

스마트 제조시설 구축을 위한 데이터 수집 및 제품분석 시스템 설계 - UV 램프 제조시설의 예를 기초로 하여

김재민*, 유영환^o

Design of Data-Collection & Analysis System for Smart Factory - Based on UV Lamp Manufacturing Facility

Jaemin Kim*, Younghwan Yoo^o

요약

본 논문은 스마트 공장의 필수 기능인 생산 시설의 데이터 수집과 제품 품질을 분석하는 시스템을 설계한다. 설계된 시스템은 UV 램프 제조시설에 적용되며, 생산되는 제품의 특징에 따라 데이터를 수집하고 실시간으로 확인할 수 있다. 또한 수집된 데이터를 기반으로 생산된 제품을 실시간 분석을 통해 수명을 예측하고 이를 확인할 수 있도록 한다. 특히, 제안 시스템은 제품 생산 공정에 사용되는 제조법과 같은 단순한 공정데이터뿐만 아니라 주변의 온도, 습도 등 제조시설 내의 환경 데이터를 수집하여 외부 환경이 제품의 품질에 영향을 줄 수 있는지 분석할 수 있도록 하였다. 이 시스템을 구현함으로써 제조시설은 제품의 품질 향상을 위한 공정 프로세스 조정뿐만 아니라 효율적인 제품의 재고 및 생산 관리를 기대할 수 있다.

키워드 : 스마트 공장, 데이터 수집시스템, 제품 품질 분석, UV램프

Key Words : Smart Factory, Data-Collection System, Product Quality Analysis, UV Lamp

ABSTRACT

This paper proposes the smart manufacturing system which consists of a data-collection system and product analysis system. The proposed system is used for a UV lamp manufacturing facility. Using the system, we can monitor the data collected by IoT devices, and analyze the quality of products in real time. The main feature of the system is to collect the environment-data such as ambient temperature, humidity, and so on, because this data have a strong influence on the quality of products. We can expect the cost-effective inventory management as well as manufacturing process control to improve product quality.

1. 서론

스마트 공장이란 기존 제조 산업을 정보통신기술과 융합하여 제품의 기획·설계, 생산, 유통 등 전 과정이 최소 비용·시간으로 제품을 생산하는 미래형 공장이

다¹⁾. 독일, 미국, 영국 등 제조 선진국들은 스마트 공장 구축을 위한 다양한 정책을 펼치고 있으며, 다양한 정보통신기술의 융·복합된 스마트공장 구축을 통해 자국의 제조업분야 경쟁력을 강화를 시도하고 있다²⁾. 이러한 움직임에 맞춰 한국 정부도 스마트 공장과

※ 이 과제는 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음.

• First Author : Pusan National University Dong-Nam Grand ICT Research Center, repushedkim@gmail.com, 연구원, 정희원

° Corresponding Author : Pusan National University School of Computer Science and Engineering, ymomo@pusan.ac.kr, 정교수, 종신회원

논문번호 : 202001-258-D-RE, Received October 15, 2020; Revised November 30, 2020; Accepted November 30, 2020

관련된 다양한 정책을 추진하고 있다. 정부는 2015년 12월 스마트 제조 R&D 중장기로드맵을 발표하였다. 이에 따르면 스마트공장을 구축하는 데 필요한 8대 스마트 제조 기술은 스마트센서, 사이버물리시스템, 3D프린팅, 에너지 절감기술, 사물인터넷, 클라우드, 빅데이터 스마트 센서와 홀로그램 등이다. 정부는 이러한 8대 기술을 중심으로 다양한 기술과제를 수행하고 있으며 스마트 공장 구축을 시도하는 기업을 지원하고 있다³⁾.

스마트 공장 구현의 핵심은 사물인터넷기술을 기반한 공장내 외부관리자원을 연결하고 제조 및 서비스를 최적화할 수 있는 플랫폼 구현이다⁴⁾. 이 플랫폼은 공정상에서 발생하는 다양한 생산 데이터들을 실시간으로 수집할 수 있으며, 빅데이터 기술을 이용하여 제품의 품질 분석 및 예측을 할 수 있는 기능을 가지고 있다.

스마트 공장 시스템에서 빅데이터 기술을 활용하여 제품의 품질을 분석하려면 많은 데이터가 필요하다. 또한 분석에 사용되는 데이터들을 어떻게 수집하고 어떤 데이터를 수집할지 계획하는 것이 빅데이터 분석을 위한 선행요건 중 하나이다. 그러므로 제조시설에서 생산되는 제품의 재료, 공정 등과 같은 다양한 특성을 고려하여 데이터 수집 시스템을 설계할 필요가 있다⁵⁾.

본 논문에서는 스마트 공장의 기능 중 제품 품질 분석을 위한 데이터 수집 시스템 설계를 제안한다. 뿐만 아니라 수집된 데이터를 이용하여 제품 품질을 예측하는 분석 기능을 제안한다. 본 논문에서는 제안 시스템을 UV램프를 생산하는 제조 시설의 스마트 공장 구축을 예로 들어 설명한다. 제안된 수집 및 분석 시스템은 생산된 램프의 불량, 수명 등 품질을 분석하여 제품의 품질 향상 및 효율적인 재고·수요 관리를 목적으로 한다.

특히, 데이터분석시스템은 2가지 특징을 가지고 있다. 첫 번째 특징은 학습모델을 쉽게 추가할 수 있도록 모듈형식으로 구성되어있다는 점이다. 이러한 방식을 이용하여 기계학습 알고리즘들을 다른 언어, 라이브러리로 구현하더라도 하나의 시스템에서 동작이 가능하도록 하였다. 두 번째 특징은 웹 브라우저를 이용하여 제품번호에 따른 제품을 예측수명을 쉽게 확인할 수 있다. 생산관리자 뿐만 아니라 고객사에서도 기능을 이용할 수 있어 효율적인 재고관리가 가능하다.

본 논문의 구조는 다음과 같다. 2장에서는 본 논문에서 제안 시스템을 적용할 생산시설과 관련된 전반적인 내용을 다룬다. 3장에서는 설계된 전체 시스템을

데이터 수집 기능과 분석기능으로 분리하여 상세히 설명한다. 마지막으로 4장은 결론을 나타낸다.

II. 배경 지식

본 논문은 선박 평형수 장치에서 사용되는 UV램프를 제조하는 공장을 예시로 하여 스마트 생산 시스템을 설계하고 설명한다. 그림 1과 같이 선박 평형수(ballast water)는 선박들이 해양에서 균형을 잡을 때 사용된다. 선박들은 안정적으로 선체의 균형을 잡기 위해 바닷물을 선박의 평형수 탱크(ballast tank)에 채워 균형을 유지한다. 하지만 이러한 평형수는 다량의 미생물들을 포함하고 있어, 평형수를 함부로 다른 해양에 배출할 경우 생태계 혼란을 야기한다. 따라서 배출 시킬 때 평형수를 살균해야 한다.

평형수를 살균하는 방법 중 하나는 자외선을 사용하는 것이다. 그림 2의 UV램프는 자외선을 이용하여 평형수 내의 미생물을 살균한다. 램프는 선박 평형수 처리 장치 내부에 장착되며 형광등이나 전구처럼 소모성 제품이다. 즉 UV램프는 제한된 수명을 가지고 있으며 수명이 다하면 주기적으로 교체되어야 한다.

따라서 제품의 공정을 분석하여 공정프로세스 조정을 통해 램프의 수명을 향상시킬 수 있으며 제품의 경쟁력을 높일 수 있다. 또한 제품의 품질 향상뿐만 아




그림 1. 평형수(Ballast Water)교환의 개념도[6]
Fig. 1. Concept of ballast water exchange




그림 2. 생산된 UV 램프
Fig. 2. Manufactured UV Lamps

나라, 납품된 제품들의 수명을 예측하여 효율적인 재고 관리를 기대할 수 있다.

본 논문에서 제안한 시스템이 적용될 UV 램프 제조 시설은 제조실행시스템(Manufacturing Execution System; MES)을 이용하여 UV 램프를 생산하고 있다. 제조실행시스템이란 원부자재 투입부터 제품 생산, 출하에 이르는 모든 물류와 정보를 일체화하고 생산현장을 최적화를 위한 제반활동을 지원하는 통합 생산관리시스템이다⁸⁾.

현재 운용중인 제조실행시스템은 단순히 제조법과 관련된 공정 데이터만을 관리하고 있는 등 제한된 기능을 수행하고 있다. 하지만 동일한 제조법(램프의 크기, 가스주입량 등)으로 UV 램프를 생산하더라도 제품의 품질이 균일하지 않는 문제가 있었다. 즉, 현재 제조실행시스템에서 관리되고 있는 데이터만으로 분석하기 어려운 결과가 나타났다. 또한 생산직원이 직접 불량유무를 판단하는데, 외관적으로는 문제가 없더라도 짧은 수명을 가지는 제품이 존재하였다.

따라서 제품의 품질이 제품 생산 시 주변의 기온, 습도 등이 제품의 품질에 영향을 받을 수 있기에, 환경 데이터를 수집할 수 있는 기능을 포함하여 다양한 데이터를 수집할 수 있는 시스템을 설계할 필요가 있다.

본 논문에서는 기온, 습도 등과 같은 주변 환경 데이터를 수집할 수 있도록 시스템을 구성한다. 또한 수집된 다양한 종류의 데이터들을 이용하여 램프의 품질을 불량유무를 판단할 수 있는 인공지능 기반 분석 시스템을 구축한다.

III. 시스템 구조

그림 3은 본 논문에서 설계한 전체 시스템을 간략히 보여준다. 생산시설 내에 센서를 설치하고 제품생산과 관련된 데이터를 수집한다. 데이터들은 제조실행시스템의 데이터베이스서버에 저장되며 제품 생산과 관련된 데이터를 실시간으로 확인할 수 있다.

그리고 데이터베이스 서버에 저장된 공정데이터, 환경데이터 등 다양한 데이터를 이용하여 제품의 품질을 분석 및 예측한다. 분석 결과는 데이터베이스서버에서 저장되며 실시간으로 생산된 제품의 품질 예측 결과를 확인할 수 있다.

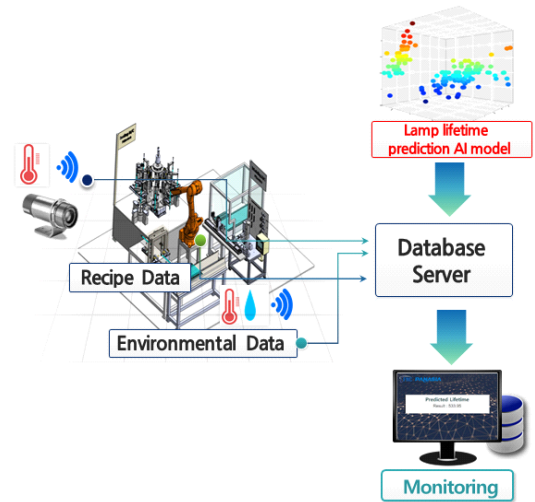


그림 3. 전체 시스템 구조
Fig. 3. Structure of overall system

3.1 센서 데이터 수집 시스템

그림 4는 전체 시스템 구조 중 센서 수집 시스템을 나타낸 것이다. 이전 연구에서 구현한 시스템을 기반으로 하였다⁷⁾. 시스템에서 센서는 설치 위치에 따라 2가지로 구분된다. 실내의 경우 라즈베리파이와 같은 초소형 PC나 임베디드 보드에 다수의 센서들이 부착되며 센서들에 의해 측정된 데이터는 이더넷 또는 와이파이를 통해 데이터베이스서버로 전송된다.

실외의 경우 센서들은 LoRa통신이 가능한 임베디드 보드에 부착되며 LoRa 통신을 이용하여 측정된 데이터들을 LoRa 게이트웨이가 부착된 PC로 전송한다. 그리고 PC로 전송된 데이터는 목적에 맞게 가공된 후 MES서버로 전송된다.

LoRa 통신은 중장거리 무선통신 기술로서 셀룰러 통신이나 와이파이 통신에 비해 전력소모가 상당히 낮으며, 이론적으로 센서가 장착된 임베디드 보드에서 배터리로 동작하더라도 수년간 동작할 수 있다. 또한




그림 4. 센서 데이터 수집 시스템 구조
Fig. 4. Structure of sensor data-collection system

최대 15km의 통신 거리를 가지고 있다⁹⁾. 이러한 특징을 고려하면 실외와 같이 와이파이 등의 사용이 어렵거나 유선으로 전력을 공급하기 힘든 환경에서 사용하는 것이 적합하다. 따라서 본 논문에서는 실외에서 사용하는 센서들은 LoRa 통신을 이용하여 데이터를 전송한다.

이전 연구에서 설계한 시스템과 달리 센서 데이터는 실시간으로 서버에 전송된다. 기존 연구에서는 센서들이 하루동안 수집한 데이터를 센서에 연결된 PC가 모은 후 공장이 가동 중이지 않을 때 데이터베이스 서버에 보내는 방식으로 동작하였다. 하지만 이러한 방식은 센서 측정 중에 비정상적인 값이 발생했을 때 빠른 대처가 불가능하다. 따라서 본 논문의 센서수집 시스템은 실시간으로 측정된 데이터를 서버로 보내

제조 시설내 관리자가 실시간으로 측정한 센서 데이터를 모니터링할 수 있도록 하였다.

그림 5는 센서가 데이터를 생산하고 서버로 전달하는 흐름도를 나타낸다. 먼저 센서가 부착된 PC는 MES 서버와 연결을 시도한다. 연결이 성공할 경우 공장이 가동 중인지 확인하고 가동 중일 경우 PC는 목적에 맞게 센서 측정을 통해 데이터를 생산한다. 만약 기기 등의 문제(센서와 PC 간의 단선, 센서 고장 등)가 발생하여 센서 측정이 어려울 경우 오류정보를 로그에 기록하며, 서버 또는 작업자의 이메일로 이러한 정보를 전송하여 문제점을 빠르게 보수할 수 있도록 한다. 측정된 센서 데이터는 데이터베이스서버로 전송된다. 서버와의 연결문제로 인해 데이터가 전송되지 못한 경우 센서가 부착된 PC내 저장소에 센서 데이터를 저장하며, 주기적으로 서버와 재연결을 시도한다. 서버와 재연결될 때, PC는 저장된 데이터를 전송하여 통신문제로 인한 데이터 누락을 방지한다.

3.1.1 설치 센서

(1) 실내 센서

그림 6은 램프 제조 시설 내 설치한 센서 중 하나를 보여준다. 설치된 센서는 적외선 온도 센서이며 RS-485통신을 이용하여 임베디드 보드와 연결된다. UV 램프를 생산할 때 유리를 약 2,000°C의 온도로 가열하여 그림 7과 같이 전극과 유리를 접합(핀치실링; Pinch Sealing)한다. 램프의 품질은 대체로 이 공정과 밀접하게 연관이 있다. 램프의 수명이 다하게 되는 대부분의 경우는 램프를 지속적으로 사용할 때 실링부위가 벌어지는 경우이다. 이때 가스가 누출되어 램프가 더 이상 발광하지 않는다. 따라서 얼마만큼의 온도로 가열하느냐에 따라 실링의 품질이 달라질 수 있으므로 센서를 통해 그것을 측정하고 분석을 위한

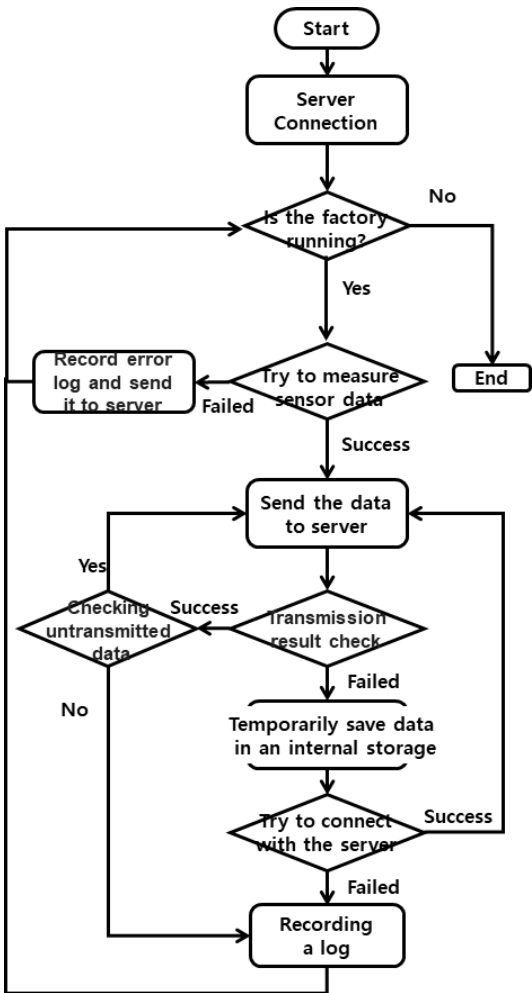


그림 5. 센서 데이터 생산 및 서버 전송 흐름도
Fig. 5. flowchart of the sensor data collection and transmission to DB server



그림 6. 실링 온도 측정용 온도계 설치 모습
Fig. 6. Infrared thermometer for measuring sealing temperature



그림 7. UV램프 양 끝단의 전극 실링 부분
Fig. 7. pinch sealing at end side of the UV lamp

데이터로 사용한다.

적외선 온도 센서를 통해 측정된 온도 값은 최대온도와 평균온도 등 2가지로 구분된다. 센서는 1800°C 이상의 온도에서 0.1초마다 값을 측정하게 되는데, 최대온도는 실링 시 가열될 때 최대온도를 나타내고, 평균온도는 가열시 평균온도를 나타낸다. 평균온도는 유리에 가하는 총열량과 관련되므로 실링 품질의 주요 인자가 될 수 있다.

(2) 실외 센서

그림 8은 LoRa 통신 기반의 센서 보드의 구조를 나타낸다. 센서는 아두이노 기반의 보드에 부착되어 있으며 배터리로 동작한다. 가스실의 경우 안전법에 의해 유선으로 전기를 공급하기 어려워 배터리를 사용하였으며, 오래 동작이 가능하도록 저전력 통신방법인 LoRa 통신을 이용하였다. LoRa 기반 임베디드 보드는 LoRa 게이트웨이가 연결된 PC와 통신을 한다.

그림 9는 실외에 설치된 센서를 보여준다. 이 센서는 외부 가스실의 온습도를 측정한다. 외부 가스실에는 램프에 주입되는 가스와 램프 실링시 사용되는 가




그림 8. 실외설치용 컨트롤 박스 내부
Fig. 8. Internal structure of control box for outdoor sensor



그림 9. 실외에 설치된 LoRa 기반의 센서
Fig. 9. LoRa-based Sensor placed outdoors

스들이 저장된 탱크들이 있다. 주변 온도에 따라 가스의 밀도가 달라지기 때문에 램프 제조에 사용되는 각 가스의 양은 온도에 따라 달라질 수 있다. 따라서 센서를 설치하여 가스실의 온습도를 측정하여 분석 인자로 사용한다.

3.2 데이터 분석 시스템

이 장은 램프의 품질 예측을 위해 사용되는 데이터를 설명한다. 또한 본 논문에서 설계한 데이터 분석 기능을 설명한다. 앞서 설명한 것과 같이 분석에 사용되는 모든 데이터는 제조실행시스템의 데이터베이스 서버에 저장되며 실시간으로 확인할 수 있다. 그림 10은 제조실행시스템의 실제 화면을 나타내며, 빨간 색 네모박스는 제품의 LoT 번호에 따른 점등 검사 테스트관련 데이터들의 일부를 보여주고 있다.

3.2.1 분석에 사용되는 데이터

표 1과 같이 데이터베이스서버 안의 데이터들은 3가지 카테고리로 구분된다. 첫 번째 데이터 타입은 공정데이터로서 제품을 생산할 때 사용되는 데이터이다. 공정데이터 중 첫 번째 열에 있는 데이터는 핀치실링을 위한 공정과 관련된 데이터이다. 유리를 가열할 때 사용되는 산소와 수소의 양, 핀치 실링시 버너가 회전하는 속도와 가열시간, 램프에 가해지는 가열온도 등의 데이터가 이 공정에서 수집되며 데이터베이스서버에 저장된다.

두 번째 열은 어닐링(annealing)과 배기 공정이다. 이 공정은 램프내부를 열처리하고 진공 상태로 만들어 불순물을 제거한 후 가스 및 수은을 주입하는 공정이다. 따라서 이 공정에서는 열처리 유지시간, 열처리할 때의 온도와 램프에 주입되는 가스와 수은양 등이 주요 데이터로 생성된다.

두 번째 데이터 타입은 규격데이터로서 생산된 제품의 규격과 관련된 데이터이다. 이 데이터는 동일한 공정에도 램프마다 다른 램프의 길이, 핀치 두께, 전

표 1. 품질분석에 사용되는 데이터
Table 1. Data for analysis of product quality

category		data name
process data	Pinch sealing process	amount of oxygen , amount of hydrogen, burner speed, Heating temperature
	annealing & exhaust process	heat treatment time, temperature for heat treatment, gas injection amount, mercury injection amount
Specification		electrode spacing, pinch thickness, electric current, Voltage, intensity, Power factor, Temperature when lit
Environment		Ambient temperature, humidity

다. 예를 들어 주변 온도나 습도 등이 여기에 속한다.

3.2.2 데이터 분석

시스템의 분석 기능을 설명하기 전, 수집된 데이터의 효용성을 검증한다. 이 장에서는 간단한 알고리즘들을 이용하여 램프의 불량률을 판별하고 판별 정확도를 계산한다.

(1) 수명데이터 수집

생산된 제품 중 외관적으로 정상으로 보이는 일부를 램프 수명 테스트기를 사용하여 수명을 측정한 후 수명 데이터를 만든다. 램프 수명을 측정하는 램프 테스트기는 실제 평형수 처리장치에서 동작되는 것과 유사하게 램프를 주기적으로 켜고 끄으로써 램프의 수명을 측정한다. 램프가 더 이상 점등되지 않을 때 또는 밝기 강도 특정 값 이하가 되었을 때, 그때까지의 점등유지 시간을 수명시간으로 한다.

본 논문에서는 수명 테스트기에서 실험을 진행했을 때 램프의 수명이 1000시간 이하인 제품을 불량품이라 판단하였다. 상기 측정 과정을 통해 126개의 데이터셋을 얻었으며, 이 데이터셋은 정상품 52개와 불량품 75개로 구성되어 있다. 데이터 셋 중 약 80%인 100개의 데이터는 학습을 위해 사용하고, 나머지 26개의 데이터는 학습결과를 검증하기 위한 테스트 셋으로 사용하였다.

(2) 분석 모델

본 논문의 목적은 생산된 제품의 수명을 예측할 수 있는 분석 시스템을 설계하는 것이다. 하지만 현재 수집된 데이터의 수가 매우 적어 수명 예측에서 유의미한 결과를 보이지 않았다. 따라서 본 논문에서는 간단한 인공지능 모델을 사용하여 정상품과 불량품을 구분함으로써 수집된 데이터의 유의미성을 검증하고, 추후 충분한 데이터가 수집되면 수명 분석을 위한 모델을 설계하여 실제 업무에 활용될 예정이다.

불량품 분류 모델로서 서포트벡터머신(SVM), 의사결정트리(Decision Tree), 다층퍼셉트론(Multilayer Perceptron; MLP)을 사용하였다. 실험에 사용되는 알고리즘은 Python 프로그래밍 언어 기반인 Scikit learn^[10]과 Tensorflow^[11] 패키지를 이용하여 구현하였다. 본 논문에서 UV램프 품질 예측을 위해 최적화된 모델을 알고리즘을 제안하거나 설명하는 것은 본 논문의 목적을 벗어나는 것이므로, 단순한 알고리즘을 이용하여 수집 데이터의 유의미성을 판단하였다.

먼저 의사결정트리의 경우 Scikit learn의

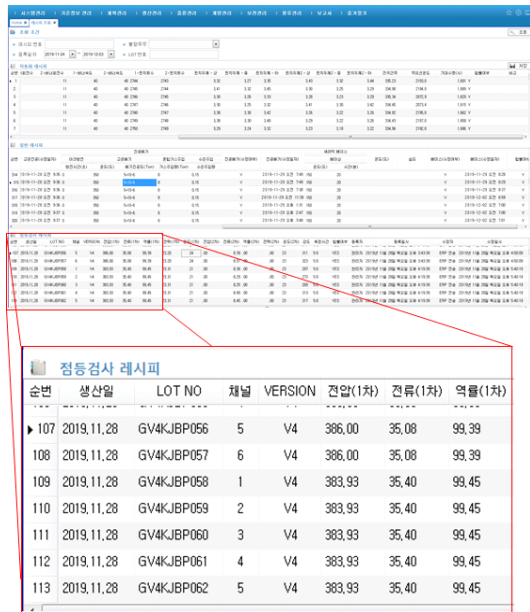


그림 10. 제품분석에 사용되는 데이터와 그 일부를 보여주는 모니터링 프로그램 화면

Fig. 10. Program showing the data used for quality analysis

극 간격 등을 가지는데 이것과 관련된 데이터들이 여기에 속한다. 또한 램프를 생산하고 램프들의 불량률 측정하기 위해 점등검사를 실시하는 때 이때 발생하는 각 램프의 전압, 전류, 점등 시 온도, 밝기 강도 등의 데이터들도 이 데이터 타입에 속한다. 즉, 규격데이터는 각 생산된 램프들의 특징과 관련된 데이터이다.

세 번째 데이터 타입에 포함되는 데이터는 환경 데이터로서 제품 주변의 측정 데이터들이 여기에 속한다.

DecisionTreeClassifier 함수를 사용하여 구현하였고 의사결정트리의 알고리즘 중 하나인 CART (Classification And Regression Tree)를 사용하였다. 트리의 분할 기준을 정하기 위해 지니 불순도(Gini Impurity)를 이용하였다. 나머지 변수는 함수의 기본 값으로 설정하였다. 또한 과적합 문제를 예방하기 위해 비용 복잡도 가지치기(Cost Complexity Pruning)^[12]를 이용하였다.

서포트벡터머신의 경우 Scikit learn의 SVC함수를 이용하여 구현하였으며 선형 서포트벡터머신이다. 이 모델에서 손실함수는 hinge loss이며 마진(margin) 넓이를 제어하는 C 파라미터는 1로 하였다. 나머지 변수는 기본 값으로 설정하였다.

마지막으로 다층퍼셉트론의 경우 Tensorflow를 사용하여 fully connected layer를 구현하였다. 총 5계층으로 구성되어 있고 은닉층은 각각 16개, 16개, 8개의 노드를 가지고 있는 3개의 계층이다. 또한 각각의 은닉층은 L2 규제(Ridge Regularization)를 이용하여 과적합을 방지하였다. 손실 함수는 cross entropy를 사용하였으며, 활성화 함수의 경우 은닉층은 relu 함수를, 출력층은 sigmoid 함수를 이용하였다. epoch는 2000, batch size는 10, learning rate는 0.1로 하였다.

(3) 분석 결과

표 2는 학습모델을 이용하여 테스트 데이터를 검증한 결과를 나타낸다. 표에서 정상품이 Positive이고 불량품이 Negative라 할 때, 정상품에 대한 TP(True Positive)와 불량품에 대한 TN(True Negative)는 정확히 예측한 경우이다. 반대로 FP(False Positive)와 FN(False Negative)는 잘못 판단한 경우를 나타낸다. 정확도(accuracy)는 옳게 판단한 경우의 수를 전체 경우의 수로 나누어 퍼센트(%)로 표현한 것이다.

의사결정트리의 경우 약 69.2%의 정확도를 보여 다른 모델에 비해 낮은 성능을 보였다. 이러한 결과를 보인 이유는 의사결정트리는 훈련데이터의 작은 변화에도 매우 민감하다^[13]. 따라서 과적합 문제를 피하는 것이 상대적으로 어렵다^[14]. 본 논문의 실험에서는 매

우 적은 수의 훈련데이터를 사용하였다. 따라서 다른 모델들처럼 과적합 문제를 피하기 위해 가지치기를 사용하였지만 훈련데이터가 매우 적어 대표성을 띠지 못하였고, 과적합되어 상대적으로 낮은 성능을 보였음을 유추할 수 있다.

서포트벡터머신과 다층퍼셉트론의 경우 각각 76.9%, 80.8%의 정확도를 보였다. 그리고 정상품 예측의 경우 다층 퍼셉트론은 11개 중에 7개만 옳게 예측하였고 4개는 틀리게 예측하였으며, 서포트벡터머신은 11개 중에 6개만 옳게 예측하였다. 하지만 두 모델 모두 불량품의 경우 1개를 제외하고 14개를 옳게 예측하였다. 따라서 수집된 데이터는 불량품 반별과 상관관계를 가지고 있다.

3.2.3 시스템의 분석기능

간단한 알고리즘을 이용하여 불량을 판별 하여 수집된 데이터의 유의미성을 검증하였다. 하지만 제안 시스템의 목적은 추후 충분한 데이터를 수집한 후 각 제품의 수명을 예측하는 것이다. 따라서 본 논문의 분석 시스템은 수명예측기능을 포함한 시스템을 구현하였으며, 그와 관련된 내용을 이 장에서 설명한다.

분석기능은 크게 3가지로 구분된다. 시스템의 첫 번째 기능으로 알고리즘의 학습을 수행하는 것으로써, 학습모델을 선택하고 학습을 진행하며, 학습결과 출력한다. 학습결과는 두 가지 파일로 나타낸다.

그림 11은 첫 번째 파일내부의 일부를 보여준다. 파일은 JSON형식으로 되어있으며 학습모델의 정보를 나타낸다. 예를 들어 어떤 학습 기법을 사용했는지, 그 학습기법에서 세부적인 파라미터, 사용할 데이터

표 2. 학습모델에 따른 정확도
Table 2. Accuracy of each algorithm

model	TP	TN	FP	FN	Accuracy (%)
Decision Tree	6	12	3	5	69.2
SVM	6	14	1	5	76.9
MLP	7	14	1	4	80.8

```
{
  "model_type": "MLP",
  "file_path": "",
  "encoding": "CP949",
  "data_path": "./data/datasets_learning.csv",
  "model_path": "./models/",
  "model_file_name": "model_result.h5",
  "class_ID": "LOT",
  "result_ID": "LIFETIME",
  "Learning parameter": "",
  "batch_size": 100,
  "epochs": 20000,
  "layer": [32, 32, 1],
  "activation_fn": ["relu", "relu", "relu"],
  "optimizer": "adam",
}
```

그림 11. 분석 알고리즘의 정보를 나타내는 파일의 내부
Fig. 11. Algorithm information contained in the file

파일 위치 등을 보여준다.

두 번째 파일은 첫 번째 파일을 토대로 만들어진 결과를 나타내는 파일이다. 이 파일을 사용한 학습방법에 따라 파일의 확장자가 다른데 의사결정트리의 경우 Scikit-learn 패키지를 이용하였기 때문에, 학습 결과는 IF-ELSE 룰을 보여주는 파이썬 언어파일(.py)로 생성된다. 인공신경망의 경우 Tensorflow 기반 학습 결과 파일(.h5)이 생성된다.

학습과 관련된 내용을 두 가지 파일로 분리함으로써 기계학습 알고리즘들을 다른 언어, 라이브러리로 구현하더라도 하나의 시스템에서 동작이 가능하도록

하였다. 즉, 제안 시스템은 학습모델 방법을 모듈형식으로 만들어 추후 다양한 학습모델 방법을 추가할 수 있다.

시스템의 두 번째 기능은 학습 결과 파일을 이용하여 생산된 제품의 수명을 실시간으로 측정하여 확인할 수 기능이다. 그림 12는 MES에서 제품의 생산데이터들을 토대로 분석된 제품의 기대수명을 화면에 보여준다.

품질 분석시스템의 마지막 기능으로 웹브라우저를 이용하여 각 제품 번호에 따른 수명예측 결과를 출력할 수 있는 기능이다. 이 기능은 외부에서 웹브라우저를 이용하여 기능을 사용할 수 있다. 따라서 제품 생산을 관리하는 직원뿐 만 아니라 제품을 구매한 고객사가 수명 예측결과를 직접 확인할 수 있도록 하였다. 따라서 이 기능을 통해 제조사와 고객이 효율적인 재고관리를 할 수 있도록 하였다.

그림 13은 웹페이지에 접속한 화면을 나타낸다. 웹페이지에 접속하여 수명예측을 원하는 제품의 제품번호를 입력하면 제품의 예측수명을 보여준다.

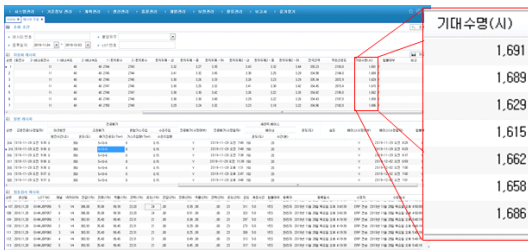


그림 12. 생산된 제품의 예측 수명 실시간 확인 화면
Fig. 12. Real-time monitoring of product life expectancy

IV. 결 론

본 논문에서는 UV램프 제조 시설을 예시로 하여 스마트 공장을 위한 센서 수집 시스템 설계를 보여준다. UV 램프의 제조과 관련된 데이터들을 수집 및 모니터링 할 수 있는 시스템을 구현하였고, 이 시스템은 실내와 실외의 특징을 구분하여 데이터의 통신 방식을 달리하여 데이터를 수집하였다. 수집된 데이터는 크게 공정데이터, 규격데이터, 환경데이터 등 3가지 타입으로 구분하여 데이터베이스 서버에서 관리된다.

또한 수집된 데이터를 활용한 제품 품질 분석 기능을 구현하였다. UV 램프의 경우 품질은 램프의 살균 지속시간(수명)과 관련되므로 생산된 제품 수명 예측을 위한 기능들로 시스템이 구성되었다. 특히, 실시간으로 생산된 제품의 수명예측 결과를 확인할 수 있을 뿐만 아니라, 웹브라우저를 이용하여 고객들이 구매한 제품의 예상수명을 확인할 수 있다. 이를 통해 제품 분석을 통한 품질 향상뿐만 아니라 효율적인 재고, 수요관리를 기대할 수 있다.

하지만 제조된 램프는 1,500시간이 넘는 긴 수명을 가지고 있어 현재 매우 적은 데이터만을 수집할 수 있었다. 수집된 데이터를 이용했을 시 불량 유무를 약 80.8%의 정확도를 판별할 수 있었다. 하지만 실제 업무에 활용되거나 램프의 수명 예측이 가능하려면 장 시간동안 많은 데이터의 수를 수집할 필요가 있다. 또

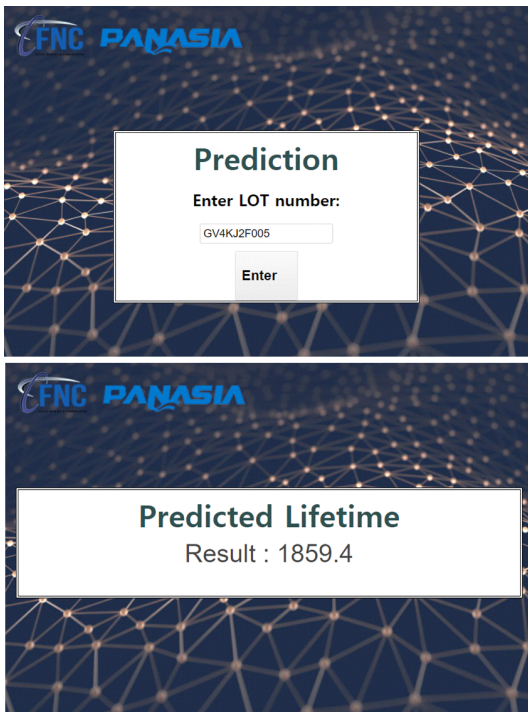


그림 13. LOT번호에 따른 램프 예측 수명 결과 확인할 수 있는 웹페이지
Fig. 13. Webpage showing product's predicted lifetime against LoT

한 충분한 데이터를 수집한 후 실제 업무에 활용될 수 있도록 분석모델을 개선하거나 설계할 필요가 있다.

References

[1] Y. H. Choi and S. H. Choi, "A study on the factors influencing the competitiveness of small and medium companies applied with smart factory system," *Inf. Syst. Rev.*, vol. 19, no. 2, pp. 95-113, Jun. 2017

[2] G. Büchi, M. Cugno, and R. Castagnoli, "Smart factory performance and Industry 4.0," *Technological Forecasting and Social Change*, vol. 150, p. 119790, Jan. 2020.

[3] J.-K. Park and T.-W. Chang, "Review of domestic research on smart manufacturing technologies," *The J. Soc. e-Business Stud.*, vol. 23, no. 2, May 2018.

[4] J. Park, "Technology and issue on embodiment of smart factory in small-medium manufacturing business," *J. KICS*, vol. 15, no. 12, Dec. 2015.

[5] D. Mourtzis, E. Vlachou, and N. J. P. C. Milas, "Industrial big data as a result of IoT adoption in manufacturing," *5th CIRPe 2016, Research and Innovation for Future Production*, pp. 290-295, Patras, Greece, Oct. 2016.

[6] S.-G. Cheon, et al., "Development of an ultra-violet lamp and a ballast for ship's ballast water treatment," *J. Korean Soc. Marine Eng.*, vol. 35, pp. 675-681, Jul. 2011.

[7] J. Kim, et al., "Design of environment data collection system for smart factory," *KSC*, pp. 319-321, Pyeongchang, South Korea, Dec. 2018.

[8] S.-S. Lee, et al., "A study on standardization of manufacturing execution system (MES) master data for solar module production," *J. ITPM*, vol. 13, no. 2, pp. 1671-1680, Apr. 2020.

[9] LoRa Alliance, *What is LoRaWAN*(2015) Retrieved Oct. 7, 2020, from <https://loro-alliance.org/resource-hub/what-lorawan>

[10] F. Pedregosa, et al., "Scikit-learn: Machine

learning in Python," *J. Mach. Learn. Res.*, vol. 12, no. 85, pp. 2825-2830, Oct. 2011.

[11] M. Abadi, et al., *Tensorflow: Large-scale machine learning on heterogeneous distributed systems*(2016), Retrieved Oct. 7, 2020, from <https://dalspace.library.dal.ca/handle/10222/14184>

[12] L. Breiman, et al., *Classification and Regression Trees*, Wadsworth, 1984.

[13] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*, 2nd Ed., O'Reilly Media, 2019.

[14] R. G. Leiva, et al., "A novel hyperparameter-free approach to decision tree construction that avoids overfitting by design," *IEEE Access*, vol. 7, pp. 99978-99987, Jul. 2019.

김 재 민 (Jaemin Kim)



2018년 2월 : 부산대학교 정보 컴퓨터공학부 졸업
 2020년 2월 : 부산대학교 전기 전자컴퓨터공학과 석사
 2020년 4월~현재 : 부산대학교 동남권 Grand ICT연구센터 연구원

<관심분야> 센서네트워크, 사물인터넷, 인공지능
 ORCID:0000-0003-2337-8287

유 영 환 (Youngwan Yoo)



1996년 2월 : 서울대학교 컴퓨터 공학과 학사
 1998년 2월 : 서울대학교 컴퓨터 공학과 석사
 2004년 2월 : 서울대학교 전기컴퓨터공학부 박사
 2004년 5월~2006년 12월 : 미국

신시내티대학교 전기전자컴퓨터과학과 연구원
 2007년 3월~현재 : 부산대학교 정보컴퓨터공학부 교수
 <관심분야> 지능형네트워크, 5G이동통신, 사물인터넷
 [ORCID:0000-0002-2813-6116]