

스마트 공장의 품질예측을 위한 딥러닝 모델 적용 연구 - 플라스틱 사출공정을 중심으로

조현민, 신현준*
상명대학교 경영공학과

A Study on Deep Learning Models Application for Quality Prediction in Smart Factory - A Case for Plastic Injection Molding Process

Hyunmin Cho, Hyun Joon Shin*
Department of Management Engineering, Sangmyung University

요약 스마트공장의 고도화된 기술들을 통해 산업 현장에서 생성되는 무수히 많은 데이터를 기반으로 공정 내에 발생하는 문제의 원인을 분석하고 탐색하는 것이 실시간으로 가능하며, 이러한 데이터를 바탕으로 효율적인 의사결정을 할 수 있게 된다. 본 연구에서는 플라스틱 사출성형 공정 내 센서들에서 생성되는 총 36개의 제조조건 데이터 학습을 통해 제품의 품질을 예측하는 것을 목표로 한다. 품질 예측을 위한 딥러닝 모델은 잡음 제거 오토인코더, 장·단기 기억신경망, 합성곱 신경망을 적용하였다. 학습 데이터 셋은 KAMP(Korea AI Manufacturing Platform)를 통해 수집하였고 모두 양품과 불량품에 대한 레이블링이 되어있다. 각 모델별 파라미터를 달리하여 성능을 평가하였으며, 각 모델을 비교·분석하여 좋은 성능을 내는 모델과 파라미터 셋을 혼동행렬 및 f1-score를 활용하여 성능을 평가하였다. 본 연구에서 제안한 딥러닝 모델에 기반을 둔 사출공장 품질예측 시스템은 사출기계로부터 실시간 취합되는 센서 데이터 셋을 이용하여 공정 조건 변화에 따른 품질을 예측하게 함으로써 품질 신뢰도를 향상하고 공정 품질검사 투입인력을 절감할 수 있을 것으로 기대한다.

Abstract When it comes to smart factories technology, the analysis, and exploration of the causes of problems in the processes can be made in real-time, based on the myriad data gathered from manufacturing facilities, and efficient decisions can be made based on these data. We conducted a study to predict the quality of products through the analysis of sensor data from the plastic injection molding process. We utilized a denoising autoencoder (DAE), long-shot memory network (LSTM), and a convolutional neural network (CNN) to formulate deep learning models for quality prediction. The training data set was collected through KAMP (Korea AI Manufacturing Platform) and the information regarding defects was labeled. Performance was evaluated by different parameters for each model and compared using two measures such as the confusion matrix and f1-score. A quality prediction system based on deep learning models for an injection molding factory makes it possible to accurately predict the quality according to a change in process conditions by utilizing the sensor data set gathered from the machines. We can therefore expect an improvement in quality and reliability and a reduction of the input manpower for process quality inspection.

Keywords : Smart Factory, Plastic Injection Molding, Quality Prediction, Deep Learning, DAE, LSTM, CNN

본 연구는 2020학년도 상명대학교 교내연구비를 지원받아 수행하였음.

*Corresponding Author : Hyun Joon Shin(Sangmyung Univ.)

email: hjshin@smu.ac.kr

Received June 29, 2021

Accepted October 1, 2021

Revised July 26, 2021

Published October 31, 2021

1. 연구배경

글로벌 기업들은 산업현장에서 활용되는 기술들을 꾸준히 발전시키고 진화하여 과거의 단순한 생산방식으로부터 데이터를 기반으로 하는 디지털 트랜스포메이션으로의 변환과 함께 새로운 비즈니스 모델을 창출하고 있다. 나날이 발전하는 산업의 변화에 얼마나 빠르게 적응하는지에 따라 경쟁력이 달라지며 국가의 산업발전과 경제성장에 큰 영향을 미칠 것이다. 제조업 강국인 독일, 일본뿐만 아니라 미국, 중국을 포함한 상당수 국가가 4차 산업 혁명에 대응하는 국가 전략을 시행 중이며, 이를 통해 자국 제조업 경쟁력을 강화하고 첨단제조기술 시장을 선도하기 위해 치열하게 경쟁하고 있다[1]. 우리나라도 4차 산업혁명에 대응하기 위해 제조업의 혁신성장을 도모하도록 스마트공장을 중심으로 대응하고 있다. 스마트공장은 생산시스템을 유연화·최적화·효율화·지능화하여 생산비용 절감과 생산성을 향상하는 것을 목표로 한다. 이와 더불어 빠르게 변화하는 소비자의 수요에 능동적으로 대응하고, 최소한의 비용으로 제조공정을 변경할 수 있도록 생산시스템을 구축하는 부분에 초점을 맞추고 있다. 이에 스마트공장은 주문에 따라 맞춤형 생산이 가능하고, 생산량에 따라 유연하게 생산할 수 있어야 한다. 스마트공장이 실현되면 제조공정에서 생성되는 데이터를 기반으로 의사결정 하는 공장 운영체계를 갖추게 된다. 또한, 데이터 기반의 제조공정 운영체계를 갖추으로써 공정 내 발생하는 정보뿐 아니라 실시간 데이터 분석으로 불량 예측과 품질문제에 대한 문제해결을 보다 정확하고 신속하게 처리할 수 있게 된다. 이러한 이유로 최근 제조공정 현장에서 생성되는 데이터 수집은 매우 중요하다. 수집된 데이터의 관계와 규칙, 패턴, 정보를 통한 분석을 시각화하여 의사결정에 도움을 주는 데이터마이닝 분야의 연구가 활발히 진행되고 있다[2]. 이에 글로벌 제조 기업들은 공정에서 생성되는 데이터를 수집하고 데이터베이스를 구축하여 관리하고 있다. 이를 바탕으로 인공지능 기술을 활용한 빅데이터 분석, 딥러닝 모델을 활용한 품질관리의 효율성과 정확성을 높이고 있다. 우리나라의 스마트공장 규모는 제조 강국 사이에서 5번째 규모를 가지고 있다[3]. 기존 품질관리는 많은 인력과 비용이 발생하였지만, 스마트공장의 도입으로 데이터분석을 통해 최소한의 비용으로 제조공정의 품질관리를 효율적으로 운영할 수 있다.

플라스틱 사출 성형기 운용 중 실제 많은 불량들이 발생하는데 불량이 발생하면 빠르게 문제의 원인을 발견하

고 사출 성형기를 수리하거나, 사출성형 설계 변경을 통해 작업을 이어간다. 그러나 불량 원인을 찾아내다 해도 불량 원인이 복잡하거나, 하나의 불량해결로 인한 다른 불량현상이 생기는 경우가 있다[4]. 이러한 이유로 사출성형에서는 여러 공정이 복잡하게 작용하고, 품질변수에 영향을 끼쳐 공정 변수와 품질 변수 사이의 관계는 비선형적이라고 알려져 있다. 따라서 작업자가 원하는 품질의 제품을 생산하기 위해 수학적 또는 물리적 법칙을 통해 모든 공정 변수를 계산하여 선택하는 것은 현실적으로 어렵다[5].

본 연구에서는 품질예측을 통한 효율적인 품질관리를 위해 딥러닝 모델을 적용함으로써 품질관리의 효율증대와 품질 향상 가능성을 분석하고자 한다. 분석에 사용한 데이터는 플라스틱 사출성형기의 센서 데이터를 활용하였다. 연구는 총 3개 모델에 대한 성능을 검증해보았다. 잡음 제거 오토인코더(Denoising Auto Encoder, 이하 DAE), 장·단기 기억 신경망(Long-Short Tern Memory Network, 이하 LSTM), 합성곱 신경망(Convolutional Neural Network, 이하 CNN)의 3개의 딥러닝 모델을 활용하여 4개의 다른 파라미터 셋을 적용하여 데이터 분석을 수행하였다. 성능평가지표로 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1 Score 값을 비교하여 각 모델별 성능을 비교·분석하였다.

2. 관련연구

최근 스마트공장이 주목을 받으며 공정에서 발생하는 센서 데이터를 활용한 연구가 활발히 이루어지고 있다. 데이터 분석을 활용한 품질예측 연구 사례는 많았으며, 실례로 심현식 외[7]은 데이터마이닝 기법 중 로지스틱 회귀모형을 바탕으로 변수선택법을 사용하여 PCB제조 라인의 데이터를 분석하여 어떤 공정이 영향을 끼치는지 분석하고, 공정별 분석을 시행하여 불량에 영향을 미치는 핵심설비 요인에 관한 연구를 수행했다. 강대현 외[8]은 인공신경망을 활용한 후판 제품에 관한 품질예측 연구를 진행하였다. 슬래브(반제품)의 인장강도와 항복강도를 예측 가능한 빅데이터 및 기계학습 기반의 시스템을 제안하였고, 주요 예측부에서 도출되는 주요영향 인자를 인공신경망을 활용하여 불량을 예측하는 연구를 수행하였다. 한세웅 외[9]는 특수원사 공정의 센서 데이터를 활용하여 의사결정나무 알고리즘으로 제품 품질에 영향을 주는 요인을 예측하는 연구를 진행하였다. 분석을 통해

불량률이 낮은 공정과 불량률이 높은 공정의 차이를 나타내는 변수를 찾아내고, 변수 중 최종 선정된 변수의 안정 값 범위를 설정하여 센서 설정값의 안정범위를 벗어나지 않게 값을 조절하여 불량률 개선 효과를 측정하였다. 김재경 외[10]는 국내 철강 생산 공정 데이터를 활용하여 제품에 발생하는 품질결함을 파악하고, 이에 더 나아가 실시간으로 생산 공정을 관리하기 위해 데이터마이닝 기법인 의사결정나무분석을 통해 제품 이상 트랜잭션 검출 모형을 제시하였다. 또한 모형의 유용성을 검증하고자 로지스틱 회귀분석 신경망으로 비교 분석을 하였다.

딥러닝 모델을 활용한 예측모델에 대한 연구 사례 중에 이금성[11]은 머신러닝과 딥러닝 모델 성능 비교를 위해 로지스틱 회귀 모델, 의사결정나무 모델, 서포트 벡터 머신등의 모델과 심층 신경망 기반의 모델을 구현하여 데이터를 학습하였다. 이를 통해 전력수요 예측 정확도를 향상시켰고, 더 나아가 심층 신경의 학습 데이터를 추가하여 복합 예측 모델을 구현하여 성능 검증 연구를 수행하였다. 최상규[14]는 저항 점 용접 공정에서 용접성 예측을 위해 심층신경망(Deep neural network)과 CNN 모델을 활용한 데이터 분석을 수행하여 용접성 예측을 연구하였다. 전지혜[12]는 압출 공정의 센서 데이터를 활용하여 데이터 분석을 수행하였다. 연구에 활용된 모델로는 ANN(Artificial neural network), 로지스틱 회귀모델, 의사결정나무 모델, LDA, GNB, KNN, SVC의 8가지 머신러닝 모델을 활용하여 데이터 분석을 수행하였다. 모델의 정확도와 손실, ROC curve를 성능평가 지표로 각 모델의 성능을 비교분석 하였다. 이와 같이 기존 연구에서 예측모델을 활용한 성능검증연구와 제품 품질에 영향을 주는 요인예측연구는 일부 수행되었지만, 플라스틱 사출 공정에서 제품의 품질예측을 위한 딥러닝 모형 적용에 관한 연구는 찾아보기 힘든데 그 이유는 사출성형기 센서들로부터 실시간으로 취합되는 데이터 및 해당 데이터에 대한 양품-불량품이 표시(tagging)된 품질데이터를 수집하는 것이 어렵기 때문으로 이해할 수 있다.

3. 딥러닝

딥러닝은 머신러닝의 여러 방법론 중에서 인공신경망을 여러 층 쌓아 올린 기법을 의미한다. 인공신경망을 깊게 쌓아 올려서 학습하기 때문에 딥러닝이라고 불리게 되었다. 머신러닝은 인공지능(Artificial Intelligence,

AI)이라는 좀 더 큰 연구 분야의 방법론 중 하나이다. 인공지능은 컴퓨터가 사람과 같은 지능적인 행동을 할 수 있게 해주는 기법들을 연구하는 분야이며, 인공지능의 다양한 기법 중에서 머신러닝은 데이터를 이용해서 컴퓨터를 학습시키는 기술이라 할 수 있다. 하지만 인공지능의 다른 기법 중에는 데이터를 이용하지 않고 인간이 미리 정의한 논리 구조에 따라 컴퓨터가 행동하도록 만드는 규칙기반의 기법도 있다[13].

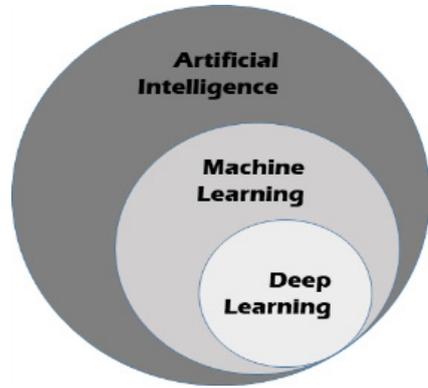


Fig. 1. Deep learning, machine learning, artificial intelligence

딥러닝 알고리즘은 갑자기 등장한 것이 아니라 많은 사람들이 장시간에 걸쳐서 연구한 인공지능 연구결과들을 토대로 등장하였다. 게다가 딥러닝 알고리즘 근간인 인공신경망 기법은 이미 1980년대부터 활발히 연구되고 실제로 다양한 산업 군에 사용되어왔다. 최근 들어 딥러닝 알고리즘이 주목받고 있다. 그 이유는 첫째로, 과거에 비해 쉽게 빅데이터를 구할 수 있게 된 환경이 조성되었다는 것이고, 두 번째로는 GPU를 필두로 한 컴퓨팅 파워의 발전이다. 마지막으로 새로운 딥러닝 알고리즘의 개발이다. 머신러닝 알고리즘이 잘 학습되기 위해서는 대량의 데이터가 필요하다. 하지만 인터넷이 존재하지 않았던 1980년대에는 많은 데이터를 구하는 것이 어려웠다. 하지만 인터넷이 등장하고 인간행동의 많은 부분이 웹상에서 이루어지면서 대량의 데이터를 구하는 것이 가능해졌고, 빅데이터를 이용해서 머신러닝 알고리즘을 학습시킬 수 있는 환경이 조성되었다. 하지만 빅데이터가 있더라도 컴퓨터의 연산 속도가 충분히 빠르지 않다면 불가능하다. 그렇지만 최근에 GPU를 이용한 병렬 처리 연산이 발전하면서 대량의 데이터를 빠른 시간 안에 처리할 수 있게 되었다[15]. 마지막으로 새로운 딥러닝 알고리즘들이 개발되었다는 것이다. 데이터가 많고 연산

을 충분히 빠르게 할 수 있더라도 오버피팅 문제 때문에 머신러닝 알고리즘이 좋은 성능을 보여주지 못했다. 하지만 최근 오버피팅 문제를 해결하기 위해서 ReLU, Dropout 등 다양한 기법들이 새롭게 제안되었다. 이러한 이유로 딥러닝 알고리즘은 기존의 인공지능 기법들을 월등히 뛰어넘은 성능을 보여주고 있다. 특히 딥러닝은 다른 머신러닝 기법들보다 좋은 성능을 보여준다. 딥러닝 알고리즘은 인공신경망을 깊게 쌓아 올린다. 깊게 쌓아 올림으로써 얻는 효과는 데이터의 특징을 단계별로 학습할 수 있다는 점이다. 데이터의 특징을 단계별로 학습하기 때문에 딥러닝을 표현 학습이라고도 부른다. 데이터의 특징을 잘 나타낼 수 있는 표현을 학습하는 것은 딥러닝 뿐만 아니라 모든 머신러닝 알고리즘의 핵심이다. 데이터의 특징을 잘 학습하면 학습한 특징을 이용해서 알고리즘이 더 좋은 성능을 낼 수 있다[15].

머신러닝 외에 다른 전통적인 기법들은 데이터의 특징들을 연구자들이 고민을 통해서 제안한 알고리즘을 통해 추출했다. 이렇게 추출한 특징을 연구자들의 손으로 추출했다고 하여 Hand-Crafted Feature라고 부른다. 이에 반해 머신러닝 알고리즘으로 추출한 특징은 학습 과정에서 자동으로 특징이 추출되기 때문에 Learned Feature이라고 한다. 머신러닝 알고리즘을 수행하기 위해서는 대량의 데이터 수집 과정이 선행되어야 한다. 따라서 데이터를 충분히 확보할 수 없는 상황에서는 오히려 Hand-Crafted Feature를 사용하는 것이 성능이 더 좋을 수 있다. 따라서 풀어내고자 하는 문제와 상황을 고려해서 적절한 알고리즘을 선택하는 것이 중요하다.

3.1 인공신경망

인간의 뇌에 관한 연구가 발전하면서 인간의 뇌는 여러 개의 신경세포가 서로 연결되어 있고, 이들이 병렬적으로 연산을 진행하면서 정보를 처리한다는 사실이 발견되었다. 좀 더 정확히 사람의 뇌 속에는 약 10^{11} 개의 뉴런이 있고, 1개의 뉴런은 약 10^3 개의 다른 뉴런들과 연결되어 있다고 알려져 있다. 즉, 인간의 뇌 속에는 약 10^4 개의 뉴런과 뉴런 사이의 연결이 존재하고, 각각의 뉴런들은 서로 전기 신호를 주고받으면서 연산을 수행한다[16].

Fig. 2.는 생물학적 뉴런의 구조를 보여준다. 수상돌기(Dendrite)는 다른 뉴런으로 주어지는 전기 신호를 입력받는다. 축삭돌기(Axon)는 수상돌기로부터 주어진 전기 신호를 축삭돌기 말단(Axon Terminal)에서 다른 뉴런들로 전달한다. 이때 수상돌기로부터 입력받은 전기 신호는 역치를 넘지 못하면 중간에 사라지기도 한다. 인

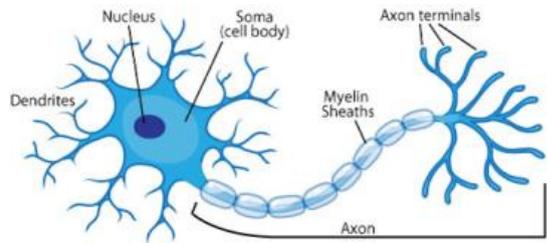


Fig. 2. Structure of Biological Neural Network

간의 뇌 속에 이런 수많은 뉴런이 전기 신호를 주고받는 연산을 수행함으로써 인간은 눈으로 물체를 인식하거나 귀로 어떤 사람의 목소리를 분간해내거나 몸을 움직이는 등 다양한 고차원 행동을 수행할 수 있다. 따라서 인간의 뇌는 엄청난 양의 병렬 처리 연산기다. 하지만 컴퓨터의 경우 메모리에서 값을 불러와서 CPU에서 순차적으로 연산을 처리한다. 즉 컴퓨터는 순차 처리 연산기라고 한다. 그러나 기본적으로 사람이 인지하는 음성이나 물체에 대한 인식 등에 대한 인지활동에는 문제점이 있다. 이에 인공신경망을 연구하는 연구자들은 컴퓨터도 사람의 뇌처럼 대량의 병렬 처리 연산을 가능하도록 만들어 컴퓨터도 사람이 기본적으로 할 수 있는 인지 활동을 할 수 있을 것이라 기대하고 초기 인공신경망 구조를 디자인하였다[17].

3.2 오토인코더

오토인코더는 입력층(Input Layer)의 노드개수와 출력층(Output Layer)의 노드 개수가 같은 구조의 인공신경망이다.

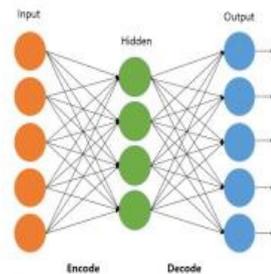


Fig. 3. Structure of Autoencoder

Fig 3.은 은닉층(Hidden Layer)이 1개인 오토인코더의 구조이다. 따라서 오토인코더의 출력은 원본 데이터를 재구축한 결과가 된다. 오토인코더 은닉층의 노드 개수는 출력층과 입력층의 노드 개수보다 적다. 따라서 은

닉층은 원본 데이터의 특징들을 더 작은 표현력으로 학습해야 한다. 은닉 층의 불필요한 특징들을 제거한 압축된 출력 값의 특징을 학습하게 된다. 오토인코더는 은닉 층의 출력 값을 불필요한 잉여특징을 자동으로 제거하고 남은 주요 특징만을 가지게 된다. 따라서 은닉층의 압축된 특징을 보여주고 출력 값을 기존 데이터에 대체하여 분류기 입력으로 활용한다면 더 나은 성능을 기대할 수 있다[18].

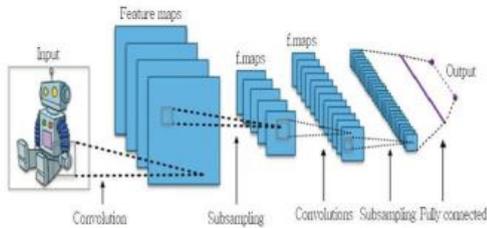


Fig. 4. Structure of Convolutional Neural Network

3.3 합성곱 신경망

합성곱 신경망은 크게 컨볼루션층과 풀링층으로 구성되어 있다. 컨볼루션층은 컨볼루션 연산을 통해서 데이터의 특징을 추출하는 역할을 한다. 컨볼루션은 커널 또는 필터라고 불리는 윈도우 크기만큼의 $X \times X$ 크기의 행렬을 $Y \times Y$ 크기의 이미지 행렬의 $X \times X$ 크기 부분과 곱해서 모두 더하는 수학 연산자이다. 행렬 곱의 결과로 이미지 행렬의 $X \times X$ 크기부분의 값들은 모두 더해져 하나의 값으로 모아진다. 이런 $X \times X$ 크기의 행렬 곱셈을 $Y \times Y$ 크기의 이미지 행렬의 가장 왼쪽 위부터 가장 오른쪽 아래까지 순차적으로 수행하는 연산이 컨볼루션 층에서 이루어지는 동작이다[3].

커널을 활용하여 컨볼루션을 활용하면 커널에 종류에 따라 원본의 특징들이 활성화 맵으로 추출되게 된다. 이때 커널을 어떻게 활용하는가에 따라 다양한 특징을 추출할 수 있다. CNN을 구성하는 2번째 요소인 풀링층은 차원을 축소하는 연산을 수행한다. 풀링의 종류에는 최대값 풀링, 평균값 풀링, 최소값 풀링이 있다. 최대값 풀링은 $X \times X$ 크기 부분에서 가장 큰 값 하나를 추출해서 원본의 $X \times X$ 개의 값을 1개의 값으로 축소한다. 동일한 원리로 평균값 풀링, 최소값 풀링은 평균값, 최소값으로 축소한다. 풀링층 역시 데이터의 좌측 상단에서 우측하단으로 순차적으로 전체 데이터에 대해 풀링을 수행한다. 풀링층은 크게 2가지 장점이 있다. 데이터의 차원을 축소함으로써 필요한 연산량을 감소시킬 수 있고, 데이터

의 가장 강한 특징만을 추출하는 특징 선별 효과가 있다 [15].

3.4 순환 신경망

순환신경망(Recurrent Neural Network, RNN)은 순차적인 데이터 또는 시계열 데이터를 사용하는 인공지능 신경망의 한 유형이다. 이러한 딥러닝 알고리즘은 일반적으로 언어번역, 자연어 처리, 음성인식 및 이미지 캡션과 같은 서수 또는 시간문제에 사용된다. 컨볼루션 신경망(Convolution Neural Network)과 마찬가지로 순환신경망은 학습데이터를 활용하여 학습한다[19].

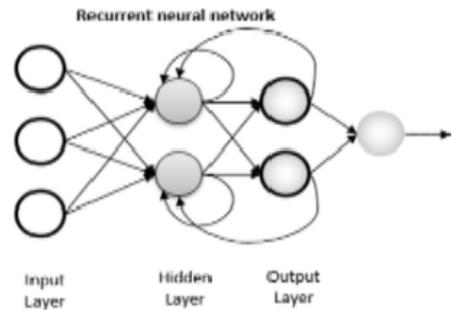


Fig. 5. Structure of Recurrent Neural Network

RNN은 Fig.5와 같이 히든 노드가 방향을 가진 엣지로 연결돼 순환구조를 이루는(directed cycle) 인공신경망의 한 종류다. 이전 입력에서 정보를 가져와 현재입력 및 출력에 영향을 미치므로 메모리로 구별된다. 이는 앞에서 얻은 데이터의 정보가 다음에 얻은 데이터와 관계를 갖는 시계열 데이터를 다룰 때 효과적인 성능을 발휘한다. 전통적인 심층신경망은 입력과 출력이 서로 독립적이라고 가정하지만 반복신경망의 출력은 스텝스 내의 이전요소에 따라 달라진다.

3.4.1. 장·단기 기억 신경망

RNN은 순차적인 데이터를 처리하는데 적합하지만 경사도 사라짐 문제에 큰 단점을 보인다. LSTM은 순환신경망에 경사도 사라짐 문제를 보완하고자 발전된 순환신경망의 구조이다[20].

Fig 6.은 LSTM의 전체적인 구조를 보여준다. LSTM은 각 노드를 인풋게이트, 포갯 게이트, 아웃풋 게이트로 구성된 메모리 블록이라는 구조를 갖는다. 이와 같은 구조는 순환신경망의 경사도 사라짐 문제(Vanishing Gradient Problem)를 완화할 수 있다[21].

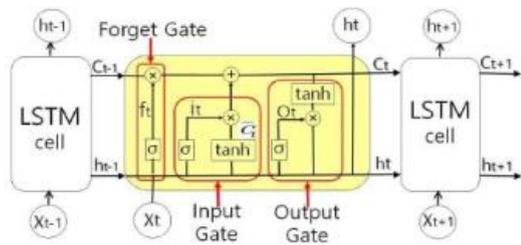


Fig. 6. Structure of Long Short Tern Memory Network

4. 사례분석

본 연구는 Korea AI Manufacturing Platform(KAMP) 내의 사출 성형기 AI 데이터 셋[6]을 활용하였다. 데이터는 각 딥러닝 모델에 동일하게 전 처리하여 진행하였다.

Table 1. Description on Data

Process Condition Variables		Categories
Independent Variables	Temperatures on	Screw/Cylinder, Resin, Mold, Dry, Hydraulic, Circumstance
	Pressure on	Filling pressure, Clamping pressure, Holding pressure, Release pressure, Back pressure(Pressure generated during metering), Mold opening pressure
	Time on	Cooling time, Holding time, Filling time, Drying time
	Speed on	Injection speed, Screw rotation speed, Mold opening speed, Ejection(ejecting) speed
	Volume on	Weighing, Release amount, Cushion amount
Dependent Variables	Good Quality vs. Defect	Y: Good quality N: Defect (Labeled)

4.1 데이터 정의 및 특징

본 연구에 활용된 데이터는 자동차 앞 유리 사이드 몰딩 제조공정 내 사출 성형기 센서 데이터다. 기간은 1개월, 주기는 0.2 sec으로 수집되었다.

독립변수와 종속변수를 포함한 공정조건 변수들에 대한 범주별 구분은 Table 1.과 같이 정리할 수 있고, Table 2.는 데이터의 속성을 나타내고 있다.

Table 2. Data Properties

Data Properties	Unit	Data Properties	Unit
id	-	Cushion_Position	mm
TimeStamp	-	Switch_Over_Position	mm
PART_FACT_PLAN_DATE	-	Plasticizing_Position	mm
PART_FACT_SERIAL	-	Clamp_Open_Position	mm
Shot_Number	-	Max_Injection_Speed	mm/s
PART_NO	-	Max_Screw_RPM	mm/s
PART_NAME	-	Average_Screw_RPM	mm/s
EQUIP_CD	-	Max_Injection_Pressure	MPa
EQUIP_NAME	-	Max_Switch_Over_Pressure	MPa
PART_FACT_PLAN_QTY	Qty(Pcs)	Max_Back_Pressure	MPa
ERR_FACT_QTY	Qty(Pcs)	Average_Back_Pressure	MPa
FACT_QTY	Qty(Pcs)	Barrel_Temperature_1~7	℃
Injection_Time	Sec	Hopper_Temperature	℃
Filling_Time	Sec	Mold_Temperature_1~12	℃
Plasticizing_Time	Sec	Clamp_open_time	Sec
Cycle_Time	Sec	PassOrFail	Y N
Clamp_Close_Time	Sec		

*: Dependent Variable, Y(Good Quality), N(Defect)

4.2 데이터 분석

Korea AI Manufacturing Platfrom(KAMP) 사출 성형기 AI 데이터셋[6]을 활용하여 연구를 수행하였다. 데이터 중 제품 'CN7'에 대한 센서 데이터를 활용하여 연구를 수행하였다. 공정에서 발생한 양품, 불량품에 대한 레이블링된 데이터를 활용하였고, 수집된 데이터 중 불필요한 데이터를 제거하여 제품 'CN7'에 대한 연구를 수행하였다.

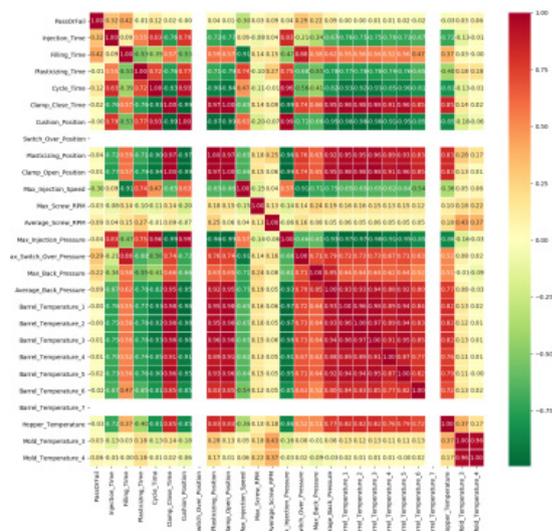


Fig. 7. Correlation by variable in product 'cn7'

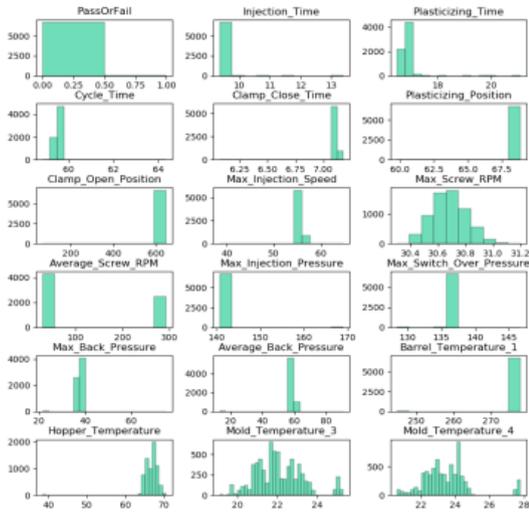


Fig. 8. Histogram by variable in product 'cn7'

Fig 7.과 Fig 8.은 각각 본 연구에 활용된 데이터의 변수별 상관계수, 주요 속성들에 대한 히스토그램을 보여주고 있다.

Table 3. Hyperparameter setting values for 3 models

Model Settings	DAE	LSTM	CNN
Performance	Accuracy, Precision, Recall, F1-Score		
Data set	Plastic injection molding machine		
Hidden Layer	3		
Hidden Unit	5, 15		
Dropout	0.3		
Leaning rate	0.0001		
Optimizer	Adam		
Activation Function	ReLU, Softmax		
Loss Function	MSE		
Scaler	MinMax Scaler		

4.3 실험 및 결과분석

본 연구에서는 Tensorflow, Keras 등을 활용하여 데이터를 분석하였다. 3개의 딥러닝 모델에 다른 파라미터 셋을 적용하여 각 모델의 성능을 비교하는 방법으로 연구가 진행되었다. 모델에 사용한 데이터는 동일하게 전처리하여 총 6,736개의 데이터를 사용하였고, 6,736개의 데이터를 Sklearn Package의 MinMaxScaler를 활용하여 데이터를 정규화하였다. 모델에 동일한 데이터로

파라미터셋 1~4를 적용하여 연구모델들을 서로 비교·분석하였다. Table 3.은 3개의 딥러닝 모델의 하이퍼 파라미터 설정 값이고, Table 4.는 모델별로 각기 다른 설정 값을 적용한 파라미터 조합이다.

총 6,736개의 데이터 중 학습데이터는 5,000개로 설정하였고, 검증데이터는 학습데이터의 파라미터 Set별 Validation Split값을 적용하였다. DAE, LSTM, CNN 개의 딥러닝 모델을 4가지의 파라미터 셋을 적용하여 실험을 진행하였고, 각 조합별 세부사항은 Table 5.~7.과 같고 Fig. 9.~11.은 학습과정을 보여준다.

Table 4. Parameter setting values for 3 models

Set	Batch Size	epoch	Validation Split	Patience
Set 1	30	30	0.2	15
Set 2	30	60	0.3	20
Set 3	60	60	0.3	30
Set 4	90	60	0.3	45

Table 5 DAE Model Analysis Results

Set	Accuracy	Precision	Recall	F1 Score
1	0.9925	0.1667	0.4000	0.2353
2	0.9983	1.000	0.4000	0.5714
3	0.9931	0.2308	0.6000	0.3333
4	0.9931	0.2308	0.6000	0.3333

Table 6 LSTM Model Analysis Results

Set	Accuracy	Precision	Recall	F1-Score
1	0.9977	1.000	0.2000	0.3333
2	0.9983	1.000	0.4000	0.5714
3	0.9977	1.000	0.2000	0.3333
4	0.9971	0	0	0

Table 7 CNN Model Analysis Results

Set	Accuracy	Precision	Recall	F1 Score
1	0.9994	1.000	0.8000	0.8889
2	1.000	1.000	1.000	1.000
3	0.9994	1.000	0.8000	0.8889
4	0.9994	1.000	0.8000	0.8889

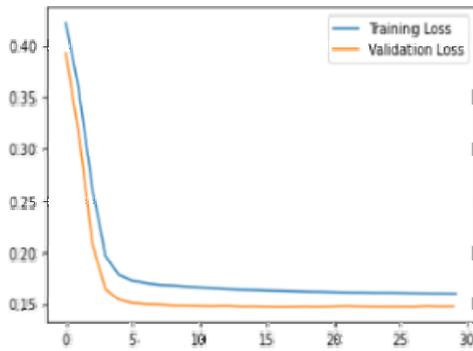


Fig. 9. DAE Loss Changes by Epoch

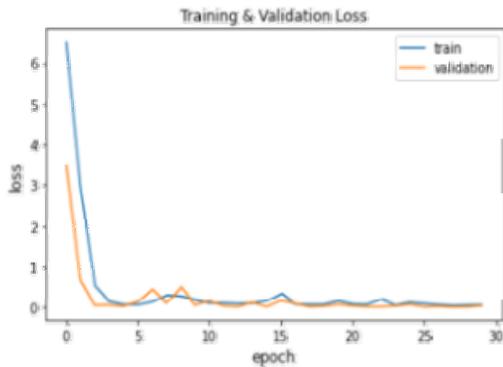


Fig. 10. LSTM Loss Changes by Epoch

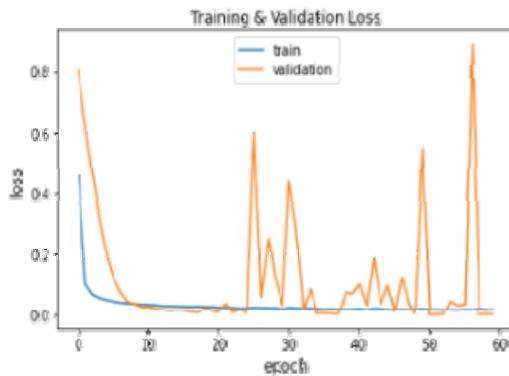


Fig. 11. CNN Loss Changes by Epoch

각 모델에 대한 분석 결과이다. 3개의 모델을 비교해 보았을 때 파라미터 set2가 가장 좋은 성능을 보여주고 있으며, 그 중 CNN모델의 성능이 가장 좋은 것을 확인할 수 있다. 본 실험 결과값을 설명하기에 앞서, 먼저 AI 기반의 품질 예측시스템이 예측한 결과는 다음과 같이 총 4개의 경우로 나뉜다. - True Positive(양품을 양품

이라고 예측, 이하 TP), True Negative(불량품을 불량품이라고 예측, 이하 TN), False Positive(불량품을 양품이라고 예측, 이하 FP) 그리고 False Negative(양품을 불량품이라고 예측, 이하 FN). 여기서, 예측 정확도(Accuracy)는 전체 예측한 결과(=TP+TN+FP+FN) 중 TP+TN의 비율을 뜻한다. 그리고 정밀도(Precision)는 양품이라고 예측한 결과 중에서 실제 양품인 확률(=TP/(TP+FP))을 의미하고 재현율(Recall)은 실제 양품인 제품을 양품이라고 판단할 확률(=TP / (TP+FN))이다. 다만, 전체 데이터 셋에 불량품 데이터가 매우 적을 경우 정확도, 정밀도와 재현율의 의미가 퇴색되므로 보조적인 척도로 f1-score를 활용하기도 한다.

따라서 실제 사출공정에 본 CNN 기반의 최적화된 품질예측 시스템을 도입한다고 가정할 경우, 예측 정확도, 정밀도, 재현율, f1-score가 모두 100%에 가까운 성능을 보이므로 사출 후 제품의 양품, 불량품 여부를 시스템적으로 처리하여 분기함에 따라 품질 전수검사의 효율을 높일 수 있다. 더불어 품질의 영향을 주는 요인을 찾아내어 사출기를 제어할 수 있다면 전체 불량률을 낮출 수 있을 것이다.

5. 결론

본 연구는 플라스틱 사출 성형기에서 수집된 센서 데이터를 바탕으로 제품 품질에 대한 데이터 분석을 수행하였다. 딥러닝 기법 중 DAE, LSTM, CNN모델을 활용하여 제품 품질에 대한 예측 성능을 검증하는 연구를 수행하였다. 수집된 데이터 중 분석에 불필요한 자료를 전처리하여 데이터 분석에 사용된 데이터의 수는 총 6,736개이다. 그 중 학습 데이터는 5,000개이며, 검증데이터로는 각 파라미터 셋에 따라 적용되었다. 검증데이터의 비율은 학습데이터의 20%, 30%로 각 모델별로 적용하였다. 혼동행렬의 결과값을 바탕으로 정확도 (Accuracy), 정밀도(Precision), 재현율(Recall), f1 score값을 성능평가지표로 두고 비교하여 각 모델과 파라미터 셋 별로 성능차이를 비교·분석하였다. 파라미터 셋을 비교분석한 결과 Batch Size 30, Epoch 60, Validation Split 0.3, Patience 20으로 설정한 파라미터 set2가 가장 성능이 좋은 것을 확인할 수 있었다. 모델별로 파라미터 set2를 적용하여 분석을 수행해 보았을 때 CNN모델의 파라미터 Set2가 가장 성능이 좋은 것을 확인할 수 있었다. 본 연구에서 제안한 딥러닝 모델에 기반을 둔 사출공

장 품질예측 시스템은 사출기계로부터 실시간 취합되는 센서 데이터 셋을 이용하여 공정조건 변화에 따른 품질을 예측하게 함으로써 품질 신뢰도를 향상하고 공정 품질검사 투입인력을 절감하는 등의 효율을 기대할 수 있다.

본 연구에서 활용된 데이터 이외에 불균형의 비율이 더 높고, 데이터의 개수가 더 많은 데이터를 활용하여 연구를 수행한다면 더욱 신뢰도 있는 결과를 도출해낼 수 있을 것이다. 그리고 본 연구에서 설정한 파라미터 값을 더 다양하게 설정하여 학습모델 간 차이점을 더욱 선명하게 나타낼 수 있는 연구가 필요할 것이다.

References

- [1] C. G. Lee, S. H. Jung, M. H. Kim, "Effectiveness and Policy Implications of Introducing Smart Factories", KDI, 2019.
https://www.kdi.re.kr/research/subjects_view.jsp?pub_no=16317
- [2] P. Adriaans, D. Zantinge, "Introduction to Data Mining and Knowledge Discovery, 3rd ed. Two Crows Corporation, Potomac", MD, USA, pp.2-5, 2005.
<https://www.twocrows.com/intro-dm.pdf>
- [3] T. W. Jang, S. I. Sung, J. C. Lee, "Analysis of Small and Medium-sized Supply Companies in Smart Factories and Improvement Plan", *Entrue Journal of Information Technology*, pp.78-79, 2019.
<https://kiss.kstudy.com/thesis/thesis-view.asp?key=3758168>
- [4] Y. D. Jung, J. S. Park, "Development of Manufacturing Facility System for Diagnosing Quality Abnormalities of Injection Molding", "Confirmation of Korea Safety Management Price, pp.559-563, 2011
<https://www.earticle.net/Article/A159011>
- [5] C. A. Hieber, S. F. Shen, "A Finite-Element/Finite-Difference Simulation of the Injection-Molding Filling Process", *J. Non-Newtonian Fluid Mech.*, Vol. 7, No. 1, pp. 1-32, 1980.
<https://www.sciencedirect.com/science/article/pii/0377025780850129>
- [6] Ministry of SMEs and Startups, Korea AI Manufacturing Platform(KAMP), Plastic injection molding machine AI dataset, KAIST(UNIST,EPM Solutions), 2020.
<https://www.kamp-ai.kr/front/main/MAIN.01.01.jsp>
- [7] H. S. Shim, C. W. Kim, "Process and facility analysis of PCB manufacturing lines suspected of defects using data mining techniques", *Korean Society of Information Processing*, pp.65-70, 2015.
<https://kiss.kstudy.com/thesis/thesis-view.asp?key=3302575>
- [8] D. H. Kang, S. G. Oh, J. H. Park, M. S. Seo, "Prediction of Quality of Backplate Products Using Artificial Neural Network", *Korea Society of Quality Management*, pp.146-146, 2019.
<https://kiss.kstudy.com/thesis/thesis-view.asp?key=3736983>
- [9] S. W. Han, J. H. Kim, B. H. W. Hwang, "A Study in Sensor Data Analysis and Product Defect Improvement for Smart Factory", *Korea bigdata society*, pp.95-103, 2018.
<https://kiss.kstudy.com/thesis/thesis-view.asp?key=3644209>
- [10] J. K. Kim, T. S. Kwon, I. R. Choi, H. K. Kim, M. Y. Kim, 'A Study on Quality Control Using Adat Mining in Steel Continuous Casting Process', *Korea Society of IT Services*, pp.2011.
<http://www.riss.kr/link?id=A82674575>
- [11] G. S. Lee, 'A Study on Performance Comparison of Deep Learning Model for power Demand Forecasting', *Gwangju University*, 2020.
<http://www.riss.kr/link?id=T15656899>
- [12] J. H. Jeon, 'Data Analysis based Continuous Process Quality Prediction and Yield Improvement Method', *kyonggi University*, 2020.
<http://www.riss.kr/link?id=T15669340>
- [13] S. Y. Kim, Y. J. Jung, 'First time learning machine learning', 'Hanbit media', pp.1-376, 2017.
- [14] S. K. Choi, "A prediction Method of Weld Quality Using Neural Network Algorithm in Resistance Spot Welding", *Inha University*, 2019.
<http://www.riss.kr/link?id=T15393475>
- [15] Solaris, *Learning by Tensorflow*, Youngin, pp.28-183, 2020.
- [16] C. W. Lee, H. K. Moon, "Development of an Artificial Neural Network Expert System for Preliminary Design of Rock Tunnel", *Hanyang University*, pp. 79-96, 1994
<http://www.riss.kr/link?id=A106723567>
- [17] C. H. Son, "Prediction of Non-Drain Shear Behavior of Silt Using Artificial Neural Networks", *Kyungpook University*, pp. 4-43, 2004.
<http://www.riss.kr/link?id=T9981347>
- [18] Y. Bengio, P. Lamblin, D. Poppvici, H. Larochelle, 'Greedy layer-wise training of deep networks', *Advances in neural information processing systems*, pp. 153-160, 2007.
<https://books.google.co.kr/books?hl=ko&lr=&id=Tbn119P1220C&oi=fnd&pg=PA153&dq=greedy+layer-wise+raining+of+deep+networks&ots=V5maIlikXZ&sig=yLXRlBf3wAkTzhQB9Kp5cDEWVI#v=onepage&q=greedy%20layer-wise%20training%20of%20deep%20networks&f=false>
- [19] Y. Sugomori, 'Deep Learning as a Standard', *Wikipedia*, 2017.
- [20] S. J. Yoo, "Feature extraction form MS/MS spectra using Long Short-Term Memory Autoencoders", *Soongsil University*, pp. 7-9, 2019.

<http://www.riss.kr/link?id=T15305623>

- [21] S. Hochreier, J. Schmidhuber, 'Long Short-term memory', Neural Computaion, Volume. 9 Issue. 8, pp.1735-1780, 1997.
<https://direct.mit.edu/neco/article/9/8/1735/6109/Long-Short-Term-Memory>
-

조 현 민(Hyunmin Cho)

[준회원]



- 2020년 2월 : 상명대학교 경영공학과 (공학사)
- 2019년 9월 ~ 현재 : 상명대학교 경영공학과 학석사연계과정

<관심분야>

품질경영, 스마트제조, 인공지능, 빅데이터

신 현 준(Hyun Joon Shin)

[종신회원]



- 1997년 2월 : 고려대학교 산업공학과 (공학석사)
- 2002년 2월 : 고려대학교 산업공학과 (공학박사)
- 2002년 5월 ~ 2004년 4월 : Texas A&M Univ. Post-Doc.
- 2004년 5월 ~ 2005년 2월 : (주)삼성전자 책임연구원
- 2005년 3월 ~ 현재 : 상명대학교 경영공학과 교수

<관심분야>

금융공학, 인공지능, 빅데이터, 스마트제조