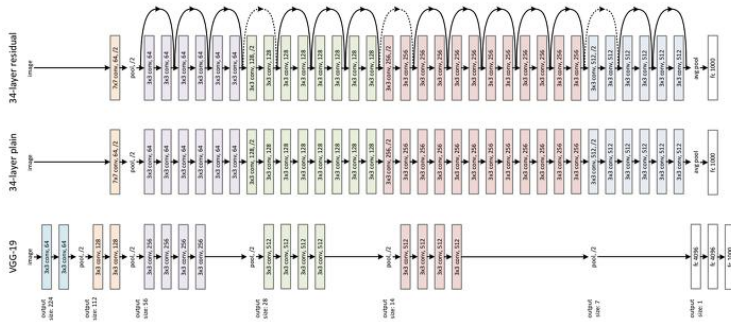


그림 30. ResNet Architecture[5]




그림 31. Resnet residual plain 모델 성능[5]

2.3 DenseNet

DenseNet[6]은 ResNet의 Skip Connection 구조의 확장된 형태인 Dense Connectivity 구조를 활용하여 성능을 개선한 모델이다. Dense Connectivity는 기존 출력값에 직전의 입력값을 더해주는 Skip Connection 구조와 달리 모든 이전 layer의 입력값들과 출력값을 연결하는 구조를 지니고 있다(그림 32. 참조). 이러한 연결구조를 수식으로 나타내면 아래와 같이 표현할 수 있다. 모든 layer를 연결하는 DenseNet의 특성상 피쳐 맵의 채널 수가 많은 경우 계속해서 채널이 증가하는 경우가 발생하는데, 이를 위해 DenseNet에서는 각 layer의 피쳐 맵의 채널 수를 낮게 설정한다.

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}])$$

Dense Connectivity를 통해 DenseNet 모델은 기존의 CNN 모델들이 가지고 있던 깊은 layer를 거치면서 처음 layer의 피쳐 맵에 대한 정보가 사라지는 feature reuse 문제와 역전파(Backpropagation) 과정에서 Gradient의 기울기가 소실되는 Vanishing Gradient 문제를 개선할 수 있었다. 또한, 적은 채널 수의 피쳐 맵을 생성하여 모델의 파라미터 수와 연산량을 감소시키는 효과를 얻을 수 있었다.




그림 32. DenseNet Architecture[6]

3. Transfer Learning

전이학습(Transfer Learning)은 대량의 데이터 셋을 통해 학습된 사전 학습 모델의 구조와 가중치를 사용하여 다른 데이터 혹은 다른 문제에 맞게 재학습시켜 사용하는 방법으로 컴퓨터 비전 분야에서 이미지 분류 문제를 해결하기 위해 주로 사용된다. 전이학습 모델은 전체 모델을 재학습 시키는 방법과 일부 layer만 훈련하는 방법 그리고 Fully Connected Layer만 학습시키는 방법 중 하나를 사용하는 데, 이는 데이터의 양과 사전 학습된 모델과 해결하고자 하는 문제의 유사도에 따라 결정한다. 전이학습 방법을 사용하면 전이학습을 수행하지 않은 모델들보다 비교적 빠르고 높은 성능의 모델의 구현이 가능하다.




그림 33. 종류별 Transfer Learning 방법

[출처, towardsdatascience.com, Transfer learning from pre-trained models]

4. 구현 및 평가

4절에서는 2장에서 변환한 이미지를 VGGNet, ResNet, DenseNet 전이학습 모델에 학습시켜 비정상 데이터의 양에 따라 전이학습 모델과 이미지 변환 별 분류성능을 비교하고, 비정상 이미지 분류를 위한 최적의 조합을 결정한다.

4.1 성능 평가 지표

본 연구에서는 이미지 분류 모델의 성능 평가를 위한 지표로 ROC(Receiver Operating Characteristic) curve와 AUC(Area Under the Curve)를 사용하였다. ROC curve는 모든 분류 임계값에서 모델의 성능을 보여주는 그래프로 FPR(False positive rate)과 TPR(True Positive Rate)를 각각 x축과 y축으로 활용한다. TPR 과 FPR은 아래와 같은 식으로 계산되고, 이를 다시 표현하면 민감도(Sensitivity)와 1-특이도(Specificity)로 나타낼 수 있다. 민감도(참이라고 판단한 것 중 실제 참의 비율)와 특이도(거짓이라고 판단한 것 중 실제 거짓의 비율)는 이진 분류 문제에서 정확도를 평가하기 위해 사용되며 두 지표는 반비례의 관계를 갖는다.

$$TPR = \frac{TP}{TP+FN} \quad FPR = \frac{FP}{FP+TN}$$

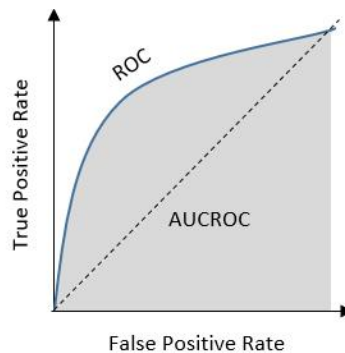


그림 34. ROC AUC

[출처, towardsdatascience.com, 11 Evaluation Metrics Data Scientists Should Be Familiar with- Lessons from A High-rank Kagglers' New Book]

좋은 성능의 모델을 고르기 위해서는 민감도와 특이도가 높은 모델을 선택해야 하는데, 이는 ROC curve 그래프의 좌측 상단에 가장 근접한 ROC curve를 보이는 모델을 선택하는 것과 동일하다(그림 34. 참조). 하지만 ROC curve만으로는 정량적인 비교가 불가능하므로 ROC curve 아래의 면적을 나타내는 AUC를 사용한다. 즉, AUC가 높은 모델일수록 성능이 좋은 모델이라 할 수 있다. 그림35는 AUC 값에 따라 변화하는 True Negative와 True Positive의 분포이다.

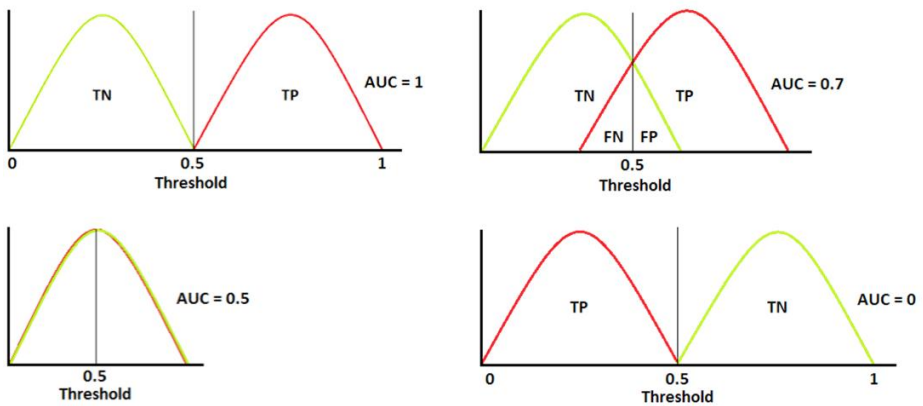


그림 35. AUC별 TN, TP분포

[출처, <https://webnautes.tistory.com/1675>]

4.2 Dataset

실험에서 사용된 데이터 셋은 각 렌즈의 변환 이미지를 활용하였으며, 학습 데이터와 검증 데이터, 테스트 데이터의 수를 6:2:2 비율로 설정하였다. 이후 전체 모델의 학습 데이터 정상과 비정상의 비율을 맞추기 위해 검증 데이터를 가감하여 데이터 셋을 구성하고, 비정상 데이터의 양에 따른 성능 변화를 확인하기 위해 비정상 데이터의 수를 10%부터 100%까지 10%씩 증가하여 학습을 진행하였다.

FA21BW Top	Train										valid	test
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0		
Normal	300										100	100
Abnormal	30	60	90	120	150	180	210	240	270	300	42	86
total	330	360	390	420	450	210	240	540	570	600	142	186

표 3. FA21BW Top 데이터셋

FA21BW Bottom	Train										valid	test
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0		
Normal	300										114	104
Abnormal	30	60	90	120	150	180	210	240	270	300	70	93
total	330	360	390	420	450	210	240	540	570	600	184	197

표 4. FA21BW Bottom 데이터셋

LF1A02W Top	Train										valid	test
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0		
Normal	300										103	101
Abnormal	30	60	90	120	150	180	210	240	270	300	77	95
total	330	360	390	420	450	210	240	540	570	600	180	196

표 5. LF1A02W Top 데이터셋

LF1A02W Bottom	Train										valid	test
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0		
Normal	300										103	101
Abnormal	30	60	90	120	150	180	210	240	270	300	100	100
total	330	360	390	420	450	210	240	540	570	600	203	201

표 6. FA21BW Top 데이터셋

LF2P01X Top	Train										valid	test
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0		
Normal	300										100	100
Abnormal	30	60	90	120	150	180	210	240	270	300	100	101
total	330	360	390	420	450	480	510	540	570	600	200	201

표 7. LF2P01X Top 데이터셋

LF2P01X Bottom	Train										valid	test
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0		
Normal	300										112	104
Abnormal	30	60	90	120	150	180	210	240	270	300	107	102
total	330	360	390	420	450	210	240	540	570	600	219	206

표 8. LF2P01X Bottom 데이터셋

4.3 실험 환경

본 연구에서 사용된 실험 환경은 Window 10 기반 python 3.8에서 수행되었다. 실험에 사용된 하드웨어의 구성은 Intel Xeon Silver 4210, 2.2GHz CPU 2개와 256GB의 메모리 RTX 3090, 24GB 그래픽 카드로 이루어졌으며, 딥러닝 구현을 위한 프레임워크로는 PyTorch를 사용하였다.

실험 환경	
CPU	Intel Xeon Silver 4210 2.2GHz*2
RAM	256GB
GPU	RTX 3090 24GB
OS	Window 10
Framework	PyTorch

표 9. PC 실험 환경

4.4 성능 평가 및 분석

본 실험에서는 정상 데이터와 비정상 데이터의 비율이 낮은 경우와 비율이 높은 경우 즉, 데이터에 불균형이 존재할 때와 존재하지 않을 때의 전이학습 모델과 이미지 변환 별 성능을 비교하기 위해 비정상 데이터의 수를 0%부터 10%씩 순차적으로 증가시켜 학습을 진행하였다. 학습 시 사용한 Optimizer와 loss function은 Adam Optimizer(Adaptive Moment Estimation)와 Binary Cross Entropy를 사용하였으며, learning rate, batch size, Epoch는 각각 0.0002, 64, 100으로 설정하였다. 학습 모델의 성능 비교를 위해 이미지 변환 별 AUC를 그림 36-40와 같이 나타내었으며, 그림의 x축과 y축은 비정상 데이터의 비율과 AUC로 표현하였다. 실험결과 극좌표 변환을 하였을 때와 기본 이미지에서는 비정상 이미지가 증가함에 따라 전반적인 모델의 성능이 안정적으로 상승하는 것을 확인할 수 있었고, Edge와 필터를 사용한 이미지 변환에서는 광학렌즈 종류와 전이학습 모델에 따라 국소적으로 높은 성능을 보였으나 비정상 데이터가 증가함에도 불구하고 성능이 저하되는 경향을 보였다. 단순히 성능만을 놓고 볼 때 Edge와 필터 기반의 모델이 상대적으로 떨어지는 것처럼 보였으나 비정상 데이터가 충분할 때 기본 이미지와 극좌표 변환 모델에 비해 정상과 비정상의 명확한 분류가 가능했다. 이를 좀 더 자세히 비교하기 위해 전이학습과 이미지 변환 별 AUC를 그림 41과 같이 나타내었다.

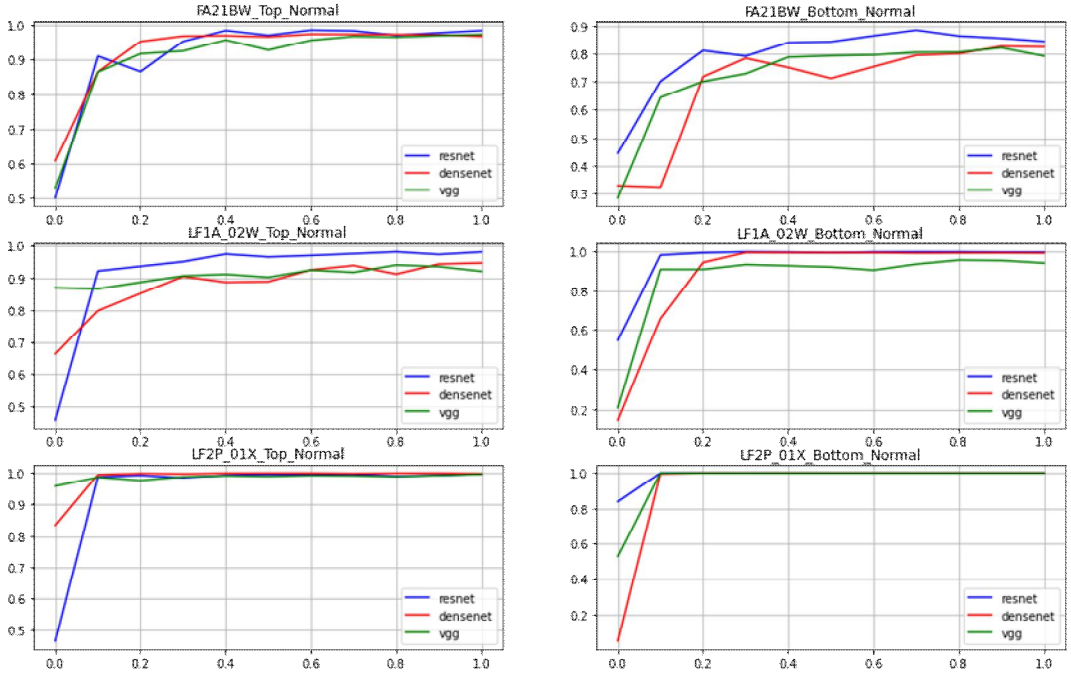


그림 36. Normal AUC

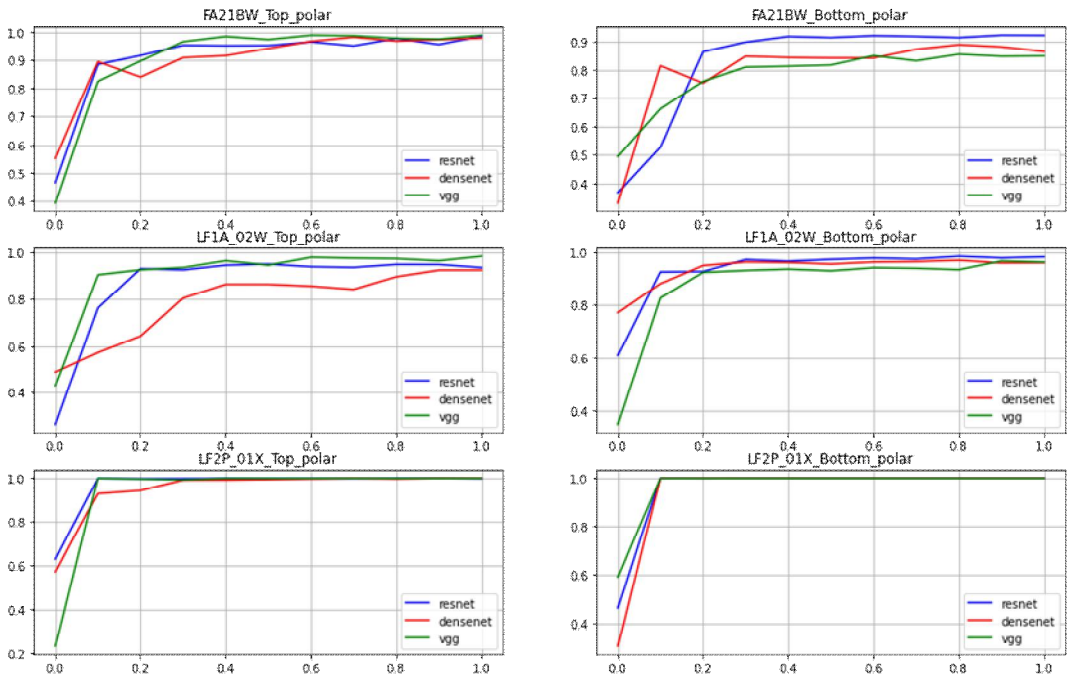


그림 37. Polar 변환 AUC

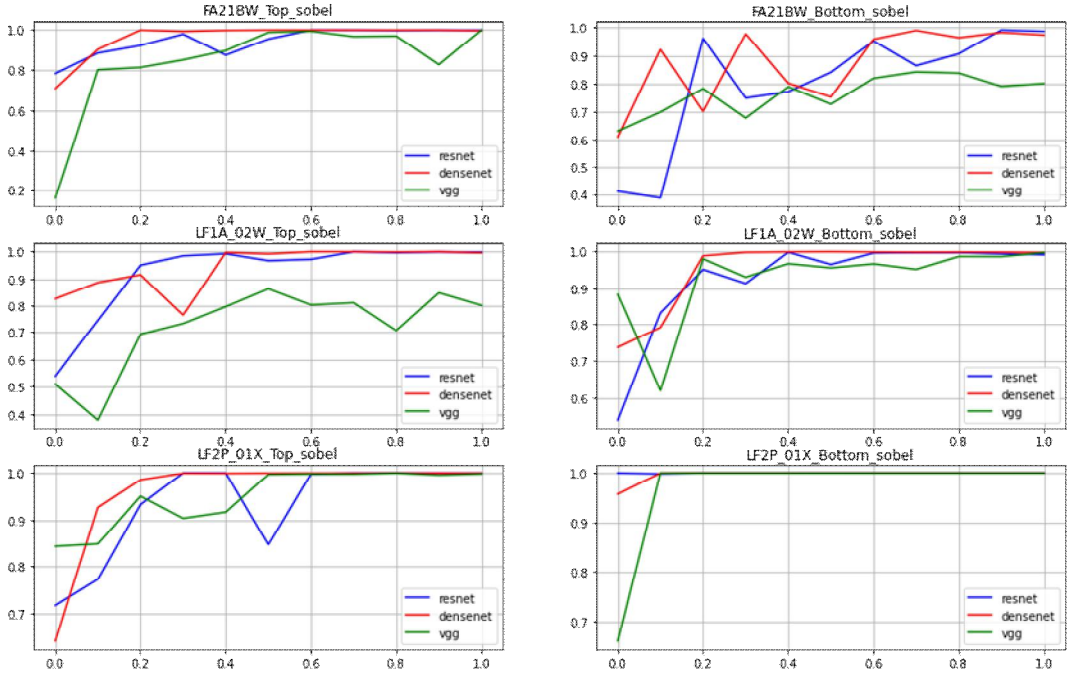


그림 38. sobel filter 적용 AUC

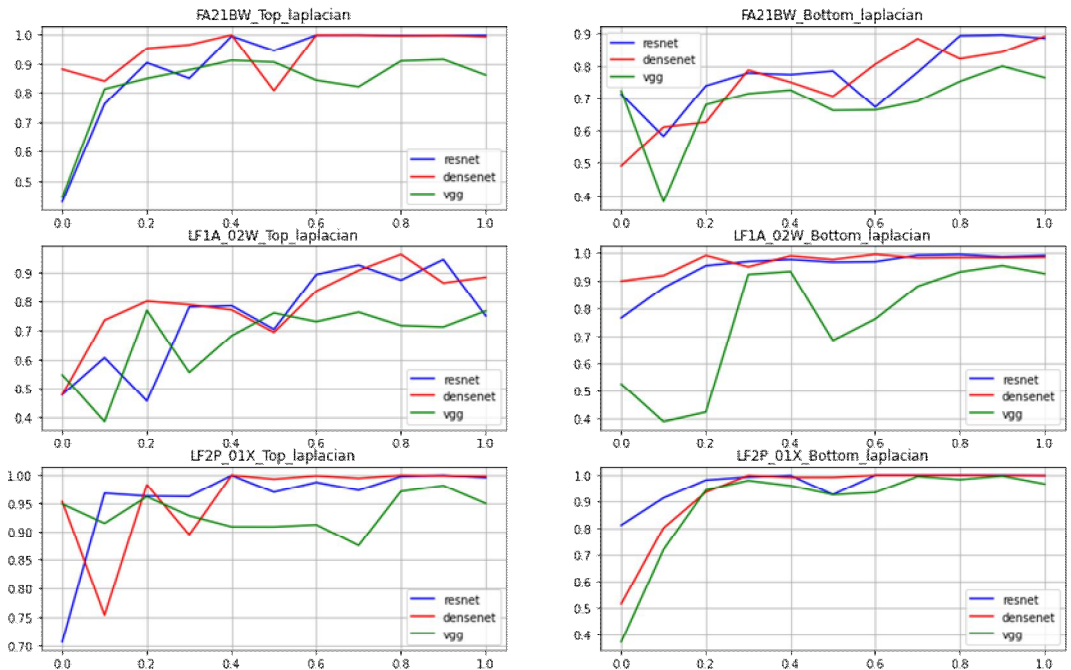


그림 39. Laplacian filter 적용 AUC

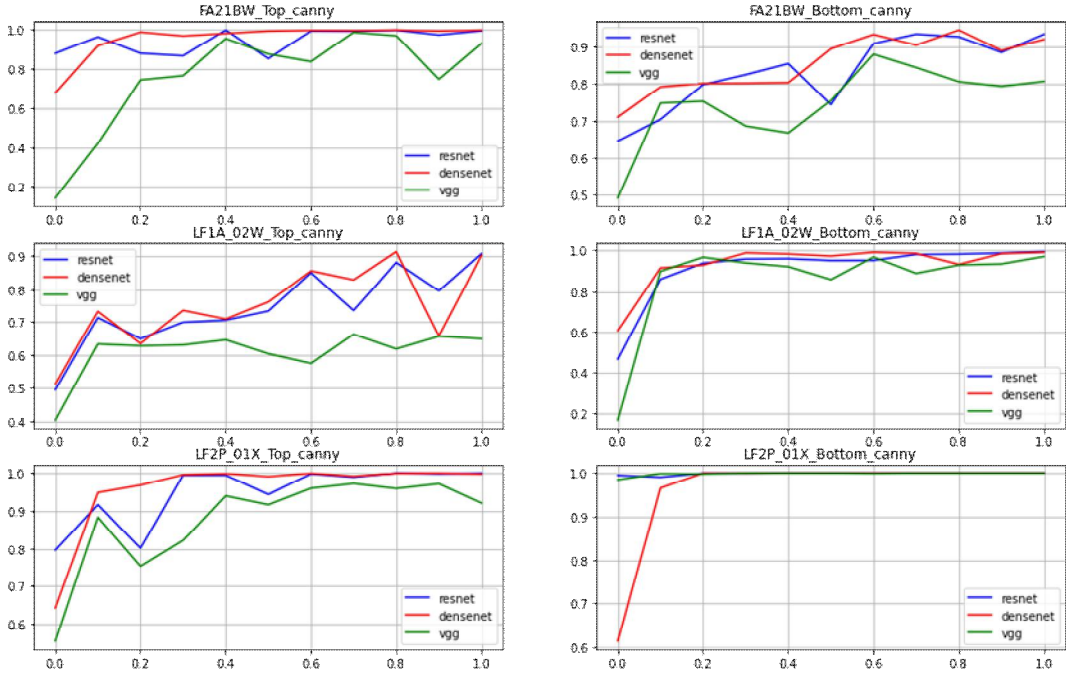


그림 40. Canny filter 적용 AUC

전이학습을 기반으로 종합하였을 때 비정상 데이터 수의 40%를 기점으로 전체 모델에서 0.9 이상의 AUC를 보였고, ResNet 모델을 사용할 때 가장 우수한 것으로 나타났다. 이미지 변환 기반의 종합의 경우는 앞서 언급한 것과 같이 기본 이미지 모델과 극좌표 변환, Sobel filter 적용 모델에서 성능이 우수하였으며, 비정상 데이터 수의 50% 이후부터는 Sobel filter 적용 모델이 일반 이미지 모델과 극좌표 변환 모델에 대비하여 성능이 높은 것을 확인할 수 있었다(그림 41. 참조).




그림 41. CNN 모델 및 이미지 변환 별 AUC

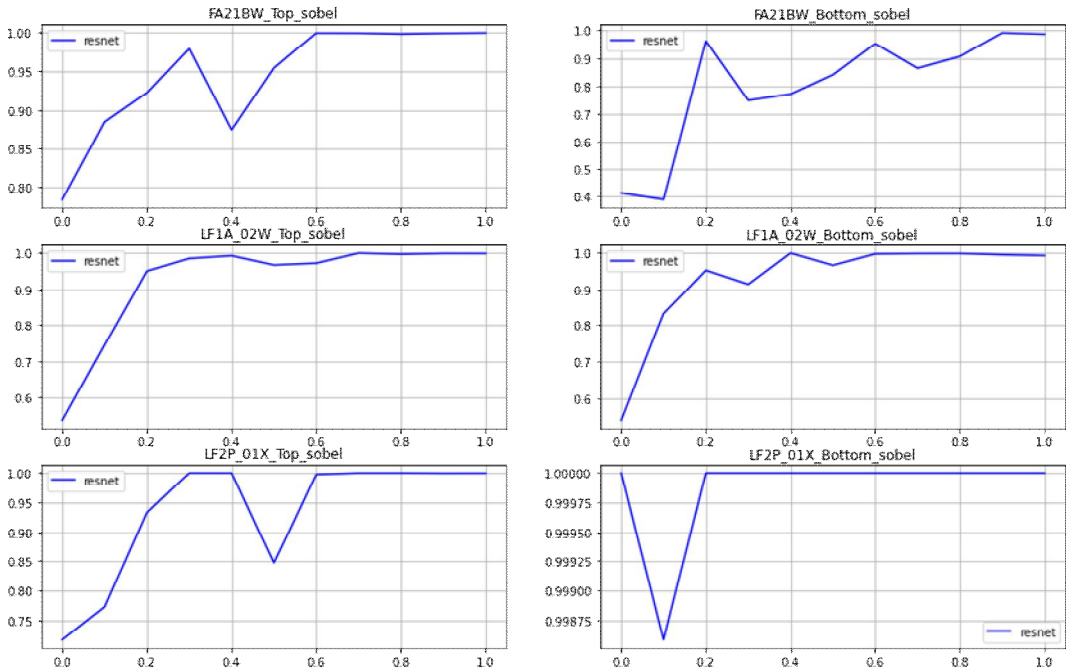


그림 42. Sobel filter 적용 ResNet 모델 AUC

위의 결과를 토대로 Sobel Polar 모델을 전체 광학렌즈 모델 분류를 위한 최적 조합으로 선정하였다. 해당 조합의 AUC 그래프(그림 42. 참조)를 보면 모든 광학렌즈 모델에서 전반적으로 높은 성능을 보였으며 특히 비정상 데이터의 수의 50% 이후일 때 대부분의 모델에서 AUC 값이 0.95 이상으로 정상 비정상 이미지 분류 모델의 기대 성능 이상의 결과를 보이며 CNN 모델의 적용 가능성을 확인할 수 있었다. 하지만 50% 미만의 경우에는 AUC 값이 상승하다가 떨어지는 경향을 보였고, 30% 이하에서는 대부분 기대 성능 AUC 0.95 이상에 미치지 못하였다(그림 43. 참조). 이를 정상과 비정상 이미지의 히스토그램을 통해 시각화하면 분류 모델의 성능을 직관적으로 확인할 수 있다(그림 43-48. 참조). 해당 그림은 정상과 비정상 이미지의 예측 확률을 히스토그램으로 나타낸 것으로 좌측 상단부터 우측으로 비정상 데이터 수의 10%씩 증가하였을 때의 이미지로 예측 확률이 1에 가까울수록 비정상 이미지로 판단한다. 결과적으로 CNN 모델을 활용한 분류 모델만으로는 비정상 데이터의 수가 정상 이미지 수에 비해 부족할 때 발생하는 데이터 불균형 문제를 완벽하게 해결하지 못하였으며 기대성능 이상의 모델을 구현하기 위해서는 최소 150 여장의 이상의 비정상 이미지와 300 여장의 정상 이미지가 필요하였다.

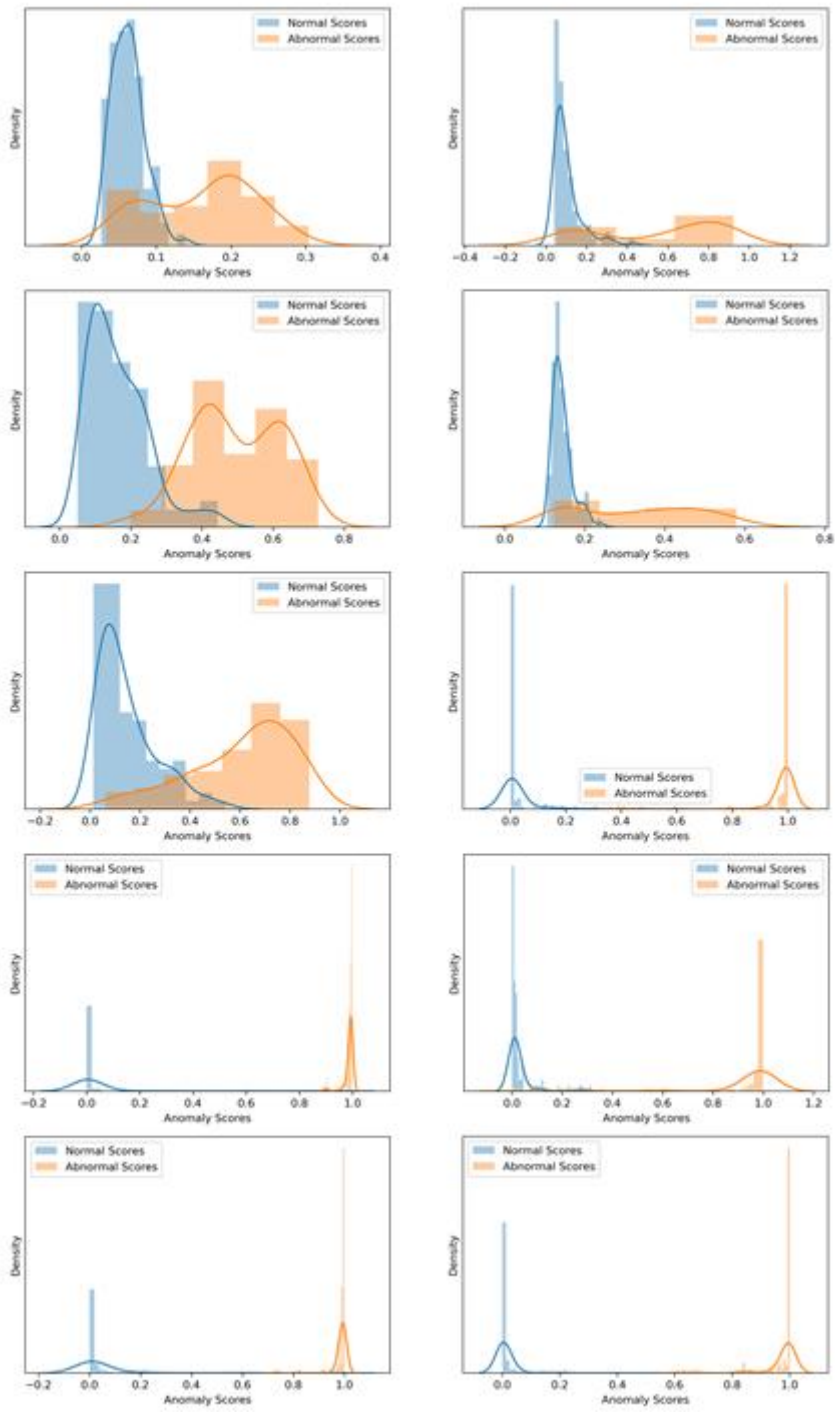


그림 43 FA21BW Top 히스토그램

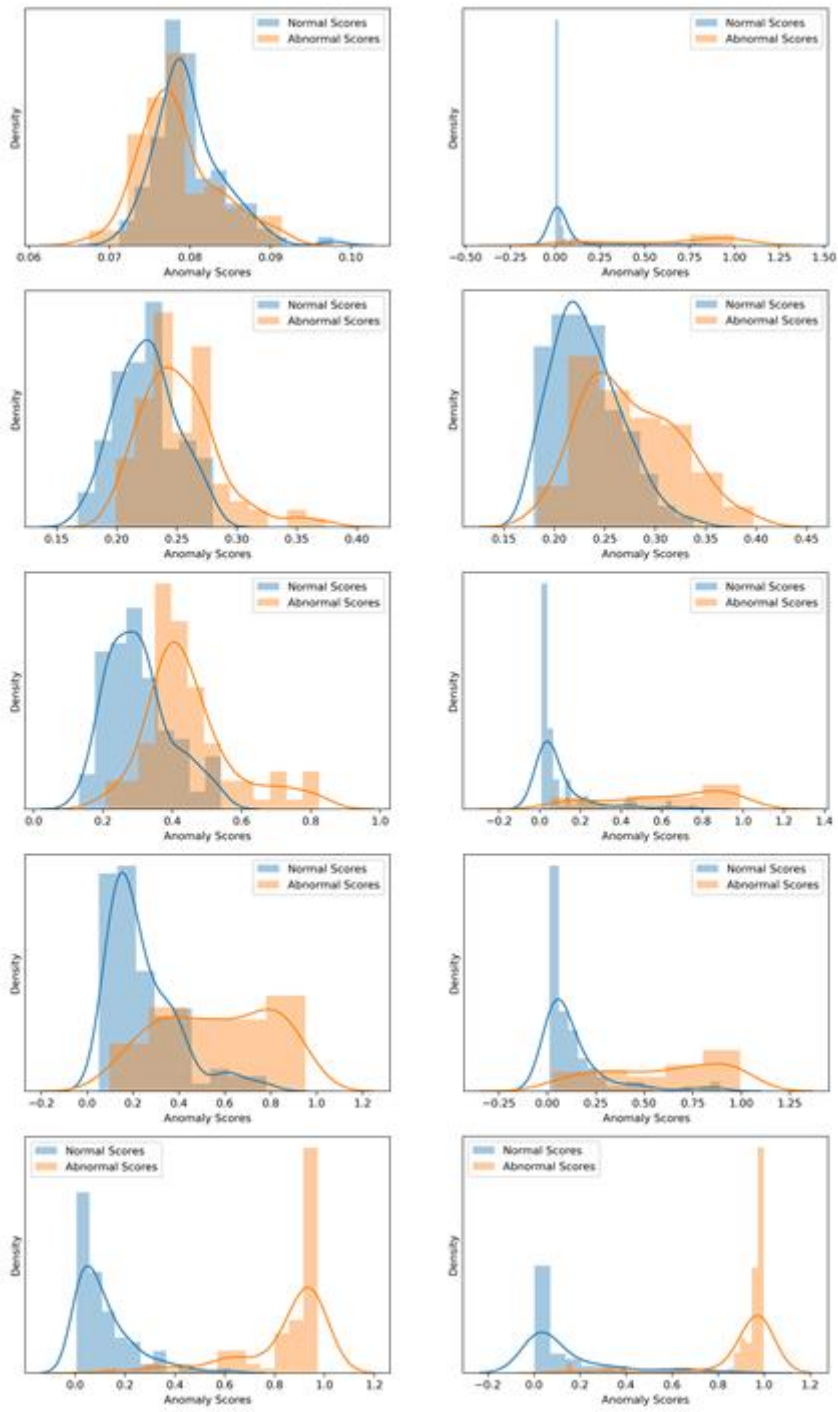


그림 44 FA21BW Bottom 히스토그램

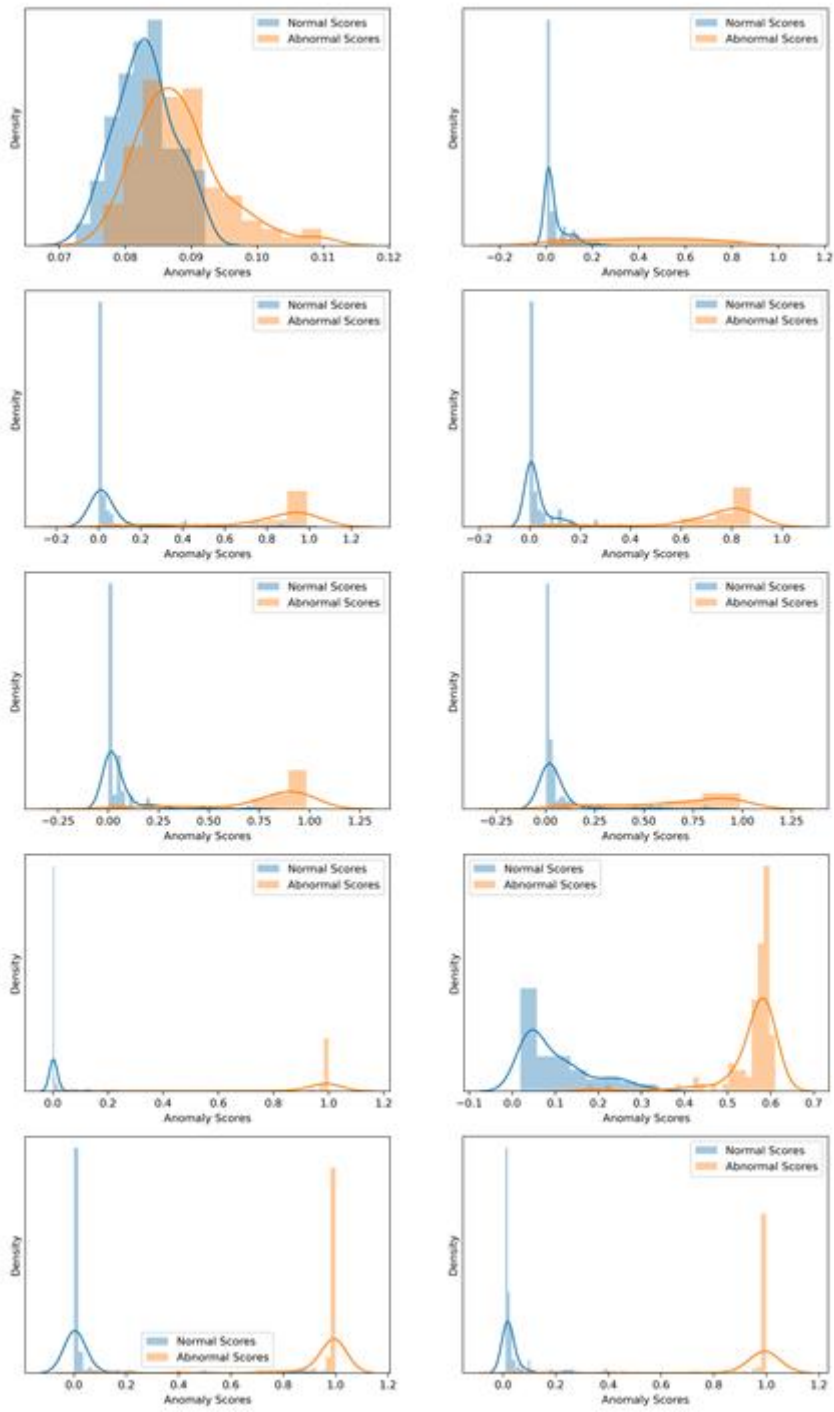


그림 45 LF1A02W Top 히스토그램

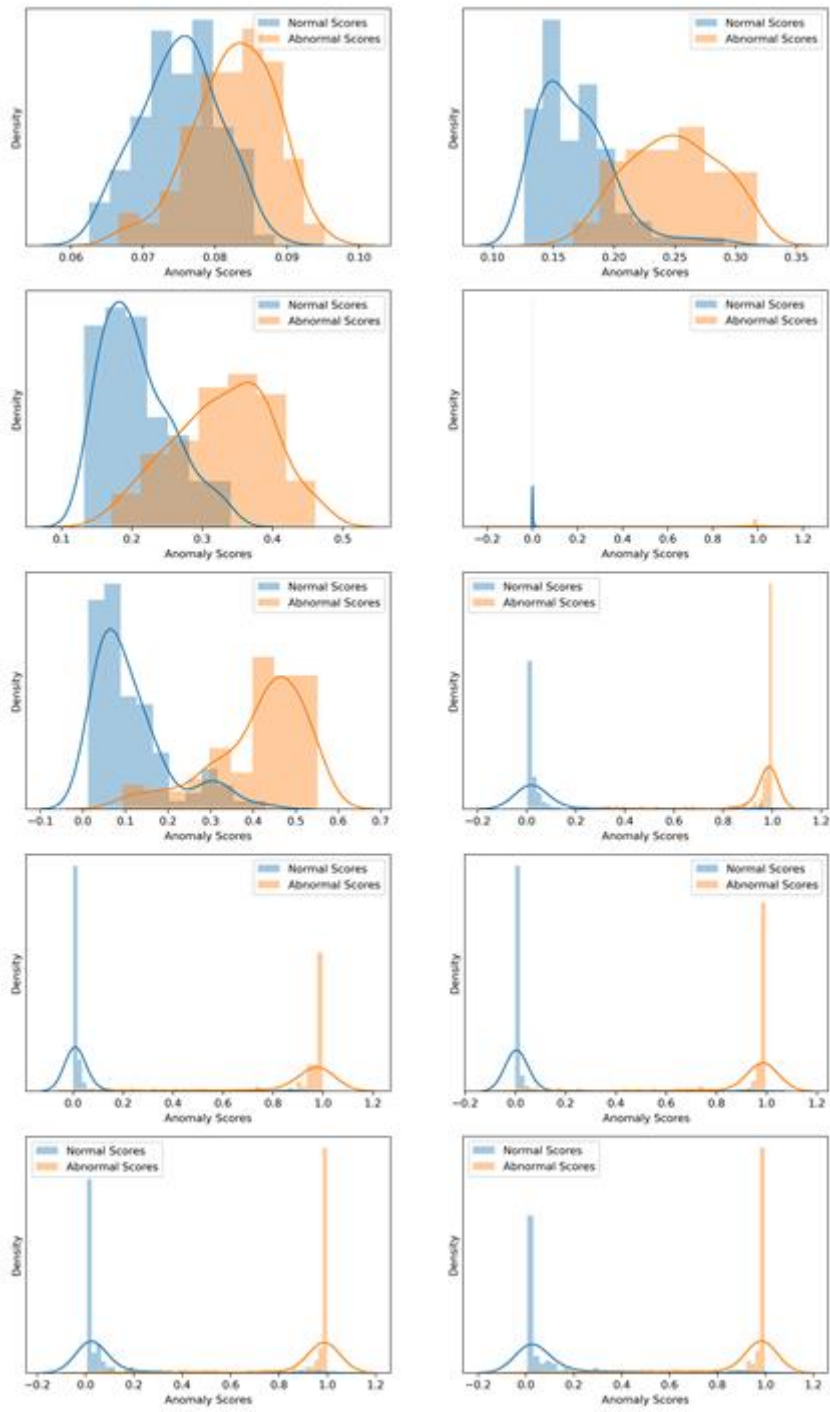


그림 46 LF1A02W Bottom 히스토그램

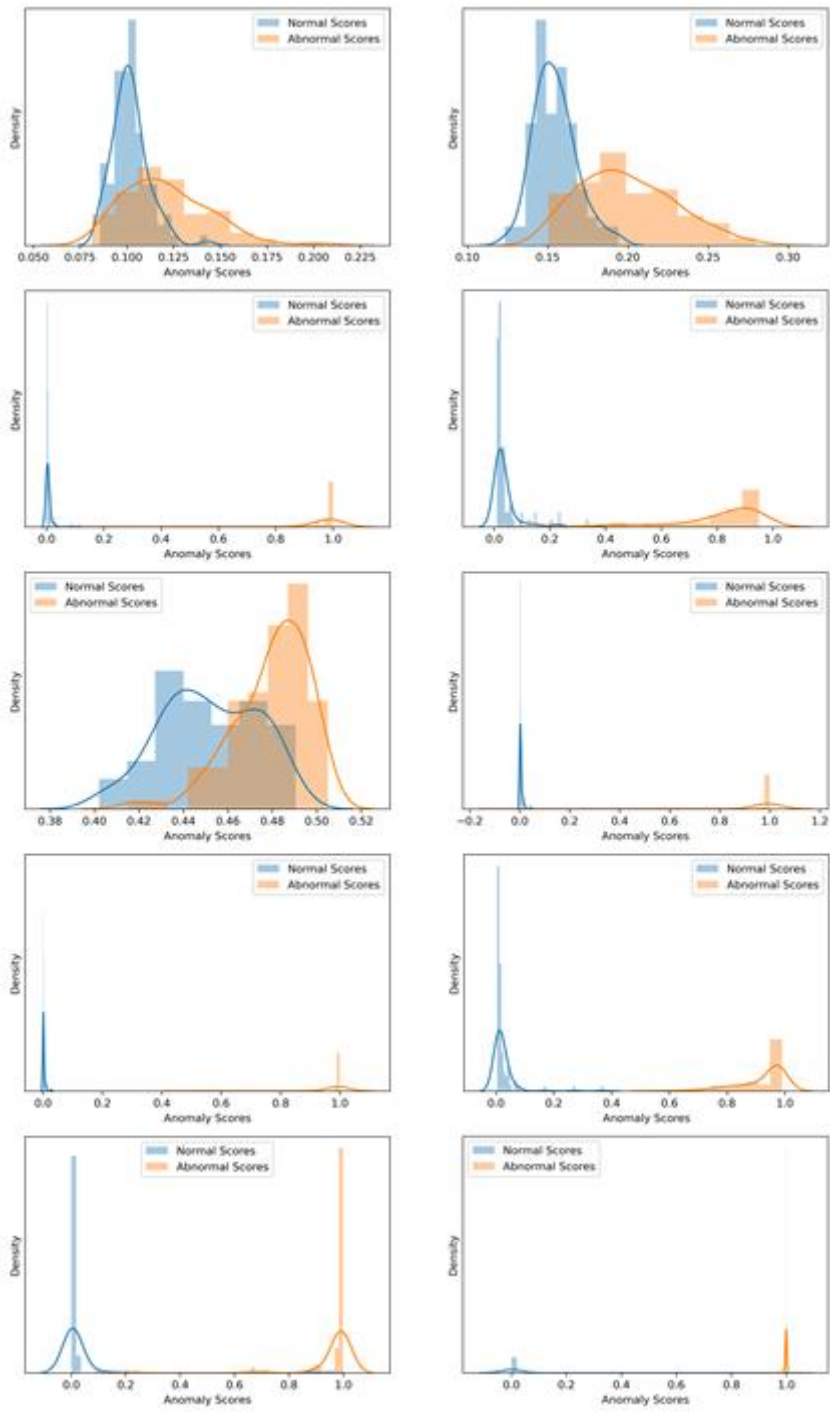


그림 47 LF2P01X Top 히스토그램

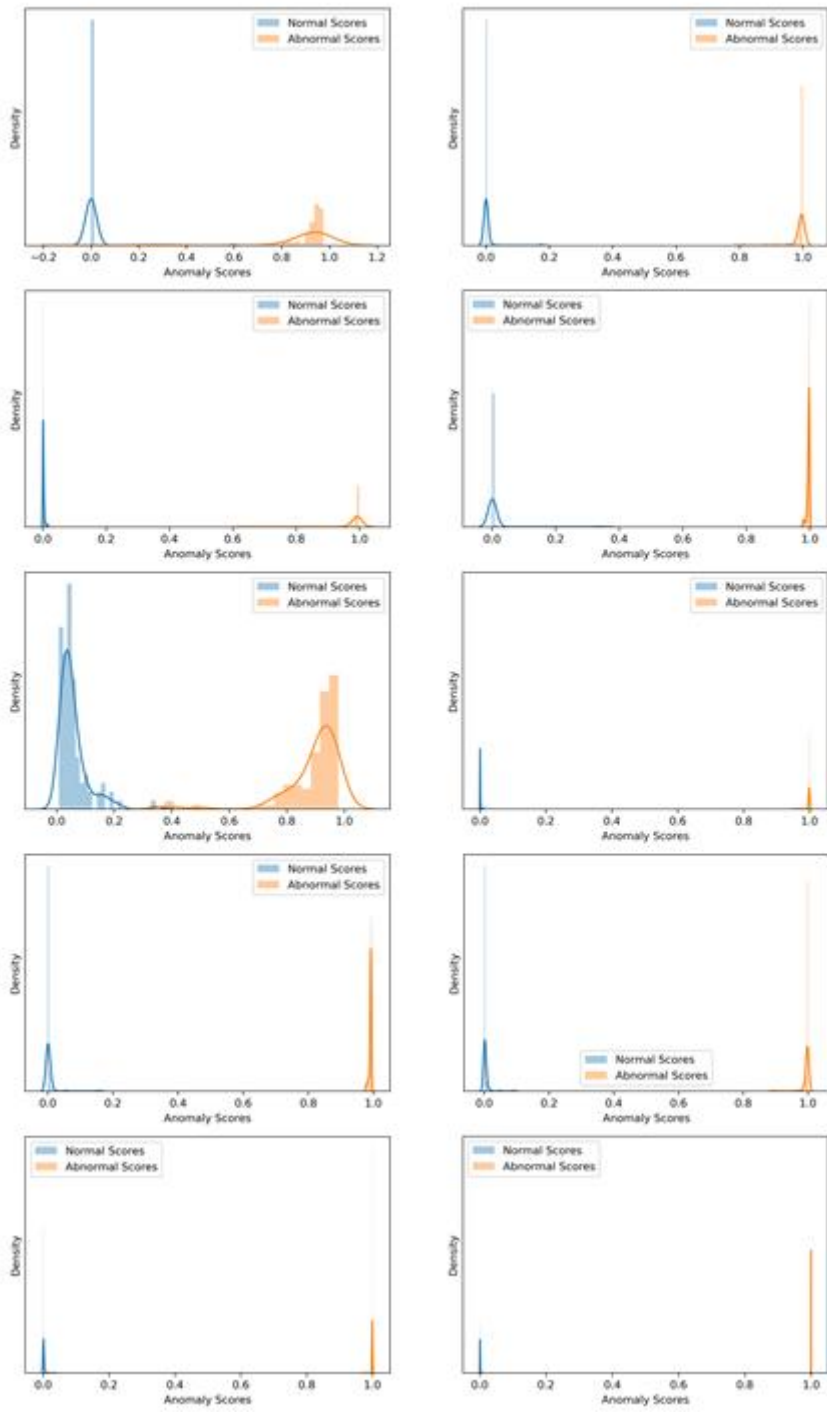


그림 48 LF2P01X Bottom 히스토그램

제 4 장 Anomaly Detection

본 장에서는 Anomaly Detection에 관해 논하고, GAN을 활용한 비정상 탐지 모델인 AnoGAN, GANomaly, Skpi-GANomaly에 대해 설명한다. 이후 GAN 모델을 기반으로 비정상 탐지 모델을 구현하여 앞서 3장에서 구현한 CNN 모델과의 비교를 통해 두 모델의 차이점을 분석한다.

1. Anomaly Detection

Anomaly Detection은 정상 데이터와 비정상, 이상, 특이 데이터를 구별해내는 문제로 학습 데이터 셋의 비정상 데이터의 포함 여부와 레이블의 유무에 따라 Supervised Anomaly Detection과 Semi-supervised Anomaly Detection 그리고 Unsupervised Anomaly Detection으로 구분된다. Supervised Anomaly Detection의 경우 레이블이 있는 정상과 비정상 데이터를 가지고 학습하는 Supervised Learning 방식으로, 다른 Anomaly Detection 방법에 비해 높은 정확도를 가진다. 하지만 이를 구현하기 위해서는 레이블 된 정상과 비정상의 데이터를 균형적으로 확보해야 하는데 이 과정에서 비정상 데이터 수집에 많은 시간과 비용이 소모되어 실제 현장에 적용이 어렵다는 단점이 있다. 다음으로 Semi-supervised Anomaly Detection이다. Semi-supervised Anomaly Detection은 One-Class Anomaly Detection이라는 이름으로 불리기도 하며 레이블이 있는 정상 데이터만을 사용하여 학습을 진행한다. 이 방법은 Supervised Anomaly Detection의 문제점이었던 비정상 데이터 확보의 어려움을 고려하지 않아도 된다는 장점이 있는 반면에 Supervised Anomaly Detection보다 상대적으로 낮은 정확도를 갖는 단점이 있다. 마지막으로 레이블이 존재하지 않을 때 사용되는 Unsupervised Anomaly Detection이다. Unsupervised Anomaly Detection은 레이블링 과정이 필요하지 않아 시간과 비용 측면에서 앞선 두 모델보다 장점이 있지만 세 모델 중 가장 성능이 떨어지고 hyper parameter에 따라 성능이 민감하게 반응하여 hyper parameter의 튜닝을 통한 최적화가 필요하다. 이를 정리하면 표 10과 같이 나타낼 수 있다.

	정상 데이터	비정상 데이터
Supervised Anomaly Detection	0	0
Semi-supervised Anomaly Detection	0	X
Unsupervised Anomaly Detection	레이블이 존재하지 않음	

표 10. Anomaly Detection의 종류 및 데이터에 따른 분류

본 연구에서는 현재 확보된 데이터와 앞서 개발한 모델의 문제점을 고려하여 Semi-supervised Anomaly Detection 모델을 개발 모델로 선정하였다. 딥러닝을 활용한 Semi-supervised Anomaly Detection 모델은 크게 Auto Encoder[11]를 사용하는 방법과 GAN[4]을 사용하는 방법으로 나눌 수 있으며 실험에서는 GAN 기반의 모델인 AnoGAN, GANomaly, Skip-GANomaly를 사용하였다.

2. AnoGAN

AnoGAN[15]은 기존 Supervised Anomaly Detection의 문제점이었던 정상과 비정상 데이터의 불균형과 Annotation 작업의 어려움을 개선하기 위해 제안되었으며, AnoGAN의 학습 과정은 다음과 같다. 먼저 정상 이미지를 DCGAN[13]을 통해 학습하여 정상의 가짜 이미지를 만들어 내는 모델을 생성하고, DCGAN 모델의 Generator 함수와 Discriminator 함수의 parameter를 고정한 채 latent space z 를 Random Sampling 하여 최적의 latent space z 를 찾아준다. 이렇게 하면 모델은 정상의 이미지를 생성해내게 되고, 이후 생성된 정상 이미지를 실제 이미지와 비교하여 Residual Loss(생성 이미지와 실제 이미지의 차이)와 Discrimination Loss(생성 이미지의 Discriminator 출력과 실제 이미지의 Discriminator 출력의 차이)의 가중치 합인 Total Loss를 계산하여 Total Loss 최소가 되도록 latent space z 를 조정해준다. 조정이 끝나면 AnoGAN 모델은 학습이 완료되고, 학습 모델을 통해 실제 이미지와의 Total Loss 즉, Anomaly score를 얻을 수 있다.

$$L_R(z_r) = \sum |x - G(z_r)| \qquad L_D(z_r) = \sum |f(x) - f(G(z_r))|$$

$$L(z_r) = (1 - \lambda) \cdot L_R(z_r) + \lambda \cdot L_D(z_r) \qquad A(x) = (1 - \lambda) \cdot R(x) + \lambda \cdot D(x)$$

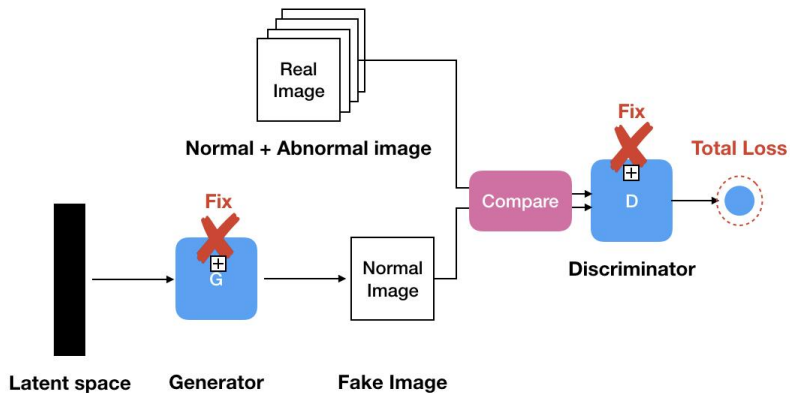


그림 49. AnoGAN Architecture

[출처, blog.promedius.ai/anogan-unsupervised-anomaly-detection-with-gan/]

3. GANomaly

GANomaly[1] 모델은 AnoGAN과 같은 문제를 해결하기 위해 제안된 방법으로 Generator와 latent space를 순차적으로 학습하던 AnoGAN 모델과 달리 GANomaly 모델에서는 Generator와 latent space의 학습이 한 번에 이루어진다. GANomaly 모델의 경우 Encoder-Decoder-Encoder 구조를 생성기의 네트워크로 사용한다는 구조적인 특징이 있으며 이에 따라 세 가지 유형의 Loss function이 정의된다. 첫째, Encoder Loss, L_{enc} 는 입력 이미지의 압축을 통해 생성된 latent space z 와 생성 이미지를 압축하여 생성된 latent space \hat{z} 의 L2 노름으로 계산된다. 둘째, Contextual Loss, L_{con} 는 입력 이미지와 생성 이미지의 L1 노름으로 계산된다. 셋째, Adversarial Loss, L_{adv} 는 입력 이미지의 Discriminator 출력과 생성 이미지의 Discriminator L2 노름으로 계산된다. 이를 정리하면 목적 함수 L 은 아래와 같이 정의되고, 목적 함수가 최소가 되도록 GAN모델을 학습한다. 이후 모델의 평가과정에서 Encoder Loss를 사용하여 각 테스트 이미지에 대한 Anomaly score를 계산과 정규화를 통해 0과 1 사이의 Anomaly score를 얻을 수 있다.

$$L = w_{adv} L_{adv} + w_{con} L_{con} + w_{enc} L_{enc}$$

$$A(\hat{x}) = \|G_E(\hat{x}) - E(G(\hat{x}))\|_1$$




그림 50. GANomaly Architecture[1]

4. Skip-GANomaly

Skip-GANomaly[2] 모델은 기존 GANomaly 모델의 개선된 형태의 모델로, 생성기의 네트워크에 U-Net [14] 구조를 사용한다. U-Net 모델은 Skip-Connection을 통해 병목 구간에서 발생하는 정보의 손실을 줄여 더 선명한 이미지를 얻을 수 있으며 이는 같은 구조를 사용하는 Skip-GANomaly 모델에서도 적용된다. Skip-GANomaly 모델의 Loss function은 Contextual Loss와 Latent Loss, Adversarial Loss의 가중치 합으로 정의되며 각 Loss function은 아래와 같이 계산된다.

$$L_{con} = \|x - \hat{x}\|_1$$

$$L_{lat} = \|f(x) - f(\hat{x})\|_2$$

$$L_{adv} = \log(D(x)) + \log(1 - D(\hat{x}))$$

$$A(x) = \lambda R(x) + (1 - \lambda)L(x)$$

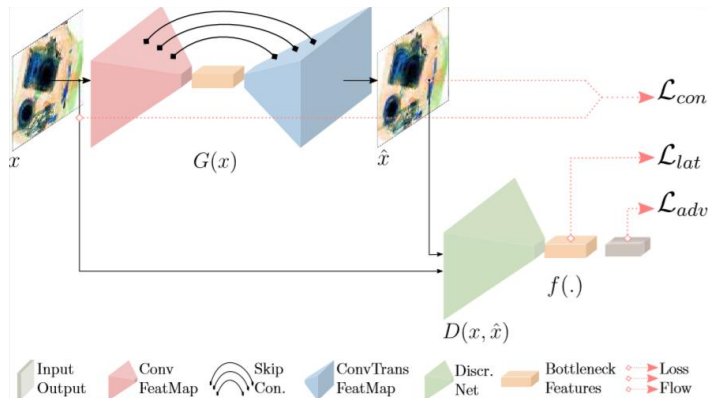


그림 51. Skip-GANomaly Architecture[2]

Skip-GANomaly 모델의 Anomaly score는 입력 이미지와 생성된 이미지 사이의 상황적 유사성을 측정하는 L_{con} 와 입력 이미지와 생성 이미지의 차이를 측정하는 L_{lat} 의 가중치 합으로 계산되고, 이 값을 0과 1 사이의 값으로 정규화시켜주면 최종 Anomaly score를 얻을 수 있다.

5. 구현 및 평가

5절에서는 GAN 기반의 Semi-supervised Anomaly Detection 모델의 성능을 비교 분석하고 광학렌즈의 정상과 비정상 분류에 적합한 모델을 선정한다. 그 후 4장에서 구현한 모델과 비교하여 각 구현 모델의 장단점을 서술한다.

5.1 Dataset

GAN 기반의 모델 구현 실험에서 사용된 데이터 셋은 4장에서 사용된 데이터 셋과 같은 데이터 셋에서 학습 데이터의 비정상 데이터를 제외하고 표 11과 같이 구성하였으며 GAN 기반의 모델들은 300장의 정상 이미지를 가지고 학습을 진행하였다.

GAN based Models Dataset					
	Normal valid	Abnormal valid	Normal test	Abnormal test	Normal train
FA21BW Top	100	42	100	86	300
FA21BW Bottom	114	70	104	93	300
LF1A02W Top	103	77	101	95	300
LF1A02W Bottom	103	100	101	100	300
LF2P01X Top	100	100	100	101	300
LF2P01X Bottom	112	107	104	102	300

표 11. GAN 기반 모델 데이터 셋

5.2 성능 평가 및 분석

GAN 기반 모델의 실험은 4장에서 구현한 모델과 같은 학습환경에서 진행되었으며, 비교를 위해 동일한 평가지표를 사용하였다. GAN 기반 모델은 정상 데이터만을 가지고 학습을 진행하였고, 검증 데이터를 사용하여 학습 과정에서 가장 성능이 우수한 모델을 평가 모델로 사용하였다. 학습 시 사용된 옵션들은 4장에서 구현된 모델과 동일하며 입력 이미지의 크기는 각 모델의 논문에서 사용된 입력 이미지의 크기를 사용하였다(AnoGAN 모델은 64×64 , GANomaly와 Skip-GANomaly 모델은 32×32 를 사용). GAN 기반의 모델의 성능은 히스토그램으로 시각화하였으며 각 그림의 좌측 상단부터 오른쪽으로 FA21BW Top, FA21BW Bottom, LF1A02W Top, LF1A02W Bottom, LF2P01X Top, LF2P01X Bottom 순으로 배치하였다(그림 52-54. 참조).

실험결과 GAN 기반의 모델의 성능은 Skip-GANomaly, GANomaly, AnoGAN 순으로 높았으며 AnoGAN 모델을 제외한 나머지 모델에서 높은 성능을 보였다. AnoGAN 모델의 경우 LF2P01X Top, LF2P01X Bottom 모델을 제외한 나머지 부분에서 AUC 값이 0.7 ~ 0.8의 값을 보이며 적은 수의 비정상 데이터로 학습한 CNN 모델보다 성능이 저조했다. 반면 GANomaly 모델과 Skip-GANomaly 모델은 FA21BW Bottom 이미지 이외의 광학렌즈 이미지에서 1에 가까운 AUC를 보였고, 특히 Skip-GANomaly 모델은 모든 광학렌즈 이미지에서 기대 성능 AUC 0.95의 값 이상의 성능을 보였다(표12. 참조). 하지만 4장에서 학습한 모델과 동일한 성능을 보일 때 앞선 모델에 비해 정상과 비정상 이미지를 극명하게 구분하지 못하였으며 정상 데이터의 분포와 비정상 데이터의 분포가 겹치거나 맞닿아있었다(그림 54. 참조). 즉, GAN 기반의 모델은 분류 경계면 근처에 정상과 비정상 데이터가 분포하여 분류 경계면에 따라 성능이 민감하게 반응한다는 단점이 존재한다.

	AUC					
	FA21BW Top	FA21BW Bottom	LF1A02W Top	LF1A02W Bottom	LF2P01X Top	LF2P01X Bottom
AnoGAN	0.68	0.72	0.75	0.82	0.91	0.99
GANomaly	1.0	0.86	0.98	0.97	0.99	1.0
Skip-GANomaly	1.0	0.95	1.0	1.0	1.0	1.0

표12. GAN 모델 별 AUC 성능

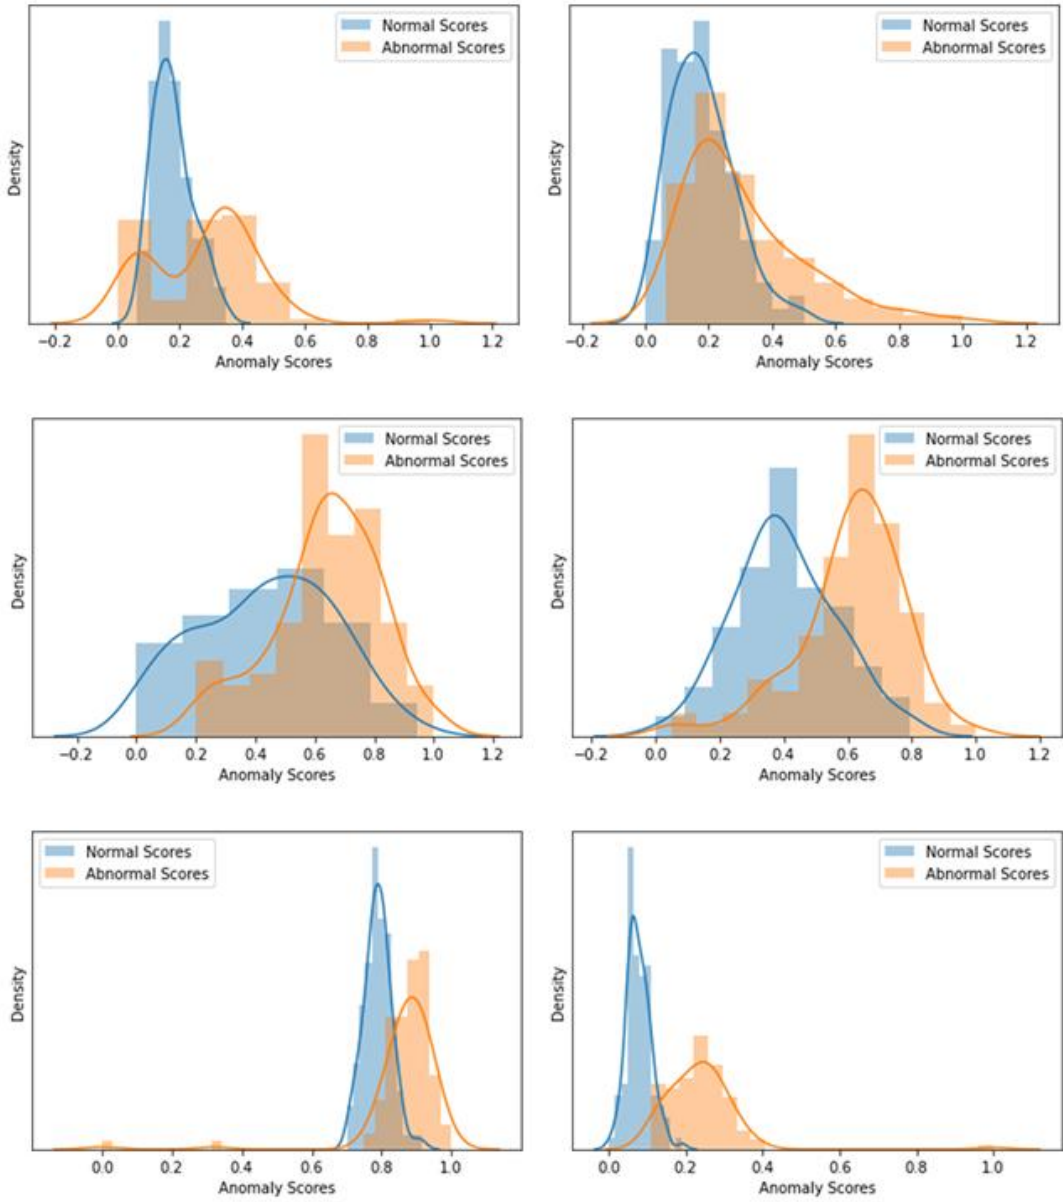


그림 52. 광학렌즈 이미지 별 AnoGAN 히스토그램

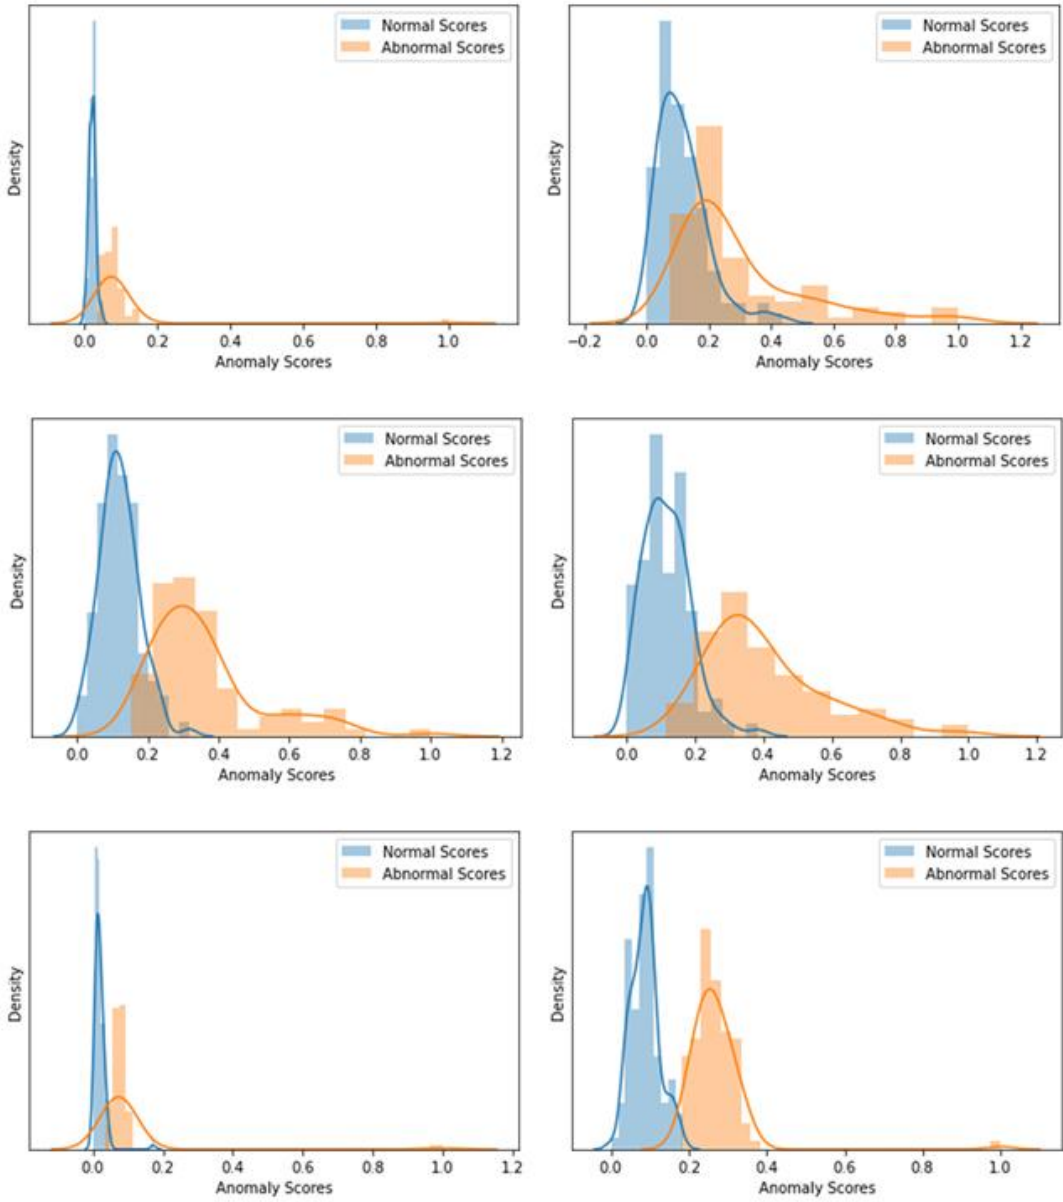


그림 53. 광학렌즈 이미지 별 GANomaly 히스토그램

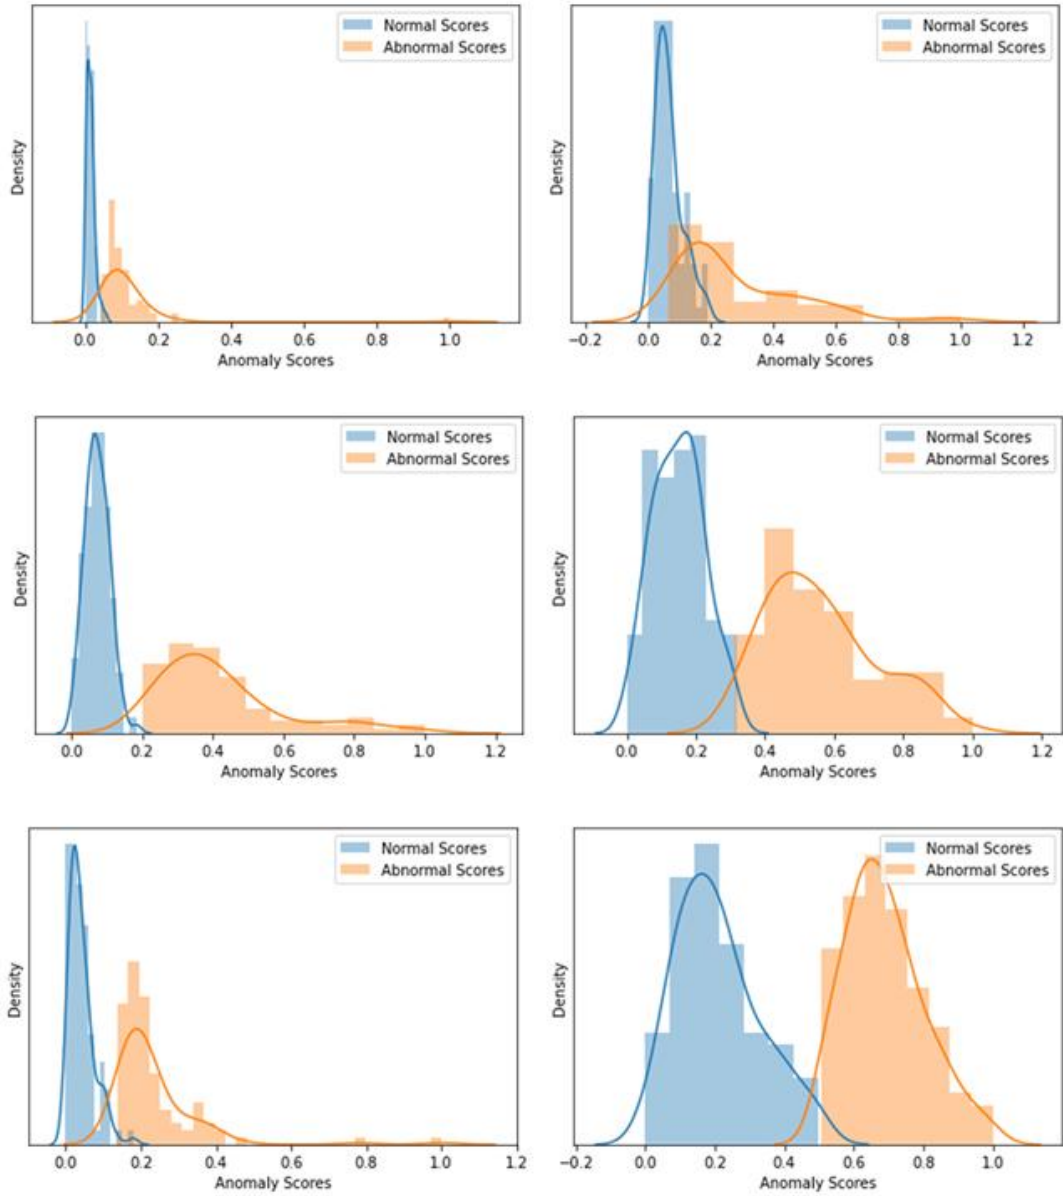


그림 54. 광학렌즈 이미지 별 Skip-GANomaly 히스토그램

제 5 장 Ensemble Model

본 장에서는 앞서 사용된 CNN 기반의 비정상 분류 모델과 GAN 기반의 비정상 탐지 모델의 문제점을 개선하기 위해 보팅(Voting) 유형의 앙상블 모델을 개발하고, 결과 분석을 통해 앙상블 모델의 적용 가능성에 대해 논한다.

1. Ensemble Learning

앙상블 학습(Ensemble Learning)은 여러 종류의 약한 분류기(Weak Classifier)를 적절히 조합하여 더 정확하고 일반화된 강한 분류기(Strong Classifier)를 생성하는 방법으로, 간단한 모델들로 높은 예측 성능을 얻을 수 있어 머신러닝 분야에서 주로 사용된다. 앙상블 학습은 크게 보팅(voting), 배깅(Bagging), 부스팅(Boosting) 방식 나누어지며 각 방식은 최종값을 결정하는 방법과 데이터 셋을 어떻게 구성하느냐에 따라 결정된다. 보팅과 배깅 방식의 경우 최종 예측의 결과를 투표표를 통해 결정하며 두 방식은 여러 분류기를 학습하는 과정에서 데이터 셋 구성 방법에 따라 나뉜다. 보팅 방식에서는 하나의 데이터 셋을 각 분류기가 동일하게 사용하여 모델을 학습하고, 배깅에서는 하나의 데이터 셋에서 Bootstrapping 방법을 통해 데이터를 샘플링하여 각 분류기를 학습한다. 이는 보팅 방식과 배깅 방식에서 사용하는 분류기의 차이로 인해 구분되며 보팅 방식에서는 다른 유형의 분류기를 사용하고 배깅 방식에서는 모두 같은 유형의 분류기를 사용한다는 특징이 있다(그림 55. 참조).

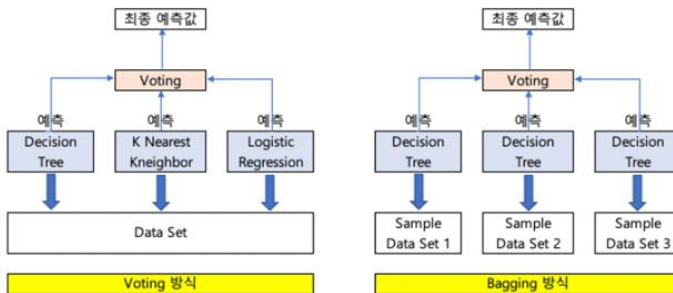


그림 55. 보팅과 배깅 방식의 앙상블 학습

[출처, <https://injo.tistory.com/22>]

이와 다르게 부스팅 방식에서는 앞선 방식과 다른 형태로 최종값을 도출한다. 부스팅 방식은 분류기를 순차적으로 구성한 후 이전 분류기에서 예측이 틀린 데이터에 대해 올바르게 예측할 수 있도록 다음 분류기에 높은 가중치를 부여하면서 학습을 진행한다. 부스팅 방식은 보팅과 배깅 방식에 비해 높은 성능을 얻을 수 있어 많은 모델에서 사용되고 있지만, 학습 속도가 느리고 과적합 발생 위험이 높다는 특징이 있다.




그림 56. 부스팅 방식의 앙상블 학습

[출처, <https://continuous-development.tistory.com/180>]

본 논문에서는 세 방식 중 보팅 방식의 앙상블 학습을 진행하였으며 보팅 방식의 앙상블 학습에서 최종값을 결정하는 방법은 크게 약 분류기의 예측 결과를 다수결로 투표를 하여 최종 결과값을 결정하는 방법인 하드 보팅 (Hard voting)과 최종 결과값을 약 분류기의 예측 결과의 평균 또는 가중치의 합으로 나타내는 소프트 보팅 (Soft voting)으로 나눌 수 있다(그림 57. 참조). 연구에서 개발한 광학렌즈 결함판정 모델은 가중치 기반의 소프트 보팅 방식을 사용하였다.

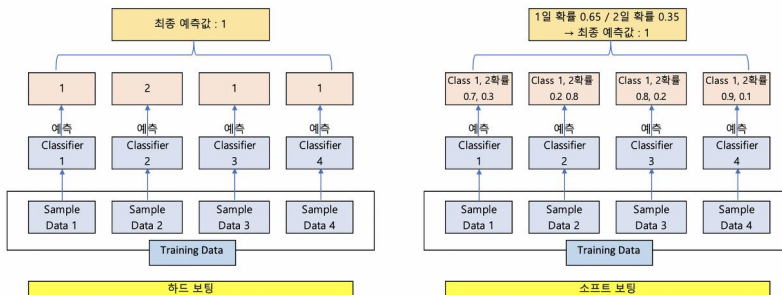


그림 57. 하드 보팅과 소프트 보팅

[출처, <https://injo.tistory.com/22>]

2. 비정상 검출기

앞서 3장과 4장에서 구현한 모델에서는 각각의 문제점이 존재했다. 먼저 CNN 기반의 모델의 경우 비정상 데이터가 충분하지 않은 상황에서 낮은 성능과 불안정하게 증가하는 성능이 문제가 되었으며, GAN 기반의 모델에서는 정상과 비정상의 분류 경계면 근처 데이터가 분포하여 분류 경계면에 따라 성능이 민감하게 반응하는 문제가 발생하였다. 이를 해결하기 위해서 본 절에서는 정확하고 극명한 비정상 분류를 위한 비정상 검출기를 제안한다.

제안된 비정상 검출기는 아래와 같은 식으로 표현되며 통합 Abnomaly Score A_T 는 Sobel 필터를 적용한 ResNet 분류 모델의 비정상 확률 A_C 와 Skip-GANomaly 모델의 Abnomaly Score A_G , 정상 데이터 대비 비정상 데이터의 비율 P_{Ab} , 안정적인 모델 학습을 위한 데이터 확보율 P_D 로 구성된다. 해당 식은 네 가지의 경우로 나뉘질 수 있다. 첫 번째 경우는 전체 데이터의 수가 안정적인 학습을 위한 데이터 (정상과 비정상 각 500개)에 미치지 못하는 경우로 A_T 의 가중치로 P_D (전체 데이터)/(안정적인 학습을 위한 데이터)의 값을 사용한다. 두 번째 경우는 데이터가 충분하지만 불균형한 경우로 A_T 의 가중치로 P_{Ab} 만을 사용한다. 세 번째 경우는 첫 번째와 두 번째가 동시에 발생한 경우로 A_T 의 가중치로 P_D 와 P_{Ab} 의 곱을 사용한다. 네 번째 경우는 데이터가 충분하면서 균형을 이루는 경우로 이 경우는 P_D 와 P_{Ab} 의 값이 1로 되어 CNN 모델의 비정상 확률 A_C 을 사용하여 비정상 데이터를 검출한다.

$$W = P_{Ab}P_D$$

$$A_T = (1 - W)A_G + WA_C$$

3. 적용 및 평가

양상블 모델의 실험은 앞서 개발된 두 모델의 결과를 비정상 검출기에 적용을 통해 진행하였다. 실험 시 사용된 데이터는 Sobel 필터를 적용한 ResNet 분류 모델과 동일하게 정상과 비정상 데이터를 각각 300장씩 사용하였으며, 안정적인 모델 학습을 위한 데이터 확보율 P_D 는 0.6(600/1000)으로 설정하였다.

양상블 모델의 실험 결과 전체 광학렌즈 이미지에서의 성능이 앞선 두 모델에 비해 비약적으로 상승하였으며, 결함판정 모델의 기대성능인 AUC 0.95의 값을 상회하는 것으로 나타났다(표 13-18. 참조). 특히 데이터가 불균형한 조건에서도 균형적인 데이터로 학습한 모델과 비슷한 성능을 보여주었으며, 이를 통해 양상블 모델의 적용 가능성을 시사했다. 그뿐만 아니라 정상 데이터 분포와 비정상 데이터 분포 사이의 거리가 증가하여 조금 더 명확하게 구분이 가능해졌으며 분류 경계면에 민감하게 반응하던 Skip-GANomaly 모델의 문제점 또한 개선되었다.

그림 58-63은 비정상 검출기를 적용하였을 때의 정상과 비정상 데이터의 분포로, 이상적으로 정상(파란색 분포)과 비정상(주황색 분포)을 분류하였을 경우 두 분포는 그림 35의 우측 하단의 이미지와 같은 형태로 분포되고, 두 분포의 사이가 멀어질수록 정상과 비정상의 차이가 극명하게 존재한다는 것을 의미한다. 앞서 Skip-GANomaly 모델의 결과로 도출된 히스토그램(그림54. 참조)과 비교하면 비정상 검출기 기반의 정상과 비정상 분포의 거리가 더 멀어진 것을 확인할 수 있다.

LF1A02W	AUC									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
Top	0.89	0.92	0.98	0.87	0.95	1.0	1.0	1.0	1.0	1.0
CNN	0.89	0.92	0.98	0.87	0.95	1.0	1.0	1.0	1.0	1.0
GAN	0.999									
Ensemble	1.0	1.0	1.0	1.0	0.98	1.0	1.0	1.0	1.0	1.0

표 13. 모델 별 AUC 성능 FA21BW Top

LF1A02W Top	AUC									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
CNN	0.39	0.96	0.75	0.77	0.84	0.95	0.86	0.91	0.99	0.99
GAN	0.948									
Ensemble	0.95	0.98	0.95	0.95	0.96	0.97	0.93	0.94	1.0	0.99

표 14. 모델 별 AUC 성능 FA21BW Bottom

LF1A02W Top	AUC									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
CNN	0.75	0.95	0.99	0.99	0.97	0.97	1.0	1.0	1.0	1.0
GAN	1.0									
Ensemble	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

표 15. 모델 별 AUC 성능 LF1A02W Top

LF1A02W Top	AUC									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
CNN	0.83	0.95	0.91	1.0	0.97	1.0	1.0	1.0	0.99	0.99
GAN	1.0									
Ensemble	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

표 16. 모델 별 AUC 성능 LF1A02W Bottom

LF1A02W Top	AUC									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
CNN	0.77	0.93	1.0	1.0	0.85	1.0	1.0	1.0	1.0	1.0
GAN	0.997									
Ensemble	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

표 17. 모델 별 AUC 성능 LF2P01X Top

LF1A02W Top	AUC									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0
CNN	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
GAN	1.0									
Ensemble	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0

표 18. 모델 별 AUC 성능 LF2P01X Bottom

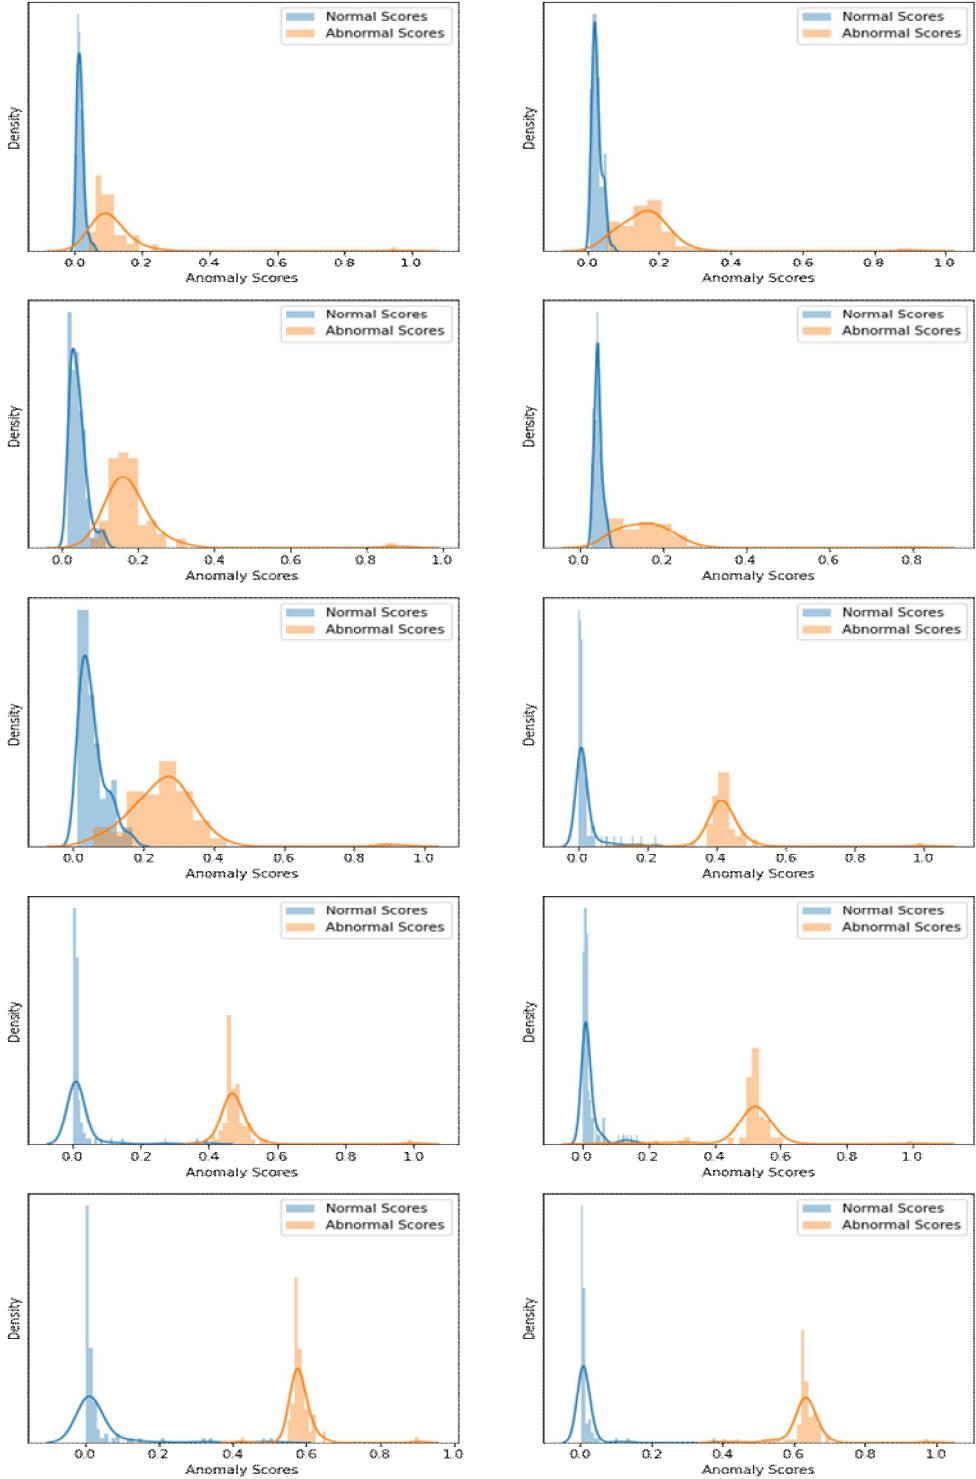


그림 58. 비정상 비율별 히스토그램 FA21BW Top

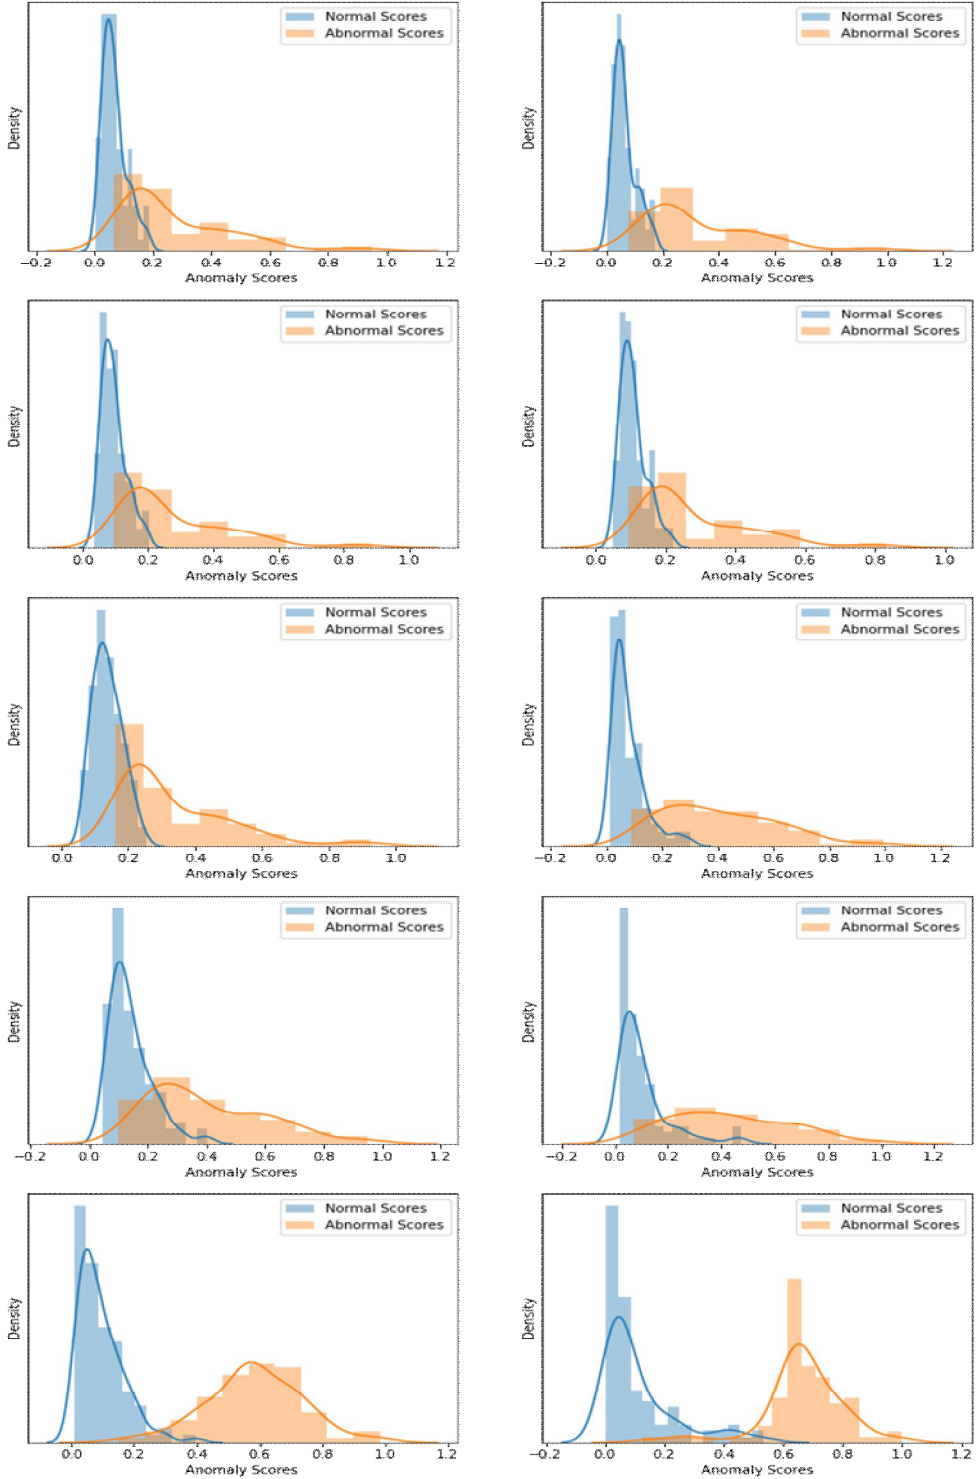


그림 59. 비정상 비율별 히스토그램 FA21BW Bottom

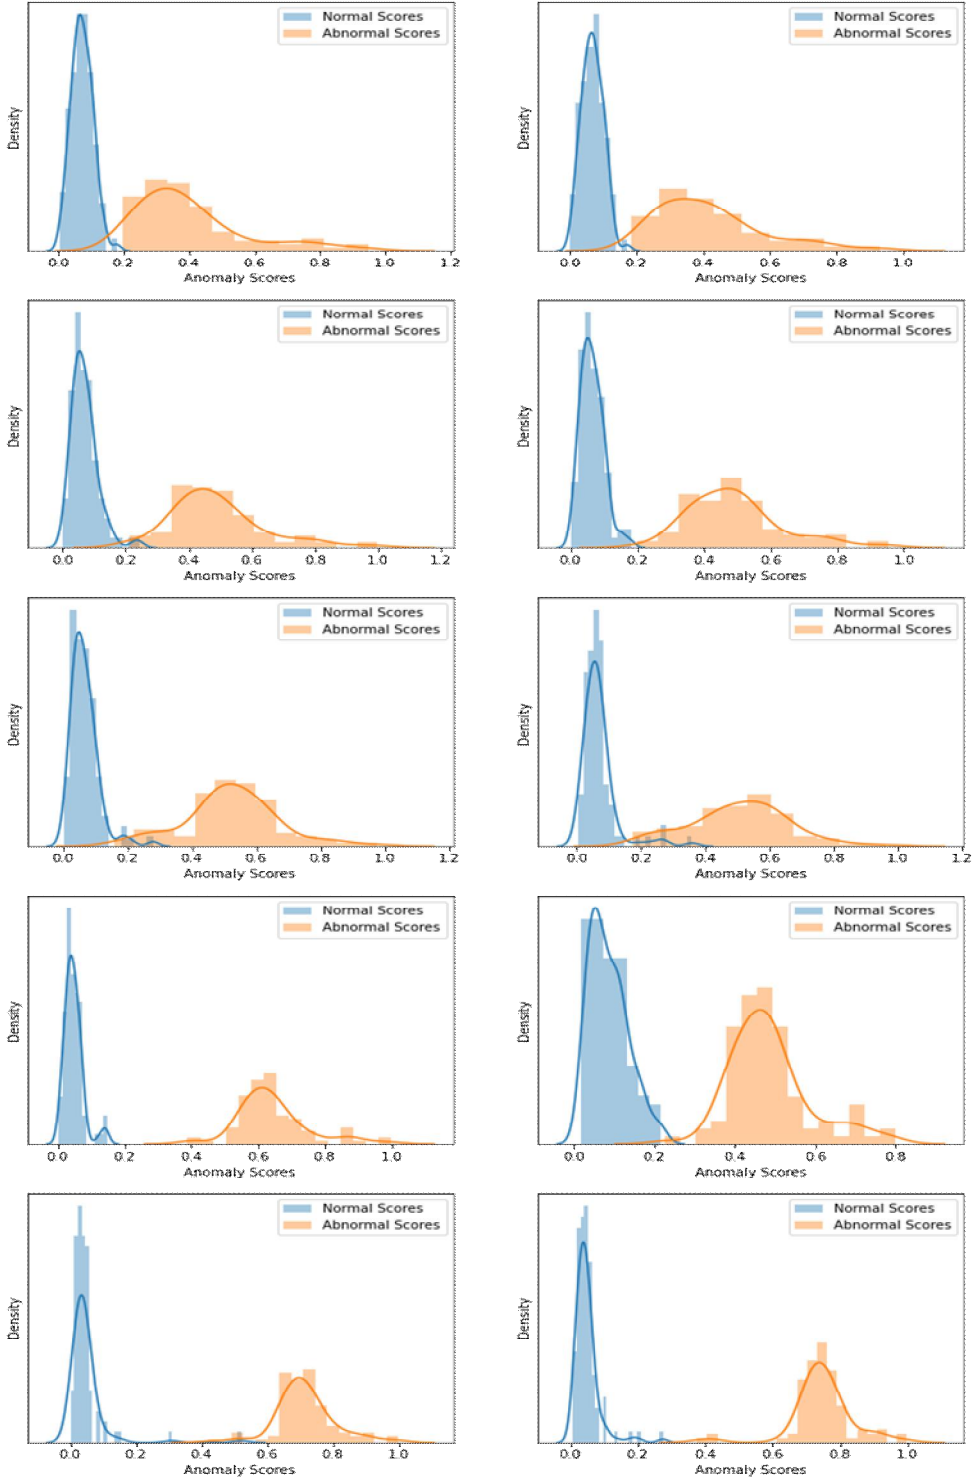


그림 60. 비정상 비율별 히스토그램 LF1A02W Top

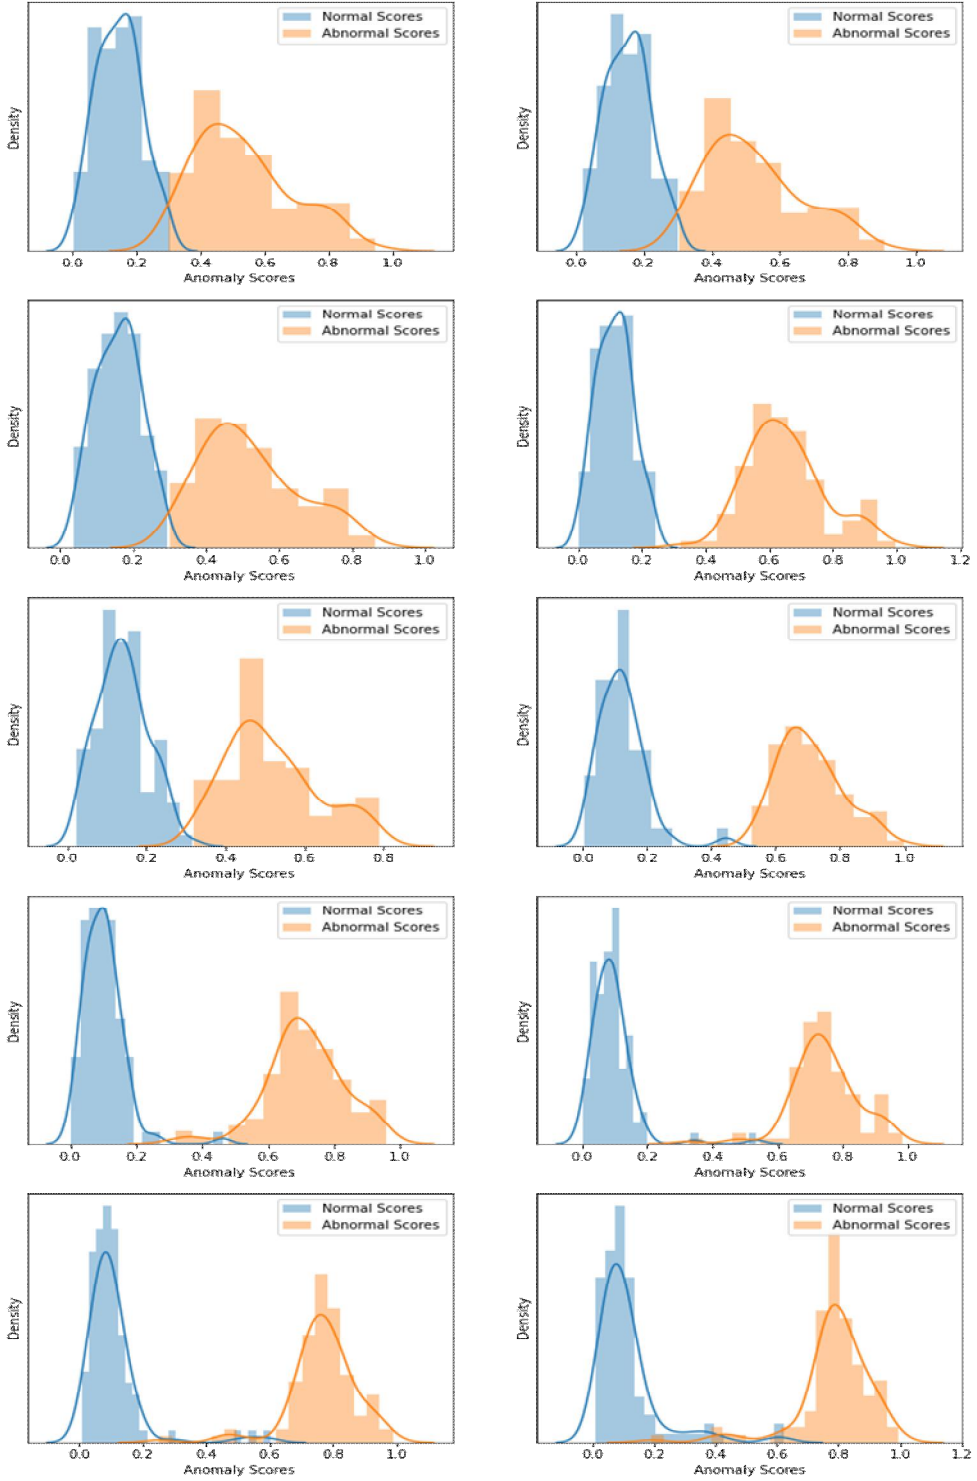


그림 61. 비정상 비율별 히스토그램 LF1A02W Bottom

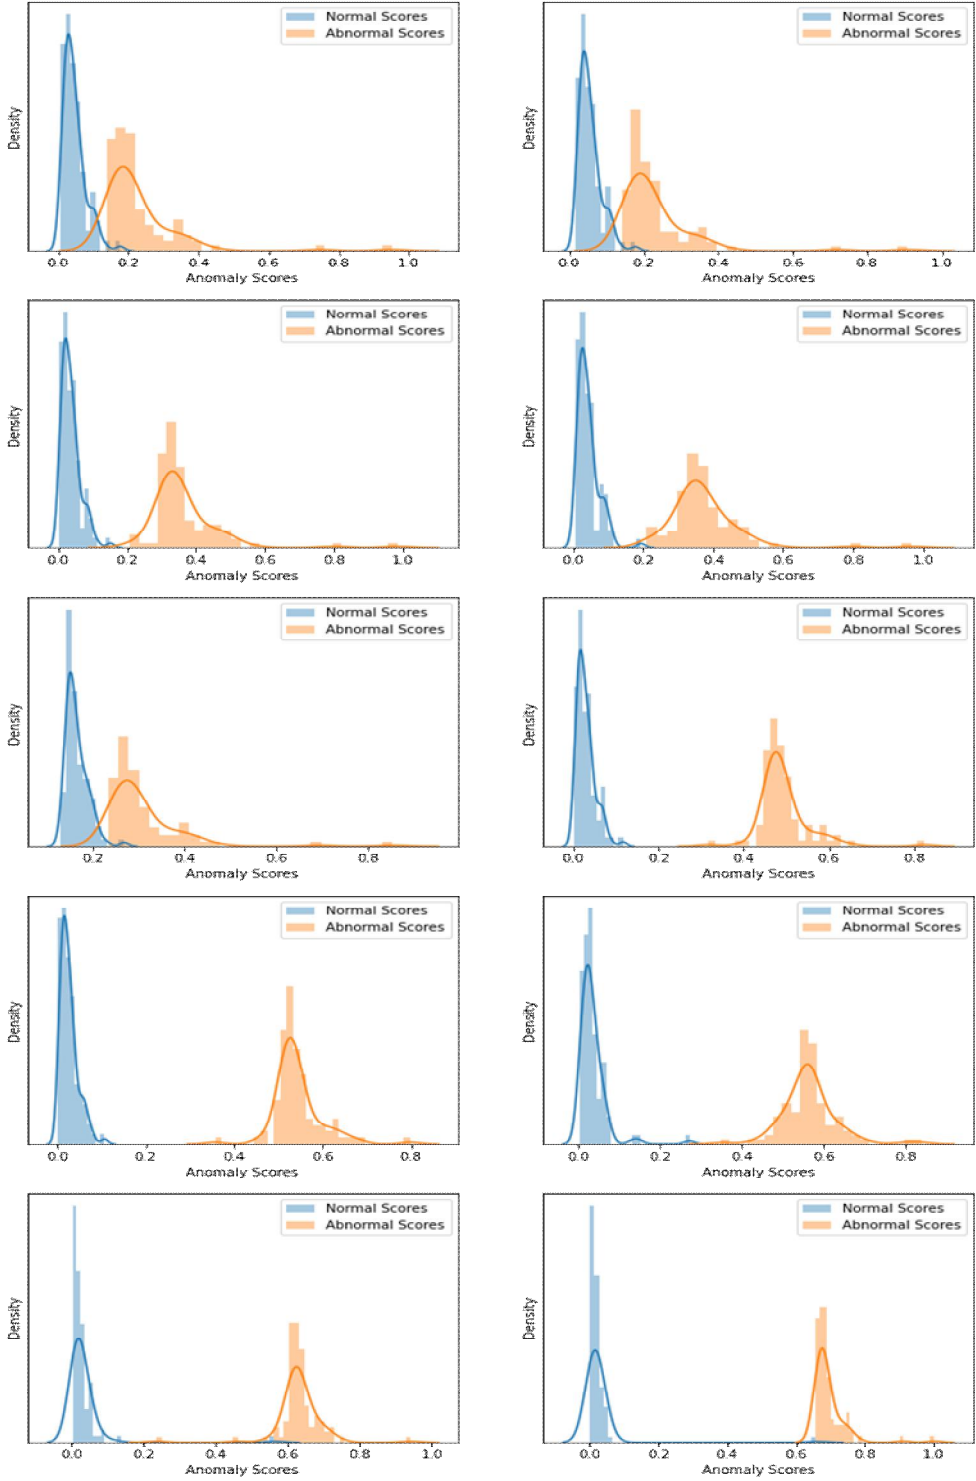


그림 62. 비정상 비율별 히스토그램 LF2P01X Top

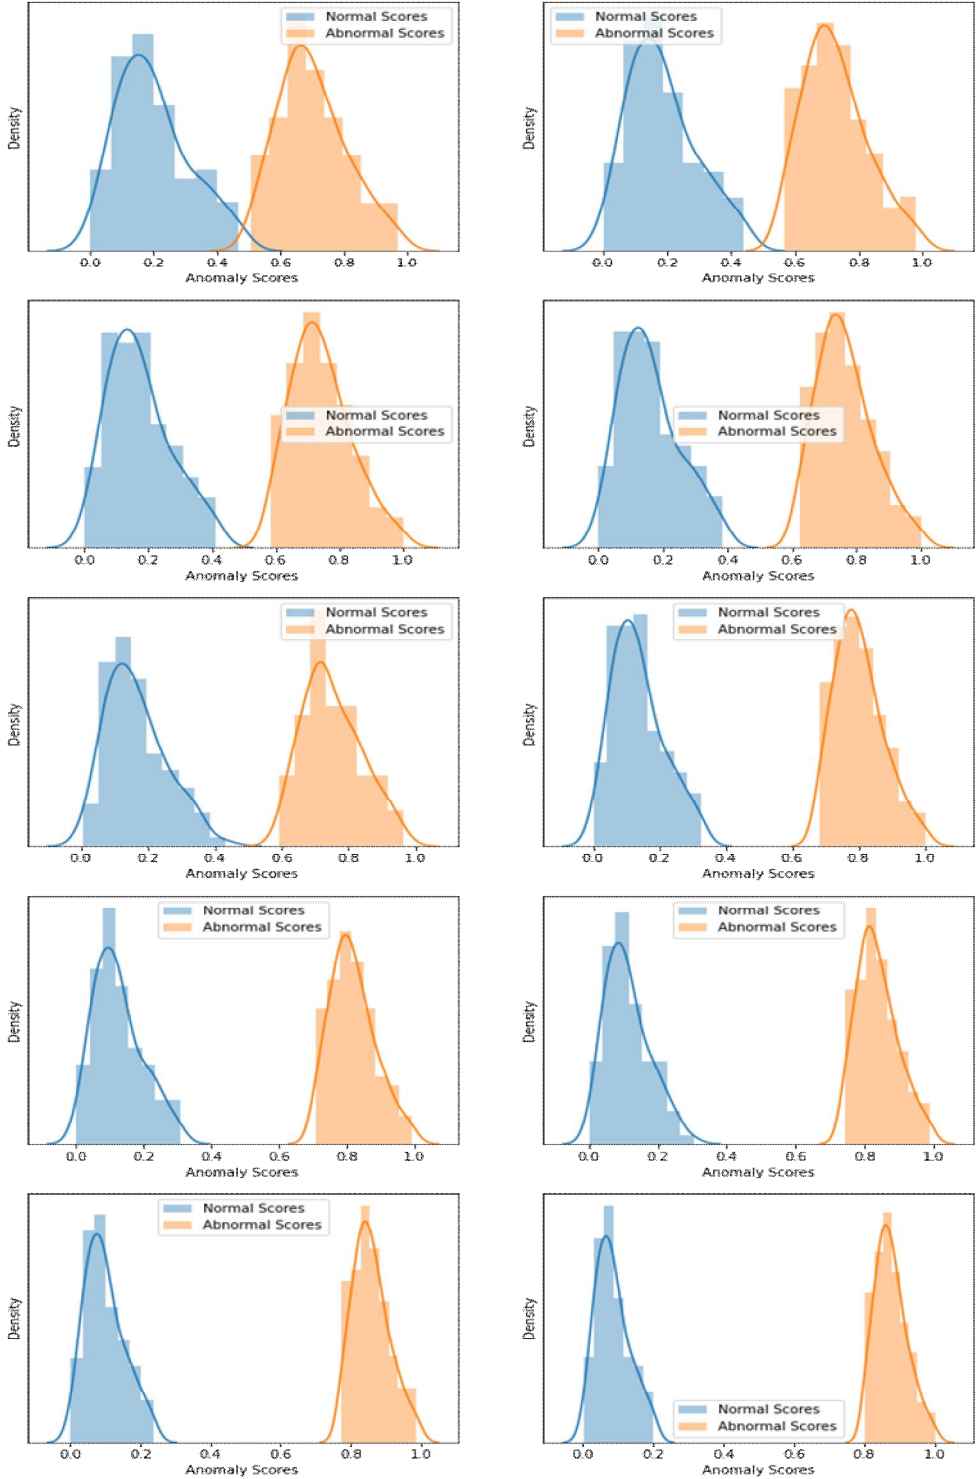


그림 63. 비정상 비율별 히스토그램 LF2P01X Bottom

제 6 장 결론 및 토의

본 논문에서는 광학렌즈의 상부와 하부에 발생 되는 표면 결함 유무의 판정과 딥러닝 모델 개발 과정에서 발생할 수 있는 문제를 해결하기 위한 방법론을 제안하였다. 논문에서 제안된 비정상 검출기 기반의 앙상블 모델은 데이터 증가에 따라 Semi-supervised Learning에서 Supervised Learning으로 변화되는 구조로 되어 있어 개발 초기 단계부터 지속적인 사용이 가능하다는 장점이 있으며, 산업현장에서 주로 발생 되는 데이터 불균형 문제를 해결할 수 있다는 점에서 높은 의미가 있다. 광학렌즈의 결함판정을 위한 모델은 CNN 기반의 모델인 ResNet 모델과 GAN 기반의 모델인 SKip-GANomaly 모델을 사용하였으며, 각각 Sobel 필터를 적용한 이미지 데이터 셋과 기본 이미지 데이터 셋을 사용하여 학습을 진행하였다. 두 모델의 성능 분석결과 각 모델에서 데이터 불균형에 따른 성능 저하 현상과 분류 경계에 따라 성능이 민감하게 반응하는 문제를 확인하였고, 단일 모델로의 사용은 적합하지 않은 것으로 판단되었다. 그러나 두 모델에서 발생하는 문제는 모델의 조합을 통해 상호보완이 가능하였으며, 이에 비정상 검출기 기반의 앙상블 모델을 도입하였다. 비정상 검출기 기반의 앙상블 모델에서는 두 문제 중 더 큰 문제인 데이터 불균형 문제해결에 초점을 두어 데이터의 수가 적거나 불균형한 상황에서는 불균형 문제에 강점이 있는 Semi-Supervised Learning 모델인 SKip-GANomaly 모델에 더 큰 가중치를 부여하도록 하였고, 데이터가 충분한 상황에서는 안정적인 학습이 가능한 Supervised Learning 모델인 CNN 모델을 사용하도록 설계하였다. 그 결과 데이터가 불균형한 상황에서도 목표 성능 이상의 성능을 보여주었으며, 분류 경계에 따른 성능의 민감도 또한 감소시킬 수 있었다.

본 논문에서 개발된 광학렌즈 결함판정 방법론의 적용을 통해 제조 현장에서 인공지능 기술 도입의 걸림돌이었던 데이터 불균형 문제를 해결하고, 학습 데이터 수집에 소모되는 시간과 비용을 절감할 수 있을 것으로 기대된다. 그러나 현재 개발된 방법론으로는 고장 모드 분류나 고장 영역 추출과 같은 심도 있는 문제의 해결에는 어려움이 있었다. 이와 같은 문제를 해결하기 위해 향후 연구에서는 Image Segmentation 맵 기반의 결함판정 모델을 구현하여 비정상 영역의 추출과 고장 모드의 분류가 가능한 모델을 설계하고자 한다.

참고문헌

- [1] Akçay, Samet, Amir Atapour-Abarghouei, and Toby P. Breckon. "Ganomaly: Semi-supervised anomaly detection via adversarial training." Asian conference on computer vision. Springer, Cham, 2018.
- [2] Akçay, Samet, Amir Atapour-Abarghouei, and Toby P. Breckon. "Skip-ganomaly: Skip connected and adversarially trained encoder-decoder anomaly detection." 2019 International Joint Conference on Neural Networks (IJCNN). IEEE, 2019.
- [3] Canny, John Francis. Finding Edges and Lines in Images. MASSACHUSETTS INST OF TECH CAMBRIDGE ARTIFICIAL INTELLIGENCE LAB, 1983.
- [4] Goodfellow, Ian, et al. "Generative adversarial networks." Communications of the ACM 63.11 (2020): 139-144.
- [5] He, Kaiming, et al. "Deep residual learning for image recognition." arXiv preprint arXiv:1512.03385 (2015).
- [6] Huang, Gao, et al. "Densely connected convolutional networks." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.
- [7] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." Advances in neural information processing systems. 2012.
- [8] LeCun, Yann, et al. "Backpropagation applied to handwritten zip code

recognition." *Neural computation* 1.4 (1989): 541-551.

[9] LeCun, Yann, et al. "Gradient-based learning applied to document recognition." *Proceedings of the IEEE* 86.11 (1998): 2278-2324.

[6] Mao, Xinyun, et al. "Introduction to Opencv3 programming." Publishing House of Electronics Industry: Beijing, China (2015).

[11] Makhzani, Alireza, et al. "Adversarial autoencoders." *arXiv preprint arXiv:1511.05644* (2015).

[12] Nair, Vinod, and Geoffrey E. Hinton. "Rectified linear units improve restricted boltzmann machines." *ICML*. 2010.

[13] Radford, Alec, Luke Metz, and Soumith Chintala. "Unsupervised representation learning with deep convolutional generative adversarial networks." *arXiv preprint arXiv:1511.06434* (2015).

[14] Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015.

[15] Schlegl, Thomas, et al. "Unsupervised anomaly detection with generative adversarial networks to guide marker discovery." *International conference on information processing in medical imaging*. Springer, Cham, 2017.

[16] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for largescale image recognition." *arXiv preprint arXiv:1409.1556*(2014).

[17] Sobel, I. "An Isotropic 3×3 Image Gradient Operator, Presentation at

Stanford AI Project (1968)." (2014).

[18] Srivastava, Nitish, et al. "Dropout: a simple way to prevent neural networks from overfitting." The journal of machine learning research 15.1 (2014): 1929-1958.

[19] Szegedy, Christian, et al. "Goingdeeper with convolutions." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015.

[20] Zeiler, Matthew D., and Rob Fergus. "Visualizing and understanding convolutional networks." European Conference on Computer Vision. Springer International Publishing, 2014.

[21] 강승희, MONTHLY SOFTWARE ORIENTED SOCIETY No.83 MAY 2021

[22] 신동윤, “2022년, 고도화 기대되는 스마트팩토리”, 테크월드뉴스, 2022년 05월 27일. <https://www.epnc.co.kr/news/articleView.html?idxno=221587>

[23] 이수민, “‘제조혁신 동력 스마트 팩토리’ 양적 확대 아닌 질적 전환 시작됐다”, e4dsnews, 2020년 11월 23일. https://www.e4ds.com/sub_view.asp?ch=1&t=0&idx=12323

[24] 중소벤처기업부(2020). 스마트제조 2.0 본격 시동, 인공지능(AI) 활용한 제조 플랫폼 구축. 중소벤처기업부 보도자료 (2020. 07. 31.).