



# 난삭재 절삭공정 시 인공지능 기반 실시간 공구 상태 판단을 위한 예측 시스템 설계 및 구현

김미루<sup>a,\*</sup>, 이훈희<sup>a</sup>, 박민석<sup>a</sup>, 윤왕호<sup>a</sup>

## Design and Development of a Real-Time AI-Based Tool Failure Prediction System for Machining Difficult-to-Cut Materials

Mi-Ru Kim<sup>a,\*</sup>, Hoon-Hee Lee<sup>a</sup>, Min-Suk Park<sup>a</sup>, Wang-Ho Yun<sup>a</sup>

<sup>a</sup> Dongnam Technology Application Division, Korea Institute of Industrial Technology

### ARTICLE INFO

#### Article history:

Received	24	April	2025
Revised	28	May	2025
Accepted	10	June	2025

#### Keywords:

Artificial intelligence  
Cutting process  
Tool failure detection  
Real time  
Difficult to cut materials

### ABSTRACT

Cutting processes are essential in manufacturing metal components, particularly in aerospace applications. For difficult-to-cut materials such as titanium alloys, tool condition significantly impacts machining quality, making real-time failure prediction critical. While many studies have applied artificial intelligence (AI) to analyze sensor data for predictive maintenance, real-time AI implementation during cutting remains limited. This study presents a real-time tool failure detection system capable of executing an AI model during machining. Titanium alloy was machined using an end mill, and an acceleration sensor was mounted on the machine tool for condition monitoring. Data acquisition, preprocessing, and transmission to the AI model were handled via LabVIEW. The AI model classified the tool condition into four states and was integrated with the monitoring system through TCP/IP communication for real-time prediction. The system was validated through cutting experiments, demonstrating its effectiveness for real-time tool condition monitoring in high-performance machining environments.

## 1. 서론

항공우주, 방산 등 분야에는 다양한 금속 부품들이 존재하며, 주요 연결부위나 극한 환경에서 사용되는 부품의 경우 성능과 수명을 위하여 난삭재가 사용되는 경우가 많다<sup>[1,2]</sup>. 다양한 난삭재 중 티타늄, 인코넬 등의 금속 부품 가공에는 절삭공정을 많이 적용하고 있으며 해당 소재의 가공에는 고온에서 강도가 우수하고 낮은 열 전도성으로 인해 가공이 어렵고 공구 수명이 짧아 공정관리가 필요하다<sup>[3-5]</sup>. 특히 절삭공구 상태에 따라 가공 품질이 달라지고,

공구 교체 시점을 정하게 되므로 공구의 상태를 예측하고 분석하는 것은 중요한 문제이다. 최근 수년간 스마트 팩토리, IoT, 인공지능(AI) 등이 주목을 받아왔으며 이러한 공정 지능화 기술개발을 위하여 센서 데이터를 기반으로 절삭공정 상태 분석, 공구 수명 예측, 모니터링 기술, 머신러닝을 활용한 예지보전 등 많은 연구가 이루어지고 있다<sup>[6-11]</sup>. 이 중 몇 가지 연구 사례를 살펴보면, Mohanraj의 연구에서는 인코넬 소재의 엔드밀 공정에서 절삭공구 상태 모니터링을 위해 진동 신호에서 웨이블릿 특징과 Hoelder's exponent(HE)를 추출하고 머신러닝 알고리즘을 적용하였다.

\* Corresponding author. Tel.: +82-55-924-0122

E-mail address: mrkim@kitech.re.kr (Mi-Ru Kim).

SVM, MLP, 결정 트리 등의 알고리즘을 통해 예측 모델을 개발하였으며 높은 공정 상태 예측 정확도를 달성하였다<sup>[8]</sup>. 또한 Liu의 연구는 절삭 공구의 상태를 모니터링하고 공구 마모를 예측하기 위해 음향 신호를 기반으로 하는 시스템을 개발하였다. 웨이블릿 패킷 분해를 통해 시간-주파수 통계 특징을 추출하고, 특징들을 회귀 분석 및 인공신경망 모델에 적용하여 공구 마모 정도를 예측하였다. 이 방법은 다양한 절삭 조건에서도 높은 예측 정확도를 유지하며, 기존의 RMS 값보다 더 나은 성능을 가진다고 보고하였다<sup>[9]</sup>. Chen의 연구는 가변 절삭 조건에서 밀링 채터 모니터링을 위해 시계열 특징을 기반으로 한 방법을 제안하였다. Recurrence plot(RP)과 Quantitative analysis(RQA)를 사용하여 절삭력 신호에서 통계적 특징을 추출하고, LGB 모델을 통해 채터 상태를 예측하였다. 분석 결과 다양한 절삭 조건에서도 채터 상태를 효과적으로 판단할 수 있음을 보여주었다<sup>[11]</sup>. 위 사례들은 가공을 통해 얻은 데이터를 활용하여 사후 공정분석 및 사전 예측에 적용하는 연구와 정확도가 높은 인공지능(AI) 모델을 개발하는 연구들이며, 많이 연구자료를 많이 찾아볼 수 있었으나 AI 모델을 실시간으로 적용하지는 않고 있다. 제조공정에서 AI 예측을 실시간으로 적용하는 연구로는, Kim의 연구에 따르면 프레스 공정에서 제품 불량을 탐지하기 위하여 CNN 알고리즘을 활용한 실시간 상태 예측 시스템을 구현한 사례가 있다<sup>[12]</sup>. Terrazas의 연구에서는 절삭공정에서 공구동력계를 활용하여 CNN으로 공구 상태나 수명을 DB에 저장하면서 준 실시간으로 모니터링 하는 연구가 있다. 공구 마모에 따라 상태를 분류하는 CNN 모델은 오프라인 테스트에서 78%의 정확도를 보였으며, 실시간 검증에서도 유사한 성능을 확인하였다<sup>[13]</sup>. 위와 같이 기존 연구들은 제조공정에서 여러 가지 모니터링, AI를 활용한 연구들이 많지만, 실시간이 아닌 사전 예측과 FFT 및 웨이블릿 분석, 이미지 분석을 적용한 연구들이 대부분이며 시계열의 데이터 분석으로 AI 모델을 실시간으로 적용하여 절삭공정 중 공구 상태를 예측하는 연구 사례는 상대적으로 미흡하다. 실제 가공 현장에서는 작업자에게 사전 예측된 결과를 제공하는 것보다는 작업자가 가공 도중 공정과 공구의 상태를 실시간으로 확인할 수 있는 환경이 더 적합하며, 실시간으로 공구 상태를 가시적으로 판단할 수 있는 예측 시스템 개발이 필요하다. 따라서 본 논문에서는 절삭가공 중에 공구의 상태를 판단할 수 있도록 실시간 AI 모델 구동이 가능한 공구상태 예측 시스템을 제안하였다. 우선 공정 데이터 취득 및 분석, AI 모델 생성을 위해 엔드밀 공구를 활용한 티타늄 합금의 가공을 진행하였으며, 가공장비에 가속도 센서를 부착하여 모니터링 시스템을 구성하였다. 모니터링 시스템에서 데이터 취득과 전처리, AI 모델로 데이터 전송을 위하여 Labview SW를 활용하였다. 머신러닝 모델은 Tensorflow 기반으로 공구 상태를 예측하는 모델 생성하였다. 공정 상태 예측은 공구

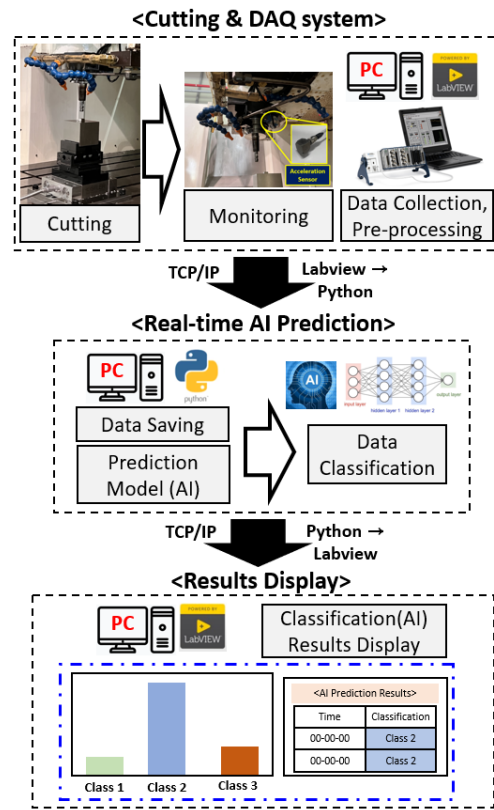


Fig. 1 Schematic of the real-time tool failure prediction system based on AI in the cutting process

의 마모 상태에 따라 공회전(air-cut), 안정(steady), 마모 진행(normal), 마모 파손(severe) 4가지 상태로 분류가 되도록 하였다. 또한 실시간 구현을 위해 AI 모델을 모니터링 SW와 AI 모델간 TCP/IP 통신으로 전처리 데이터를 전달하고, 예측 결과를 반환하는 구조로 실시간 예측이 가능하도록 하였다. 해당 실시간 공구 상태 예측 시스템을 구성 후 가공 실험에 적용하여 동작을 확인하였으며, 실시간 공구상태 판단의 실용성을 확인하였다.

## 2. 시스템 설계 및 가공 데이터 획득

### 2.1 시스템 구성

Fig. 1은 절삭가공 중 공정 데이터 분석을 통한 AI 예측으로 공구의 상태를 판단할 수 있는 모델이 포함된 실시간 공구 상태 예측 시스템의 구성도이다. 제안한 시스템은 Data Acquisition(DAQ) 장치 및 PC H/W와 데이터 수집 및 전처리 과정(Labview), AI 예측 분류 과정(Python), 시각화 과정(Labview)으로 구동하는 SW로 구성된다. 데이터 수집 프로세스는 가공 시 발생하는 데이터를 DAQ 장치에서 수집하고 전처리하여 일정한 주기로 데이터를 AI 모델로 TCP/IP 통신을 통해 전달한다. 데이터 분류 프로세스는 전달받은 데이터를 AI 학습모델

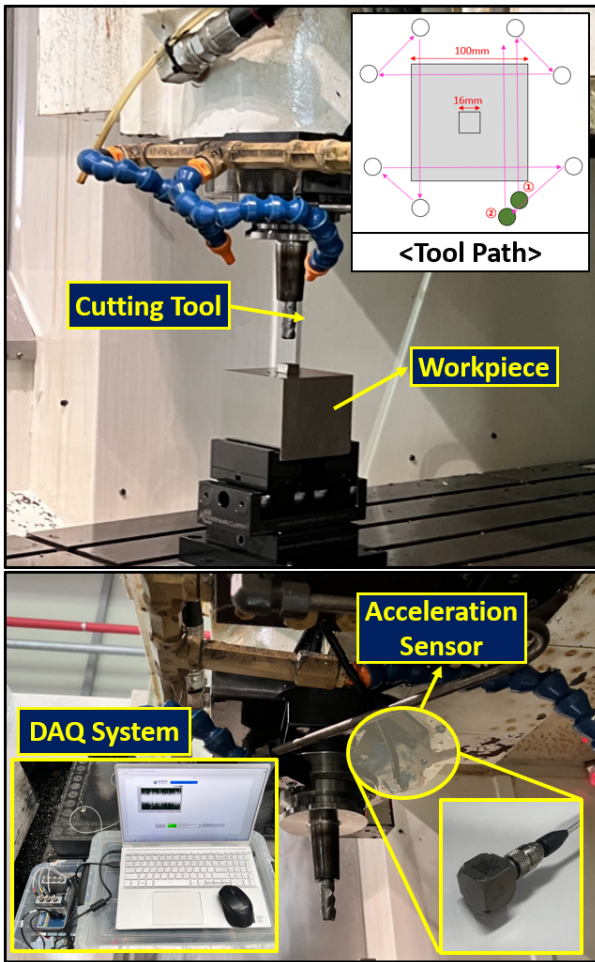


Fig. 2 Experimental set-up for cutting test with DAQ system

에 입력하고 학습모델은 공회전(air-cut), 안정(steady), 마모 진행(normal), 마모 파손(severe) 4가지 상태 중 하나를 공구 상태로 분류하고 결과를 즉시 시각화 프로세스로 TCP/IP 통신을 통해 전달한다. 시각화 프로세스는 실시간 수집된 센서 신호와 데이터 분류 프로세스에서 전달받은 AI 예측 결과를 나타낸다.

## 2.2 가공 실험 방법 및 공정 데이터 수집

절삭가공 중 공구의 상태를 실시간으로 예측하는 시스템을 구성하기 위하여 공정 데이터 수집 및 분석을 위한 기초 절삭가공 실험을 수행하였다. 가공 실험은 장비에 센서를 부착하고 공구와 소재를 세팅한 후 가공을 수행하고 공정 데이터를 수집하는 과정으로 이루어진다. Fig. 2는 가공 실험 장치 및 모니터링을 위한 DAQ 장치가 구성된 모습을 나타낸다. 가공 실험에 사용된 소재는 대표적 난삭재인 티타늄 합금 Ti-6Al-4V 블록(100×100×100 mm, AMS 4911)을 사용하였다. 티타늄 합금은 높은 고온 강도와 낮은 열전도성으로 가공이 어려운 소재이므로 공정 시 공구 상태 관리가 필요한 소재이다<sup>[4]</sup>. 절삭 공구는 직경 16 mm의 4날 Solid

Table 1 Conditions of cutting test

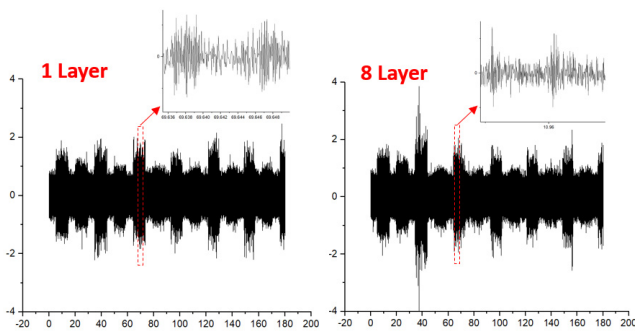
Vc (m/min)	80
fz (mm/tooth)	0.1
Axial depth of cut (Ap, mm)	5
Radial depth of cut (Ac, mm)	3

carbide end mill 공구를 사용하여 수행되었다(Walter, F4700-8323802). 가공실험은 Table 1과 같은 조건으로 이루어졌으며, 가공 장비는 최대 출력 20 kW의 3축 CNC 머시닝 센터가 사용되었다(Bridge Center-10, KITAMURA). 가공 경로는 Web 가공 방식으로 공구가 바깥에서 안쪽 방향으로 x축, y축을 반복하면서 가공이 되도록 설정하였다. 절삭가공 중 센서 데이터 기반으로 공구의 상태를 분석하기 위하여 본 논문에서는 3축 가속도 센서(Kistler, 8688 50 g)를 사용하였으며, 가공 장비의 스핀들에 부착하였다. 데이터 수집을 위한 DAQ 장치는 상용 모듈인 NI-9234 모듈과 NI-DAQ 보드(cDAQ-9147)를 사용하여 모니터링 시스템을 구성하고 가속도 센서로부터 진동 데이터를 수집하였으며, 가속도 센서의 데이터 수집 속도(sampling rate)는 20 kHz의 조건으로 설정하였다. 티타늄 합금 블록을 가공하면서 모니터링 데이터 분석에 활용하기 위해 공구 마모(tool wear)를 주기적으로 측정하였고 공구 마모 측정은 광학 현미경(Leica, APO-14)으로 측정하였다. 공구 마모는 가공 길이 6,802 mm 간격으로 Flank wear(VB)가 측정되었으며<sup>[14]</sup>, 가공실험은 동일한 실험을 3회 반복하여 공구가 파손될 때까지 진행되었으며 티타늄 합금의 10 Layer까지 면이 가공되었다.

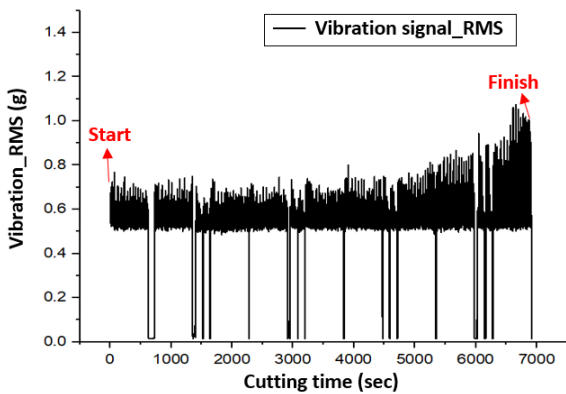
## 2.3 데이터 전처리 및 공구 상태 예측 AI 모델 구성

절삭가공 실험을 통해 공정 데이터 수집 과정을 거쳐 공회전 시점부터 공구 상태가 양호할 때의 정상 상태에서 마모로 인한 불량 상태까지의 진동 데이터를 연속으로 수집하였다. 수집된 데이터는 x축, y축, z축의 진동 데이터가 가공 경로에 따라 지속적으로 변하기 때문에 합 가속도(resultant acceleration)로 연산하여 가공 방향에 따른 영향을 최소화하였다. 합 가속도로 연산된 진동 데이터는 가공 중 경로와 관계없이 공구의 상태에 따라 발생하는 진동의 Amplitude가 달라지며, 본 연구에서는 센서 신호의 Amplitude 크기에 따라 공구 상태를 구분하고자 한다.

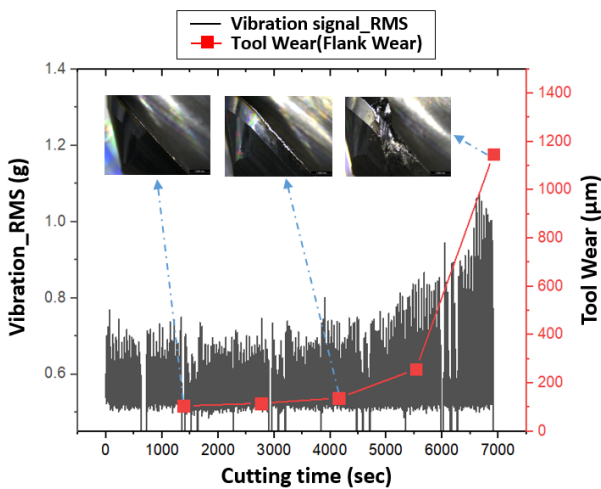
Fig. 3(a)는 가공 초반(1 layer)과 가공 후반(8 layer)의 Raw signal을 나타낸다. Raw signal의 경우 1초에 20,000개의 대량의 데이터가 발생하며, Fig. 3(a)와 같이 Amplitude나 파형만으로는 공구 상태에 따라 나타나는 특성을 잘 반영하지 못한다. 따라서 공구 상태와 Amplitude의 상관관계와 공구 상태에 따라 나타나는 특성을 반영하기 위해 센서 신호의 Amplitude를 비교적 잘 나타



(a) Raw signal of vibration data in 1&8 layer



(b) RMS pre-processing vibration data



(c) RMS vibration data with tool wear

Fig. 3 Results of pre-processing vibration data with tool wear

내는 Root Mean Square(RMS)로 전처리를 수행하였다. RMS 데이터는 1초에 10개의 RMS 값이 RMS 값이 발생하도록 처리하였다. 가공을 시작한 후 공구가 파손될 때까지 발생한 진동 데이터를 RMS 처리한 데이터는 Fig. 3(b)와 같이 나타났다. RMS 데이터는 가공이 진행될수록 RMS 값이 점점 증가하는 것을 볼 수 있다. Fig. 3(c)는 RMS 데이터와 가공 시 발생하는 공구 마모(flank wear)를 비교한 결과이다. 가공이 진행될 때 공구 마모가 발생하며 그에 따라 진동의 크기도 공구 마모 변화와 유사하게 증가하는 모

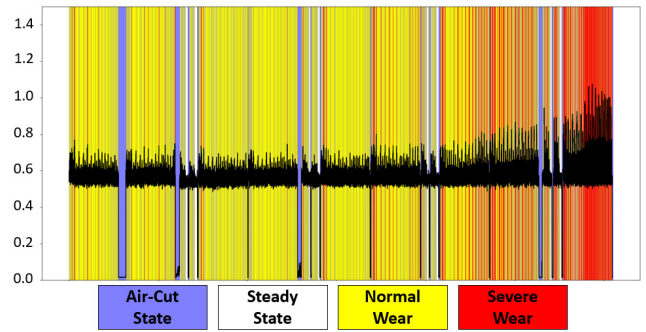


Fig. 4 Tool state labeling of 4 types by K-means clustering

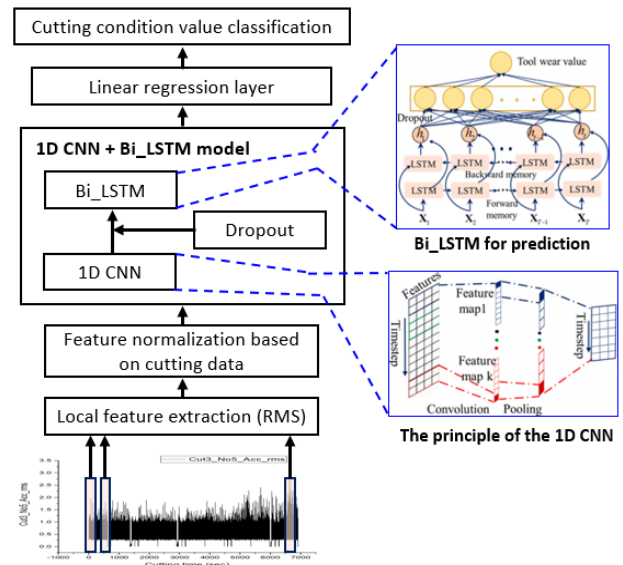


Fig. 5 Schematic diagram of AI model for tool state classification

습을 나타낸다. 따라서 이 전처리한 RMS 데이터를 활용하여 가공 시 공구의 상태를 구분할 수 있다.

공구 마모의 경향과 함께 RMS 데이터를 활용하여 공구의 상태를 구분하기 위해 머신러닝 모델 중 대표적인 비지도 학습 모델인 K-means clustering 알고리즘을 적용하였다. 본 연구에서 공구의 상태는 K-means clustering을 적용하여 가공을 하지 않는 공회전 (air-cut) 상태, 공구 마모가 거의 발생하지 않은 안정(steady) 상태, 마모가 점진적으로 진행되는 정상(normal) 상태, 심한 마모로 인한 공구 파손(severe)의 4가지 상태로 구분 및 라벨링을 수행하였으며, 4가지의 상태로 라벨링된 결과는 Fig. 4와 같다. 가공이 진행되다가 Severe 상태가 발생하는 시점이 공구 마모가 갑자기 증가하는 부분과 유사하며, 공구 마모와 분류 결과를 비교하였을 때 RMS 데이터의 4가지 상태가 공구 상태를 잘 반영하고 있음을 확인할 수 있다.

위와 같이 공구 상태를 4가지로 구분하고 반복된 가공 실험으로 획득한 진동 데이터에 모두 적용하였다. 이 데이터를 활용하여 공구 상태를 분류, 예측하는 AI 모델을 만들기 위해 동일한 가공 실

험을 3회 반복하여 얻은 데이터를 Test-1, Test-2, Test-3로 구분하였으며, 그 중 Test-1과 Test-3에서 발생한 데이터를 학습 데이터로 활용하여 AI 모델을 구성하였다. 그리고 나머지 Test-2 데이터를 활용하여 개발한 AI 분류 모델의 성능을 평가하였다. 본 논문에서는 가속도 센서의 시계열 진동 데이터를 활용하여 공구 상태 분류를 위해 CNN-LSTM 알고리즘을 이용하였다. CNN-LSTM 알고리즘은 높은 성능을 나타내며 많은 논문에서 활용되고 있는 알고리즘이다<sup>[15,16]</sup>. 학습 데이터를 사용하여 개발한 CNN-LSTM 기반의 학습 데이터를 사용하여 개발한 CNN-LSTM 기반의 AI 모델 구조는 Fig. 5와 같다. Test-1과 Test-3의 진동 데이터를 활용하여 구성한 AI 모델을 Test-2 데이터로 공구 상태 예측 정확도를 확인하기 위한 성능평가를 수행한 결과 95.3%의 예측 정확도를 나타내었다.

본 AI 모델은 RMS 데이터를 입력값으로 사용하여 공구 상태 예측 결과를 출력하며, DAQ 장치를 포함한 모니터링 시스템에서는 0.1초에 1개의 RMS 데이터를 발생시키기 때문에 이 AI 모델은 실시간으로 구현 시 0.1초당 한 번씩 새 예측을 출력한다.

### 3. 실시간 AI 예측 시스템 구현

#### 3.1 실시간 AI 예측 시스템

난삭재 절삭공정에서 인공지능 기반 공구상태 예측 시스템을 구현하기 위한 실시간 예측 시스템 구조는 Fig. 6과 같으며, Fig. 7은 실시간 데이터 처리를 위한 데이터 세트의 Moving shift 구조를 나타낸다. 실시간 공구상태 시스템은 2절과 Fig 1에서 언급한 것과 같이 Labview SW와 Python SW에서 기능에 맞게 센서 데이터 수집과 전처리 프로세스, 데이터 분류 프로세스, 예측결과 저장 프로세스, 시각화(U/I) 프로세스로 구성된다. 모든 동작은 순차적으로 동시에 동작하며 모니터링 시스템 내 DAQ 장치에서 진동 데이터를 수집하고 RMS 처리하여 0.1초 간격으로 데이터를 생성 및 AI 모델로 TCP/IP 통신을 통해 데이터를 전달한다. AI 모델은 전달받은 데이터를 분류 처리하여 공구 상태를 예측하고 예측 결과를 TCP/IP 통신을 통해 모니터링 시스템으로 반환한다. 모니터링 시스템에서는 반환받은 결과를 U/I 상에 가시화하고 결과를 표현한다. 이러한 과정을 반복적으로 수행함으로써 실시간으로 수행되는 절삭공정의 공구 상태를 탐지하고 사용자에게 현재 공구 상태를 알려준다.

#### 3.2 실시간 AI 예측 시스템 적용 및 성능평가

본 연구에서 개발한 실시간 공구 상태 예측 시스템에서 DAQ 장치와 별도의 PC를 구성하여 모니터링 시스템을 패키징화 하였으며, 실시간 공구 상태 예측 및 탐지 성능을 확인하기 위해 실제

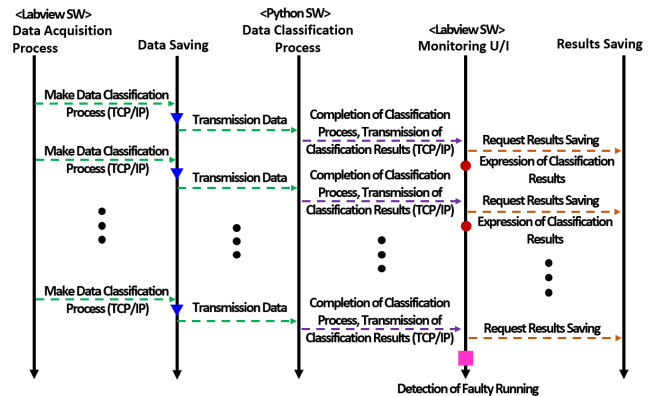


Fig. 6 Operation process of real-time tool failure prediction system based on AI


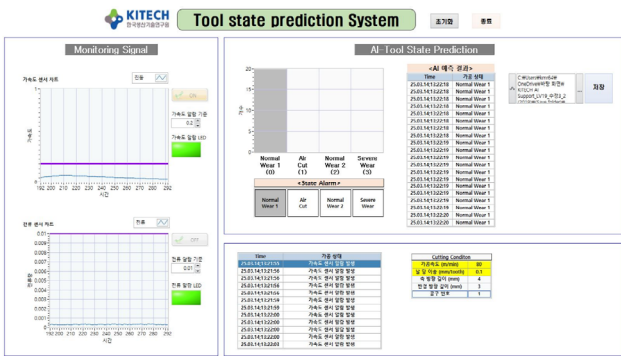


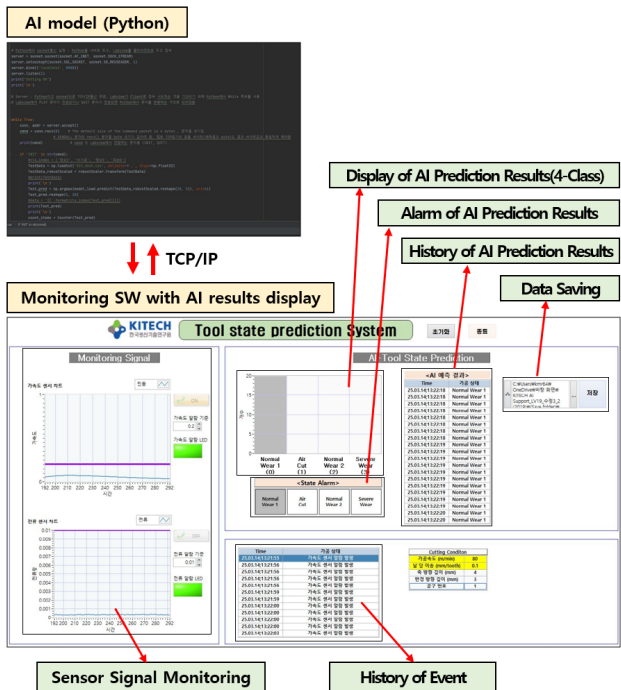
Fig. 7 Data streaming structure for real-time data processing

난삭재 절삭공정에 적용하여 재현성 평가를 수행하였다. 먼저 실시간 공구 상태 예측 시스템의 U/I는 Fig. 8(a)와 같이 구성하였다. U/I는 Labview SW로 개발되었으며, 센서 데이터 모니터링 및 전처리와 예측결과를 가시화, 저장하는 역할을 한다. Fig. 8(b)와 같이 예측 시스템 U/I에는 전처리된 센서 데이터의 모니터링 그래프, TCP/IP 통신을 통해 AI 모델에서 예측한 결과를 가시화하는 그래프, 예측 결과의 이력 관리, 공구 파손 알림과 같은 이벤트 관리, 데이터 저장관리 등의 기능을 포함한다.

본 시스템을 적용하는 가공 실험의 경우, 2.2절과 2.3절에서 정의하였던 Table 1과 같은 가공 조건( $V_c = 80 \text{ m/min}$ ,  $f_z = 0.1 \text{ mm/tooth}$ ,  $A_p = 5 \text{ mm}$ ,  $A_e = 3 \text{ mm}$ )과 동일한 가공 장비, 동일한 센서 및 DAQ 장치, 같은 공정 환경에서 실험을 진행하였으며, Fig. 9와 같이 가공 장치 구성 및 시스템을 세팅하였다. 센서와 패키징된 모니터링 시스템을 구성하고 모니터링 SW 및 AI 모델 동작을 위한 전용 PC를 구성하였다. 그리고 공구 상태의 AI 예측 결과 비교를 위해 실험 수행 시 센서의 RMS 데이터를 저장하였다. 본 실험 전 동작 테스트 결과 오류사항 없이 정상 구동하는 것을 확인하였다. 본 가공을 시작하고 실시간 공구상태 예측 시스템을 주기적으로 확인하였으며 티타늄 합금 블록을 순차적으로 연속 가공하면서 발생하는 가속도 센서의 진동 신호를 실시간으로 UI에서 모니터링하고 현재 공구 상태를 AI 모델로 실시간으로 구

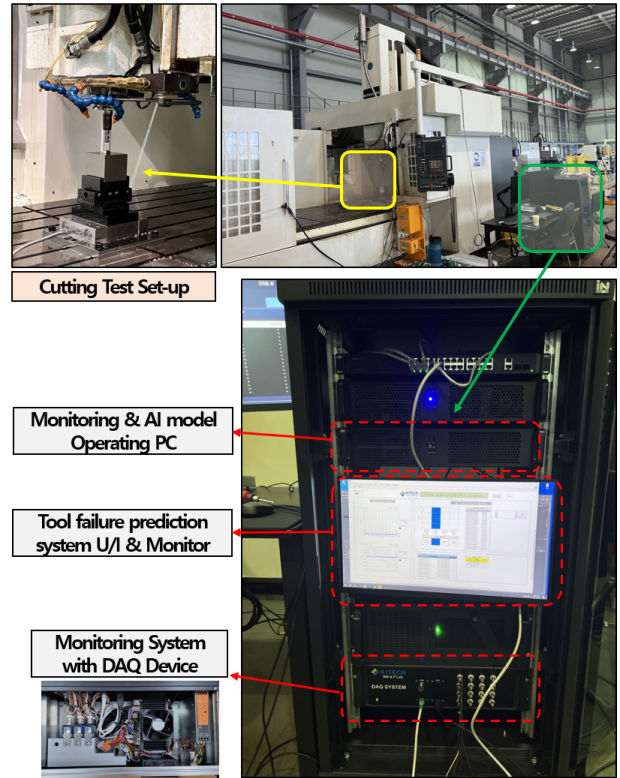


(a) Photograph of real-time tool failure prediction system U/I

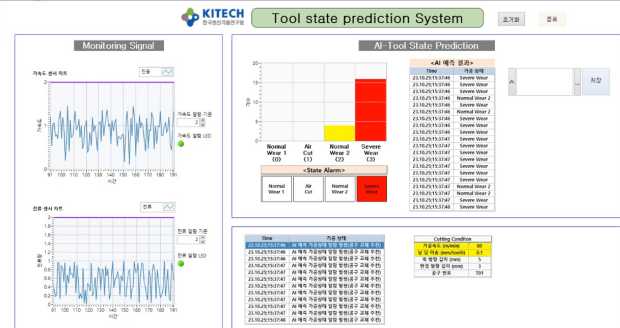


(b) Operating function of real-time tool failure prediction system U/I  
**Fig. 8 Developed real-time tool failure prediction system U/I**

동 및 예측을 하여 결과를 0.1초에 1번씩 가시화하는 모습을 확인할 수 있었다. Fig. 10은 실제 연속 가공 시 실시간으로 나타나는 센서 신호와 AI 모델에 의해 예측되어 나타나는 공구의 상태를 가시화하고 있는 모습을 나타낸다. 연속적으로 가공이 진행되면서 가공이 이루어지는 모습과 실시간 AI 예측 시스템을 관찰한 결과, 가공 시작 전 및 가공 중 공회전이 이루어지는 구간에서는 Air-cut의 예측 결과가 나타났으며, 가공 초기에는 Steady 상태와 Normal 상태를 실시간으로 예측 결과가 나타났으며, 가공이 계속 진행되면서 공구 마모가 심해져 가공 부하가 높아졌을 때는 Fig. 10과 같이 AI 예측 결과가 Severe 상태를 예측값으로 결과를 나타냈으며 가공 중 실시간으로 공구 상태를 모니터링 및 AI 예측 시스템이 정상적으로 구동하는 것을 확인할 수 있었다.



**Fig. 9 Set up of cutting test for performance evaluation of real-time tool failure prediction system**



**Fig. 10 Operating results of real-time tool failure prediction system during cutting test**

재현성 평가 및 성능 확인을 위한 가공 실험을 진행하면서 발생했던 실시간 AI 예측 시스템의 공구상태 예측 결과가 타당하지 확인하기 위해 예측 정확도 비교평가를 수행하였다. 먼저 연속 가공 실험을 진행하면서 저장된 센서의 신규 RMS 데이터를 2.3절에서 언급했던 K-means clustering 알고리즘으로 4가지 공구 상태를 라벨링하여 기준 데이터를 만들었다. 그리고 RMS 데이터를 활용하여 기 개발했던 95.3%의 예측정확도를 가지는 분류 예측 AI 모델을 통해 실시간으로 나타난 공구 상태 예측 결과를 비교하였다. 연속 가공 실험에서 발생한 데이터를 활용하여 AI 모델의




Fig. 11 Confusion matrix about real-time tool failure prediction results of AI model

예측 정확도를 확인한 결과 약 93.2%로 나타났다. 재현성 평가를 통한 연속 가공 실험의 공구 상태 예측 정확도는 기존의 모델과 비슷한 성능을 나타내는 것을 확인할 수 있었다. Fig. 11은 연속 가공 실험에서 발생한 RMS 데이터를 활용한 AI 모델의 공구 상태 예측 결과에 따른 혼동 행렬(confusion matrix)을 나타낸다. y축의 ‘True label’은 라벨링된 실제 공구 상태를 나타내며, x축의 ‘Predict label’은 AI 모델에 의해 예측한 공구 상태를 나타낸다. 예측 정확도가 93.2% 이므로, 대부분 실제 공구 상태와 동일하게 예측 결과가 나타났으며 특히 가공 중 안정(steady) 상태 및 정상(normal) 상태의 경우 판별 정확도가 매우 높은 것을 확인할 수 있다. 이는 가공 시 발생하는 진동 데이터가 공구의 상태에 따라 안정 상태와 정상 상태가 명확히 구분되는 Amplitude를 가졌으며 높은 재현성을 보이며 예측 모델에 의해 올바른 예측 결과를 나타낸 것으로 보인다. 공회전(air-cut) 상태의 경우 공구가 소재에 진입할 때와 빠져나갈 때의 순간적인 타이밍에 발생하는 가공 구간이 원인으로 보이며, 마모 파손(severe) 상태의 경우 공구 마모가 심하게 발생되어 Severe로 나타나다 공구가 파손되어 순간적으로 Air-cut으로 예측하여 Severe 예측과 복합적으로 나타난 것으로 판단된다.

#### 4. 결론

본 연구에서는 난삭재인 티타늄 합금의 절삭가공 중에 공구의 상태를 판단할 수 있도록 실시간 AI 모델 구동이 가능한 공구 상태 예측 시스템을 개발하고 실제 가공에 적용하여 예측 성능에 대한

분석을 수행하였다. 가속도 센서를 활용한 DAQ 장치와 모니터링 시스템을 구성하고 가공 실험을 통해 데이터 수집과 분석을 하여 공구 상태를 분류하는 AI 모델을 구성하였다. 그리고 모니터링 SW와 AI 모델 간의 TCP/IP 통신을 통해 전처리 데이터와 공구 상태 예측 결과의 데이터 통신이 연속적으로 가능하도록 개념을 설계하고 공구 상태 예측 및 결과 가시화가 가능한 시스템을 구성하였다. 반복적인 가공 실험을 통해 수집한 진동 데이터의 RMS 전처리 데이터와 K-means clustering 알고리즘을 활용하여 각각 공정 상태를 분류할 수 있었다. 공정 상태는 RMS 데이터를 대상으로 공구의 마모 상태에 따라 공회전(air-cut), 안정(steady), 마모 진행(normal), 마모 파손(severe) 4가지 상태로 분류하였다. 공구 상태를 분류 예측하는 AI 모델은 일반적인 대부분의 딥러닝 모델을 활용할 수 있으며, 본 연구에서는 성능이 높다고 알려진 CNN-LSTM 알고리즘을 활용하였다. 실시간으로 공구 상태 예측을 위해 개발한 AI 모델은 95.3%의 예측 정확도를 가졌으며, 본 AI 모델을 활용하여 모니터링 시스템, AI 모델 SW, 통신 알고리즘 등을 통합하여 실시간 공구상태 예측 시스템을 구성하였다. 본 시스템을 실제 난삭재 연속 가공에 적용한 결과 0.1초에 1번씩 각 공정 상태에 맞는 예측 결과를 나타내었으며, 예측 성능평가를 수행한 결과 93.2%의 예측 정확도를 나타내었다. 재현성과 성능평가에서 얻은 센서 데이터의 실제 공구 상태와 예측된 공구 상태를 비교한 결과 Severe 상태에서 가장 높은 오차가 발생하였는데, 이는 공구 마모가 점차 진행되다가 마모가 심하게 발생하여 RMS 데이터의 진폭이 증가하면서 완전 마모가 되어 Severe으로 예측하다가 공구 파손 이후 순간적으로 Air-cut으로 예측이 되어 Severe과 Air-cut이 번갈아가면서 나타난 것으로 파악된다. 실시간 공구 상태 AI 예측 모델의 예측 정확도가 개발 단계와 성능 평가 단계에서 모두 90% 이상의 예측 정확도를 나타내므로 본 가공 실험에서는 성능이 양호하다고 볼 수 있다.

본 연구에서는 실시간으로 AI에 기반한 공구 상태를 예측하는 시스템을 개발하였지만 하나의 공구와 하나의 가공 조건, 반복되는 가공 경로에만 적용하였다. 다양한 가공 조건과 가공 경로, 여러 공구 종류에 동시에 적용하기에는 아직 한계가 있으며, 다양한 방면에서의 연구가 필요하다. 예측 시스템에서 AI 모델과의 통신 뿐만 아니라 가공 장비와의 통신, 다양한 공구와 가공 조건에서 활용할 수 있는 데이터 처리 방법 등이 추가로 연구될 필요가 있다. 또한 예측 정확도도 더 높고 안정적인 성능을 나타낼 수 있어야 한다. 본 연구를 기반으로 향후 더 많은 실험 데이터 확보하고 타 연구 분석을 통해 예측 정확도를 높일 필요가 있으며, 향후 여러 가공 요소들을 고려하여 공정 조건 적용 범위를 확장 나타낼 수 있도록 연구 방향을 설정하고 추가 연구를 수행하고자 한다.

## 후 기

이 연구는 한국생산기술연구원 기관주요사업 "고위험, 고난이도 파이프 제작 공정 대응 원격 제조 시스템 개발(1/5) (kitech EH-25-0004)"의 지원으로 수행한 연구입니다.

## References

- [1] Soni, R., Verma, R., Garg, R. K., Sharma, V., 2024, A Critical Review of Recent Advances in the Aerospace Materials, *Materials Today: Proceedings*, 113 180-184, <https://doi.org/10.1016/j.matpr.2023.08.108>.
- [2] Kim, J. M., Koo, J. Y., Jun, C. S., 2022, A Study on Vibration Characteristics and Machining Quality in Thin-wall Milling Process of Titanium Alloy, *J. Korean Soc. Manuf. Process Eng.*, 21:6 81-88, <https://doi.org/10.14775/ksmpe.2022.21.06.081>.
- [3] Hourmand, M., Sarhan, A. A. D., Sayuti, M., Hamdi, M., 2021, A Comprehensive Review on Machining of Titanium Alloys, *Arab. J. Sci. Eng.*, 46 7087-7123, <https://doi.org/10.1007/s13369-021-05420-1>.
- [4] Park, M. S., Lee, H. H., Yun, Y. W., Kim, M. R., 2023, Evaluation of Cutting Performance Based on Tool Orientation during Solid Carbide End-milling of Ti-6Al-4V, *J. Korean Soc. Manuf. Technol. Eng.*, 32:2 92-100, <https://doi.org/10.7735/ksmte.2023.32.2.92>.
- [5] Kim, D. M., Park, H. B., Kim, B. G., Lee, H. H., Hwang, Y. H., Kim, K. H., Shin, I. S., Kim, D. Y., 2023, Study on the Effect of MQL Spraying Condition on the Machinability in Titanium Cryogenic Machining, *J. Korean Soc. Precis. Eng.*, 40:4 261-267, <http://doi.org/10.7736/JKSPE.022.144>.
- [6] Kim, H. K., 2022, Wear Diagnostic System for End Mill based on Machine Learning, *J. Korean Soc. Manuf. Technol. Eng.*, 31:1 37-40, <https://doi.org/10.7735/ksmte.2022.31.1.37>.
- [7] Nasir, V., Sassani, F., 2021, A Review on Deep Learning in Machining and Tool Monitoring: Methods, Opportunities, and Challenges, *Int. J. Adv. Manuf. Technol.*, 115 2683-2709, <https://doi.org/10.1007/s00170-021-07325-7>.
- [8] Mohanraj, T., Yerchuru, J., Krishnan, H., Nithin Aravind, R. S., Yameni, R., 2021, Development of Tool Condition Monitoring System in End Milling Process Using Wavelet Features and Hoelder's Exponent With Machine Learning Algorithms, *Measurement*, 173 108671, <https://doi.org/10.1016/j.measurement.2020.108671>.
- [9] Liu, M. K., Tseng, Y. H., Tran, M. Q., 2019, Tool Wear Monitoring and Prediction Based on Sound Signal, *Int. J. Adv. Manuf. Technol.*, 103 3361-3373, <https://doi.org/10.1007/s00170-019-03686-2>.
- [10] Cheng, Y., Gai, X., Guan, R., Jin, Y., Lu, M., Ding, Y., 2023, Tool Wear Intelligent Monitoring Techniques in Cutting: A Review, *J. Mech. Sci. Technol.*, 37 289-303, <http://doi.org/10.1007/s12206-022-1229-9>.
- [11] Chen, K., Zhang, X., Zhao, Z., Yin, J., Zhao, W., 2021, Milling Chatter Monitoring Under Variable Cutting Conditions Based on Time Series Features, *Int. J. Adv. Manuf. Technol.*, 113 2595-2613, <https://doi.org/10.1007/s00170-021-06746-8>.
- [12] Kim, D. H., Lee, J. M., Kim, J. D., 2021, Design and Implementation of a Real-Time Product Defect Detection System based on Artificial Intelligence in the Press Process, *J. Korea Inst. Inf. Commun. Eng.*, 25:9 1144-1151, <http://doi.org/10.6109/jkiice.2021.25.9.1144>.
- [13] Terrazas, G., Martínez-Arellano, G., Benardos, P., Ratchev, S., 2018, Online Tool Wear Classification during Dry Machining Using Real Time Cutting Force Measurements and a CNN Approach, *J. Manuf. Mater. Process.*, 2:4 72, <http://doi.org/10.3390/jmmp2040072>.
- [14] Kepczak, N., Zgorniak, P., Lajmert, P., Rosik, R., Sikora, M., 2020, Influence of Machining Parameters on the Polymer Concrete Milling Process, *Int. J. Adv. Manuf. Technol.*, 106 3017-3032, <https://doi.org/10.1007/s00170-019-04811-x>.
- [15] Cheng, M., Jiao, L., Yan, P., Jiang, H., Wang, R., Qiu, T., Wang, X., 2022, Intelligent Tool Wear Monitoring and Multi-Step Prediction Based on Deep Learning Model, *J. Manuf. Syst.*, 62 286-300, <https://doi.org/10.1016/j.jmsy.2021.12.002>.
- [16] Ma, J., Luo, D., Liao, X., Zhang, Z., Huang, Y., Lu, J., 2021, Tool Wear Mechanism and Prediction in Milling TC18 Titanium Alloy Using Deep Learning, *Measurement*, 173 108554, <https://doi.org/10.1016/j.measurement.2020.108554>.



**Mi-Ru Kim**

Principal Researcher in the Extreme Process Control Group, Dongnam Technology Application Division, Korea Institute of Industrial Technology. His research interest is Process Monitoring.

E-mail: mrkim@kitech.re.kr



**Hoon-Hee Lee**

Principal Researcher in the Extreme Process Control Group, Dongnam Technology Application Division, Korea Institute of Industrial Technology. His research interest is Machine Tool Metrology.

E-mail: hhlee84@kitech.re.kr



**Min-Suk Park**

Ph.D. Student in the Extreme Process Control Group, Dongnam Technology Application Division, Korea Institute of Industrial Technology. His research interest is Machining Process.

E-mail: msparker8@kitech.re.kr



**Wang-Ho Yun**

Researcher in the Extreme Process Control Group, Dongnam Technology Application Division, Korea Institute of Industrial Technology. His research interest is Machining Process.

E-mail: whyun@kitech.re.kr