

이미지 기반 품질 관리 기법의 스마트 팩토리 현장 적용 이슈와 전략

Issues and Strategy for Deploying Image-Based Quality Management for Smart Factory

이경진, 권준우

Lee, Kyoung-Jun · Kwon, Jun-Woo

Abstract

콘볼루션 신경망 기술의 발전이 영상 기반 품질 경영에서의 전처리 부담을 많이 줄여주는 의미가 있지만, 콘볼루션 신경망의 발전이 전처리 노력을 완전히 제거해주지는 못한다. 그러나, 조금만 훈련받으면 컴퓨터 비전 전문가가 아니더라도 영상 기반의 품질 관리를 할 수 있으며, 이에 기반하여 가변적인 생산체계에 빠르게 적용할 수 있다. 스마트 팩토리에서 자동화된 품질관리를 현실에서 실제 적용하는 것은, 이 방법론들을 이해하고, 이를 일부 구현하여 적용하거나, 통합적으로 구현하여 완전 자동화하는 형태로 진행된다. 이 논문은 스마트 팩토리 환경에서 자동화된 품질 검사를 위한 이미지 기반 품질 관리 기법들을 개관하고 현실에 이러한 기법을 실제 적용하는 데에서 나타나는 이슈와 전략에 대해 토론한다.

주제어: 품질 경영, 기계 학습, 합성곱 신경망, 스마트 팩토리

Although the development of convolutional neural network technology reduces a lot of preprocessing burden in image-based quality management, it does not completely eliminate the preprocessing effort. However, with a little training, even non-computer vision specialists can perform image-based quality management, which allows them to quickly adapt to variable manufacturing systems. The actual application of automated quality control at the smart factory in the real world is based on understanding, implementing, and integrating these methodologies. This paper provides an overview of image-based quality management techniques for automated quality inspection in a smart factory environment and discusses the issues and strategies of applying these techniques in practice.

Key Words: Quality Management, Machine Learning, Convolution Neural Network, Smart Factory

이경진: 경희대학교, 경영대학, 교수

권준우: 경희대학교, 소셜네트워크학과, 석사

1. 서론

제조기업들은 고객들의 요구사항을 만족하며 품질을 일정하게 유지하기 위해 비파괴 품질 검사를 수행한다. 제조기업에서 직원들을 동원해 수작업으로 품질 검사를 수행하면, 작업원들의 눈에 피로가 누적되고 주관적인 기준으로 검사하여 일정하고 일관된 품질을 유지할 수 없다. 제조기업은 카메라나 레이저 센서 등을 통해 제품의 표면 또는 제품의 상태를 데이터화 하고 통계적 방법론, 이미지 처리 방법론, 기계학습 모델을 사용한 방법론 등을 사용해 품질 검사를 자동으로 수행해왔다[38][54]. 이 논문은 스마트 팩토리 환경에서 자동화된 품질 검사를 위한 이미지 기반 품질 관리 기법들을 개관하고 현실에 이러한 기법을 실제 적용하는 데에서 나타나는 이슈에 대해 토론한다.

2. 이미지 기반 품질 관리를 위한 통계적 방법론

통계적 방법론은 이미지 기반 품질관리의 가장 기초적인 방법론으로, 픽셀값의 공간적 분포를 측정하는 방법으로 히스토그램 분석, 자기상관 분석 등을 사용한다. 히스토그램 (Histogram) 분석은 평균, 기하 평균, 표준편차, 중앙값 등을 포함한 통계분석을 수행하며 단순하기 때문에 다양한 문제에서 저비용, 저수준 분석용으로 많이 사용된다[46]. 히스토그램 분석으로 품질 검사를 수행할 경우, 불량과 양품의 텍스처 (Texture) 표면의 강도가 분리할 수 있을 정도로 다를 경우에만 사용이 가능한 한계가 존재한다.

자기상관 분석은 목재 또는 섬유 제품같이 제품 표면의 문양 또는 질감이 반복적으로 나타날 때 사용하는 방법으로 이미지와 이미지에서 나온 변위 벡터 간의 상관관계를 측정한다[53]. 자기상관 측정 결과에서 골과 마루는 강한 규칙성을 갖은 표면을 나타내고 규칙에 기

반을 두기 때문에 노이즈에 민감하고 랜덤 텍스처에 적합하지 않다는 한계가 존재한다.

3. 이미지 기반 품질 관리를 위한 전처리 방법론

연구 환경과 실제 환경은 다르다. 최근에 이미지 자동인식에 강력한 성과를 보이는 합성곱 신경망 방법론도 원 이미지를 그대로 넣는 형태로 실제 환경에서 사용되지 않는다. 실제 환경에서 얻어지는 제품 이미지는 전처리 과정을 거쳐야 성과가 좋은 합성곱 신경망에서 제대로 활용될 수 있게 된다. 결국 현실 문제는 딥러닝과 같은 인공지능 방법론만으로는 해결할 수 없다.

이미지 전처리 방법론은 픽셀값을 조작하거나, 필터를 통해 특징을 추출, 이미지를 다른 형태로 변환하는 방법으로 나뉜다. 일반적으로 사용하는 회색 조, 컬러와 같은 색상 공간의 픽셀값들을 공간영역이라고 하고, 이미지의 주파수 성분 또는 에너지로 이루어진 스펙트럼을 주파수 영역이라고 한다. 각 영역에서 필터링 작업을 수행해 이미지에서 원하는 특징을 추출할 수 있다.

3.1 공간 영역

이미지에서 특징들을 더 잘 찾기 위해 명도와 채도를 조절하거나 임계처리 (Thresholding) 등을 수행한다. 이러한 방법들은 주파수 영역을 다루는 것보다 쉽고 빠르게 구현 가능하여 많은 검사에 사용된다[29]. 특히 금속 표면은 다른 재질에 비해 노이즈가 많이 포함되어 있어 공간영역에서 노이즈를 감소시키고, 불량 영역을 강조시키는 전처리 과정을 수행한다. 임계처리는 특정 임계 값을 기준으로 픽셀값을 처리하는 방법이다. 임계값보다 작으면 0, 크면 특정 값으로 설정하는 이진 임계처리를 많이 사용한다. 특히 밝기 차이에 대한 효과를 줄이거나 노이즈의 영향을 줄이는 데 사용하며, 이미지

에서 대상을 분리할 때 사용할 수 있다.

노이즈의 효과를 줄이거나 끊어진 픽셀을 연결하는 등의 작업을 위해 블러 (Blur) 필터를 전처리에 사용할 수 있다. 블러 필터에는 이미지와 합성곱을 수행하여 블러 과정을 수행하고 합성곱의 결과를 평균으로 처리하는 평균 블러 필터 [44], 중간값으로 처리하는 중간값 블러 필터, 가우시안 (Gaussian) 함수에 의해 생성되는 값들로 채워진 가우시안 블러 필터[12]가 존재한다. 소금-후추 노이즈 제거 등에는 중간값 필터가 많이 쓰이고, 엣지 검출 방법론 등을 사용하기 전에 가우시안 블러를 많이 사용한다[Nixon and Aguado 2008].

공간영역에서 엣지 또는 고립된 점 등과 같은 특징들을 추출하기 위해서는 경사 필터를 사용한다. 경사 필터를 통해 엣지를 찾는 방법론으로, 소벨 엣지 검출 방법론이 있다. [7]에서는 해당 도메인에 맞게 탐색한 결과를 바탕으로 소벨 엣지 검출기의 파라미터를 설정하고 금속 표면에서 불량 영역을 탐색했다.

라플라시안 엣지 검출 방법론[35]은 라플라시안 필터를 이미지에 합성곱하여 엣지를 탐색하고 2차 미분에 기반하기 때문에 엣지가 가늘게 형성되며, 형성된 엣지가 폐곡선을 이룬다. [12]에서는 x축과 y축에 라플라시안 필터를 적용하여 3종류의 막대형 불량을 탐지하는데 활용하였다. 캐니 엣지 검출[10]은 노이즈로 인해 잘못된 엣지를 계산하지 않도록 고안된 방법론이다. 먼저 이미

지에 가우시안 블러를 적용하여 노이즈의 영향을 줄이고 소벨 엣지 검출 방법과 동일하게 기울기의 크기와 방향을 계산한다. 기울기 크기에 대한 경계값을 작은 경계값과 큰 경계값을 지정하여 작은 경계값 이하는 버리고 경계값 사이의 값을 약한 엣지, 큰 경계값보다 큰 기울기를 강한 엣지로 지정한다. 강한 엣지를 기준으로 8방향으로 탐색했을 때 약한 엣지가 연결되면 약한 엣지를 유지하고 그렇지 않으면 제거한다. 이런 과정을 통해 그림 1의 (ㄷ)와 같이 굵고 주된 엣지만 검출되는 것을 확인할 수 있다.

경사 필터 외에도 공간영역에서 지역적 에너지에 분포에 따라 영역을 구분하는 선형 유한 응답 필터를 사용해 결합 위치를 특정할 수 있다[39]. 하지만, 도메인별로 최적화하는 필터를 실험을 통해 찾아야 하는 한계가 존재한다. 잘 정의된 형태를 탐지해야 할 경우, 허프 변환 (Hough Transform)을 통해 선[20]이나 원[42] 형태의 대상을 탐색할 수 있다. Luiz et al.[31]의 경우, 임계처리, 엣지 검출 과정이 끝난 결과물에서 허프 변환을 통해 선형 불량 2가지와 원형 불량 1가지를 탐지하는데 활용하였다.

3.2 주파수 영역

이미지를 처리할 때 공간영역뿐만 아니라 주파수 영




그림 1. 경사 필터를 사용하는 엣지 검출 방법론 비교

역에서도 필터링 작업을 수행할 수 있다. 특히 주기적인 특성이 있거나, 지역적인 에너지 특성이 있을 경우 또는 공간영역에서 필터링을 수행해도 이미지의 패턴을 검출할 수 없을 때 많이 사용한다. 주파수 영역으로 변환하기 위해 푸리에 변환을 많이 사용한다[8]. 푸리에 변환을 통해 얻은 스펙트럼에서 필터 처리를 수행해 이미지에서 특징을 추출할 수 있다. 대표적으로 원형과 쉘기 형태의 필터가 많이 사용된다[13]. 특히 직물 같이 이미지에서 반복되는 선 같은 패턴이 존재하는 경우, 해당 주파수 영역을 제거해 역변환을 수행한 결과와 결합이 존재하는 이미지와의 차이가 존재하는지 여부를 통해 결품을 특정할 수 있는데, 이미지의 문양의 규칙이 없으면 사용 불가능하다 [47][48].

푸리에 변환은 이미지 전체에 대해서 수행하기 때문에 지역적인 공간영역에서 결합 영역을 파악할 수 없다. 이러한 문제를 해결하기 위해 윈도우 함수를 곱해 지역화를 수행하고 푸리에 변환을 수행하는 윈도우 푸리에 변환 (Windowed Fourier Transform)을 도입했다. 이때 윈도우 함수가 가우시안 함수이면 가버 변환 (Gabor Transform)이라고 하며, 육안 검사로 수행하던 결품 검사 영역에 많이 적용되었다[27][17].

가버 변환과 특성이 유사한 웨이블릿 변환 (Wavelet Transform)은 이미지와 같은 데이터를 여러 주파수 성분으로 나눈다. 주파수 성분으로 나눌 때, 푸리에 변환 계열 방법론들과 다르게 나뉜진 영역의 스케일에 맞는 해상도로 성분들이 나뉜진다[19]. 웨이블릿 변환은 고주파수 성분을 추출하는 웨이블릿 함수 (h)와 고주파수 성분을 제거하는 스케일링 함수 (g)로 구성된다. 분해할 주파수 영역의 수를 레벨이라고 하며, 웨이블릿 변환은 분해 영역을 늘릴수록 세밀하게 성분들을 분석할 수 있다. 레벨 1에서 샘플을 절반으로 나누고 레벨이 올라갈수록 나머지 저주파 성분을 절반씩 나눠 분해한다. 따라서 각 레벨의 성분은 n이 레벨일 때 이미지 크기의 배만큼 작아진다. 웨이블릿 변환은 푸리에 변환 계열 방법론에 달리 스케일에 맞는 해상도로 주파수 성

분들이 분해되기 때문에 저주파수 성분들을 잘 분해할 수 있고 함수의 조합으로 이루어져 있어서 상황에 맞게 무한한 조합이 가능하다. 대표적으로 Haar 웨이블릿, Daubechies 웨이블릿[14], 이항 직교(Biorthogonal) 웨이블릿 [32] 등이 존재한다. 그리고 이산 웨이블릿 변환의 경우를 이산 푸리에 변환 보다 계산과 메모리에서 효율적이다. 웨이블릿 변환은 이러한 장점들과 각 주파수 성분들의 평균 및 표준편차 등으로 특징 벡터를 구성할 수 있어서 섬유, 용접, PCB 보드의 납땀 등의 표면 결품 검사에 많이 활용된다[24][30][34].

3.3 주성분 분석

차원축소와 특징 추출을 위해 많이 사용되는 주성분 분석 (Principal Component Analysis; PCA)을 사용해 특징을 추출하여 기계학습 모델의 입력으로 넣기도 한다[23]. 주성분 분석은 선형 결합을 통해 원본 데이터의 분산을 최대한 유지하면서 저차원으로 표현할 수 있는 새로운 벡터를 만드는 방법이고 이에 따라, 새로운 벡터의 분산은 최대가 되게 설정된다[5]. 특히 합성곱 신경망 이전의 신경망 모델의 경우, 하드웨어의 성능과 입력을 1차원으로 받아야 하는 제약조건 때문에 이미지를 사용하기 힘들어 주성분 성분으로 이미지에서 특징을 꺼내 차원을 축소하여 입력을 생성하는 역할로 많이 사용되었다. Luiz et al.[31]은, 허프 변환으로 탐지된 불량일 있을 영역을 주성분 분석으로 특징 벡터를 생성하고 복잡한 형태를 가지는 불량 유형 구분을 위한 신경망의 입력으로 사용하였다. Kumar[26]의 경우, 섬유에서 불량을 찾는 문제를 다층 퍼셉트론으로 해결하기 위해 추출한 특징 벡터를 주성분 분석을 사용해 특징 공간의 차원을 축소하였고 이를 다층 퍼셉트론의 입력으로 사용하였다.

4. 기계학습: k-최근접 이웃 방법, 서포트 벡터 머신, 합성곱신경망

공간 영역과 주파수 영역에서 얻어진 특징들과 주성분 분석을 통해서 얻어진 특성 등을 결합 분류하는 지도 학습 계열의 기계학습 모델에 넣어서 품질관리에 적용하게 된다. 지도 학습은 훈련 데이터와 테스트 데이터가 잘 생성된 경우에 효과적이다.

4.1 k-최근접 이웃 방법

품질 검사를 위해 사용하는 지도학습에는 k개의 대다수가 공유하는 거리 기반 학습 알고리즘인 k-최근접 이웃 (k-Nearest Neighbor) 방법이 있고 이를 통해 불량유형을 분류할 수 있다[49][16]. k-최근접 이웃 방법은 분류의 정확도를 올리기 위해서 해당 문제에 맞게 다양한 k값을 탐색해야 한다[33][52].

4.2 서포트 벡터 머신

서포트 벡터 머신은 회귀 모델에서 마진을 허용한 지도학습 방법론으로 이미지 분류 문제에서도 Alex-Net[25]이 나오기 전까지 많이 사용되었다. 전통적인 서포트 벡터 머신은 이진 분류에 많이 사용되었고 금속 제품의 표면에서 결함을 찾는 데 많이 사용되어왔다[22][41][56]. 서포트 벡터 머신 기반 이진 분류기를 모아 다중 클래스 분류기를 구현하고 히스토그램, 엣지 추출, 형상 추출 등 다른 전처리 과정으로 구현된 특징 추출기나 지식 기반 방법론 등을 접목해 불량 분류에 사용한 사례들이 존재한다[57][11][6][37].

4.3 합성곱 신경망

전통적인 품질관리 방법론들은 특징을 추출하기 위해 도메인 지식이 많이 필요하거나 각 도메인에 최적화

된 전처리 과정 및 필터를 설계해야 했다. 하지만, 이미지 분석을 위해 설계된 합성곱 신경망과 같은 방법론들이 나타나면서 해당 도메인에 대한 지식이 없어도 좋은 성능을 내는 방법론들이 많이 개발되었다. 최대 풀링을 사용한 합성곱 신경망의 경우, 서포트 벡터 머신과 다층 퍼셉트론보다 더 좋은 성능을 냄을 보여주었다 [Scholz-Reiter et al. 2012]. 품질 검사를 수행할 이미지에서 합성곱 신경망이 질감의 유무와 관계없이 올바르게 결품 분류를 수행할 수 있음도 보여주었다[36].

Janssens et al.[21]은 진동 분석을 통한 베어링 결함 탐색에 있어, 특징 추출의 오버헤드를 줄이기 위해 합성곱 신경망을 도입하였다. 이산 푸리에 변환을 수행한 모터의 신호를 합성곱 신경망의 입력으로 받아 베어링의 상태를 4단계로 분류했다. Wang et al. [56]은 이산 웨이블릿을 통해 진동에 대한 스펙트로그램을 형성하고 이를 합성곱 신경망에 넣어 정상과 불량 5가지 유형으로 분류하였다. Dong et al. [15]은 풍력발전기의 진동 데이터에서 노이즈나 공진으로 인해 기존 방법으로 잡기 힘든 6가지의 작은 결함을 구별하기 위해 합성곱 신경망을 도입했다. Ferguson et al. [18]은 주물의 결함을 찾기 위해 x-ray 촬영 이미지를 합성곱 신경망을 도입해 결함으로 예상되는 위치를 파악하고 결함 유형을 분류하는 연구를 수행하였다. Weimer et al. [51]은 사람의 개입을 최소화하는 것을 목표로 하고 마이크로 제조 시나리오를 가정하여 인위로 생성한 6가지 양품과 6가지 결함이 포함된 데이터셋에서 합성곱 신경망을 이용해 분류를 시도하였다. Ye et al. [55]은 터치 패널의 유리 표면을 정상과 10가지 불량으로 구분하기 위해 합성곱 신경망을 도입하였다.

5. 현실 적용 이슈: 프론텍 사례

단조기술 기반의 중소기업 프론텍은 고객사가 외관 이 예쁜 너트만 납품하라고 요구를 하기 시작함에 따라,

이에 대응하기 위해 인공지능 품질관리시스템을 개발하기로 결정했다[4]. 고객사의 직원과 소비자들이 볼트나 너트 하나에도 관능 품질, 감성 품질을 요구하는 시대가 되어, 경영진에서는 이에 적극 대응하기로 결정한 것이다 [3]. 프론텍이 인공지능 기반의 품질관리 시스템의 개발과 도입을 결정하기 전에는 제품을 한테 모아서 육안으로 품질을 검사해야 했다. 품질 검사 속도가 제품 생산 속도를 따라가지 못했다. 작업자들은 단순 반복되는 작업을 고통스러워했다. 모든 제품 품질을 육안으로 검사하는 것은 사실상 불가능했다.

제품의 규격이나 핵심 특징 (예: 나사선의 존재 유무) 등만을 체크하는 비전 검사기만을 사용하고 있었고, 비전 검사기 공급 업체는 인공지능 기반의 품질 관리 시스템 기술을 보유하지 못했기 때문에 프론텍의 새로운 요구에 대응할 수 없는 상태였다. 통계적 방법론만을 사용하는 단계였던 것이다.

딥러닝 기반의 품질관리 시스템은 데이터만 입력한다고 기계학습을 잘 해내는 것은 아니었다. (주)벤플과 경희대학교의 연구팀이 공장에서 찍은 사진을 전(前)처리하는 기법을 연구했다. 프론텍 사례는 원형 모양 너트의 불량 여부를 판단하는 것이었으므로, 허프 변환을 전처리 기법으로 사용하였고, 연구팀은 이산 웨이블릿 변환(DWT), 주성분 분석(PCA)을 모두 검토하였고, 성과 분석 비교를 통해서 최종 결과에 취사선택을 하였다[1]. 처음 한 달 동안은 요구하는 정확도를 만족하는 파라미터를 찾지 못하였는데, 두 달째에 들어서 결국 딥러닝의 최적 파라미터(parameter)를 찾아내었으며, 회사가 요구하는 정확도 95%를 넘어 99%에 육박하는 품질관리시스템을 개발해냈다 [2]. 이 시스템은 전처리와 인공지능 학습과정, 그리고 학습된 모델을 공장의 요구조건에 맞게 구현하는 과정에서 혁신성을 인정받아, 세계인공지능학회(AAAI: Association for Advancement of Artificial Intelligence)의 혁신적 인공지능 응용상을 2020년 2월에 수상하게 되었다[28]. 프론텍은 이제 제품이 생산되는 순간 0.2초 이내에 품질을 검사할 수 있게 됐다.

6. 토론: 제조기업의 품질 경영 과제

기업은 인공지능 자체의 품질을 지속적으로 향상시키고, 품질경영체제를 환경에 적용할 수 있도록 하는 인공지능 기반 품질 체계를 구축해야 한다. 과거의 품질경영이 안정적인 생산 체계에서 통계적 방법론에 따른 품질경영을 추구했다면, 4차산업혁명 시대의 품질경영은 가변적인 생산체계에 빠르게 적용할 수 있는 인공지능에 기반한 경영을 추구해야 한다는 점이 다르다. 일반적인 인공지능 기반 품질경영은 제품단위에 대해 적용하게 되지만, 그 단계를 넘어서게 되면, 설비 단위에 대한 품질경영(설비 고장 예측 및 유지 보수 계획)으로, 그리고 더 나아가 공장 단위에 대한 품질 경영(공장 관리 및 일정 계획 자동화)으로 진화해야 한다.

기업에서 품질경영의 자동화를 위해 콘볼루션 신경망만 쓰게 되지 않는다. 설비에서 나오는 소리를 분석하여 설비의 이상 상태를 확인하는 형태의 기법도 사용될 수 있으므로, 기업은 품질 경영에 활용될 수 있는 다양한 기법을 컨설팅과 연구 개발을 통해 확인해볼 필요가 있다.

미국 기업 코그넥스가 2019년 10월에 1억 950만불에 인수한 한국 기업 수아랩은 이미지 기반 품질 관리 인공지능 솔루션 기업으로 매출의 95%가 제조기업이 직접 알고리즘을 만들 수 있게 도와주는 SW 수아킷에서 나온다고 밝혔다. 수아랩 송기영 대표는, 수아킷이 이미지에 불량, 정상 레이블링을 하고, 학습시키고, 모델을 설정하는 고객의 작업 부담과 문제를 해결해주는 솔루션이라고 밝히고 있다. 수아킷의 솔루션도 결국 본고에서 설명한 통계적 방법론, 데이터 전처리 방법론, 기계학습 방법론을 인간 관리자가 손쉽게 적용할 수 있도록 도와주는 도구이며, 계속적으로 자동화되는 범위를 넓히고 문제 특성에 맞는 모델을 통해 성과를 높여가는 것을 지향하는 솔루션인 것으로 예상된다.

모그룹의 생산기술연구원은 다양한 인공지능 기법을 현실 품질 경영 문제의 해결을 위해 테스트하고 적용

하고 있으며, 이를 사내에만 한정하지 않고, 솔루션화하여 회사의 품질경영팀이 새로운 매출을 만들어낼 수 있는 가능성까지 검토하고 있다. 예전의 인공지능 기업들은 개별 기업의 프로젝트만 수행하고 용역비를 받았다. 그러나, 현재의 인공지능 기업들은 어떤 기업과 공동으로 프로젝트를 수행하고, 그 결과를 인공지능 모델로 정리하고, 공동으로 특허를 취득한 후, 이를 기반으로 상품을 만들어 판매하고 그 수익을 공동으로 프로젝트를 수행한 기업과 나누는 형태로 비즈니스 모델을 플랫폼화하고 있다. 의료 인공지능 분야에서는 한국 기업 뷰노가 이와 같은 비즈니스 모델을 개발해나가고 있는 것으로 해석된다. 의료만큼 쉽지는 않지만, 제조기업의 품질경영에도 이러한 비즈니스 모델이 가능할 수 있다. 인공지능 회사는 특정 제조기업과 제휴하여 먼저 인공지능 기반의 품질경영을 저렴하게 개발하고, 이를 토대로 특허화, 상품화하는 것을 모색할 수 있다.

최근에는 5G 기술과 결합하여 스마트 팩토리를 구축하는 모델에 대해서 많은 기업들이 골몰하고 있다. 제조기업 종사자들은 고객의 물량과 품질 요구에 대응하는데도 벅하다. 제품 생산과정에서 많은 데이터가 발생하고, 설비 그 자체에서도 많은 데이터가 발생하는데 그것을 차분하게 분석할 여유와 여력이 없는 경우가 많은 것이다. 인공지능 기술과 5G 기술의 발달은 이러한 기업들의 데이터를 실시간으로 대용량 초고속 모바일 커뮤니케이션 방법을 통해 받아서 분석하고 이를 다시 제조기업에게 진단 서비스로 제공하는 형태의 비즈니스 모델의 탄생 가능성을 높인다. 여기서 수익 모델은 가입비 모델이 가능하다. 제조기업들은 평소에 자신들이 관심이 없었던 데이터를 외부에서 분석해서 관련된 유지보수, 일정계획 서비스를 제공하면, 이에 대한 효용을 느끼게 되고, 이러한 서비스에 대해서 지불 의사가 발생할 수 있다. 이렇게 됨으로써 제조분야의 새로운 품질경영 비즈니스 모델이 만들어질 수 있는 것이다.

기존의 품질경영은 개별 제품에 대해서 방법론을 현

업의 전문가가 비밀리에 만들어 내는 고비용의 품질경영 방법론이었다면, 인공지능기술과 5G 기술의 발전, 빅데이터 처리 기술의 발전, 그리고 플랫폼 비즈니스 모델의 발전으로, 그러한 개별적, 비공개 품질경영 방법론들이 어느 정도 공개되고, 공유 가능한 플랫폼 비즈니스 모델, 가입비형 수익 모델로 전환될 수 있는 것이다. 제조기업의 현장에서는 제조에만 전념할 수 있고, 품질경영, 일정계획, 설비유지 관리를 위한 데이터 처리 및 인공지능 분석 서비스는 외부 플랫폼 서비스 사업자로부터 저렴하게 받을 수 있다

참고문헌

- [1] 권준우. 2019. 제조 분야의 자동화된 품질 검사를 위한 딥러닝 기반의 대형 이미지 분류 시스템 개발 및 구축 (Development and Deployment of Deep Learning Based Large-Scale Image Classification System for Automated Quality Inspection in Manufacturing), 경희대학교 소셜네트워크과학과 석사 논문.
- [2] 김진호, 권준우, 황보유정, 이경전. 2018. “제조분야 자동 품질 검사를 위한 딥러닝 기반 대형 이미지 분류시스템 개발 및 구축 사례”, 2018 한국지능정보시스템학회 추계학술대회.
- [3] 이경전. 2019. “영상인식 인공지능으로, 프로세스와 서비스를 혁신하라”, 품질경영 2019년 5월호.
- [4] 이경전. 2018. “인공지능이 제조업 살린다”, 한국경제신문, 2018.11.27
- [5] Abdi, H., & Williams, L. J. 2010. “Principal component analysis” , Wiley interdisciplinary reviews: computational statistics 2(4):433-459.
- [6] Agarwal, K., Shivpuri, R., Zhu, Y., Chang, T. S., & Huang, H. 2011. “Process knowledge based multi-class support vector classification (PK-MSVM) approach for surface defects in hot rolling”, Expert Systems with Applications 38(6):7251-7262.
- [7] Blackledge, J., & Dubovitskiy, D. 2008. “A surface inspection machine vision system that includes fractal texture analysis”, Journal of Intelligent Systems 3(2):76-89.
- [8] Boashash, B. 2015. Time-frequency signal analysis and processing: a comprehensive reference. Academic Press.
- [9] Boukouvalas, C., Kittler, J., Marik, R., & Petrou, M. 1999. “Color grading of randomly textured ceramic tiles using color histograms”, IEEE Transactions on industrial electronics 46(1):219-226.
- [10] Canny, J. 1986. “A computational approach to edge detection”, IEEE Transactions on pattern analysis and machine intelligence 6(6):679-698.
- [11] Choi, K., Koo, K., & Lee, J. S. 2006. “Development of defect classification algorithm for POSCO rolling strip surface inspection system”, In 2006 SICE-ICASE International Joint Conference, pp. 2499-2502. IEEE.
- [12] Choi, S. H., Yun, J. P., Seo, B., Park, Y. S., & Kim, S. W. 2007. “Real-time defects detection algorithm for high-speed steel bar in coil”, In Proceedings of World Academy of Science, Engineering and Technology (Vol. 21), pp. 1307-6884.
- [13] Coggins, J. M., & Jain, A. K. 1985. “A spatial filtering approach to texture analysis”, Pattern recognition letters 3(3):195-203.
- [14] Daubechies, I. 1992. Ten lectures on wavelets (Vol. 61). Siam., pp.194
- [15] Dong, H. Y., Yang, L. X., & Li, H. W. 2016. “Small fault diagnosis of front-end speed controlled wind generator based on deep learning”, WSEAS Trans. Circuits Syst 15(9).
- [16] Dupont, F., Odet, C., & Cartont, M. 1997. “Optimization of the recognition of defects in flat steel products with the cost matrices theory”, NDT & E International 30(1):3-10.
- [17] Escofet, J., Navarro, R. F., Garcia-Verela, M. S. M., & Pladellorens, J. M. 1998. “Detection of local defects in textile webs using Gabor filters”, Optical Engineering 37(8):2297-2308.
- [18] Ferguson, M., Ak, R., Lee, Y. T. T., & Law, K. H. 2017. “Automatic localization of casting defects with convolutional neural networks”, In 2017 IEEE International Conference on Big Data, pp. 1726-1735. IEEE.
- [19] Haar, A. 1910. Zur theorie der orthogon-alen

- funktionensysteme” , *Mathematische Annalen* 69(3):331-371.
- [20] Hart, P. E. 1971. Use of the hough trasfor-mtion to detect lines and curves in pictures.
- [21] Janssens, O., Slavkovikj, V., Vervisch, B., Stockman, K., Loccufier, M., Verstockt, S., Van de Walle, R. Van Hoecke, S. 2016. “Convolutional neural network based fault detection for rotating machinery” , *Journal of Sound and Vibration* 377:331-345.
- [22] Jia, H., Murphey, Y. L., Shi, J., & Chang, T. S. 2004. “An intelligent real-time vision system for surface defect detection” , In *Proceedings of the 17th International Conference on Pattern Recognition (ICPR 2004)*, Vol. 3, pp. 239-242. IEEE.
- [23] Ke, Y., & Sukthankar, R. 2004. “PCA-SIFT: A more distinctive representation for local image descriptors” , *CVPR* 2(4):506-513.
- [24] Kim, S., Lee, M. H., & Woo, K. B. 1999. “avelet analysis to fabric defects detection in weaving processes. In *Industrial Electronics*” ISIE'99. *Proceedings of the IEEE International Symposium on* (Vol. 3), pp. 1406-1409. IEEE.
- [25] Krizhevsky, A., Sutskever, I., & Hinton, G. E. 2012. “Imagenet classification with deep convolutional neural networks” , In *Advances in neural information processing systems*, pp. 1097-1105.
- [26] Kumar, A. 2003. “Neural network based detection of local textile defects” , *Pattern Recognition* 36(7): 1645-1659.
- [27] Kumar, A., & Pang, G. K. 2002. “Defect detection in textured materials using Gabor filters” , *IEEE Transactions on industry applications* 38(2):425-440.
- [28] Lee, K., Kwon, J., Min, S., Yun, J. 2020. “Embedding Convolution Neural Network-Based Defect Finder for Deployed Vision Inspector in Manufacturing Company Frontec” , Forthcoming in *IAAI (Innovative Applications of Artificial Intelligence) 2020 Conference*, New York.
- [29] Li, W. B., Lu, C. H., & Zhang, J. C. 2012. “A local annular contrast based real-time inspection algorithm for steel bar surface defects” , *Applied Surface Science* 258(16):6080-6086.
- [30] Liu, J. J., & MacGregor, J. F. 2006. “Estimation and monitoring of product aesthetics: application to manufacturing of engineered stone countertops” , *Machine Vision and Applications* 16(6):374.
- [31] Luiz, A. M., Flávio, L. P., & Paulo, E. A. 2010. “Automatic detection of surface defects on rolled steel using computer vision and artificial neural networks” , In *IECON 2010-36th Annual Conference on IEEE Industrial Electronics Society*, pp. 1081-1086. IEEE.
- [32] Mallat, S. 1999. *A wavelet tour of signal processing*. Elsevier.
- [33] Mandriota, C., Nitti, M., Ancona, N., Stella, E., & Distanto, A. 2004. “Filter-based feature selection for rail defect detection” , *Machine Vision and Applications* 15(4):179-185.
- [34] Mar, N. S. S., Yarlagadda, P. K. D. V., & Fookes, C. 2011. “Design and development of automatic visual inspection system for PCB manufacturing’ , *Robotics and computer-integrated manufacturing* 27(5):949-962.
- [35] Marr, D., & Hildreth, E. 1980. “Theory of edge detection” , *Proc. R. Soc. Lond. B* 207(1167):187-217.
- [36] Masci, J., Meier, U., Ciresan, D., Schmidhuber, J., & Fricout, G. 2012. “Steel defect classification with max-pooling convolutional neural networks” , In *Neural Networks (IJCNN), The 2012 International Joint Conference on*, pp. 1-6. IEEE.
- [37] Murino, V., Bicego, M., & Rossi, I. A. 2004. “Statistical classification of raw textile defects. In *Pattern*

- Recognition", ICPR 2004. Proceedings of the 17th International Conference on (Vol. 4), pp. 311-314. IEEE.
- [38] Neogi, N., Mohanta, D. K., & Dutta, P. K. 2014. "Review of vision-based steel surface inspection systems", *EURASIP Journal on Image and Video Processing* (1):50.
- [39] Neubauer, C. 1992. "Segmentation of defects in textile fabric. In *Pattern Recognition*", Vol. I. Conference A: Computer Vision and Applications, Proceedings., 11th IAPR International Conference on, pp. 688-691. IEEE.
- [40] Nixon, M., & Aguado, A. S. 2008. *Feature Extraction & Image Processing*.
- [41] Park, C., & Won, S. 2009. "An automated web surface inspection for hot wire rod using undecimated wavelet transform and support vector machine", In *2009 35th Annual Conference of IEEE Industrial Electronics*, pp. 2411-2415. IEEE.
- [42] Pedersen, S. J. K. 2007. "Circular hough transform", Aalborg University, *Vision, Graphics, and Interactive Systems*, 123(6).
- [43] Rodrigues, M. T., Padua, F. L., Gomes, R. M., & Soares, G. E. 2010. "Automatic fish species classification based on robust feature extraction techniques and artificial immune systems", In *2010 IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA)*, pp. 1518-1525. IEEE.
- [44] Sasaki, T., Takada, H., & Tomura, Y. 2007. "Automatic Surface Inspection System for Tin Mill Black Plate(TMBP) 1", *JFE technical report* (9):60-63.
- [45] Scholz-Reiter, B., Weimer, D., & Thamer, H. 2012. "Automated surface inspection of cold-formed micro-parts", *CIRP Annals-manufacturing technology* 61(1):531-534.
- [46] Swain, M. J., & Ballard, D. H. 1992. "Indexing via color histograms", In *Active Perception and Robot Vision*, pp. 261-273. Springer, Berlin, Heidelberg.
- [47] Tsai, D. M., & Hsieh, C. Y. 1999. "Automated surface inspection for directional textures", *Image and vision computing* 18(1):49-62.
- [48] Tsai, D. M., & Huang, T. Y. 2003. "Automated surface inspection for statistical textures", *Image and Vision computing* 21(4):307-323.
- [49] Ünsalan, C., & Erçil, A. 1999. "Automated inspection of steel structures", *Recent Advances in Mechatronics*, 468-480.
- [50] Wang, J., Zhuang, J., Duan, L., & Cheng, W. 2016. "A multi-scale convolution neural network for featureless fault diagnosis", In *Flexible Automation (ISFA), International Symposium on*, pp. 65-70. IEEE.
- [51] Weimer, D.; Scholz-Reiter, B.; and Shpitalni, M. 2016. "Design of Deep Convolutional Neural Network Architectures for Automated Feature Extraction in Industrial Inspection", *CIRP Annals* 65(1): 417-420.
- [52] Wiltschi, K., Pinz, A., & Lindeberg, T. 2000. "An automatic assessment scheme for steel quality inspection", *Machine Vision and Applications* 12(3):113-128.
- [53] Wood, E. J. 1990. "Applying Fourier and associated transforms to pattern characterization in textiles", *Textile Research Journal* 60(4):212-220.
- [54] Xie, X. 2008. "A review of recent advances in surface defect detection using texture analysis techniques", *ELCVIA Electronic Letters on Computer Vision and Image Analysis* 7(3):1-22.
- [55] Ye, R., Pan, C. S., Chang, M., & Yu, Q. 2018. "Intelligent defect classification system based on deep learning", *Advances in Mechanical Engineering* 10(3).
- [56] Yun, J. P., Park, C., Bae, H., Hwang, H., & Choi, S. 2010. "Vertical scratch detection algorithm for high-

speed scale-covered steel BIC (Bar in Coil)”, In ICCAS 2010, pp. 342-345. IEEE.

- [57] Zhao, J., Yang, Y., & Li, G. 2010. “The cold rolling strip surface defect on-line inspection system based on machine vision”, In 2010 Second Pacific-Asia Conference on Circuits, Communications and System (Vol. 1), pp. 402-405. IEEE.

저자소개



이경전(Lee, Kyoung Jun)

KAIST 경영과학과 학석박사를 졸업하고, 서울대 행정학 석박사를 수료하였다. 경희대 경영대학 교수로 근무하고 있으며, AI & BM (인공지능 & 비즈니스 모델) 연구소장, 경희대 후마니타스 빅데이터 연구센터 소장, (사)국제전자상거래연구센터 소장을 맡고 있다. 미국인공지능학회의 혁신적 인공지능 응용상을 3회(1995, 1997, 2020 예정) 수상하였다. 카네기멜론대, MIT, UC버클리에서 초빙과학자와 초빙교수로 활동하였다. 한국지능정보시스템학회 회장을 역임하고, 현재 한국경영커뮤니케이션학회장이자, 사물인터넷 기업 벤플과 전자상거래 기업 올원웨어의 (공동)창업자이다.

E-mail: klee@khu.ac.kr



권준우(Kwon, Jun Woo)

경희대학교 전자전파공학 학사, 소셜네트워크과학 석사를 졸업하였다. 석사 논문 <제조 분야의 자동화된 품질 검사를 위한 딥 러닝 기반의 대형 이미지 분류 시스템 개발 및 구축>이 있고, LG전자, 한국생산성본부, 프론텍의 인공지능 시스템 및 비즈니스 모델 개발 프로젝트에 참여하였다.

E-mail: kh.shin@lgcns.com

◇ 이 논문은 2019년 11월 18일에 접수하여 2019년 12월 08일에 1차 수정을 거쳐 2019년 12월 09일에 게재 확정되었습니다.