

프레스 공정에서 인공지능기반 실시간 제품 불량탐지 시스템 설계 및 구현

김동현¹ · 이재민² · 김종덕^{3*}

Design and Implementation of a Real-Time Product Defect Detection System based on Artificial Intelligence in the Press Process

Dong-Hyun Kim¹ · Jae-Min Lee² · Jong-Deok Kim^{3*}

¹Research Professor, Dong-Nam Grand ICT R&D Center, Pusan National University, Busan, 46241 Korea

²Doctor course Student, School of Computer Science and Engineering, Pusan National University, Busan, 46241 Korea

^{3*}Professor, School of Computer Science and Engineering, Pusan National University, Busan, 46241 Korea

요 약

프레스 공정은 가열 또는 가열하지 않은 상태의 재료에 힘을 가해 원하는 형태로 변형시켜 제품을 만드는 압축 가공 과정이다. 짧은 시간의 연속 압축을 통해 제품을 생산하는 프레스 장비의 특성상 제품 불량은 연속적으로 발생하며 이러한 문제를 해결하기 위한 시스템은 다양한 기술을 이용하여 개발되고 있다. 본 논문은 불량을 탐지하는 인공지능 알고리즘을 기반으로 실시간 불량탐지 시스템을 제안한다. 프레스 장치에 각종 센서를 부착하여 장비의 상태와 불량과의 관계를 빅데이터 플랫폼을 기반으로 정의하고 수집한다. 수집된 데이터를 기반으로 인공지능 알고리즘을 개발하고 개발된 알고리즘을 임베디드 보드를 이용하여 구현함으로써 실제 현장에 적용하여 시스템의 실용성을 보여준다.

ABSTRACT

The pressing process is a compression process in which a product is made by applying force to a heated or unheated material to transform it into the desired shape. Due to the characteristics of press equipment that produces products through continuous compression for a short time, product defects occur continuously, and systems for solving these problems are being developed using various technologies. This paper proposes a real-time defect detection system based on an artificial intelligence algorithm that detects defects. By attaching various sensors to the press device, the relationship between equipment status and defects is defined and collected based on a big data platform. By developing an artificial intelligence algorithm based on the collected data and implementing the developed algorithm using an embedded board, we will show the practicality of the system by applying it to the actual field.

키워드 : 인공지능, 불량탐지, 생산관리시스템, 스마트공장, 프레스 공정

Key word : Artificial intelligence, Faulty detection, Manufacturing execution system, Smart factory, Press process

Received 8 April 2021, Revised 16 April 2021, Accepted 1 May 2021

* Corresponding Author Jong-Deok Kim(E-mail:kimjd@pusan.ac.kr, Tel:+82-51-510-3519)

Professor, School of Computer Science and Engineering, Pusan National University, Busan, 46241 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.9.1144>

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

스마트팩토리는 제조, 유통, 물류 등 생산과정에 디지털 자동화 솔루션이 결합한 정보통신기술을 적용하여 생산성, 품질, 고객만족도를 향상하는 지능형 생산공장으로 Big data, AI(인공지능), 산업용 사물인터넷(IIoT) 기술과 결합하여 사용 영역을 확장하고 있으며 향후 생산성 향상을 위한 Industry 4.0의 핵심 지능형 생산 프레임 워크로 자리를 잡고 있다[1].

인공지능은 인간의 학습능력과 추론능력, 지각능력 및 자연언어의 이해능력 등을 알고리즘으로 설계하고 컴퓨터 프로그램으로 실현한 기술이다. 이것은 인간의 지능으로 할 수 있는 사고, 학습 및 자기 개발 등을 컴퓨터가 할 수 있도록 하는 방법을 연구하는 컴퓨터 공학 및 정보통신 기술의 한 분야로서, 컴퓨터가 인간의 지능적인 행동을 모방할 수 있도록 하는 전체적인 과정을 가리키며 대표적으로 Machine Learning(기계학습), Deep Learning(심층학습), Reinforcement Learning(강화학습)이 있다. 그리고 이러한 인공지능 기술은 많은 영역에서 융합기술로 응용되며 연구가 진행 중이다[2].

프레스 공정은 가열 또는 가열하지 않은 상태의 재료에 힘을 가해 원하는 형태로 변형시켜 제품을 만드는 압축 가공 과정으로 불량품의 발생은 생산성에 있어 막대한 손실을 줄 수 있으며, 제품의 품질을 저해하는 큰 요소로 작용한다[3]. 대부분의 프레스 공정은 단일공정이 아닌 다중공정과정을 통해 제품을 생산하는데 이러한 환경에서 제품 불량을 추적 및 예측하는 것은 대단히 어려운 문제이다[4].

이러한 문제를 해결하기 위해 본 논문은 다중 프레스 공정에서 제품 불량을 예측하기 위한 인공지능 기반 시스템을 제안한다. 이를 위해 장비에 진동 센서를 부착하고 정상 제품과 불량제품이 발생할 때의 프레스 동작 정보 및 진동 센서 정보를 수집한다. 수집된 정보를 기반으로 인공지능 알고리즘을 설계하고 구현한다. 그리고, 현장 적용을 위한 시스템을 설계 및 구현하여 사용의 실용성을 보이겠다.

본 논문의 이후 구성은 다음과 같다. 2장에서는 관련 연구로 프레스 공정과 인공지능 알고리즘의 하나인 CNN에 대하여 설명한다. 3장에서는 시스템 설계로 데이터 수집에서 전처리, 학습모델 설계 및 정확도 분석을 위한 학습 단계와 학습에 사용된 데이터 세트를 설명하

며 4장에서는 설계된 시스템을 구현하기 위하여 전체 시스템 구조와 실시간 데이터 처리를 위한 방법 및 웹 기반 실시간 불량탐지 애플리케이션에 대하여 설명한다. 5장에서는 설계된 모델의 성능을 확인하기 위한 다양한 성능지표 및 그에 따른 모델의 성능을 설명하고 마지막으로 6장에서는 결론을 도출하고 향후 연구 방향을 제시한다.

II. 관련 연구

프레스 공정은 하나의 제품을 생산하기 위해 단일 압축을 할 수도 있지만, 대부분은 하나의 제품을 생산하기 위해 다수의 압축 및 절단 과정을 거친다. 이러한 환경에서 불량품을 판정하는 것은 대단히 어려운 일이고, 특히 불량품이 발생하는 시점을 알아내는 것은 매우 큰 비용과 노력이 필요하다. 프레스 공정과정에서 제품 불량과 관련한 인공지능 연구들이 있다. 대표적인 것이 영상을 이용한 제품 불량 탐지기술로 양품의 영상과 불량품의 영상을 이용하여 학습하고 이를 기반으로 제품 불량을 판단한다. 이를 위해서는 고성능의 카메라가 필요하고 판정을 위한 시스템 또한 고성능의 GPU를 이용해야 하므로 비용이 올라가는 문제가 있다. 그리고 공정에 따라 카메라로 제품의 불량 유무를 판단하기 어려운 경우도 많아서 매우 제한적인 영역에서 사용되고 있다[5].

현재 생산 중인 프레스 기계에 최소한의 센서를 부착하고 시계열 데이터를 이용한 불량 및 정상품일 때의 정보를 수집하고 이를 이용하여 인공지능 알고리즘을 생성한 후 현장에 적용하고자 한다. 인공지능 알고리즘은 합성곱 신경망(Convolutional Neural Network, CNN)을 기반으로 하며 이것은 시각적 영상을 분석하는 데 사용되는 다층의 피드-포워드적인 인공신경망의 한 종류이다. 딥러닝에서 심층 신경망으로 분류되며, 시각적 영상 분석에 주로 적용된다. 또한, 공유 가중치 구조와 변환 불변성 특성에 기초하여 변이 불변 또는 공간 불변 인공신경망으로도 알려져 있다. 영상 및 동영상 인식, 추천 시스템, 영상 분류, 의료 분석 및 자연어 처리 등에 응용된다. 합성곱 신경망은 크게 합성곱층(Convolutional Layer)와 풀링층(Pooling Layer)으로 구성된다[6].

합성곱층은 입력데이터로부터 특징을 추출하는 역할을 한다. 합성곱층은 특징을 추출하는 기능을 하는 필터

(Filter)와 이 필터의 값을 비선형 값으로 바꾸어 주는 활성 함수(Activation Function)로 이루어진다. 풀링층은 데이터의 공간적인 특성을 유지하면서 크기를 줄여주는 층으로 연속적인 합성곱층 사이에 주기적으로 위치한다. 데이터의 공간적인 특성을 그대로 유지하면서 크기를 줄여, 특정 위치에서 큰 역할을 하는 특징을 추출하거나, 전체를 대변하는 특징을 추출할 수 있는 장점이 있다. 또한, 크기가 줄어들어 학습할 가중치를 크게 줄이게 되고 이것은 과적합 문제(Overfitting problem) 해결에도 도움이 된다. 풀링은 값을 추출하는 방식에 따라 Max Pooling과 Average Pooling으로 구분한다. 본 논문의 인공지능 알고리즘은 경량 장비에서의 사용을 고려하여 3개의 합성곱층과 풀링층으로 구성하고자 한다[7].

III. 시스템 설계

3.1. 시스템 구성

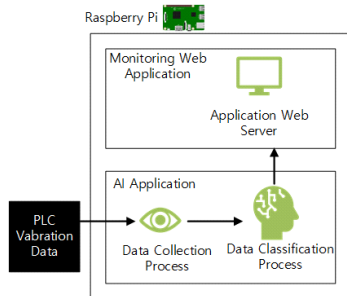


Fig. 1 Block diagram of the real-time faulty prediction system based on artificial intelligence in the pressing process

그림 1은 스마트 팩토리에서 생산/ 공정 데이터 분석을 통한 인공지능 기반 제품 불량 탐지모델이 포함된 실시간 불량탐지 시스템의 구성도이다. 제안한 시스템은

라즈베리파이 3 하드웨어에서 동작하며 데이터 수집 프로세스, 분류 프로세스 및 시각화 웹 애플리케이션으로 구성된다[8].

데이터 수집 프로세스는 일정한 주기로 PLC(Programmable Logic Controller)로부터 불량탐지를 위한 데이터를 수집한다. 데이터 분류 프로세스는 수집한 데이터를 인공지능 기반 학습모델에 입력하고 학습모델은 정상 제품, 불량제품 중 하나를 분류한다. 시각화 웹 애플리케이션은 실시간 데이터 수집 값과 분류 결과를 나타낸다.

3.2. 불량탐지 모델

불량탐지 모델의 학습 과정은 학습데이터 수집, 데이터 전처리, 인공지능 학습, 제품 불량탐지 정확도 분석으로 이루어진다. 그림 2는 불량탐지 모델을 위한 학습 단계를 나타낸다. 데이터는 프레스에서 발생하는 전압, 전류와 같은 장비의 고유 속성 정보와 온도 및 진동 센서와 같은 검출 정보이다. 그리고, 수집된 데이터의 다양한 속성 중 학습에 활용할 수 있는 속성들을 선별한다. 선별된 데이터들은 학습하기 전 전처리 과정을 통해 정제된다. 제품 불량을 탐지하는 인공지능 모델은 앞선 과정을 모두 처리한 데이터 집합을 학습한다. 모델은 학습을 모두 수행한 뒤 다양한 지표들을 통해 평가된다. 모델은 더 나은 성능을 위해 파라미터 등을 수정하여 앞서 설명한 학습과 평가 과정을 반복한다. 추가로 완성된 불량탐지 모델은 GPU 서버에서 수행했으며, 이를 라즈베리파이로 옮겨 실시간 인공지능 기반 불량탐지 시스템을 설계 및 구현한다.

3.2.1. 학습데이터 수집

학습 데이터 수집은 아날로그 정보인 진동 센서값과 시간, 이산정보인 불량 발생 정보와 불량이 발생하였을 때의 시간 정보를 수집한다. 진동 센서값의 시간과 이상 발생할 때의 시간을 동기화하였으며 진동 센서의 정보




Fig. 2 Learning process of artificial intelligence of false detection

수집 주기는 100Hz이다. 불량 발생 시간 이전 2초의 진동 센서 데이터를 하나의 학습 데이터 세트로 정하고 불량 데이터를 수집한다. 그림3은 정상 동작과 불량 발생 시의 진동 데이터값을 보여주며 이러한 데이터를 기반으로 불량과 정상 상태일 때의 데이터 세트를 구성한다.




Fig. 3 Comparison of faulty and Normal running signal

3.2.2. 데이터 전처리 및 데이터 분류

데이터 수집 과정을 거쳐 불량과 정상 상태의 진동 값을 수집하였다. 정상시 불량률이 0.002% 미만이기 때문에 불량 상태일 때 데이터가 매우 부족하다. 그래서 데이터 전처리 과정을 거쳐 데이터를 임의로 생성하는 과정을 거쳤다.




Fig. 4 Data preprocessing process

그림 4는 원 데이터를 바탕으로 불량 데이터 생성을 위한 데이터 전처리 과정이다. 하나의 불량에 대하여 200개의 데이터가 생성되는 시계열 데이터의 특성상 데이터 하나를 기준으로 Moving Shift 하는 방법으로 데이터를 추가 생성하였다. 불량하나에 대하여 200개의 시계열 데이터가 생성되고 200개의 시계열 데이터를 가지고 각각 200개씩 데이터가 생성되기 때문에 불량이 발생할 때마다 200개의 불량 데이터 세트가 생성된다.

정상 운용보다 제품 불량이 발생하는 경우가 매우 적어서 불량제품 데이터수집을 위해 30일간 데이터수집 기간을 가졌으며 196개의 불량 데이터를 얻을 수 있었다. Training, Validation, Test의 데이터 비율은 6:2:2로 구성하였으며 구성된 데이터는 아래 표1과 같다.

Table. 1 Distribution of training, validation, and test dataset for Normal and False running

Category	Normal Running	False Running	Total
Training	23,520	23,520	47,040
Validation	7,840	7,840	15,680
Test	7,840	7,840	15,680
Total	39,200	39,200	78,400

3.2.3. 인공지능 모델

본 논문은 제품 불량 시계열 데이터 구분을 위해 합성곱 신경망 알고리즘을 이용하였다. 학습알고리즘 구조는 그림5와 같다. 진동 센서 신호의 시계열 신호를 입력으로 사용하고 불량품과 정상품 예측을 출력한다.

프레스 동작 주기가 2초이기 때문에 2초의 신호를 100Hz로 샘플링하였으며 모델은 초당 한 번씩 새 예측을 출력한다. 모델의 구성은 3개의 합성곱 층과 3개의 MaxPooling층 그리고 Dropout과 SoftMax층을 포함한다.

불량품과 정상품의 신호 파형은 다르다. 또한, 신호 파형은 2초 내 위치를 특정하기 어렵다. 따라서, 본 모델은 2초 내 불특정 위치의 불량품 신호 파형을 탐지하는 것을 의도한다. 다시 말해, 본 모델은 시계열 데이터 간의 관계를 구분해내는 것이 아니라 불량 특징을 탐지하는 모델이다.




Fig. 5 Block diagram of learning model

IV. 시스템 구현

4.1. 전체 시스템 구조

프레스 공정에서 인공지능기반 불량예측 시스템의

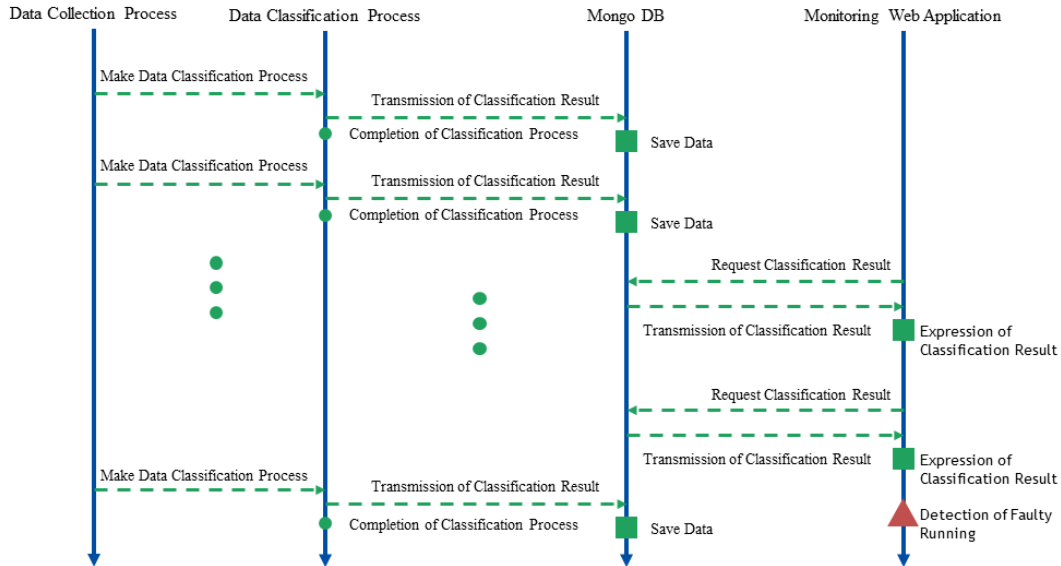


Fig. 6 Operation process of real-time product defect detection system based on artificial intelligence

성능을 확인하기 위한 시스템 구조는 그림 6과 같다.

시스템은 데이터 멀티 프로세서인 수집 프로세스, 데이터 분류 프로세스 그리고 몽고DB와 모니터링 웹 애플리케이션으로 구성된다. 데이터 수집 프로세스와 데이터 분류 프로세서는 멀티 프로세서로 동시에 동작한다. 데이터 수집 프로세서는 진동 센서값을 100Hz 단위로 수집하며 200개(2초)의 데이터를 수집한 후 분류 프로세서를 생성한다. 분류 프로세서는 200개의 데이터를 학습 네트워크를 통해 분류하고 분류된 결과를 몽고 DB에 저장한다. 모니터링 웹 애플리케이션은 몽고 DB로 분류 결과를 확인하기 위한 메시지를 요청하고 그 결과를 웹 애플리케이션을 통해 표시한다. 이러한 과정을 반복적으로 수행함으로써 제품 불량을 탐지하고 사용자에게 탐지 여부를 알려준다.

OPC-UA(Open Platform Communication Unified Architecture)를 통해 PLC(Programmable Logic Controller)의 진동 센서 정보를 실시간으로 수집하고 분류하여 웹 애플리케이션을 통해 결과를 보여주기 위해서 데이터 가공 과정을 거쳤다[9][10]. 그림 7은 실시간 데이터 처리를 위한 데이터 수집 프로세서와 데이터 분류 프로세스의 동작 과정을 나타낸다. 그림 8은 실시간 데이터 처리를 위한 데이터 세트의 Moving Shift 구조를 나타내며 그림 9는 실시간으로 불량품과 정상품을 구별한 웹 애플리케이션과 실시간 데이터수집 장면을 나타낸다.

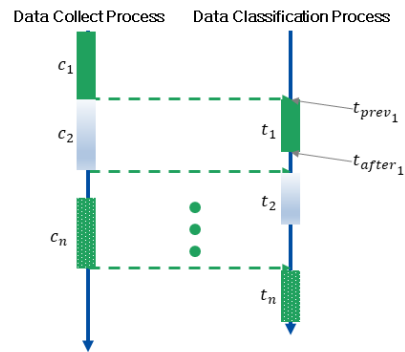


Fig. 7 Relationship between data collection and classification for real-time data processing




Fig. 8 Data structure diagram for real-time data processing



Fig. 9 A screen of a web application showing the results of the product False prediction system and real-time data collection

V. 성능분석

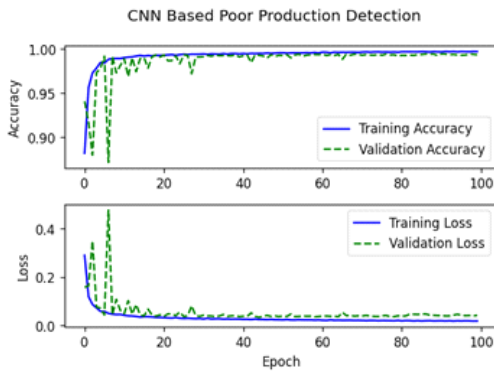


Fig. 10 Training accuracy, validation accuracy, training loss, and validation loss according to the epoch during the learning process

그림 10은 학습 과정 중 Training Accuracy, Validation Accuracy, Training Loss 그리고 Validation Loss 지표변화를 나타낸다. Epoch는 전체 트레이닝 셋이 신경망을 통과한 횟수를 의미한다. 예를 들어 1-epoch는 전체 트레이닝 셋이 하나의 신경망에 적용되어 순전파와 역전파를 한 번 통과했다는 것을 의미한다[11]. 학습 과정 중 초기 epoch들은 Validation Data와 Training Data 간 Loss와 Accuracy의 차이가 크다. 그러나 학습이 진행되면서 약 20-epoch부터 정확도와 손실이 최고의 성능에 근사하기 시작한다. 또한, 과적합(Overfitting)은 모델의 성능이 일정한 수준에 도달했을지라도 모델이 Training Loss를 줄이는 데 초점을 두어 오히려 Validation Loss가 증가한 상황을 말한다. 그림 10의 결과로 본 모델은

과적합이 발생하지 않는 수준에서 최고 성능에 도달했다고 말할 수 있다.

Table. 2 Confusion matrix about learning result

Category	Normal Running	False Running
Normal Running	7,831(TN)	36(FP)
False Running	47(FN)	7,766(TP)

표 2는 학습 결과에 따른 혼동행렬을 나타낸다. 테스트 셋 15,680개 중 정상운용을 정상 운용으로 판정한 것은 7,831이고 정상 운용을 불량운용으로 판정한 것은 36건이었다. 이에 반해, 불량운용을 불량운용으로 판정한 것은 7,766건이고 불량운용을 정상 운용으로 판정한 것은 47건이었다. 수많은 데이터 중에 불량운용 데이터를 탐지하는 것이 목표이기 때문에 불량을 불량으로 판정한 것을 True Positive(TP)로 정했으며 정상 운용을 정상 운용으로 판정한 것을 True Negative(TN)로 정했다. 그리고 불량운용을 정상 운용으로 판정하는 것을 False Negative(FN), 정상 운용을 불량운용으로 판정하는 것을 False Positive(FP)로 정했다. 학습 결과에 대한 정밀도(Precision), 재현율(Recall), F1-score는 표 3과 같다.

Table. 3 Precision, recall, and F1-score according to normal running and false running

Category	Precision	Recall	F1-score
Normal Running	0.99	1.00	0.99
False Running	1.00	0.99	0.99

정밀도는 Positive로 예측된 그것(TP+FP) 중 양성(Positive)의 비율이며 양성에 대한 평가의 정확도로서 양성 예측도라고 한다. Precision은 수식 1과 같다.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

재현율은 전체 경기 양성(TP+FN) 중 양성으로 분류된 것(TP)의 비율이며 양성 샘플이 얼마나 식별되었는지를 보여준다. 민감도, 적중률이라고도 하며 수식 2와 같다.

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

F1-Score는 정밀도와 재현율을 하나로 요약한 값이다. 모든 샘플을 양성으로 예측하면 FN은 0이고, TP는

모두 찾지 않으므로 재현율은 1이 된다. 그러나 그 경우 가짜 양성 즉, FP가 높아지므로 정밀도는 낮아진다. 반대로 하나만 양성으로 판정했는데 그것이 맞았고, 그 외 모든 샘플은 무조건 음성으로 예측하면 TP는 1이고, FP는 0이므로 정밀도는 1이 된다. 그러나 그 경우 가짜 음성 즉, FN이 높아지므로 재현율은 낮아진다. 이처럼 정밀도와 재현율은 그 값이 반비례할 수 있어서 둘의 평균을 구할 때는 조화평균의 방법을 이용한다. 조화평균은 한쪽의 점수가 극단적인 것을 반영하는 특징이 있으며 수식 3과 같다.

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

정밀도, 재현율, F1-score 모두 0에서 1의 값을 가지며 1이 가까울수록 성능이 우수하다 할 수 있다. 표 3에서 볼 수 있듯이 모든 요소에 대하여 성능이 우수함을 확인 할 수 있다.

VI. 결론

프레스 공정은 금속가공 및 생산 방법 중 하나로 얇은 금속판에서 제품 형상을 떼어내거나 금속을 구부려 원하는 형상을 얻어내는 것으로 강한 힘으로 철판을 찍어서 가공하는 모든 방식을 의미한다. 수많은 제품은 프레스 공정을 거쳐 생산되며 공장자동화 또는 스마트팩토리를 위해서 프레스 공정을 위한 장비 모니터링 및 장비 상태에 따른 불량품 예측은 필수적인 기술이며 향후 급속히 발전할 것으로 예측된다.

본 논문에서는 프레스 공정간 발생하는 불량품을 예측하기 위해 프레스 장비에 진동 센서를 부착하고 불량품과 정상품일 때의 진동 센서값을 수집하였다. 수집된 데이터를 기반으로 인공지능 학습모델을 생성하였으며 인공지능 모델기반 실시간 불량예측 시스템을 설계 및 구현하였다. 모델의 성능은 혼동행렬, 정밀도, 재현율, F1-score를 이용하여 평가하였으며 현장에서 사용 가능한 수준의 성능을 얻었다. 본 논문은 불량과 정상품에 대한 진동 값만을 이용하여 실시간으로 불량품을 예측하였지만 보다 많은 데이터를 수집하고 분석하면 장비 자체의 이상을 예측할 수 있는 예지 보전 기술로 발전할 수 있을 것이며 이를 위한 근간을 마련하였다 할 수 있

다. 추후 이와 관련된 연구가 필요하다.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education (NRF-2020R111A306594711).

References

- [1] D. H. Kim, J. M. Lee, and J. D. Kim, "Design and Implementation of Real Time Device Monitoring and History Management System based on Multiple devices in Smart Factory," *Journal of The Korean Institute of Information and Communication Engineering*, vol. 25, no. 1, pp. 124-133, Jan. 2021.
- [2] S. G. Han, "Educational Contents for Concepts and Algorithms of Artificial Intelligence," *The Korean Society of Computer and Information*, vol. 26, no. 1, pp. 37-44, Jan. 2021.
- [3] J. W. Yun, "A Study for In-process Monitoring in Press die," *Korea Academy Industrial Cooperation Society*, vol. 18, no. 6, pp. 692-696, Jun. 2017.
- [4] Y. J. Jeon, H. S. Choi, Y. B. Ko, and D. E. Kim, "Perform Process Design to Form Sharp Wedges on Both Surfaces of Anti-loosening Washer," *The Korean Society Of Automotive Engineers*, vol. 28, no. 12, pp. 897-901, Dec. 2020.
- [5] D. H. Kim, S. B. Boo, H. C. Hong, W. G. Yeo, and N. Y. Lee, "Machine Vision-based Defect Detection Using Deep Learning Algorithm," *Journal of The Korean Society for Nondestructive Testing*, vol. 40, no. 1, pp. 47-52, Feb. 2020.
- [6] H. J. Shin, N. J. Kwak, and T. S. Song, "Detection The Behavior of Smartphone Users using Time-division Feature Fusion Convolutional Neural Network," *Journal of The Korean Institute of Information and Communication Engineering*, vol. 24, no. 9, pp. 1224-1230, Sep. 2020.
- [7] H. C. Lee, I. H. Park, T. H. Im, and D. T. Moon, "CNN-based Building Recognition Method Robust to Image Noises," *Journal of The Korean Institute of Information and Communication Engineering*, vol. 24, no. 3, pp. 341-348, Mar. 2020.
- [8] Raspberrypi project [Internet]. Available: <https://www.raspberrypi.org/>.

- [9] OPC FOUNDATION [Internet]. Available:
<https://opcfoundation.org/>.
- [10] EMERSON AUTOMATION SOLUTIONS [Internet].
Available: <https://www.emerson.com/en-gb/>.
- [11] N. Adiga, D. Govind, and M. Prasanna, "Significance of epoch identification accuracy for prosody modification," in *Proceeding of the 2014 International Conference on Signal Processing and Communications (SPCOM)*, Bangalore, India, 2014.



김동현(Dong-Hyun Kim)

2013년 부산대학교 전자전기컴퓨터공학과 (공학박사)
2013년 ~ 현재 : 부산대학교 동남권 그랜드 ICT 연구센터 연구교수
※관심분야: 무선통신, 사물인터넷, 무선 멀티미디어 방송 시스템, LPWAN



이재민(Jae-Min Lee)

2017년 부산대학교 정보컴퓨터공학부 (공학사)
2017년 3월 ~ 현재 : 부산대학교 정보융합공학과 석박사통합과정
※관심분야: 무선 이동통신, 인공 신경망, 최적화, LPWAN



김종덕(Jong-Deok Kim)

2003년 서울대학교 컴퓨터공학과 (공학박사)
2004년 ~ 현재 : 부산대학교 정보융합공학과 교수
※관심분야: 무선통신, 사물인터넷, 무선 멀티미디어 방송 시스템, LPWAN