

# 마이크로 드릴비트 연마 시스템 연삭휠의 마모 진단 연구

김민섭\*, 허장욱\*,#

\*금오공과대학교 기계공학과(항공기계전자융합공학전공)

## A Study on the Wear Condition Diagnosis of Grinding Wheel in Micro Drill-bit Grinding System

Min-Seop Kim\* and Jang-Wook Hur\*,#

\*Department of Mechanical Engineering(Department of Aeronautics, Mechanical and Electronic Convergence Engineering), Kumoh National Institute of Technology

(Received 28 December 2021; received in revised form 26 January 2022; accepted 08 February 2022)

### ABSTRACT

In this study, to diagnose the grinding state of a micro drill bit, a sensor attachment location was selected through random vibration analysis of the grinding unit of the micro drill-bit grinding system. In addition, the vibration data generated during the drill bit grinding were collected from the grinding unit for the grinding wheels under the steady and worn conditions, and data feature extraction and dimension reduction were performed. The wear of the micro-drill-bit grinding wheel was diagnosed by applying KNN, a machine-learning algorithm. The classification model showed excellent performance, with an accuracy of 99.2%. The precision, recall and f1-score were higher than 99% in both the steady and wear conditions.

**Keywords** : Micro Drillbit Grinding System(드릴비트 연마 시스템), Machine Learning(머신러닝), Grinding Wheel(연삭휠), Wear Diagnostics(마모 진단)

### 1. 서 론

최근 IT 산업기술이 발달함에 따라 전기·전자부품에서 핵심적인 역할을 하는 PCB의 제조공정은 고정밀화되어가고 있으며, PCB의 내외층간 전기접속을 위해서는 드릴 홀이 필요한데, 특히, 정확한 깊이와 균일한 직경을 가지는 홀의 형성은 PCB 생산에서 매우 중요한 공정이다<sup>[1]</sup>. 또한, PCB 적층수의 증가로 두께가 증대되고 있으며, 홀 크기의 미세화로 인해 가공에 적용되는 드릴비트의 직경이 점차 소형화

됨으로써, 드릴비트가 조기에 마모되고 있는 실정이다<sup>[2]</sup>.

일반적으로 PCB 가공에 사용되어 마모된 드릴비트는 연마하여 재사용되며, 직경  $\geq 0.2\text{mm}$  이상의 드릴비트는 수작업장비 또는 해외업체에서 제작된 자동화 장비를 이용해 연마가 가능하였다. 그러나, 직경이  $0.075 \sim 0.15\text{mm}$ 의 마이크로 드릴비트의 경우에는 연마가 불가능하여 대부분 폐기하였다<sup>[3]</sup>.

최근 국내 업체에서 마이크로 드릴비트를 연마하여 폐기율을 축소시키는 마이크로 드릴비트 연마 인라인 시스템을 개발하였으며, 이는 연마, 검사 및 재설치와 같은 모든 연마 공정이 자동으로 구동되는 시스템이다.

하지만, 마이크로 드릴비트 연마 시스템의 연마

# Corresponding Author : hhjw88@kumoh.ac.kr

Tel: +82-54-478-7399

유닛은 다이아몬드 연삭휠을 장착하여 연마를 진행하는데, 연마 가공을 반복적으로 장시간 진행하게 되면 눈꺼움 현상으로 인해 연삭휠에 마모가 발생하며, 이에 따라 적절한 시기에 교체하지 않으면 연마과정에서 상당수의 불량품이 발생하게 된다.

이러한 문제로부터 연삭 가공시 발생하는 진동 등의 신호를 활용하여 주파수 특성 분석과 머신러닝 모델을 통해 연삭휠의 상태 진단 및 수명 예측을 위한 다양한 연구가 수행되고 있으나<sup>4,6</sup>, 데이터 수집 과정에서 센서 위치 선정에 대한 근거가 명확히 제시되지 않고 있으며, 특히, 진동 신호의 경우에 측정 위치는 주파수 분석과 머신러닝 수행에 있어서 중요한 변수로 작용하므로 공학적 근거에 의해 센서 위치를 선정하는 과정이 필요하다.

따라서, 본 연구에서는 마이크로 드릴비트의 연마 상태를 진단하기 위해 연마 시스템의 연마유닛을 대상으로 랜덤진동 해석을 통해 최적의 센서 부착 위치를 선정하였으며, 드릴비트 연마시 발생하는 진동 데이터를 정상상태의 연삭휠과 마모된 연삭휠에 대해서 각각 수집하여 데이터 특징 추출 및 차원축소를 수행하고, 머신러닝 알고리즘인 KNN을 적용하여 마이크로 드릴비트 연삭휠의 마모를 진단하였다.

## 2. 실험장치 및 방법

### 2.1 실험장치

마이크로 드릴비트 연마 시스템의 각부 명칭 및 주요 형상을 Fig. 1에 나타내었으며, 시스템 중앙에서 반시계방향으로 회전하는 인덱스 로봇에 의해 로더유닛, 연마유닛, 검사유닛 및 취출유닛의 순서로 주요 공정을 거치게 된다.

먼저, 로더유닛은 트레이에 적재되어있는 드릴비트를 인덱스 로봇으로 전달하여 고정하는 역할을 하며, 드릴비트가 고정된 인덱스 로봇은 반시계방향으로 회전하여 연마유닛으로 진행하게 되고, 연마 작업을 수행한다. 또한, 다음 공정인 검사유닛에 장착된 비전검사 장치에서 연마된 드릴비트의 품질검사를 통해 불량을 판별하게 되며, 판별 결과에 따라 취출유닛에서 정상품과 비정상품으로 구분되어 적재함으로써 최종 가공이 완료된다<sup>7</sup>.




Fig. 1 Drillbit re-grinding system



(a) before

(b) after

Fig. 2 Comparison before and after drill bit grinding

### 2.2 실험대상

장시간 마이크로 드릴비트의 사용으로 마모된 사진과 이를 연마하여 재사용이 가능하게 된 사진을 Fig. 2에 나타내었다.

마이크로 드릴비트의 마모 진단 실험에 사용된 연마유닛은 Fig. 3과 같이 드릴비트를 연마하는 가공공정부의 핵심유닛으로써, 드릴비트가 가지는 연삭휠 날부의 형상에 가공이 용이하게 진행될 수 있도록 개발되었다. 또한, 고속으로 회전하여 절삭부하를 낮추고, 회전시 진동이 작아서 우수한 가공면을 얻을 수 있는 고주파 스피들에 연삭휠을 장착하여 드릴비트를 연마하는 장치이며, 스피들의 사양은 Table 1에 나타낸 바와 같다.





Fig. 3 Grinding unit in drillbit re-grinding system

Table 1 High frequency spindle specification

Parameter	Specification
Voltage	220V
Power	0.5kW
Maximum RPM	20,000rpm
Cooling Method	Air Cooling




(a) healthy (b) faulty

Fig. 4 Grinding wheel in different conditions


### 2.3 데이터 수집

연삭휠의 상태별 진동데이터를 수집하기 위해 실험에 사용된 정상상태와 최대 마모상태의 연삭휠을 Fig. 4에 나타내었다.

먼저, 진동데이터 수집을 위해서는 진동 센서를 부착해야 하는데, 연마유닛은 고주파 스피들에 의해 마이크로 단위의 드릴비트를 연마하는 시스템으로 드릴비트 연마시 진동은 매우 작은 진폭으로 발생한다. 그러나, 진동데이터를 머신러닝 모델에 적용



(a) grinding unit



(b) frame

Fig. 5 Deformation results of vibration analysis

하는 데 있어서 비교적 진폭이 큰 데이터를 사용하는 것이 모델의 분류 성능에 보다 우수한 결과를 가져오기 때문에 진폭이 가장 크게 나타나는 위치에 진동 센서를 부착해야 한다.

최적의 센서 위치를 선정하기 위해서 연마유닛에 대해서 랜덤진동 해석을 수행하였으며, 해석 결과를 Fig. 5에 나타내었다. 연삭휠 및 프레임 상부 중앙에서 진폭이 가장 크게 나타나지만, 센서 부착이 가능한 프레임만을 고려하여 상부 중앙을 최적의 위치로 선정하였다. 이에 따라 진동 센서를 프레임의 상부 중앙에 Fig. 6과 같이 부착하여 데이터를 수집하였으며, 데이터 수집 과정을 도식적으로 Fig. 7에 나타내었다. 연마유닛의 프레임에 부착된 진동 센서를 통해 연삭휠의 상태별로 드릴비트 연마시 발생하는 진동데이터를 NI 진동모듈 및 DAQ를 이용하여 PC로 수집하였다.




Fig. 6 Sensor installation for data collection

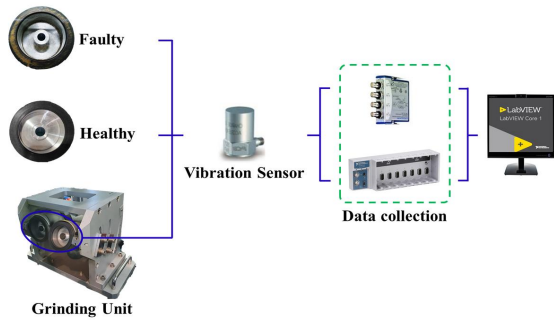


Fig. 7 Conceptual diagram of big data collection system

### 3. 연삭휠 마모 진단

#### 3.1 데이터 처리 및 특징 추출

마이크로 드릴비트 연삭휠의 마모를 진단하기 위해 정상상태와 마모상태에 대해서 진동 센서로부터 각각 1,400,000개의 데이터를 수집하였다.

하지만, Fig. 8에 나타나 있듯이 시간 영역의 데이터만으로 상태를 구분하는 것은 쉽지 않기 때문에 판단의 근거가 되는 데이터의 통계적 특징들을 머신러닝 모델에 학습이 가능하도록 특징 추출 과정을 거쳐야 한다<sup>[8]</sup>.

이를 위해 획득된 진동데이터를 1,000개씩 구간을 나누어 총 1,400개의 데이터셋(1000, 1400)으로 변형하고, Table 2에 나타난 12개의 통계적 특징을

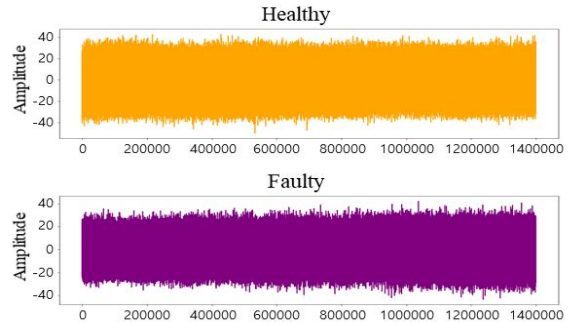


Fig. 8 Vibration signal of grinding unit



Fig. 9 Correlation analysis between features

추출하였다. 또한, 추출된 특징들에 대해서 Fig. 9에 나타난 바와 같이 상관관계 분석을 수행하였으며, 각 특징들 간의 유사도가 높을수록 +1에 가까운 값을 산출하도록 설정하였다.

#### 3.2 데이터 차원 축소

특징 추출을 통해 형성된 데이터는 고차원을 형성하고 있으며, 머신러닝을 수행하기 위해서는 저차원 데이터로 차원축소가 필요하다<sup>[9]</sup>. 또한, 차원 축소 기법이 분류 성능에 큰 영향을 미치기 때문에 최적의 차원 축소 기법 선정이 필요하다. 따라서, PCA(Principal Component Analysis), LLE(Locally Linear Embedding), t-SNE(t-Stochastic Neighbor Embedding) 및 Isomap(Isometric Mapping)의 4가지 기법을 사용하여 차원축소를 수행하였다. 여기서, PCA는 고차원 데이터의 분산이 최대가 되는 축을 찾아 선형 연관성이 적은 저차원으

**Table 2 Statistical feature**

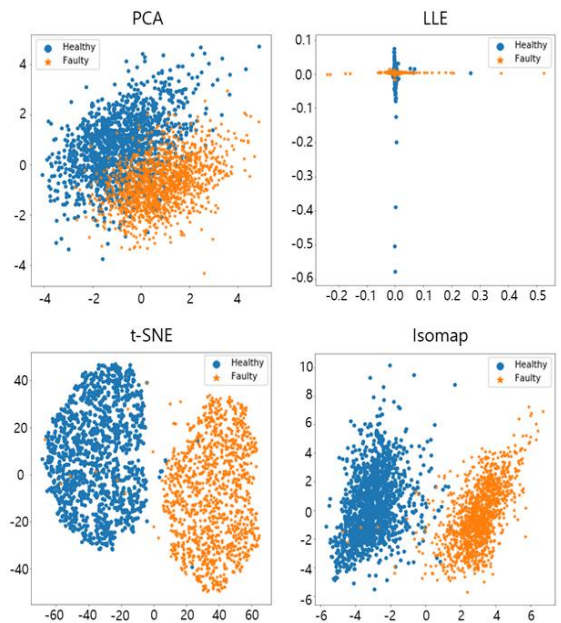
Statistical Feature	Formula	Statistical Feature	Formula
Mean	$\bar{x} = \frac{1}{n} \left( \sum_{i=1}^n x_i \right)$	Standard Error of the Mean	$SE_{\bar{x}} = \frac{s}{\sqrt{n}}$
Root Mean Square	$x_{rms} = \sqrt{\frac{\sum_{i=1}^n (x_i)^2}{n}}$	GSTD	$\sigma_g = \exp\left(\sqrt{\frac{\sum_{i=1}^n (\ln \frac{A_i}{\mu_g})^2}{n}}\right)$
Standard Deviation	$v = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$	Kurtosis	$x_{kurt} = \frac{1}{n} \sum \left( \frac{(x_i - \mu)^3}{\sigma} \right)$
Variance	$x_{var} = E((X - \mu)^2)$	Skewness	$x_{skew} = E\left(\frac{(x_i - \mu)^3}{\sigma}\right)$
Max	$x_{max} = \max(x_i)$	Crest Factor	$x_{CF} = \frac{x_{max}}{x_{rms}}$
Min	$x_{min} = \min(x_i)$	IQR	$IQR = Q_3 - Q_1$

로 변환하며<sup>[10]</sup>, LLE는 서로 인접한 데이터들을 보존하면서 고차원인 데이터셋을 저차원으로 축소하는 방법이고<sup>[11]</sup>, t-SNE는 PCA의 단점을 보완하기 위해 고안된 방법으로 고차원 공간에서 데이터의 벡터가 2차원 공간에서도 유사하도록 데이터간의 특성을 보존하면서 차원을 축소한다<sup>[12]</sup>. 또한, Isomap은 PCA와 MDS (Multidimensional Scaling)의 특징을 결합하여 모든 점 사이의 측지선 거리를 유지하는 더 낮은 차원으로 임베딩하는 기법이다<sup>[13]</sup>.

이러한 4가지 방법을 사용하여 Fig. 10과 같이 차원축소를 수행하였다. 그림에서 경계가 불분명한 PCA 및 LLE를 제외하고, t-SNE와 Isomap을 비교하였을 때, t-SNE가 보다 경계가 분명하게 나타나는 우수한 결과를 가져왔으므로 t-SNE를 연삭질 상태 진단을 위한 최적의 차원축소 기법으로 선정하였다.

### 3.3 KNN 알고리즘

t-SNE를 통해 차원축소된 데이터를 분류하기 위한 알고리즘으로 KNN(K-Nearest Neighbor)을 선정하였다. KNN 알고리즘은 k개의 최근접 이웃을 사용한 분류 기법이며, 데이터로부터 거리가 가까운 k개의 다른 데이터의 레이블을 참조하여 분류하는 알고리즘이고, 식 (1)에 나타난 유클리드 거리 계산법을 사용하여 거리를 측정한다.



**Fig. 10 Technique performed for dimension reduction**

$$D(\underline{x}, \underline{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

여기서,  $\underline{x} = (x_1, \dots, x_p)$ ,  $\underline{y} = (y_1, \dots, y_p)$ 는 공간상의 두 점이며,  $p$ 는 차원을 의미한다<sup>[14]</sup>.

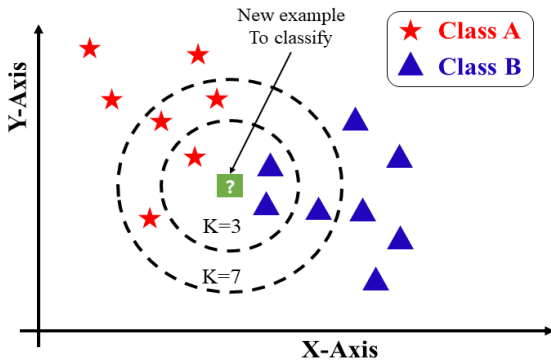


Fig. 11 Principle of KNN algorithm

KNN 알고리즘은 Fig. 11에 나타난 예시와 같이 새로운 미지의 데이터에 대해서 k를 3으로 설정한 경우, 설정된 거리 내에서 Class B의 데이터가 Class A와 비교하여 많은 수를 차지함에 따라 Class B로 분류하지만, k를 7로 설정한 경우에는 Class A로 분류하는 원리이다. 따라서, KNN 알고리즘을 활용함에 있어서 같은 데이터라도 k의 설정값에 따라 다른 값으로 분류하기 때문에 적절한 k값을 지정해주는 것이 중요하다<sup>[5]</sup>.

분류 모델의 성능평가는 식 (2)~(5)에 나타난 파라미터에 의해 수행되며, 이러한 파라미터는 Fig. 12에 나타난 바와 같이 TP, FP, TN, FN 값을 통해 계산된다. 여기서 TP는 True Positive로 실제 True인 정답을 분류 모델이 True라고 잘 예측한 것이며, FP는 False Positive로 실제 False인 정답을 True라고 잘못 예측한 것이고, TN은 True Negative로 실제 False인 정답을 False라고 잘 예측한 것이다. 그리고 FN은 False Negative로 실제 True인 정답을 분류 모델이 False라고 잘못 예측한 것을 의미한다.

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

		True Label	
		True	False
Predicted Label	True	True Positive(TP)	False Positive(FP)
	False	False Negative(FN)	True Negative(TN)

Fig. 12 Example of performance evaluation indicator

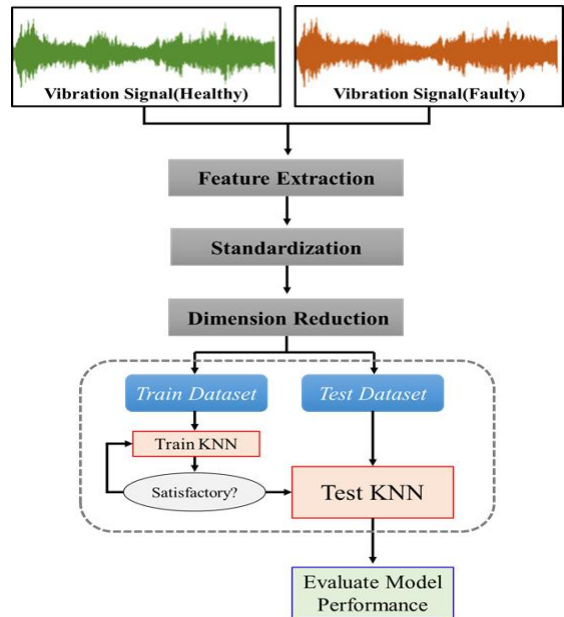


Fig. 13 Framework of proposed condition diagnosis

## 4. 결과 및 고찰

연삭휠 마모 진단을 위한 프레임워크를 Fig. 13에 나타내었다. 연마유닛으로부터 연삭휠의 상태별로 진동데이터를 수집하였으며, 12가지 통계적 특징에 대해서 특징 추출을 수행하였다. 또한, 추출된 특징 데이터에 대해서 표준화 작업 및 t-SNE 기법을 사용한 차원축소를 수행하였으며, KNN 알고리즘을 적용한 분류 모델에 대해서 최종적으로 정확도 측정과 성능평가를 진행하였다.

KNN 알고리즘을 통한 머신러닝을 위해서는 최적의 k값을 선정하는 것이 분류 모델의 성능을 좌우하며, 최적의 k값 선정을 위해 Fig. 14에 k값에




Fig. 14 Calculating the optimal k value for KNN




Fig. 15 KNN decision boundary of test data

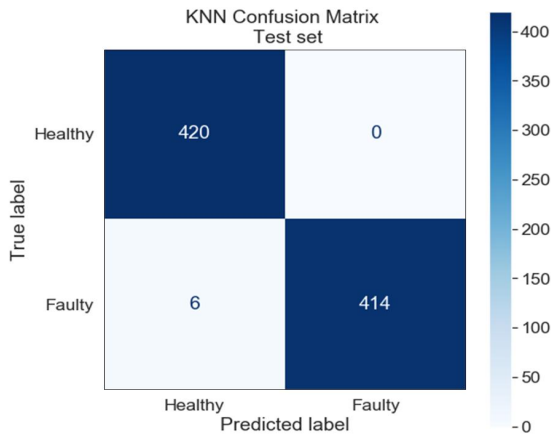


Fig. 16 Confusion matrix of KNN(test set)

따른 KNN 모델의 분류 정확도를 나타내었다. 이에 따라, KNN 분류 모델 생성을 위해 k=2로 설정 하였으며, 총 2,800개의 데이터 중 1,960개(70%)를 분류 모델의 학습에 사용하고, 840개(30%)의 데이터를 학습된 모델의 시험에 사용하였다. 학습된 KNN

Table 3 Classification performance

Type	Accuracy	Precision	Recall	F1-score
Healthy	0.992	0.99	1.00	0.99
Faulty		1.00	0.99	0.99

분류 모델의 시험 결과는 Fig. 15와 같으며, 이에 따른 혼동행렬(confusion matrix)을 Fig. 16에 나타내었다. 연삭질이 정상상태의 경우, 420개의 정상상태 데이터 중 420개(100%)를 정상상태로 완벽하게 분류하였다. 그러나, 마모상태의 경우에는 420개의 마모상태 데이터 중 414개(98%)를 마모상태로 분류 하였으나, 6개(2%)는 정상상태로 잘못 분류하였다.

KNN 알고리즘을 이용한 모델의 분류성능 평가를 수행한 결과를 Table 3에 나타내었다. 정확도 (accuracy)는 전체 데이터 중에서 True는 True로 False는 False로 잘 예측했는지에 대한 지표이고, 정밀도(precision)는 모델이 True로 예측한 값 중 실제 True인 것의 비율이며, 재현율(recall)은 실제 True인 것 중 모델이 True로 예측한 비율이다. 그리고 F1 점수(f1-score)는 정밀도와 재현율의 조화 평균이다.

분류 성능평가에 따르면 정확도는 99.2%가 산출 되었으며, 정상상태와 마모상태 모두 F1 점수가 99%의 결과를 나타낸다. 그러나 정밀도는 정상상태 에서 99%인 반면에 마모상태에서는 100%의 결과를 확인할 수 있으며, 재현율은 정상상태에서 100%의 결과를 나타내지만, 마모상태에서는 99%의 결과를 산출하였다.

## 5. 결론

마이크로 드릴비트 연마 시스템의 연마유닛으로부터 획득한 진동데이터를 통해 통계적 특징을 추출하고, t-SNE 기법을 사용하여 차원축소를 수행하였으며, KNN 분류 모델을 통한 연삭질 마모 진단의 효율성을 평가하였다. 얻어진 결과를 요약하면 다음과 같다.

1. 연마유닛의 진동데이터를 획득하여 KNN 기반으로 연삭질의 마모상태를 진단할 수 있다.
2. 최적의 센서 위치 선정을 위해 연마유닛에 대해서 랜덤진동 해석을 수행하였으며, 결과는 프레

임 상부 증상으로 나타났다.

3. 마이크로 드릴비트 연마 시스템의 연삭휠 마모 진단을 위한 차원축소 기법으로 t-SNE가 PCA, LLE 및 Isomap보다 적합하다.
4. 분류 모델은 정확도가 99.2%로 매우 우수한 성능을 나타내며, 정밀도, 재현율 및 F1 점수는 정상상태 및 마모상태 모두에서 99% 이상으로 높게 나타났다.

## 후 기

본 연구는 중소기업청(중소벤처기업부)의 맞춤형 기술파트너 지원사업의 연구결과로 수행되었음 (G21S312033701).

## REFERENCE

1. Choi, H. G., "A Study on Micro Drill-Bit Measurement Using Images", Journal of the Korea Institute of Convergence Signal Processing, Vol. 16, No. 3, pp. 90-95, 2015.
2. Park, D. H., Choi, S. D. and Jo, Y. J., "Processing Technology for Regrinding the Micro Drillbit," Proceedings of the Korean Society of Precision Engineering Conference, pp. 873-874, 2013.
3. Kuk, Y. H. and Choi, H. J., "Analysis of Fluid-Structure Interaction of Cleaning System of Micro Drill Bits", Journal of the Korean Society of Manufacturing Process Engineers, Vol. 15, No. 1, pp. 8-13, 2016.
4. Rameshkumar, K., Mouli, D. S. B. and Shivith, K., "Machine Learning Models for Predicting Grinding Wheel Conditions Using Acoustic Emission Features", SAE International Journal of Materials & Manufacturing, Vol. 14, No. 4, pp. 387-406, 2021.
5. Thomazella, R., Lopes, W., Aguiar, P., Alexandre, F., Fiocchi, A. and Bianchi, E., "Digital Signal Processing for Self-vibration Monitoring in Grinding: A New Approach based on the Time-frequency Analysis of Vibration Signals", Journal of Measurement, Vol. 145, pp. 71-83, 2019.
6. Hassui, A., Diniz, A., Oliveira, J., Felipe, J., Gomes, J., "Experimental Evaluation on Grinding Wheel Wear through Vibration and Acoustic Emission", Journal of Wear, Vol. 217, No. 1, pp. 7-14, 1998.
7. Choi, H. J., Jang, E. S., Kuk, Y. H. and Park, J. H., "Dynamic Analysis of the Index Robot used in the Drill bit Grinding Equipment", Proceedings of the KSMPE Conference, pp. 125-125, 2015.
8. Kim, S. I., Noh, Y. J., Kang, Y. J., Park, S. H. and Ahn, B. H., "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.
9. Ahn, M. G., Kim, J. K. and Kwon, C. H., "Machine Learning Based Dimension Reduction Technique for Efficient Surveillance Reconnaissance of UAV", Proceedings of Symposium of the Korean Institute of Communications and Information Sciences, pp. 748-749, 2019.
10. Jang, J. and Park, J. W., "Stabilization Determination Method of Laser Tracker Target Using Principal Component Analysis", Spring and Autumn Conference of the Korean Society of Mechanical Engineers, pp. 103-104, 2021.
11. Roweis, S. T. and Saul, L. K., "Nonlinear Dimensionality Reduction by Locally Linear Embedding", Journal of Science, Vol. 290, No. 22, pp. 2323-2326, 2000.
12. Song, W., Wang, L., Liu, P., "Improved T-SNE Based Manifold Dimensional Reduction for Remote Sensing Data Processing", Journal of Multimedia Tools and Applications, Vol. 78, pp. 4311-4326, 2019.
13. Kim, J. S. and Youn, J. S. "Data Visualization using Linear and Non-linear Dimensionality Reduction Methods", Journal of the Korea Society of Computer and Information, Vol. 23, No. 12, pp. 21-26, 2018.
14. Lee, H. S., Kim, E. T. and Kim, D. Y., "Pattern Recognition System Combining KNN rules and New



Feature Weighting algorithm”, Journal of the Institute of Electronics Engineers of Korea - Computer and Information, Vol. 42, No. 4, pp. 43-50, 2005.

15. Aung, S. S., Nagayama, I and Tamaki, S., “Dual-kNN for a Pattern Classification Approach”, Journal of IEIE Transactions on Smart Processing & Computing, Vol. 6, No. 5, pp. 326-333, 2017.