

기계학습 기법을 이용한 CNC 공구 마모도 예측에 관한 연구

이강배¹, 박성호^{2*}, 성상하³, 박도명⁴

¹동아대학교 경영정보학과 교수, ²동아대학교 경영정보학과 박사과정, ³동아대학교 경영정보학과 석사과정, ⁴(주)태광 이사

A Study on the Prediction of CNC Tool Wear Using Machine Learning Technique

Kangbae Lee¹, Sungho Park^{2*}, Sangha Sung³, Domyoung Park⁴

¹Professor, MIS, Donga University

²Doctoral Course, MIS, Donga University

³Master's Course, MIS, Donga University

⁴CTO, Taekwang Co., Ltd.

요 약 4차 산업혁명이 주목받고 있다. 특히 스마트 팩토리는 제조 분야에서 그 필요성이 강조되고 있다. 현재 제조 분야에서 CNC(Computerized Numeric Controller: 컴퓨터 수치 제어)에 관한 연구가 활발히 진행 중이다. 국내에서는 CNC 설비에 음향 센서, 진동 센서 등 여러 가지 센서를 부착하여 소음, 진동 등 설비 관련 데이터를 수집하는 방안이 관한 연구가 존재한다. 본 연구는 CNC 머신에서 발생하는 데이터를 중심으로 머신러닝 기법을 활용하여 설비 가동 조건이 공구 마모도에 미치는 영향을 분석한다. CNC 설비에서 발생하는 X축, Y축, Z축의 힘, 이동 속도 등 다양한 데이터를 수집한다. 데이터 탐색 기법을 통해 데이터의 특성 및 분포를 분석하였다. 데이터를 RF(Random Forest), XGB(Extreme Gradient Boost), SVM(Support Vector Machine)을 이용하여 CNC 설비 가동 조건이 공구 마모도에 미치는 영향을 분석하였다. 본 연구의 결과는 CNC 설비 가동에서 최적의 조건을 찾고, 이를 바탕으로 품질 향상 및 기계 손상을 예방하는데 활용될 수 있을 것으로 기대된다.

주제어 : CNC 설비, 머신러닝, 랜덤 포레스트, 서포터 벡터 머신

Abstract The fourth industrial revolution is noted. It is a smarter factory. At present, research on CNC (Computerized Numeric Controller) is actively underway in the manufacturing field. Domestic CNC equipment, acoustic sensors, vibration sensors, etc. This study can improve efficiency through CNC. Collect various data such as X-axis, Y-axis, Z-axis force, moving speed. Data exploration of the characteristics of the collected data. You can use your data as Random Forest (RF), Extreme Gradient Boost (XGB), and Support Vector Machine (SVM). The result of this study is CNC equipment.

Key Words : Random Forest, XGBoost, CNC, SVM, Machine Learning

*This paper is a basic research project that was carried out with the support of the Korea Research Foundation as a fund of Dong-A University's URP project in 2019 (No. 2019-0494)

*Corresponding Author : Sungho Park(psh2975@donga.ac.kr)

Received October 1, 2019

Revised November 4, 2019

Accepted November 20, 2019

Published November 28, 2019

1. 서론

제조 분야에서는 작업자의 경험이 가장 중요한 요인 중 하나이다. 오늘날 설비의 가동 조건 설정은 작업자들의 축적한 경험을 바탕으로 이루어지고 있다. CNC 공작 기계를 사용하는 주된 이유는 가공 제품의 품질을 향상하고, 기계 손상을 예측하는 등 현장에서 요구하는 사항을 충족시키기 위함이다[1]. CNC 공작 기계에서 가공시간을 단축하고, 제품의 품질을 일정하게 유지하기 위해서 많은 노력이 필요하다. 또한, 이를 위해 많은 센서 정보가 필요하다[2]. 따라서 공작 기계의 공구 마모도를 예측하고 관리하기 위하여 주변에 온도감지, 회전력 감지 센서, 진동 감지 센서 등 다양한 센서가 부착된 절삭 도구를 이용한다. 내장된 센서의 가격이 고가임에도 불구하고, 아직까지 필요한 데이터를 수집하는 것에 한계가 있다[3]. CNC 절삭 공구에 관한 연구는 국내와 해외 연구로 구분할 수 있다. 국내 연구는 센서를 이용하여 데이터를 수집하는 방법에 초점을 맞추고 있다. 다양한 특성을 사용한 연구를 찾아보기 어렵고, 특히 머신러닝 방법론을 적용한 연구가 부족한 실정이다. 해외 연구에서는 머신러닝 방법론을 사용한 연구가 다수 존재하지만, PHM 데이터와 같이 한정된 특성을 사용한 연구가 대부분이다. 본 연구에서는 국내·외 선행연구와 달리 다양한 머신러닝 기법을 이용하여 CNC 절삭 공구에 영향을 미치는 48가지의 특성을 분석하였다. 절삭 공구에 영향을 미치는 요인을 분석하여, 가공 제품의 품질을 향상시키고, 절삭 공구 손상을 예측하여 전체 가공 공정의 비용을 절감할 수 있을 것으로 예상된다. 또한 본 연구를 통해 CNC 설비에서 발생하는 여러 특성을 가장 효율적으로 분석할 수 있는 머신러닝 기법을 제시할 수 이론적 근거를 마련할 수 있을 것으로 기대된다.

본 연구의 구성은 다음과 같다. 2장에서는 공구 마모도에 관한 이론적 배경을 설명한다. 3장에서는 분석 데이터와 분석 방법을 제시한다. 4장에서는 분석 결과를 해석하고, 5장에서는 본 연구의 결론을 제시한다.

2. 이론적 배경

2.1 기계학습

기계학습은 1950년대 인공지능망이라는 개념으로부터 시작되었다. 하지만 발표 이후 컴퓨팅 파워 부족 등의 현실적인 이유로 오랜 기간 침체를 겪었다가 2010년

이후 컴퓨팅 파워 향상과 다양한 머신러닝 방법론의 발전으로 최근까지 다양한 분야에서 적극적으로 연구되고 있다. 기계학습은 기존의 샘플링 데이터에 대한 통계적 분석에서 찾아내기 어려웠던 새로운 통찰을 찾아내는 것을 목적으로 한다. 이 과정에서 통계적인 기법에서는 연구자의 주관에 개입될 확률이 높은 반면, 기계학습을 이용한 분석에서는 연구자의 주관에 아닌 데이터 기반으로 분석을 진행하기 때문에 기존의 방법보다 연구의 객관성을 확보하기 용이하다[4]. 기계학습은 지도 학습과 비지도 학습으로 구분된다. 지도 학습은 입력 값과 출력 값이 존재하는 데이터를 설정된 알고리즘을 통해 학습시켜 최적의 모형을 찾는 것이다. 지도 학습을 통해 미래에 대한 예측 또는 분류하는 것이 가능하다. 비지도 학습은 데이터의 특성을 알 수 없을 때, 컴퓨터가 스스로 데이터의 패턴이나 데이터 사이의 관계를 찾아내는 것이다. 본 연구는 지도 학습 방법론을 이용하여 CNC 절삭 공구 마모도에 영향을 미치는 요인을 분석하고자 한다. 본 연구에서 사용한 방법론은 부스팅 방법을 이용한 XGBoost와 다양한 커널 기법을 활용할 수 있는 서포터 벡터 머신(Support Vector Machine ; SVM), 비교적 쉬운 전처리 과정과 배깅 방법으로 기존의 의사결정 나무에서 발생하는 과적합 문제에 강점을 보이는 랜덤 포레스트(Random Forest ; RF)를 사용하였다.

2.2 선행연구 검토

Akhilesh Kumar은 PHM 데이터¹⁾를 사용하였으며, 예측 모델 구축의 수단으로는 다항식 회귀 분석을 사용하였다. 분석 결과는 이전 논문과 비교해 상당히 높은 결정계수와 RMSE 수치를 달성하였다[5].

정성택은 하향 절삭 중 건식 제약조건에서 주 절삭력을 예측하였으며, 직접 공구에 센서를 부착하여 데이터를 수집하였다. 실험 결과는 편차가 크게 나타났다. 예측의 정확도를 높이기 위해서 지속적인 연구의 필요성을 제시하였다[6].

Dazhong Wu 외 4명은 PHM 데이터를 사용하여 분석을 진행하였다. RF의 성능을 ANN 및 SVR과 비교하였다. 또한 사전진단 방법을 도입하였으며 RF의 정확도가 가장 높다는 결과를 도출하였다[7].

Jinjiang Wang은 PHM 데이터를 사용하여 분석을

1) PHM Society data challenge 2010에서 사용된 데이터로 c1에서 c6까지 실험으로 구성된 데이터이다. 대회에서 주어진 모니터링 데이터는 7개의 특성으로 구성되어 있다.

진행하였다. Convolutional Bi-directional LSTM 네트워크 (CBLSTM)라는 새로운 기계 상태 모니터링 시스템을 제안하였다. 다양한 기법들을 비교하여 CBLSTM이 가장 낮은 오차를 달성하였다[8].

강성현은 스마트폰 메탈 프레임의 CNC 설비를 이용한 가공 공정에 들어가는 비용을 최소화하기 위해 공구 상태를 파악하였다. 통계기법들을 기반으로 다변량 모니터링 방안을 개발하여 지연 공정과 중단 공정의 이상 원인을 확인하였다. 지연 공정은 주로 스피들 모터, 중단 공정은 주로 Z축 모터가 원인임이 확인하였다[9].

Amit Kumar Jain 등은 PHM 데이터를 활용하여, 잔여 유효 수명(Remaining Useful Life)을 예측하였다. 적절한 특징을 우선 추출하였으며, 이를 기반으로 온라인, 오프라인, 반 오프라인 방법으로 각각에 적용시켰다. 그 결과 각 방식의 예측 결과가 뛰어난을 확인하였다[10].

T. Benkedjough, 외 3명은 PHM 데이터를 사용하였으며 두 가지 비선형 피쳐 감소 기술과 SVR을 사용하여 공구 마모 평가 및 RUL²⁾ 예측 방법을 제시하였다. 최종적으로 이 모델은 절삭공구의 RUL을 예측하였으며 실제 마모도와 비슷한 결과를 출력하였다[11].

CNC 절삭 공구에 관한 연구는 국내 연구와 해외 연구로 구분할 수 있다. 국내 연구는 CNC 절삭 공구에 온도, 소음 등의 센서를 달아서 데이터를 수집하는 연구가 대부분이다. 이러한 연구들은 수집된 데이터를 회귀분석과 실험계획법을 사용하여 분석하였다. 해외 연구는 주파수, 공구 이동 속도, 전력, 진동 등 데이터를 이용하여 다양한 머신러닝 기법에 적용시킨 연구가 다수 존재한다[12]. 그러나 실제 CNC 절삭 공구에 영향을 미치는 특성은 다양함에도 불구하고 선행연구들에서 사용된 데이터는 한정적이다. 본 연구들에서는 다양한 특성을 활용하여 X축, Y축, Z축의 회전력, 축력, 이송속도, 전력, 전압 등의 48가지 특성을 사용하여 분석을 시도하고 공구 마모도를 예측하였다.

3. 분석자료 및 분석 방법

3.1 자료설명

본 연구에서 사용된 데이터는 Kaggle Competition의 미시간 대학의 SMART(System-Level Manufacturing

and Automation Research Testbed)에서 CNC 머신에 대해 일련의 가공 실험 과정에서 발생한 공구 상태, 이송속도, 클램프 압력 등의 데이터를 수집하였다. CNC의 4개의 모터인 X, Y, Z 축 및 스피들에 사용된 측정값을 구분하였다. 해당 데이터는 미시간 대학의 Rockwell Cloud Collector Agent Elastic을 이용하여 데이터를 추출하였다.

Table 1. Data description

no	Item	Explanation
1	X1_ActualPosition	Actual x position of the part (mm)
2	X1_ActualVelocity	Actual x speed of parts (mm / s)
3	X1_ActualAcceleration	Actual x acceleration of the part (mm / s / s)
4	X1_CommandPosition	X position of the part (mm)
5	X1_CommandVelocity	X part speed (mm / s)
6	X1_CommandAcceleration	X part acceleration (mm / s / s)
7	X1_CurrentFeedback	Current (A)
8	X1_DCBusVoltage	Voltage (V)
9	X1_OutputCurrent	Current (A)
10	X1_OutputVoltage	Voltage (V)
11	X1_OutputPower	Power (kW)
12	Y1_ActualPosition	Actual Y position of the part (mm)
13	Y1_ActualVelocity	Actual Y speed of parts (mm / s)
14	Y1_ActualAcceleration	Actual Y acceleration of the part (mm / s / s)
15	Y1_CommandPosition	Y position of the part (mm)
16	Y1_CommandVelocity	Y part speed (mm / s)
17	Y1_CommandAcceleration	Y part acceleration (mm / s / s)
18	Y1_CurrentFeedback	Current (A)
19	Y1_DCBusVoltage	Voltage (V)
...
23	Z1_ActualPosition	Actual Z position of the part (mm)
24	Z1_ActualVelocity	Actual Z speed of parts (mm / s)
...
48	Machining_Process	Current processing stage

본 연구의 목적인 공구 마모도에 영향을 미치는 요인을 분석하기 위하여 CNC 머신에서 발생한 Table 1과 같이 48가지 데이터를 사용하였다. X, Y, Z 축과 스피들에 사용된 전력, 전류, 이송 속도, 좌표 값, 부품의 실제 x, y, z 축의 실제 속도를 센서를 이용하여, 데이터를 수집하였다. 모든 CNC 가동 데이터는 수행 중인 작업이 독립적인 관찰로 수행되었다. 또한 수집된 데이터는 18개의 시험을 독립적으로 수행하였다. 공구 마모도는 육안 검사를 통해 측정되었다. 본 연구에서는 수집된 데이터를 사용하여 공구 마모도에 영향을 미치는 요인을 다양한 머신러닝 기법을 활용하여 분석하고자 한다.

3.2 분석방법

본 연구에서 사용된 분석 방법은 Xgboost(Extreme Gradient Boosting; XGB), 서포터 벡터 머신(Support

2) Remaining useful life, RUL, 잔여 내용연수

Vector Machine; SVM), 랜덤 포레스트(Random Forest; RF) 방법을 사용하였다. 전체 데이터의 80%를 train 데이터로 활용하고, 나머지 20% 데이터를 test 데이터로 활용하였다. 기계학습에서는 각 모형 별로 초모수의 설정이 중요하기 때문에 각 모형 별로 초모수를 변화시키면서 정확도 값을 계산하였다[13]. 모형 별로 계산된 정확도를 비교하여 가장 큰 값을 가지는 모형을 가장 우수한 모형으로 선정하였다. 기계 학습 분석을 진행하기 앞서 탐색적 분석을 실행하여 데이터의 특성을 살펴보았다. Table 2에서 데이터의 특성을 살펴본 결과 변수들 간의 관계를 파악할 수 있다. XGB, RF, SVM 기계학습 분석도구로 파이썬(Python) Scikit-Learn 패키지를 이용하였다.

Table 2. Data exploration analysis

Variable	count	mean	std
X1_ActualPosition	25286	159.052	19.330
X1_ActualVelocity	25286	-0.28866	5.6582
X1_ActualAcceleration	25286	0.094264	93.877
X1_CommandPosition	25286	159.0507	19.331
X1_CommandVelocity	25286	-0.28308	5.6643
X1_CommandAcceleration	25286	0.253215	72.594
X1_CurrentFeedback	25286	-0.46971	4.2207
X1_DCBusVoltage	25286	0.066031	0.0370
X1_OutputCurrent	25286	326.9459	1.4599
X1_OutputVoltage	25286	7.986942	7.7103
X1_OutputPower	25286	0.00061	0.0015
Y1_ActualPosition	25286	99.23006	29.244
Y1_ActualVelocity	25286	-0.42293	6.0064
Y1_ActualAcceleration	25286	0.928832	85.074
M1_sequence_number	25286	47.34501	43.826
M1_CURRENT_FEEDRATE	25286	16.54204	19.620
target	25286	0.526299	0.4993

4. 분석결과

4.1 모형별 학습결과

4.1.1 SVM

SVM 모형은 다양한 커널 함수 중 RBF(Radial Basis Function, RBF) 커널을 이용해서 모형을 구축하였다. train 데이터를 모형에 학습 시킨 후 최적의 모형을 선정하였다. 커널 기법이란 데이터의 차원을 고차원 공간으로 사영하여 선형 분류기로 비선형 관계의 데이터를 모형에

적합이 가능하게 하는 것이다[14]. 가우시안 RBF 커널은 오류에 대한 페널티를 부여하는 초모수, train 데이터의 영향도와 범위에 관련된 초모수, train 데이터의 오차 허용 비율을 결정하는 초모수 설정이 우선되어야 한다. Table 3과 같이 초모수를 조정하면서, 정확도를 비교하였다.

Table 3. SVM Fit results

Division	time(s)	accuracy
RBF Kernel		
C		
1	110	0.626
5	165	0.629
10	169	0.629
50	166	0.629

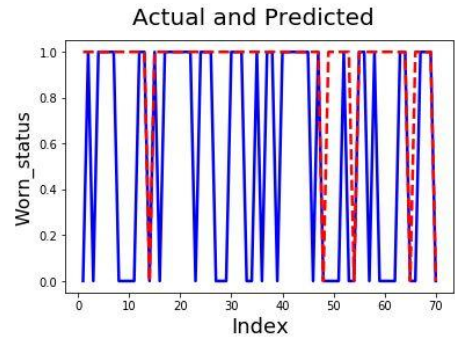


Fig. 1. SVM Actual and predicted value results

SVM의 적합 결과는 Fig. 1과 같다. 파란 선과 빨간 점선이 일치하는 부분이 예측이 잘 된 것이다. 파란 선은 실제 값이며, 빨간 점선은 예측 값이다. 오차 허용률인 C 값을 조정하면서 최적의 모형을 탐색한 결과 C=5 일 때 최적의 모형으로 선정하였다. SVM의 경우 특정 구간에서 예측에 어려움이 있었던 것으로 나타났다.

4.1.2 XGB

XGB 모형은 분류와 회귀로 구분된다. 본 연구에서는 XGB 분류 방법으로 분석을 진행하였다. XGB에서 중요한 초모수는 모델의 복잡도를 결정하는 트리의 깊이이다. 트리의 깊이가 커질수록 모델의 복잡도가 커지면서 과적합의 위험도 커진다. 다른 모형들과 비교 및 cross validation을 통해 과적합 정도를 확인할 수 있다. XGB는 가지 수에 따라 정확도에 차이가 많이 나는 것을 확인하였다. 최종 모형은 Table 4에서 보듯이 트리의 깊이를

조절하면서 분석에 필요한 시간과 정확도를 고려하여 결정하였다.

Table 4. XGB Fit results

Tree number	Time(s)	Accuracy
10	0.36	0.882
50	1.87	0.954
100	2.88	0.97
200	5.69	0.986
500	14	0.993




Fig. 2. XGB Actual and predicted value results

XGB의 적합 결과는 Fig. 2와 같다. 트리의 수가 증가할수록 정확도가 높아지는 결과를 보였다. 모든 구간에서 매우 잘 예측되었다.

4.1.3 RF(Random Forest)

RF는 분류와 예측에 강점을 보이는 기계학습 방법이다. 기존의 의사결정 나무와 다르게 다수의 트리로부터 평균 예측치를 출력해서 전체적인 데이터의 분산을 감소하는 것이 특징이다[15]. 무작위로 다른 트리를 구성하여 각 트리 간의 상관관계를 최소화하여 데이터의 크기나 분포의 영향을 적게 받는다. RF는 다른 방법론에 비해 전처리 과정이 단순하지만, 좋은 성능을 보인다. RF에서 중요한 초모수는 트리의 수이다. 본 연구에서는 Table 5와 같이 트리의 수를 조절하면서, 최적의 모형을 탐색하였다.

Table 5. RF Fit results

Tree number	Time(s)	Accuracy
10	0.26	0.988
50	1.29	0.993
100	2.6	0.992
200	5.22	0.992
500	13	0.993




Fig. 3. RF Actual and predicted value results

RF는 트리 수가 50일 때 최적의 모형으로 선정되었다. 분석에 소요된 시간과 정확도를 모두 고려할 때 가장 우수한 결과를 나타냈었고, Fig. 3과 같이 실제 값과 예측 값을 비교한 결과도 매우 우수하게 나타났다.

4.2 분석결과 종합

각 모형들의 최종 학습 결과는 Table 6과 같다. SVM, XGB, RF 중 분석에 소요된 시간과 정확도를 모두 고려한 결과 RF가 가장 우수한 모형으로 선정되었다. SVM의 경우 특성의 수가 많고, 데이터의 분포가 일정하지 않은 문제로 인해 다른 모형에 비해 성능이 떨어졌다. XGB와 RF는 SVM에 비해 빠른 분석 속도와 정확도를 나타내었다. XGB와 RF는 복잡하지 않은 전처리 과정이 장점이다. 또한 분석 결과 높은 정확도를 보였으며, 이를 통해 모형의 우수함이 검증할 수 있었다. Table 6에서 보듯이 분석에 소요된 시간과 정확도를 모두 고려한 결과 RF를 가장 우수한 모형으로 선정하였다.

Table 6. Analysis result

Division	Time(s)	Accuracy	Hyper Parameter
SVM	165	0.629	5
XGB	14	0.993	500
RF	1.29	0.993	50

5. 결론

본 연구는 CNC 설비 가동에 필요한 가동 조건들을 최대한 반영하여 실제 산업 현장에서 도움이 되고자 하였다. 따라서 기계학습 방법을 이용하여 CNC 절삭 공구에 영향을 미치는 요인을 파악했다. 기계학습 모형 간 정

확도를 비교하여 가장 우수한 모형을 선정하였으며, 각 모형별 분석을 통한 연구 결과는 다음과 같다.

기계학습 모형인 SVM, XGB, RF의 예측 결과는 SVM이 가장 낮게 나타났다. SVM은 분석 시간도 가장 길었을 뿐만 아니라 정확도도 가장 낮게 나타났다. SVM의 경우 분석에 사용된 특성이 많고, 각 특성들의 수치가 다르기 때문에 좋은 않은 성능을 보여줬다. XGB와 RF의 경우 분석에 소요된 시간과 정확도에서 강점을 보였다. RF는 분석에 소요된 시간과 정확도를 모두 고려한 결과 가장 뛰어난 성능을 보여 최종 모형으로 선정하였다.

국내 연구에서는 한정된 특성의 수에 대한 수치해석 및 통계 기법을 사용하며, 이러한 통계 분석은 현실적인 문제를 반영하는데 한계점이 있었다. 또한 선행연구에서 PHM 2010 데이터 챌린지 컨퍼런스를 이용한 논문들의 공구 마모도 예측 정확도가 90%에 머물렀던 것에 비해 본 연구의 정확도는 99%의 정확도를 보였다. 본 연구의 시사점은 48개의 특성을 다양한 머신러닝 기법을 이용하여 CNC 절삭 공구 마모도에 미치는 영향을 분석한 것이다. 본 연구에서 가장 우수한 모형으로 선정된 RF 모형은 특성 중요도를 파악하여, 현장에서 사용하는 CNC 공작 기계의 최적 가동 조건을 설정할 수 있다. 이를 통해 가공품의 품질 향상 및 기계 손상의 예측을 하여, 가공 공정에서 발생하는 낭비를 줄일 수 있을 것으로 기대된다.

REFERENCES

- [1] J. H. Ryu. (2019). *Monitoring of Milling Processes through Measurement of Power Consumption*. Master dissertation, Seoul University, Seoul.
- [2] J. J. Kim. (2019). A Detection and Stabilization Method for CNC Tool Vibration using Acoustic Sensor. *Journal of Korea Institute of Information, Electronics, and Communication Technology*, 12(2), 120–146. DOI : 10.17661/jkiect.2019.12.2.120
- [3] Y C Liu, X F Hu & S. X. Sun. (2019, July). Remaining Useful Life Prediction of Cutting Tools Based on Support Vector Regression. *IOP Conference Series: Materials Science and Engineering* (pp. 1–8). China : IOP Publishing.
- [4] J. H. Oh & J. S. Kim. (2017. June). Prediction of Housing Price using Machine Learning: Focusing on MARS, *Korea Housing Association 2017 Spring Conference* (pp. 153–17)1, Korea : the Korean Association for Housing Policy Studies
- [5] A. Kumar et al. (2019). An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools, *Computers & Industrial Engineering*, 128, 1008–1014. DOI : 10.1016/j.cie.2018.05.017
- [6] S. T. Jung. (2018). Prediction and Experiments of Cutting Forces in Down Milling of Hardened Mold Steel, *Journal of the Korean Society of Manufacturing Technology Engineers*, 27(4), 346–350. DOI : 10.7735/ksmte.2018.27.4.346
- [7] D. Wu et al. (2017). A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests, *Journal of Manufacturing Science and Engineering*, 139(7), 1–19. DOI : 10.1115/1.4036350
- [8] J. Wang & R. Zhao. (2017). Learning to Monitor Machine Health with Convolutional Bi-Directional LSTM Networks, *Sensors* 2017, 17(2), 2–18 DOI : 10.3390/s17020273
- [9] S. H. Kang. (2016). Multivariate Monitoring of the Metal Frame Process in Mobile Device Manufacturing, *Journal of the Korean Institute of Industrial Engineers*, 42(6), 1–9 DOI : 10.7232/JKIEE.2016.42.6.395
- [10] AMIT JAIN & BHUPESH KUMARLAD. (2016). Data Driven Models for Prognostics of High Speed Milling Cutters, *International Journal of Performability Engineering*, 12(1), 3–12 DOI : 10.23940/ijpe.16.1.p3.mag
- [11] T. Benkedjough (2015). Health assessment and life prediction of cutting tools based on support vector regression, *Journal of Intelligent Manufacturing* 2015, 26(2), 213–223 DOI : 10.1007/s10845-013-0774-6
- [12] A. Gouarir & G. Martinez-Arellano. (2018. June). In-process Tool Wear Prediction System Based on Machine, *8th CIRP Conference on High Performance Cutting*, (pp. 501–504), Hungary : Procedia CIRP DOI : 10.1016/j.procir.2018.08.253
- [13] H. J. Kim. (2019). Machine Learning-based Quality Control and Error Correction Using Homogeneous Temporal Data Collected by IoT Sensors, *Journal of the Korea Convergence Society*, 10(4), 17–23 DOI : 10.15207/JKCS.2019.10.4.017
- [14] S. W. Bae. (2018). Estimation of the Apartment Housing Price Using the Machine Learning Methods: The Case of Gangnam-gu, *Journal of the Korea Real Estate Analysts Association*, 24(1), 69–85 DOI : 10.19172/KREAA.24.1.5
- [15] H. J. KIM. (2019). Estimating the Performance of Random Forest versus Multiple Regression for Predicting Prices of the Apartments, *International Journal of Geo-Information*, 7(5), 1–16 DOI : 10.3390/ijgi7050168

이 강 배(Kangbae Lee) [장학원]



- 1991년 3월 ~ 1995년 8월 : 한국과학기술원 산업공학(박사)
- 2001년 3월 ~ 2004년 8월 : 부산 가톨릭대학교 경영정보학과 교수
- 2008년 2월 ~ 현재 : 동아대학교 경영정보학과 교수
- 관심분야 : 머신러닝, 딥러닝

· E-Mail : kanglee@dau.ac.kr

박 성 호(Sungho Park) [장학원]




- 2017년 2월 : 동아대학교(학사)
- 2019년 2월 : 동아대학교(석사)
- 2019년 2월 ~ 현재 : 동아대학교 경영정보학과 박사과정
- 관심분야 : 머신러닝, 딥러닝
- E-Mail : psh2975@donga.ac.kr

성 상 하(Sangha Sung) [학생회원]



- 2018년 2월 : 동아대학교 경영정보학과(학사)
- 2018년 3월 ~ 현재 : 동아대학교 경영정보학과 석사과정
- 관심분야 : 머신러닝, 딥러닝
- E-Mail : sangha@donga.ac.k

박 도 명(DoMyoung Park) [장학원]



- 1997년 ~ 2006년 : (주)동화엔텍 전산실장
- 2006년 ~ 현재 : (주) 태광 이사
- 2019년 2월 : 동아대학교 경영정보학과 석사
- 2019년 6월 ~ 현재 : 동아대학교 경영정보학과 박사과정

· 관심분야 : 통계, 수치해석, WCF, Smart Factory

· E-Mail : home21cc@gmail.com