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

조선대학교
CHOSUN UNIVERSITY

[UCI]I804:24011-200000336764

2020년 8월

석사학위 논문

이미지 기반 제품 표면 결함 탐지용 AI 모델 개발

조선대학교 대학원

산업공학과

김 민 재

조선대학교
CHOSUN UNIVERSITY

이미지 기반 제품 표면 결함 탐지용 AI 모델 개발

AI Model development
for surface defect detection from image

2020년 08월 28일

조선대학교 대학원

산업공학과

김 민 재

조선대학교
CHOSUN UNIVERSITY

이미지 기반 제품 표면 결함 탐지용 AI 모델 개발

지도교수 신 종 호

이 논문을 공학 석사학위신청 논문으로 제출함

2020년 05월

조선대학교 대학원

산업공학과

김 민 재

조선대학교
CHOSUN UNIVERSITY

김민재의 석사학위논문을 인준함

위원장 조선대학교 교 수 백 정 우 (인)

위 원 조선대학교 교 수 신 종 호 (인)

위 원 조선대학교 교 수 김 성 준 (인)

2020년 06월

조선대학교 대학원

조선대학교
CHOSUN UNIVERSITY

목차

목차 i
그림 목차 iii
표 목차 vi
ABSTRACT viii
제 1 장 서론 1
1.1 연구 배경 1
1.2 연구 목적 4
1.3 연구 구성 6
제 2 장 기존연구 고찰 7
2.1 필터 기반 결함 검출 7
2.2 CNN 기반의 결함 검출 12
2.2.1 Convolution Neural Network 12
2.2.2 다양한 구조의 Convolution Neural Network 15
2.3 Transfer Leaning 20
2.4 제조산업에서의 딥러닝 적용의 한계 20
제 3 장 전이학습을 위한 최적의 학습 데이터 양 결정 ... 22
3.1 학습을 위한 데이터 전처리 22
3.1.1 통계적 분석방법을 이용한 이미지의 질감 특성 분석 22
3.1.2 데이터 설명 및 전처리 학습 데이터 생성 27
3.2 이미지 데이터를 이용한 전이학습 36

조선대학교
CHOSUN UNIVERSITY

3.2.1 최적의 모델 학습을 위한 실험 계획 36
3.2.2 성능 평가 및 결과 시각화 방안 37
제 4 장 구현 및 평가 40
4.1 딥러닝 기반 결함 검출 시스템 구현 40
4.1.1 실험 환경 및 시스템 구성 40
4.1.2 결함 검출 CNN 모델 성능 비교 결과 42
4.1.3 방법론 유효성 검증 57
제 5 장 결론 및 토의 66
참고문헌 68

조선대학교
CHOSUN UNIVERSITY

그림 목차

그림 1. 글로벌 스마트 팩토리 시장의 규모 변화 ····· 2

그림 2. 딥러닝 기반 결함탐지 모델 개발 방법론 개요도 ····· 4

그림 3. 규칙정보 기반 결함탐지 예시 ····· 7

그림 4. 하나의 keypoint 특징을 나타내는 128개의 숫자[9] ····· 9

그림 5. HOG(좌), Haar(우) Feature[10,12] ····· 9

그림 6. Gabor Filter 파라미터 조절 결과 ····· 10

그림 7. 노이즈가 포함된 불규칙적인 이미지 ····· 11

그림 8. Multi Layer Perceptron ····· 12

그림 9. Convolutional Neural Networks[31] ····· 13

그림 10. Convolutional Layer에서의 합성곱 연산 ····· 14

그림 11. ImageNet Challenge Top-5 Error ····· 15

그림 12. Vggnet의 네트워크 구조[32] ····· 16

그림 13. Googlenet의 네트워크 구조[6] ····· 17

그림 14. Inception Module 구조[6] ····· 17

그림 15. Resnet의 네트워크 구조[2] ····· 18

그림 16. Residual Block 구조[2] ····· 19

그림 17. Bottleneck 구조[2] ····· 19

조선대학교
CHOSUN UNIVERSITY

그림 18. Transfer Leaning 방법 및 구조 ····· 20

그림 19. GLCM 계산 방법 예시 ····· 23

그림 20. GLCM 평가를 위한 몸체, 나사선, 시트면 이미지 데이터 ····· 23

그림 21. 자동차 글로우 플러그 ····· 28

그림 22. 비전기반 이미지 데이터 수집 장비 및 수집 데이터 ····· 28

그림 23. 몸체 데이터의 결함 특징 ····· 30

그림 24. 나사선 데이터의 결함 특징 ····· 30

그림 25. 시트면 데이터의 결함 특징 ····· 31

그림 26. 히스토그램 평활화 적용 결과 ····· 32

그림 27. Gaussian Blur Filter ····· 33

그림 28. Sobel Filter ····· 33

그림 29. 최종 전처리 몸체 데이터 ····· 34

그림 30. 최종 전처리 나사선 데이터 ····· 35

그림 31. 최종 전처리 시트면 데이터 ····· 35

그림 32. CNN 모델을 이용한 결함 판별 모델 개념도 예시 ····· 37

그림 33. 표면 결함 검사 시스템 구성도 ····· 41

그림 34. 이미지 데이터 100개로 각 모델 학습 그래프 ····· 44

그림 35. 이미지 데이터 200개로 각 모델 학습 그래프 ····· 45

그림 36. 이미지 데이터 500개로 각 모델 학습 그래프 ····· 46

조선대학교
CHOSUN UNIVERSITY

그림 37. 이미지 데이터 1000개로 각 모델 학습 그래프 47

그림 38. Grad CAM 적용 결과 56

그림 39. 마그네틱 데이터 결함 특징 59

그림 40. 최종 전처리 마그네틱 데이터 59

그림 41. 80/160/400/700개 마그네틱 데이터 학습 그래프 61

그림 42. Class 2 결함 데이터 특징 62

그림 43. 최종 전처리 Class 2 데이터 62

그림 44. 보일러 수벽 튜브 결함 데이터 특징 63

그림 45. 최종 전처리 보일러 수벽 데이터 64

조선대학교
CHOSUN UNIVERSITY

표 목차

표 1. 몸체 데이터 GLCM 계산값 ····· 24

표 2. 나사선 데이터 GLCM 계산값 ····· 24

표 3. 시트면 데이터 GLCM 계산값 ····· 25

표 4. 통계적 기법 기반 데이터 복잡도 평가 결과 ····· 27

표 5. 전체 수집 데이터 ····· 29

표 6. 전이학습을 위한 데이터 분할 ····· 37

표 7. 분류 결과 Confusion Matrix ····· 38

표 8. PC 실험 환경 ····· 40

표 9. 결함 판별 모델 정확도 변화 (R: Resnet, G: Googlenet, V: Vggnet) ····· 42

표 10. 검증용 나사선 데이터 판별 결과 ····· 48

표 11. 검증용 몸체 데이터 판별 결과 ····· 50

표 12. 검증용 시트면 데이터 판별 결과 ····· 52

표 13. 검증 데이터에 대한 결함 판별 결과 정리 (AC: Accuracy, SE: Sensitivity, SP: Specificity, F1: F1-Score) ····· 54

표 14. 통계적 기법 기반 검증 데이터 복잡도 평가 결과 ····· 57

표 15. L1 norm, L2 norm에 의해 결정된 학습데이터 양 ····· 58

표 16. 마그네틱 데이터 학습 모델 정확도 변화 (R: Resnet, G: Googlenet, V: Vggnet) ····· 61

조선대학교
CHOSUN UNIVERSITY

표 17. 질감 표면 Class2 데이터 모델 정확도 변화 (R: Resnet, G: Googlenet, V: Vggnet) ····· 63

표 18. 보일러 수벽 데이터 모델 정확도 변화 (R: Resnet, G: Googlenet, V: Vggnet) ····· 64

조선대학교
CHOSUN UNIVERSITY

ABSTRACT

AI model development for surface defect detection from image

Min-Jae Kim
Advisor: Prof. Jongho Shin, Ph.D.
Department of Industrial Engineering
Graduate School of Chosun University

Artificial intelligence technology due to the 4th industrial revolution is widely used in all fields of industries such as process optimization, quality control, maintenance, and service by utilizing various types of big data collected in the industry. Numerous Open Sources (Tensorflow, Keras, etc.) have been developed, and deep learning by the general public is becoming common. In addition, studies on machine learning and deep learning are being actively conducted at home and abroad. Among them, CNN [1] (Convolutional Neural Network, CNN), one of artificial intelligence technologies, is mainly used to recognize objects in an image. In the case of CNN, in the field of artificial intelligence technology, in the case of image recognition, CNN is already showing performance beyond human discrimination[2]. Sufficient amount of training data is needed to develop

조선대학교
CHOSUN UNIVERSITY

such artificial intelligence technology[3]. Even if there is a large amount of data, there is no clear standard and calculation method to determine the amount of data needed to train the CNN to develop a model with satisfactory performance.

In order to solve these problems, this study provides a method for sequential experimental design and the development of artificial intelligence models to collect the data necessary for the development of artificial intelligence models with minimal effort. The data used in this study can generate noise from the surrounding environment (lighting, machine accuracy, etc.) when collecting the data on the image data of the surface of the product collected on the automobile glow production line. The feature of the defect was inconspicuous and difficult to discriminate, and the feature of the defect was reinforced through the pre-processing of the image. In the case of missing data, the peripheral part was additionally created by Random Crop centering on the defects in the entire image data, and the data set was constructed using the conventional data augmentation method. In addition, by analyzing the morphological complexity of the data collected in the three forms by statistical methods, calculating the similarity of the data, and developing a model that satisfies the required performance according to the complexity of the data. Transferred learning Vggnet, Googlenet, Resnet, which perform well in the image deep learning model, based on sequential experiment design to determine the amount of proper data required. The verification of the model performance was confirmed by comparing/analyzing the result determined by the learned model and the result

조선대학교
CHOSUN UNIVERSITY

determined by the operator. Finally, for verification of the development methodology, we conducted experiments based on the method of presenting three different types of surface defect data, and obtained the target performance with the same amount of data as required for transfer learning of the CNN model. We were able to develop a model that satisfied.

조선대학교
CHOSUN UNIVERSITY

제 1 장 서론

1.1 연구 배경

제조산업은 경제 발전을 견인해 온 성장의 동력으로 국가 경제에 미치는 영향이 매우 크다. 최근 국내 제조산업은 4차 산업혁명에 대한 대응책으로서 CNN(Convolutional Neural Network)과 같은 딥러닝을 기반으로 하는 제품 결함검사 시스템의 도입과 같은 스마트 팩토리 구축을 통해 경쟁력 강화를 꾀하고 있다. 세계적으로도 스마트 팩토리의 제조 지능화를 위해 다양한 기술을 적용하여 제조공정을 향상시키고 제품의 품질을 높이는 등 제조업 혁신 전략이 국가적 과제로 추진되고 있다. 스마트 팩토리는 기존 공장들의 자동화 수준을 넘어 차세대 신기술인 AI와 IoT를 제조기술과 융합하여 공장운영을 지능화하고, 이를 통해 제조업 생산성을 획기적으로 향상시킬 수 있는 수단으로 주목 받고 있다. 그 중 제조 지능화에 큰 역할을 담당하고 있는 컴퓨터 비전은 사물인식, 문자인식 등 다양한 형태로 적용되며, 최근 딥러닝(Deep Learning)을 통해 더욱 강력해지고 있다. 특히, 컴퓨터 비전을 활용해 제품의 불량을 검출하는 '결함탐지(Defect Detection)'는 제조산업에서 큰 역할을 수행이 기대되고 있다.

국내의 경우 GDP 대비 제조업 비중이 30%를 초과하는 만큼 스마트 팩토리 구축은 국내 제조산업의 고도화에 큰 영향을 줄 수 있다. Markets & Markets에 따르면 스마트 팩토리의 글로벌 시장 규모는 2022년까지 매년 9.3%씩 성장하여 2054.2억달러 시장이 형성되고, 국내 시장의 경우 2020년 78.3억 달러에서 2022년 127.6억 달러까지 예상된다. 결과적으로 스마트 팩토리의 세계 시장은 활황을 맞이하고 있으나 국내의 스마트 팩토리는 시범 도입하는 수준이다[7].

조선대학교
CHOSUN UNIVERSITY

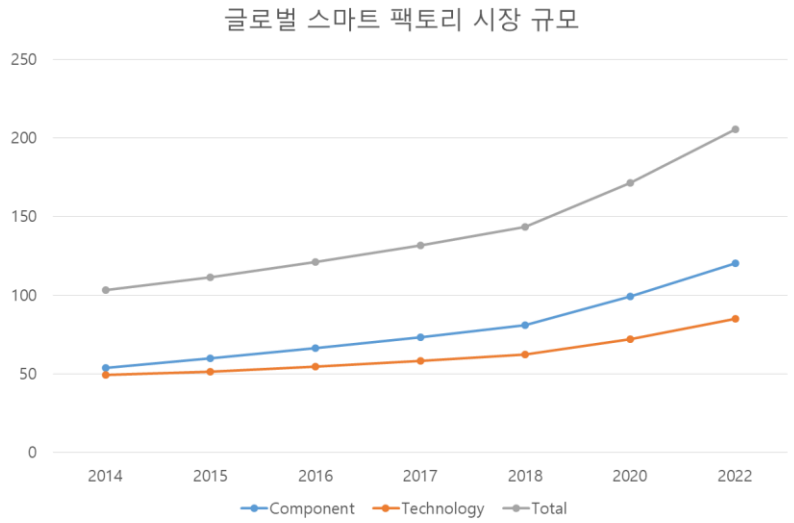

Offering	2014	2015	2016	2017	2018	2020	2022	CAGR(2017~2022)
Component	54.04	59.86	66.24	73.34	81.19	99.10	120.23	10.4%
Technology	49.44	51.57	54.74	58.29	62.31	72.20	85.18	7.9%
Total	103.48	111.43	120.98	131.63	143.50	171.30	205.42	9.3%

그림 1. 글로벌 스마트 팩토리 시장의 규모 변화

[출처, 2020 IoT, AI 기반 스마트 팩토리 기술개발 전략과 시장 전망 보고서]

현재 국내에 존재하는 많은 제조공장들은 제품의 결함 검출을 위한 비전 기반의 장비와 시스템이 구축되어 있지 않다. 비전 검사 장비를 구축하고 있더라도 생산되는 제품의 특성에 따라 여러 형태와 크기를 가진 결함이 발생하고, 그 결함들의 위치가 특정되지 않거나 이에 대한 전문적인 지식이 부족하여 사용도가 낮은 상황이다. 이로 인해 대부분의 산업 현장에서는 전문 감별원들이 제품의 결함을 수작업을 통해 판별하고 있는 실정이다. 하지만 감별원들이 수년간 축적된 노하우를 바탕으로 하여 검사를 하는 경우에도 여러 문제점이 발생한다. 첫 번째로 전문 감별원들의 숙련도에도 불구하고 장시간의 동일한 업무로 인한 축적된 피로는 일의 능률을 떨어지게 된다. 전문 감별원들의 인간적 특성으로 인한 잘못된 판단은 검사의 신뢰성을 떨어뜨릴 수 있다. 두 번째는 각각의 감별원들의 숙련도가 동일하지 않기 때문에 속도가 일정하지

조선대학교
CHOSUN UNIVERSITY

않고, 숙련도가 낮은 감별원의 판별에 대한 신뢰성 또한 불분명하다. 세 번째로 신규 감별원을 육성하기 위해서는 오랜 시간과 비용, 노력 등을 필요로 한다. 이러한 문제들로 인해 제품 품질의 신뢰성을 확보하지 못하고 생산 계획이 틀어지게 될 경우 기업은 막대한 손해를 감수해야 한다. 때문에 기업들은 스마트 팩토리 구현을 위해 딥러닝 기반 제품 결함 검출 자동화 시스템 구축에 많은 관심을 가지고 투자를 지속하고 있다.

조선대학교
CHOSUN UNIVERSITY

1.2 연구 목적

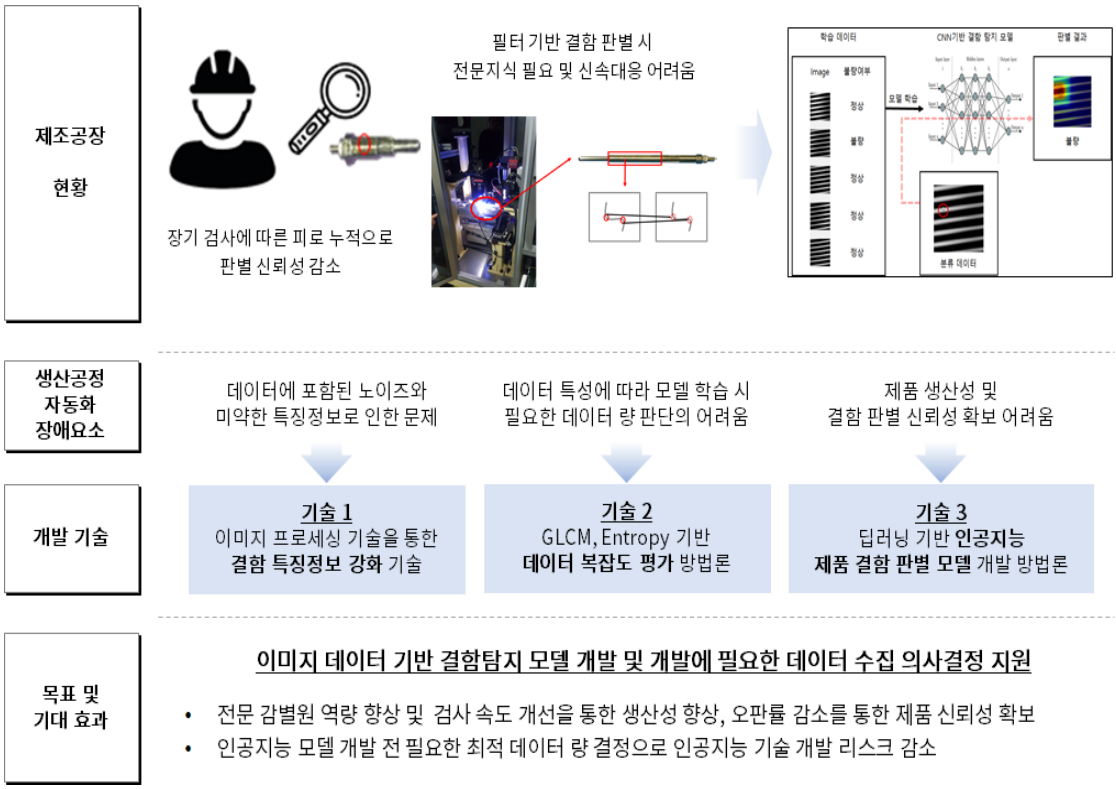

그림 2. 딥러닝 기반 결함탐지 모델 개발 방법론 개요도

딥러닝 기술 중 하나인 CNN의 경우 2015년 이후 인간의 판별 능력보다 높은 성능을 달성하였지만 아직까지 실전에 적용하기에는 다양한 문제점이 존재한다. 가장 큰 문제 중 하나는 CNN 모델을 학습하기 위해 현장 데이터를 충분히 확보하기 어렵다는 것과 수집된 데이터의 전처리 및 라벨링 분류 작업이 어렵다는 점이다. 이러한 문제점들은 딥러닝 기술을 현장에 적용하는 데 어려움을 준다. 이에 대한 해결책으로 충분한 데이터를 확보하기 위해 많은 노력을 기울이고 있지만, 여러가지 제약 조건으로 인해 쉬운 일이 아니다. 특히 정상 상태의 데이터 확보에 비해 결함이 포함된 데

조선대학교
CHOSUN UNIVERSITY

이터를 확보하기가 매우 어려운데, 이는 제조업체가 제품 자체의 결함을 최소화하기 위해 수많은 노력으로 불량 제품의 생산 자체가 많지 않기 때문이다. 또한 양품과 불량의 평가자와 데이터 수집 전문가마다 결함의 기준이 달라 결함을 정상/비정상 판정에 오류가 발생하는 경우도 존재한다.

이러한 문제점들은 CNN 모델의 품질과 성능에 영향을 미치기 때문에 데이터에 대한 많은 확인 작업이 요구되고, 이를 보완하여 고품질의 데이터 마트를 구축하는 것이 매우 중요하다. 하지만 실제 제조산업에서는 충분한 양의 데이터를 확보하고자 하기에는 많은 비용과 시간이 소요되기 때문에 충분한 결함 데이터를 확보하기가 쉽지 않다. 이를 해결하기 위해 다양한 방식의 데이터 증식 기법들이 연구 및 개발되고 있다. 전통적인 데이터 증식 기법으로는 이미지 변환(크기, 회전 등)이나 노이즈 추가 등이 있다. 그리고 최근에는 딥러닝 기술 중 GAN(Generative Adversarial Network)[8]을 이용한 데이터 증식 기법들이 연구되고 있다. 하지만 이러한 데이터 증식 기법들을 통해 생성된 결함 데이터들은 실제 결함에 대한 특징(feature)들을 포함하지 않을 수도 있어 이를 기반으로 개발된 딥러닝 모델의 일반성이 부족할 수 있다.

따라서, 본 연구에서는 생산라인에서 수집된 이미지 데이터를 활용하여 결함을 탐지하기 위한 딥러닝 모델 개발에 요구되는 최적의 학습 데이터 양을 제시해 줄 수 있는 방안에 대해 연구하고자 한다. 결함을 탐지하기 위한 딥러닝 모델 개발에 요구되는 최적의 학습 데이터 양을 제시해 주기 위해 1) 딥러닝 모델 개발 시 결함 특징을 강화하기 위한 이미지 전처리 기법들을 적용하고, 2) 딥러닝 기술에서 이미지 분석에 특화된 CNN에 데이터를 축차적으로 전이학습(Transfer Learning)하여 최적의 데이터 양을 제시해 줄 수 있는 방법론을 제안한다. 이를 통해 현장에서 수집된 데이터를 활용한 딥러닝 모델 개발에 요구되는 학습 데이터의 양을 사전에 판단할 수 있고, 데이터 수집 및 전처리에 대한 시간과 비용을 감소할 수 있을 것으로 기대된다.

조선대학교
CHOSUN UNIVERSITY

1.3 연구 구성

1장 이후 본 연구의 구성은 다음과 같다. 2장에서는 전통적인 결함 검사 방법 및 딥러닝 기반의 결함 검출 방법들에 대해 설명한다. 3장에서는 본 연구에서 수집된 데이터 별 GLCM(Gray Level Co-occurrence Matrix)[27], Entropy[4]를 통해 계산된 복잡도 값을 기준으로 이미지의 범주를 구분한다. 그 후 부분별 랜덤 추출을 통해 각 이미지 범주에 부족한 학습 데이터를 증식하고, 이미지 전처리 기법들을 통해 이미지 내 결함에 대한 특징 정보를 강화하여 모델 학습에 필요한 데이터 마트를 구축한다. 모델 학습을 위해 실험계획을 수립하고, 성능을 평가 및 결과 시각화를 위한 방안을 설명한다. 마지막으로 4장에서는 구축된 데이터 마트를 바탕으로 축차적 실험을 통해 3가지 기준 모델인 Vggnet[5], Googlenet[6], Resnet[2]을 전이 학습시키고 각 모델의 성능 변화를 비교 분석한다. 또한, 제안된 방법론에 새로운 결함 데이터들을 적용하여 제안된 방법의 유효성을 검증한다. 마지막으로 5장에서는 본 연구의 결론 및 향후 연구 방향에 대해 기술한다.

조선대학교
CHOSUN UNIVERSITY

제 2 장 기존연구 고찰

본 장에서는 CNN의 기본 개념 및 주요 연구 분야를 설명한다. 그리고 결함 검출 시스템을 개발하기 위해 주로 활용되었던 필터 기반의 특징 추출 기술들과 CNN 기반의 특징 추출 기술들에 대한 특징과 한계점을 정리한다.

2.1 필터 기반 결함 검출

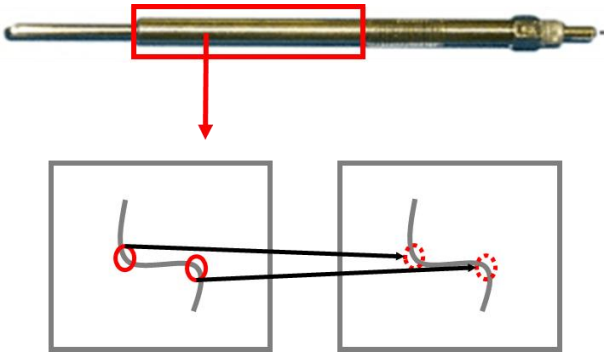

그림 3. 규칙정보 기반 결함탐지 예시

현재까지 머신 비전 검사를 위해 가장 많이 쓰인 방법으로는 규칙정보를 기반으로 특징을 추출하는 기법이다. 그림 3과 같이 Edge에서 발생하는 변화에 대해 규칙정보를 기반으로 탐색하고, 기존에 존재하는 특징과 비교를 통해 결함을 검출하는 것이다. 규칙을 기반으로 특징을 추출하는 방법에는 주로 이미지의 밝기 차이 또는 Edge의 변화를 확인하는 SIFT(Scale Invariant Feature Transform)[9], HOG(Histogram of Oriented Gradient)[10], Gabor Filter[11] 등이 있다. 이러한 방법들은 주로 특징 정보를 수학적으로 모델링하여 특징을 추출하고 정상 특징과의 차이를 통해 이미지를

조선대학교
CHOSUN UNIVERSITY

판별하는 방법이다.

CNN이 활발하게 응용되기 전 일반적으로 많이 사용되던 규칙정보기반의 특징 추출 방법인 SIFT의 경우 이미지의 크기와 회전에도 영향을 받지 않는 특징을 추출하여 매칭시켜 대응 되는 부분을 찾아주는 기법이다. 특징점 주변의 지역적인 그래디언트 분포의 특성(밝기 변화 방향, 변화 정도)을 표현한 특징정보로 이미지 유사도 평가를 통해 결함의 유무를 판단한다. SIFT는 1) scale-space extrema detection 2) keypoint localization 3) orientation assignment 4) keypoint descriptor 총 4단계에 걸쳐 특징을 추출한다.

1단계에서 원본이미지의 2배 크기 이미지(Octave 1)와 원본(Octave 2), $\frac{1}{2}$(Octave 3), $\frac{1}{4}$(Octave 4)크기의 이미지에 가우시안 필터를 적용하여 Blur 처리하고 같은 Octave 내에서 인접한 두 개의 Blur 이미지를 빼는 Difference of Gaussian 연산을 통해 특징점을 찾기 위한 이미지를 생성한다. 1단계 과정에서 여러 크기의 데이터에 Blur를 적용하여 이미지의 특징을 추출함으로써 이미지의 크기에 불변하는 특성이 생긴다.

2단계에서는 동일한 Octave에서 인접한 서로 다른 3장의 이미지를 비교하여 선택한 픽셀을 제외하고 주변의 8개 픽셀과 나머지 두 이미지의 동일 부분 픽셀을 비교하여 극소값, 극대값을 탐색한다. 이렇게 추출된 극값의 경우 정확한 극값을 찾아내기 어려워 테일러 2차 전개 수식을 통해 정확한 극값의 위치를 찾아낸다. 찾아낸 극값의 경우 노이즈에도 민감하게 반응하여 노이즈를 Edge로 잘못 찾아낼 수 있어 수평/수직 방향으로의 그래디언트 값으로 변화량을 계산해 불필요한 keypoint를 제거하고 가능성 높은 특징점을 추출한다.

3단계에서는 찾아낸 Keypoint들에 그래디언트 크기와 방향을 공식을 통해 계산한다. 이를 통해 특징에 대한 회전 불변성을 가지게 한다. 1개의 bin 당 10 degree를 포함하는 36개의 bin으로 구성된 Orientation histogram을 구성하고 80%이상의 높이를 가지는 bin을 keypoint에 부여한다.

마지막으로, 4단계에서는 이미지에서 찾아낸 keypoint들의 위치, 방향, 크기 정보

조선대학교
CHOSUN UNIVERSITY

를 16*16(128개)에 생성하고 16개의 keypoint descriptor를 생성한다. 이렇게 생성된 특징 keypoint를 바탕으로 이미지 내의 결함을 찾아낼 수 있다.

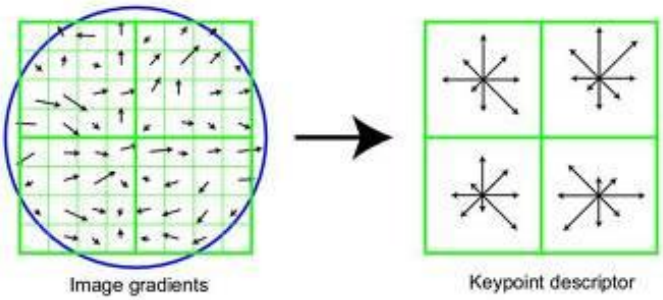

그림 4. 하나의 keypoint 특징을 나타내는 128개의 숫자[9]

HOG는 픽셀의 변화량과 각도, 크기를 고려하여 Histogram 형태의 특징을 추출하는 방법이다. 대상 이미지를 일정 크기의 셀로 분할하여 각 셀마다 Edge 픽셀들의 방향 그래디언트 값의 Histogram을 구한 것이다. Edge 특징을 기반으로 판별하기 때문에 패턴이 복잡하지 않고, 결함의 특징 고유한 형태를 갖추고 있는 경우에 사용하기 적합하다. 이외에도 Haar like feature[12], Ferns[13], LBP(Local Binary Pattern)[14], MCT(Modified Census Transform)[15] 등과 같이 영역간 밝기 차이를 이용해 특징을 추출하는 다양한 방법들이 연구되었다.

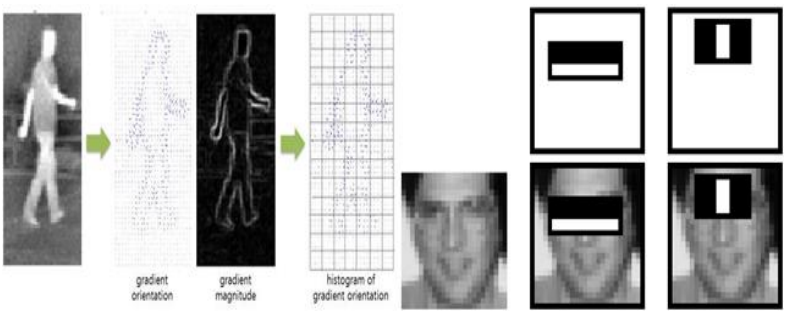

그림 5. HOG(좌), Haar(우) Feature[10,12]

조선대학교
CHOSUN UNIVERSITY

Gabor Filter의 경우 $\lambda, \theta, \Psi, \sigma, \gamma$ 5가지 파라미터 값 조정을 하는데 각각의 파라미터의 값에 따라 변화하는 것은 다음과 같다. λ는 Kernel의 sin함수를 조절하여 필터의 중심으로부터 주변의 값을 빼거나 더해 특징을 추출하고, θ는 Kernel의 방향을 Ψ는 중심으로부터 필터가 얼마나 이동하는지, σ는 Kernel 필터의 크기를 γ는 필터의 가로세로 비율을 조절하여 필터의 형태를 구성하고 규칙적인 배경을 제거하여 외곽선 특징을 추출하는 기법이다.

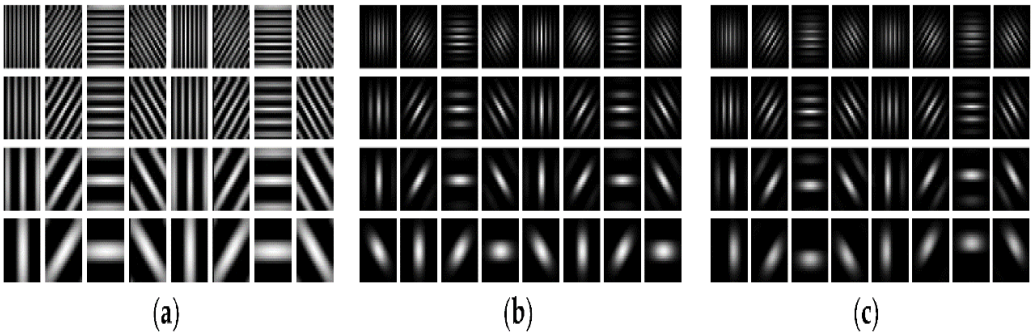

그림 6. Gabor Filter 파라미터 조절 결과

그림 6의 (a)에서 좌측에서 우측으로 σ는 15, θ는 0°에서 360°까지 45°식 회전하고, 위에서 아래로는 λ를 2,4,10,20으로, Ψ를 0으로 하여 나온 결과이다. (b)는 (a)와 동일하나 σ 값을 5로 조정한 것이고 (c)는 (b)의 결과 중 Ψ만 5로 조정한 것이다. 이와 같이 파라미터들을 조절함으로써 특정 결함 특징에 최적화된 필터를 생성할 수 있으나, 이러한 필터의 경우 일반화된 특성을 발휘할 수 없어 조금의 변화에도 결함을 검출하지 못하거나 새로운 형태의 필터를 다시 생성해야 하는 문제가 있다.

$$g(x,y;\ \lambda,\theta,\Psi,\sigma,\gamma) = \exp\left(\frac{-x'^2 + \gamma^2 y'^2}{2\sigma^2}\right)\cos\left(2\pi\frac{x'}{\lambda} + \Psi\right)$$

$$x' = x\cos\theta + y\sin\theta,\ y' = -x\sin\theta + y\cos\theta$$

조선대학교
CHOSUN UNIVERSITY

이러한 규칙을 기반으로 하는 결함 검출 방식들의 경우 데이터가 복잡하지 않고 일정한 형태를 가지거나, 데이터에서 결함이라고 표현되는 부분의 대비가 확실한 경우 또는 특징을 탐색하기 위한 계산량을 처리할 수 있는 컴퓨터 성능이 보장된 경우에 가능한 방법이다. 규칙 기반의 결함 검출 방식은 데이터의 형태에 따라서 특징을 추출하는 방법을 새로 만들어 내야하고 데이터에서 결함을 찾기 위해서는 결함이라고 의심되는 부분을 두드러지게 만들어 결함의 특징을 찾아야 한다.

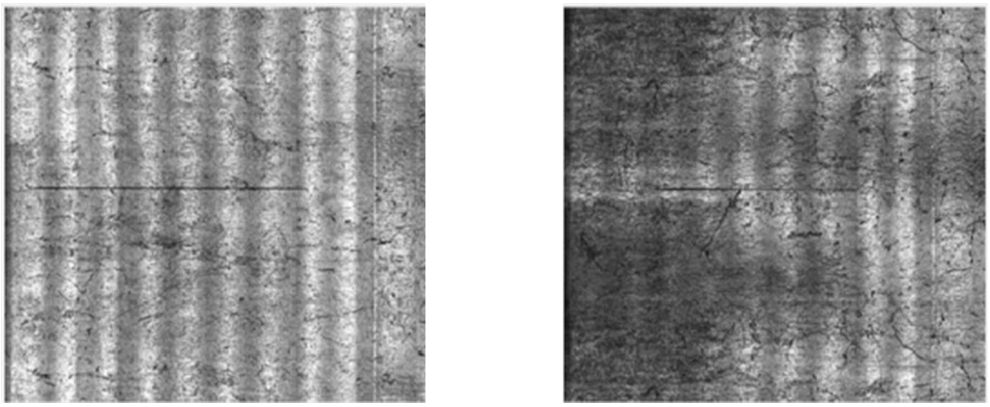

그림 7. 노이즈가 포함된 불규칙적인 이미지

전체적인 배경의 패턴이 존재하면서 결함의 특징이 주변과 확연히 다른 경우 밝기 특징 정보를 활용하여 이를 탐지할 수 있으나 그림 7과 같이 고르지 못한 배경이 존재할 경우 규칙을 기반으로 하는 결함 검출 방식으로는 구분하기 어렵다. 또한, 규칙 기반의 결함 검출 방법은 데이터의 변화 시 신규 특징을 탐색하기 위해 많은 배경지식이 필요하며, 관련 분야를 깊게 연구한 전문가가 아니면 다루기 쉽지 않아 제품의 형태가 수시로 수정·변형되는 제조 산업현장에 적용하기 어려운 문제점이 있다.

조선대학교
CHOSUN UNIVERSITY

2.2 CNN 기반의 결함 검출

2.2.1 Convolution Neural Network

딥러닝은 1958년 Frank Rosenblatt가 제안한 가장 단순한 구조의 인공 신경망인 퍼셉트론[12]을 기반으로 발전한 것이다. 다음 그림 8과 같이 인공 신경망은 데이터를 받는 입력층(Input Layer)과 여러 개의 Node와 Layer로 구성되어 특징을 찾는 은닉층(Hidden Layer), 결과를 출력하는 출력층(Output Layer)으로 구성된다. 이렇게 구성된 인공 신경망은 출력층의 결과와 실제값의 오차를 최소화 하는 것을 목적으로 역전파 알고리즘을 통해 모든 층의 가중치를 갱신하며 학습을 한다.

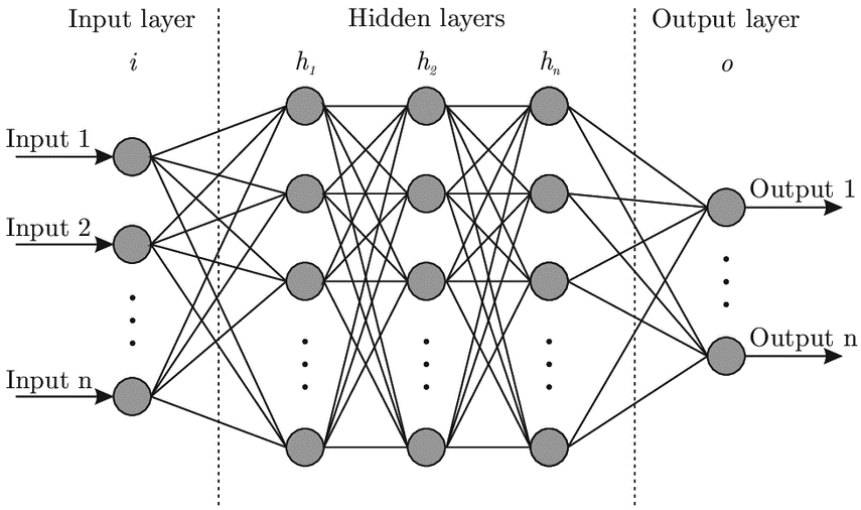

그림 8. Multi Layer Perceptron

딥러닝의 대표적인 모델인 MLP(Multi Layer Perceptron, 다층 퍼셉트론) 방식은 학습 시 데이터를 1차원 형태로 바꾸기 때문에 2차원 데이터의 형태적 특징이 무시된다. 그리고 모든 픽셀에 계산되는 가중치들로 인해 메모리 부족현상이 발생할 수가 있다. 또한, 학습 시간이 많이 필요하며 과적합(Overfitting)에 빠질 위험이 존재한

조선대학교
CHOSUN UNIVERSITY

다. 이러한 문제들로 인해 데이터의 형태적인 특징을 고려하고 학습 가중치를 줄여 모델의 복잡도를 낮추면서 데이터의 특징을 추출하기 위한 방법으로 CNN이 고안되었다. 현재 딥러닝 기술 중 이미지 분류 분야에서 가장 많이 사용되는 기술인 CNN은 LeCun이 1989년 제안한 기술로서 이미지에 필터를 적용하여 특징맵을 추출하는 컨볼루션(Convolution) 연산이 포함된 신경망 네트워크를 말한다[1]. CNN 모델의 일반적인 구조는 그림 9와 같다.

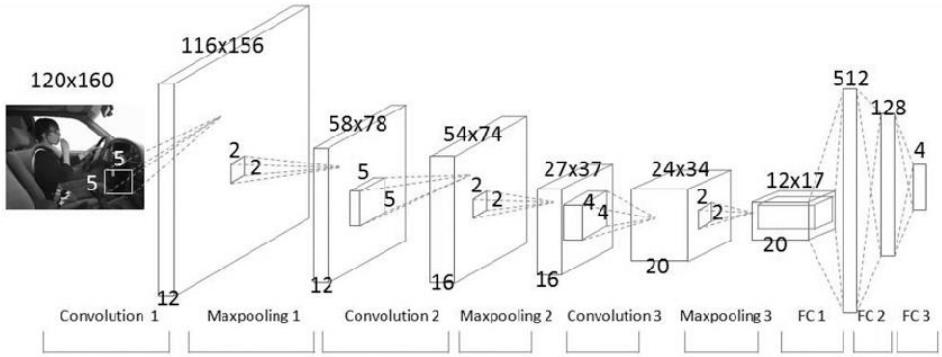

그림 9. Convolutional Neural Networks[31]

CNN은 이미지의 형태적 특징을 추출하기 위하여 Convolutional Layer, Pooling Layer와 분류를 위한 Fully Connected Layer로 구성된다. Convolutional Layer에서는 다음 그림과 같이 각 픽셀 별로 필터와 곱하고 그 결과를 모두 더하는 단순한 선형 연산이 이루어 진다. 이미지에서 정보는 픽셀과 픽셀의 주변 픽셀 또는 RGB의 각 채널 별 픽셀들이 밀접하게 연관되어 나타난다. 이미지에 들어있는 정보를 추출하기 위해 여러 개의 필터를 생성하고 컨볼루션 연산하여 핵심 정보를 추출할 수 있는 특징맵을 생성한다. 이때, 컨볼루션 연산을 위해 필터의 크기, 필터의 이동간격(Stride), 원본 이미지 크기와 동일한 크기의 특징맵을 만들기 위해 원본 이미지 주변에 다른 값을 둘러 쌓는 패딩(Padding)의 크기 등을 결정한다. 2D Cross-Correlation에 대한 컨볼루션 연산을 식으로 표현하면 다음 식과 같다.

조선대학교
CHOSUN UNIVERSITY

$$y[i,j] = (x * w)[i,j] = \sum_{n=-\infty}^{\infty} \sum_{m=-\infty}^{\infty} x[m-i, n-j]w[m,n]$$

Pooling Layer에서는 컨볼루션 연산에 의해 구해진 특징맵에서 특정 크기의 정사각형 안에 있는 값들 중 최대값(Max Pooling) 또는 평균값(Average Pooling) 등을 구하는 연산이 이루어 진다. 이를 통해 그림과 같이 특징맵의 특징을 유지하거나 강조하면서 크기를 줄여 메모리 사용량을 낮춘다. Fully Connected Layer에서는 추출된 특징 값을 기존 인공 신경망에 넣어 학습을 하고 결과값의 총합이 1이 되도록 0 ~ 1 사이의 확률 값으로 결과를 변환해주는 Softmax 함수를 사용한다. 이외에도 오버피팅(Overfitting)을 막기 위해 신경망 사이의 연결된 가중치를 끊어버리는 연산을 하는 Dropout Layer[13] 또는 각 층마다 Input의 분포를 평균 0과 표준편차 1인 Input으로 정규화 해주는 Batch Normalization Layer[14]과 같은 Layer들이 개발되었다.

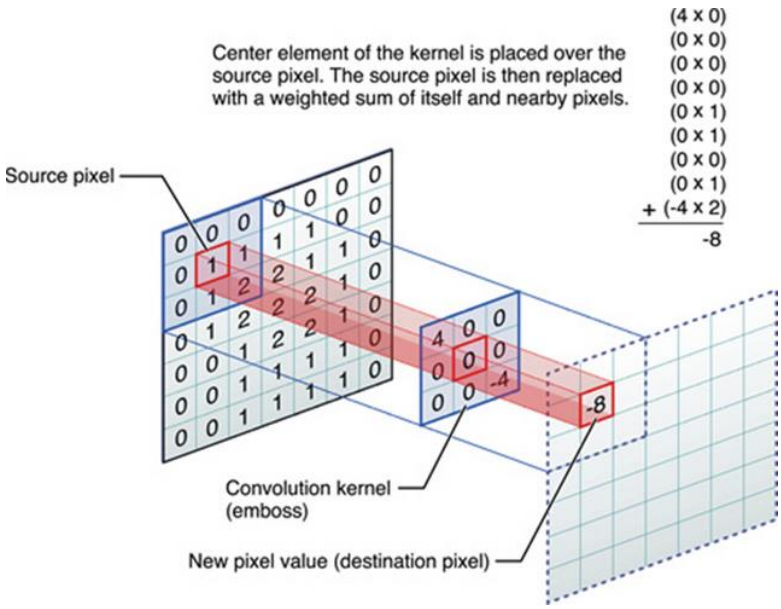

그림 10. Convolutional Layer에서의 합성곱 연산

[출처, https://imjuno.tistory.com/entry/Convolutional-Neural-NetworkCNN]

조선대학교
CHOSUN UNIVERSITY

2.2.2 다양한 구조의 Convolution Neural Network

앞서 설명한 Layer를 기반으로 높은 성능을 발휘하는 모델을 개발하는 과정에서 다양한 형태의 CNN 모델이 제안되었다. Image Classification 대회인 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)는 1420만장의 이미지 데이터를 학습하여 분류하는 대회로 2010년부터 개최되었고, 2015년부터는 사람이 잘못 판단하는 Error Rate 5%보다 더욱 낮은 Error Rate로 분류가 가능하게 되었다.

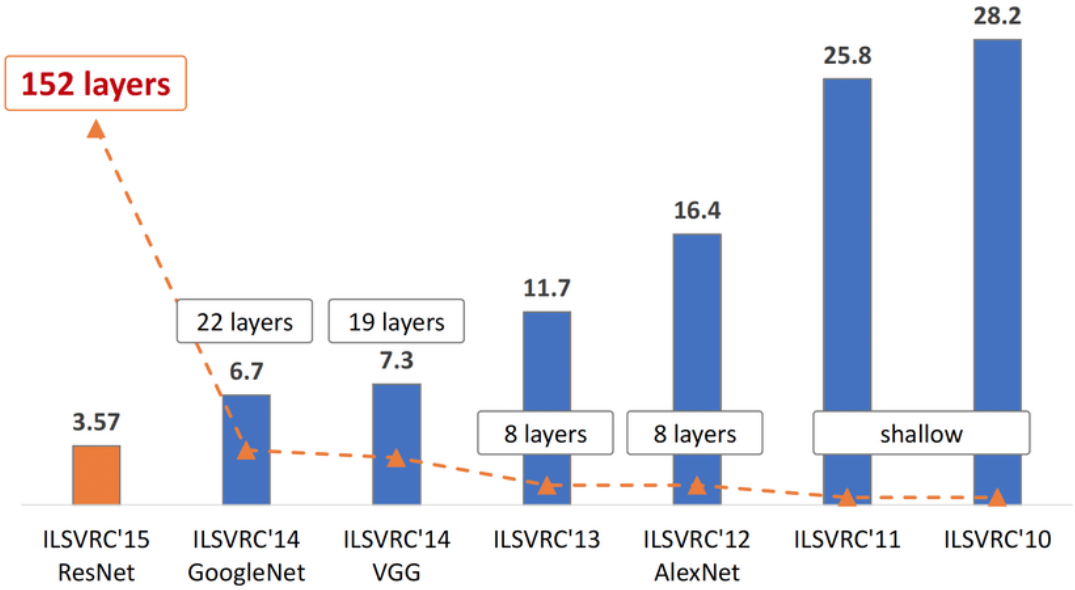

그림 11. ImageNet Challenge Top-5 Error

[출처, https://medium.com/analytics-vidhya/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5]

2012년 대회에서 CNN 모델인 Alexnet[15]이 사용된 이후 2011년까지 주로 사용되던 모델 파라미터 튜닝을 통한 성능 향상 방법이 아닌 Layer를 깊게 쌓는 등의 모델 변형을 통한 성능 향상 방법들이 연구되었다. 2014년 발표된 Vggnet[6]에서는 Layer의

조선대학교
CHOSUN UNIVERSITY

깊이가 모델의 성능에 어떤 영향이 있는지에 대해 연구하였다. 가장 작은 크기의 3*3 Convolutional Layer로 모델을 구성하여 실험한 결과 여러 층의 Layer에 의해 비선형성이 높아지고, 전체적인 학습 파라미터의 수가 감소됨을 확인하였다. Vggnet은 그림 12와 같은 구조로 구성되어있다. 224*224 크기의 Color 이미지를 Input으로 사용하였고, Convolutional Layer과 Pooling Layer가 반복되면서 마지막에는 Fully Connected Layer를 두어 19층의 Layer로 구성되었다.

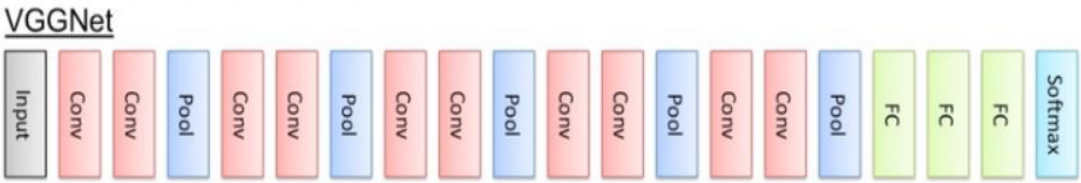

그림 12. Vggnet의 네트워크 구조[32]

3*3 Convolutional Layer를 2개 쌓으면 5*5 Convolutional Layer와 동일한 크기의 Feature Map을 얻을 수 있으나 사용된 파라미터의 수는 줄고 학습시간 또한 감소한다. Layer가 깊어지면 Gradient Vanishing 또는 Gradient Exploding 현상으로 인해 학습이 어려워진다. 이때 Vggnet에서는 새로 학습될 19 Layer의 초기 파라미터 값을 이전에 학습된 11 Layer로 구성된 Vggnet의 결과를 사용함으로써 문제를 해결하였다.

다음 Googlenet의 경우 2014년 Vggnet과 동일하게 발표된 모델로 당시 Top-5 Error 6.7%로 1위를 한 모델이다. 당시 Vggnet에 비해 모델이 복잡하여 많이 사용되지는 않았으나 모델의 구조는 이슈가 되었다. 그림 13에서 각각의 색이 의미하는 것은 파란색 Convolutional Layer, 빨간색 Pooling Layer, 초록색 Concatenate 또는 Normalize Layer, 노랑색 Softmax Layer를 나타낸다.

조선대학교
CHOSUN UNIVERSITY

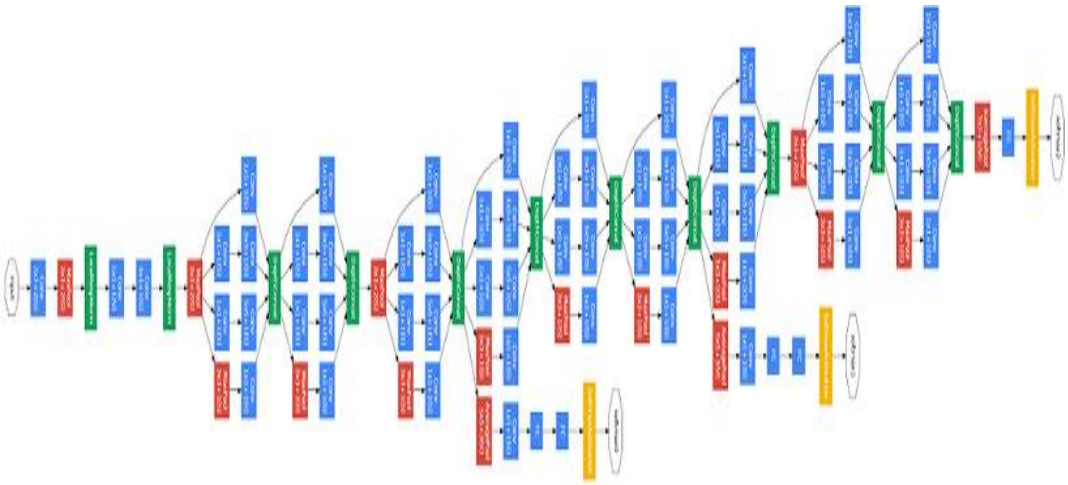

그림 13. Googlenet의 네트워크 구조[6]

Googlenet은 총 22개의 Layer로 구성되고 하나의 Layer에 다양한 종류의 필터가 병렬로 구성되어 4가지의 서로 다른 연산을 하는 Block 구조를 이루고 있다. 그림 14와 같은 구조를 Inception Module 이라 하였다.

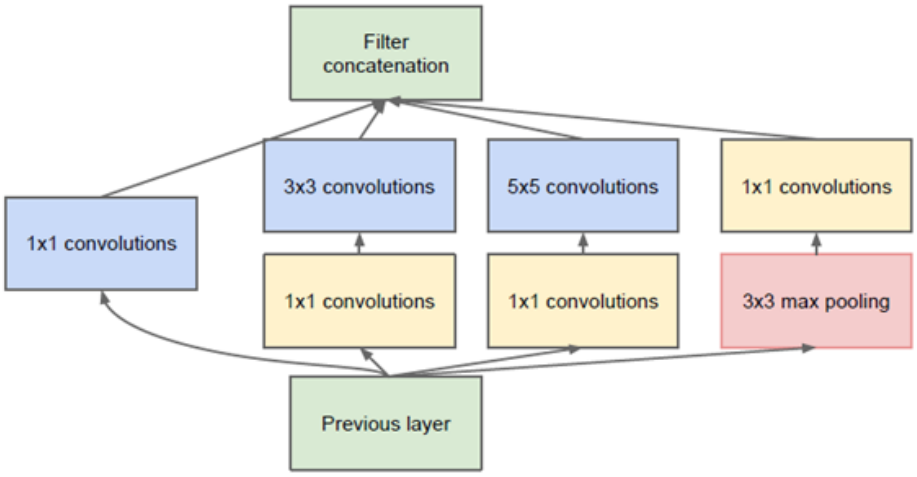

그림 14. Inception Module 구조[6]

조선대학교
CHOSUN UNIVERSITY

Inception Module은 다양한 형태의 Feature를 추출하기 위해 1*1, 3*3, 5*5 Convolutional Layer와 Pooling Layer를 쌓고, 1*1 Convolutional Layer를 통해 Feature Map의 개수를 줄여 전체적인 연산량을 줄였다. Inception Module을 사용함으로써 Alexnet에 비해 Layer를 깊게 쌓으면서 Fully Connected Layer를 줄여 전체적인 파라미터의 양이 1/120이 되도록 개선하였다. 또한 Layer가 깊어지면 Gradient Vanishing 문제가 발생하는데 이를 해결하기 위해 Layer 중간에 Auxiliary Classifier에서 역전파를 계산하고 나온 결과를 최종 Layer에서 계산된 역전파에 합하였다. 그 결과 Gradient 값이 0으로 수렴하지 않아 깊은 Layer에서 학습 시 학습 시간이 증가하거나 학습이 되지 않는 것을 방지하였다.

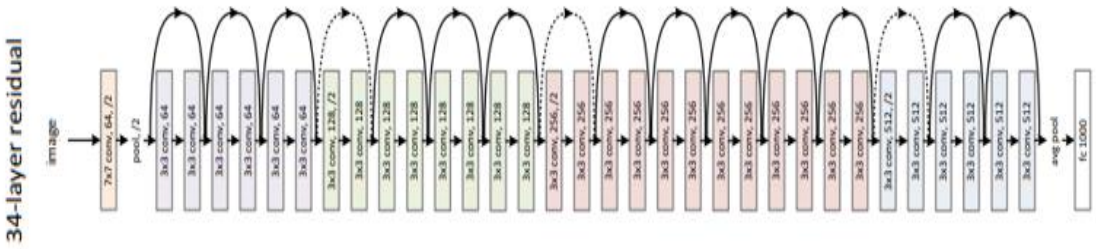

그림 15. Resnet의 네트워크 구조[2]

마지막으로 Resnet은 2015년 ILSVRC에서 Top-5 Error 3.57%로 1등을 한 모델이다. 그림 15와 같이 모델의 복잡도를 줄이기 위해 Pooling Layer, Fully Connected Layer, Dropout Layer를 사용하지 않고 Vggnet 구조를 뼈대로 하여 여러 개의 3*3 Convolutional Layer와 1개의 Pooling Layer로 구성되어있다. Vggnet, Googlenet 등 기존의 모델들은 Layer가 깊어질수록 파라미터의 수가 늘어나고 학습이 되지 않거나 학습 속도가 느려지는 문제가 더욱 심각해졌다. 이러한 이유로 Layer를 깊게 쌓지 못하는 문제를 그림 16과 같은 방법으로 해결하였다.

조선대학교
CHOSUN UNIVERSITY

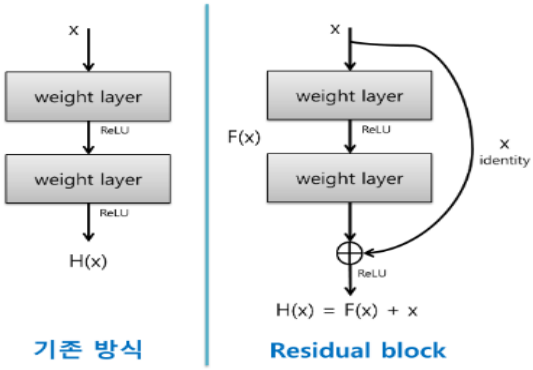

그림 16. Residual Block 구조[2]

각 층의 입력을 출력에 연결하는 Skip Connection 방법을 통해 Residual Block을 생성하였다. Skip Connection은 Convolution 연산이 이루어 지고 난 뒤 나온 결과값에 초기 입력값을 더하는 방법이다. 기존의 모델들은 입력값 x를 출력값 y로 보내주는 $\mathrm{H}(x)$ 함수를 찾도록 학습하였으나, Resnet에서는 $\mathrm{F(x)}+x$를 최소화 하는 것을 목적으로 $\mathrm{H}(x)$ 함수에서 입력값 x를 뺀 $\mathrm{F}(x)$의 잔차(Residual)를 학습한다. 이후 더 깊은 Layer를 쌓기 위해 Bottleneck Block을 구성하였다. Bottleneck Block은 더 많은 Feature Map을 유지하면서도 기존의 Residual Block보다 적은 파라미터로 학습할 수 있도록 하는 방법으로 그림 17과 같은 구조이다.

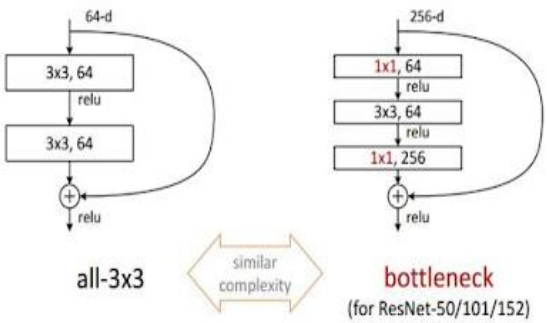

그림 17. Bottleneck 구조[2]

조선대학교
CHOSUN UNIVERSITY

2.3 Transfer Leaning

전이학습[16]이란 사전에 학습된 모델의 가중치를 바탕으로 새로운 모델을 다시 학습시키는 기법으로 그림 18과 같은 방법들이 있다. 확보된 데이터의 양에 따라 사전에 학습된 모델이 가지고 있는 가중치를 Layer의 재학습 범위를 결정한다. 보통 앞부분의 Layer의 가중치들은 추상적인 Feature들을 추출하는 Layer로 마지막 분류를 위한 Fully Connected Layer의 가중치만을 새로운 데이터로 학습한다. 이 같은 방법을 통해 학습 속도와 적은 데이터에서도 높은 성능을 보이는 모델을 학습할 수 있다.

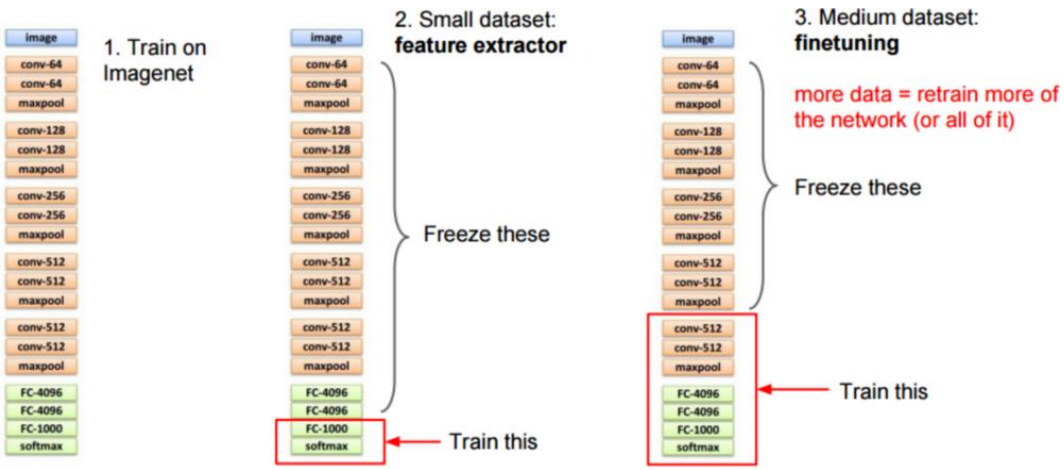

그림 18. Transfer Leaning 방법 및 구조

[출처, CS231n, Stanford University]

2.4 제조산업에서의 딥러닝 적용의 한계

딥러닝은 기존의 머신러닝 또는 수리적 모델을 기반으로 하는 알고리즘에 비해 높은 성능을 보이나 고품질의 학습 데이터를 많이 필요로 한다. 이안 굿펠로우(Ian

조선대학교
CHOSUN UNIVERSITY

Goodfellow), 요슈아 벤지오(Yoshua Bengio), 에런 쿠빌(Aaron Couville)이 저술한 'Deep Learning'에 따르면, 카테고리당 대략 5,000개 정도의 학습 데이터가 있어야 허용 성능(Acceptable Performance)을 보인다 하며, 인간 성능에 필적하거나 뛰어넘기 위해서는 적어도 100만 장의 학습 예제가 필요하다고 한다. 전이학습이 아닌 처음부터 초기 가중치를 학습하는 형태로 5종류의 불량을 분류하는 인간의 작업을 딥러닝 모델로 구현하기 위해서는, 최소 500만 장 이상의 학습 이미지가 필요하다는 의미이다[3].

하지만 제조산업에서는 이러한 딥러닝을 구현하기 위해 고품질의 데이터를 수집하는 것은 환경적으로 쉽지 않은 일이다. 결함 데이터의 경우 자주 발생하지 않고, 인위적으로 생성한 결함 데이터의 경우 자연적으로 발생하는 결함과 다른 특징을 가지고 있고 이러한 데이터들을 수집하기 위해서는 많은 시간과 비용, 인적 노력이 요구된다. 만약 적은 데이터로 모델 학습 시 학습에 사용되지 않은 데이터를 판별할 때 변화하는 상황에 맞추어 판별하는 것이 어렵다. 또한, 학습을 위한 데이터의 특징이 다양하면 학습모델의 구조가 복잡하게 되고 이로 인해 학습에 필요한 데이터 양과 학습 시간이 비정상적으로 늘어나는 문제가 있다.

하여, 제조산업에서 부족한 데이터를 기반으로 결함 검사 시스템을 구축할 때 도움을 주기 위해 본 연구에서는 데이터의 복잡도에 따라 시간과 비용, 노력 등을 고려하여 학습에 필요한 최적의 데이터 양을 결정하고, 전이 학습을 통해 높은 성능의 결함 검출 CNN 모델을 개발하는 방법론이 필요하다.

조선대학교
CHOSUN UNIVERSITY

제 3 장 전이학습을 위한 최적의 학습 데이터 양 결정

본 장에서는 결함 검출 시스템의 핵심 알고리즘인 CNN 모델의 최적 학습 데이터 양을 결정하기 위해 데이터의 복잡성을 평가하고, 평가 결과에 따라 이미지 전처리 기법들을 적용하여 학습 데이터를 생성하고 전이학습 하는 방안에 대한 내용을 기술한다.

3.1 학습을 위한 데이터 전처리

본 절에서는 비전 기반 시스템에서 수집된 이미지 데이터를 복잡도에 따라 구분하는 방법과 구분된 이미지들에 대해 영상처리 기법들을 적용하는 내용을 기술한다. 앞서 이야기한 바와 같이 이미지에 포함되어있는 특징 정보들은 다양하여 CNN 모델을 학습시키기 위해 필요한 적정 데이터 양을 가늠하기 어렵고, 특징정보가 주변의 다른 노이즈에 의해 구분되지 않는 등의 문제점이 있다. 이러한 문제를 해결하기 위해 Entropy, GLCM를 기반으로 수집된 데이터의 복잡도를 계산하여 기존 데이터와 유사도 비교를 통해 학습에 필요한 데이터 양을 결정한다. 그리고 Gray Scale 이미지에 영상처리기법인 Canny Edge[17], binarization[18]을 통해 노이즈를 제거하여 학습데이터를 생성하는 방안에 대하여 기술한다.

3.1.1 통계적 분석방법을 이용한 이미지의 질감 특성 분석

이미지의 텍스처 특성을 분석하는 통계적 방법에는 선택한 화소와 이웃하는 화소간 명암 관계를 평균, 대비, 상관성 등의 통계량으로 계산하여 특성을 분석하는 GLCM과 이미지의 픽셀들에 대한 전체적인 분포를 통해 정보량을 계산하는 Entropy 등이 있다.

조선대학교
CHOSUN UNIVERSITY

GLCM은 일반적으로 그림 19와 같이 계산할 수 있다. 0에서 3까지의 값을 가지는 4x4 픽셀의 이미지에서 i, j번째의 픽셀을 미리 정의한 기준 거리 1픽셀과 방향 조건 0도를 만족하는 이웃한 픽셀들의 동시 발생 빈도수가 GLCM 값이다. 이렇게 생성된 GLCM 값으로부터 이미지의 질감을 분석하기 위해 통계적 특징값을 추출한다.

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

Gray Level	0	1	2	3
0	S(0,0)	S(0,1)	S(0,2)	S(0,3)
1	S(1,0)	S(1,1)	S(1,2)	S(1,3)
2	S(2,0)	S(2,1)	S(2,2)	S(2,3)
3	S(3,0)	S(3,1)	S(3,2)	S(3,3)

2	2	1	0
0	2	0	0
0	0	3	1
0	0	0	1

그림 19. GLCM 계산 방법 예시

본 데이터에서의 GLCM 값은 다음과 같이 계산한다. 원본 이미지 데이터에서 데이터를 학습하기 위한 크기인 224 * 224로 일정 구역을 잘라내어 100개의 데이터들의 평균적인 값을 구하였고, 0~32, 33~64, …, 223~255으로 픽셀의 범위를 지정하여 8단계로 나누어 특징을 계산하였다. 본 연구에서는 그림 20과 같이 3가지 다른 부위인 몸체, 나사선, 시트면 이미지 데이터들을 GLCM으로 계산하였다.

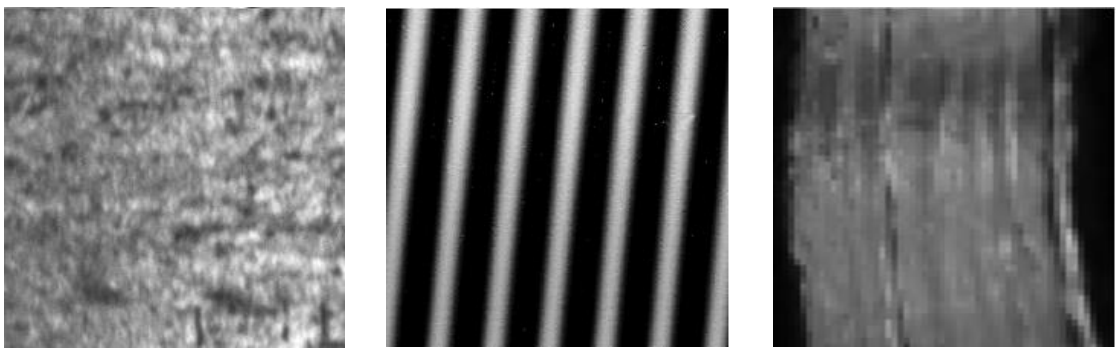

그림 20. GLCM 평가를 위한 몸체, 나사선, 시트면 이미지 데이터

조선대학교
CHOSUN UNIVERSITY

표 1. 몸체 데이터 GLCM 계산값

Level	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	33	30	0	0	0	0	0
2	0	30	2244	893	4	0	0	0
3	0	0	860	11783	2758	19	0	0
4	0	0	9	2641	13693	2320	15	0
5	0	0	0	16	2252	6550	793	6
6	0	0	0	0	8	778	1630	173
7	0	0	0	0	0	1	170	243

표 2. 나사선 데이터 GLCM 계산값

Level	0	1	2	3	4	5	6	7
0	23486	1343	92	4	0	0	0	0
1	1326	855	1246	76	1	0	0	0
2	54	1241	725	1244	86	0	0	0
3	3	69	1224	756	1277	41	0	0
4	0	0	74	1254	1991	1401	17	0
5	0	0	1	52	1362	4097	726	0
6	0	0	0	0	21	720	3071	8
7	0	0	0	0	0	1	7	0

조선대학교
CHOSUN UNIVERSITY

표 3. 시트면 데이터 GLCM 계산값

Level	0	1	2	3	4	5	6	7
0	7732	309	0	0	0	0	0	0
1	305	2333	592	11	0	0	0	0
2	4	572	9610	1009	6	0	0	0
3	0	27	981	22361	628	2	0	0
4	0	0	18	616	2622	65	0	0
5	0	0	0	2	65	80	0	0
6	0	0	0	0	0	1	0	0
7	0	0	0	0	0	0	0	0

표 1,2,3과 같이 계산된 GLCM 값을 기반으로 Contrast(variance), Correlation, Energy(ASM), Homogeneity(IDM), Entropy와 같은 특징 값을 계산하였다. Energy와 Entropy의 경우 이미지 안 픽셀들의 명암도가 얼마나 일정하게 변화하는지를 측정하는 척도이다. Energy는 명암의 균일 정도를 계산 한 것으로 영상 내 픽셀 사이의 밝기 변화가 없고 각 픽셀들의 밝기가 비슷하면 큰 값을 가진다. Entropy는 픽셀들의 분포를 측정하는 척도로 밝기의 변화가 심하고 각 픽셀의 값이 서로 다른 값들을 가질수록 큰 값을 가진다. Contrast는 이미지 전체에서 어느 한 픽셀과 이웃한 픽셀 간의 명암 대비 값으로 균일한 픽셀을 가지는 이미지일수록 작은 값을 가진다. Homogeneity의 경우 GLCM의 요소가 GLCM 대각선에 얼마나 근접하게 분포해 있는지 측정하는 값으로 대각선에 가까울수록 큰 값을 가진다. 이는 현재 픽셀과 이웃하는 픽셀이 동일하거나 비슷할수록 균일 하다는 것을 의미한다. 마지막으로 Correlation은 픽셀 사이의 밝기에 대한 선형적인 의존성에 대한 척도로 이미지의 외곽선에 대한 날카로운 정도를 파악할 수 있다. 앞서 설명한 통계적 특징 값들은 다음과 같은 수식으로 계산된다.

조선대학교
CHOSUN UNIVERSITY

$$\boldsymbol{Energy} = \sum_{i,j}^{f-1} \boldsymbol{p(i,j)^2}$$

$$\boldsymbol{Entropy} = -\sum_{i,j}^{f-1} \boldsymbol{p_{i,j} log_2(p_{i,j})}$$

$$\boldsymbol{Contrast} = \sum_{i,j}^{f-1} \boldsymbol{|i-j|^2\, p(i,j)}$$

$$\boldsymbol{Homogeneity} = \sum_{i,j}^{f-1} \frac{\boldsymbol{p(i,j)}}{\boldsymbol{1+|i-j|}}$$

$$\boldsymbol{Correlation} = \sum_{i,j}^{f-1} \frac{\boldsymbol{(i-\mu i)(j-\mu j)p(i,j)}}{\boldsymbol{\sigma_i \sigma_j}}$$

제시한 방법을 통해 그림 20의 이미지 데이터에서 100개의 데이터들의 평균값을 기준으로 특징을 추출한 결과는 표 1,2,3와 같다. 표 1,2,3를 분석한 결과 Contrast 값은 이웃한 픽셀 간 밝기 대비가 큰 나사선 데이터가 가장 크게 나왔고, 외곽선 경계의 날카로운 정도를 구분하는 Correlation 값은 Edge가 잘 나타난 이미지인 나사선 데이터가 높게 계산되었다. 이미지 밝기의 변화 정도와 분포 정도가 비슷한 지를 평가한 Energy 값은 밝기 변화가 크지 않고 일정한 시트면이 가장 높게 계산되었다. 마지막으로 Entropy는 밝기의 변화가 심하고 각 픽셀의 값이 서로 다른 값을 가질수록 큰 값을 가지는 것으로 계산 결과 몸체가 가장 높게 계산되었다.

데이터에 대한 5가지의 복잡도 평가 지표를 바탕으로 L1 norm(Manhattan norm)과 L2 norm(Euclidean norm)을 계산하여 데이터를 비교하였다. L1 norm은 벡터의 요소에 대한 절대값의 합을 계산한 것이고, L2 norm은 n차원 좌표평면에서의 벡터의 크기를 계산한 것이다. L1 norm과 L2 norm은 아래 수식을 통해 계산된다. 표 4의 값을 통해 데이터를 비교한 결과 L1 norm, L2 norm 값이 동일하게 몸체가 가장 큰 값을 나타내었고 그 다음 순으로 나사선, 시트면이다.

조선대학교
CHOSUN UNIVERSITY

$$L1\ norm\ (Euclidean\ norm)\ =\ \sqrt{\sum_{i}^{n} x_i^2} = \sqrt{x_1^2 + x_2^2 + x_3^2 + \cdots + x_n^2}$$

$$L2\ norm\ (Manhattan\ norm)\ =\ \sum_{i}^{n} |x_i| = |x_1| + |x_2| + |x_3| + \cdots + |x_n|$$

표 4. 통계적 기법 기반 데이터 복잡도 평가 결과

	Contrast	Correlation	Energy	Homogeneity	Entropy	L1 norm	L2 norm
몸체	0.2863	0.9245	0.1154	0.8591	7.5205	9.7059	7.6319
나사선	0.3316	0.9642	0.2533	0.8520	5.6541	8.0553	5.8137
시트면	0.0860	0.9878	0.5721	0.9745	4.1391	6.7595	4.4036

3.1.2 데이터 설명 및 전처리 학습 데이터 생성

본 연구에 사용된 데이터는 자동차 부품 생산공장에서 수집한 이미지 데이터로 그림 21과 같은 자동차 글로우 플러그 제품의 표면을 다각도로 촬영한 것이다. 자동차 글로우 플러그의 경우 디젤 차량의 시동을 돕기 위한 장치로서 동절기 연소실 내의 공기가 자기 착화에 필요한 온도까지 오르지 못할 경우를 대비하여 시동 전 글로우 플러그에 전압을 인가하여 발생한 열을 바탕으로 기관 내부를 예열 하는 장치이다. 플러그에 결함이 발생할 경우 고르지 못한 열 전달로 인해 차량의 시동이 발생하지 않거나, 차량 공회전 안정성을 보장하지 못하고 백연을 발생시킬 수 있다.

조선대학교
CHOSUN UNIVERSITY

그림 21. 자동차 글로우 플러그

이와 같은 문제가 발생하지 않도록 CNN을 기반으로 한 결함 검사 방법을 도입하고자 한다. CNN 모델 개발을 위한 학습데이터는 그림 22와 같은 장비를 통해 고화질의 이미지 데이터로 수집하였다.

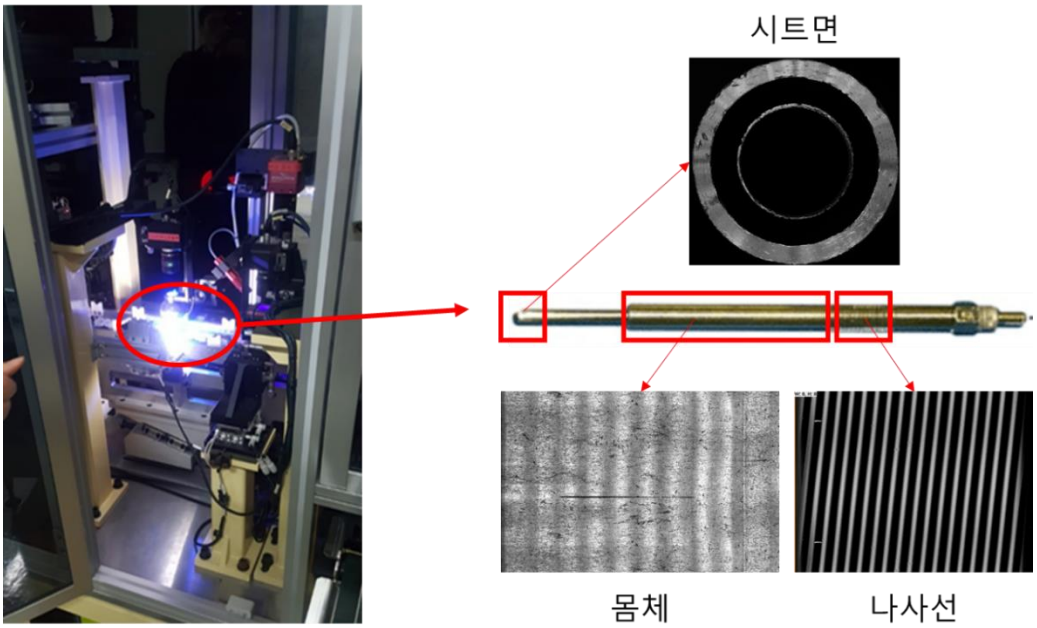

그림 22. 비전기반 이미지 데이터 수집 장비 및 수집 데이터

조선대학교
CHOSUN UNIVERSITY

본 연구에서 활용한 데이터는 다음과 같다. 자동차 글로우 플러그 전체 중에서 결함이 주로 발생되는 나사선과 몸체, 시트면을 주요 목표구역으로 설정하였다.

표 5. 전체 수집 데이터

	데이터		
	정상 데이터	비정상 데이터	크기
나사선	1000	1000	690*524
몸체			8192*3000
시트면			2592*1944

표 5와 같이 나사선, 몸체, 시트면 부위를 촬영한 데이터는 정상 1000개와 비정상 1000개이다. 나사선 이미지의 경우 690 * 524 크기이고, 몸체 이미지의 경우 8192 * 3000의 크기로 저장하였다. 시트면 이미지는 2592 * 1944 크기로 저장하였다. 이와 같이 비전을 기반으로 수집된 데이터는 빛에 영향이 크기 때문에 주변 환경조건에 강건화 된 데이터를 수집하기 위하여 그림 22와 같이 주변환경을 암실로 구성하고, 촬영 전 바람을 통해 먼지와 같은 이물질을 제거하는 공정을 추가하였다. 마지막으로 제품을 360도 회전시켜가며 2D Gray Scale 데이터를 수집하였다.

조선대학교
CHOSUN UNIVERSITY

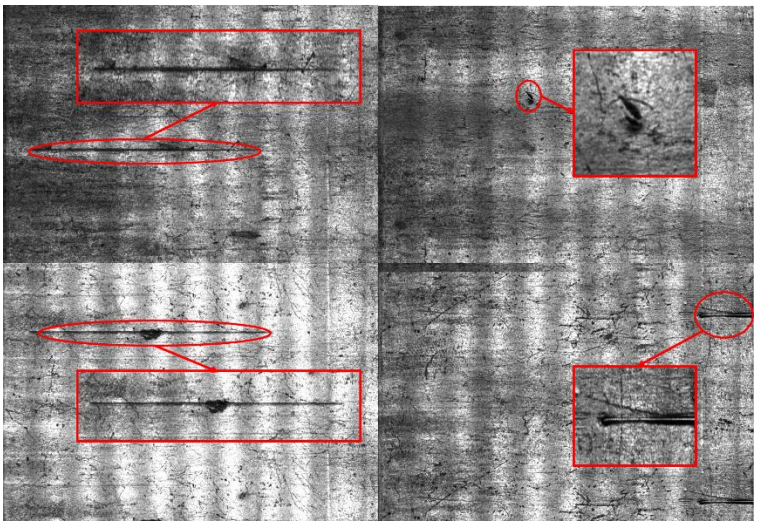

그림 23. 몸체 데이터의 결함 특징

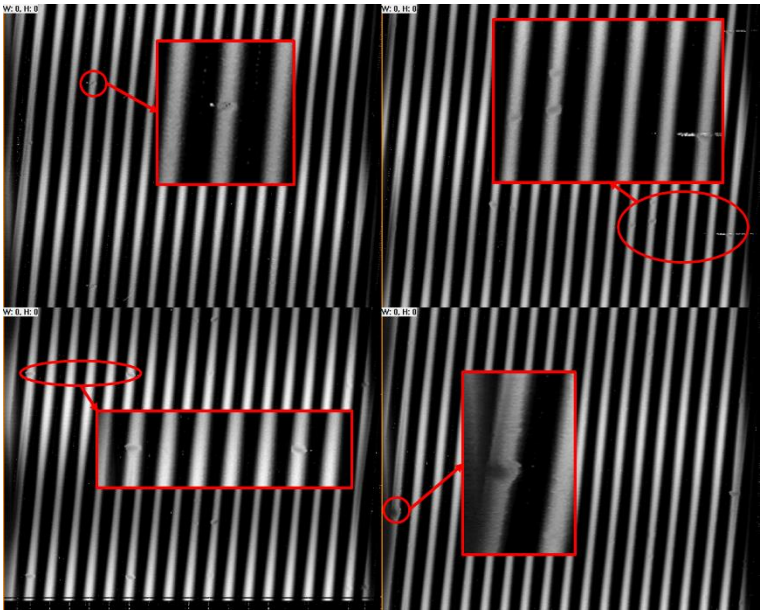

그림 24. 나사선 데이터의 결함 특징

조선대학교
CHOSUN UNIVERSITY

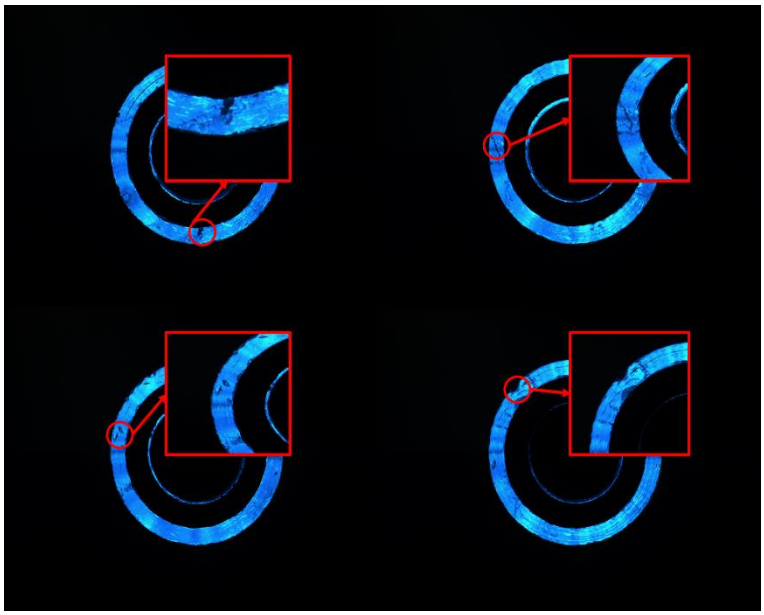

그림 25. 시트면 데이터의 결함 특징

자동차 글로우 플러그에서 발견되는 결함은 위 그림 23, 24, 25와 같이 대부분 단조, 균열, 찍힘 3가지 형태로 구분된다. 제품 생산 공정에서 주로 옮겨지는 작업 중 제품간 충돌로 인하여 위와 같은 결함이 생성된다. 하지만, 결함을 구별하기 위한 모델 개발 시 수집된 데이터에 포함된 노이즈로 인하여 학습에 문제가 발생한다. 이는 비전을 기반으로 수집하다 보니 조명과 같은 주변 환경에 영향을 받아 데이터에 노이즈가 생성되는 것으로 판단하였다. 몸체 데이터에서는 제품의 표면에 크롬을 도금한 후 옮겨지는 과정에서 도금이 벗겨진 부분과 도금의 두께에 따라 일정하지 않은 빛의 반사로 인해 생성된 노이즈로 인하여 결함 구별이 쉽지 않다. 나사선의 경우 나사선 사이 간격이 좁아 나사선 사이에 먼지와 같은 이물질이 끼어 있거나, 나사선 안과 밖의 높이 차이에 의해 찍힘 결함의 형태가 뚜렷하게 구분되지 않고, 시트면 이미지의 경우에도 몸체와 마찬가지로 도금이 벗겨진 부위로 인해 수집된 데이터에 노이즈가 많이 포함되어있다.

하여, 본 연구에서는 데이터에서 학습에 필요한 정보가 아닌 노이즈를 제거하고

조선대학교
CHOSUN UNIVERSITY

결함의 특징을 강화하기 위하여 이미지 전처리 기법인 히스토그램 평활화[19], Canny Edge와 Binarization, Sharpen 기법들을 적용한다. 히스토그램은 이미지의 픽셀들에 대한 명암값의 분포를 나타낸 것으로 가로축은 명암값, 세로축은 이미지에서 해당 명암값이 사용된 빈도수를 의미한다. 히스토그램 값이 좁은 영역에 분포하는 이미지의 경우 명암의 대비가 낮아 선명하지 않고, 넓은 영역에 고루 퍼져 있을 경우 명암의 대비가 높아 이미지가 선명하다. 수집된 데이터는 주변 환경과 도금의 두께 차이로 인한 밝기 차이에 의해 그림 26의 상단 이미지와 같이 분포가 일정하지 않게 수집되었다. 이 문제를 해결하기 위해 명암 값 분포의 기준 이미지를 결정하고 다른 이미지들을 매칭시켜 이미지의 명암값 분포를 재분배하였다. 그림 26의 하단 이미지와 같이 히스토그램이 일치되도록 조정되어 일관된 데이터로 정제하였다.

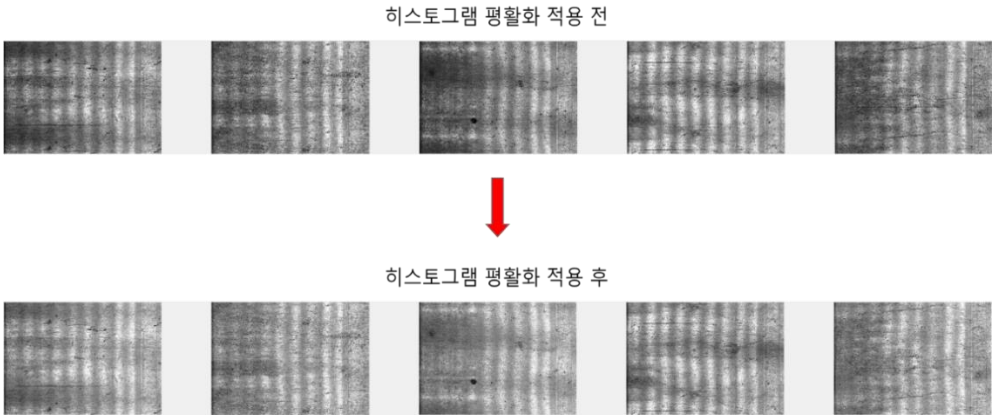

그림 26. 히스토그램 평활화 적용 결과

1차 정제된 데이터에서 노이즈를 제거하고, 결함 특징을 강화하기 위해 Canny Edge와 Binarization을 적용하였다. 자동차 글로우 플러그에서 수집된 데이터에는 결함과 형태가 비슷한 노이즈가 많이 포함되어있고, 결함의 특징이 Edge로 잘 표현되어 있기 때문에 노이즈를 제거하고 Edge를 강조해주는 Canny Edge를 적용하였다. Canny Edge는 1986년 John F Canny가 개발한 기법으로서 Edge를 찾는데 탁월한 성능을 보인

조선대학교
CHOSUN UNIVERSITY

다. Canny Edge는 다음과 같은 단계로 Edge를 찾아낸다. Edge를 검출 시 노이즈에 영향을 많이 받기 때문에 Gaussian Blur를 적용하여 이미지의 섬세한 부분을 단순화 하여 노이즈를 제거한다.

$$B = \frac{1}{159} \cdot \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix}$$

그림 27. Gaussian Blur Filter

노이즈가 제거된 이미지에서 그림 28과 같은 3*3 크기의 소벨 필터를 적용하여 이미지가 급격하게 변화하는 Edge에 대한 그래디언트 크기 및 방향 다음과 같은 식으로 계산한다.

$x\ Filter$

-1	0	+1
-2	0	+2
-1	0	+1

$y\ Filter$

+1	+2	+1
0	0	0
-1	-2	-1

그림 28. Sobel Filter

$$\text{Edge} - \text{Gradient(G)} = \sqrt{G_x^2 G_y^2}$$

$$Angle\ \ (\theta) = tan^{-1}(\frac{G_y}{G_x})$$

조선대학교
CHOSUN UNIVERSITY

이미지 전체를 탐색하여 Edge를 표현하기 위해 사용되지 않은 픽셀을 제거하기 위해 Edge에 수직한 방향으로 존재하는 그래디언트 값들을 비교하여 가장 큰 값을 제외한 나머지 값을 0으로 만든다. 마지막으로 앞 단계에서 구해진 Edge들이 실제 Edge인지 거짓 Edge인지 판별하여 확실한 Edge를 탐지한다.

Canny Edge를 적용하였어도 이미지에 남아있는 노이즈를 제거하기 위해 결정한 임계값을 기준으로 밝은 값은 모두 흰색으로 그렇지 않은 부분은 검은색으로 바꾸는 Binarization을 적용하여 전처리 하였다. 하지만 데이터의 결함이 뚜렷하지 않은 데이터의 경우 Edge를 찾는 것 보다 결함이 확연하게 두드러지게 보일 수 있도록 필터를 적용하였다. 최종 학습에 사용된 데이터는 그림 29와 같은 형태로 원본 이미지, Binarization 한 이미지, Binarization 적용 후 Canny Edge 전처리 한 이미지를 Concatenate 한 데이터 또는 원본 이미지와 명암조절을 통해 밝기 대비를 키운 이미지, Sharpen 기법을 이용하여 선명도를 높인 이미지를 Concatenate 한 데이터이다.

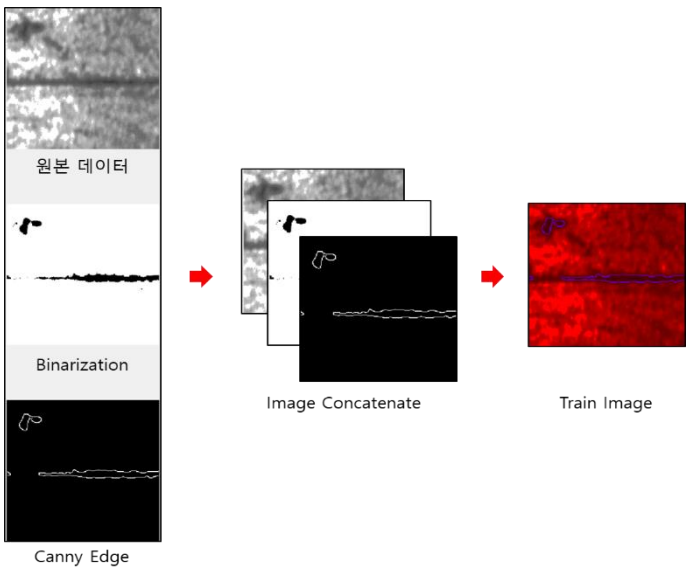

그림 29. 최종 전처리 몸체 데이터

조선대학교
CHOSUN UNIVERSITY

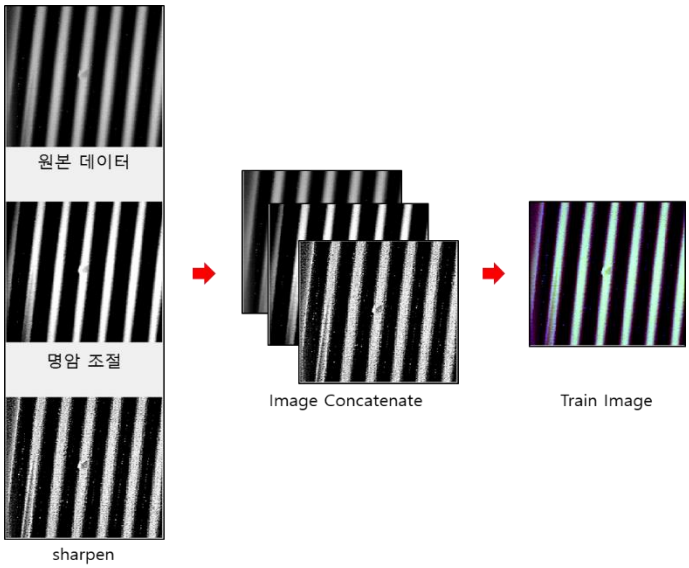

그림 30. 최종 전처리 나사선 데이터

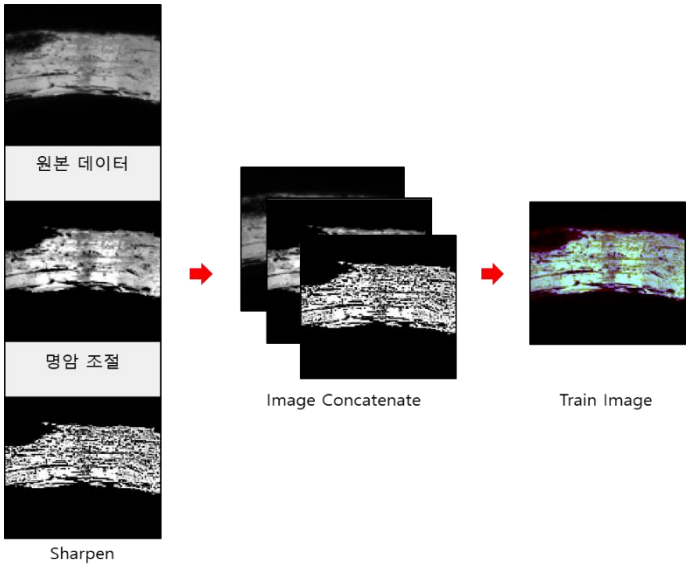

그림 31. 최종 전처리 시트면 데이터

조선대학교
CHOSUN UNIVERSITY

3.2 이미지 데이터를 이용한 전이학습

본 절에서는 전처리한 이미지 데이터를 이용하여 Vggnet, Googlenet, Resnet 모델에 전이학습하고, 데이터의 복잡도와 학습 모델에 따라 전이학습을 위한 적절한 학습 데이터의 양을 결정하는 방법에 대해 기술한다.

3.2.1 최적의 모델 학습을 위한 실험 계획

2가지 가정을 기반으로 실험을 진행하였다. 첫 번째 가정으로 결함 이미지가 아닌 특성이 다른(사람, 사물, 동물 등) 이미지 데이터로 학습된 모델의 가중치를 바탕으로 새로운 결함 데이터를 전이학습 하여도 기존의 학습된 가중치들에 의해서 적은 학습데이터로도 높은 성능의 모델이 학습될 것이라는 가정이다. 두 번째 가정으로 결함 데이터 중 데이터의 복잡도에 따라 학습에 필요한 데이터가 많이 필요할 것이라는 가정이다. 즉, 사람이 한 명이 있는 이미지와 사람이 여러 명이 있는 이미지를 비교할 시 많은 사람이 존재하는 데이터일수록 여러 특징 정보들로 이미지가 표현된다. 때문에 이미지 안에 내포되어 있는 특징 정보들이 많을수록 데이터가 복잡하여 충분한 학습데이터가 필요할 것이라 생각하였다.

본 연구에서는 학습된 가중치를 초기 가중치로 하여 제품 결함을 탐지하기 위한 CNN모델을 학습하였다. 이때 학습에 사용된 데이터는 특징 정보를 강화한 이미지 데이터이고, 결함 데이터의 복잡도가 낮은 순서대로 학습 데이터의 수를 100, 200, 500, 1000개로 늘려가며 학습 데이터와 테스트 데이터를 8대 2의 비율로 나누어 모델의 성능을 평가하였다. 마지막으로 10개의 원본 데이터를 모델에 사용되는 입력 크기로 분할하여 정확도, 민감도, 특이도, F1-Score 값을 기준으로 모델의 성능을 검증하였다. 또한 학습된 모델의 특징맵을 시각화하여 모델의 학습 성능과 같이 비교 분석하였다.

조선대학교
CHOSUN UNIVERSITY

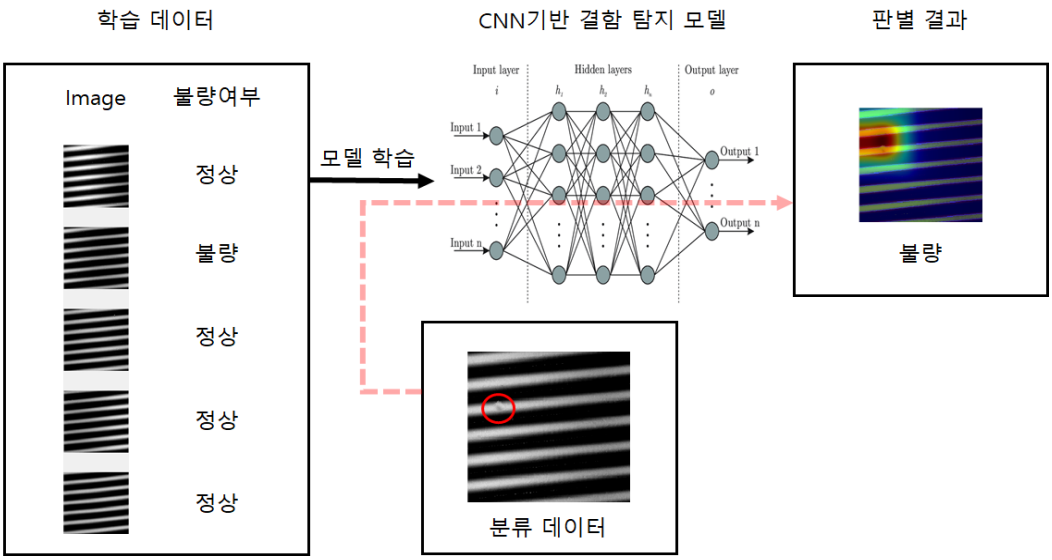

그림 32. CNN 모델을 이용한 결함 판별 모델 개념도 예시

표 6. 전이학습을 위한 데이터 분할

	학습/테스트/검증 데이터 수			
나사선	80/20/10	160/40/10	400/100/10	800/200/10
몸체				
시트면				

3.2.2 성능 평가 및 결과 시각화 방안

검증용 이미지 데이터에서 정상과 비정상을 얼마나 잘 구분하는지를 확인하기 위해 정확도(Accuracy)와 민감도(Sensitivity/Recall), 특이도(Specificity), F1-Score 값을 기준으로 모델의 성능을 평가하였다. 정상데이터와 결함데이터의 비율을 1:1로

조선대학교
CHOSUN UNIVERSITY

구성하였기 때문에 정확도를 우선평가 기준으로 선정하여 테스트 데이터를 평가하였고, 비율에 영향을 받는 민감도와 특이도, F1-Score 값은 비율이 맞지 않은 검증용 데이터를 평가 시 추가적으로 계산하여 모델의 성능을 비교하였다. 평가 기준들은 표 7과 같은 형태의 결과를 토대로 아래 식에 의해 계산된다.

표 7. 분류 결과 Confusion Matrix

		Predicted	
		Positive	Negative
Observed	Positive	True Positive	False Negative
	Negative	False Positive	True Negative

$$\text{정확도} = \frac{TP+TN}{TP+FP+FN+TN} \times 100, \quad \text{민감도} = \frac{TP}{TP+FN} \times 100$$

$$\text{특이도} = \frac{TN}{FP+TN} \times 100, \quad \text{F1-Score} = 2 \times \frac{\text{민감도} \times \text{특이도}}{\text{민감도} + \text{특이도}}$$

민감도는 실제 결함 데이터 중 모델의 판별 결과 결함이었는데 실제 결함일 확률이고, 특이도는 실제 정상 데이터 중 모델이 정상이라 판별한 결과 중 실제 정상일 확률이다[20]. F1-Score는 민감도와 특이도의 조화 평균을 통해 계산된다[21]. 불균형 데이터에서 민감도와 특이도 중 한곳에 결과가 높게 나올 경우 잘못 판단할 수 있다. 하여 각 지표에 가중치를 두어 정확한 결과를 평가하기 위해 F1-Score를 사용한다.

제조 산업에서 발생하는 결함은 큰 손실 비용을 초래함으로 민감도 높은 모델을 사용하여 과검출 되더라도 결함을 컨트롤할 필요가 있다. 때문에 학습 모델은 정확도를 최대로 하며 민감도 높은 모델이 학습되도록 축차적인 반복 실험을 진행한다.

조선대학교
CHOSUN UNIVERSITY

마지막으로 모델이 판단한 결과에 대해 근거를 확인하고, 모델을 사용하는 사용자들에게 보다 쉽게 이해 시키기 위해서 Grad CAM[22] 기법을 활용하였다. Grad CAM 기법은 CNN을 시각화하는 방법 중 하나로 Convolutional Layer 이후 Global Average Pooling을 통해 Class Activation Mapping을 하여 어떤 부분이 Class 예측에 큰 영향을 주었는지를 확인하기 위한 방법인 Class Activation Map을 개선시킨 방법이다. 기존의 CAM은 마지막 Convolutional Layer의 뒤에 Global Average Pooling을 하여야 CNN의 구조를 변경해야 확인이 가능하였다. 이를 해결하기 위해 그래디언트로 가중치를 계산하여 특징 정보를 시각화 하였다. 시각화 하려는 Feature Map과 Fully Connected Layer 사이의 편미분 값을 통해 구해진 기울기를 각 채널 별로 평균한다. 이 값을 시각화 하고자 하는 Feature Map에 곱하고 채널방향으로 평균하여 구한 값을 원본 이미지와 동일한 크기로 바꾼다. 그 결과를 계산된 값을 이미지에 Mapping 하여 결함 판별 시 사용된 주요 특징들을 시각적으로 확인하고 잘못 판별한 결과에 대해 이유를 설명 할 수 있다.

조선대학교
CHOSUN UNIVERSITY

제 4 장 구현 및 평가

본 장에서는 연구에서 제안하는 방법론을 기반으로 결함 검출 시스템 구성 및 성능 평가 시스템의 세부적인 구현 환경에 대해 서술한다. 그리고 제안한 방법론의 실효성을 평가하기 위해 비슷한 형태의 결함 데이터를 활용하여 본 연구에서 제안하는 방법론으로 모델을 학습하고 그 결과를 분석하여 모델의 성능을 평가한다. 이를 통해 본 연구의 유용성을 검증하고자 한다.

4.1 딥러닝 기반 결함 검출 시스템 구현

4.1.1 실험 환경 및 시스템 구성

본 연구에서 제안하는 방법을 구현하고 성능을 평가하기 위한 소프트웨어 실험 환경은 Window 10 기반의 MATLAB 2020에서 수행되었다. 실험에 사용된 하드웨어 구성은 인텔 제온 E5-2620 V4, 메모리는 32GB, GPU는 NVIDEA에서 개발된 11GB 그래픽 메모리 용량의 GTX 2080Ti 1개로 이루어져 있다. 학습 데이터 생성 및 전처리, 전이학습을 위한 모듈이 개발되었으며, 시각화 등을 통해 성능 평가를 수행하였다.

표 8. PC 실험 환경

실험 환경	
CPU	Intel Xeon E5-2620 V4 2.1Ghz
RAM	32Gb
GPU	GTX 2080Ti(11G Memory)

조선대학교
CHOSUN UNIVERSITY

공정에서 사용되는 표면 결함 검사 시스템 구성도는 그림 33과 같다. 실제 구축된 설비는 생산된 제품들의 표면을 검사할 수 있도록 비전을 기반으로 되어있다.

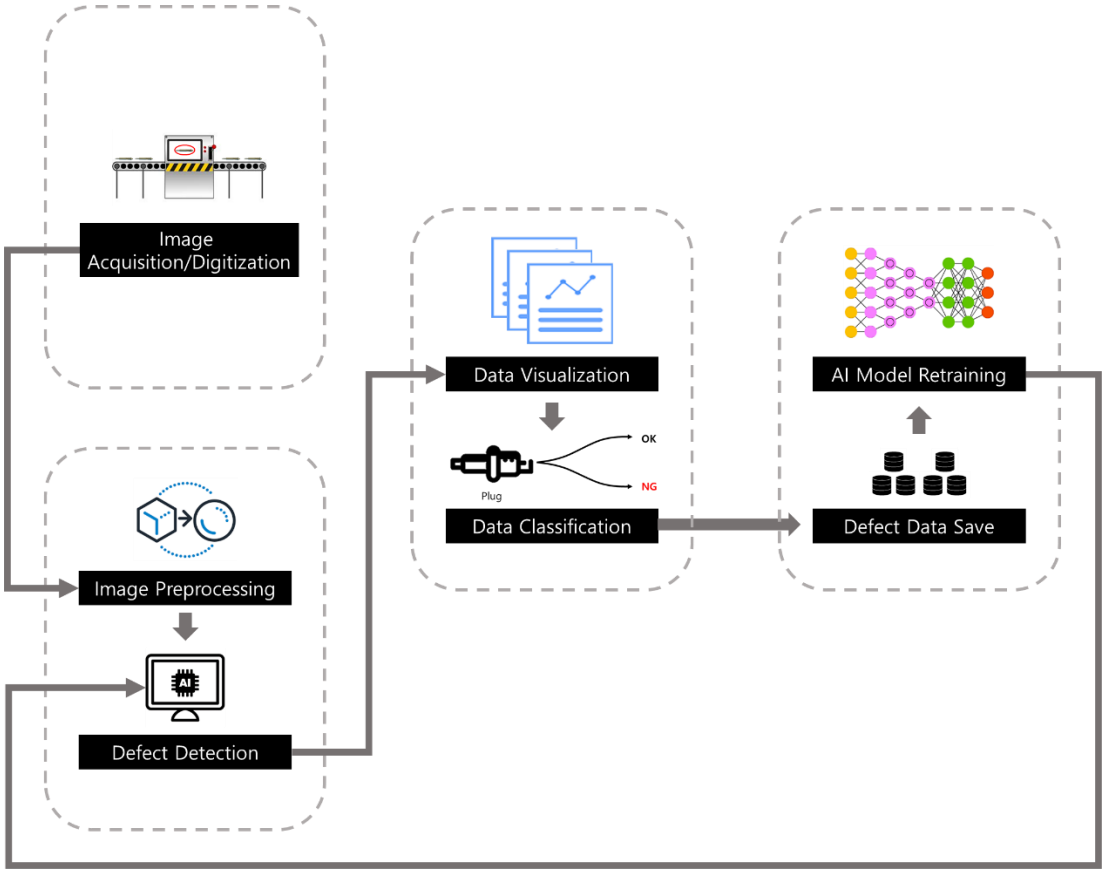

그림 33. 표면 결함 검사 시스템 구성도

표면 검사 설비는 제품의 표면을 이미지 데이터로 변환하여 저장한다. 저장된 이미지는 전처리 가공하는 과정을 진행한다. 전처리 한 데이터들은 학습된 CNN 모델을 통해 결함을 판별한다. 불량으로 판별된 데이터는 서버에 저장하고 감별원이 데이터를 확인한다. 추가된 결함 데이터를 바탕으로 모델을 업데이트 한다. 지속적인 모델 개선을 통해 최적의 표면 결함 검사 시스템을 구축한다.

조선대학교
CHOSUN UNIVERSITY

4.1.2 결함 검출 CNN 모델 성능 비교 결과

데이터의 복잡도에 따라 결함데이터의 전이학습 모델 성능을 비교하기 위해 학습 데이터의 양을 늘려가며 축차적으로 학습하였다. 학습 시 옵션으로 목적함수 F의 최소값을 찾는 알고리즘은 Adam Optimizer(Adaptive Moment estimation)를 사용하였고, 최대 반복횟수를 30 Epoch, 학습률을 0.001로 설정하여 학습하였다. 또한, 결함의 위치와 크기에 강건한 모델을 개발하기 위해 일부분의 데이터를 옮기거나 크기를 키우는 증식기법을 학습 데이터에 적용하였다.

특징 정보를 강화한 학습 데이터를 기반으로 각 모델 별 테스트 데이터에 대한 판별 정확도는 표 9와 같다.

표 9. 결함 판별 모델 정확도 변화

(R: Resnet, G: Googlenet, V: Vggnet)

구분	학습모델	학습 데이터 개수 / 테스트 데이터 개수			
		80/20	160/40	400/100	800/200
나사선	R	87.5	89	90.5	94
	G	96	91	97	92
	V	50	53	48.5	95.5
몸체	R	98.5	97.5	100	100
	G	100	99.5	100	100
	V	100	99	100	100
시트면	R	82	86.5	85	88
	G	79	84.5	84.5	91
	V	68	66.5	57.5	85.5

조선대학교
CHOSUN UNIVERSITY

전이학습 결과 데이터가 복잡한 형태이면서 적은 양의 데이터로 학습할수록 정확도가 낮고 학습 데이터에 최적화된 모델이 만들어지는 오버피팅(Overfitting) 현상이 발생하였다. 또한, 학습 데이터가 테스트 데이터의 특징을 찾지 못하여 Loss가 수렴하지 않는 경향을 보였다. 데이터의 복잡도가 상대적으로 높고, 데이터의 라벨링 단계에서부터 결함과 결함이 아닌 특징이 섞여 정확환 라벨링이 어려운 시트면 이미지의 경우 Loss가 쉽게 감소하지 않고 상대적으로 많은 학습 데이터를 필요로 하였으며, 학습 모델의 정확도가 나머지 데이터로 학습된 모델에 비해 낮게 나왔다. 하지만 동일한 패턴이 반복적으로 있는 나사선과 결함의 특징이 확연히 두드러지는 몸체의 경우 시트면 데이터에 비해 적은 데이터에서 빠르게 수렴되고 높은 정확도를 보였다.

각 모델 별 분석 결과는 다른 모델에 비해 Vggnet이 가장 얕은 Layer로 구성되어 있어 학습시간이 짧았고 그 다음으로 깊은 구조를 가진 Googlenet과 Resnet 순으로 많은 학습 시간이 소요되었다. Vggnet의 경우 다른 모델에 비해 구조가 단순하여 많은 양의 학습 데이터가 필요하였고, 학습 데이터에 오버피팅 되는 경향이 많이 발생하였다. Googlenet과 Resnet은 적은 데이터에서도 높은 성능을 보였으나 데이터의 복잡도에 따라 성능차이가 있음을 확인하였다. 결론적으로 모델 학습 시 결함과 정상을 구별하기 힘든 복잡한 형태의 데이터일수록 학습에 필요한 데이터의 양이 많아지고 학습모델의 수렴이 어려움을 확인하였다.

그림 34, 35, 36, 37에서 첫 번째 그래프는 Resnet, 두 번째 그래프는 Googlenet, 세 번째 그래프는 Vggnet의 학습 그래프이다.

조선대학교
CHOSUN UNIVERSITY

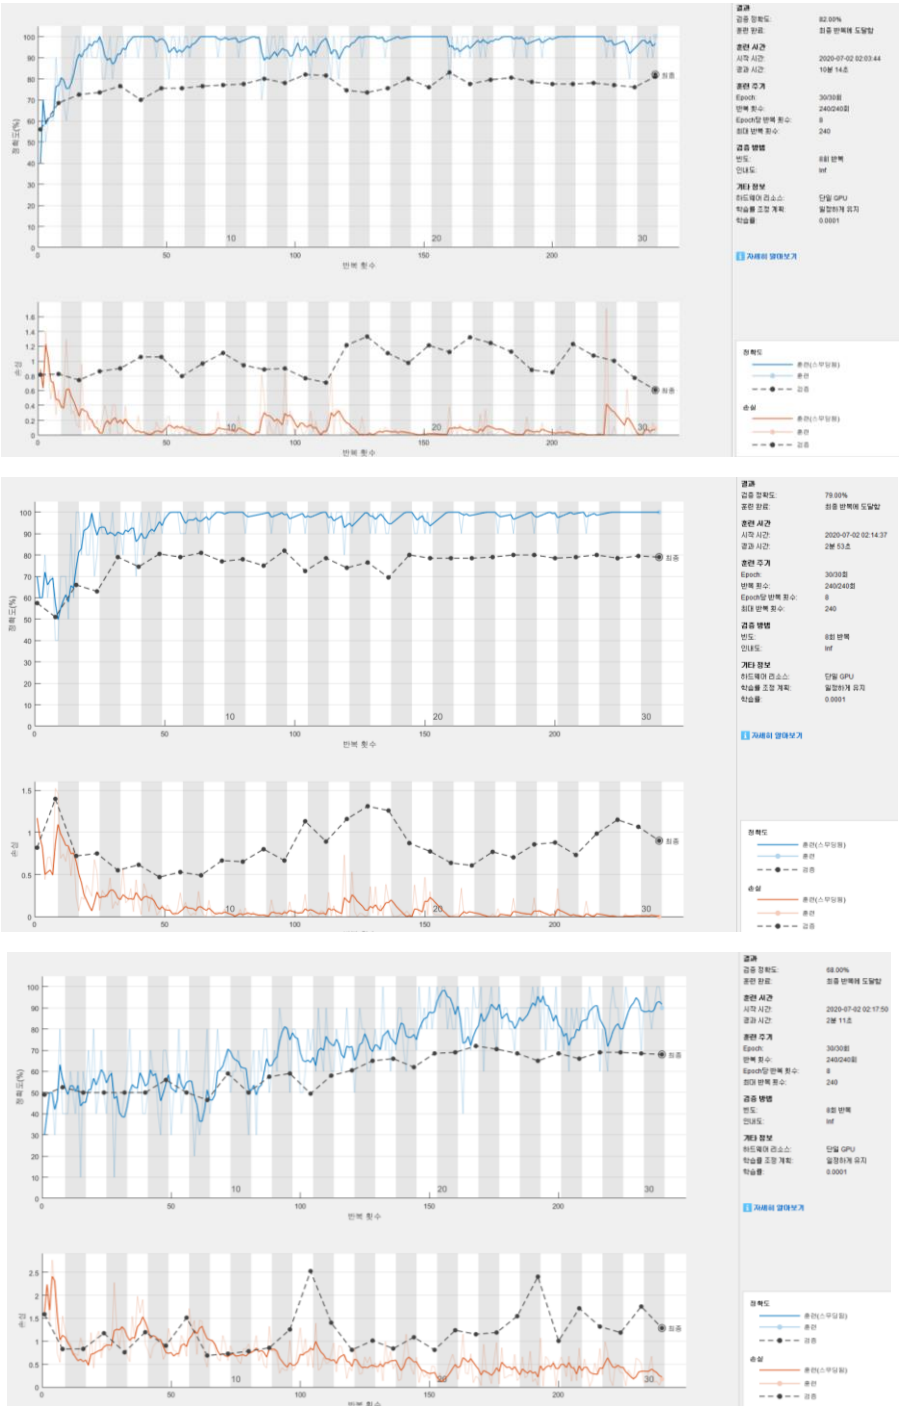

그림 34. 이미지 데이터 100개로 각 모델 학습 그래프

조선대학교
CHOSUN UNIVERSITY

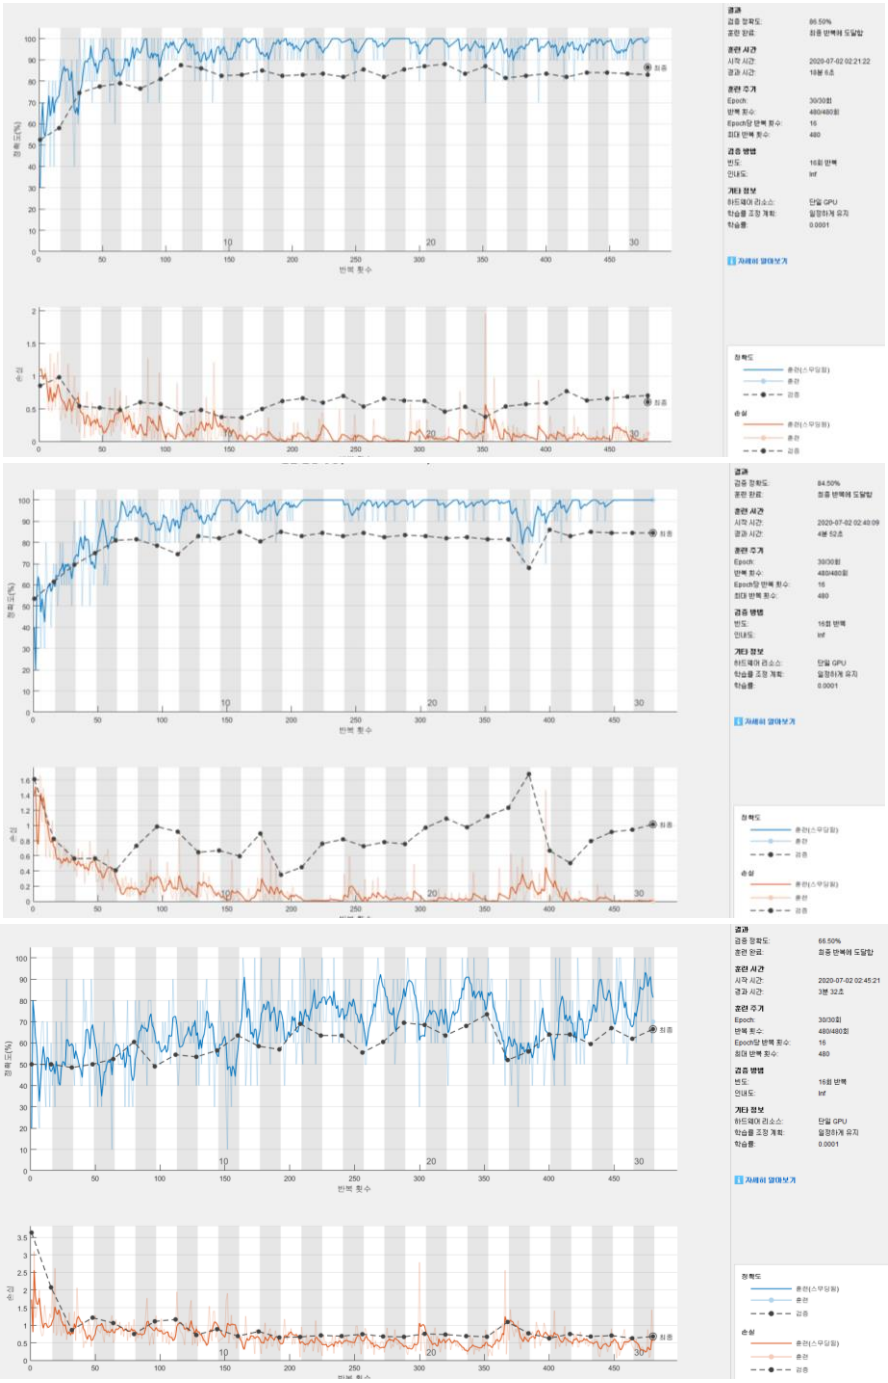

그림 35. 이미지 데이터 200개로 각 모델 학습 그래프

조선대학교
CHOSUN UNIVERSITY

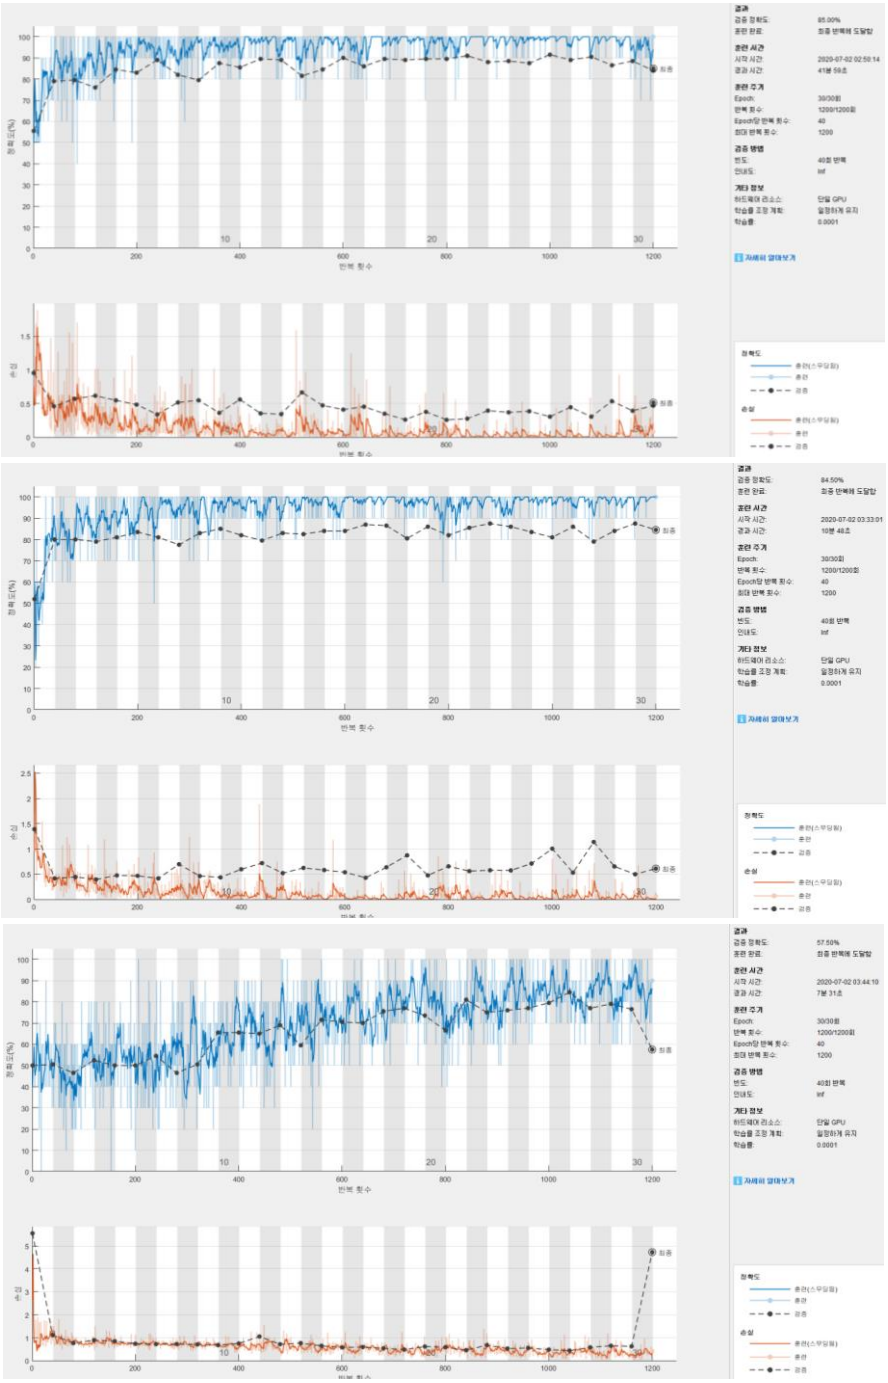

그림 36. 이미지 데이터 500개로 각 모델 학습 그래프

조선대학교
CHOSUN UNIVERSITY

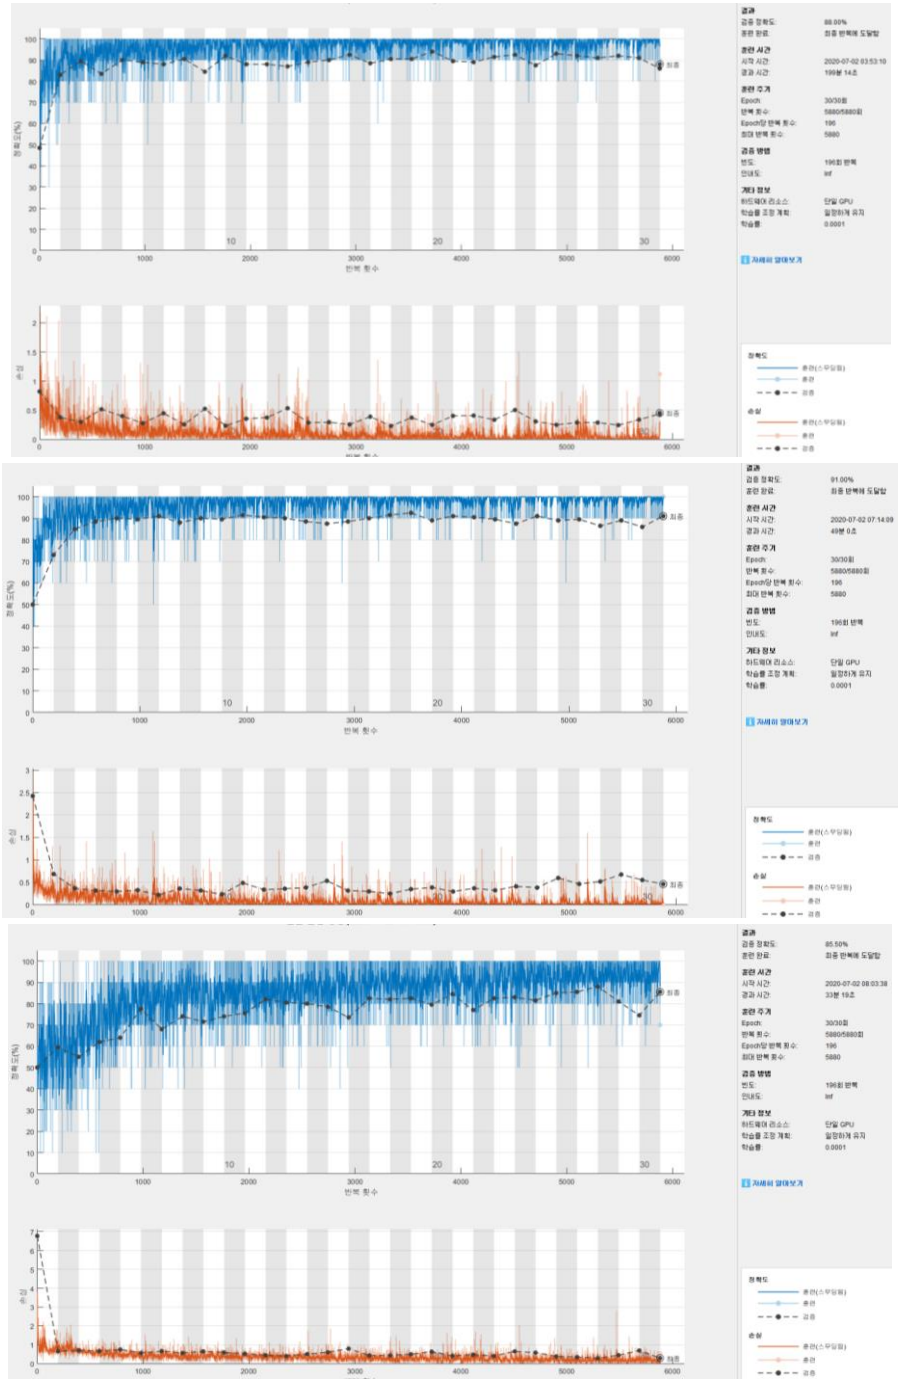

그림 37. 이미지 데이터 1000개로 각 모델 학습 그래프

조선대학교
CHOSUN UNIVERSITY

하지만 3개의 모델 모두 학습 데이터를 100개에서 1000개까지 점진적으로 늘려가며 학습한 결과 데이터가 증가함에 따라 모델의 판별 정확도가 개선됨을 확인하였다. 학습데이터가 증가함에 따라 모델의 학습시간이 최소 2분에서 최대 200분까지 늘어났으나 모델의 가중치 초기값을 처음부터 학습하는 방법에 비해 적은 시간과 데이터가 필요함을 확인하였다.

마지막으로 학습 데이터와 모델에 따라 검증데이터에 대한 판별된 결과는 표 10, 11, 12의 Confusion Matrix를 통해 확인할 수 있다. 검증데이터는 서로 다른 크기의 원본 데이터를 모델 학습에 사용되는 입력데이터의 크기(224 * 224)로 분할하였기 때문에 결함과 정상데이터의 비율이 맞지 않다. 때문에 정확한 모델의 성능 분석을 위하여 표 13과 같이 정확도, 민감도, 특이도, F1-Score 값을 계산하였다. 생성된 총 검증 데이터는 10개의 원본데이터를 분할하여 나사선 40개(정상29개, 결함11개), 몸체 1040개(정상984개, 결함56개), 시트면 80개(정상63개, 결함17개)이다.

표 10. 검증용 나사선 데이터 판별 결과

나사선 Resnet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	10	8
	Normal	1	21
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	11	1
	Normal	0	28
학습데이터 400		Predicted	
		Abnormal	Normal
Observed	Abnormal	9	1
	Normal	2	28
학습데이터 800		Predicted	
		Abnormal	Normal

조선대학교
CHOSUN UNIVERSITY

Observed	Abnormal	8	1
	Normal	3	28

나사선 Googlenet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	9	1
	Normal	2	28
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	10	1
	Normal	1	28
학습데이터 400		Predicted	
		Abnormal	Normal
Observed	Abnormal	10	1
	Normal	1	28
학습데이터 800		Predicted	
		Abnormal	Normal
Observed	Abnormal	10	1
	Normal	1	28

나사선 Vggnet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	11	29
	Normal	0	0
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	11	24
	Normal	0	5
		Predicted	

조선대학교
CHOSUN UNIVERSITY

학습데이터 400		Abnormal	Normal
Observed	Abnormal	6	14
	Normal	5	15
학습데이터 800		Predicted	
		Abnormal	Normal
Observed	Abnormal	10	1
	Normal	1	28

표 11. 검증용 몸체 데이터 판별 결과

몸체 Resnet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	31	25
	Normal	25	959
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	19	13
	Normal	37	971
학습데이터 400		Predicted	
		Abnormal	Normal
Observed	Abnormal	28	30
	Normal	28	954
학습데이터 800		Predicted	
		Abnormal	Normal
Observed	Abnormal	24	3
	Normal	32	954

몸체 Googlenet			
학습데이터 80		Predicted	
		Abnormal	Normal
	Abnormal	32	3

조선대학교
CHOSUN UNIVERSITY

Observed	**Normal**	24	981
학습데이터 160		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	13	2
	Normal	43	982
학습데이터 400		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	16	1
	Normal	40	983
학습데이터 800		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	16	1
	Normal	40	983

몸체 Vggnet			
학습데이터 80		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	1	0
	Normal	55	984
학습데이터 160		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	1	0
	Normal	55	984
학습데이터 400		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	1	0
	Normal	55	984
학습데이터 800		**Predicted**	
		Abnormal	**Normal**
Observed	**Abnormal**	12	0
	Normal	44	984

조선대학교
CHOSUN UNIVERSITY

표 12. 검증용 시트면 데이터 판별 결과

시트면 Resnet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	7	9
	Normal	10	54
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	8	5
	Normal	9	58
학습데이터 400		Predicted	
		Abnormal	Normal
Observed	Abnormal	9	12
	Normal	8	51
학습데이터 800		Predicted	
		Abnormal	Normal
Observed	Abnormal	4	4
	Normal	13	59

시트면 Googlenet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	9	11
	Normal	8	52
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	11	4
	Normal	6	59
학습데이터 400		Predicted	
		Abnormal	Normal
Observed	Abnormal	12	6
	Normal	5	57

조선대학교
CHOSUN UNIVERSITY

학습데이터 800		Predicted	
		Abnormal	Normal
Observed	Abnormal	8	5
	Normal	9	58

시트면 Vggnet			
학습데이터 80		Predicted	
		Abnormal	Normal
Observed	Abnormal	6	15
	Normal	11	48
학습데이터 160		Predicted	
		Abnormal	Normal
Observed	Abnormal	4	5
	Normal	13	58
학습데이터 400		Predicted	
		Abnormal	Normal
Observed	Abnormal	0	3
	Normal	17	60
학습데이터 800		Predicted	
		Abnormal	Normal
Observed	Abnormal	11	15
	Normal	6	48

조선대학교
CHOSUN UNIVERSITY

표 13. 검증 데이터에 대한 결함 판별 결과 정리

(AC: Accuracy, SE: Sensitivity, SP: Specificity, F1: F1-Score)

		학습 데이터 / 검증 데이터(나사선, 몸체, 시트면)															
데이터	모델	80 /(40,1040, 80)				160 /(40,1040,80)				400 /(40,1040,80)				800 /(40,1040,80)			
		AC	SE	SP	F1	AC	SE	SP	F1	AC	SE	SP	F1	AC	SE	SP	F1
나사선	R	77	55	95	70	97	91	100	95	92	90	93	91	90	88	90	89
	G	92	90	93	91	95	90	96	93	95	90	96	93	95	90	96	93
	V	27	27	0	0	40	31	100	47	52	30	75	42	95	90	96	93
몸체	R	95	55	97	70	95	59	96	73	94	48	97	64	96	88	96	92
	G	97	91	97	94	95	86	95	91	96	94	96	95	96	94	96	95
	V	94	100	94	97	94	100	94	97	94	100	94	97	95	100	95	97
시트면	R	76	43	84	57	82	61	86	71	75	42	86	57	78	50	81	62
	G	76	45	86	59	87	73	90	81	86	66	91	77	82	61	86	71
	V	67	28	81	42	77	44	81	57	75	0	77	0	73	42	88	57

표 13의 판별 결과와 같이 Resnet 모델을 전이학습한 결과 제일 복잡하다고 평가된 시트면 데이터의 경우 1000개의 데이터를 모두 학습하였음에도 불구하고 다른 데이터에 비해 약 70%에 가까운 낮은 정확도와 민감도, F1-Score이었고, 두 데이터의 중간의 복잡도를 가지는 나사선은 200개의 데이터를 학습하였을 때 97%의 정확도와 91%

조선대학교
CHOSUN UNIVERSITY

의 민감도, 100%의 특이도, F1-Score는 95%이었다. 가장 낮은 복잡도를 가지는 몸체는 100개의 데이터를 학습하였을 때 95%의 정확도에 도달하였으나, 민감도가 55%로 결함을 결함으로 정확하게 분류해 내지 못하여 F1-Score 값이 70%이었다. 그 이유는 학습데이터의 테스트 정확도는 95%나 되었으나 검증 데이터의 결함 데이터에 대한 판별 정확도가 낮은 것으로 보아 모델이 복잡하여 학습데이터에 오버피팅 된 것으로 판단된다.

Googlenet 모델을 전이학습한 결과는 Resnet과 동일한 경향을 보였다. 몸체와 나사선 모두 100개의 데이터에서 높은 성능을 보였고, 가장 낮은 복잡도를 가지는 몸체의 경우 나사선 보다 동일한 학습데이터를 학습하였으나 더 높은 정확도를 보였다. 하지만 시트면은 Resnet과 마찬가지로 90% 이상의 정확도를 보이는 모델이 학습되지 않았으나 Resnet 보다는 학습이 잘되는 것을 확인하였다.

Vggnet 모델을 전이학습한 결과 복잡도가 낮은 몸체는 100개 데이터로 학습하여도 95%에 이르는 판별 정확도를 보였으나, 나사선의 경우 1000개의 학습데이터를 사용한 모델이 95%의 정확도와 93%의 F1-Score 값을 보였다. 시트면의 경우 1000개의 데이터를 학습하였음에도 불구하고 모델이 수렴하지 않았다. 이와 같은 결과를 보면 단순한 형태의 특징을 가지고 있는 경우 Vggnet이 적은 데이터로 높은 성능을 보이나, 복잡한 형태의 특징을 가지는 경우에는 모델이 학습되지 않음을 알 수 있었다.

마지막으로 학습 결과를 시각화 하기 위해 앞서 설명한 Grad CAM 기법을 적용하였다. 그림 38은 1000개의 학습 데이터로 학습된 모델을 바탕으로 결함 데이터에 대해 Grad CAM 결과를 시각화한 것이다. 그림 26에서 상단의 4개 데이터는 원본 이미지이고 하단의 4개 데이터는 Grad CAM 결과를 중첩한 것으로 나사선, 몸체, 시트면 순으로 정리하였다. 모델의 정확도가 낮은 것에 대해 분류결과를 시각화하여 판별하지 못하는 결함 형태의 데이터를 학습데이터에 더 추가하였고, 이렇게 학습데이터가 충분해짐에 따라 결함부위의 특징이 정확히 학습됨을 시각화를 통해 확인할 수 있었다.

정리하면 본 연구에서는 데이터의 복잡도를 평가하고, 표 4와 같이 기준이 되는 복잡도와 비교하여 목표하는 모델의 성능에 도달하기 위해 필요한 적정 학습 데이터

조선대학교
CHOSUN UNIVERSITY

양을 결정할 수 있는 가능성을 확인하였다.

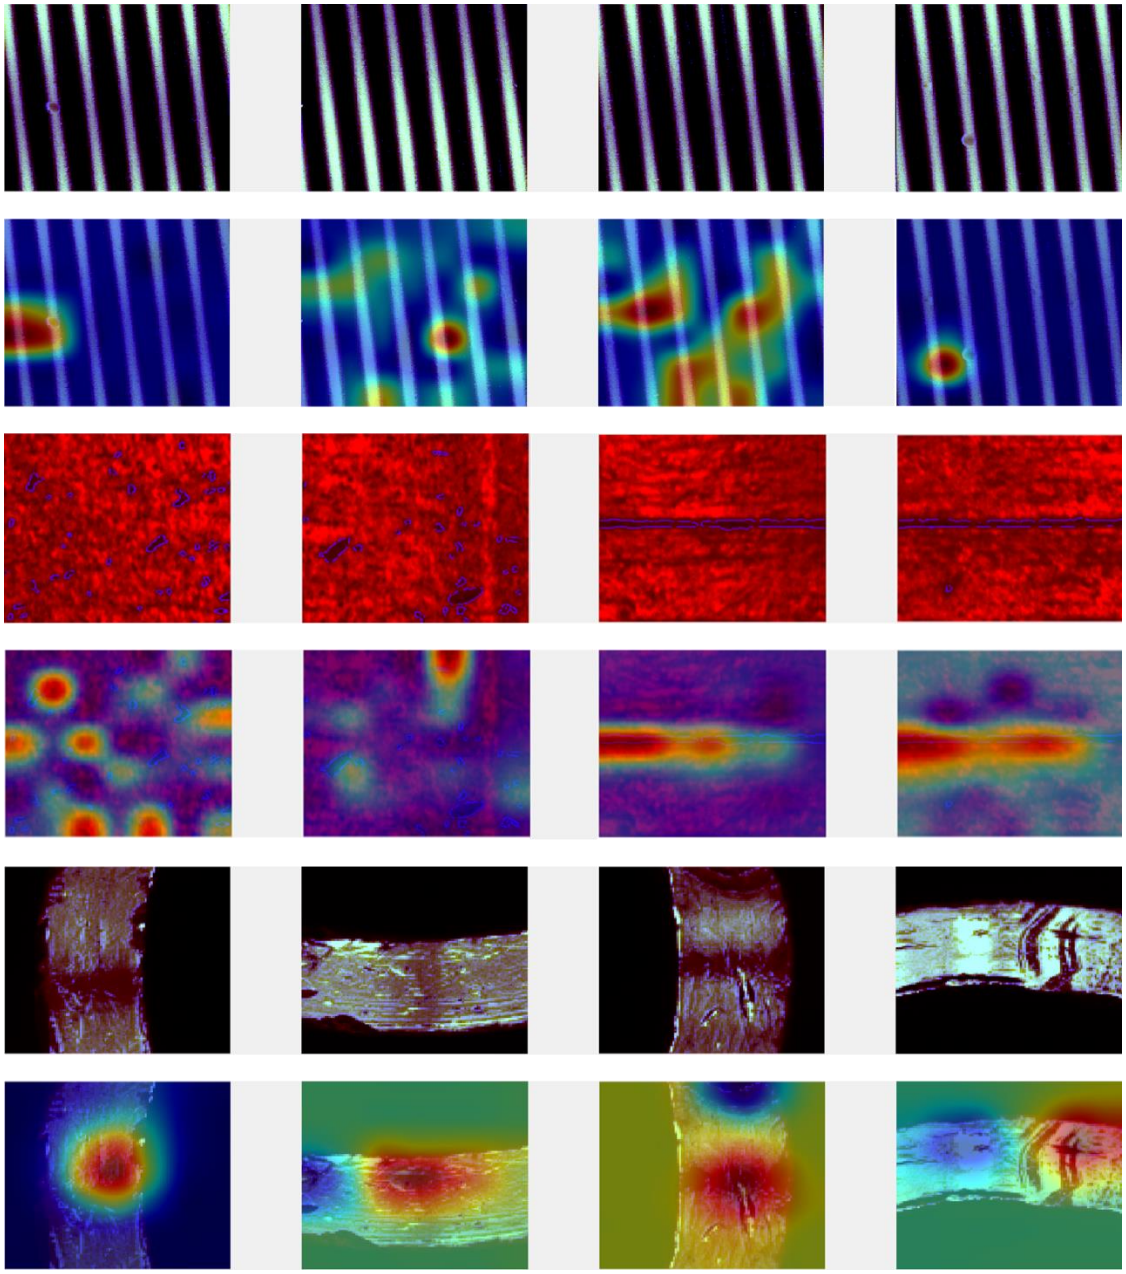

그림 38. Grad CAM 적용 결과

조선대학교
CHOSUN UNIVERSITY

4.1.3 방법론 유효성 검증

본 연구에서 제시한 방법론의 유효성을 검증하기 위해 마그네틱 표면의 결함 데이터와 산업 광학 검사를 위한 지도학습 모델 개발을 위해 제공되는 데이터셋[29]의 Class 2 데이터, 보일러 수벽 튜브의 결함 데이터를 이용하여 검증 실험을 진행하였다.

방법론 개발을 위해 사용된 몸체, 나사선, 시트면 데이터와 유효성 검증을 위해 사용된 데이터들의 복잡도 계산결과는 표 14와 같다. 마그네틱 데이터의 경우 L1 norm 8.5246, L2 norm 6.2586으로 몸체와 나사선 데이터의 사이의 값이었고, Class 2 데이터는 몸체보다 더 큰 L1 norm 14.5827, L2 norm 10.0332의 값을 보였다. 마지막으로 보일러 수벽의 경우 나사선 데이터에 근접한 L1 norm 8.1077, L2 norm 5.7254 값이었다.

표 14. 통계적 기법 기반 검증 데이터 복잡도 평가 결과

	Contrast	Correlation	Energy	Homogeneity	Entropy
몸체	0.2863	0.9245	0.1154	0.8591	7.5205
나사선	0.3316	0.9642	0.2533	0.8520	5.6541
시트면	0.0860	0.9878	0.5721	0.9745	4.1391
마그네틱	0.0541	0.9419	0.4632	0.9730	6.0925
Class 2	6.3676	0.0009	0.0255	0.4481	7.7406
보일러 수벽	0.0322	0.9265	0.6383	0.9840	5.5267

조선대학교
CHOSUN UNIVERSITY

표 15. L1 norm, L2 norm에 의해 결정된 학습데이터 양

	L1 norm	L2 norm	학습데이터
몸체	9.7059	7.6319	100
나사선	8.0553	5.8137	200
시트면	6.7595	4.4036	1000
마그네틱	8.5246	6.2586	700
Class 2	14.5827	10.0332	1000
보일러 수벽	8.1077	5.7254	200

본 연구에서 90% 이상의 성능인 모델을 만들기 위해 나사선의 경우 500개의 데이터가 필요하였고, 시트면의 경우 1000개 이상의 학습데이터가 필요하였다. 하여, L1 norm 값을 기준으로 학습데이터 양을 비율로서 계산한 결과 표 15와 같이 학습에 필요한 데이터 결정되었다.

마그네틱 데이터의 특징정보를 강화하기 위해 나사선과 시트면에 적용한 방법을 동일하게 적용하였고 그림 40과 같이 학습데이터를 생성하였다. Resnet, Googlenet, Vggnet 모델을 사용하여 전이학습하고 80개의 데이터를 평가하였다.

조선대학교
CHOSUN UNIVERSITY

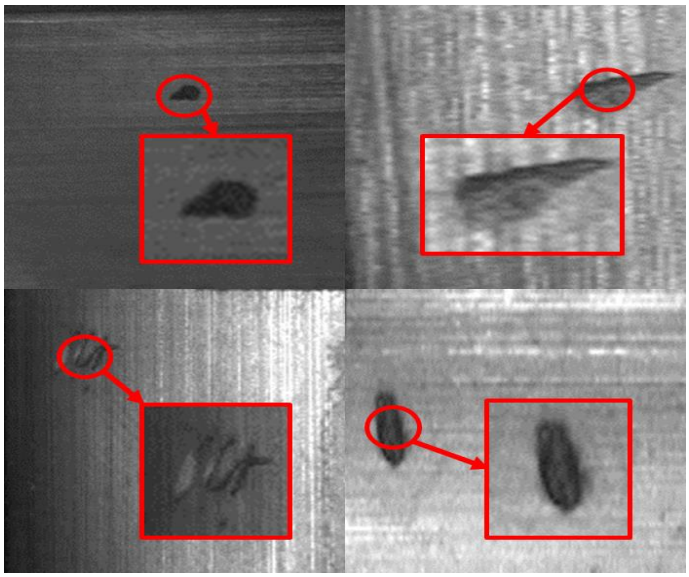

그림 39. 마그네틱 데이터 결함 특징

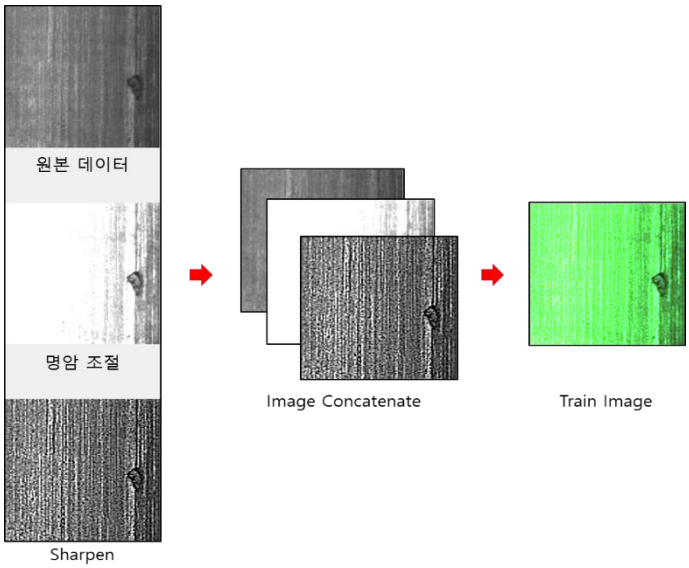

그림 40. 최종 전처리 마그네틱 데이터

조선대학교
CHOSUN UNIVERSITY

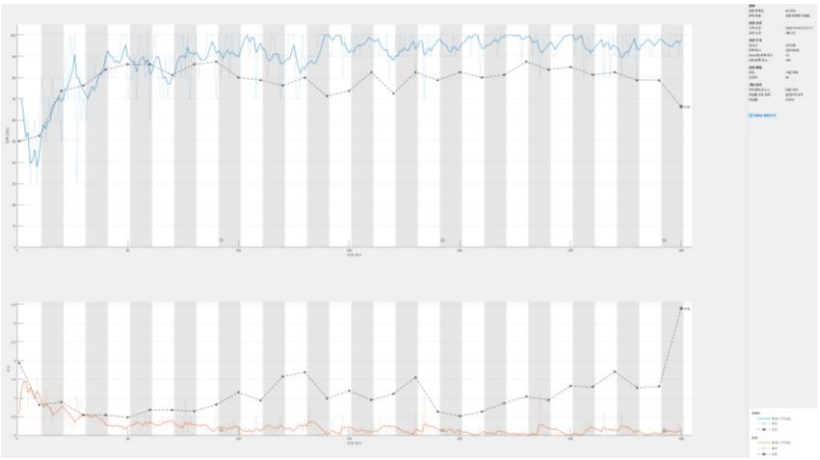

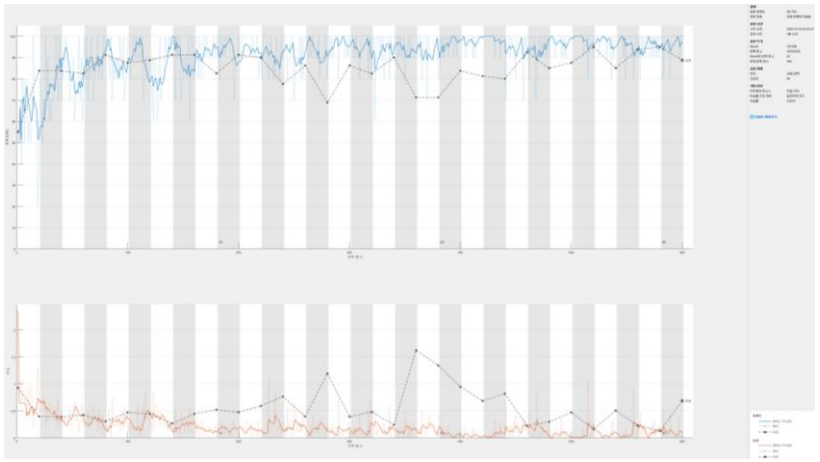

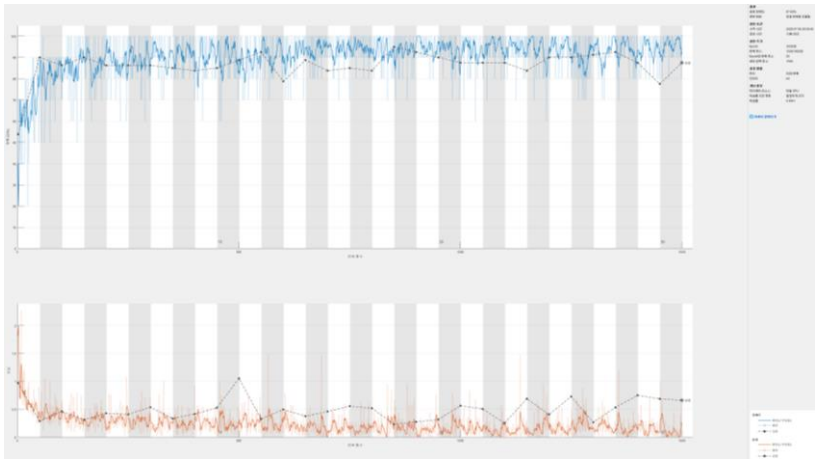

조선대학교
CHOSUN UNIVERSITY

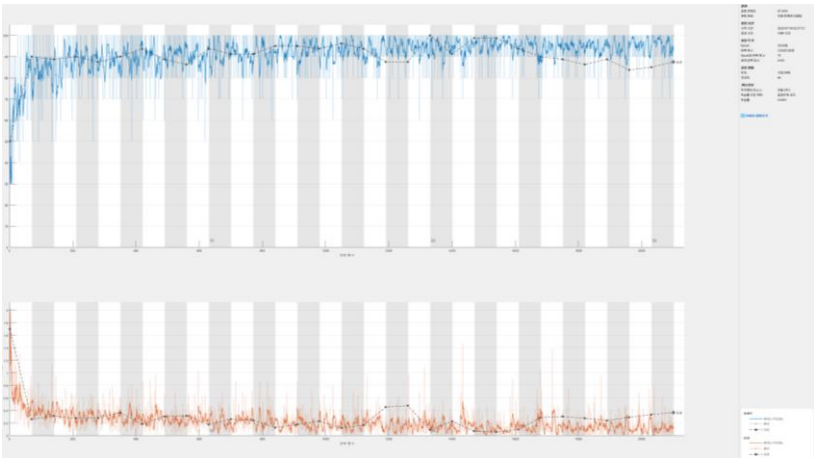

그림 41. 80/160/400/700개 마그네틱 데이터 학습 그래프

표 16. 마그네틱 데이터 학습 모델 정확도 변화

(R: Resnet, G: Googlenet, V: Vggnet)

		학습 데이터 / 검증 데이터			
데이터	학습모델	80/80	160/80	400/80	700/80
마그네틱	R	81.25	75	87.5	83.75
	G	66.25	88.75	87.5	87.5
	V	50	50	50	50

정상데이터와 비정상데이터가 1:1 비율로 구성된 검증 데이터의 판별 결과는 표 14와 같다. 90%에 근접하는 성능을 발휘할 수 있는 모델이 학습되었으나, 90%가 넘는 모델은 학습되지 않았다. 그 이유는 그림과 같이 마그네틱 데이터의 결함의 형태가 비교적 단순하나 학습 데이터를 생성하기 위해 사용된 원본 데이터가 너무 적어 모델 학습이 잘 이루어지지 않았다고 판단하였다.

조선대학교
CHOSUN UNIVERSITY

두 번째 검증데이터인 Class 2 또한 특징정보를 강화하기 위해 몸체 데이터에 적용한 방법을 동일하게 사용하였고 학습과 검증을 진행하였다.

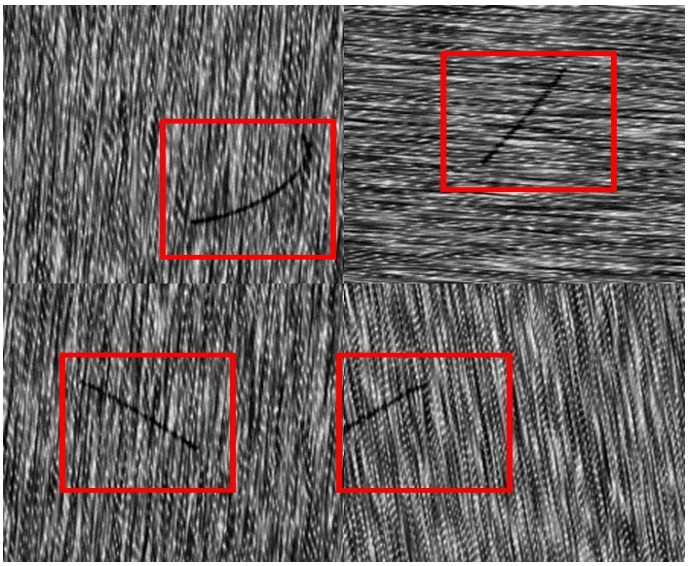

그림 42. Class 2 결함 데이터 특징

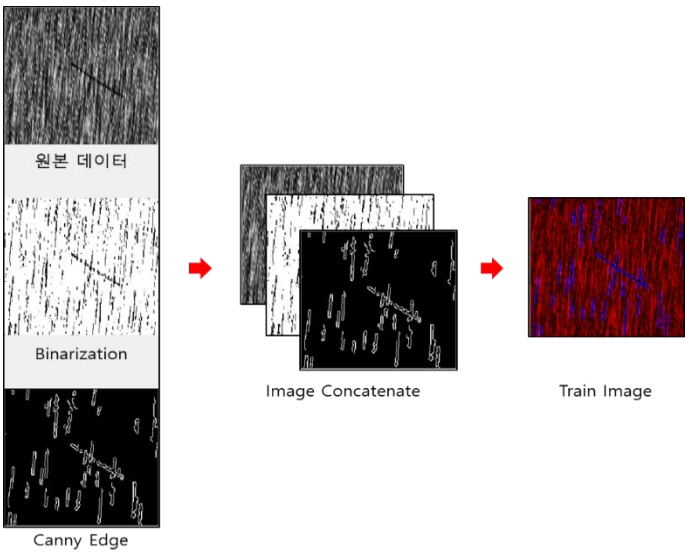

그림 43. 최종 전처리 Class 2 데이터

조선대학교
CHOSUN UNIVERSITY

표 17. 질감 표면 Class2 데이터 모델 정확도 변화

(R: Resnet, G: Googlenet, V: Vggnet)

		학습 데이터 / 검증 데이터			
데이터	학습모델	80/80	160/80	400/80	700/80
질감표면 Class 2	R	93.75	93.75	98.75	95.25
	G	97.5	98.75	98.75	100
	V	50	98.75	50	50

질감 표면의 Class 2 검증 데이터의 판별 결과는 표 17과 같다. 몸체 데이터와 비슷한 복잡도로 평가된 질감 표면 Class 2 데이터는 90% 이상의 모델이 학습되는데 100개이하의 학습 데이터가 필요함을 확인할 수 있었다.

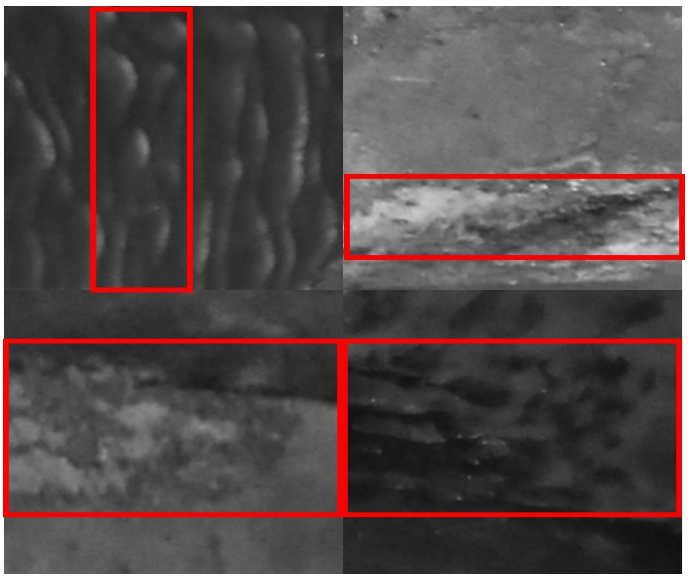

그림 44. 보일러 수벽 튜브 결함 데이터 특징

조선대학교
CHOSUN UNIVERSITY

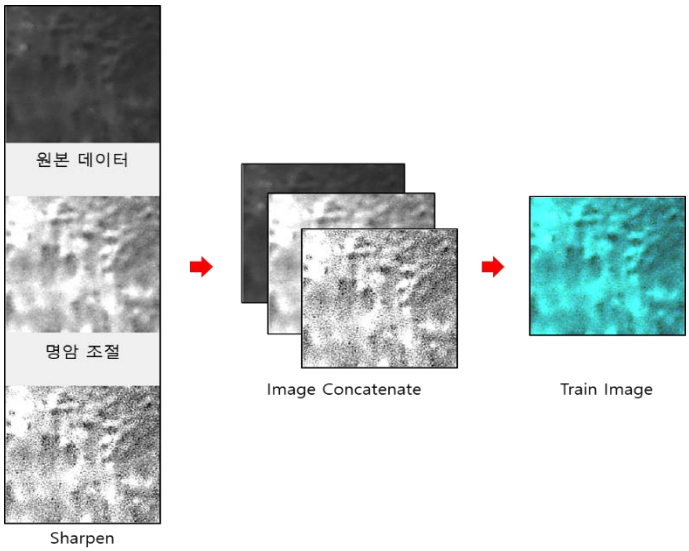

그림 45. 최종 전처리 보일러 수벽 데이터

표 18. 보일러 수벽 데이터 모델 정확도 변화

(R: Resnet, G: Googlenet, V: Vggnet)

		학습 데이터 / 검증 데이터			
데이터	학습모델	80/80	160/80	400/80	700/80
보일러 수벽	R	88.75	96.25	97.5	100
	G	93.75	96.25	98.75	98.75
	V	75	95	97.5	93.75

마지막으로 보일러 수벽의 튜브 결함을 판별하기 위한 모델의 학습 결과는 표 18과 같다. L1 norm과 L2 norm이 나사선 데이터와 유사한 값으로 계산되어 목표 성능의 모델을 학습하기 위한 학습데이터 양은 200개로 결정되었다. 결론적으로 200개의 학습데이터를 사용하여 모델을 학습하였을 때 95%이상의 성능을 보이는 모델이 학습되

조선대학교
CHOSUN UNIVERSITY

었다.

본 연구에서 제안하는 방법론을 토대로 데이터의 복잡도를 평가하고 기준에 따라 학습데이터 양을 결정하여, 이미지 전처리 기법을 통해 강화된 특징정보를 포함하는 학습 데이터를 사용한 전이학습 시 모델의 성능이 기대하는 것과 같이 나타남을 확인함으로써 방법론의 유효성을 입증하였다.

조선대학교
CHOSUN UNIVERSITY

제 5 장 결론 및 토의

본 논문은 자동차 글로우 플러그 생산 공장에서 수집된 비전기반의 제품 표면 결함 이미지 데이터를 기반으로 딥러닝 기반의 결함 검출 시스템을 구축하기 위한 데이터 처리 방법론을 제안하였다. 특히 본 논문에서 제안된 핵심 알고리즘 중 하나인 이미지 복잡도에 따라 결함 검출 CNN 모델의 학습에 필요한 최적 데이터 개수 결정 알고리즘은 산업 현장에서 결함 탐지 시스템을 현장에 적용하기 위한 실용적인 지침을 제안해 준다는 점에서 의미가 크다.

결함 탐지 설비에서 수집된 이미지의 복잡도를 평가하기 위해 텍스처의 특성 분석기법인 GLCM, Entropy를 사용하였으며, 정상과 비정상 데이터의 수가 불균형한 문제는 결함 데이터의 Random Crop을 통한 증식으로 해결하였다. 증식된 데이터를 다양한 방식의 이미지 전처리 기법을 적용하여 생성된 학습데이터 기존에 이미지 분류에 우수한 성능에 보이는 CNN 모델에 전이학습하여 결함 판별 인공지능 모델에 적용하였다.

생성된 데이터셋을 기반으로 데이터를 축차적으로 늘려가며 CNN 모델에 전이 학습한 결과 소량의 학습 데이터를 기반으로 생성된 모델은 목표 성능을 이루지 못하였으나, 적절한 개수의 학습데이터가 존재할 경우 전이학습을 통한 모델 학습이 가능함을 확인하였다.

이러한 방법을 통해 전이학습을 위한 적정 데이터 개수를 결정하는 방법론을 제안하였고, 이 방법론의 유효성을 검증하기 위하여 비슷한 복잡도를 가지는 표면 결함 데이터에 적용해 개발된 방법론의 검증을 수행하였다. 그 결과 자동차 글로우 플러그 이미지로 CNN 모델을 전이학습하기 위해 필요한 데이터의 개수와 비슷한 데이터 양으로 목표 성능을 만족하는 모델을 개발 할 수 있었다.

이에 따라 본 논문은 실제 현장에서 사용할 수 있는 성능을 만족하는 CNN 모델을 개발하고 적용하는데 있어 필요한 학습데이터를 수집하는데 소모되는 시간과 비용을 절감할 수 있을 것으로 기대된다.

조선대학교
CHOSUN UNIVERSITY

하지만 CNN모델을 학습시키고, 현장에 사용하기 위해서는 결함 검출 장비와 시스템이 구축되어야 하는 문제가 존재한다. 대량으로 생산하는 제품의 경우 판별시간이 늘어나기 때문에 전수검사 할 수 없다. 이러한 문제를 해결하기 위해 향후 연구로는 CNN 모델의 검출 성능은 유지하며, 고성능의 모델을 경량화하여 낮은 사양의 시스템에서도 빠르게 검사가 가능한 모델을 설계하고자 한다.

조선대학교
CHOSUN UNIVERSITY

참고문헌

1. Yann LeCun, L`eon Bottou, Yoshua Bengio, and Patrick Haffner. 1998, Gradient-based learning applied to document recognition. in *Proceedings of the IEEE*, Vol.86, No.11, pp. 2278-2324.

2. K. He, X. Zhang, S. Ren, and J. Sun, Deep residual learning for image recognition, 2016, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778.

3. I. Goodfellow, Y. Bengio,A. Couville, 2016, "Deep Learning," MIT press.

4. Haralick, R.M., K. Shanmugan, and I. Dinstein, 1973, Textural Features for Image Classification, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, pp. 610-621.

5. S. Karen and Z. Andrew, 2014, Very deep convolutional networks for large-scale image recognition, in *ICLR,* arXiv preprint arXiv:1409.1556.

6. C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich, 2015, Going deeper with convolutions, in *Proceeding of the Computer Vision and Pattern Recognition CVPR*, pp. 1-9.

7. 2020 IoT, AI 기반 스마트 팩토리 기술개발 전략과 시장 전망 보고서, 데이코 산업연구소

조선대학교
CHOSUN UNIVERSITY

8. L. Perez and J. Wang, 2017, The effectiveness of data augmentation in image classification using deep learning, arXiv:1712.04621.

9. Lowe D G., 2004, Distinctive Image Features from Scale-Invariant Keypoint. *International Journal of Computer Vision*, Vol.60, No.2, pp. 91-110.

10. N.Dalal and B. Triggs, 2005, Histograms of oriented gradients for human detection, *In Computer Vision and Pattern Recognition, IEEE Computer Society Conference on*, Vol.1, pp. 886-893.

11. Fanjie Meng , Xinqing Wang , Faming Shao , Dong Wang , Xia Hua, Energy-Efficient Gabor Kernels in Neural Networks with Genetic Algorithm Training Method, Department of Mechanical Engineering, *Electronics 2019*, Vol.8, pp. 105.

12. P. Viola , M. Jones, 2001, Rapid Object Detection using a Boosted Cascade of Simple Features, in *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR*.

13. M. Ozuysal, P. Fua, V. Lepetit, 2007, "Fast Keypoint Recognition in Ten Lines of Code", in *Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition.*

14. Ojala, T., Pietikäinen, M. and Harwood, D., 1996, A Comparative Study of Texture Measures with Classification Based on Feature Distributions. in *Pattern Recognition*, Vol.29, No.1, pp. 51-59.

15. B. Froba and A. Ernst, 2004, Face detection with the modified census transform,

조선대학교
CHOSUN UNIVERSITY

in *Proceedings of the Sixth IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 91-96.

16. Rosenblatt, Frank, The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, Cornell Aeronautical Laboratory, Psychological Review, Vol.65, No.6, pp. 386-408, 1958.

17. Nitish Srivastava, Geoffrey Hinton, Alex krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov, 2014, Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research,* Vol.15 1929-1958.

18. S. Ioffe, C. Szegedy, 2015, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, in *Proceedings of ICML*, pp. 448-456.

19. Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, 2012, ImageNet classification with deep convolutional neural networks, in *NIPS'12 Proceedings of the 25th*, Vol.1, pp. 1097-1105.

20. Shin HC, Roth HR, Gao M, Lu L, Xu Z., 2016, Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning, in *IEEE Transactions on Medical Imaging*, Vol.35, No.5, pp. 1285-1298.

21. J. Canny, 1986, A Computational Approach To Edge Detection, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.8, No.6, pp. 679-698.

22. N. Otsu, 1979, A Threshold Selection Method from Gray-Level Histograms, in

조선대학교
CHOSUN UNIVERSITY

IEEE Transactions on Systems, Man, and Cybernetics. Vol.9, No.1, pp. 62-66.

23. Yu Wang, 1999, Image enhancement based on equal area Dualistic Sub-Image Histogram equalization method, in *IEEE Trans Consumer Electronics*, Vol.45, No.1, pp. 68-75.

24. Olson, David L, Delen, Dursun, 2008, Advanced Data Mining Techniques, Springer, 1st edition, pp. 138

25. Y. Sasaki, 2007. "The truth of the F-measure"

26. R.R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, D. Batra, Gradcam: Visual explanations from deep networks via gradient-based localization. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition CVPR, pp. 618-626.

27. C. Yang, P. Liu, G. Yin, H. Jiang, and X. Li, 2016, Defect detection in magnetic tile images based on stationary wavelet transform, *NDT & E Int.*, Vol. 83, pp. 78-87.

28. Hongyan Xu, Xiu Su, Yi Wang, Huaiyu Cai, Kerang Cui and Xiaodong Chen, 2019, Automatic Bridge Crack Detection Using a Convolutional Neural Network, *Appl. Sci.* vol.9, pp. 2867.

29. Yong Shi, Limeng Cui, Zhiquan Qi, Fan Meng, and Zhensong Chen, Automatic Road Crack Detection Using Random Structured Forests, 2016, in *IEEE TRANSACTIONS ON*

조선대학교
CHOSUN UNIVERSITY

INTELLIGENT TRANSPORTATION SYSTEMS, Vol.17, No.12, pp. 3434-3445.

30. Class 2 Data, https://hci.iwr.uni-heidelberg.de

31. Chao Yan, Frans Coenen, and Bailing Zhang., Driving posture recognition by convolutional neural networks. IET Computer Vision, Vol.10, No.2, pp. 103-114.

32. Kataoka H, Iwata K and Satoh Y. Feature evaluation of deep convolutional neural networks for object recognition and detection. arXiv preprint arXiv:1509.07627, 2015.