



공작기계의 절삭용 인서트의 잔여 유효 수명 예측 모형

Machine Learning Model for Predicting the Residual Useful Lifetime of the CNC Milling Insert

최원근¹, 김흥섭², 곽봉진^{1*}

¹국립창원대학교 전기전자제어공학부

²국립창원대학교 산업시스템공학과

Won-Gun Choi¹ · Heungseob Kim² · Bong Jin Ko^{1*}

¹ Department of Electronic Engineering, Changwon National University, Changwon 51140, Korea

² Department of Industrial & Systems Engineering, Changwon National University, Changwon 51140, Korea

[요 약]

스마트 팩토리의 구축을 위해서는 제조 환경에서 여러 센서 및 기기 등을 연결하여 데이터를 수집하고, 데이터 분석을 통해 생산설비 등의 장애를 진단하거나 예측하여야 한다. 본 논문에서는 공작기계에서 제품을 가공하기 위해 사용되는 절삭용 인서트의 잔여 유효 수명을 예측하기 위해 진동 신호를 기반으로 한 가중화 k -최근접이웃(Weighted k -NN) 알고리즘, 의사결정나무(Decision Tree), 서포트벡터회귀(SVM), XGBoost, 랜덤포레스트(Random forest), 1차원 합성곱신경망(1D-CNN), 그리고 진동 신호를 FFT한 주파수 스펙트럼에 대해 알아보았다. 연구결과, 주파수 스펙트럼으로는 잔여 유효 수명의 정확한 예측에 대해서는 신빙성있는 기준을 제공하지 못한다는 것을 알 수 있었고, 예측 모델 중 가중화 k -최근접이웃 알고리즘이 MAE가 0.0013, MSE가 0.004, RMSE가 0.0192로 가장 우수한 성능을 나타내었다. 이는 가중화 k -최근접이웃 알고리즘에 의해 예측되는 인서트의 잔여 유효 수명의 오차가 0.001초 수준으로 평가되어, 실제 산업현장에 적용이 가능한 수준으로 사료된다.

[Abstract]

For the implementation of a smart factory, it is necessary to collect data by connecting various sensors and devices in the manufacturing environment and to diagnose or predict failures in production facilities through data analysis. In this paper, to predict the residual useful lifetime of milling insert used for machining products in CNC machine, weight k -NN algorithm, Decision Tree, SVR, XGBoost, Random forest, 1D-CNN, and frequency spectrum based on vibration signal are investigated. As the results of the paper, the frequency spectrum does not provide a reliable criterion for an accurate prediction of the residual useful lifetime of an insert. And the weighted k -nearest neighbor algorithm performed best with an MAE of 0.0013, MSE of 0.004, and RMSE of 0.0192. This is an error of 0.001 seconds of the remaining useful lifetime of the insert predicted by the weighted-nearest neighbor algorithm, and it is considered to be a level that can be applied to actual industrial sites.

Key word : Acceleration sensor, Machine learning, Milling insert, Smart factory, Weighter k -NN.

<http://dx.doi.org/10.12673/jant.2023.27.1.111>



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.

Received 12 December 2022; Revised 31 January 2023

Accepted (Publication) 9 February 2023 (28 February 2023)

*Corresponding Author : Bong Jin Ko

Tel: +82-55-213-3653

E-mail : bjko@changwon.ac.kr

1. 서론

현대사회는 정보통신기술로 빠르게 발전하고 있으며 특히 4차산업혁명으로 불리는 융합과 공유의 산업시대로 변환하고 있다. 이러한 4차산업혁명은 제조 분야에서는 스마트팩토리(Smart factory)로 귀결된다[1]-[3].

스마트팩토리는 생산과정에 정보통신기술이 결합되어 생산성 및 품질 등을 높여주는 지능형 공장을 의미한다. 이를 위해서는 제조 환경에서 여러 센서 및 기기 등을 연결하여 데이터를 수집하고, 데이터 분석을 통해 생산설비 등의 장애를 진단하거나 예측함으로써 설비 고장으로 인한 생산 중단, 안전사고 등을 방지하거나, 고장을 사전에 예측하기 위해 설비 또는 주요 구성품의 잔여 유효 수명(RUL; Residual Useful Lifetime)을 예측하여 정비계획(Maintenance schedule)에 활용함으로써 생산성과 설비 가동률을 극대화 할 수 있게 한다[4][5].

생산 설비의 고장을 진단/예측하여 정비를 수행하는 개념을 상태기반정비(CBM; Condition Based Maintenance)라 하며, 잔여 유효 수명 예측을 통해 정비계획을 운영하는 개념을 예지정비(PdM; Predictive Maintenance)라 한다. 따라서 스마트팩토리 분야에서 생산 설비를 관리하기 위한 정비개념에 대한 연구들은 상태기반정비와 예지정비(PdM) 체계 구축을 지원하는 방향으로 수행되어 왔다. 상태기반정비에서 생산 설비의 고장 징후 감지는 주로 이상치 탐지 또는 정상 상태와 비정상 상태를 분류하는데 목적을 두고 있다. 반면, 예지정비는 고장 직전의 징후보다는 생산 설비 또는 구성품의 잔여 유효 수명을 예측하고, 예고된 고장 원인을 분석하여 대응 방안을 제시하는 것까지를 포함한다.

회전기계의 진동 신호를 기반으로 하는 상태기반정비에 대한 연구로는, Lim *et al.*(2003)[6]은 회전기계인 압축기로부터 수집된 진동 신호의 웨이블릿 변환을 통해 특징을 추출하고, 인공신경망(ANN: Artificial Neural Network)을 이용해 압축기의 상태 진단 모형을 제안하였으며, Son *et al.*(2015)[7]은 압축기의 소음원을 규명하기 위한 실험을 통해 주요 인자 간의 관계를 파악하였다. Ko *et al.*(2018)[8]은 회전기계에서 발생하는 진동 신호에서 노이즈 성분을 제거하여 강건한 고장 진단 모델을 제시하였다. Verstraete *et al.*(2017)[9]도 진동 신호의 웨이블릿 변환을 거쳐 이미지화하여 회전기계의 상태를 정상/비정상 상태로 분류하기 위한 합성곱신경망(CNN; Convolutional Neural Network)을 제안하였으며, Yang *et al.*(2019)[10]은 Verstraete *et al.*(2017)[9]과 동일한 목적에서 별도의 전처리(Preprocessing) 과정을 거치지 않은 진동 신호를 입력 데이터로 활용하는 합성곱신경망을 제안하였다. Kim *et al.*(2021)[11]은 진동 신호의 시간 영역에서의 통계적, 물리적 특성치들을 이용하여 설비의 고장 여부를 진단하기 위한 서포트벡터머신(SVM; Support Vector Machine) 모형을 제안하였다.

예지정비에 대한 연구는 상태기반정비보다 진보된 개념이므로 비교적 최근에 이에 대한 많은 연구들이 수행되고 있다.

Benkedjough *et al.*(2015)[12]은 "PHM(Prognostics and Health Management) Society data challenge 2010"에서 사용된 데이터로 연구를 수행하였으며, 절삭용 공구의 잔여 유효 수명을 예측하기 위해 Expectation-Maximization Principle Component Analysis (EM-PCA)와 Iso-metric feature mapping (ISOMAP) 방법론을 이용하여 특성치를 추출하고, 서포트벡터회귀 모형을 제안하였다. 그 PHM 데이터[13]에는 CNC(Computerized Numeric Controller)의 절삭용 공구의 3축의 절삭력과 진동, 그리고 음향 신호와 같은 7종의 특성치를 포함하고 있다. Jain and Lad(2016)[14]도 PHM 데이터를 이용하였으며, 3축의 절삭력, 진동, 그리고 음향 신호의 평균, 표준편차 등의 통계적 특성치들을 이용하여 절삭 공구의 잔여 유효 수명을 예측하기 위한 인공신경망(ANN) 모형을 제안하였다. Wu *et al.*(2017)[15], Zhao *et al.*(2017)[16], 그리고 Kumar *et al.*(2019)[17]도 PHM 데이터를 이용하여 연구를 수행하였으며, Wu *et al.*(2017)[15]은 절삭용 공구의 마도 예측을 위해 랜덤포레스트(Random forest), 인공신경망, 서포트벡터회귀 모형들 간의 성능을 비교하였다. Zhao *et al.*(2017)[16]은 합성곱신경망 등 다양한 모형들과의 비교를 통해 가장 우수한 성능을 나타낸 Convolutional Bi-directional Long Short-Term Memory(CBLSTM) 네트워크 모형을 제안하였고, Kumar *et al.*(2019)[17]은 은닉마르코프모형(HMM; Hidden Markov Model)과 다항회귀모형(Polynomial regression model)을 제안하였다. Lee *et al.*(2019)[18]은 미시간 대학의 SMART(System-Level Manufacturing and Automation Research Testbed)에서 제공하는 3축 스피indle에 사용된 전력, 전류, 이송 속도 등 48종의 CNC 가공 실험 데이터를 기반으로, 서포트벡터머신, XGBoost(Extreme Gradient Boosting) 모형, 랜덤포레스트 모형을 이용하여 공구 마모도에 영향을 미치는 요인을 분석하였다.

본 연구는 수집된 진동 신호를 바탕으로 실시간으로 인서트의 잔여 유효 수명 예측을 수행하기 위해 시간 영역에서의 통계적, 물리적 특성치들을 활용하였다. 통계적 특성치로는 진동 신호의 절대 평균, 평균, 분산, 왜도(Skewness)와 첨도(Kurtosis)가 고려되었으며, 물리적 특성치로는 진동 신호의 Peak-to-Peak, 제곱평균제곱근(RMS; Root Mean Square), Impulse factor(IF)와 Shape factor(SF)가 고려되었다. 선행연구의 고찰을 통해 잔여 유효 수명을 예측하기 위한 후보 모형으로는 가중화 k -최근접이웃(Weighted k -NN; Weighted k -Nearest Neighbor) 알고리즘, 의사결정나무(Decision Tree) 모형, 서포트 벡터회귀, 앙상블 학습(Ensemble learning) 모형 중 XGBoost 모형, 랜덤포레스트 모형, 그리고 딥러닝 모형 중 1차원 합성곱신경망(1D-CNN; 1 Dimension Convolutional Neural Network) 모형으로 고려하였다.

본 연구의 2장에서는 공정환경 및 데이터 측정 과정을 소개하고, 인서트의 진동 신호에 대한 주파수 스펙트럼 분석 결과를 제시한다. 3장에서는 특성치 선정 및 데이터 전처리, 후보 모형 선정 및 모델링, 그리고 후보 모형들의 잔여 유효 수명 예측 성능의 평가 결과를 제시한다. 마지막으로, 4장에서는 결론 및 향

후 연구 방향을 제시한다.

II. 공정환경 및 데이터 측정

본 연구를 위해 그림 1의 현대 WIA SE2200L 공작기계에서 그림 2에서와 같은 모터하우징을 멀티툴로 가공하는 공정 중 인서트로 가공 시의 진동을 Digiducer사의 333D01 진동 센서를 사용하여 0.000125초단위로 X 축과 Y축의 진동 데이터를 수집하였다.



그림 1. 공작기계
Fig. 1. CNC machine.



그림 2. 가공된 제품
Fig. 2. Processed product.

그림 3과 그림 4에 교체 직후의 인서트와 교체 직전의 인서트로 가공 시의 진동 데이터 파형을 각각 나타내었다. 같은 공정을 진행하더라도 그림 3의 마모되지 않은 인서트의 진동 파형보다 그림 4에서의 교체 직전의 마모가 많이 된 인서트의 진동 파형의 형태가 전반적으로 다를 수 있다.




그림 3. 인서트 교체 직후의 진동 데이터 파형
Fig. 3. Vibration data waveform after Insert replacement.




그림 4. 인서트 교체 직전의 진동 데이터 파형
Fig. 4. Vibration data waveform before Insert replacement.

진동 데이터뿐만 아니라 이를 FFT한 주파수 스펙트럼에 대해서도 구하였다. 그림 5와 그림 6에 인서트 교체 직후의 주파수 스펙트럼과 인서트 교체 직전의 주파수 스펙트럼을 각각 나타내었다.




그림 5. 인서트 교체 직후의 주파수 스펙트럼
Fig. 5. Frequency spectrum after Insert replacement.




그림 6. 인서트 교체 직전의 진동 데이터 파형
Fig. 6. Frequency spectrum before Insert replacement.

그림 5와 그림 6에서 보면 새로이 교체된 인서트에 비해 교체 직전의 마모된 인서트의 주파수 스펙트럼의 크기가 약 750Hz 부근의 주파수 스펙트럼이 감소하는 오히려 감소하는 형태를 보이고 다른 주파수대에서는 뚜렷한 변화를 볼 수 없다.

총 32개의 인서트에 대한 결과에서도 모두 거의 비슷한 경향을 보였다. 그림 5와 그림 6에서의 주파수 스펙트럼으로는 인서트가 어느 정도 마모되었다는 것을 알 수 있지만 잔여 유효 수명의 정확한 예측에 대해서는 신빙성있는 기준을 제공하지 못한다는 것을 알 수 있다.

III. 잔여 유효 수명 예측 모형

3-1 특성치 선정 및 데이터 전처리

진동 신호를 바탕으로 기계 부품류 등의 상태를 예측하기 위해 활용되는 특성치들은 시간 영역과 주파수 영역에서 추출된다. 하지만, 본 연구는 기계 부품을 절삭 가공하고 있는 상황에서 실시간으로 인서트의 잔여 유효 수명을 예측하는 것을 목적으로 함에 따라 표 1에 제시된 시간 영역에서의 특성치들만을 활용하였으며[19]-[21], 각 특성치들은 잔여 수명 예측 단위인 1 초 단위 영역에서 산정된다. 진동 신호의 절대 평균, 평균, 분산,

왜도와 첨도와 같은 시간 영역에서의 통계적 특성치들은 부품의 절삭 가공, 즉, 인서트의 마모가 진행됨에 따라 진동 데이터의 확률밀도함수가 변화될 것이라는 연구가설을 바탕으로 선정되었다. 또한, 진동 신호의 Peak-to-Peak, 제곱평균제곱근, Impulse factor와 Shape factor와 같은 물리적 특성치들에서, Peak-to-Peak는 시간 독립적인 진동 신호의 Peak 크기를 나타내며, 진동 신호를 표현할 때 가장 빈번하게 활용된다. 진동 신호의 실효치를 나타내는 제곱평균제곱근은 에너지와 직접적으로 관련되며, 급격한 신호 변동에 대한 특성치로 활용되며, Impulse factor는 일반적으로 회전기계에서 충돌에 의한 진동과 관련된 특성치이다. 마지막으로, Shape factor는 회전기계에서 불균형에 의한 진동 신호의 특징을 대표하는 특성치이다[21].

데이터 전처리의 첫 번째 단계는 진동 신호의 수집 시간을 바탕으로 모형의 반응변수(Response variable)로 활용할 절삭용 인서트의 잔여 유효 수명을 지정하는 것이며, 총 수명 시간에서 사용 수명시간(Working lifetime)을 제외하는 변환을 수행하였다. 이때, 진동 신호가 수집되지 않은 결측치(Missing values)가 존재하는 인서트에 대해서는 결측치 구간을 고려하여 잔여 유효 수명을 변환하였다. 두 번째 단계에서는, 모형에서 설명변수(Explanatory variables)로 활용할 표 1에 제시된 특성치들에 대해 식 (1)과 같은 최대-최소 정규화(Min-Max normalization)를 수행하였다. 본래의 특성치들은 상이한 수치적 크기를 갖으며, 이는 예측 모형이 상대적으로 큰 크기를 갖는 특성치들에 편향되게 학습되거나 학습 과정의 수렴성이 저하되는 원인이 된다. 따라서 본 연구에서는 최대-최소 정규화를 적용하여 모든 특성치들이 [0, 1] 범위에서 정의되도록 변환하였다.

$$X_i^{New} = \frac{X_i - \text{Min}(X_i)}{\text{Max}(X_i) - \text{Min}(X_i)} \quad (1)$$

3-2 후보 모형 선정 및 모델링

본 연구에서는 표 1에 제시된 진동 신호의 통계적/물리적 특

성치를 바탕으로 절삭용 인서트의 잔여 유효 수명을 예측하기 위한 후보 모형(총 6개)으로 가중화 k-최근접이웃 알고리즘, 의사결정나무 모형, 서포트벡터회귀, 앙상블 학습 모형 중 XGBoost 모형, 랜덤포레스트 모형, 그리고 딥러닝 모형 중 1차원 합성곱신경망 모형을 선정하였다.

가중화 k-최근접이웃 알고리즘은 별도의 모형이 개발되지 않고 기존 데이터를 활용하는 사례 기반 학습 알고리즘이며, 새로운 데이터와 유사도가 가장 높은 k개의 기존 데이터를 이용하여 유사도에 대한 가중치(w_i)를 바탕으로 식 (2)와 같은 예측 결과(Y_{New})를 제공한다. 여기서, 유사도는 데이터 간의 거리($d_{(i,j)}$)와 반대적인 개념이다. 의사결정나무 모형은 의사결정 규칙을 나무 구조로 나타내어 전체 자료를 몇 개의 소집단으로 분류하거나 예측을 수행하며, 상위 노드로부터 하위노드로 나무 구조를 형성하는 때 분할 단계마다 분류변수와 분류변수의 기준값에 대한 선택이 중요하다. 이에 따라 각 분류변수와 기준값을 결정하기 위한 다양한 방법론이 개발되어 왔으며, 본 연구에서는 순열 테스트 기반 비편향 재귀 분할(Unbiased recursive partitioning based on permutation tests) 방법론을 적용하였다 [22]. 서포트벡터회귀 모형은 데이터의 분류에 사용되는 서포트벡터머신 ϵ -무감도 손실함수를 도입하여 임의의 실수 값을 예측하도록 일반화한 방법이다[23]. XGBoost 모형은 예측력이 약한 모델들의 학습 에러에 가중치를 두고 순차적으로 다음 학습 모델에 반영하여 강한 예측 모델을 만드는 앙상블 기법이며, 랜덤포레스트 모형은 의사결정 나무와 배깅(Bagging)을 혼합한 형태로서 여러 개의 의사결정나무를 형성한 후에 각 의사결정나무의 분류 결과를 종합하여 예측을 수행하는 앙상블 기법이다[24]. 일반적인 합성곱신경망 모형은 주로 이미지 데이터 분석에서 우수한 성능이 입증되어왔으나, 시계열 데이터(Time-series data), 텍스트 데이터와 같은 순차 데이터 분석에서는 1차원 합성곱신경망(1D-CNN)이 활용되고 있다[25]. 여기서, 1차원이라는 것은 합성곱(Convolution)을 위한 커널(Kernel)과 적용하는 데이터의 순서가 1차원의 모양을 가진다는 것을 의미한다.

표 1. 진동 신호에 대한 통계적/물리적 특성치
Table 1. Statistical and physical features of vibration signals.

Statistical features	Formula	Physical features	Formula
Absolute mean	$\frac{1}{N} \sum_{k=1}^N X_k $	Peak-to-Peak	$\text{Max}(X_k) - \text{Min}(X_k)$
Mean	$\frac{1}{N} \sum_{k=1}^N X_k$	Root Mean Square(RMS)	$\left(\frac{1}{N} \sum_{k=1}^N X_k^2 \right)^{1/2}$
Variance	$\frac{1}{N} \sum_{k=1}^N \left(\frac{X_k - \mu}{\sigma} \right)^2$	Impulse factor(IF)	$\frac{\text{Max}(X_k)}{\text{RMS}}$
Skewness	$\frac{1}{N} \sum_{k=1}^N \left(\frac{X_k - \mu}{\sigma} \right)^3$	Shape factor(SF)	$\frac{\text{RMS}}{\left(\frac{1}{N} \sum_{k=1}^N X_k \right)^{1/2}}$
Kurtosis	$\frac{1}{N} \sum_{k=1}^N \left(\frac{X_k - \mu}{\sigma} \right)^4$	-	-

$$Y_{New} = \frac{\sum_{i=1}^k w_i Y_i}{\sum_{i=1}^k w_i}, w_i = [d_{(New, X_i)}]^{-2} \quad (2)$$

기계학습 모델링에서 각 모형의 하이퍼 파라미터는 모형의 성능에 상당한 영향을 미치는 중요한 요소이다. 따라서 본 연구에서는 각 모형을 위한 최적의 하이퍼 파라미터들의 조합을 효율적으로 탐색하기 위해 격자 탐색법(Grid search method)과 무작위 탐색법(Random search method)을 상호보완적으로 활용하였다. 즉, 하이퍼 파라미터 탐색에 있어 격자 탐색법은 안정성은 우수하지만, 탐색 격자를 세분화할수록 계산시간이 증가하는 특성이 있으며, 무작위탐색법은 계산시간 측면에서는 격자 탐색법보다 유리할 수 있으나 탐색 결과에 대한 신뢰성이 부족하다. 따라서 본 연구는 격자 탐색법을 통해 넓은 영역에서 최적 하이퍼 파라미터 조합이 위치할 수 있는 격자를 탐색(전역 탐색)하고, 해당 격자 내에서는 무작위탐색법을 이용하여 보다 세부적으로 최적 하이퍼 파라미터 탐색(지역 탐색)을 시도하였다. 각 모형을 위해 탐색된 하이퍼 파라미터들은 표 2와 같다.

3-3 후보 모형들의 성능 평가

본 연구의 잔여 유효 수명(RUL)과 같은 연속형 변수를 예측하는 모형에 대한 성능 지표로는 실제값(y_i)과 예측값(\hat{y}_i) 간의 차이를 평가하는 평균절대오차, 평균제곱오차, 평균제곱근오차 등이 활용되며, 각 지표들은 식 (3)-(5)와 같이 정의된다. 따라서 각 지표들이 낮게 측정되는 모형이 우수한 모형으로 선정된다.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5)$$

각 후보 모형에 의한 절삭용 인서트의 잔여 유효 수명 예측 성능은 표 3과 같이 나타났다. 가장 우수하게 평가된 후보 모형은 가중화 k -최근접 이웃 알고리즘이었으며, 평균절대오차는 0.0013, 평균제곱오차는 0.004, 평균제곱근오차는 0.0192로 나타났다. 즉, 가중화 k -최근접 이웃 알고리즘에 의한 절삭용 인서트의 잔여 유효 수명 예측치의 평균적인 오차는 실제값 대비 0.001초 정도의 수준임을 의미한다. XGBoost 모형의 평균 오차는 1.1초 수준, 랜덤포레스트 모형의 평균 오차는 9.4초 수준, 그리고 1D-CNN 모형, 서포트벡터회귀 모형, 의사결정나무 모형의 평균 오차는 20초 이상으로 나타났다. 그림 7은 가장 우수하게 평가된 가중화 k -최근접 이웃 알고리즘으로 임의적으로 선택한 22번 인서트와 26번 인서트의 잔여 유효 수명을 예측한 결과를 예시적으로 보여주고 있다.

표 3. 후보 모형들의 하이퍼 파라미터


Table 3. Hyper-parameters for alternative models.

Model	MAE	MSE	RMSE
Weighted k-NN	0.0013	0.0004	0.0192
Decision tree	22.2093	661.7705	25.7249
SVR	21.6343	624.9136	24.9983
XGBoost	1.0630	2.4662	1.5704
Random Forest	9.3560	122.9570	11.0886
1D-CNN	20.1684	559.4313	23.6523


표 2. 후보 모형들의 하이퍼 파라미터

Table 2. Hyper-parameters for alternative models.

Model	Hyper-parameters
Weighted k -NN	• $k = 5$, Euclidean distance
Decision tree	• Unbiased recursive partitioning based on permutation tests
SVR	• Kernel function(Gaussian RBF) : $K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$, $\gamma = 1/9$ • $\epsilon = 0.96$, cost = 1
XGBoost	• Maximum number of iterations(N) = 300, • Step size of each boosting step(Learning rate, η) = 0.1, Gamma(γ) = 0, • Maximum depth of the tree(D_{max}) = 10, • Minimum sum of weights of all observations required in a child(O_{min}) : 2
Random Forest	• Number of trees to grow(G) = 800, • Number of variables randomly sampled as candidates at each split = $\sqrt{9} = 3$ [26]
1D-CNN	• Filter : 16, Kernel : 2, Maxpooling : 2, Dense layers : 2-layer, (32, 16) • Activation function : relu, Optimizer : adam, Early stop(30) : 788 epoch



(a) Insert #22



(a) Insert #26

그림 7. 인서트의 잔여 유효 수명 예측 예시
 Fig. 7. Examples of predicting the RUL of Inserts.

VI. 결 론

본 연구에서는 수집된 공작기계의 절삭용 인서트의 진동 신호 데이터를 이용하여 인서트의 잔여 유효 수명을 실시간으로 예측하기 위해 진동 데이터에 대한 시간 영역의 통계적, 물리적 특성치들을 이용하여 가중화 k -최근접이웃 알고리즘, 의사결정나무 모형, 서포트벡터회귀 등 6종을 모형에 대해 검토 하였다. 수집된 데이터를 바탕으로 한 후보 모형들에 대한 예측 성능 평가에서 가중화 k -최근접이웃 알고리즘이 평균절대오차는 0.0013, 평균제곱오차는 0.004, 평균제곱근오차는 0.0192로 가장 우수한 성능을 나타내었다. 이는 가중화 k -최근접이웃 알고리즘에 의해 예측되는 인서트의 잔여 유효 수명의 오차가 0.001 초 수준으로 평가된 것으로, 실제 산업현장에 적용이 가능한 수준으로 판단된다. 또한, 제안된 모형은 제품을 가공 중인 절삭용 인서트의 진동 패턴에 따라 잔여 유효 수명에 대한 실시간 예측을 통해 인서트 교환 시점에 대한 의사결정 정보를 제공하며, 이는 가공품의 불량률 감소와 가공 중 공구 파손 등에 의한 안전사고를 방지하는데 기여할 것으로 기대된다.

향후 연구 방향으로는, 본 연구에서는 절삭용 인서트의 진동 패턴에 대한 특성치 산정 단위를 잔여 유효 수명의 예측 단위인

1초로 부여하였지만, 초고속의 절삭가공 공정에 사용되는 공구에 있어서는 보다 짧은 시간 단위로 특성치를 산정하고, 잔여 유효 수명을 예측할 수 있어야 할 것으로 판단된다. 이에 따라 진동 외에도 음향, 절삭력 등 잔여 유효 수명에 대한 보다 다양한 특성치들을 식별하기 위한 연구가 필요할 것으로 사료된다. 뿐만아니라 정밀 가공품을 대상으로 절삭용 공구의 마모도에 따른 표면 거칠기 등 가공품의 품질 요소의 변화를 예측할 수 있는 모형에 대한 연구가 필요할 것으로 사료된다. 이러한 연구는 공구의 진동, 음향, 절삭력 등의 특성치를 바탕으로 공구 마모도를 예측하고, 예측된 마모도를 바탕으로 가공품의 품질 요소를 예측하는 형태가 될 수 있을 것이다. 이러한 기계학습 모형은 정밀 가공품 공정의 스마트화에 유용하게 활용될 수 있을 것이다.

Acknowledgments

이 논문은 2021~2022년도 창원대학교 자율연구과제 연구비 지원으로 수행된 연구 결과임.

References

- [1] Elvis Hozdic, "Smart Factory for Industry 4.0 : A review," *International Journal of Manufacturing Technologies*, Vol. 7, No. 1, pp. 28-35, 2015.
- [2] S.Wang, J.Wan, and C.Zhang, "Implementing Smart Factory of Industry 4.0: An Outlook," *International Journal of Distributed Sensor Networks*, Vol. 12, Iss: 1, pp. 1-40, 2016.
- [3] M. Pech, J.Vrcholta, and J. Bednar "Predictive Maintenance and Intelligent Sensor in Smart Factory:Review," *Sensors (Multidisciplinary Digital Publishing Institute)*, Vol. 21, Iss: 4, pp. 1-40, Feb. 2021.
- [4] W.G Ha, N.H Choi, *The 4th Industrial Revolution*, ETRI easy IT, 2016.
- [5] J.H. Yoon, M.J. Jung, and B.J. Ko, "Implementation of Monitoring System for Smart Factory," *Journal of Advanced Navigation Technology*, Vol. 22, No. 5, pp. 485-489, Oct. 2018.
- [6] D. S. Lim, B. S. Yang, B. H. An, A. Tan, and D. J. Kim, "Condition Classification for Small Reciprocating Compressors Using Wavelet Transform and Artificial Neural Network," *Journal of Power System Engineering*, Vol. 7, No. 2, pp. 29-35, 2003.
- [7] Y. B. Son, J. H. Ha, and J. W. Lee, "An experimental study on the noise source identification of rotary compressor," *Transactions of the Korean Society for Noise and Vibration*

- Engineering*, Vol. 25, No. 11, pp. 723-730, 2015.
- [8] J. U. Ko, J. H. Jung, M. Kim, H. B. Kong, and B. D. Youn, "Noise Robust Fault Diagnosis Technique to Simultaneously Learn Classification and Denoising," *Proceedings of The Korean Soc. of Mech. Eng. (KSME)*, pp. 165-167, 2018.
- [9] D. Verstraete, A. Ferrada, E. L. Droguett, V. Meruane, and M. Modarres, "Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings," *Shock and Vibration*, Vol. 2017, 2017.
- [10] H. B. Yang, J. A. Zhang, L. L. Chen, H. L. Zhang, and S. L. Liu, "Fault diagnosis of reciprocating compressor based on convolutional neural networks with multisource raw vibration signals," *Mathematical Problems in Engineering*, Vol. 2019, 2019.
- [11] S. I. Kim, Y. Noh, Y. J. Kang, S. Park, and B. Ahn, "Fault classification model based on time domain feature extraction of vibration data," *Journal of the Computational Structural Engineering Institute of Korea*, Vol. 34, No. 1, pp. 25-33, 2021.
- [12] T. Benkedjouh, K. Medjaher, N. Zerhouni, and S. Rechak, "Health assessment and life prediction of cutting tools based on support vector regression," *Journal of Intelligent Manufacturing*, Vol. 26, No. 2, pp. 213-223, 2015.
- [13] The Prognostics and Health Management Society, 2010 Conference Data Challenge, Accessed 18 October 2014. Available: <https://www.phmsociety.org/competition/phm/10>.
- [14] A.K. Jain, and B.K. LAD, "Data driven models for prognostics of high speed milling cutters," *International Journal of Performability Engineering*, Vol. 12, No. 1, pp. 3-11, 2016.
- [15] D. Wu, C. Jennings, J. Terpenney, R. X. Gao, and S. Kumara, "A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests," *Journal of Manufacturing Science and Engineering*, Vol. 139, No. 7, 2017.
- [16] R. Zhao, R. Yan, J. Wang, and K. Mao, "Learning to monitor machine health with convolutional bi-directional LSTM networks," *Sensors*, Vol. 17, No. 2, pp. 273, 2017.
- [17] A. Kumar, R. B. Chinnam, and F. Tseng, "An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools," *Computers & Industrial Engineering*, Vol. 128, pp. 1008-1014, 2019.
- [18] K. Lee, S. Park, S. Sung, and D. Park, "A Study on the Prediction of CNC Tool Wear Using Machine Learning Technique," *Journal of the Korea Convergence Society*, Vol. 10, No. 11, pp. 15-21, 2019.
- [19] Saxena, N. Chowdhury, and S. Devendiran, "Assessment of gearbox fault detection using vibration signal analysis and acoustic emission technique," *Journal of Mechanical and Civil Engineering*, Vol. 7, No. 4, pp. 52-60, 2013.
- [20] W. Caesarendra and T. Tjahjowidodo, "A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing," *Machines*, Vol. 5, No. 4, pp. 21, 2017.
- [21] S. I. Kim, Y. Noh, Y. J. Kang, S. Park, and B. Ahn, "Fault classification model based on time domain feature extraction of vibration data," *Journal of the Computational Structural Engineering Institute of Korea*, Vol. 34, No. 1, pp. 25-33, 2021.
- [22] T. Hothorn, K. Hornik, and A. Zeileis, "Unbiased recursive partitioning: A conditional inference framework," *Journal of Computational and Graphical statistics*, Vol. 15, No. 3, pp. 651-674, 2006.
- [23] J. Kim, S. Oh, and K. Seo, "Comparison of MLR and SVR Based Linear and Nonlinear Regressions - Compensation for Wind Speed Prediction," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 65, No. 5, pp. 851-856, 2016.
- [24] S. Seo and H. Kim, "Quality Prediction Model for Manufacturing Process of Free-Machining 303-series Stainless Steel Small Rolling Wire Rods," *Journal of Korean Society of Industrial and Systems Engineering*, Vol. 44, No. 4, pp. 12-22, 2021.
- [25] H. J. Lee, H. A. Kang, S. H. Lee, C. H. Lee, and S. B. Park, "Optimization of 1D CNN Model Factors for ECG Signal Classification," *Journal of The Korea Society of Computer and Information*, Vol. 26, No. 7, pp. 29-36, 2021.
- [26] R. Díaz-Uriarte, and S. A. De Andres, "Gene selection and classification of microarray data using random forest," *BMC bioinformatics*, Vol. 7, No. 1, pp. 1-13, 2006.



최원근 (Won Gun Choi)

2020년- 현재 : 창원대학교 전자공학과 대학원 석사과정
※관심분야 : smart factory



김흥섭 (Heungseob Kim)

2014.01월 - 2018.08월 : 공군사관학교 시스템공학과 조교수
2018.09월 - 현재 : 창원대학교 산업시스템공학과 부교수
※관심분야 : 머신러닝/딥러닝, 확률시스템 모델링, 시스템 최적화, 군사OR



고봉진 (Bong Jin Ko)

1994년 - 1996년 : 인하공업전문대학교 통신과 조교수
1996년 - 현재 : 창원대학교 전기전자제어공학부 교수
※관심분야 : Mobility & wireless sensing system