

석사학위논문

산업-IoT 기반 공장데이터 수집 분석을
활용한 불량 요인 예측 방법 연구

2018년

한성대학교 지식서비스&컨설팅대학원

지식서비스&컨설팅학과

컨버전스컨설팅전공

이 인 배

석사학위논문
지도교수 나도성

산업-IoT 기반 공장데이터 수집 분석을 활용한 불량 요인 예측 방법 연구

Study on the Prediction Method of Defect Factors Using
Industrial-IOT based Factory Data Collection & Analysis

2018년 6월 일

한성대학교 지식서비스&컨설팅대학원

지식서비스&컨설팅학과

컨버전스컨설팅전공

이 인 배

석사학위논문
지도교수 나도성

산업-IoT 기반 공장데이터 수집 분석을 활용한 불량 요인 예측 방법 연구

Study on the Prediction Method of Defect Factors Using
Industrial-IOT based Factory Data Collection & Analysis

위 논문을 컨설팅학 석사학위 논문으로 제출함

2018년 6월 일

한성대학교 지식서비스&컨설팅대학원

지식서비스&컨설팅학과

컨버전스컨설팅전공

이 인 배

이인배의 컨설팅학 석사학위 논문을 인준함

2018년 6월 일

심사위원장 _____(인)

심 사 위 원 _____(인)

심 사 위 원 _____(인)

국 문 초 록

산업-IoT 기반 공장데이터 수집 분석을 활용한 불량 요인 예측 방법 연구

한성대학교 지식서비스&컨설팅대학원

지식서비스 & 컨설팅학과

컨버전스 컨설팅전공

이 인 배

본 연구에서는 설비로부터 수집된 수많은 공정 변수에 대해 실시간으로 유입되는 IoT 데이터를 기계 학습을 통한 분석 및 예측하는 것이 생산 품질을 사전에 예측하고 불량을 발견하며 이에 따른 빠른 대응이 가능함을 제시하고자 한다. 현재 대다수의 공장에서는 제품의 품질 검사를 완제품 단계에서 진행하고 있으나, 불량률의 원인 파악은 오랜 경험을 통해 습득한 숙련공에 의해 발견되고 있으며, 이 또한 경험적이고 주관적인 감에 의존한 원인 분석일 수밖에 없으며, 제품의 품질 관리 능력이 제조 기업의 자산임을 감안할 때 객관적이고 지속 가능한 공정 데이터 관리는 기업 경쟁력의 원천이 될 것이다.

본 연구는 IoT 기술을 공장의 중요한 생산 설비에 적용하여 공장에서 발생하는 데이터를 최적으로 관리하고 운영하는 방법을 제시하며, 수집한 데이터가 품질에 작용하는 주요한 변수로 관리되도록 하는 방법 및 생산효율에 의한 제조 원가를 절감하고 품질 경쟁력을 향상시키는 IoT 기반의 스마트팩

토리 구축 기법과 데이터의 수집, 관리, 분석에 대한 방법을 제시하고자 한다.

또한 노후화된 설비가 대다수인 중소제조 공장에도 적용이 가능한 데이터 수집 및 저장 기술과 머신러닝 알고리즘을 활용함으로 설비의 실시간 모니터링과 제조 과정의 품질 이상 징후를 감지하여 사전에 불량을 예측하는 기술 및 방법에 대한 해법을 제시하고자한다. 이는 사물인터넷 환경에서 생산되는 각 종의 공정 설비로 부터 불량 요인을 발견하고, 사전 조치가 가능한 빅데이터 기반의 품질 예측 스마트팩토리 구축이 생산성 향상을 위한 제조 기술의 자산화 이며 기업의 무형 가치를 높일 수 있어 생산 혁신 부분의 해법이 될 수 있을 것으로 기대한다.

본 연구를 통해 설비로부터 발생 된 데이터의 특성 파악을 통한 고급 분석 기술을 적용함으로써, 최종 공정 이전에 품질 불량 인자를 발견하여 대응을 한다면 공정 수율 향상을 통한 제조기업의 이익을 기대할 수 있으며, 대기업 주도로 이루어지고 있는 스마트팩토리 확산을 중소, 중견 기업까지 진입장벽을 낮추어, 구축하고 확산 할 수 있도록 하여, 대기업-중소기업 간 기술 격차 감소 및 불균형 해소할 수 있을 것이다.

【주요어】 사물인터넷, 스마트팩토리, 제조혁신, 빅데이터, 머신러닝, 예측분석

목 차

I. 서 론	1
1.1 연구의 배경	1
1.2 연구의 목적	3
1.3 연구의 차별성	4
II. 이론적 배경 및 선행연구	5
2.1 IoT	5
2.1.1 IoT 산업의 전망	5
2.1.2 IoT 데이터 운영 인프라의 필요성	7
2.1.3 IoT 엣지 컴퓨팅 기술	7
2.1.4 IoT의 가치	8
2.2 4차 산업혁명과 스마트팩토리	9
2.2.1 4차 산업혁명 시대와 대한민국의 현 주소	9
2.2.2 스마트팩토리의 개념	11
2.2.3 스마트팩토리 구축의 목적	13
2.2.4 스마트팩토리 기반의 제조업 혁신	14
2.2.5 제조업 혁신 3.0	15
2.2.6 스마트팩토리 기대효과	16
2.2.7 스마트팩토리의 전망	17
2.3 사이버물리시스템(CPS)	18
2.3.1 사이버물리시스템의 개념	18
2.3.2 사이버물리시스템과 스마트팩토리	19
2.3.3 IoT와 CPS	20

2.4 IoT 기반 데이터 수집 및 저장 방법	21
2.4.1 IoT 플랫폼의 개념	21
2.4.2 IoT 기반 플랫폼의 포지션	23
2.4.3 IoT 엣지 게이트웨이를 활용한 설비 데이터의 수집의 다양한 방법	24
2.5 생산성 혁신의 이해	29
2.5.1 생산성 관리	29
2.5.2 손실 항목 체계	31
2.5.3 손실 체계에 따른 개선 활동 체계	31
2.5.4 생산성 향상 활동 3대 중점 관리 영역	33
2.6 빅데이터의 이해	40
2.6.1 빅데이터의 정의	40
2.6.2 빅데이터의 특징	41
2.6.3 빅데이터의 구분	45
2.6.4 빅데이터의 주요 기술 영역과 기술 요건	46
 III. 연구 방법	 48
3.1 공장 데이터 수집 및 응용 분석 기법	48
3.1.1 연구 공장의 사출 공정 데이터 관리 현황	48
3.1.2 사출공정 데이터의 수집 분석의 차별성	49
3.2 연구 데이터 수집 및 분석 절차	51
3.2.1 (1단계) 사출 성형 설비 데이터 수집	51
3.2.2 (2단계) 시계열 IoT 데이터의 저장	52
3.2.3 (3단계) 머신러닝 분석	52
3.2.4 (4단계) 모니터링 응용 소프트웨어를 통한 결과 시각화	55
3.2.5 사출성형기의 데이터의 수집, 저장, 분석 전체 구성도	54
3.2.6 IoT 네트워크의 구성	56

3.2.7 실험 서버의 사양	57
3.3 사출 성형 설비 공정 데이터의 수집 결과	58
3.3.1 사출 성형 1호기 , 2호기 수집 데이터 항목	58
3.3.2 사출 성형 3호기 수집 데이터 항목	59
3.4 IoT 데이터 분석	60
3.4.1 수집 설비 데이터의 머신 러닝 분석의 구성	60
3.4.2 불량 원인 분석의 과정	62
IV. 연구 결과	64
4.1 사출 불량 요인 분석 결과	64
4.1.1 사출 1호기의 의사결정나무 분석 결과	65
4.1.2 사출 2호기의 의사결정나무 분석 결과	66
4.1.3 사출 3호기의 의사결정나무 분석 결과	67
4.1.4 사출 2호기의 GAS 불량 프로파일 분석 결과	68
4.1.5 분석 데이터 모델의 검증	69
V. 결 론	70
5.1 연구결과 요약	70
5.2 연구결과에의 시사점	71
5.3 한계점 및 향후 연구방안	72
참 고 문 헌	73
부 록	79
ABSTRACT	82

표 목 차

〈표 2-1〉 부문별 IoT 설치 대수	5
〈표 2-2〉 손실 체계에 따른 개선 활동 체계표	32
〈표 3-1〉 서버 사양	57
〈표 3-2〉 사출 성형 1호기 , 2호기 수집 데이터 항목	58
〈표 3-3〉 사출 성형 3호기 수집 데이터 항목	59

그 립 목 차

〈그림 2-1〉 Hype Cycle for ICT	6
〈그림 2-2〉 4차 산업혁명 적응 국가 순위	10
〈그림 2-3〉 스마트 팩토리 개념도	13
〈그림 2-4〉 제조업 혁신 3.0	16
〈그림 2-5〉 스마트팩토리 도입에 따른 기대 효과	16
〈그림 2-6〉 세계 스마트팩토리 시장 규모	18
〈그림 2-7〉 국내 스마트 팩토리 시장 규모	18
〈그림 2-8〉 사이버물리시스템(CPS) 개념도	19
〈그림 2-9〉 사물인터넷을 활용한 사이버물리시스템 개념도	20
〈그림 2-10〉 IoT Platform의 개념도	22
〈그림 2-11〉 IoT 아키텍처 및 솔루션 포지션	24
〈그림 2-12〉 IoT 엣지 게이트웨이를 활용한 데이터 수집 방법	25
〈그림 2-13〉 IO Sensor Bridge	25
〈그림 2-14〉 PLC 인터페이스	26
〈그림 2-15〉 메모리 데이터 수집 흐름도	26
〈그림 2-16〉 Monitor 출력되는 DATA 수집	27
〈그림 2-17〉 LOG 발생 Data 수집	27
〈그림 2-18〉 RFID시스템 데이터 수집	28
〈그림 2-19〉 Barcode Data 수집	28
〈그림 2-20〉 각종 센서 DATA 수집 흐름	29
〈그림 2-21〉 손실 구조화의 진행 방법	30
〈그림 2-22〉 손실 항목 체계도	31
〈그림 2-23〉 생산성 향상 활동 3대 중점 관리 영역	33
〈그림 2-24〉 생산 공정 제조력	33
〈그림 2-25〉 사내의 관리력	37
〈그림 2-26〉 거래처의 공급력	39
〈그림 2-27〉 빅데이터의 3가지 특성	42

〈그림 2-28〉 빅데이터 V4+C1	44
〈그림 2-29〉 기존의 데이터와 빅데이터의 구분	45
〈그림 2-30〉 빅데이터 주요 기술 영역과 기술 요건	46
〈그림 3-1〉 연구 공장의 사출 공정 개요	48
〈그림 3-2〉 일반적인 사출성형 공정	49
〈그림 3-3〉 공정 데이터 수집 게이트웨이 구성도	51
〈그림 3-4〉 IoT 빅데이터 플랫폼 구성도	52
〈그림 3-5〉 머신러닝 도구의 구성도	53
〈그림 3-6〉 모니터링 응용소프트웨어 구성도	54
〈그림 3-7〉 사출성형기 IoT 구성도	55
〈그림 3-8〉 사출성형기 PLC	55
〈그림 3-9〉 IoT 네트워크 구성도	56
〈그림 3-10〉 프로토콜 표준화 모듈 구성도	57
〈그림 3-11〉 머신러닝 분석 구성도	61
〈그림 3-12〉 응용 분석 엔진 개념도	61
〈그림 3-13〉 예측분석 처리 흐름도	62
〈그림 3-14〉 1호기 RAW Data	62
〈그림 3-15〉 1호기 불량 결과 Data	62
〈그림 3-16〉 2호기 RAW Data	63
〈그림 3-17〉 2호기 불량 결과 Data	63
〈그림 3-18〉 2호기 RAW Data	63
〈그림 3-19〉 2호기 불량 결과 Data	63
〈그림 4-1〉 불량 요인 별 응용프로그램 분석 결과	64
〈그림 4-2〉 사출1호기 Decision Tree	65
〈그림 4-3〉 사출2호기 Decision Tree	66
〈그림 4-4〉 사출3호기 Decision Tree	67
〈그림 4-5〉 사출2호기 프로파일 분석 결과	68
〈그림 4-6〉 공정 데이터 학습 모델의 검증	69

I. 서 론

1.1 연구의 배경

세계 주요국이 제조업의 부흥을 위해 정책 강화에 주력하고 있지만, 국내의 제조업은 전문 제조 인력의 감소, 제조 원가 비용의 상승, 저 부가가치형 제조, 중소기업의 낮은 제조 효율 등 총체적이면서 만성적인 어려움을 겪고 있어 상대적으로 경쟁력을 점차 잃고 있다고 평가된다.

그리고 최근 제조 산업의 중요성이 일자리 문제 해결 및 글로벌 국가 경쟁력 측면에서 재확인됨에 따라 미국과 독일 등 선진국을 중심으로 스마트한 제조 혁신이 빠르게 진화하고 있는데, 이에 발마추어 우리 정부도 “제조 혁신 3.0”의 정책 아래 Smart Factory의 전략을 수립하여 국가 제조 혁신을 주도하고 있다.

지금까지는 무엇을 만들 것인가의 혁신에 집중하는 전략을 취하고 있던 국내의 제조 전략이었다면, 이제부터는 “제조 혁신 3.0”정책에 따른 글로벌 경쟁력을 높이고 어떻게 잘 만들 것인가의 혁신을 통해 제조업의 새로운 도약을 꿈꾸어야 할 것이다. 그러나 아직 초기 단계의 걸음마 수준이고, 짧은 기간에 제조 강국의 혁신 속도를 따라가는 것도 어렵겠지만, 이 정책을 가속화하고 조기에 경쟁력을 확보하기 위한 다양한 전략과 이에 따른 조치가 반드시 필요할 것이다.

정부 정책에 따라 제조기업의 생산성 향상 대책 및 스마트 공장 혁신 전략이 활발하게 추진되고 있다. 그럼에도 비교적 신규 장비 및 제조 설비 투자가 가능한 대기업의 경우 로봇 도입, 물류 자동화 등의 스마트 공장 구축 추진이 계획대로 되고 있지만, 중소기업의 경우 대기업 방식의 설비 투자는 매우 어렵고, 기존의 제조 설비의 수명이 남아있는 이유로 스마트 공장 구축 결

정 및 스마트 화에 따른 기대효과에 대해 여전히 주저하고 있는 현실이다.

지금까지 제조 현장은 전통적인 제어계측 및 설비 자동화 기술을 기반으로 생산성을 향상시키기 위해 꾸준히 노력해 왔다. 그러나 근래에는 ICT (정보통신 기술)가 제조 기술에 적용되면서 제조 산업의 큰 변화가 진행되고 있고 제조 업계에 스마트 한 바람이 불고 있다. 특히, 사물의 인터넷이 모든 생산 현장으로 확산되면서 경제적 효과가 높아 질 것으로 전망된다. (제조 산업의 27 %, 총 매출의 3.7 조 달러, 출처 : Cisco). 비록 이러한 변화가 미래에 다가 올 아직 먼 일처럼 보일 수도 있지만 이미 시작되었으며, 제조업이 과거 정보 통신 기술(ICT)의 급격한 변화만큼 따라오지 못한 점이 우려되더라도 변화의 물결은 우리의 생각보다 훨씬 앞설 것으로 예상된다.

연구 대상의 산업-IoT 스마트 공장에서는 현재 구축되어 있는 기존의 운영 설비를 신규 장비로 교체하지 않고 데이터를 수집하는 다양한 기술을 도입하여 작업자, 설비, 원재료, 방법 및 환경 요인 (4M1E)에 대한 빅데이터를 구축하고, 기록된 데이터를 분석하여 현장에서 객관적이고 신뢰성 있는 데이터에 의한 불량 발생의 근본적인 원인을 빠르게 발견하고 대응할 수 있는 방법을 제시하고자 한다.

1.2 연구의 목적

Smart Factory의 핵심 기술은 사물인터넷(IoT)과 빅데이터 이다. 센서와 제어장치 기술의 발전으로 모든 장치가 네트워크로 연결되어 시간과 공간의 제약 없이 실시간으로 모든 데이터를 공유할 수 있으며, 공장과 기업의 신속한 의사결정에 의한 운영 최적화를 위해 수집한 데이터를 분석하여 활용한다. 대표적으로 미국, 독일, 일본 등 선진국에서는 제조업 재 부흥을 위해 Smart Factory를 적극 도입하고 있으며, 국내의 경우에도 현실에 최적화 된 Smart Factory 구축을 위해서는 다음과 같은 구축 조건이 충족돼야 한다.

제조 생산 현장에는 설비(Machine), 작업자(Man), 공법(Method), 원부자재(Material) 및 환경(Environment)의 4M1E 요소에 의한 공정 및 품질 변수가 발생한다. 이 4M1E 변수는 생산 과정에서 불량률의 문제로 나타나기도 하는데, 이러한 문제를 인지할 수도 있지만, 인지 할 수 없는 문제가 더 많이 존재한다. 기계 고장, 제품 불량, 운영 지연, 설비의 효율성의 문제와 같은 명확한 문제에 대해서는 현장 기술자에 의해 관리나 대응이 가능하지만, 인지하기 어려운 수많은 문제에 의한 설비의 노후화 진행 상황, 설비 고장 주기 변화, 작업자의 설비 운영을 위한 처리, 원재료 성분에 따른 작업 표준 지시 값의 변화, 생산 품질에 영향이 될 수 있는 외부의 환경 조건과 같은 세부적인 데이터는 보이지 않기 때문에 문제 대응을 위한 근본적인 해결 방안을 찾아내기 매우 어려운 현실이다.

이러한 문제는 중소제조기업의 현장에서 생산성 및 설비 효율을 감소시키는 큰 원인으로 작용하고 있다. 4차 산업 시대에 중소 제조 현장의 문제를 해결하는 핵심적 요소는 기능 장인의 감에 의존하여 내재될 수 있는 문제 해결의 불확실성을 다루는 능력이며, 스마트팩토리를 위한 초석이라 할 수 있다. 본 연구는 이러한 문제를 4M1E에서 발생하는 제조 현장의 생산데이터를 산업-IoT 기술을 이용하여 체계적으로 저장, 분석하여 데이터 중심적인 의사결정 환경을 구축하는 방법을 제시하고자한다.

1.3 연구의 차별성

국내의 중소, 중견 제조 공장에 적용 가능한 IoT 기술을 공장의 중요한 생산 자산인 설비에 적용하여 최적으로 관리하고 운용하는 방법을 제시하고, 수집 한 데이터가 품질에 작용하는 주요한 변수로 관리되도록 하여, 생산효율에 의한 제조 원가를 절감하고 품질 경쟁력을 향상시키는 IoT 기반의 스마트팩토리 구축 기법과 데이터의 수집, 관리, 분석이 얼마나 중요한 기업 자산이 될 수 있는지에 대한 해법을 제시한다.

특히 고가의 패키지 솔루션 도입 없이 노후화된 설비가 대다수인 중소제조 공장에도 적용이 가능한 데이터 수집 및 저장 기술과 머신러닝 알고리즘을 활용함으로 설비의 실시간 모니터링과 제조 과정의 품질 이상 징후를 감지하여 미리 알려주고, 나아가 설비의 수명을 예측하는 기술 및 방법에 대한 해법을 제시한다.

본 연구를 통한 경제·산업적 측면으로는 설비로부터 발생 된 데이터의 특성 파악을 통한 고급 분석 기술을 적용함으로써, 최종 공정 이전에 품질 불량 인자를 발견하여 대응을 한다면 공정 수율 향상을 통한 제조기업의 이익을 기대할 수 있으며, 대기업 주도로 이루어지고 있는 스마트팩토리 확산을 중소, 중견 기업까지 진입 장벽을 낮추어, 구축하고 확산 할 수 있도록 하여, 대기업-중소기업 간 기술 격차 감소 및 불균형 해소할 수 있을 것이다.

사회적 측면으로는 스마트팩토리를 통해 얻게 되는 제조 기술의 자산화로 기업의 무형 가치를 높일 수 있고, 불요한 본 업무 외적인 요소를 제거하여 스마트팩토리 자체가 사람을 지원하는 생산 혁신 솔루션이 될 수 있을 것이다. 이는 저부가가치 단순 제조기술자에서 품질데이터 및 제조 기술의 지식 재산을 관리하는 고부가가치 산업 군으로 분류되어 질적 업무 환경이 개선되어, “인텔리전트 블루”라는 인식 제고로 청년 구직자의 제조업 포비아를 불식시켜 중소기업 지원자 증가 및 실업률 감소 기대 할 수 있을 것이다.

Ⅱ. 이론적 배경 및 선행연구

2.1 IoT

2.1.1 IoT 산업의 전망

2018년은 IoT와 산업용 IoT 기술이 주도할 것이다. 제품, 공정 프로세스, 워크 플로우에 IoT기술이 빠르게 통합되고 있기 때문이다. 2020년까지 200억대에 가까운 기기가 인터넷에 연결되고 IoT제품 및 서비스 공급 업체의 매출은 3천억달러에 이를 것이라고 한다(Gartner, 2017).

〈표 2-1〉 부문별 IoT 설치 대수 (단위: 백만 대)

부문	2016년	2017년	2018년	2020년
소비자	3,963.0	5,244.3	7,036.3	12,863.0
비즈니스 : 산업간	1,102.1	1,501.0	2,132.6	4,381.4
비즈니스 : 수직 산업	1,316.6	1,635.4	2,027.7	3,171.0
총계	6,381.8	8,380.6	11,196.6	20,415.4

자료 : Gartner, 2017

모든 것이 연결되는 산업 인터넷 공간은 기회의 땅이다. 상호 연결된 장치와 네트워크는 실시간 데이터 분석에 의한 피드백을 사용할 수 있을 것이며, 이처럼 IoT가 확산되면 업무 방식과 사람과 기기 간 소통의 방식에도 큰 변화가 있을 것이다. (Scott Gnau, Hortonworks 2018)


2018년은 IoT기술로 공장이 소프트웨어 주도 공장으로 빠르게 전환되는 해이다. IoT기술로 자동화, 오케스트레이션¹⁾, 데브옵스²⁾ 방식으로 운영할 수

1) 오케스트레이션(orchestration) : 기능적으로 높은 수준의 형식을 가진 자동화. 여러 컴포넌트로 이루어진 자동화 작업을 컨트롤하고 조정하는 작업.

2) 데브옵스(DevOps) : 고성능, 고품질의 소프트웨어에 대한 개발 생명주기를 보다 더 빠르게 관리하는 것을 가능하게 하는 개발에서부터 IT 운영에 이르는 팀 사이의 기술적 협력 문화

있게되며, 모바일 원격 모니터링에 의한 공장 관리가 대규모로 이루어지고 있다. 각 시설에 설치된 IoT센서의 데이터 기반의 통찰력을 활용하여 보다 합리적인 비즈니스 의사 결정을 내릴 수 있는 것이다. (Hitachi Vantara, 2018)

사물 인터넷(IoT)의 핵심 기술인 IoT플랫폼, 서비스, 보안 분야는 대중 인지도가 높은 편으로, 많은 실패 사례를 통해 기술 대중화를 위한 검증 단계의 기간에 있다. 이에 따라 사물 인터넷이 산업 전반의 가치 사슬에 미치는 영향은 급속히 확대되고 있으며, B2C 시장에 머물러있던 사물 인터넷이 4차 산업혁명의 핵심 기술로 발전하여 B2B 시장으로도 급속히 확대될 전망이다. 현재 사물 인터넷과 관련된 주요 기술의 위치는 미래 주요 제조업의 가치를 높이는 "기대 거품"의 정점에 있다. (정보통신기술진흥센터 주간기술동향 2017.12)



〈그림 2-1〉 Hype Cycle for ICT

자료 : Gartner, 2017

2.1.2 IoT 데이터 운영 인프라의 필요성

사물인터넷의 최종의 활용 목적은 센서 데이터를 단순히 수집하는 것이 아니라 실행하여 활용 가능한 정보를 얻는 것이다. 이를 위해서는 현재까지의 방식이 아닌 새로운 형태의 데이터 인프라가 필요하다. 사물 인터넷의 센서 기술이 발전함에 따라 수집된 데이터는 가치를 실현하는 데 사용될 수 있다.

사물인터넷을 도입하는 기업이 늘어나면서 실시간으로 사물을 추적 과정에 방대한 양의 데이터가 발생하는데, 이 방대한 양의 데이터를 제대로 활용하려면 데이터를 다양한 구조의 형식으로 결합해야 하며, 지속적으로 스트리밍 되는 데이터를 반복하여 자동으로 처리할 수 있는 기술이 필요하다. 그리고 데이터에서 실행 가능한 통찰력을 얻으려면 머신러닝³⁾ 및 딥러닝⁴⁾ 같은 보다 효과적인 데이터 분석 방법을 적용 할 필요가 있다. (Neil Barton, WhereScape CTO, 2017)

2.1.3 IoT 엣지 컴퓨팅 기술

산업 분야에서 사용하는 애플리케이션의 경우 일반 기업의 애플리케이션과 같이 중앙 집중화 방식의 데이터 저장과 처리하는 방식으로만 의존하는 것이 불가능하다. 산업 현장의 인프라는 무수한 이벤트에 즉각적으로 반응해야 할 필요성이 있는데, 원격 지 중앙 서버로 데이터를 전송 시 발생할 수 있는 병목현상에 영향을 받으면 큰 문제를 야기할 수 있다. IoT 연결기기는 파티션과 레이턴시 민감도에 따라 분류할 필요성이 있는데, 지속적으로 인터넷에 연결되어 있을 필요가 없는 기기가 있으며, 반면 몇 밀리 초의 지연만 발생해도 대형 참사로 이어지는 기기가 있기 때문이다. 이러한 이유로 실시간으로 이벤트에 대응하기 위한 엣지 단에 컴퓨팅 기술이 결합된 산업인터넷 아키텍처가

3) 머신러닝(Machine Learning) : 알고리즘을 이용하여 데이터를 분석하고 학습하며, 학습한 결과 기반으로 판단과 예측을 하는 기술

4) 딥러닝(Deep Learning) : 인공신경망에서 발전한 인공지능으로, 인간의 뉴런과 유사한 입출력 정보 계층을 활용해 데이터를 학습하는 기술

요구된다.(Nikhil Chauhan, GE, 2016)

2018년에는 산업 IoT의 엣지 컴퓨팅과 엣지 지능화 분석이 한층 더 탄력적으로 진행 될 것이다. 대다수의 이름 있는 하드웨어 제조 기업은 엣지 처리를 지원하는 제품군을 시장에 출시했으며, 이는 산업 IoT시장이 성숙했다는 의미인 것이다(Sastry Malladi, FogHorn Systems, 2017).

엣지컴퓨팅 플랫폼 기업인 포그혼의 CTO 사스트리 말라디는 전통적인 제조 업계에서 고객을 위한 중요한 개선사항을 발견하고 새로운 수입원을 만들어내기 위해 엣지 컴퓨팅 분석을 활용할 것으로 전망했다. 또한 제조 자산의 디지털화와 브라운 필드 방식의 운영 기업은 첨단 엣지 인텔리전스의 가치를 충분히 활용할 수 있다(한국IDG, 2018).

그리고 말라디는 "이러한 가치에 대해 예전에 실현되지 않았던 효율성 및 최적화를 활용함으로 실현할 수 있는데, 가치 있는 인사이트는 종종 머신러닝 분석을 통해서 발견되는 경우가 많다. 가스, 석유, 광산 등의 광 대역 접속에 제한이 있는 수직 산업에서는 엣지 컴퓨팅의 도움이 크다. 또한, 엣지 지능 분석을 적용하게 되면 실시간 의사 결정을 위한 도움을 받을 수 있으며, 방대하게 유입되는 센서 스트리밍 데이터로부터의 통찰력 또한 활용할 수 있다"라고 말했다.

2.1.4 IoT의 가치

2017년까지는 사물인터넷과 산업-IoT를 탐색하던 해로 개념적 증명과 연구 및 기능 구현이 증가했다. 2018년에도 이런 추세가 지속될 것이고, IoT 엣지 컴퓨팅 기술을 통해 얻을 수 있는 비즈니스 가치 인식도 높아질 것으로 기대된다(이민석, 2017).

현 시대는 컴퓨터 및 네트워크 기술과 모바일 장치의 발전에 힘입어 사물

과 사람 간의 모든 정보가 언제 어디서나 소통할 수 있는 사회적, 기술적 환경이 주어졌다.

그리고 이에 따른 사물 인터넷 기술이 산업 전반에 걸쳐 적용되고 상용화되기 시작하면서 새로운 서비스가 제공될 수 있는 기반이 마련됐다. 사물 인터넷은 "초 연결사회(Hyper Connected Society)"의 핵심 개념으로 사물과 사물의 연결, 사람과 사람의 연결 또한 사물과 사람을 연결하고 소통할 수 있는 환경을 제공하여 새로운 비즈니스의 가치를 창출한다. 사물 인터넷은 사물, 사람, 서비스의 세가지 분산 환경 요소에 대하여 감지, 네트워크, 정보처리와 같은 지능적인 관계가 사람의 개입 없이 서로 협력하여 형성되는 '사물 공간 네트워크'를 말한다. 이는 기존의 RFID⁵⁾, USN⁶⁾ 및 M2M⁷⁾의 확장 개념으로 네트워크를 통한 장치 간 연결을 기반으로 비즈니스 가치를 창출한다(주대영, 2014).

2.2 4차 산업혁명과 스마트팩토리

2.2.1 4차 산업혁명 시대와 대한민국 현 주소

4차 산업혁명은 미래가 아닌 현재 진행형이다. 2016년 세계경제포럼(WEF)은 다보스포럼에서 이제 우리는 제4차 산업 혁명의 시대로 돌입한다고 발표했다. 세계적으로 각 나라의 정부를 비롯한 기업, 교육기관 및 연구기관들은 4차 산업혁명에 집중하고 있으며, 빠르고 유연한 대응을 위해 많은 준비를 하고 있다(김승현, 김만진, 2016).

제조혁신을 4차 산업 혁명을 통해 이루려는 다른 나라들의 움직임에 비해 한국은 준비와 추진의 속도가 느린 모습을 보이고있다. 다보스포럼 기간 중

5) RFID : Radio Frequency IDenfication

6) USN : Ubiquitous Sensor Network


7) M2M : Machine to Machine

발표된 UBS 보고서(2016) 「Extreme automation and connectivity :

The global, regional, and investment implications of the Fourth Industrial Revolution」는 4차 산업혁명에 적절히 대응하고 있는 국가 순위를 소개한 바 있다. 종합순위에 따르면 OECD 주요 45개국 중 한국은 25위, 중국은 약간 뒤쳐진 28위를 기록하였으나, 5위를 기록한 미국과 영국, 12위의 일본, 13위인 독일 등의 주요국보다 많이 뒤쳐지는 상황이었다(인터비즈, 2018).

주요 영역별로 살펴보면 한국의 교육 시스템은 19위, 사회 간접 자본은 20위, 기술 수준은 23위로 상대적으로 양호한 수준을 보였지만, 법적 보호 부분은 62위, 노동 시장 유연성 부분은 83위로 상대적으로 취약한 부분으로 나타났다(UBS, 2016).

》 4차 산업혁명 적응 국가 순위



》 주요 영역별 4차 산업혁명 적응 국가 순위

	노동시장 유연성	기술 수준	교육 시스템	사회 간접자본	법적 보호
스위스	1	4	1	4	7
미국	4	6	4	14	23
영국	5	18	12	6	10
일본	21	21	5	12	18
독일	28	17	6	10	19
한국	83	23	19	20	62
중국	37	68	31	57	64

〈그림 2-2〉 4차 산업혁명 적응 국가 순위

자료 : “Extreme automation and connectivity : The global, regional, and investment implications of the Fourth Industrial Revolution”, UBS(2016)

2.2.2 스마트팩토리의 개념

스마트팩토리는 다음과 같이 정의할 수 있다. 기 제조업 생산제조 기술과 사물인터넷, 빅데이터, Cloud 컴퓨팅, CPS(Cyber Physical System) 등의 ICT⁸⁾ 기술을 융합하여 공장 내의 설비와 공정, 그리고 운영에 필요한 각 장치들이 상호 네트워크로 연결된 지능 제조 생산체계라고 할 수 있다. 그리고 모든 공정 데이터와 생산 정보가 실시간으로 수집, 공유, 활용되어 공장 간, 공정 간, 설비 간의 협업 운영되어 제품 생산에 최적화 운영이 가능한 공장이다(이규택, 2016).

스마트(Smart)는 데이터를 바탕으로 한 생각에 따른 합리적인 결정을 자동화하는 것으로 정의할 수 있다. 그러므로, 소프트웨어 및 하드웨어에 관해서 이야기 할 때 정보에 대한 처리 능력을 갖고 있다는 것과, 지금까지는 기대하지 못한 경로에 대한 정보 처리 능력을 가졌다는 의미이다. 이러한 지능형 스마트 제조 시스템의 시작은 현재의 상황을 정확히 파악하는 관점에서 방대한 데이터를 모으기부터 하는 것으로 센서, 사물인터넷, 네트워크의 적용이 필수이다(이대성, 2015).

또한 스마트 제조 기술 및 스마트팩토리는 제조업과 정보통신기술을 결합, 적용하여 설계 시점부터 공정 전 주기의 운영을 최적화 하는 제조혁신전략이며, 가장 큰 목적은 제조 과정에 발생하는 낭비와 손실이 없는 '최적의 제조 방법'의 구현이라고 할 수 있다(노상도, 2016).

(조용주, 2016)는 "공장의 제조 설비 시스템을 기반으로 하는 수직적 통합과 고객 요구 사항을 비롯한 제품 개발 Value Chain을 기반으로 수평 적 통합이 구현되는 공장"을 스마트팩토리 라고 말했다.

생산 시스템의 수직적 통합은 생산 효율을 높이기 위한 목표를 가지고 있

8) ICT : 정보 통신 기술 (Information & Communication Technology)

다. 제품이 생산되는 다양한 공정에 장치와 센서를 이용하여 신호(데이터)를 얻으며, HMI⁹⁾ 및 PLC¹⁰⁾ 등의 장비 제어 기술을 이용하여 생산 설비를 제어하고, 생산 공정을 관리하기 위해 MES¹¹⁾ 및 창고 관리를 위한 WMS¹²⁾와 ERP¹³⁾까지 전사적인 통합 시스템의 운영과 관리를 할 수 있는 개념이다.

수평적 통합(가치사슬)은 제품을 이용하는 기업 및 개인 고객의 요구 사항을 찾기 위해 충분한 시장 조사 및 세부적인 제품 기획 단계에서부터 제품 개발을 위한 R&D 설계 단계와 설계 이후의 제품을 생산하여 고객에게 제품이 전달되는 모든 과정을 포함하고 있다(황태곤, 2018).

스마트팩토리를 위한 수직적, 수평적 통합이 실현되려면 연결과 통합, End-to-End Engineering¹⁴⁾의 관점에서 소프트웨어와 하드웨어에 기반한 다양한 ICT 기술로 이루어져야 한다. IoT(사물 인터넷), CPS(사이버 물리 시스템), 빅데이터 등의 최신 기술을 바탕으로 더욱 정확하고 정밀한 수직적이고 수평적인 형태의 통합 구현이 가능 한 것이다.

수평 통합을 위한 기술에는 CAD, CAE, PLM과 같은 제품 설계 및 라이프사이클 관리 도구, 빠르게 프로토타입을 통해 시제품화가 가능한 3D 프린터, 실재의 공장과 가상의 공장을 연동하여 통합을 가능하게 하는 CPS 및 제조 프로세스를 분석할 수 있는 공정 시뮬레이션 등이 포함되며, 수직 통합을 위한 지원 기술에는 생산 시설로부터 많은 데이터를 수집 할 수 있는 스마트 센서 및 IoT 기술, 에너지 절감 기술, 생산 데이터 분석을 위한 빅데이터 기술 등이 포함된다.

9) HMI : Human Machine Interface

10) PLC : Programmable Logic Controller


11) MES : Manufacturing Execution System

12) WMS : Warehouse Management System

13) ERP (Programmable Logic Controller)

14) End-to-End Engineering (Siemens, 2015)

스마트팩토리를 간단하게 정의하면 IoT, CPS, 빅데이터와 같은 정보통신 기술과 제조 기술을 융합하여 공장의 모든 설비와 생산 공정 프로세스를 네트워크에 연결하고 모든 정보가 공유 소통할 수 있도록 하는 전사적인 가치 사슬에 모든 자원이 통합되는 생산체계를 말한다(임정일 김용운, 2015).



〈그림 2-3〉 스마트팩토리 개념도

자료 : 삼성KPMG 경제연구원, 2018

2.2.3 스마트팩토리 구축의 목적

스마트팩토리는 공정 작업자가 프로그램을 사용하여 생산 시설을 자동화하고 최적화 할 수 있는 유비쿼터스 생산 공간이다(권혁성 김준모 2015). 즉, 공장 자동화를 뛰어넘는 스마트팩토리는 제조업의 경쟁력을 높일 목적으로, 제조 공정의 전체 과정을 정보통신기술(ICT)로 통합하여 지능화 된 자동화의 비중을 높여 생산 효율을 높이고 제품의 불량률을 낮추는 등의 제조 생산 시스템을 최적화하는 맞춤형 공장을 목표로 한다(배병축, 2017).

4차 산업 혁명 시대에서의 스마트 팩토리는 기존 공장 자동화인 FA (Factory Automation) 수준을 훨씬 뛰어넘는 개념이며, 기획-설계-생산-유

통-판매 등의 제조 사업의 전 과정을 현재의 제조 기술과 차세대 디지털 신 기술을 융합하여 최소 시간과 비용으로 생산이 가능한 소비자 지향 적인 지능형 공장을 의미하고 있다. 한 개의 생산 라인에서도 다 품종의 제품 생산이 가능하고, 모듈화 기능을 통해 이전의 대량 생산 체계에서 개인 별 소량 맞춤 생산 체계로 변화될 것으로 보고 있다. 스마트 팩토리의 전환으로 제조업의 생산성이 획기적으로 향상 될 것으로 보이며, 에너지 절감의 효과와 인간 중심의 작업 환경 실현도 가능하다. 또한 가상 공간 및 원격지에서 제조 현장을 감시할 수 있을 뿐 아니라 제어까지 가능하기 때문에 효율적인 공장 관리가 가능하고, 이는 품질이나 원가 경쟁력의 강화로 이어질 것으로 예상된다(삼정 KPMG, 2018).

그러므로 스마트팩토리는 제조 생산 시스템을 보다 지능적이고 유연하며 효율적으로 최적화하여 생산 비용을 절감하고, 변화하는 외부 환경에 적극적으로 대체하고 고객 요구에 대한 능동적 대응으로 궁극적으로는 생산성을 향상시키는 것을 목표로한다(서창성, 2016).

2.2.4 스마트팩토리 기반의 제조업 혁신

많은 기업들이 제조 공정에 스마트팩토리를 도입함에 따라 제조 업계는 일대 혁명의 시대를 맞이하고 있다. 스마트팩토리를 위한 핵심 기반 기술에는 사물인터넷, CPS, 로봇, 엣지컴퓨팅, 3D프린팅, 사이버 보안 기술이 포함된다. 스마트 팩토리가 식품, 제약, 섬유, 화학, 철강, 자동차, 항공 등 다양한 제조 산업을 통해 도입되면서 생산성이 높아지고 새로운 디지털 기술을 이용한 소비자 서비스가 가능해 지고 있다(삼정KPMG, 2018).

스마트팩토리의 도입으로 제조업의 패러다임이 변하고 있다. 제조 공정의 디지털화가 가속화되어 실시간 맞춤 생산이 가능하며, 불량 및 재고율이 최소화되고, 인건비 또한 감소함에 따라 생산성 혁신의 결과를 나타내고 있다. 또한 제조 업체와 원부자재 공급 업체 간의 네트워킹으로 공급망 프로세스와

생산 라인 전반에 걸쳐 유연한 연결과 소통이 향상되고 있으며, 보안 분야 또한 생산 단계에서 요구되는 기계 및 부품과 같은 자산 보안에서, 공장에서 얻을 수 있는 빅데이터에 초점을 맞춘 사이버 보안으로 이동하고 있다.


2.2.5 제조업 혁신 3.0

국내의 제조업 혁신 3.0은 대한 소프트웨어, 사물인터넷 등의 ICT 기술과 융합을 통해 제조 생산의 전 과정을 지능화 및 최적화하는 것이며, 우리나라 정부의 전략은 민관 공동으로 2020년까지 1조원 규모의 재원을 만들어 1만 개의 IT, SW 역량이 부족한 중소기업 및 중견기업의 공장에 스마트팩토리 추진단을 통해 생산성 향상을 위한 스마트팩토리를 보급하는 것이며, 설비 투자 분야에서 가장 적합한 솔루션으로 조명 되고 있다(서창성, 2016).

또한 제조 혁신 3.0을 정의하는 것은 제조 산업과 정보 통신 기술이 융합되어 생산성과 효율성을 높여 제품의 경쟁력을 높이고, 빠른 기간에 새로운 제품을 만들어 신사업의 진출 기회를 만드는 것이다(배병축, 2017).

현재 우리나라 정부는 제조업 혁신 3.0을 통해 제조업 부흥을 위한 4대 추진방향과 13대 세부 추진과제를 시행중이다(김용운 등, 2016). 기본 방향은 IT와 SW의 융합을 통해 새로운 융합 산업을 창출하고, 새로운 부가가치를 창출하고, 선진국을 추구하고 리더십 전략으로 전환하고, 자체 제조 산업에 대한 경쟁 우위를 확보하는 것이다(박형욱, 2015).

신 융합 산업의 주도 전략인 제조업 혁신 3.0을 촉진하기 위해서는 중소기업의 가치 사슬 수준에 따른 기술 정책의 전문성과 글로벌 기술 개발에 대비한 핵심 기술 개발 우선 순위에 따른 상세한 실행 계획이 필요하다(박종만, 2015).



〈그림 2-4〉 제조업 혁신 3.0

자료 : 관계부처합동 , 2015

2.2.6 스마트팩토리 기대 효과

스마트팩토리의 구축은 지속 가능한 기업으로의 필수 적인 과정임을 확신시키는 것이 중요하다. 스마트팩토리를 구축할 때는 기존의 운영 방식과 생산 시스템을 완전히 바꿔야 하기 때문에 변화에 대한 내부 구성원들의 반발이 상상 이상일 수 있다. 특히 기존 관행에 따라 근무하는 작업자가 거부감이 더 높으며, 경영 부분에 있어서도 대규모 투자에 대한 위험이 있지만 QCD(Quality, Cost, Delivery) 경쟁력 확보의 결과로 나타난다(나형배, 2018).



〈그림 2-5〉 스마트 팩토리 도입에 따른 기대 효과

자료 : Deloitte, 2015

FA저널의 스마트 팩토리 도입 후 기대 효과에 대한 설문 조사 결과에서는 ‘효율성 향상 : 32.9%’로 가장 높게 집계 되었으며, ‘원가 절감 : 15.0%’, ‘품질 향상 : 13.0%’, ‘관리 원활 : 11.4%’, ‘가격경쟁력 향상 : 10.5%’, ‘인원 감축 : 6.0%’, ‘빠른 납기 : 4.5%’, ‘기타 : 6.7%’ 순으로 집계되었다. 스마트팩토리에서 추가적으로 제품 생산 라인을 설치하기보다는 기존 시스템의 업그레이드를 통해 제품 관리 및 생산 효율성, 상호 운용성에 대한 투자이기 때문에 도입 초기 단계에서는 큰 효과를 기대하기 어려울 수 있으나, 점진적으로 제품의 품질 관리의 효과를 기대할 수 있다(인더스트리뉴스, 2017).



2.2.7 스마트팩토리의 전망

글로벌 스마트팩토리 시장은 연간 평균 8.0% 대를 성장해 2018년에는 2,961억 달러의 경제적 가치를 창출할 것으로 예상된다. 스마트팩토리의 구축은 정보통신기술을 공급하는 시장과 장치 디바이스를 공급하는 시장으로 나뉜다. 정보통신기술을 공급하는 시장은 2016년에 1,451억 달러에서 2018년에는 1,705억 달러 규모의 성장을 전망하며, 장치 공급 시장은 2016년에 644억 달러에서 2018년에는 756억 달러로 성장을 전망한다(한국산업기술평가관리원, 2018).

지역별로 보면 아시아 스마트팩토리 ICT 공급 시장 규모는 2014년 367억 달러에서 2018년 555억 달러로 10.8% 성장 할 전망이다. 아시아 ICT 공급 시장의 성장은 주로 중국의 영향을 받고 있는 것이며, 중국 정부의 스마트팩토리 확장 정책에 기인하여 2016년 유럽과 2019년에는 미주 지역의 수요를 넘어설 것으로 전망된다. 유럽 등의 선진국들은 저출산 기조와 고령화에 따른 생산 잠재력 감소에 대응할 방침이고 중국 등의 신흥국들은 인건비 상승에 대응해 제조업 경쟁력을 강화할 것으로 보인다.

한국의 스마트팩토리 시장은 2012년 24억 달러에서 2018년 44억 달러로 급성장할 것으로 전망된다. ICT 공급 시장과 단말 공급 시장이 평균 11.6%,

8.9%로 성장하면서 스마트팩토리 공급이 빠르게 확대될 전망이다. 그러나 물리적 확장성과 가변성을 제한하는 자체 공장 생산 환경에 여전히 갇혀 있다. 또한 제조 분야에서는 해외 솔루션이 약 90%가 도입되어 있으며, 하드웨어와 소프트웨어에 대한 기초 연구 및 디지털 신기술을 구현하는 원천 기술을 확보하기가 어려운 실정이다.



〈그림 2-6〉 세계 스마트팩토리 시장 규모


〈그림 2-7〉 국내 스마트 팩토리 시장 규모

자료 : Markets and Markets, 삼정KPMG 경제연구원 재구성, 2018

2.3 사이버물리시스템 (CPS)

2.3.1 사이버물리시스템(CPS : Cyber physical System)의 개념

제조분야의 사이버물리시스템(CPS)은 Operation Technology(OT) 시스템, 즉 생산정보시스템(PLM, MES 등) 및 기업운영시스템(ERP, SCM, CRM 등)과 같이 정형화된 디지털 데이터로 구성된 IT시스템과 공정, 제조 설비와 같은 물리적 세계가 네트워크로 통합되어, 실제 제품 혹은 설비의 작동이 디지털 세계(사이버 공간)에서도 동기화되고, 축적된 데이터에서 도출된 패턴과 알고리즘에 의해 지능적으로 제어되는 시스템을 의미한다. 사이버물리시스템을 구현하기 위해서는 모든 사물들을 연결시키는 사물인터넷과 데이터를 통합적으로 수집하는 플랫폼, 자율적으로 의사결정을 지원하는 빅데이터 분석력과 인공지능 기술 등 다양한 기술이 요구된다.




〈그림 2-8〉 사이버물리시스템(CPS) 개념도

자료 : 삼정KPMG 경제연구원, 2018

2.3.2 사이버물리시스템과 스마트팩토리

사이버물리시스템(CPS : Cyber physical System)은 인간의 개입 없이 인터넷에 사물을 직접 연결하고 이를 기반으로 데이터를 수집, 분석, 제어하는 실시간 제어 분산 시스템, 사이버상의 정보를 처리하면서 현실의 움직임을 제어할 수 있는 시스템이다. 이것은 물리적 실체의 세계와 가상세계가 상호 연동되는 시스템이며, 스마트팩토리를 기반으로 하는 생산설비의 제조 공정부터 물류 인프라에 IoT 기술을 접목하여 서비스까지 통합한 형태의 시스템이다. 사이버물리시스템이 제조업에서 구현된 결과가 스마트팩토리라고 볼 수 있다.

사물 인터넷(IoT)과 네트워크를 통해 공정 프로세스와 설비에서 실시간으로 디지털 데이터를 수집, 저장하고 인공지능(AI)기능을 통해 현실을 분석한다. “인공 지능은 21세기에 전 산업에 침투할 새로운 전기가 될 것이다”라고 스탠포드대학교 앤드류 응 교수는 말했다. 100년 전 전기가 산업 전체를 혁명으로 바꾼 것처럼 인공 지능도 앞으로 많은 산업 분야에서 큰 변화가 될 것이다.



〈그림 2-9〉 사물인터넷을 활용한 사이버물리시스템 개념도

자료 : Industrie 4.0 Working Group. (2013)

2.3.3 IoT와 CPS

독일의 Industry 4.0은 제조업과 ICT를 융합하여 제조 생산 기계와 공정 및 물류, 서비스 시스템을 관리하는 산업 생산 시스템으로 사물인터넷(IoT) 기술을 기반으로 한다(심상석 2017).

스마트팩토리를 구성하는 요소 기술을 나누어 보면, 작업자 애플리케이션, 다양한 스마트센서, 자동화 기기로 구성된 장치 분야, 애플리케이션과 기기를 연결하는 플랫폼 기술로 나뉜다. 각각의 영역에서 ERP 및 MES와 같은 전통적인 정보 서비스 기술에서부터 산업인터넷, CPS와 같은 최신 첨단 기술에 이르기까지 다양한 기술이 상호 유기적으로 작용한다(월간엘세이프, 2018).

CPS 기반의 스마트팩토리는 시스템 네트워킹 내의 가상 환경과 실제 환경 간의 상호 작용을 통해 지능형 생산 프로세스가 가능하도록 한다(박형욱, 2015). 이를 통해 생산 장비는 프로그램된 공정뿐만 아니라 가공 자재와 공

장 내 정보의 상호 운용성을 어떻게 처리해야 할지 스스로 결정할 수 있다. 또한 가장 경제적인 비용으로 최고의 품질을 보장하며 가공이 가능하도록 여러 센서에서 수집한 빅데이터를 통해 프로세스 매개 변수의 최적 값을 선택할 수 있다(심상석 2017).


이에 따라서, 스마트팩토리는 스마트 빌딩, 스마트 교통, 스마트 그리드와 연동하여 제품 및 자재의 전주기 라이프 관리 시스템을 구축하게 되어, 제품 정보가 실시간으로 출하부터 폐기까지 공유되며, 보관된 모든 정보가 다시 생산 과정에서 공유되기 때문에 자원 효율의 극대화에 기여하게 된다(투테이에너지, 2016).

2.4 IoT 기반 데이터 수집 및 저장 방법

2.4.1 IoT 플랫폼의 개념

2.4.1.1. IoT 플랫폼

스마트 팩토리의 IoT 솔루션은 4M에서 발생하는 데이터를 엣지 게이트웨이 기술을 통해 센싱, 수집, 표준화, 분석하여 빅데이터 기반의 의사결정 및 원격 자동 제어를 가능케 하는 스마트 팩토리를 위한 응용 솔루션이다.



〈그림 2-10〉 IoT Platform의 개념도

자료 : 내부자료, IoT 솔루션

2.4.1.2. IoT 플랫폼의 특징

IoT 플랫폼은 IoT 기반의 스마트팩토리를 빠르게 구축하는 솔루션으로, 고속 통신 인프라에 의한 실시간 이벤트 처리가 가능하고, 빅데이터 수집과 분석에 의한 품질 예측 환경을 구축할 수 있다.

2.4.1.2.1 기계 데이터 수집

- 공정 및 설비 현황에 대한 스마트팩토리 표준 프로토콜 및 PLC 비표준 프로토콜의 머신 데이터를 수집한다.

2.4.1.2.2 데이터 표준화 정제

- 표준/비표준 프로토콜을 OPC-DA, OPC-UA, Modbus, SECS/GEM, MQTT 등의 산업용 표준 프로토콜로 변환하여 데이터 표준화 및 호환성을

확보한다.

2.4.1.2.3 지능형 공정 제어

- 빅데이터 처리 및 분석을 통한 지능형 장애 진단 및 효율적 생산 체계 수립이 가능하다.

2.4.1.2.4 데이터 분석 시각화

- 실시간 공정 운영에 필요한 데이터를 분석하여 모니터링이 가능하도록 한다.

2.4.2 IoT 기반 플랫폼의 포지션

최상위 레벨 4 단계에는 전사적인 비즈니스 계획 및 물류가 포함된다. 또한 공장 수준에서 생산 계획 및 운영 관리를 담당하며 ERP의 주요 목표 영역이다. 레벨 3 단계는 제품 생산 활동을 포함하는 제조 운영 시스템인 MES의 영역이다. 레벨 2와 레벨 1은 제조 현장과 실제 제조 공정을 관리하는 영역이며 공정 유형에 따라 컨트롤의 방법이 다르다. 레벨 0은 현장에서의 생산을 수행하는 기계적인 활동을 포함한다(이창수, 최경일, 2007). <그림 3-8은> ISA-95 Level에 대응하는 IoT 아키텍처의 포지션을 도식화 한 것이다.



ISA-95 : ANSI(American National Standard Institute: 미국표준협회)와 공동으로 표준화를 선도하고 있는 ISA에서 제안된 생산정보화에 필요한 표준화 모델 계층 구조

〈그림 2-11〉 IoT 아키텍처 및 솔루션 포지션

자료 : 내부자료, IoT 솔루션


2.4.3 IoT 엣지 게이트웨이를 활용한 설비 데이터의 수집의 다양한 방법

IoT 엣지 게이트웨이는 PLC 및 검측 센서의 시계열 데이터가 발생하는 시점에 데이터를 추출 및 수집, 산업표준 프로토콜(OPC/UA 등)로 표준화 하는 이벤트 기반 실시간 데이터 처리 장치이다.

공장에는 다양한 이 기종 운영설비의 인터페이스 및 통신 전송 규격(프로토콜)으로 데이터가 발생되고 있기 때문에 각기 다른 데이터를 엣지에서 필터링¹⁵⁾ 및 프로토콜 표준화하여 전사적 시스템 표준 인터페이스에 의한 다양한 산업솔루션과의 유연한 통합을 가능케 한다.

15) 엣지 필터링: 데이터가 발생하는 시점에 연결된 게이트웨이에서의 실시간 컴퓨팅(연산/로직)


IoT 엣지 게이트웨이는 다양한 검측측 설비 및 PLC 등에 연결하여 발생하는 데이터 수집 및 표준화가 가능하다.



〈그림 2-12〉 IoT 엣지 게이트웨이를 활용한 데이터 수집 방법

자료 : 내부자료, IoT 솔루션

2.4.3.1. IO Sensor Bridge: 장비의 센서신호를 Bridge(분배)하여 DATA 취득



〈그림 2-13〉 IO Sensor Bridge

자료 : 내부자료, IoT 솔루션


2.4.3.2. PLC Data Capture: PLC(Program Logic Controller)의 로직을 분석하여 발생하는 DATA 취득



〈그림 2-14〉 PLC 인터페이스

자료 : 내부자료, IoT 솔루션


2.4.3.3. Memory Capture: Windows 기반의 메모리에 저장되어 있는 DATA 취득



〈그림 2-15〉 메모리 데이터 수집 흐름도

자료 : 내부자료, IoT 솔루션


2.4.3.4. VGA Signal Capture: Monitor에 출력되는 DATA 취득



〈그림 2-16〉 Monitor 출력되는 DATA 수집

자료 : 내부자료, IoT 솔루션

2.4.3.5. Log Data Parsing: 장비에서 발생하는 Text파일 또는 Database 형태의 DATA 취득



〈그림 2-17〉 LOG 발생 Data 수집

자료 : 내부자료, IoT 솔루션


2.4.3.6. RFID Devices: RFID장치에서 발생하는 DATA 취득



〈그림 2-18〉 RFID시스템 데이터 수집

자료 : 내부자료, IoT 솔루션


2.4.3.7. 1D/2D Barcode: LOT 물류 DATA 취득



〈그림 2-19〉 Barcode Data 수집

자료 : 내부자료, IoT 솔루션

2.4.3.8. 각종 센서에서 발생하는 Multi DATA 취득



〈그림 2-20〉 각종 센서 DATA 수집 흐름

자료 : 내부자료, IoT 솔루션

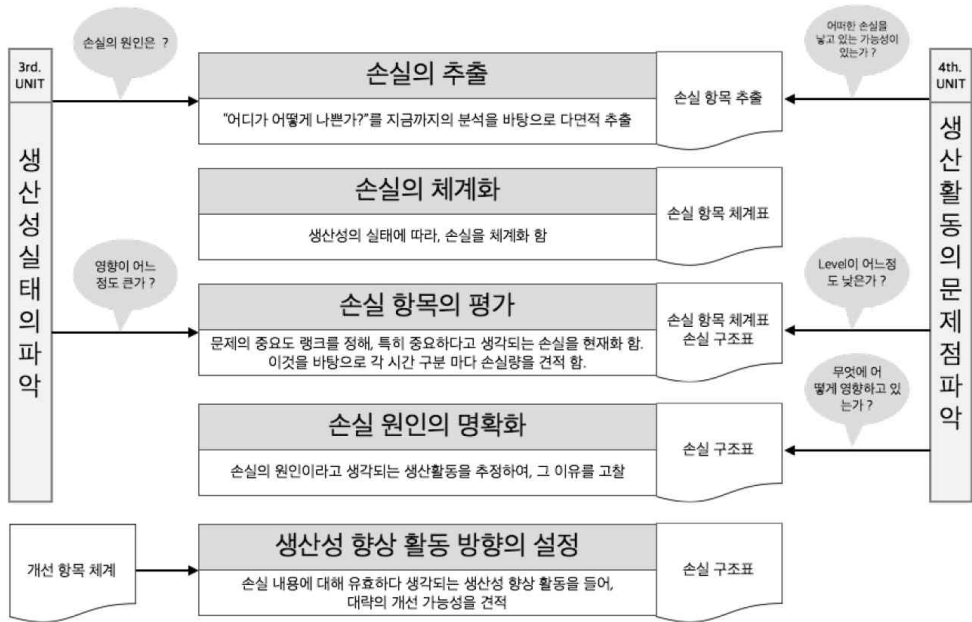
2.5 생산성 혁신의 이해

2.5.1 생산성관리

생산성관리의 목적은 기업의 생산성 악화의 실태와 원인과의 관련을 명확히 하여, 생산성 향상에 유효하다고 생각되는 활동을 설정하는 것이다. 이를 위해 손실의 구조화와 개선활동방향을 검토하는 단계로 구분할 수 있다.

이에 따르는 4단계의 진행방법은 손실의 실태를 현재화하기 위해 무엇을 보다 상세하게 조사, 분석할 필요가 있는지를 결정하는 손실항목의 체계화 작업, 손실 항목의 손실량의 크기를 평가하여 중대손실을 명확히 하고, 이것을 바탕으로 투입시간의 구성별로 그 손실시간을 견적하는 작업, 손실의 원인이 라고 생각되는 생산 활동의 내용을 추정하여 명확히 하는 작업, 3가지의 작업을 바탕으로 어떠한 생산성 향상 활동이 유효한가를 검토하여, 유효하다고 생각되는 활동을 투입 취업시간의 구분에 따라 명확히 하고 대략적인 개선 가능량을 견적한다.


다음은 손실구조화의 진행 방법을 도식화 한 것이다.



〈그림 2-21〉 손실 구조화의 진행 방법

2.5.2 손실 항목 체계

손실은 크게 비 실동 시간 손실과 무효 시간손실로 구분할 수 있으며, 비 실동 시간 손실은 간접시간 손실과 수대기 시간 손실로 분류되고, 무효시간 손실은 불량제작, 검토시간 손실과 Trouble 대책 시간 손실로 분류된다. 분류 별 세부 손실 항목은 아래와 같다.



〈그림 2-22〉 손실 항목 체계도


2.5.3 손실 체계에 따른 개선 활동 체계

〈표 2-2〉 손실 체계에 따른 개선 활동 체계표

손실의 체계			손실 실태 조사 방법	개선 활동
비실동 시간 손실	간접시 간 손실	직장 규율 철저 손실	직장 규율의 준수 상태 체크	직장 규율 개선
		간접 업무 과대 손실	간접 업무 실태 조사	간접 업무 효율 개선
	수대기 시간 손실	부품,재료 대기 손실	결품 실태 조사	생산관리 개선 거래처 지표 강화 부품,재료 공급 방식의 개선
		제품 대기 손실	공정 진도 준수율 조사	공정 관리 개선
		작업 대기 손실	M-M 분석 사람-사람 가동률 사람-설비 가동률 라인밸런스를	작업 환경 개선 설비 개선 부하 관리
무효 시간 손실	불량제 작/검토 시간 손실	설계 불량 손실	불량 실태 조사 (원인분석)	설계 변경
		부품,재료에 관한 불량 손실	불량 실태 조사 (원인분석)	거래처 품질관리 지도
		제조 공정 불량 손실	불량 실태 조사 (원인분석)	QA 매트릭스에 의한 품질 보증력 강화 / T형 매트릭스에 의한 공정품질 강화 공정 품질 설계 (FMEA) 현장 품질 개선 활동
	Trouble 대책 시간 손실	설비 Trouble 손실	설비 고장률 조사	TPM
능률 저하 시간 손실	작업의욕 부족에 의한 손실		능률 관리 진단 시트	생산성 관리, 목표 관리
	Pace Control 손실			흐름 작업화 개선
	기능 손실		Skill 진단 시트	현장 기능 교육
저 가치 시간 손실	운반 시간 과대 손실	찾는 시간 과대	5S 진단 시트에 의한 점수화	5S 철저
		이동 시간 과대	운반 경로 분석 (운반거리/1일)	가공 구획 편성 개선
		보관 시간 과대	운반 활성 분석	마태항 개선 가공 구획 편성 개선
	준비 교체 과대 손실	준비교체 회수 과대	제품 그룹 별 준비 교체 회수	생산 관리 개선
		준비교체 시간 과대	준비 교체 분석 작업 방법 진단 시트	싱글 준비 교체 개선 작업 개선 작업 표준화
	3대 손실			
비효율 시간 손실	가공 조건 부적절		설비 능력 조사 시트 (기준 능력, 현상 능력의 비교)	설비 개선
	가공 프로세스,설비의 부적절			


2.5.4 생산성 향상 활동 3대 중점 관리 영역

① 사내 생산 공정의 제조력 ② 사내의 관리력 ③ 거래처의 공급력



〈그림 2-23〉 생산성 향상 활동 3대 중점 관리 영역

2.5.4.1. 사내 생산 공정의 제조력의 생산성 향상 활동 테마



〈그림 2-24〉 생산 공정 제조력

다음은 생산 공정 제조력 부분의 생산성 향상 활동 테마의 목적을 설명한다.

2.5.4.1.1 생산 시스템 개발

대상 제품군을 전제로, 목표로 하는 CQD를 목적으로 한 생산시스템을 원점으로 돌려 설계하여, 현상의 생산 시스템을 기본적으로 검토한다.

- 자동화 , 신 가공 방식의 도입, In-line화

2.5.4.1.2 제조 VE

각 공정의 기능과 그 기능이 필요한 이유를 원점으로 돌려 추구하고, 공정의 기본적인 검토를 한다.

- 공정의 통폐합, 공정 기능의 신 가공 방식의 추구, 생산 설계의 검토

2.5.4.1.3 가공구획 편성 개선

대상 제품군의 가공형태, 생산량을 전제로, 가공의 그룹화, 가장 경제적인 흐름방법을 검토하여, 최적의 가공구획을 편성한다.

- 제품의 유사 층 별, 그룹 별 가공, Process Flow의 검토, 최적 가공 구획의 설정

2.5.4.1.4 Layout 개선

설비작업 영역 배치의 최적화를 검토하여, 노동생산성, 설비생산성, Space 효율, 운용 효율 등을 높인다.

- 근접성의 최적화, 공정 간의 Flexible화, 물류의 최소 경로화, 관리 심플화

2.5.4.1.5 흐름 작업화 개선

배치적 생산을 흐름작업화 하여, 페이스 안정화에 의한 작업능률 향상, 흐름의 단순화에 의한 운용효율 향상 등을 목적으로 한다.

- 라인밸런싱, 1개 흐름 검토

2.5.4.1.6 마테항 개선

각 공정을 연결하는 운반을 효율화 하여, 생산을 향상한다.

- 핸드링 회수의 최소화, 카라운반의 삭감, 운반 로트, 빈도의 최소화
우반 핸드링을 최소화 하는 Stock 방식 검토

2.5.4.1.7 설비 개선

설비생산성을 저해하고 있는 요인을 체계적으로 현재화하여 개선하고, 잠재능력을 향상하여 설비생산성을 향상한다.

- 설비능력의 최대 활용, 순간 정지의 개선, 실수 방지의 장비, CP의 향상, 가동 초기 유동 향상

2.5.4.1.8 싱글 준비 교체 개선

준비 교체 시간, 특히 내준비 교체, 시간의 최소화를 꾀하고, 설비의 가동률, 준비교체 작업의 생산성을 향상시킨다.

- 외준비교체화, 준비 교체 작업의 기능별 증별화, 표준화

2.5.4.1.9 작업편성 개선

작업의 특성, 볼륨을 고려하여 작업의 분담을 최적화하고, 작업 시간의 작업 밸런스를 적정화하여 대기시간을 최소화한다.

- Man Machine 분석, 연합 작업 분석, 다공정 대기, 다대 대기

2.5.4.1.10 작업 개선

작업의 로스를 배제하여, 효율적인 작업을 실현하여 노동생산성을 향상시킨다.

- 경제 동작의 철저, 치공구의 활용

2.5.4.1.11 작업 표준화

개선한 내용을 표준화하여, 철저히 함으로써, 효과적으로 신뢰성이 높은

작업을 실현한다.

- 표준화 항목의 명확화, 현장에 게시하는 표준 품 만들기, 표준을 유지하는 체제 만들기

2.5.4.1.12 현장기능 교육

대상의 제조부문에서 필요한 기능과 그 수준을 명확히 하여 계획적인 기술 향상 활동을 진행, 작업의 질을 높이고, 다기능공화를 추진한다.

- 필요한 기능의 체계화, 작업자의 기능 평가, 기능 수득 계획 입안, 기능 수준을 나타내는 마크 등의 설정

2.5.4.1.13 목표 관리

각 그룹의 목표를 명확히 하여, 항상 개선활동에 도전하고 착실하게 생산성을 높일 수 있는 체질을 만든다.

- 공장 목표에서의 각 부문의 목표에의 Breakdown, PDCA의 회전방법의 체제 만들기, 활동을 원활히 진행하는 코디네이트

2.5.4.1.14 5S의 철저

정리, 정돈, 청소, 청결, 습관화를 철저히 하고, 생산성을 높이는 전제가 되는 현장의 관리 상태를 만든다.

- 정치관리, 체크시트에 의한 체크 -> 액션의 체제 만들기

2.5.4.1.15 직장 규율 개선

기분 좋게 안전하게 생산성이 높은 직장을 만들어가는 제약을 철저히 한다.


- 지켜야 할 규율의 명확화, 서로 대화하는 체제 만들기

2.5.4.1.16 현장 품질 개선 활동

높은 품질을 창출하는 환경 만들기, 공정 능력의 유지, 실주방지 체제 만들기를 통해 현장의 품질을 만드는 힘을 높인다.

- 제조 관리 항목의 체계화, 각 관리항목의 관리방법의 설정, 불량실적의 파악과 액션, 실수방지 등의 연구의 철저

2.5.4.2. 사내의 관리력의 생산성 향상 활동 테마



〈그림 2-25〉 사내의 관리력

다음은 사내의 관리력 부분의 생산성 향상 활동 테마의 목적을 설명한다.

2.5.4.2.1 생산 관리 개선

수주에서 출하까지의 생산 PDCA를 관리하여, 생산 시스템을 생산성 높게 움직일 수 있도록 한다.

- 생산관리 방식 검토 (MRP, 간판 등), 기준 일정 계획의 입안, 기준 일정 계획과 자재 조달 계획, 공정마다의 생산계획의 연동

2.5.4.2.2 부하 관리 개선

각 공정, 설비의 보유 능력과 수주 공수를 항상 파악하여, 각 공정, 설비를 적절한 조업 Level로 유지한다.

- 보유 능력의 파악의 방법의 명확화, 공수 산정, 물의 확립

2.5.4.2.3 공정 관리 개선

각 공정을 연결하는 흐름을 컨트롤하여, 대기없는, 정체없는 흐름을 만든다.

- 기준 생산 일정과의 연동의 방법 검토, 공정간의 작업지시, 이동지시의 물화, 정보의 흐름과 물품의 흐름 일원화 (차립판, 간판, 생산관리판)

2.5.4.2.4 부품, 재료 공급 방식 개선

각 공정에 적기에 부품, 재료를 공급하는 체제를 만들고, Stock의 최소화, 대기의 제로화를 꾀한다.

- 출고형태의 최적화, 공급 방식의 검토, 표준 재공량의 명확화

2.5.4.2.5 생산성 관리 도입

생산 활동의 성과를 측정하는 정량적인 척도를 도입하여, 항상 스스로의 생산성의 수준을 의식하여, 더욱 높이기 위한 활동을 계속적으로 전개할 수 있다.

- 생산성 개념의 확립, 생산성 파악을 위한 기초 Data 만들기, PDCA 최적 방법의 설계와 현장에의 정착화

2.5.4.2.6 T형 매트릭스에 의한 공정품질 강화

공정불량 절감과 그 재발을 방지하기 위한 체제 만들기를 하고, 품질, 생산성을 높인다.

- 불량률의 원인 추구, 공정 불량재발을 방지하는 시스템 만들기

2.5.4.2.7 공정 품질 설계 (FMEA)

공정불량을 예측하여, 사전에 대책하는 체제 만들기를 하고, 제품 교체 시 혼란을 최소화한다.

- FMEA 기법의 활용

2.5.4.2.8 간접 업무 효율 개선

업무의 기능을 원점으로 하여 명확히 하고, 그 필요성을 추구함과 동시에,

최적의 방법을 검토하여 업무 효율화를 높인다.

- 간접 업무 기능의 체계화, 간접 업무 시간의 파악, 간접 업무의 효율화, 관점의 체계화와 개선안 입안

2.5.4.2.9 업무적인 시스템화


- 간접 업무 기능의 체계화, 간접 업무 시간의 파악, 간접 업무의 효율화, 관점의 체계화와 개선안 입안

2.5.4.2.10 규정 표준류의 정비

제조의 관리수준을 유지하기위해 필요하다고 생각하는 표준류의 목적, 가져야할 기능을 명확히 하여 정리한다.

- 필요규정 표준류의 일람화, 표준류의 품 설계, 표준류의 정비 실행

2.5.4.3. 거래처의 공급력의 생산성 향상 활동 테마



〈그림 2-26〉 거래처의 공급력

다음은 거래처 공급력 부분의 생산성 향상 활동 테마의 목적을 설명한다.

2.5.4.3.1 신규 거래처 생산력 지도 강화

협력 공장의 생산성을 높여, 능력 벉을 해소하고, Cost저감, 납기확보를 한다.

- 사내에서 생산성 향상의 방법을 효율적(단기에)으로 공장에 적용

2.5.4.3.2 생거래처 품질관리 지도 강화

협력 공장의 품질을, 협력 공장에 도입 일제히 향상하여, 안정한 품질의 부품·외주품의 공급을 할 수 있다.

- 사내에서 공정품질설계, 현장품질 설계의 방법을 협력공장에 효율적(단기)으로 적용

2.5.4.3.3 생QA 매트릭스에 의한 품질 보증력 강화

수입부품, 외주부품의 품질수준과 그것을 만들기 위한 Point를 명확히 하여, 품질보증 체제의 강화를 꾀한다.

- QA 매트릭스의 전개, 부품, 외주품의 평가방법의 확립

2.6 빅데이터의 이해

2.6.1 빅데이터의 정의

현재까지 빅데이터의 정의에 대해 합의 된 바는 없지만 맥킨지와 IDC는 빅데이터를 데이터베이스 크기와 성능에 중점을 두고 다음과 같이 정의하였다.

데이터베이스 시스템이 저장, 분석할 수 있는 범위를 초과하는 규모의 데이터로 규모에 대한 초점으로 빅데이터를 정의(McKinsey, 2011).

대규모 데이터에서 저 비용으로 가치를 발견하고, 다양한 종류의 데이터를 초고속으로 수집, 분석을 할 수 있도록 고안된 차세대 기술 및 아키텍처로 업무수행의 관점으로 빅데이터를 정의(IDC, 2011).

IDC 아시아 태평양 지역 총괄 부사장 필립 카터는 "빅 데이터 기술은 실시간으로 빠른 캡처, 검색 및 분석을 할 수 있어야 하며 다양한 데이터로부터 경제적 가치를 창출하도록 설계되어진 기술과 아키텍처이다" 라고 하였으며,

“이 분석 기술은 경제성과 안전성 및 현실성을 충족할 수 있는 실시간 또는 준 실시간으로 운영되는 것으로 정의한다” 라고 하였다(손종수, 2012).

2012년 가트너는 빅데이터의 정의를 다음과 같이 업데이트하였다. “빅데이터는 대용량(Volume), 고속(Velocity) 다양성(Variety)을 가진 정보 자산으로 의사결정의 개선, 통찰력의 발견 및 프로세스의 최적화를 위해 새로운 형태의 처리 방법이 필요한 것이다.” 그리고, IBM 및 몇몇 기관에서는 새로운 V를 빅데이터의 특징으로 신뢰성(Veracity)을 추가하였다(유선희, 2013).

빅데이터 기술은 기존 방식의 데이터 관리 및 분석 시스템으로는 불가능한 방대한 양의 데이터를 파악하는데 사용되는 기술이다. 허용되는 경과 시간 내에 데이터를 수집, 저장, 관리 및 처리함으로써 기업은 범용 하드웨어 환경 및 소프트웨어 툴의 범위를 벗어나 확장할 수 있다. 데이터의 규모가 방대하고(Volume), 다양한(Variety) 종류의 데이터를 융합하며, 수집/처리/분석/예측을 적시에 해결하는(Velocity) 빅데이터 기술은 기존 데이터 분석과 달리 빅주어진 형식의 정형 데이터뿐만 아니라 정제되지 않은 대량의 비정형 데이터에 대한 분석도 포함된다(안창원, 황승구, 2012).

2.6.2 빅데이터의 특징

빅데이터의 특징은 일반적으로 3V(Volume, Velocity, Variety)를 말한다. 이것은 데이터의 양, 데이터 생성 속도, 형태의 다양성을 의미하는 것으로 (O'Reilly Radar Team, 2012). 최근에는 가치(Value)와 복잡성(Complexity)을 포함하기도 한다.


이렇게 다양하고 방대한 양의 데이터는 미래의 경쟁력을 좌우하는 중요한 자원으로 활용될 수 있다는 점에 주시하고 있다. 과거에도 가치 있는 정보를 찾기 위해 많은 대용량의 데이터를 분석하려는 시도가 있었다. 그러나 현재의 빅데이터를 구성하는 환경은 품질과 다양성 및 양의 측면에서 과거와 비교

시 패러다임의 전환을 의미한다. 이러한 측면에서 빅데이터는 스마트혁명 시대에 경쟁력 강화 및 생산성 향상의 주요한 원천으로 인식되고 있다 (McKinsey, 2011).

빅 데이터는 온라인 시스템에 의한 활동이 증가함에 따라 발생하는 부산물로 데이터 저장소에 보관되기도 한다. 계량 데이터, 콜 센터의 통화 기록, 환경 데이터 감지 및 RFID 시스템과 같은 설비 대 설비 시스템 간 상호 작용도 방대한 양의 데이터를 생성하고 있다. 이렇게 다양한 종류의 데이터가 지속적으로 증가함에 따라 비정형 및 반정형 데이터 스트림이 증가하는 소셜 미디어가 부담을 가중시키고 있다(유선희, 2013).

기업, 기관 및 다양한 조직은 빠른 속도와 볼륨으로 생성되는 엄청난 양의 데이터로 인해 어려움을 겪고 있다. 일반적으로 조직은 통상 100 테라바이트 이상의 데이터를 대부분 보유하고 있으며, 어느 경우는 페타바이트를 초과하기도 한다. 미래 학자인 손톤 메이(Thornton May)는 2011 부터 6개월마다 두배 씩 데이터가 폭발적으로 증가할 것이라고 말했다(SAS, 2012).

그래서 빅데이터 정의 기준을 이야기하면 데이터의 양이 아닌, 지속적으로 증가하는 다양성과 속도, 가변성, 복잡성이라 할 수 있다.



〈그림 2-27〉 빅데이터의 3가지 특성

자료 : TDWI Research, Big Data Analytics Report , 2011

2.6.2.1. 다양성(Variety): 조직 내 데이터의 85%~90%는 숫자 형식이 아닌 비정형 데이터 이므로 정량적 분석 및 의사 결정 시 반드시 고려해야 한다. 궁극적으로 텍스트, 비디오, 오디오를 포함한 구조화되지 않은 비정형 데이터를 적절하게 분석하려면 다양한 아키텍처와 첨단 기술이 필요하다.

2.6.2.2. 속도(Velocity): 대량의 데이터를 실시간으로 처리해야 하는 필요성이 RFID 태그와 스마트 계측기 등의 사용으로 인해 지속적으로 증가하고 있다. 또한 높은 수준의 인사이트를 신속하게 도출해야 하기 때문에, 조직은 이러한 상황에 즉시 대응하는데 필요한 인프라와 기술 기반을 구축해야 하는 많은 부담을 안게 되는 것이다(Thornton May, 2011).

2.6.2.3. 가변성(Variability): 대용량 데이터가 빠르게 진행되는 것도 문제지만, 매우 가변적인 특성을 지닌 데이터 흐름이 더 큰 문제이다. 일일, 분기, 연간 및 실시간 이벤트를 처리할 때 발생하는 피크 로드(peak loads)는 매우 까다로운 관리영역이다.

2.6.2.4. 복잡성(Complexity): 원천 데이터의 유형이 증가함에 따라 기업 간 또는 시스템 간에 데이터를 연결하고 일치시키고 변환해야 하기 때문에 데이터 처리가 어려워진다. 따라서 관계 조직은 우선적으로 모든 데이터에 대한 복잡한 계층 구조 및 데이터 연결과 같은 관계를 충분히 이해해야 한다.

구분	주요 내용
규모 (Volume)	- 기술적인 발전과 IT의 일상화가 진행되면서 해마다 디지털 정보량이 기하급수적으로 폭증 → 제타바이트(ZB) 시대로 진입 - 기존 DB보다는 규모가 훨씬 크고 일정 기준으로 구분하지 않음
다양성 (Variety)	- 로그기록, 소셜, 위치, 소비, 현실데이터 등 데이터 종류의 증가 - 텍스트 이외의 멀티미디어 등 비정형화된 데이터 유형의 다양화 - 구조적 데이터와 비구조적 데이터를 포함하며, 다양한 구조의 데이터를 서로 연관해서 분석할 수 있어야함
생성속도 (Velocity)	- 사물정보(센서, 모니터링), 스트리밍 정보 등 실시간성 정보 증가 - 실시간성으로 인한 데이터 생성, 이동(유통)속도의 증가 - 대규모 데이터 처리 및 가치있는 현재 정보(실시간)활용을 위해 데이터 처리 및 분석 속도가 중요 - 배치, 리얼타임, 스트림형태, 실시간분석과 반응을 필요로 함
복잡성 (Complexity)	- 구조화되지 않은 데이터, 데이터 저장방식의 차이, 중복성 문제 등 - 데이터 종류의 확대, 외부 데이터의 활용으로 관리 대상의 증가 - 데이터 관리 및 처리의 복잡성이 심화되고 새로운 기법 요구 - 위의 3가지 특성에 따라 보관, 운영 활용하는 것이 매우 복잡함
가치 (Value)	- 새로운 가치의 창출과 관련된 것으로, 기존의 구조적 데이터는 거래를 안전하게 처리하기 위한 목적이었다면, 빅데이터는 경쟁력 및 운영 효율성에 직접적으로 큰 영향을 줄 수 있음 - 규모가 크고, 빠르며, 다양해서 복잡하지만 큰 가치를 지님

〈그림 2-28〉 빅데이터 V4+C1

자료 : SAS, 2012

2.6.3 빅데이터의 구분

기존의 데이터	빅데이터
기가바이트~테라바이트	페타바이트 ~ 엑사바이트
집중형	분산형
정형	반정형, 비정형
안정한 데이터 모델	평면 스키마(flat schemas)
알려진 복잡 상호관계	거의 알려지지 않은 복잡 상호관계
샘플	전수(전체)
과거	준실시간, 실시간
고비용	저비용
특정 유형(Text 위주)	모든 유형(소리, 영상 등)

〈그림 2-29〉 기존의 데이터와 빅데이터의 구분

자료 : 한국과학기술정보연구원, 2012

기존 데이터와 빅데이터를 <표 2-5>와 같이 구분할 수 있다. 규모의 관점으로는 페타바이트 ~ 엑사바이트 이상을 말하며, 관리의 방법 관점에서는 중앙 집중형이 아닌 분산형 관리 체계를 빅데이터라고 할 수 있다. 그리고 분석하려는 데이터가 전체 그룹의 표본인지 전체 인지가 주요한 구분 기분이며, 특히 대상 데이터가 수집 처리되는 데 비용이 많이 들지 않는지도 구분의 기준으로 요약할 수 있다.

2.6.4 빅데이터의 주요 기술 영역과 기술 요건

구분	현실적 문제점	기술 요구사항
수집	• 대용량의 수집 대상 데이터 • 적재시간이 전체 시간의 상당 부분을 차지 • 데이터는 지속적으로 증가함	• 대용량 데이터 수집 • 실시간 수집, 적재시간 단축 • 수평적 확장 용이성
저장	• 데이터 저장과 관리에 고비용 소요 • 저장된 데이터의 효율적 관리가 곤란 • 용량한계 봉착 시 확장 곤란(기술, 비용)	• 대용량 데이터 저장 • 수평적 확장 용이성 • 데이터 저장에 낮은 TCO 실현
처리	• 데이터 처리, 연산에 고비용 소요 • 장시간의 처리로 데이터의 적시성 부족	• 다차원 데이터의 고속 연산 • 다중 노드로 분산/병렬처리
분석	• 데이터 분석에 많은 연산 시간과 고비용 소요 • 통계적 분석 기법의 프로그램 구현과 검증 문제 • IT에 능통한 통계 및 분석 전문가의 부족 또는 부재	• 검증된 통계적 기법 기반의 고급 분석 • 실시간 또는 준 실시간 분석 • 사용자와 상호작용하는 탐색적 데이터 분석
표현/ 활용	• 분석된 빅데이터의 해석과 의미 파악 곤란 • 다차원 빅데이터의 효율적인 비교 분석 방법 부재	• 대용량 데이터의 요약적, 직관적 표현 • 다차원 데이터의 비교, 분석적 표현 • 실시간 인지 및 실시간 대응
관리	• 다수 장비로 구성된 인프라의 관리 곤란 • 각각 영역별로 특화된 다양한 기술요소들이 사용 • 오픈소스 기반인 경우 관리도구가 부족 또는 부재 • 처리, 분석관련 비즈니스로직이 분산되어 관리 곤란	• 오픈소스를 보완하는 관리도구 제공 • 통합 인프라 관리 체계(설치, 설정, 모니터링/관제 등) • 수집부터 활용까지 각 영역을 통합하는 비즈니스로직 관리 체계 제공

〈그림 2-30〉 빅데이터 주요 기술 영역 및 기술 요건

자료 : 데이터베이스백서, 2013

빅데이터 프로세싱 및 분석 기술은 개별 기술이 아닌 핵심 기술에 초점을 맞추는 플랫폼 기술이다. 주요 IT 기업들도 개발 영역의 확보와 보급을 위해 오픈 소스 소프트웨어 기반 솔루션을 전략적으로 출시해 플랫폼화 하고 싶어 한다. 빅데이터 분석 분야에서 플랫폼 전쟁이 벌어지고 있으며, Hadoop의 경우 운영 체제 시장에서 확고하게 자리 잡고 있는 Linux와 마찬가지로 빅데이터 플랫폼 시장의 주요 플랫폼으로 자리를 잡아가고 있다.

빅데이터 분석 플랫폼의 구성 기술은 데이터 수집 및 통합, 데이터 사전 처리, 저장, 관리, 분석, 예측, 가시화 이며. 빅데이터 시장에서 우위를 점하기 위해 빅데이터 처리 인프라 기술을 결합한 플랫폼 경쟁이 치열하다.

데이터 수집 및 통합 기술은 새로운 데이터 생성, 외부 데이터 수집, 내부 및 외부 데이터 소스 통합 등 데이터의 형태 및 구성에 관계없이 데이터를 얻는 기술이며, 데이터 전 처리 기술은 정보 감시, 소셜 네트워크 등에서 지속적으로 발생하는 비정형 스트림 데이터에 대한 분석 정확도와 데이터 깊이를 높일 수 있는 기술이다.

데이터 관리 기술은 웹, 소셜, 비즈니스데이터, 실시간 감지 정보와 같은 다양한 데이터 형식을 저장하고 관리할 수 있는 분산 컴퓨팅 기술이다.

빅데이터에 내재하는 가치를 창출 하려면 그래프 마이닝, 기계 학습, 인공지능 등을 활용한 심층 데이터 분석 기술이 필요하다.

데이터 시각화 기술은 비전문가가 데이터 분석을 자유롭게 수행할 수 있는 도구를 제공하는 기술과 직관적인 정보를 함축적으로 제공하는 인포그래픽 기술로 구성된다.

빅데이터 인프라 기술은 컴퓨팅 시스템 및 시스템 소프트웨어 기술로, 클라우드 컴퓨팅 및 패브릭 컴퓨팅과 같은 고성능, 고가용성 및 풍부한 성능을 제공하여 대량의 데이터를 안정적으로 처리할 수 있다.

Ⅲ. 연구 방법

3.1 공장 데이터 수집 및 응용 분석 기법

3.1.1 연구 공장의 사출 공정 데이터 관리 현황

연구 대상의 사출 제조 공장은 공정 장비의 자동화 수준이 높아 현장에서 설비 모니터링은 가능한 수준이나, 공정 설비 - MES - ERP - 품질관리 시스템으로 객관적 데이터의 연계, 수집 되지 않고 있다.

공정 기술의 노하우인 설비 가동 시 발생하는 각 종의 센싱 데이터 이력이 정량화 되어 수집 및 보관되지 않고 있어, 불량 발생 시 숙련 된 설비 기술자의 주관적 경험 치에 의존하여 원인 분석이 되고 있다. 이로 인하여 불량 의 원인이 되는 공정의 조건을 사전에 발견하기 어려워, 제조 후 품질 결과에 따라 사후 수습 정비 차원의 유지 관리 체계로 운영하고 있다.

현장에서 발생하는 설비 운영 데이터의 수집 또한 현장 작업자에 의해 주관적으로 관리되고 있어 데이터의 신뢰성 및 일관성이 부족하며, 설비운영조직 - 정보처리조직 - 품질경영 조직간 일치 된 의사결정 구조를 가질 수 없는 상황이다.




〈그림 3-1〉 연구 공장의 사출 공정 개요

3.1.2 사출공정 데이터의 수집 분석의 차별성

사출 성형 공정은 설정된 온도를 플라스틱 수지에 적용하여 수지를 용해하는 단계, 적량의 플라스틱 수지를 사출 성형 몰드에 주입하는 충전 단계, 수지가 수축하는 것을 보충하는 보압 단계, 취출 전의 냉각 단계, 성형품을 밀어내는 취출 단계로 나눌 수 있다. 사출 성형 공정에 관한 주요 연구 분야는 공정 변수 최적화에 관한 연구이다.

〈그림 3-2〉 일반적인 사출성형 공정



사출 성형은 생산할 제품의 형상이나 특성, 사출 성형기의 종류 및 성능, 원재료 특성, 설비 변수 설정 등이 모두 밀접하게 연관되어 있기 때문에 필요한 품질 수준을 맞추기 위해 공정 변수를 적시에 발견하는 것이 중요하다.

사출 성형 기술이 도입되면서 이러한 품질 수준을 충족하기 위한 방법으로, 생산 단계에서 양품 판별까지 시행착오 방식으로 공정 변수를 설정하여 초기에 불량품과 LOSS가 많이 발생하였다. 따라서, 생산 이전 단계에서 빠르게 최적화된 공정 변수를 찾아 시행착오 없이 양품을 생산하는 방안을 찾기 위한 연구가 많이 진행되었었다.


현재까지의 사출성형 관련 연구는 생산 이전 단계에서 실험계획 및 통계적 분석기법을 이용한 시뮬레이션 기법을 사용하여 최적 공정변수 도출 절차에 대한 연구가 주를 이루었으며, 또한 이제까지의 연구는 생산 단계 이전에 최적화하고자 하는 품질요소를 정의하여 공정에 최적화 된 변수 값을 발견하는 연구가 많이 진행되었었다.

하지만 본 연구에서는 사출 성형기와 IoT 기반의 게이트웨이와 PLC를 연결하여 설비 Sensor에서 발생하는 데이터를 실시간으로 연동 및 수집하고, 성형 공정 중 발생하는 작동 부분별의 압력, 시간 및 온도 데이터 등을 실시간으로 수집하여 생산 단계에서 발생할 수 있는 여러 가지 불량 및 불확실한 공정의 변수를 실시간으로 발견하여 비 숙련자라도 품질에 영향을 미치는 요인을 현장에서 발견 할 수 있는 실시간 머신러닝 품질 예측 프레임워크를 제안하고자 한다.

본 연구를 통해 생산 과정에서 발생하는 설비로 부터의 객관적인 품질 요인 데이터를 분석하여 제공하면, 이제까지 제품의 완성 시점에 발견할 수밖에 없었던 불량을 생산 중에 현장에서 즉시 발견할 수 있으며 불량의 원인 또한 발견 할 수 있으며, 수많은 양질의 품질 조건 변수들을 정확하게 발견할 수 있는 효과를 볼 수 있어, 실시간 데이터 기반의 스마트팩토리 구축 효과를 기대할 수 있을 것이다.

3.2 연구 데이터 수집 및 분석 절차


3.2.1 (1단계) 사출 성형 설비 데이터 수집



〈그림 3-3〉 공정 데이터 수집 게이트웨이 구성도

〈그림 3-5〉에서 표현된 것과 같이, 실시간 공정 데이터 취득을 위해 센서와 연결된 사출 성형기의 PLC와 게이트웨이를 연결하여 각 설비로부터의 공정 데이터를 실시간으로 수집하고, 데이터 분석을 위한 표준화 및 빅데이터 저장 시스템을 구축하였다. 설비 측정 센서로부터, PLC, HMI 등을 통해 설비에서 발생하는 운영 및 환경 정보를 이벤트 처리 장치를 사용하여 공정 데이터를 수집 및 표준화 하였다.

3.2.2 (2단계) 시계열 IoT 데이터 저장



〈그림 3-4〉 IoT 빅데이터 플랫폼 구성도


자료 : 내부자료, IoT 솔루션

IoT 빅데이터를 위한 공정 데이터 소스는 수집되는 주기와 양의 관점으로 보았을 때 시계열의 초고속 데이터를 수집, 처리 할 수 있는 IoT 빅데이터가 필요하다. IoT 빅데이터 구축 시, 기존의 레거시 시스템에서는 저장되지 않고 버려지는 데이터를 포함한 공정·설비·환경에서 생성되는 모든 데이터를 자동 수집, 기록하여 데이터의 자동전산화, 실시간 생산정보화 구축하여 제조기술의 데이터를 자산화 할 수 있으며, 데이터의 실시간 자동 수집 및 연동을 통해 생산관리문서를 자동 기록하고, 작업지시부터 포장·출고까지의 생산관리문서 전산화, 일원화, 통합화 할 수 있다.

3.2.3 (3단계) 머신러닝 분석

연구에 사용한 머신러닝 시스템의 기능 구성도이다. 사출 성형 설비의 내장 센서 및 PLC 모듈과 수집장치(게이트웨이)를 연결하여 발생 데이터를 IoT 플랫폼에 저장하며, 저장 된 데이터는 분석 소프트웨어를 통해 시각화

활용을 할 수 있는 시스템 구성이다.




〈그림 3-5〉 머신러닝 도구의 구성도

자료 : 내부자료, IoT 솔루션

빅데이터 머신러닝 분석기술을 통해 생산현장 데이터를 활용한 공정변수 실시간 대응과 품질 예측 및 분석 시스템을 구축하였다. 이를 통해 빅데이터 처리 및 분석을 통한 지능형 장애 진단 및 효율적 생산 체계 수립이 가능하며, 데이터 활용 관점으로 실시간 공정운영 모니터링과 빅데이터 분석에 기반한 실시간 의사결정 시스템과 실시간 공정 이상현상 파악 및 경고 시스템 구축이 가능하다.

연구 시스템의 IoT 빅데이터 플랫폼은 고속의 실시간 시계열 데이터베이스로서 머신데이터, 센서데이터 등의 시계열로 발생하는 데이터에 대한 빠른 저장에 특화된 빅데이터 솔루션이다. 각종의 설비 및 장치와 연계하여 데이터를 수집하는 단계에서부터 데이터와 장치의 상태를 분석하는 기능까지 스마트팩토리 구축에 최적화 된 데이터베이스 기능을 지원한다.

3.2.4 (4단계) 모니터링 응용 소프트웨어를 통한 결과 시각화




〈그림 3-6〉 모니터링 응용소프트웨어 구성도

자료 : 내부자료, IoT 솔루션

응용소프트웨어는 IoT 엣지에서 데이터를 수집 및 필터링하는 게이트웨이 단의 드라이버 소프트웨어, 각 게이트웨이에서 유입되는 데이터를 구조화 하여 빅 데이터베이스에 저장 및 조회 처리하는 IoT 운영 플랫폼의 응용소프트웨어, IoT 플랫폼을 운영 관리하는 관리자 소프트웨어, 현황 모니터링 및 분석 결과를 조회하는 사용자 모니터링 어플리케이션으로 구성되어 있다.

3.2.5 사출성형기의 데이터의 수집, 저장, 분석 전체 구성도



〈그림 3-7〉 사출성형기 IoT 구성도



〈그림 3-8〉 사출성형기 PLC


설비 데이터 수집을 위한 게이트웨이 장치는 IoT 기술이 적용 된 설비에서 생성되는 데이터를 근거리에서 수집·정제·제어할 수 있는 엣지 필터링 기술을 응용 하였다.

기존에는 IoT 환경에서 생성되는 데이터를 활용하기 위해서 이를 기업 내 또는 외부 데이터센터로 모으는 과정을 거쳐야 했으나, 엣지 기술은 실시간 동기화 기능을 통해 엣지(“끝”) 단에서 데이터 프로세싱을 지원한다.

허브(hub) 역할만 했던 기존의 게이트웨이와는 달리 IoT 디바이스(IoT가 적용된 기존 설비) 인접에서 데이터를 수집, 정제, 표준화 처리한다. 또한 네트워크 환경에 따른 지리적·물리적 제약에서 벗어나, 중앙 및 인접 클러스터


간 상호 유기적인 연계가 가능하며, 필터링 기능으로 인해 데이터 발생 단계에서 표준화 처리가 가능하여 다양한 프로토콜 및 인터페이스를 가진 데이터 발생 장치로부터 데이터 수집이 가능하다.

3.2.6 IoT 네트워크의 구성



〈그림 3-9〉 IoT 네트워크 구성도

연구 시스템의 네트워크는 TCP/IP 기반의 이더넷 네트워크로 구성을 하였으며, 사출 성형 설비의 PLC에서 HMI로 전송되어지는 RS-232 프로토콜의 데이터를 엣지 게이트웨이에서 수신하여 산업 표준화 프로토콜인 OPC-UA로 변환 후 IoT 플랫폼 서버로 전송되어 지는 구성이다. 연구 시스템은 ERP, MES, SCM 등의 기간계 시스템과는 분리 되어있는 네트워크망에서 운영되도록 하였다.



〈그림 3-10〉 프로토콜 표준화 처리 구성도

자료 : 내부자료, IoT 솔루션

3.2.7 실험 서버의 사양

다음은 연구 시스템에 사용된 하드웨어 사양표이다.

〈표 3-1〉 서버 사양

사양	수량
E5-26xx 1Processor (2.4GHz)	1대
RAM 32GB(4GB x8)	
SSD 240GB x2	
HDD 1.2TB SAS x6	
RAID H730	
1U2.5" 8bay	
Rack 12U	1대
Giga Network Switch	1대

3.3 사출 성형 설비 공정 데이터의 수집 결과

제조 품질 분석을 위한 데이터는 설비로부터 추출할 수 있는 지시 값을 IoT 통합 수집 장치로 수집하거나, 또는 생산 현장의 실제 환경 및 현황 데이터를 수집하기 위하여 회전수, 온도, 압력 등 각종 센서 네트워크를 포함하는 IoT 장비로부터 수집하였다. 총 3종의 사출기에서 발생하는 공정 데이터를 수집하였으며, 1호기와 2호기는 순번과 불량코드를 제외한 23종의 데이터를, 3호기는 순번과 불량코드를 제외한 18종의 운영 데이터를 수집하였다.

각 사출기로부터 제조된 제품 각 2,000건에 대해 전수 검사를 진행했으며, 1호기와 2호기는 4가지 유형의 불량 항목을, 3호기는 6가지 유형의 불량 항목으로 검사 결과를 기록하였다.

3.3.1 사출 성형 1호기, 2호기 수집 데이터 항목

〈표 3-2〉 사출 성형 1호기, 2호기 수집 데이터 항목

순번	수집 데이터	비고
1	ProcessNumber	공정횟수
2	InjectionTime	사출시간
3	MeasuringTime	계량시간
4	ProcessTime	공정시간
5	FormcloseTime	형폐시간
6	CusionLocation	쿠션위치
7	SwitchoverLocation	보압절환위치
8	MeasuringCompleteLocation	계량완료위치
9	MaxInjectionSpeed	최대사출속도
10	MaxScrewSpeed	최대스크류속도
11	AverageScrewSpeed	평균스크류속도
12	MaxInjectionPressure	최대사출압력
13	SwitchoverPressure	보압절환압력
14	MaxBackPressure	최대배압

15	AverageBackPressure	평균배압
16	OilTemperature	유온온도
17	HopperTemperature	호퍼입구 온도
18	LongNozzleTemperature	장노즐 온도
19	NozzleTemperature	노즐 온도
20	Heater1	히터1 온도
21	Heater2	히터2 온도
22	Heater3	히터3 온도
23	Heater4	히터4 온도
24	FormOpenLocation	형개완료위치
25	Faulty	불량코드

품질 검사 불량 코드

- 0 : 정상
- 1 : GAS
- 2 : 수축
- 3 : 이물
- 4 : 찌힘

3.3.2 사출 성형 3호기 수집 데이터 항목

〈표 3-3〉 사출 성형 3호기 수집 데이터 항목

순번	수집 데이터	비고
1	쇼트수(회)	Seq
2	사이클(s)	Cycle
3	사출(s)	Injection1
4	계량(s)	Measuring1
5	쿠션(mm)	Cusion
6	보완(mm)	Supplement
7	사출(kgf)	Injection2
8	보절(kgf)	Switchover1
9	배압(kgf)	BackPressure

10	계량(mm)	Measuring2
11	사출(mm)	Injection3
12	보절(mm)	Switchover2
13	형개(s)	FormOpen
14	형폐(s)	FormClose
15	계토크(%)	Torque
16	보절(mm/s)	Switchover3
17	형내(kgf)	FormInside
18	예비2	Reserve2
19	예비4	Reserve4
20	불량명	Faulty

품질 검사 불량 코드

- 0 : 정상
- 1 : GAS
- 2 : 기포
- 3 : 미성형
- 4 : 이물
- 5 : 찍힘
- 6 : 흑점


3.4 IoT 데이터 분석

3.4.1 수집 설비 데이터의 머신 러닝 분석의 구성

빅데이터 플랫폼에서는 게이트웨이를 거쳐 표준화한 공정설비, 환경 등의 데이터를 학습데이터(training set)와 검증데이터(validation set)로 분류, 머신 러닝 분석엔진의 반복학습을 통해 최적의 데이터 모델을 구성하였다.


분석의 결과는 현재 생산중인 실시간 공정 작업의 예상 결과 값을 모니터링 하는데 활용하거나(품질데이터 모니터링), 가상으로 임의의 측정값 또는

지시 값을 변경하면서 시뮬레이션 결과 값을 예측(가상 품질 예측)하여 데이터에 기반 한 실시간 의사결정 지원이 가능하다.




〈그림 3-11〉 머신러닝 분석 구성도

자료 : 내부자료, IoT 솔루션



〈그림 3-12〉 응용 분석 엔진 개념도

자료 : PTC ThingWorx Analytics, 2017



〈그림 3-13〉 예측분석 처리 흐름도

자료 : PTC ThingWorx Analytics, 2017

3.4.2 불량 원인 분석의 과정

3.4.2.1. 전 처리 (학습)

품질 공정 분석 머신 러닝 S/W의 구성은 분류 (classification) 모형, 예측 (prediction) 모형, 요인분석(factor analysis) 등의 모델링을 위해 생산정보데이터, 품질검사데이터, 생산 공정 데이터를 통합하는 전 처리 작업 수행하였다.

3.4.2.1.1. 사출 성형 1호기 수집 데이터 시료 2,000건 전 처리 과정

ProcessNumber	InjectionTime	MeasuringTime	ProcessTime	FormCloseTime	CustonLocat
2000	3.95	11.31	55.2	2.82	10.5
1999	3.98	11.40	55.5	2.83	10.5
1998	4.07	11.44	55.5	2.83	10.5
1997	3.94	11.32	55.2	2.81	10.5
1996	3.94	11.32	55.2	2.81	10.5
1995	3.96	11.35	55.2	2.81	10.5
1994	3.96	11.35	55.2	2.81	10.5
1993	3.96	11.35	55.2	2.81	10.5
1992	3.97	11.36	55.2	2.82	10.5
1991	3.97	11.36	55.2	2.82	10.5
1990	3.97	11.37	55.3	2.82	10.5
1989	3.98	11.37	55.3	2.82	10.5
1988	3.97	11.37	55.3	2.82	10.5
1987	3.99	11.36	55.3	2.81	10.4
1986	4.11	11.43	55.4	2.82	10.5
1985	4.01	11.43	55.4	2.82	10.5
1984	4.01	11.43	55.4	2.82	10.5
1983	4.02	11.43	55.4	2.82	10.5
1982	4.03	11.44	55.5	2.83	10.5
1981	4.03	11.44	55.5	2.83	10.5
1980	4.05	11.44	55.5	2.83	10.5
1979	4.06	11.44	55.5	2.83	10.5

〈그림 3-14〉 1호기 RAW Data

불량 Shot	10	81	151	239	375	400	465	477	508	518
이름	6	7	8	9	122	154	282	273	337	470
수측	215	219	220	261	263	264	266	267	268	269
특징	271	368	672							

공정특수	사출시간	계량시간	공정시간	형제시간	부연위치	보안원형위치	계량원형위치	최대사출속도
(ps)	(s)	(s)	(s)	(mm)	(mm)	(mm)	(mm/s)	
2000	3.95	11.31	55.2	2.82	10.5	18.5	74.9	19.3
1999	3.96	11.40	55.5	2.83	10.5	18.5	74.9	19.3
1998	4.07	11.44	55.5	2.83	10.5	18.5	74.9	19.3
1997	3.94	11.31	55.2	2.81	10.5	18.5	74.9	19.3
1996	3.94	11.32	55.2	2.81	10.5	18.5	74.9	19.3
1995	3.96	11.35	55.2	2.81	10.5	18.5	74.9	19.3
1994	3.96	11.35	55.2	2.81	10.5	18.5	74.9	19.3
1993	3.96	11.35	55.2	2.81	10.5	18.5	74.9	19.3
1992	3.97	11.36	55.2	2.82	10.4	18.5	74.9	19.3
1991	3.97	11.36	55.2	2.81	10.4	18.5	74.9	19.3
1990	3.97	11.37	55.3	2.82	10.5	18.5	74.9	19.3
1989	3.98	11.37	55.3	2.82	10.4	18.5	74.9	19
1988	3.97	11.43	55.3	2.82	10.4	18.5	74.9	19.3
1987	3.99	11.36	55.3	2.81	10.5	18.5	74.9	19.3
1986	4	11.41	55.4	2.82	10.5	18.5	74.9	19
1985	4.01	11.43	55.4	2.82	10.5	18.5	74.9	19
1984	4.01	11.4	55.4	2.82	10.5	18.5	74.9	19
1983	4.02	11.39	55.3	2.82	10.5	18.4	74.9	19
1982	4.03	11.4	55.4	2.82	10.6	18.5	74.9	19
1981	4.03	11.36	55.3	2.82	10.4	18.5	74.9	19
1980	4.05	11.37	55.4	2.83	10.6	18.5	74.9	19
1979	4.06	11.42	55.5	2.83	10.5	18.5	74.9	18.6

〈그림 3-15〉 1호기 불량 결과 Data

3.4.2.1.2. 사출 성형 2호기 수집 데이터 시료 2,000건 전 처리 과정

```
ProcessNumber,InjectionTime,MeasuringTime,ProcessTime,FormCloseTime,CusionLocation,
erPressure,MaxBackPressure,AverageBackPressure,OilTemperature,HopperTemperature,Long
2000,3.94,11.35,55.2,2.81,18.5,18.5,74.9,19.3,69.64,68.6,68.1,22.16,1.38,6.55,5.2
1999,3.94,11.35,55.2,2.81,18.5,18.5,74.9,19.3,69.64,68.6,68.1,22.16,1.38,6.55,5.229
1998,3.96,11.35,55.2,2.81,18.5,18.5,74.9,19.3,69.64,68.6,68.1,22.16,1.38,6.55,5.229
1997,3.95,11.35,55.2,2.81,18.5,18.5,74.9,19.3,69.64,68.6,68.1,22.16,1.39,1.55,8.22
1996,3.96,11.34,55.2,2.81,18.4,18.5,74.9,19.3,69.64,68.6,68.2,21.9,16.1,39.3,55.7,2
1995,3.97,11.35,55.2,2.82,18.4,18.5,74.9,19.3,69.64,68.6,68.1,21.9,16.1,39.5,55.7,2
1994,3.97,11.35,55.2,2.81,18.4,18.5,74.9,19.3,69.62,68.5,68.1,22.3,16.39,6.55,7.229
1993,3.97,11.37,55.3,2.82,18.5,18.5,74.9,19.3,69.64,68.6,68.1,22.8,16.1,39.9,55.7,2
1992,3.96,11.37,55.3,2.82,18.4,18.5,74.9,19.3,69.63,68.7,67.9,22.16,1.40,2.55,8.229.9
1991,3.97,11.43,55.3,2.82,18.4,18.5,74.9,19.3,69.64,68.4,67.8,21.8,16.4,4.55,6.229
1990,3.99,11.36,55.3,2.81,18.5,18.5,74.9,19.3,69.63,68.4,67.9,21.8,15.9,48.6,55.7,2
1989,4.11,41.55,4.2,82,18.5,18.5,74.9,19.69,63.68,3.67,9.21,8.16,1.40,8.5,5.7229.9
1988,4.81,11.43,55.4,2.82,18.5,18.5,74.9,19.69,63.68,4.67,8.21,8.16,1.41,55.6,229.9
1987,4.81,11.44,55.4,2.82,18.5,18.5,74.9,19.69,63.68,3.67,9.21,9.16,1.41,1.55,5.229.9
1986,4.82,11.39,55.3,2.82,18.5,18.5,74.9,19.70,64.68,3.67,8.21,7.16,41.2,55.6,229.9
1985,4.83,11.44,55.4,2.82,18.6,18.5,74.9,19.69,63.68,4.67,8.21,8.16,1.41,3.55,5.229.9
1984,4.83,11.36,55.3,2.82,18.4,18.5,74.9,19.69,62.68,6.67,6.22,16.41,4.55,6.229.9,240
1983,4.85,11.37,55.4,2.83,18.6,18.5,74.9,19.69,63.68,2.67,7.21,7.16,41.4,55.6,229.9
1982,4.86,11.42,55.5,2.83,18.6,18.5,74.9,19.69,62.67,9.67,5.21,9.16,41.5,55.6,229.9
1981,4.87,11.44,55.5,2.83,18.5,18.5,74.9,18.6,68.62,67.8,67.5,21.9,16.1,41.5,55.7,2
1980,4.88,11.55,6.2,83,18.6,18.5,74.9,18.6,69.63,67.9,67.4,21.8,16.1,41.5,55.5,229
1979,4.89,11.48,55.6,2.83,18.6,18.5,74.9,18.6,69.63,67.9,67.3,21.9,16.1,41.5,55.5,2
1978,4.89,11.51,55.6,2.83,18.6,18.5,74.9,18.6,69.63,67.9,67.2,21.3,16.1,41.5,55.4,2
1977,4.89,11.54,55.5,2.83,18.5,18.5,74.9,18.6,69.62,68.67,4.21,3.16,41.5,55.2,229.8
1976,4.88,11.47,55.5,2.83,18.5,18.5,74.9,18.6,69.63,67.7,67.2,15.48,9.55,5.229.9
1975,4.89,11.52,8.5,2.83,18.5,18.5,74.9,18.6,69.63,67.9,67.2,15.48,9.55,5.229.9
1974,4.87,11.46,55.5,2.83,18.5,18.5,74.9,18.6,69.62,67.9,67.2,15.16,48.6,55.2,229
```

〈그림 3-16〉 2호기 RAW Data

불량수	GAS				GAS			
	이름				이름			
	수직				수직			
	2 EA				4 EA			
유형	사출시간 (s)	개량시간 (s)	공정시간 (s)	형제시간 (mm)	후선위치 (mm)	보강철량 (mm)	개량원료 (mm)	최대사출속도 (mm/s)
2000	3.94	11.31	55.2	2.81	10.5	18.5	74.9	19.3
1999	3.94	11.32	55.2	2.81	10.5	18.5	74.9	19.3
1998	3.96	11.35	55.2	2.81	10.5	18.5	74.9	19.3
1997	3.95	11.35	55.2	2.81	10.4	18.5	74.9	19.3
1996	3.96	11.34	55.2	2.81	10.4	18.5	74.9	19.3
1995	3.97	11.36	55.2	2.82	10.4	18.5	74.9	19.3
1994	3.97	11.35	55.2	2.81	10.4	18.5	74.9	19.3
1993	3.97	11.37	55.3	2.82	10.5	18.5	74.9	19.3
1992	3.98	11.37	55.3	2.82	10.4	18.5	74.9	19
1991	3.97	11.43	55.3	2.82	10.4	18.5	74.9	19.3
1990	3.99	11.36	55.3	2.81	10.5	18.5	74.9	19.3
1989	4	11.41	55.4	2.82	10.5	18.5	74.9	19
1988	4.01	11.43	55.4	2.82	10.5	18.5	74.9	19
1987	4.01	11.4	55.4	2.82	10.5	18.5	74.9	19
1986	4.02	11.39	55.3	2.82	10.5	18.4	74.9	19
1985	4.03	11.4	55.4	2.82	10.6	18.5	74.9	19
1984	4.03	11.36	55.3	2.82	10.4	18.5	74.9	19
1983	4.05	11.37	55.4	2.83	10.6	18.5	74.9	19
1982	4.06	11.42	55.5	2.83	10.5	18.5	74.9	18.6
1981	4.07	11.44	55.5	2.83	10.5	18.5	74.9	18.6
1980	4.08	11.5	55.6	2.83	10.6	18.5	74.9	18.6
1979	4.09	11.48	55.6	2.83	10.5	18.5	74.9	18.6

〈그림 3-17〉 2호기 불량 결과 Data

- 사출 성형 3호기 수집 데이터 시료 2,000건 전 처리 과정

```
Seq,Cycle,Injection1,Measuring1,Cusion,Supplement,Injection2,Switchover1,Back
1,22,91,1.52,7.85,4.92,10.85,1684,1684,81,47.01,58.01,5.1,61.1,43,17.9,9.3,4
2,23,91,1.52,8.14,4.92,10.81,1678,1677,81,47.01,49.99,5.1,61.1,43,18.8,9.4,4
3,23,91,1.52,8.43,4.92,10.81,1683,1680,81,47.01,58.01,5.1,61.1,42,19.3,9.3,0
4,23,91,1.52,8.61,4.92,10.86,1689,1689,81,47.01,58.01,5.1,61.1,42,19.3,9.3,0
5,23,91,1.52,8.62,4.92,9.98,1684,1684,81,47.01,58.01,5.1,61.1,42,20.9,4.9,4
6,23,91,1.52,8.3,4.92,10.88,1705,1706,81,47.01,58.01,5.1,61.1,44,21.5,9.3,0
7,23,91,1.52,8.05,4.93,10.12,1716,1717,81,47.01,49.99,5.1,61.1,43,22.9,2.0,4
8,23,91,1.52,7.73,4.92,10.17,1726,1726,81,47.01,58.01,5.1,61.1,43,22.9,4.9,4
9,23,91,1.52,7.59,4.92,10.19,1731,1731,81,47.01,58.01,5.1,61.1,43,21.6,9.3,0,4
10,23,91,1.52,7.54,4.93,10.15,1722,1722,81,47.01,58.01,5.1,61.1,43,21.5,9.3,0,4
11,23,91,1.52,7.55,4.93,10.16,1724,1724,81,47.01,49.99,5.1,61.1,43,21.5,9.4,4
12,23,91,1.52,7.46,4.93,10.21,1735,1735,81,47.01,58.01,5.1,61.1,42,21.2,9.4,0,4
13,23,91,1.52,7.43,4.93,10.17,1727,1726,81,47.01,58.01,5.1,61.1,43,21.3,9.3,0,4
14,23,91,1.52,7.43,4.93,10.20,1743,1743,81,47.01,49.99,5.1,61.1,42,21.9,4.9,4
15,23,91,1.52,7.5,4.93,10.2,1734,1734,81,47.01,49.99,5.1,61.1,44,20.9,4.9,4
16,23,91,1.52,7.59,4.92,10.16,1725,1725,81,47.01,58.01,5.1,61.1,43,20.9,4.9,4
17,23,91,1.52,7.66,4.92,10.16,1723,1723,82,47.01,49.99,5.1,61.1,43,20.2,9.4,4
18,23,91,1.52,7.81,4.92,10.09,1709,1709,82,47.01,58.01,5.1,61.1,43,20.2,9.4,4
19,23,91,1.52,7.91,4.92,10.12,1712,1713,81,47.01,58.01,5.1,61.1,42,19.9,4.9,4
20,23,91,1.52,8.02,4.92,10.09,1707,1707,82,47.01,58.01,5.1,61.1,43,19.6,9.4,0,450
21,23,91,1.52,7.91,4.92,10.11,1710,1709,82,47.01,58.01,5.1,61.1,43,20.2,9.4,0,4
22,23,91,1.52,7.91,4.93,10.16,1729,1729,82,47.01,58.01,5.1,61.1,44,20.6,9.4,4
23,23,91,1.52,8.07,4.92,10.07,1703,1703,81,47.01,49.99,5.1,61.1,43,20.7,9.4,4
24,23,91,1.52,8.08,4.92,10.07,1704,1703,81,47.01,49.99,5.1,61.1,43,20.7,9.4,4
25,23,91,1.52,8.07,4.93,10.12,1714,1713,81,47.01,49.99,5.1,61.1,43,20.8,9.4,4
```

〈그림 3-18〉 2호기 RAW Data


불량수	GAS				GAS			
	이름				이름			
	2 EA				1174 1209 1206 1494			
	2 EA				1154 1625 1292 1479 1563			
유형	사출시간 (s)	개량시간 (s)	공정시간 (s)	후선위치 (mm)	보강철량 (mm)	사출(kg)	보정(kg)	개량(kg)
2000	3.94	11.31	55.2	2.81	10.5	18.5	74.9	19.3
1999	3.94	11.32	55.2	2.81	10.5	18.5	74.9	19.3
1998	3.96	11.35	55.2	2.81	10.5	18.5	74.9	19.3
1997	3.95	11.35	55.2	2.81	10.4	18.5	74.9	19.3
1996	3.96	11.34	55.2	2.81	10.4	18.5	74.9	19.3
1995	3.97	11.36	55.2	2.82	10.4	18.5	74.9	19.3
1994	3.97	11.35	55.2	2.81	10.4	18.5	74.9	19.3
1993	3.97	11.37	55.3	2.82	10.5	18.5	74.9	19.3
1992	3.98	11.37	55.3	2.82	10.4	18.5	74.9	19
1991	3.97	11.43	55.3	2.82	10.4	18.5	74.9	19.3
1990	3.99	11.36	55.3	2.81	10.5	18.5	74.9	19.3
1989	4	11.41	55.4	2.82	10.5	18.5	74.9	19
1988	4.01	11.43	55.4	2.82	10.5	18.5	74.9	19
1987	4.01	11.4	55.4	2.82	10.5	18.5	74.9	19
1986	4.02	11.39	55.3	2.82	10.5	18.4	74.9	19
1985	4.03	11.4	55.4	2.82	10.6	18.5	74.9	19
1984	4.03	11.36	55.3	2.82	10.4	18.5	74.9	19
1983	4.05	11.37	55.4	2.83	10.6	18.5	74.9	19
1982	4.06	11.42	55.5	2.83	10.5	18.5	74.9	18.6
1981	4.07	11.44	55.5	2.83	10.5	18.5	74.9	18.6
1980	4.08	11.5	55.6	2.83	10.6	18.5	74.9	18.6
1979	4.09	11.48	55.6	2.83	10.5	18.5	74.9	18.6

〈그림 3-19〉 2호기 불량 결과 Data

IV. 연구 결과

4.1 사출 불량 요인 분석 결과

의사결정나무의 머신 러닝 알고리즘을 응용 하여 예측이 가능한 품질 요인을 분석하였다. 의사결정나무기법은 분류와 공정패턴을 명확하게 나타내는데 매우 효과적인 기법이다. 제조공정에서 최종제품이 생산되기까지 여러 단계의 공정을 거치게 되므로 최종제품의 품질특성은 공정단계의 여러 변수에 의해 영향을 받게 된다.



〈그림 4-1〉 불량 요인 별 응용프로그램 분석 결과


자료 : 스크린 샷 캡처

〈그림 4-1〉은 불량 요인에 대해 가장 영향도가 높은 변수 항목에 대한 결과이다. 결과와 같이 해당 불량은 Hopper Temperature (호퍼 투입 온도)의 온도가 51.4 ~ 51.8 일 경우 평균 조건 대비 303.13 %의 불량 확률을 예측한 결과이며, 이 결과를 가지고 제품이 생산되는 과정에서 불량을 사전에 발견 할 수 있으며, 해당 범위의 값이 지속적으로 발생된다면 원인 파악을 위해 현장 작업자에게 알람 및 문제가 발행한 항목을 알려줄 수 있다.

Decision Tree는 의사 결정 규칙과 그 결과를 특정 항목에 대한 트리 구조로 분류할 수 있는 통계 분석 모듈이다. IoT 데이터 분석을 위해 선택한 이유는 낮은 연산 비용으로 대량의 데이터를 비교적 빠르게 계산할 수 있기 때문이다. 데이터 마이닝에 사용되는 의사 결정 트리 분석 방법은 크게 분류와 회귀 분석이라는 두 가지 유형으로 구분한다. 분류 트리 분석에서는 입력 데이터가 예측 결과로 분류되는 클래스를 출력하고, 회귀 트리 분석에서는 특정 오류를 예측 결과로 출력한다. 의사 결정 나무 학습 방법은 지도 분류 학습에 사용되는 가장 유용한 기술 중 하나이다.

분석에 사용된 대상 데이터 2000개 중 60%의 데이터를 학습 데이터로 지정하여 학습데이터에 대한 Decision Tree 모델을 추출하였다. 추출된 Decision Tree를 남은 40%의 평가 데이터에 대해 불량 여부를 예측하였으며, 예측된 불량여부와 실제 불량여부를 비교하여 Decision Tree 모델의 적합성을 검증하였다.

4.1.1 사출 1호기의 의사결정나무 분석 결과




〈그림 4-2〉 사출1호기 Decision Tree

사출 1호기의 주요 불량 원인 변수는 Max Injection Pressure(최대 사출

압력)과 , Max Back Pressure(최대 배압)으로 나타났으며, 불량 발생 조건은 Max Injection Pressure > 70.7 인 경우와 Max Back Pressure < 22.3 값인 경우이다.


4.1.2 사출 2호기의 의사결정나무 분석 결과



〈그림 4-3〉 사출2호기 Decision Tree

사출 2호기의 주요 불량 원인 변수는 Process Time(사출 시간)과 , Heater1(1번 히터), Process Number(사출 순번) 이며, 주요 불량 발생 조건은 Process Time < 55.3 이고 Process Number < 21 인 경우와 Process Time > 55.6 이고 Heater1 < 244.9 인 경우로 결과가 나왔다. 사출 1호기와 2호기는 동일한 제품을 생산하는 사출 성형기 이지만, 불량 원인이 되는 공정 조건은 상이한 결과로 나타났다.

4.1.3 사출 3호기의 의사결정나무 분석 결과



〈그림 4-4〉 사출3호기 Decision Tree

사출 3호기의 주요 불량 원인 변수는 Supplement(보완)과 , Cycle(주기)이며, 주요 불량 발생 조건은 Supplement < 9.36 인 경우와 Supplement > 9.41 이고 Cycle > 32.92 인 경우로 결과가 나왔다.

4.1.4 사출 2호기의 GAS 불량 프로파일 분석 결과


Model 02LAMP_RH_DATA_03	Goal Faulty Avg. Value for Goal 0.0243	Dataset 02lamp_rh_data_03 Percent of Records Used 100%	Filter all_data Number of Records 1975	Exclusions No Exclusions Applied						
Model Results Signals Profiles Predictive Scoring	Profile Status: COMPLETED Profile Result Id: 6529cd55-11a9-4fe0-9b64-2b1f43c27068				Maximize True	Max Depth 4	Min Pop. % 0.25%	Max Profiles 10	Generate New Profiles	Export
	Profile #1	Fields	Values	Avg Goal	% Diff Vs Avg	# Of Records	% Of Total Records			
		InjectionTime	3.9100 to 3.9200	0.1000	311.46%	40	2.03%			
		AND FormOpenLocation	604.4200 to 604.6100	0.4286	1663.39%	7	0.35%			
		AND MaxInjectionSpeed	19.2500 to 19.3000	0.4286	1663.39%	7	0.35%			
	Profile #2	Fields	Values	Avg Goal	% Diff Vs Avg	# Of Records	% Of Total Records			
		AverageScrewSpeed	61.0000 to 61.2000	0.0769	216.51%	26	1.32%			
		AND Heater4	230.1700 to 230.2250	0.2500	928.65%	8	0.41%			
		AND InjectionTime	4.0400 to 4.0600	0.3333	1271.53%	6	0.30%			
		AND SwitchoverLocation	18.4950 to 18.5000	0.3333	1271.53%	6	0.30%			
Profile #3	Fields	Values	Avg Goal	% Diff Vs Avg	# Of Records	% Of Total Records				
	FormOpenLocation	603.6600 to 603.8500	0.0714	193.90%	28	1.42%				
	AND AverageScrewSpeed	63.8000 to 64.0000	0.2857	1075.60%	7	0.35%				

〈그림 4-5〉 사출2호기 프로파일 분석 결과

자료 : 스크린 샷 캡처

프로파일은 분석한 데이터 내의 개별적인 하위 집단을 식별하고 목표 결과 (불량)에 영향을 미치는 요소에 대한 통찰력을 제공한다. 〈그림 4-5〉는 사출 2호기의 GAS 불량 프로파일 분석의 결과로, 불량 발생의 요인을 여러 가지 Case로 제시하고 있다. 첫 번째 케이스에서는 Injection Time이 3.91 ~ 3.92 이고 Form Open Location이 604.42 ~ 604.61 이며, Max Injection Speed 가 19.25 ~ 19.30 의 조건일 때 평균(정상) 대비 1663.39%의 차이로 불량에 가까운 결과를 나타내고 있다.

4.1.5 분석 데이터 모델의 검증



〈그림 4-6〉 공정 데이터 학습 모델의 검증

자료 : 스크린 샷 캡처

연구에서 사용한 의사 결정 나무 분석에 대한 알고리즘 성능평가의 도구로 Confusion Matrix 지표를 사용하였다. Confusion Matrix는 학습 모델을 평가할 때 모델이 얼마나 정밀한지, 얼마나 실용적인 분류가 가능한지, 정확한 분류를 할 수 있는지에 대한 평가 지표이다.

연구 데이터의 모델은 관심 범주를 정확히 분류할 수 있는 비율이 93.37%로 2,000개의 샘플 데이터에 대한 학습 모델의 결과이다. 더 많은 데이터를 이용한 머신러닝의 학습이 이루어지면 탐지율(Accurare)이 높아질 것이다.

V. 결 론

5.1 연구결과 요약

본 연구를 통해 수집 된 수많은 설비 공정 변수에 대한 기계 학습으로 실시간으로 유입되는 IoT 데이터를 분석 및 예측하는 것이 생산 품질을 사전에 발견하고 조치 할 수 있음이 가능성을 제시하였다. 현재 대다수의 공장에서는 제품의 품질 검사를 완제품 단계에서 진행하고 있으나, 불량률의 원인 파악은 오랜 경험을 통해 습득한 숙련공에 의해 발견되고 있으며, 이 또한 경험적이고 주관적인 감에 의존한 원인 분석일 수밖에 없으며, 제품의 품질 관리 능력이 제조 기업의 자산임을 감안할 때 객관적이고 지속 가능한 공정 관리는 경쟁력의 원천이 될 것이다.

본 연구에서는 IoT 기술을 공장의 중요한 생산 설비에 적용하여 공장에서 발생하는 데이터를 최적으로 관리하고 운용하는 방법을 제시하였으며, 수집한 데이터가 품질에 작용하는 주요한 변수로 관리되도록 하여, 생산효율에 의한 제조 원가를 절감하고 품질 경쟁력을 향상시키는 IoT 기반의 스마트팩토리 구축 기법과 데이터의 수집, 관리, 분석이 얼마나 중요한 기업 자산이 될 수 있는지에 대한 방법을 제시하였다.

스마트팩토리는 다양한 방법과 기술로 구축 될 수 있으나, IoT 기반의 ICT 활용 기술을 적용하고, 전통적 방식의 통계 분석이 아닌 실시간 대용량 빅데이터를 분석하여 품질 예측이 가능한 데이터를 관리하고 데이터 검증을 통한다면 공정 혁신과 생산성 혁신을 기대할 수 있을 것이다.

또한 노후화된 설비가 대다수인 중소제조 공장에도 적용이 가능한 데이터 수집 및 저장 기술과 머신러닝 알고리즘을 활용함으로 설비의 실시간 모니터링과 제조 과정의 품질 이상 징후를 감지하여 사전에 불량을 예측하는 기술

및 방법에 대한 해법을 제시하였다. 이는 사물인터넷 환경에서 생산되는 각종의 공정 설비로 부터 불량 요인을 발견하고, 사전 조치가 가능한 빅데이터 기반의 품질 예측 스마트팩토리 구축이 생산성 향상을 위한 제조 기술의 자산화이며 기업의 무형 가치를 높일 수 있어 생산 혁신 부분의 해법이 될 수 있을 것이다.

5.2 연구결과의 시사점

현재 공장에서 가동중인 설비의 대부분은 자동화가 되어 있으나, 동일한 시기에 도입 된 동일한 모델의 공정 설비라 할지라도 시간이 흐르면서 여러 가지 운영 환경 조건에 의해 동일 품질의 제품 생산이 어려워진다. 이러한 설비 별 문제를 해결해왔던 방법은 설비를 장기간 운영해 왔던 작업자의 경험에 의해 최적의 공정 조건으로 각각의 설비 설정을 다르게 부여하는 것이었다.

이 외에도 제조 현장에는 설비를 포함한 한 4M(Machine, Man, Method, Material) + 1E(Environment)에 내재된 불확실성이 늘 존재하며, 이 불확실성이 생산 품질의 요인으로 작용하게 되는데, 인지 할 수 없는 문제에 의한 기계 고장, 제품 불량, 운영 지연, 설비의 효율 문제가 기업의 경쟁력을 잃게 만드는 원인이 될 수 있다. IoT 기반의 공장 데이터 수집으로 보이지 않는 문제를 발견하여 설비의 노후화 진행 상황, 설비 고장 주기 변화, 작업자의 설비 운영을 위한 처리, 원재료 성분에 따른 작업 표준 지시 값의 변화, 생산 품질에 영향이 될 수 있는 다양한 외부의 환경 조건과 같은 세부적인 데이터를 관리한다면 생산성 혁신에 많은 기여를 할 것이다.

4차 산업 시대 제조 공장은 현장의 문제를 해결하는 핵심적 요소는 이러한 내재된 불확실성을 다루는 능력이며, 스마트팩토리를 위한 초석이라 할 수 있다. 본 연구의 결과로 보았을 때 이러한 4M1E에서 발생하는 제조 현장의 숨어 있는 데이터를 체계적으로 저장, 분석을 통해 데이터 중심적인 실시

간 의사결정이 가능한 환경을 구축한다면 생산성 혁신 및 경영성으로 이어지
질 것이다.

5.3 한계점 및 향후 연구방안

본 연구는 실제 공장 설비에서 데이터를 수집, 저장하고 분석까지 진행하
였으나 다음과 같은 한계점이 있다.

첫째, 연구를 위해 수집한 실험 학습 데이터의 범위가 전체 공정 프로세
중 1개 설비에 한정되었으며, 취득한 데이터의 수가 2,000건으로, 4M1E의
영역에서 다양한 형태로 존재하는 숨어있는 데이터가 모두 분석된 것은 아니
다. 전체 공정과 공정 별 LOT 데이터를 연계하여, 전체 공정의 접점 및 선,
후 공정의 품질 상관관계까지의 확장 연구가 요구된다.

둘째, IoT 기반의 스마트팩토리의 핵심 중의 하나는 실시간 데이터의 처리
와 분석 및 예측이나, 연구의 실험에서는 누적 된 데이터를 취득하여 과거 데
이터에 한정 된 학습과 예측 가능한 공정 변수를 도출해 낸 것이다. 이 학습
된 데이터를 실시간 공정 데이터와 연결하여 실시간으로 분석되어지는 추가
적인 연구가 필요하다.

셋째, 연구 과정의 시뮬레이션 범위는 현장 설비의 데이터만을 대상으로
하였다. 더 구체적인 실시간 의사결정 체계를 구축하기 위해서는 전사 시스템
인 ERP, SCM, PLM과 연계가 필요하며, 차기 연구에서는 IoT 기반의 스마
트팩토리의 데이터 수집 범위를 전사 운영 시스템과 연계까지 진행하도록 하
겠다.

참 고 문 헌

1. 국내문헌

- 관계부처합동. (2015). 『제조업 혁신 3.0 전략 실행대책』.
- 구본진, 이종선, 이미화, 손석호. (2018). “국내 스마트 제조 정책과 지원 현황 및 개선 방안”. 『KISTEP ISSUE WEEKLY』, 2018-01 (통권 제219호), 1-34.
- 권혁성, 김준모. (2015). “특집 : 스마트 팩토리 ; Connected Smart Factory 개념과 정책동향”. 『섬유기술과 산업』, 19(2), 125-131.
- 김승현, 김만진. (2016). “차세대 생산혁명을 대비한 제조업 혁신정책과 도전과제”. 『정책연구』, 2016(12), 1-170.
- 김재성. (2017). “스마트팩토리 구축을 위한 중소제조공정 빅데이터 분석 적용방안”. 충북대학교 대학원 박사학위논문
- 나형배. (2018). “중소기업 스마트팩토리 구축을 위한 공정/설비 부문 방법론에 대한 연구”. 공주대학교 대학원 석사학위논문
- 노상도. (2016). “스마트팩토리와 사이버물리시스템 기술”. 『정보와 통신』, 33(11), 3-7.
- 박종만. (2015). “중소제조업 스마트공장 기술 동향과 이슈”. 『韓國通信學會論文誌』, 40(12), 2491-2502.
- 박형욱. (2015). “스마트 팩토리와 연관된 생산제조기술 동향. 정보와 통신”. 『정보와 통신』, 33(1), 24-29.
- 배병축. (2017). “스마트공장의 기술적 요인이 경영성과에 미치는 영향”. 한양대학교 대학원 석사학위논문
- 삼성KPMG. (2018). “4차 산업혁명과 제조혁신”. 『Samjung Insight』, 55, 1-40.

- 서창성. (2016). “스마트 팩토리 구축을 통한 중소기업 생산성 향상에 대한 연구”. 부산대학교 대학원 석사학위논문
- 소병엽. (2017). “센서와 가상공정설계를 활용한 스마트 팩토리 구축에 관한 연구”. 호서대학교 대학원 박사학위논문
- 심상석. (2017). “가스밸브 제조공정의 추적성 향상을 위한 스마트팩토리 구축 사례 연구”. 동아대학교 대학원 석사학위논문
- 안창원, 황승구. (2012). “빅 데이터 기술과 주요 이슈”. 『정보과학회지』, 30(6), 10-17.
- 온현정. (2018). “사이버물리제조시스템(CPPS) 기반 디지털트윈(가상 제조시스템)을 활용한 공정혁신에 관한 연구”. 고려대학교 컴퓨터정보통신대학원 석사학위논문
- 임명선. (2016). “스마트 팩토리 4.0 에 기반한 한국 제조업 3.0 성공 전략”. 『디지털융복합연구』, 14(3), 219-226.
- 유선희. (2013). 『빅데이터 기반의 산업시장 정보분석』. 서울: 한국과학기술정보연구원.
- 임정일, 김용운. (2015). “스마트 팩토리를 위한 기능 모델”. 『한국통신학회 학술대회논문집』, 2015(06), 208-209.
- 이규택. (2016). “스마트공장 기술 동향 및 R&D로드맵”. 『전자공학회지』, 43(6), 16-24.
- 이대성. (2015). “스마트 팩토리 등장과 IoT 센서의 요구”, 『계장기술』, 2015(6), 81-85.
- 이민석. (2017). 『[4차 산어혁명 기획시리즈] IoT 활성화를 위한 고찰(考察)』. 충북: 정보통신정책연구원.
- 이유미. (2017). “스마트 팩토리 구축을 위한 빅데이터 시스템 연구”. 한국항공대학교 대학원 석사학위논문
- 이창수, 최정일. (2007). “ISA-95 기반의 제조실행시스템”. 『대한산업공학회

- 춘계학술대회논문집』, 2007(5), 1092 – 1096.
- 임정일, 김용운. (2015). “스마트 팩토리를 위한 기능 모델”. 『한국통신학회 학술대회논문집』, 2015(06), 208 – 209.
- 이화섭, 류광열, 조용주. (2017). “센서 기반 실시간 사출성형 공정변수 제어 프레임워크 설계”. 『한국경영과학회 학술대회논문집』, 2017(4), 3649 – 3654.
- 전인걸, 강성주, 전재호, 이수형. (2016). “가상-實공장 연동을 위한 CPS기반 스마트팩토리 기술”. 『한국통신학회지』, 33(11), 8 – 15.
- 전찬모, 이주연, 윤주성, 김보현. (2016). “대용량 제조데이터 연동 스마트공장 애플리케이션 통합운영 기술 개발”. 『한국 Cad/cam 학회 학술발표회 논문집』, 2016(동계), 219 – 230.
- 정보통신기술진흥센터. (2017). 『사물인터넷 산업의 국가경쟁력 결정 요인 분석』. 대전: 정보통신기술진흥센터.
- 조용주. (2016). 『중소중견 제조기업의 스마트 팩토리 구축을 위한 제언』. 서울: 한국무역협회.
- 주대영. (2014). “초연결시대 사물인터넷(IoT)의 활성화 방안”. 『KEIT 산업경제』, 2014(02), 16–24.
- 차석근, 윤재영, 이성근, 조현찬. (2016). “실시간 미들웨어를 활용한 생산자원 4M 통합화 방안”. 『한국생산제조시스템학회 학술발표대회 논문집』, 2016(04), 229 – 229.
- 한국데이터진흥원. (2017). 『데이터산업 백서』,
- 한국산업기술평가관리원. (2017). “생산성 최적화 및 Seamless 설비 운영을 위한 인공지능기반 제조상황 진단예측 시스템 개발”. 『KEIT PD Issue Report』, 18(5), 1 – 22.
- 한국인터넷진흥원. (2013). “시스코, 사물인터넷의 경제적 가치 14조달러에 달할 것으로 전망”. 『Internet & Security Weekly』, 3(4), 1 – 3.

- 한국콘텐츠진흥원. (2018). 『2017년 4분기 및 연간 콘텐츠산업
동향분석보고서』. 전남: 한국콘텐츠진흥원.
- 허진. (2014). “사물인터넷(IoT) 융합비즈니스 촉진전략에 대한 연구”.
한성대학교 지식서비스&컨설팅대학원 석사학위논문
- 황태곤. (2018). “스마트 팩토리 도입에 관한 연구”. 동국대학교 경영대학원
석사학위논문
- KOTRA. (2017). “4차 산업혁명에 대응하는 투자유치 전략수립에 관한
연구”. 『KOTRA자료』, 17(077), 1 - 65.
- 김광석. (2018). “4차 산업혁명 시대에 필요한 경쟁력은? 한국과 기업이
읽어야 할 트렌드”. <https://blog.naver.com>
- 박규찬. (2017). “스마트 팩토리 구축시 효율성 향상 기대”.
인더스트리뉴스. <http://www.industrynews.co.kr/>
- 손종수. (2012, December 7). “내 낡은 서랍 속의 바다, 빅 데이터”.
<https://blog.naver.com>
- 월간엘세이프. (2018). “4차 산업혁명 이끄는 스마트 팩토리, 승강기
산업에도 새 바람을 일으킨다”. <http://el-safe.or.kr/>
- 인터비즈. (2018, April 13). “급변하는 산업 패러다임 얼마나 준비됐나...日
12위, 한국은?” <https://blog.naver.com/>
- 투데이에너지. (2016). “[신년기획] 제조업 선진국들이 준비하는 Industry
4.0” <http://www.todayenergy.kr/>
- 한국IDG. (2018). “모든 것이 연결된다. 2018년을 지배할 IoT 전망 6가지”
<http://www.ciokorea.com/>

2. 국외문헌

- Baines, T. S., Lightfoot, H. W., Benedettini, O., & Kay, J. M. (2009). The servitization of manufacturing: a review of literature and reflection on future challenges. *Manufacturing Technology Management*, 20(5), 547–567.
- CISCO. (2015). *The Internet of Everything: Unlocking the Opportunity for UK Startups*, Ireland: CISCO Press.
- Gartner. (2015). *Hyper Cycle for Emerging Technology*, Stamford: Gartner
- GI McKinsey. (2011). *Big data: the next frontier for innovation, competition and productivity*, McKinsey Global Institute.
- GSMA. (2014). *Understanding the Internet of Things(IoT)*, London: GSM Association.
- Henning Kagermann (2013). *Recommendations for implementing the strategic initiative INDUSTRIE 4.0*, Forschungsunion
- Kara, S. (2017). IoT, Industry 4.0 and the Future of Manufacturing, 1 – 11.
- Laszlo Monostori. (2014). Cyber-Physical production systems: Roots, expectations and R&D challenges. *Automatisierungstechnik*, 63(10), 766 – 776.
- Lee, J., Kao, H.-A., & Yang, S. (2014). Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment. *Procedia CIRP*, 16, 3 – 8.
- O'Reilly. (2012). *Planning for Big Data*. O'Reilly Media, Inc.,
- PTC. (2017). *ThingWorx Analytics Release 8 End to End Deep Dive 2017*. PTC

- Roland Berger. (2014). *INDUSTRY 4.0 : The new industrial revolution How Europe will succeed*, ROLAND BERGER STRATEGY CONSULTANTS GMBH
- Russom Philip. (2011). *Big Data Analytics*, TDWI(The Data Warehousing Institute).
- SAS. (2012). *Big Data Meets Big Data Analytics*, SAS.
- Siemens. (2015). *Digital end to end Engineering*, Siemens.
- Thornton A May. (2011).
analytics-university-30-and-the-future-of-information-technology.
- UBS. (2016). *Extreme automation and connectivity: The global, regional, and investment implications of the Fourth Industrial Revolution*.
- Scott Gnau, Hortonworks. (2018). *Dataworks Summit 2018*
<https://www.computerworlduk.com/>

부 록

Python Code :

```
setwd("/Users/leeinbae")

raw_data =read.csv("01.LAMP_LH_DATA.csv", header = TRUE)
# categorize Faulty column
raw_data$Faulty =as.factor(raw_data$Faulty)
# Column exclusion
raw_data = subset(raw_data,select=-c(MeasuringCompleteLocation))

# functions for correlation
panel.cor <- function(x, y, digits = 2,prefix = "", cex.cor, ...)
{
  usr<- par("usr"); on.exit(par(usr))
  par(usr = c(0, 1, 0, 1))
  r<- abs(cor(x, y))
  txt<- format(c(r, 0.123456789), digits = digits)[1]
  txt<- paste0(prefix, txt)
  if(missing(cex.cor)) cex.cor <- 0.8/strwidth(txt)
  text(0.5, 0.5, txt, cex = cex.cor * r)
}

panel.hist <- function(x, ...)
{
  usr<- par("usr"); on.exit(par(usr))
  par(usr = c(usr[1:2], 0, 1.5) )
} h<- hist(x, plot = FALSE)
breaks <- h$breaks; nB <- length(breaks)
y<- h$counts; y <- y/max(y)
rect(breaks[-nB], 0, breaks[-1], y, col = "cyan", ...)
}
```

```

# scatter matrix
library("PerformanceAnalytics")
chart.Correlation(raw_data, histogram=TRUE,pch=3)

# decision tree
library(rpart)
fit <- rpart(Faulty ~ .,
             method="class", data=raw_data)

printcp(fit) # display the results
plotcp(fit) # visualize cross-validation results
summary(fit) # detailed summary of splits

# plot tree
plot(fit, uniform=TRUE,
     main="Classification Tree for Defection")
text(fit, use.n=TRUE, all=TRUE, cex=.8)

# divide defect and normal data
normal_data = subset(raw_data, Faulty == 1)
defect_data = subset(raw_data, Faulty == 0)

# randomly sampled data
library(dplyr)
sampled_normal_data = sample_n(normal_data,size = 380, replace = TRUE)
made_total_data =rbind(sampled_normal_data, defect_data)

# decision tree

```

```

library(rpart)

fit <- rpart(Faulty ~ . -ProcessNumber,
             method="class",data=made_total_data)

printcp(fit) # display the results
plotcp(fit) # visualize cross-validation results
summary(fit) # detailed summary of splits

# plot tree
plot(fit, uniform=TRUE,
     main="Classification Tree for Defection")
text(fit, use.n=TRUE, all=TRUE, cex=.8)

# random forest
library(randomForest)
set.seed(101)

train=sample(1:nrow(raw_data),200)
defect.rf=randomForest(Faulty ~ . , data =raw_data , subset = train)
defect.rf
plot(defect.rf)

```

ABSTRACT

Study on the Prediction Method of Defect Factors Using Industrial-IOT based Factory Data Collection & Analysis

Lee, In-Bae

Major in Convergence Consulting

Dept. of Knowledge Service & Consulting

Graduate School of Knowledge Service Consulting

Hansung University

In this study, it is expected that IoT data that is introduced in real time from many process variables that are collected from facilities will be analyzed and predicted through machine learning in advance and that quality of production is quickly predicted and presented. Currently, most plants are conducting quality tests of products at the end of the product stage, but the cause of the defects is due to the professional workers who have learned from their experience and are also subjective.

This research shows how IoT technologies are applied to factory critical production facilities to optimally manage and operate the data generated in the factory and to control the data collected by the company.

In addition, it uses data collection and storage techniques that can be applied to most old factories and machine learning algorithms to detect the quality anomalies of the facility in real time monitoring and manufacturing process. This is the asset of manufacturing technology to enhance productivity by discovering the reject factors from the process facilities of each species produced in the context of the Internet of Things.

Through this research, advanced analysis technology can be applied to identify characteristics of data generated from entry into large enterprises and to reduce the gap between small and medium businesses.

Keywords : Internet of things, Smart factory, Manufacturing Innovation, Big data, Machine Learning, Predictive Analysis