

머신러닝을 활용한 자동차 시트용 폴리우레탄 발포공정의 불량 예측 모델 개발

최낙훈¹, 오종석², 안종록³, 김기선^{3*}

¹공주대학교 대학원 미래융합공학과, ²공주대학교 기계자동차공학부 ³이스턴에프티씨 부설연구소

A Development of Defect Prediction Model Using Machine Learning in Polyurethane Foaming Process for Automotive Seat

Nak-Hun Choi¹, Jong-Seok Oh², Jong-Rok Ahn³, Key-Sun Kim^{3*}

¹Dep. of Future Convergence Engineering, Graduate School, Kongju National University

²Div. of Mechanical & Automotive Engineering, Kongju National University

³Eastern FTC

요약 최근 4차 산업혁명으로 인해 제조업계에서는 제조업의 인공지능을 접목시켜 효율성을 극대화하는 스마트 팩토리 붐이 일어나고 있다. 특히 자동차 부품 제조 및 생산에 널리 적용되어 불량을 낮추는 연구들이 활발히 진행되고 있다. 이에 본 연구에서는 머신러닝을 통한 불량예측을 시트 폼 발포공정에 접목시켜 발포공정의 효율성을 극대화하는 연구를 진행하였다. 자동차 시트폼 에서 주로 사용되는 폴리우레탄 폼(polyurethane foam)은 폴리올(polyol, 이하 POL)과 이소시아네이트(isocyanate, 이하 ISO)를 혼합 및 발포하는 공정으로 제조되며, 각 원료의 혼합비율과 온도의 변화에 따라 제품의 특성이 변화한다. 이에 본 연구에서는 발포공정에서 수집되는 인자별 데이터값을 머신러닝에 적용하여 불량을 예측하고자 한다. 머신러닝에 사용되는 알고리즘으로는 의사결정트리, kNN, 앙상블 알고리즘을 사용하였으며 학습은 5,147개의 데이터를 사용하였으며, 학습된 결과를 1,000개의 검증용 데이터에 적용한 결과, 세 알고리즘 중 앙상블 알고리즘에서 최대 98.5 %의 정확도를 확인할 수 있었다. 이러한 결과를 통해 발포공정에서 실시간으로 수집되는 데이터를 통해 현재 생산되는 부품의 불량 여부를 확인할 수 있으며, 나아가 각 인자를 조절하여 불량률을 개선할 수 있음을 짐작할 수 있다고 사료된다.

Abstract With recent developments in the Fourth Industrial Revolution, the manufacturing industry has changed rapidly. Through key aspects of Fourth Industrial Revolution super-connections and super-intelligence, machine learning will be able to make fault predictions during the foam-making process. Polyol and isocyanate are components in polyurethane foam. There has been a lot of research that could affect the characteristics of the products, depending on the specific mixture ratio and temperature. Based on these characteristics, this study collects data from each factor during the foam-making process and applies them to machine learning in order to predict faults. The algorithms used in machine learning are the decision tree, kNN, and an ensemble algorithm, and these algorithms learn from 5,147 cases. Based on 1,000 pieces of data for validation, the learning results show up to 98.5% accuracy using the ensemble algorithm. Therefore, the results confirm the faults of currently produced parts by collecting real-time data from each factor during the foam-making process. Furthermore, control of each of the factors may improve the fault rate.

Keywords : Smart Factory, Foaming Process, Machine Learning, Defect Prediction, 4th Industrial Revolution

본 논문은 2020년도 중소벤처기업부의 상반기 중소기업 연구인력(고경력) 지원사업으로 수행되었음.

*Corresponding Author : Key-Sun Kim(Eastern FTC)

email: easternftc@hanmail.net

Received February 19, 2021

Revised March 17, 2021

Accepted June 4, 2021

Published June 30, 2021

1. 서론

최근 우리 사회는 초 연결과 초 지능을 핵심 근간으로 하는 4차 산업혁명을 맞이했다. 4차 산업혁명의 시대를 맞이하여 제조업에서 이목을 끄는 큰 변화는, 기존의 자동화 설비를 통한 공장 자동화에서 한 단계 발전한 스마트 팩토리라는 개념의 등장이다. 스마트 팩토리의 사전적 의미는, 현실 공간과 가상공간이 연결되어 있으며, 디지털 신기술과 제조기술이 접목된 소비자 중심의 지능화된 공장을 의미한다. 기존의 공장 자동화와 스마트 팩토리는 생산 효율성 증대라는 근본적인 목표는 같지만, 공장 자동화에서는 구현할 수 없는 데이터베이스 관리와 이를 통한 불량예측, 고장진단 등 다양한 부분에서 차이점을 찾을 수 있다[1,2].

위와 같은 스마트 팩토리의 유연한 공정 운영은 발포 공정에서 효과적으로 작용할 수 있다. 최근 자동차 제조사에서 다양한 자동차 모델을 출시하고 있으며, 차량의 내장부품 등 폴리우레탄 폼의 비중이 높아지는 만큼 다양한 품목의 유연한 생산이 이루어져야 한다. 이처럼 4차 산업혁명을 맞이한 현 상황에서 발포공정의 스마트 팩토리의 도입은 불가피하다.

현재 발포공정과 관련된 연구는 폴리올(polyol, 이하 POL)과 이소시아네이트(isocyanate, 이하 ISO)의 혼합비를 변화로 서로 다른 물리적 특성을 가질 수 있다는 연구가 진행된 바 있으며[3], 원료 온도의 변화로 폴리우레탄 폼의 내부 기포셀의 크기가 변화하여 불량이 발생할 수 있다는 연구가 진행되었다[4]. 이 외 제조공정 중 폴리우레탄 폼의 팽창에 대한 수치 해석과 같은 연구가 진행되었다[5].

하지만 발포공정의 각 인자별 상관관계를 머신러닝을 통해 도출한 연구는 진행되지 않았다. 따라서, 본 연구에서는 발포공정에서 수집되는 데이터 중 유량, 압력, 온도의 데이터를 상관관계를 의사결정트리, kNN, 앙상블 알고리즘을 사용하여 머신러닝을 통해 학습시킨 후, 제품의 불량을 예측할 수 있는 기반을 구축하고자 한다. 이번 연구에서 사용된 데이터는 총 6,147개이며 이 중 5,147개의 데이터를 학습용으로, 1,000개의 데이터를 검증용 데이터로 나누어 연구를 진행하였다.

2. 이론적 배경

2.1 발포공정

폴리우레탄 폼의 제조공정은 POL과 ISO를 혼합하여 제조된다. 이러한 발포공정에서 폴리우레탄 폼의 요구 특성에 따라 혼합비와 추가되는 물질의 차이가 있지만, 전반적인 발포공정은 Fig. 1과 같이 간략하게 나타낼 수 있으며, 실제 발포 공정과 본 연구에 사용된 장비는 Fig. 2와 같다.




Fig. 1. Schematic Configuration of Foaming Process



Fig. 2. Foaming Machine Used in Actual Process and Study

위와 같은 공정을 통해 생산된 폴리우레탄 폼은 두 재료의 혼합비율 변화로 인해 서로 다른 물리적 특성을 가질 수 있다는 Kim 외 6명의 연구가 진행된 바 있다[3]. 이는 원료별 발포 유량의 변화로 인한 물리적 특성의 변화로 품질요구 수준을 충족하지 못해 불량을 초래할 수 있음을 짐작할 수 있고, 원료의 유량은 식 (1)을 통해 도출된다.

$$Q = \frac{\pi Pr^4}{8\eta l} \quad (1)$$

P denotes pressure. r denotes radius of the pipe, η denotes viscosity, l denotes length of the pipe

여기서 Q 는 유량, P 는 압력, r 은 유로의 반지름, η 는 유체의 점도, l 은 관로의 길이이다. 위 식을 통해 압력과 유량 사이의 상관관계가 있음을 알 수 있고, 압력 또한 발포공정에서 불량을 초래할 수 있는 인자임을 추측할 수 있다.

폴리우레탄 폼의 물리적 특성은 온도의 변화에 의해서도 변화할 수 있다는 연구도 진행되었다. Kim 외 1명의 연구를 통해 원로 온도의 변화로 폴리우레탄 폼의 내부 기포셀의 크기 변화가 발생함을 확인하는 연구한 바 있어 온도 또한 발포공정에서 불량률 초래하는 인자임을 알 수 있다[4].

2.2 머신러닝

머신러닝은 인공지능의 한 분야로, 1959년 Arthur Samuel의 '컴퓨터에 명시적인 프로그램 없이 배울 수 있는 능력을 부여하는 연구 분야'라는 정의에서 시작되었다. 이후 2000년대 중반부터 IoT를 통한 막대한 데이터의 수집과 연산처리장치의 발달을 통해 2010년에 이르러서는 딥러닝이라는 새로운 개념을 제시할 정도로 비약적인 발전을 이루었으며, 제조 분야에 적용하여 다양한 연구가 진행되고 있다[6-8].

하지만 이러한 머신러닝을 다양한 상황에 적용하는데 있어 한가지 알고리즘만 우수한 결과를 보여주지는 않기에 적절한 알고리즘의 선택은 중요하다.

2.2.1 의사결정트리 (Decision Tree)

의사결정트리는 결정 규칙을 도표화하여 관심 대상이 되는 집단을 몇 개의 소집단으로 분류하거나 예측을 수행하는 분석 방법이다. 분석과정은 지니 불순도, 엔트로피 감소, 투잉 규칙 중 한 가지를 선택하여 각 노드에서 불순도가 줄어드는 방향으로 분류되며, 이러한 분류과정이 나무구조로 표현될 수 있다는 장점이 있다[9-11].

2.2.2 kNN (k-Nearest Neighbor)

kNN은 입력된 값 X에 가장 가까운 점 k개를 선정하여 이들의 레이블을 사용하는 알고리즘이다. 다른 분류 알고리즘과 비교 시 가장 간단하면서 훈련 속도가 빨라 사용이 쉽다는 장점이 있다. 하지만 데이터의 양이 많아질수록 알고리즘의 실행속도가 느려진다. 또한 차원이 많아질수록 필요한 데이터가 많아져 과적합이 발생하기 쉬워지고, 이로 인해 정확한 판단이 어려워질 수 있는 단점이 있다[12,13].

2.2.3 앙상블 (Ensemble)

앙상블 알고리즘을 통한 머신러닝은 기저 분류자(base classifiers) 집합인 앙상블을 구성하고, 앙상블에서 도출된 복수의 학습 결과를 결합하여 하나의 최종결

과를 도출하는 알고리즘이다. 앙상블은 크게 부스팅(boosting)과 배깅(bagging) 방식이 존재한다. 두 가지 방식이 공통으로 추구하는 것은 한가지 학습 결과를 통해 도출된 결과를 출력하는 것이 아닌, 다양한 데이터셋을 통해 도출된 결과를 종합하여 최종결정을 내림으로써 정확도가 높다는 장점이 있다[11,14-16].

3. 연구 방법

3.1 진행 과정

머신러닝은 Fig. 2와 같이 데이터 수집, 머신러닝, 데이터 검증, 결과 분석의 과정으로 진행된다. 이번 연구에서 데이터의 수집은 발포시 센서를 통해 수집되는 데이터를 사용하였으며, 머신러닝은 앞서 말한 3가지 알고리즘에 5,147개의 데이터를 사용하였다. 3가지 알고리즘을 통해 학습된 데이터에 1,000개의 검증용 데이터를 적용하여 나온 결과를 토대로 하여 학습기의 성능을 평가한다.




Fig. 3. Flow Chart of Machine Learning Process

3.2 라벨링 조건

머신러닝을 진행하기에 앞서 라벨링 작업을 해야 한다. 라벨링은 머신러닝을 진행하는데 있어 각 인자에 대한 결과를 학습할 수 있도록 데이터를 분류 및 가공하는 과정이다. 이번 연구에서 정상범위를 판단하는 기준은 기준값에 맞게 발포된 제품 질량을 기준점(reference point)으로 지정하고, 이 기준점으로부터 $\pm 3\%$ 범위로 지정하였다. 이는 시트 발포 공정의 품질요구 수준을 따랐으며, 제조업체 또는 생산되는 물품에 따른 차이가 있을 수 있다. 추가로 기준점 대비 $\pm 2\%$ 이내 구간, $\pm 3\%$ 이내 구간과 이 외의 구간을 각각 2, 1, 0의 3단계로 구분하였으며, 이러한 라벨링 조건은 Fig. 3과 같이 표현할 수 있다.




Fig. 3. Range of Labeling

라벨링 과정에서 단순히 합격 불합격으로만 머신러닝을 진행할 경우, Fig. 3에서 2의 범위에 있는 데이터와 같이 기준값에서 $\pm 2\%$ 의 범위에 속한 예측값은 올바른 예측값이 도출될 수 있다. 반면 1의 범위와 같이 불량과 근접한 위치에 속한 데이터는 불량으로 판단하는 것과 같은 옳지 않은 판단을 할 수 있다. 이러한 잘못된 예측은 정확도를 낮추는 원인으로 작용할 수 있어 이를 배제하기 위함이다.

3.3 데이터 조합

본 연구에서 사용된 데이터는 PLC(Programmable Logic Controller)와 연결된 센서를 통해 수집되며, 데이터의 수집 시기는 발포공정의 노즐이 개방되는 순간 측정된다. PLC와 연결된 센서는 유량(이하 Flow)과 압력(이하 Press)은 각각 기어 타입과 압전 저항형의 센서를 사용하고, 온도(이하 Temp)는 일반적으로 사용하는 PT100 ohm 타입의 센서를 사용하였다. 각 인자에 따른 제품 특성을 머신러닝으로 도출하기 위해 원료별 Flow, Press, Temp 데이터를 조합하였으며, 조합은 Table. 1과 같이 총 9개의 모델로 구성하여 연구를 진행하였다. 이때 각 모델의 명명은 ISO와 POL을 순서로 Flow, Press, Temp의 앞 글자를 조합하였다.

Table 1. Naming According to Data Combination Model

POL \ ISO	Flow	Press	Temp
Flow	FF	PF	TF
Press	FP	PP	TP
Temp	FT	PT	TT

4. 연구 결과

4.1 분류 학습기

앞서 선정한 3가지 알고리즘과 앞서 지정한 9개의 데이터 조합으로 총 27개의 통한 머신러닝을 진행하기 위해 Matlab의 분류 학습기를 사용하였다. 이 과정에서 데이터 조합에 맞는 인자만을 지정하여 학습하였다. 이후 검증용 데이터와 학습용 데이터의 차원을 같게 지정하여 오류가 발생하지 않도록 하였다. 모델 중 가장 상관성이 높다고 판단된 FF의 산포도는 Fig. 4와 같다.

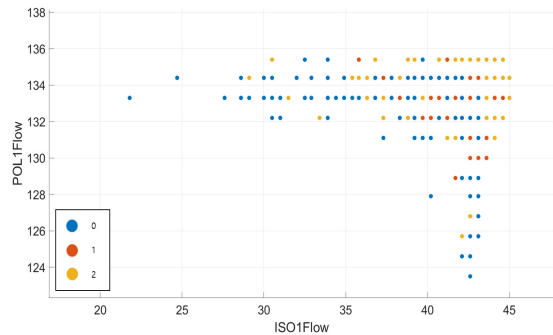


Fig. 4. Scatter Plot for FF Data Classification

Fig. 4를 보면 파란 점과 빨간 점, 노란 점이 보인다. 이는 각각의 데이터가 0, 1, 2의 값을 가지는 분류별 결과 데이터의 분포이다. 머신러닝은 이러한 경향을 학습하여 함수화하고, 이를 검증용 데이터에 적용하여 결과를 도출하는 과정으로 진행된다.

머신러닝을 진행한 결과 Fig. 5와 같은 산포도가 도출되었으며, Fig. 4와 같이 파란 점과 빨간 점, 노란 점이 보이며, 추가로 ○와 ×가 보인다. 각 색상의 의미는 Fig. 4와 같으며 추가로 보이는 ○와 ×는 옳은 모델 예측과 옳지 않은 모델 예측을 의미한다.

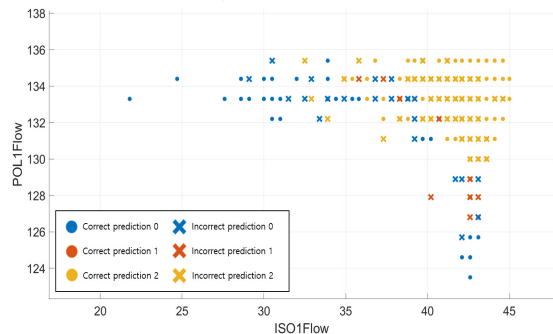


Fig. 5. Prediction Scatter Plot of Machine Learning

위 산포도와 같이 학습된 모델을 검증용 데이터에 적용하여 예측값을 도출하였다.

4.2 결과 분석

학습된 모델에 검증용 데이터를 적용하여 도출된 예측값이 올바른 결과인지 확인하기 위해, 라이브 스크립트에서 도출된 예측값을 검증하였다. 결과 분석을 위해 3.2에서 품질 분류에 따라 0, 1, 2로 라벨링을 통해 구분한 것을 양품과 불량품으로 구분할 필요가 있다. 이에 본 연

구에서는, '1'과 '2'인 기준 무게(reference point)의 ± 3 %까지의 데이터 범위를 양품으로 판단하고 남은 '0'은 불량품으로 하여 머신러닝 모델의 성능을 분석하였다. 만약 제품의 요구품질에 따라 양품의 범위를 '2'만을 사용하여 ± 2 %의 범위로 축소할 수 있다.

나아가 얼마나 신뢰성 있는 예측 결과가 도출되었는지 확인하기 위해 정확도(accuracy), 재현율(recall), 정밀도(precision), F1 지표(F1 score)를 순서대로 식 (2)~(5)를 통해 도출하였다. 각 값은 Table 2~4와 같으며, 순서대로 의사결정나무, kNN, 앙상블의 순서이다. 정확도는 전체 예측 건수 중 정확하게 예측한 정도로 가장 보편적으로 사용되는 방법이며, 데이터셋의 균형이 맞을 때 효과적이다. 재현율은 정답이 참인 것 중 예측 결과가 참으로 판단한 비율이며, 정밀도는 예측 결과가 참으로 판단한 것 중 정답이 참인 비율이다. F1 지표는 식 (5)와 같이 재현율과 정밀도의 조화평균으로 도출하며, 재현율과 정밀도만으로 분류기의 성능을 평가할 수 없을 때 사용한다.

$$Accuracy = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (2)$$

$$Recall = \frac{T_p}{T_p + T_n} \quad (3)$$

$$Precision = \frac{T_p}{T_p + F_p} \quad (4)$$

$$F_1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (5)$$

T_p denotes true positive predict. T_n denotes true negative predict, F_p denotes false positive predict, F_n denotes false negative predict

Table 2~4를 통해 각 알고리즘과 모델에 따른 정확도를 분석할 수 있다. 분석 결과, 최대 98.5 %부터 최소 83.7 %의 정확도로 제품의 불량률을 예측할 수 있음을 알 수 있다. 예측값 중 가장 정확도가 높은 알고리즘은 앙상블 알고리즘이며, 그 중 FF 모델에서 가장 높은 정확도가 도출되었다. 불량률에 가장 큰 영향을 미치는 인자는 Flow이며 가장 적은 영향을 미치는 인자는 Temp임을 확인할 수 있다.

Table 2. Performance Measure for Decision Tree Algorithm

ISO \ POL	Flow	Press	Temp
Flow	0.981	0.937	0.942
Press	0.964	0.959	0.837
Temp	0.959	0.965	0.951

(A) Accuracy

ISO \ POL	Flow	Press	Temp
Flow	0.992	0.996	0.976
Press	0.982	0.995	0.863
Temp	0.996	0.999	1.000

(B) Recall

ISO \ POL	Flow	Press	Temp
Flow	0.988	0.961	0.964
Press	0.980	0.963	0.961
Temp	0.962	0.965	0.951

(C) Precision

ISO \ POL	Flow	Press	Temp
Flow	0.990	0.978	0.970
Press	0.981	0.979	0.910
Temp	0.979	0.982	0.975

(D) F1 score

Table 3. Performance Measure for kNN Algorithm

ISO \ POL	Flow	Press	Temp
Flow	0.966	0.963	0.938
Press	0.976	0.961	0.926
Temp	0.967	0.961	0.951

(A) Accuracy

ISO \ POL	Flow	Press	Temp
Flow	0.984	1.000	0.973
Press	0.996	0.998	0.968
Temp	1.000	1.000	1.000

(B) Recall

ISO \ POL	Flow	Press	Temp
Flow	0.980	0.967	0.963
Press	0.979	0.962	0.954
Temp	0.966	0.961	0.951

(C) Precision

ISO \ POL	Flow	Press	Temp
Flow	0.982	0.983	0.968
Press	0.967	0.980	0.961
Temp	0.983	0.980	0.975

(D) F1 score

Table 4. Performance Measure for Ensemble Algorithm

ISO \ POL	Flow	Press	Temp
Flow	0.985	0.958	0.958
Press	0.972	0.958	0.875
Temp	0.963	0.962	0.949

(A) Accuracy

ISO \ POL	Flow	Press	Temp
Flow	0.993	1.000	0.994
Press	0.995	0.994	0.900
Temp	1.000	1.000	0.998

(B) Recall

ISO \ POL	Flow	Press	Temp
Flow	0.992	0.960	0.963
Press	0.976	0.963	0.966
Temp	0.963	0.962	0.951

(C) Precision

ISO \ POL	Flow	Press	Temp
Flow	0.992	0.979	0.978
Press	0.985	0.978	0.932
Temp	0.981	0.980	0.974

(D) F1 score

5. 결론

이번 연구는 발포공정에서 수집된 ISO와 POL의 Flow, Press, Temp의 인자로 총 9개의 모델을 구성하여 의사결정트리, kNN, 앙상블 알고리즘을 통한 머신러닝을 진행하였다. 이번 연구는 총 6,147개의 발포 데이터를 통해 진행되었으며, 이 중 5,147개의 데이터를 학습용 데이터로 사용 나머지 1,000개의 데이터를 학습된 결과를 검증하는 데 사용하였으며 다음과 같은 결론이 도출되었다.

모델을 9개로 구분하여 의사결정트리, kNN, 앙상블 알고리즘을 적용하였을 때, 98.5 %부터 83.7 %의 정확도가 나온 것으로 보아, 각 인자별 상관관계를 통해 최종 생산품의 불량예측이 가능하다고 판단되었다. 또한 알고리즘별 예측값의 정확도와 F1 지표를 분석한 결과 앙상블 모델에서 가장 높은 예측이 가능한 것을 확인할 수 있었다. 앙상블 알고리즘 중 모델 FF에서 98.5 %로 가장 높은 정확도와 99.2 % F1 지표가 도출되었으며, FP에서 97.2%와 98.5 %, FT에서 96.3 %와 98.1 %의 정확도와 F1 지표를 보여주었다. 다양한 알고리즘을 통해 분석한 결과 Flow, Press, Temp 인자 중 불량률에 큰 영향을 미치는 인자는 Flow이며, 가장 적은 영향을 미치는 인자는 Temp로 판단되었다.

이러한 머신러닝을 통한 결과와 그에 따른 정확도를 통해, 발포공정에서 기록되는 분사 인자를 통해 제품의 불량률 예측이 가능하다고 사료된다. 이번 연구를 통해 불량률에 영향을 미치는 인자를 실시간으로 모니터링 및 조절한다면 불량률 예측 및 개선할 수 있고, 4차 산업혁명의 핵심 역량 중 하나인 초지능의 영역을 수행할 수 있다고 사료된다. 향후 불량률과 밀접한 관련이 있는 인자를 좀 더 정확하게 도출하기 위해 이번 연구와는 다른 딥러닝을 적용한 상관관계의 도출이 진행되어야 한다고 사료된다. 또한 이번 연구를 통해 불량률 유발할 수 있는 인자로 생각되는 Flow와 Press 인자를 조절하기 위해 모터의 작동 주파수를 실시간으로 변경하는 방법을 통해 불량률을 줄이기 위한 연구와 실험적 검증이 지속되어야 한다고 판단된다.

References

- [1] S. H. Woo, Y. B. Cho, "Major Technologies and Introduction of Smart Factory." 2018.
- [2] C. S. Seo, S. J. Jeong, S. C. Kim, "Establishing a Smart Factory to Improve Enterprise Productivity", The Journal of The Korean Institute of Communication Sciences, Vol35. No.6 43-49, 2018.
- [3] S. Y. Kim, H. J. Kim, H. S. Ji, K. S. Kim, O. W. Kim, Y. D Jun, "Characteristics of Static Comfort with Changing Isocyanate/Polyol Mixing Ratio of Polyurethane Foam", The Korean Society Of Automotive Engineers, 954-954, 2019.
- [4] H. S. Kim, J. W. Youn, "A study on foaming characteristics of polyurethane depending on environmental temperature and blowing agent content." Transactions of Materials Processing Vol18. No.3 256-261, 2009.
DOI:<https://doi.org/10.5228/KSPP.2009.18.3.256>
- [5] Bikard, J., Bruchon, J., Coupez, T., & Silva, L. Numerical simulation of 3D polyurethane expansion during manufacturing process. Colloids and Surfaces A: Physicochemical and Engineering Aspects, 309(1-3), 49-63, 2007.
DOI:<https://doi.org/10.1016/j.colsurfa.2007.04.025>
- [6] H. R. Yoon, "A Empirical Study on the Financial Stability Prediction Model of South Korea's Public Enterprises with Machine Learning Techniques", Ph. D, Hansung University, 19-22.
- [7] M. M. C. Han, Y. S. Kim, C. K. Lee, "A Study on Defect Prediction Method Using Sensor Data and Machine Learning in Manufacturing Process", Entru Journal of Information Technology, Vol17. No.1, 89-98, 2019.
- [8] J. E. Ahn, J. Y. Jung, "Predicting and Interpreting Quality of CMP Process for Semiconductor Wafers Using Machine Learning." The Journal of Bigdata Vol4. No.2, 61-71, 2019.
- [9] J. H. Choi, D. S. Seo. "Decision Trees and Its Applications", Journal of statistical analysis., Vol.4 No.1 61-83, 1999.
- [10] .Navada, A., Ansari, A. N., Patil, S., & Sonkamble, B. A. "Overview of use of decision tree algorithms in machine learning." 2011 IEEE control and system graduate research colloquium. IEEE, 37-42, 2011.
DOI:<https://doi.org/10.1109/ICSGRC.2011.5991826>
- [11] Che, D., Liu, Q., Rasheed, K., & Tao, X, "Decision tree and ensemble learning algorithms with their applications in bioinformatics". Software tools and algorithms for biological systems. Springer, New York, NY, 191-199. 2011
DOI:https://doi.org/10.1007/978-1-4419-7046-6_19
- [12] Y. S. Jang, B. J. Park, C. Y. Park, "Comparison study of K-nearest neighborhood classification algorithms", Journal of the Korean Data And Information Science Society, Vol30. No.5, 977-985, 2019.
DOI:<https://doi.org/10.7465/jkdi.2019.30.5.977>
- [13] Bzdok, Danilo, Martin Krzywinski, Naomi Altman, "Machine learning: supervised methods", Nat Methods

15, 5-6, 2018.

DOI:<https://doi.org/10.1038/nmeth.4551>

- [14] S. H. Min, "Improving an Ensemble Model by Optimizing Bootstrap Sampling", Journal of Internet Computing and Services, Vol17. No.2, 49-57, 2016.
DOI:<https://doi.org/10.7472/jksii.2016.17.2.49>
- [15] Vega-Pons, Sandro, José Ruiz-Shulcloper., Faramarz Gordaninejad, Xiaojie Wang, "A survey of clustering ensemble algorithms", International Journal of Pattern Recognition and Artificial Intelligence, Vol25. No.3 337-372, 2011.
DOI:<https://doi.org/10.1142/S0218001411008683>
- [16] Polikar, Robi. "Ensemble learning." Ensemble machine learning. Springer, Boston, MA, 1-34, 2012.
DOI:https://doi.org/10.1007/978-1-4419-9326-7_1

최 낙 훈(Nak-Hun Choi)

[준회원]



- 2021년 2월 : 공주대학교 기계자동차공학부 (공학사)
- 2021년 3월 ~ 현재 : 공주대학교 미래융합공학과 석사과정

<관심분야>

스마트 팩토리, 머신러닝, 불량 예측

안 종 록(Jong-Rok Ahn)

[정회원]




- 2015년 3월 ~ 2017년 2월 : 공주대학교 생산기계공학과 (공학사)
- 2017년 3월 ~ 2019년 8월 : 공주대학교 테크노 융합대학원 기계자동차 융합전공 (공학석사)
- 2010년 1월 ~ 현재 : 이스턴에프티씨 부설연구소

<관심분야>

자동차 부품 및 공정, 스마트 팩토리

오 종 석(Jong-Seok Oh)

[정회원]



- 2009년 2월 : 인하대학교 기계공학과 (기계공학사)
- 2011년 2월 : 인하대학교 기계공학과 (기계공학석사)
- 2015년 8월 : 인하대학교 기계공학과 (기계공학박사)
- 2017년 2월 : 현대모비스 미래기술연구팀 (책임연구원)
- 2017년 3월 ~ 현재 : 공주대학교 기계자동차공학부 조교수

<관심분야>

기계 및 자동차 계측 제어 시스템 설계

김 기 선(Key-Sun Kim)

[종신회원]



- 1995년 2월 : 인하대학교 대학원 공학박사
- 1994년 3월 ~ 2020년 2월 : 공주대학교 기계자동차공학부 교수
- 2020년 6월 ~ 현재 : 이스턴에프티씨 부설연구소

<관심분야>

자동차 부품 및 공정