

효과적인 디스플레이 제조를 위한 AI/BIG DATA 기반 스마트 팩토리 기술 현황 분석

정석원¹ · 임현국^{2*}

AI/BIG DATA-based Smart Factory Technology Status Analysis for Effective Display Manufacturing

Sukwon Jung¹ · Huhnkuk Lim^{2*}

¹Undergraduate Student, Division of Computer and Information Engineering, Hoseo University, Chungnam Asan, 31499 Korea

^{2*}Assistant Professor, Division of Computer and Information Engineering, Hoseo University, Chungnam Asan, 31499 Korea

요 약

디스플레이 분야에 스마트 팩토리란 작업 자동화 뿐만 아니라 기존의 공정관리, 이동설비, 공정이상, 결함 분류 등에 AI/BIG DATA 기술을 이용한 보다 효율적인 디스플레이 제조를 의미한다. 과거 디스플레이 제조 과정에서 불량 이 나오면 결함 분류, 공정 이상에 대한 대처가 시시각각 달랐기 때문에 이에 대한 많은 시간 소모가 발생했었다. 하지만 디스플레이 제조 분야는 고도화된 공정 장비를 이용해야 하고 불량 원인을 신속하게 파악해 수율을 올리는 것이 디스플레이 제조 산업의 경쟁력이다. 본 논문에는 스마트 팩토리 AI/BIG DATA 기술을 디스플레이 제조에 접목 한 사례들에 대해 정리해 보고 기존 방법 대비 어떤 장점이 도출 되어질 수 있는지에 대해 처음으로 분석해 보고자 한다. 이를 통해 향후 AI/BIG DATA를 이용한 디스플레이 제조 분야에 보다 향상된 스마트 팩토리 개발을 위한 사전 지식으로 활용하고자 한다.

ABSTRACT

In the field of display, a smart factory means more efficient display manufacturing using AI/BIG DATA technology not only for job automation, but also for existing process management, moving facilities, process abnormalities, and defect classification. In the past, when defects appeared in the display manufacturing process, the classification of defects and coping with process abnormalities were different, a lot of time was consumed for this. However, in the field of display manufacturing, advanced process equipment must be used, and it can be said that the competitiveness of the display manufacturing industry is to quickly identify the cause of defects and increase the yield. In this paper, we will summarize the cases in which smart factory AI/BIG DATA technology is applied to domestic display manufacturing, and analyze what advantages can be derived compared to existing methods. This information can be used as prior knowledge for improved smart factory development in the field of display manufacturing using AI/BIG DATA.

키워드 : 스마트 팩토리, 인공지능/빅데이터, 디스플레이, 공정, 결함 분류

Keywords : Smart factory, AI/BIG DATA, Display, Process, Defect classification

Received 18 December 2020, Revised 11 January 2021, Accepted 15 February 2021

* Corresponding Author Huhnkuk Lim(E-mail:hklim@hoseo.edu, Tel:+82-41-540-5942)

Assistant Professor, Division of Computer and Information Engineering, Hoseo University, Chungnam Asan, 31499 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.3.471>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

국내 디스플레이 산업은 90년대 초반부터 스마트 팩토리를 본격적으로 고민하기 시작하였다. 부분적인 자동화 작업이 상당부분 이루어져 왔고 분석, 불량 원인 파악, 이동설비 등 전체적인 자동화는 아직도 개발이 진행 중에 있다. 디스플레이 제품은 긴 시간 동안 수많은 공정과 고도화된 공정장비를 거치는 만큼 불량 원인을 신속하게 파악해 수율을 올려 디스플레이 시장에서 우위를 점하는 것이 중요하다. 공정과정에서 불량원인을 신속하게 파악해야 한다는 점에서 공정관리, 불량 분류에 대한 고도화가 필요하게 되었다. 이를 위해 빅데이터를 구축하고 다양한 장비들로부터 수집된 데이터를 AI 기술을 통해 분석 예측하여 수율 및 품질관리를 보다 효율적으로 개선할 수 있는 기술의 개발이 요구되어 왔다 [1][2].

디스플레이 제조 공정에는 FAB 플랫폼, 빅 데이터 플랫폼, 그리고 이러한 플랫폼들이 활용된다. FAB 플랫폼은 생산 라인(Production Line)의 자동 제어를 위하여 도입되어 있는데 보통은 제조실행 시스템(MES), 수율 관리 시스템(YMS), 설비 제어 관리 시스템(EES), 물류 및 반송 관리 시스템(RTD), 공정, 검사, 계측 데이터 베이스로 구성된다. 최근에는 공정, 검사, 계측 데이터 베이스에 축적된 빅 데이터를 중심으로 수율과 품질 향상을 위해서 많은 머신러닝 기반 공정 제어, 진단, 모니터링 과 검사 해결책 등이 추가되고 있다 [3].

디스플레이 제조 공정 가운데 OLED(Organic Light-Emitting Diode) 제조 공정은 큰 틀로 보면 TFT(Thin Film Transistor) 소자로 이루어진 LTPS(Low-Temperature Polycrystalline Silicon), 발광 소자로 이루어진 Color Patterning, 디스플레이 패널을 조립하는 모듈 공정으로 구성되어 있고, 각 공정은 모두 합해 수백 개의 세부 공정단계로 이루어져 있다. [3] 본 논문에서는 기존 디스플레이 공정과정 및 방법에서 해결하기 힘들었던 문제점을 파악하고 이 문제점을 AI/BIG DATA 기술을 이용해 해결한 사례들에 대해 분석해 보고자 한다. AI/BIG DATA를 이용한 문제 해결 사례 및 장점을 처음으로 분석 제시함으로써 앞으로 AI/BIG DATA를 이용한 디스플레이 제조 분야에 보다 향상된 스마트 팩토리 개발을 위한 사전 지식으로 활용하고자 한다.

II. 스마트 팩토리

스마트 팩토리란 설계 및 개발, 유통에 디지털 자동제어 해결책이 결합된 정보통신기술(ICT)을 사용하여 생산성, 품질을 만족시키는 스마트 생산 공장으로 공장 내 설비에 사물인터넷(Internet of Things)을 접목하여 데이터를 즉각적으로 수집, 분석하여 공장 내 모든 상황들이 분명하게 보여지고, 이를 분석해 스스로 제어되는 공장이라 할 수 있다 [4-8].

제조업이 신기술을 활용하는 과정은 오래전부터 이어져 왔지만 이러한 신기술을 도입한다 하더라도 제조 생산성 정체 현상은 여전히 발생한다. 미국 정부가 발표한 자료를 보면 제조업 노동 생산성에 있어 2007~2018까지 증가율은 0.7%로 1987~2006년 연평균(annual average) 3.6% 성장에 비교하면 엄청 낮다. 이유로는 고령화로 인한 숙련된 노동자 감소에 기인한 공정 자동화 때문인데, 각각의 공정에만 자동화가 이루어져 있다 보니 전체적으로 통합되지 못했고 이로 인해 낮은 운영 효율성을 나타냈기 때문이다. 스마트 팩토리 도입으로 생산 설비, 사람, 데이터, 불량검출과 생산의 원재료, 노동력, 자본 등을 전체적으로 연결해 운영 효율성을 극대화시킬 수 있다는 결과를 확인 할 수 있는데, 이에 스마트 팩토리 도입 기업 600개 사를 분석한 결과를 보면 노동 생산성 증가율은 12%, 설비 운용 효율 증가율 11%, 전체 생산량 증가율 10%가 증가했음을 확인할 수 있다 [8].

표 1에서 기존 공정 대비 스마트 팩토리 적용으로 인한 효과를 확인할 수 있다. 스마트 팩토리 적용 기업은 1인당 생산량, 납기 관리, 설비 가동률과 납기 준수 제조업이 가장 중요시 하는 업무 지표가 향상되는 결과를 가져오게 된다 [8].

하지만 아직 보완할 부분이 많다. 공정, 이동설비, 공정 이상, 결함 분류 등에서 기존 공정의 수준 향상이 요구되는 상황이다. 수준 향상을 위한 기존 공정에서 발생

Table. 1 Effect of Smart Factory [8]

Increase↑	decrease↓
production per person	Production defect rate
producing ability	Manufacturing cost
Compliance with delivery date	Decision time
Overall facility efficiency	Bad stock
Facility utilization rate	Number of failures
Customer satisfaction	Failure response time

했던 문제점들을 살펴보고 AI/BIG DATA 기술을 디스플레이 제조에 적용한 대표적인 네가지 사례에 대해 분석하고자 한다. 이를 통해 AI/BIG DATA를 접목한 자동화 운영이 기존 방법에 비해 비용과 시간 측면에서 얼마나 효과적인지를 알아보하고자 한다.

III. 디스플레이 제조 AI/BIG DATA 접목 사례

3.1. 머신러닝 접목 사례

생산 공정, 공정 제어, 공정 이상 진단의 수준 향상을 위한 해결책 들은 기본적으로 공정 결과 데이터를 필요로 한다.




Fig. 1 Display process VM[3]

공정 데이터를 이용한 시스템으로 MES(Manufacturing Execution System)/POP(Point of Production System)를 예로 들 수 있다. MES는 제품 주문에 의한 착수에서 완성품의 품질검사까지 전 생산 활동을 관리하는 시스템으로 생산 현장의 각종 정보, 즉 생산실적, 작업자 활동, 설비가동, 제품 품질정보 등을 실시간으로 수집하여 집계/분석/모니터링 및 생산 공정을 제어함으로써 고품질의 수익 지향적 생산체제를 갖추게 하는 통합 생산관리 시스템이다. POP는 공장의 생산과정에서 기계, 설비, 작업자, 작업 등에서时时刻刻 발생하는 생산 정보를 실시간으로 직접 수집, 처리하며 현장 관리자에게 제공하는 시스템이다[9][10].

하지만 기술의 발전과 시장에서 요구되는 고해상도 디스플레이 제품의 품질 수준을 만족시키기 위하여 생산 공정은 기존 대비 복잡해지고 고도화되었다. 모든 공정 결과 데이터가 실시간으로 측정될 수 있다면 바랄 것이 없겠지만 예측 설비 증가에 따른 투자비 증가로 이는 불가능하다 [3]. 이러한 문제점들에 대한 솔루션으로 VM (Virtual Metrology)이 해결책으로 부상하고 있다.

VM은 예측에 의한 생산성 저하와 투자비 상승을 가

장 낮게 하면서 공정 결과 데이터를 얻을 수 있는 수단을 제공한다. 그림1은 전형적인 디스플레이 공정의 VM을 보여준다 [3].

VM은 통계모델 기반으로 공정 데이터를 사용하여 공정 완료 바로 다음 전수 glass에 대한 공정 결과를 테크니션에게 제공하는 시스템이다. 이 시스템을 이용하여 샘플링 데이터 간의 작업 과정을 확인할 수 있을 뿐 아니라 공정이상 발생 시 예측 지연 없이 빠른 조치를 가능하게 한다는 장점이 있다. 기존에 데이터 기반 공정 관리 문제점 해결을 위한 연구는 지엽적이었으나, VM을 활용할 경우 이런 한계를 해결할 수 있다 [3].




Fig. 2 APC configuration diagram[3]

그림2는 APC(Advanced Process Control) 시스템의 구성도를 보여준다. APC 시스템은 전문가를 대신해 실제 예측 또는 VM 데이터를 기계학습 기반으로 분석하여 공정 산출량이 목표값에 유지될 수 있도록 공정의 입력값을 최적화하고, 이를 통해 단위 공정능력 개선에 크게 기여 한다.

3.2. 강화학습을 통한 이동설비 운영

디스플레이 생산라인 이동설비 부분은 크게 3가지로, 웨이퍼, 웨이퍼 이송 장비, 패널 이송 장비로 구성된다. 평소 설비는 제조사가 계획한 대로 운영되지만 기계 고장, 생산 지연 등이 발생하면 현장 엔지니어의 능력에 따라 운영되어왔다. 즉 현재까지는 현장 엔지니어의 능력에 따라 수율과 생산성이 결정되었다. 하지만 고도화된 공정 생산 라인이 추가되어 보다 복잡해진 공정과정 속에서 기존 OHT(Overhead Hoist Transfer)로는 운영이 힘들어진 상황이 되었다. 이로 인해 OHT는 기존보다 증가하게 되었고, 계획대로 운영하기 힘든 상황까지 오게 되었다 [11].

이러한 문제점을 해결하기 위해 이송설비를 AI가 운영하도록 하는 방법이 모색되기 시작했다. 하지만 어떤 AI 기술이던 데이터가 충분해야 정확도가 떨어지는 일

이 발생하지 않는다. 현재로서는 데이터가 충분하지 않기 때문에 데이터 없이 학습하는 시스템 에이전트를 이용해서 환경을 관찰하고 최상의 전략을 스스로 학습하는 강화학습을 OHT 시스템에 통합했다. 그 결과 엔지니어가 OHT 시스템에 숙달되기까지 최소 수년이 필요했다면 강화학습을 통해 10분의 1로 시간이 단축되는 결과를 확인할 수 있었다 [11].

강화학습 알고리즘은 웨이퍼 처리량이 많을수록, 라인이 복잡할수록 이송 시간이 크게 감소되는 것으로 나타났다. OLED 생산 라인에 웨어준을 없애고 강화학습 알고리즘이 생산라인의 이동을 이미지화해 스스로 학습하게 했고, 그 결과 생산성을 4배 높일 수 있었다. 하지만 현재 강화학습 알고리즘을 생산라인에 무작정 도입 할 수는 없는 상황이다. 기본적으로 대부분의 생산라인이 자동화가 이루어져야하기 때문에 강화학습 알고리즘이 기존 방식보단 몇 배나 효율이 좋더라도 지금 당장 도입 할 수 없는 상황이다. 따라서 현재 생산라인이 대부분 자동화가 된 회사들을 파악하고 강화학습 알고리즘을 적용시켜 데이터를 축적하는 단계를 밟아 점차 개선해 나아가야 할 것이다 [11].

3.3. 다변량 통계 분석 공정 이상 진단

공정 이상과 불량 모니터링은 FDC(Fault Detection & Control)나 SPC(Statistical Process Control) 시스템 등 다양한 방법에 의해 이루어지고 있다. 공정에 이상이 발생했을 경우, 공정 이상의 원인요소 분석으로는 분산 분석 ANOVA(Analysis of Variance)을 통해 이루어진다. FDC는 삼성, 엘지, Toshiba, Global Foundries 등 다수의 대형 반도체 및 LCD업체에서 데이터 분석 기반의 업무분석 및 품질 관리를 위해 사용하고 있는 시스템이다. 설비 Data(각종 센서의 시그널) 실시간으로 수집하고 분석하여 설비의 Fault를 실시간 감지 및 모니터링 한다. 이를 통하여 공정이나 설비에서 일어나는 문제를 적시에 대처할 수 있고 누적된 Data의 분석을 통하여 적절한 주기의 PM(project manager)을 설정하여 설비의 장애를 최소화할 수 있으며, 각기 다른 Data 간의 상관관계를 파악하고 조합하여 더 정밀한 분석업무를 할 수 있게 하는 것. 또한, 현재 운영 중인 동일한 설비가 새로 입고 시부터 FDC를 적용하면 신규 도입 장비의 상태를 기존장비의 최적 조건으로 빠른 시간에 Setup하고 생산에 기여할 수 있다 [12]. 현재까지도 기업은 공정 안정화와 공정

이상에 대해 끊임없이 논의하고 개발중인 상황이다. 하지만 공정 이상이 복합적 원인 요소에 의해서 발생할 경우 앞서 나온 분석 방법으로는 발견되지 않는 경우가 발생한다. 이러한 복합적 원인 요소에 의한 이상분석을 위해 주성분 분석 PCA(Principal Component Analysis) 등 다변량 통계학 분석을 사용해야 하는 솔루션이 필요하게 되었다.




Fig. 3 Display process abnormality diagnosis[3]

그림 3은 공정 이상 진단 과정을 보여준다. 측정 또는 검사 데이터를 기반으로 공정 이상을 판단하고 공정 데이터와 다변량 통계분석을 통해 공정이상 원인요소를 찾아내고 이것을 활용해 조기에 이상을 감지하는 예측 모델을 개발하는 중이다. 공정의 이상 형태 및 원인요소는 매우 다양하여 경우에 따라 여러 복합적 통계 방법론이 요구되기도 한다.

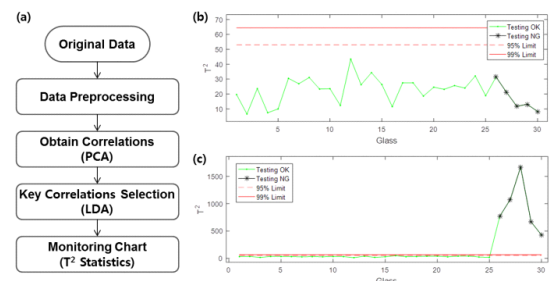


Fig. 4 (a) PCA+LDA fault diagnosis flow chart[2], (b) T2 Chart: PCA Only, (c) T2 Chart: PCA+LDA

그림 4는 주성분 분석 PCA(Principal Component Analysis)와 선형판별분석 LDA(Linear Discriminant Analysis)가 결합된 방법론의 flowchart와 결과 비교를 보여 준다. 데이터 전처리(preprocessing)를 거쳐서 PCA를 통해 상관 패턴을 얻고, 이때 얻은 상관 패턴을 입력 인자로, 대응되는 glass마다 이상 유무 판정 결과가 출력 인자로 기록되어 LDA를 통해 최종 주요 상관 패턴을 결정한다. 원본 DATA SET의 분산에 공헌한 비중이 높은

순서로 주요상관 패턴을 분석하는 통상적인 PCA 방법론과 비교하여, 이 사례로 분석된 주요상관 패턴을 활용한 결과는 T2 Chart가 공정 이상에 보다 민감하게 반응한다. (그림 4(b)와 그림 4(c)). 이를 위한 Software tool이 개발되어 양상 공정 이상 분석 및 해결 방안 도출에 적용되고 있다.

제시된 사례는 빅데이터 활용에 초점을 맞추고 있는 만큼 향후 빅데이터 처리 및 분석과 관련한 기술이 보강되어 저야 할 것이다

3.4. 딥러닝 기반 결함 분류

3.4.1. 불량 시스템 분류에 딥러닝 적용 필요성




Fig. 5 Image-based defect classification scheme[3]

디스플레이 패널 제조 결함 검출에는 여러 종류의 시각적 검사 단계가 존재한다. 일반적으로 LCD, OLED, PDP 등의 생산 현장에서는 생산된 디스플레이 패널을 작업자가 육안으로 검사하는 공정이 있었는데, 디스플레이 분야의 기술발전으로 인하여 검사해야 할 패널 사이즈가 점점 커지고, 고해상도로 변해 감에 따라 작업자에 의한 육안 검사가 어려운 상황에 이르렀다. 즉, 생산된 디스플레이 패널의 오류를 검출하는 과정에서 점등이 된 디스플레이 패널의 화면을 계속 보고 있으면 작업자의 눈이 피로하게 되어 생산성이 저하되고, 검사자의 개인차로 인해 불량 검출의 신뢰성이 떨어지는 문제점이 발생하였다. 이러한 문제 때문에 자동 광학 검사 AOI(Automatic Optical Inspection)가 개발되었다. 그림 5는 자동 광학검사 AOI로부터 얻어진 이미지를 이용한 결함 분류 구성도를 보여준다. 디스플레이 제조에 대한 자동 육안 검사로, 카메라가 부품 누락 및 품질 결함 모두에 대해 테스트 중인 장치를 모두 자동으로 검사하는 방법으로 비접촉 검사 방식이기 때문에 디스플레이 제조공정에서는 일반적으로 사용되어왔다 [13][14].

하지만 불량 특징을 정의하는 것은 많은 어려움이 있고, 불량 특징을 최적화하는 것 또한 정확성에 대한 한계가 존재한다. 이를 개선하기 위해서 분류 시스템에 딥러닝 기술을 반영함으로써 불량 판정 정확도를 대폭

상향시킬 수 있다. 또한 디스플레이 제조공정 결함 분류 외에도 패널 외관 검사나 얼룩 수준 판별 등에도 딥러닝 기반의 분류 모델이 적용 되어질 수 있다 [3].

3.4.2. 딥러닝 기반 불량 분류 사례 (1)

디스플레이 생산 시 패널의 경계가 애매한 화소 결함이 생기는데 이것을 Mura 라고 한다. Mura의 원인으로 는 제조 기계의 오작동, 제조자의 실수, 먼지, 필름의 불량으로 발생하는 디스플레이 불량 등이 있다. 이러한 결함을 검사하는 것을 디스플레이 Mura 검사라고 한다. 기존의 머신 비전을 이용한 Mura 검출 방법은 수많은 Mura 불량에 대해서 일일이 이미지를 취득하여 시험하고, 각각의 Mura 형식 별로 복잡한 검사 매개 변수를 조정하여 검사를 하는 방법을 하고 있다. 또한, 기존의 Mura와 다른 형태의 Mura가 발견되면 처음부터 다시 알고리즘을 검사해야 하는 단점이 있다. 비정형적인 mura 특성상 기존 규칙 기반 검사 방식으로는 한계가 있다. Mura Generator는 딥러닝 기반 검사기라서 학습만 해주면 된다는 점에서 간단하고 빠른 특징을 보여준다 [11]. 양품 이미지를 무라 모델링을 적용하여 딥러닝에 필요한 학습 데이터를 만들어내고, 또한 불량 이미지 생성 기법으로 딥러닝에 필요한 데이터를 스스로 만든다. 이렇게 되면 기존 규칙 기반 검사보다 개발/검토 시간이 빨라지고 양산 적용 시간이 최소화 된다. 또한 새로운 형태의 mura가 발견 됐다고 해도 처음부터 알고리즘을 검토할 필요 없이 최소 양품 이미지와 불량품 이미지를 이용하여 mura를 학습 시킬 수 있다 [15].

3.4.3. 딥러닝 기반 불량 분류 사례 (2)




Fig. 6 Ensemble model diagram for defect classification [3]

일반적으로 디스플레이 제조공정에 나타나는 결함의 형태, 크기, 위치가 다르게 나타나기 때문에 단일 CNN (Convolutional Neural Network) 분류 모델로는 판별 정확성을 확보하기 어렵다. 이 때문에, 그림 6에서 보여지는

Table. 2 Advantages due to AI use in case summary

Legacy/AI Classification	Legacy method	Problems in legacy method	AI use	Advantages in AI use
Process control Management Diagnostics	<ul style="list-style-type: none"> Actual measurement(Real Metrology) MES(Manufacturing Execution System)/POP(Point of Production System) 	The process result cannot be measured immediately due to the decrease in production and the increase in investment cost due to the increase in measurement steps and facilities.	VM(Virtual Metrology)	Limitations in the development of control, diagnostic and monitoring solutions are resolved.
Mobile facility	<ul style="list-style-type: none"> Wafer Transport Facility 	<ul style="list-style-type: none"> Increase in wafer transfer facilities due to Mega Fab Lack of data 	Reinforcement learning (Lack of data Caused use)	<ul style="list-style-type: none"> Shortened to tenths 4X more productivity
Process anomaly diagnosis	<ul style="list-style-type: none"> FDC (Fault Detection & Control) SPC(Statistical Process Control) ANOVA 	<ul style="list-style-type: none"> A complex cause of process abnormality occurs 	Multivariate Statistical Analysis	More sensitive to process anomalies
Fault Classification	<ul style="list-style-type: none"> Direct inspection by the operator Method of approaching machine vision Single CNN classification AOI(Automatic Optical Inspection) 	<ul style="list-style-type: none"> Easily tired eyes of inspectors Fine defects are not easily detected Detection performance varies according to condition Strong subjective judgment Lack of universal algorithms 	Deep Learning Algorithm Random Forest Model	<ul style="list-style-type: none"> The detection performance remains constant. Reduced manpower, time and cost involved in inspection

것처럼 복수의 CNN 분류 모델을 구성하고 복수의 CNN 분류 모델에서 얻은 결과를 취합해 최종 판정을 얻는 Random Forest 모델을 이용해 기존 결함 분류 방법인 단일 CNN 분류 모델 보다 성능을 개선할 수 있다. 이렇게 좋은 성능을 얻기 위해 다수의 학습 알고리즘을 이용하는 것을 앙상블 모델이라고 한다. 몇몇 CNN 분류 모델이 과적합을 보일 수도 있지만 복수의 CNN 분류 모델 기반으로 예측해 그 결과를 취합하기 때문에 그 영향력이 줄어들게 되어 좋은 일반화 성능을 보인다는 것이 장점이다 [3][15].

IV. 토 의

표 2는 앞서 설명하였던 AI/BIG DATA 접목 사례들에서 얻을 수 있었던 장점을 분석한 것이다.

생산 공정은 복잡해지고 고도화됨에 따라 기존 계측 설비(MES/POP 등)로는 공정에 대한 모든 데이터를 즉각적으로 피드백 받을 수 없는 상황이 되었고 VM을 이용해 데이터 부족에 대한 제한사항을 해결하게 되었다.

기존 웨이퍼 이동 설비의 증가 및 데이터의 부족 현상을 해결하기 위해 강화학습 알고리즘을 접목시켜 시간

단축과 생산성 증가 등의 이점을 확인할 수 있었다.

공정 이상 부분에서는 기존에 FDC 방식으로 실시간으로 수집된 데이터를 이용하여 설비의 장애를 빠르게 파악하여 극복했지만, 공정 이상이 복합적으로 발생하는 경우 이 장애를 해결할 수 없었다. 이를 해결하기 위해 조기에 이상을 감지 예측하는 모델을 이용한 다변량 통계분석이 도입되었음을 알 수 있었다.

패널의 제조 불량 검출을 위해 기존에는 작업자가 직접 육안으로 검사하는 방식을 사용했었다. 하지만 생산성 저하와 신뢰성 감소로 인해 AOI가 개발 되었고, 이 또한 불량의 특징을 정의하는 한계를 가졌다. 이러한 한계를 극복하기 위해 딥러닝 기술을 적용하여 불량의 특징을 스스로 만들어내고 학습을 통해 이 한계를 극복했다. 기존의 생산라인 또는 공정과정에 인공지능을 도입하여 향상된 검출 성능을 불러온다는 것을 확인 할 수 있었다.

AI/BIG DATA 기술이 사용된 공통적인 이유는 디스플레이 제조 공정이 기존보다 복잡해지고 고도화됨에 따라 관리, 제어, 이동설비, 공정 이상 진단, 결함 분류 등이 복잡해졌기 때문이다. 급격하게 기술이 발전하는 상황에서 앞으로는 현재의 공정 보다 복잡해질 것이고 고도화될 것이다.

보다 고도화된 AI/BIG DATA 기술 개발을 위해 많은 양의 데이터를 축적하는 것 또한 중요한 과제가 될 것이다. 이동설비 접목 사례 부분에서 언급한 데이터의 부족으로 강화학습 알고리즘을 사용한 사례로부터 하나의 방법론을 찾을 수 있다. 패널 결함 분류 분야는 딥러닝으로 해결될 수 있지만 패널 외관 부분은 딥러닝이 아닌 패널의 상하좌우 위치에 대해 고정값으로 검사 영역을 설정하는 방법을 이용한다. 패널 외관 결함 분류에도 딥러닝을 이용할 수 있게 된다면 시간과 비용을 줄일 수 있을 것이다.

V. 결론

디스플레이 제조공정, 공정이상, 분류, 이동설비 분야에 AI/BIG DATA를 접목한 사례에 대해 알아보고 기존 방법 대비 장점을 처음으로 분석 정리하였다. 위에서 살펴본 접목 사례뿐 아니라 포괄적인 디스플레이 제조에 스마트 팩토리 구축을 위해 방대한 데이터의 축적과 동시에 다양한 AI/BIG DATA 모델들이 개발 되어져야 한다. AI/BIG DATA를 접목한 디스플레이 제조 분야에 제시된 사례 분석이 보다 향상된 스마트 팩토리 개발을 위한 사전 지식으로 활용될 수 있을 것이다.

REFERENCES

- [1] H. Jang “A Study on Optimal Automation Level of the Smart Factory for Competitive Display Manufacturing,” *Journal of Korea Industrial and Systems Engineering*, pp. 191-193, 2019.
- [2] Smart Factory [Internet]. Available: <http://www.thelec.kr/news/articleView.html?idxno=3198>.
- [3] J. J. Hong and W. H. Jang, “Application of Big Data-based Machine Learning in Display Manufacturing,” *4th industrial revolution and smart plant*, vol. 36, no. 1, pp. 35-38, 2018.
- [4] J. H. Choi, “A review on prognostics and health management and its applications,” *Journal of Aerospace System Engineering*, vol. 8, no. 4, pp. 7-17, 2014.
- [5] S. J. Kim, B. H. Choe, and W. Kim, “Prognostics for Industry 4.0 and Its Application to Fitness-for-Service Assessment of Corroded Gas Pipelines,” *Journal of the Korean Society for Quality Management*, vol. 45, no. 4 pp. 649-664, Dec. 2017.
- [6] J. Jang and K. Kim, “PHM application case in Hybrid Vehicles,” *Mechanical Journal*, vol. 53, no. 7, pp. 35-39, 2013.
- [7] IT dong A [Internet]. Available: <https://it.donga.com/28165/>.
- [8] South Korean software company. UiPath [Internet]. Available: <https://www.uipath.com/ko/blog/smart-factory-and-rpa-1>.
- [9] An IT service company that provides SI services and optimal solutions. ComputerMate [Internet]. Available: http://www.computermate.co.kr/doc/solution1_2.php.
- [10] UNIFYSystems [Internet]. Available: <http://unify-sys.com/solutions-2/point-of-production/>
- [11] Professional media introducing advanced manufacturing industry. KIPOST [Internet]. Available: <https://www.kipost.net/news/articleView.html?idxno=10234>.
- [12] It is a South Korean company that is currently researching, developing, producing, and selling AI machine vision solutions. LAON PEOPLE [Internet]. Available: http://laonpeople.com/business/business_list2.php?s_dep=46#listCon_65.
- [13] Information Blog. Anyway Warabelle [Internet]. Available: <http://hleecaster.com/ml-random-forest-concept/>.
- [15] Web Magazine of Korean IT company nepes. SuperStar [Internet]. Available: <http://webzine.nepes.co.kr/?p=2467>.
- [14] WIKI/Automated_optical_inspection [Internet]. Available: https://en.wikipedia.org/wiki/Automated_optical_inspection.
- [15] Google Patents/To inspect the display panel [Internet]. Available: <https://patents.google.com/patent/KR101496993B1/ko>.



정석원(Sukwon Jung)

2015년 3월~현재 : 호서대학교 컴퓨터공학부 재학 중
※ 관심분야: 인공지능, 사물인터넷



임현국(Huhnkuk Lim)

2020년 3월~현재 : 호서대학교 컴퓨터공학부 조교수
2006년 3월~2020 2월 : 한국과학기술정보연구원 슈퍼컴퓨팅본부 책임연구원
2015년 3월~2020년 2월 : 과학기술연합대학원대학교 HPC 및 데이터과학 전공 교수
2006년 2월 : 광주과학기술원 정보통신공학과 박사
2001년 2월 : 광주과학기술원 정보통신공학과 석사
1999년 2월 : 항공대학교 전자공학과 학사
※ 관심분야: 사물인터넷, 엣지 AI, Vehicular NDN, 통신 컴퓨팅 융합