

공작기계 스피들용 경량 상태진단 모델 개발

윤성재, 이문영, 전승협

한국전자통신연구원

sj.yoon@etri.re.kr, munyounglee@etri.re.kr, shjeon00@etri.re.kr

Development of Lightweight Diagnostic Model for Spindle of Machine Tool

Sungjae Yoon, Munyoung Lee, Seunghyub Jeon

ETRI

요약

공작기계는 다양한 산업 분야에서 필수적으로 활용되는 장비다. 공작기계는 다양한 요소로 구성되어 있으며, 특히 스피들은 가공품 품질에 직접적인 영향을 주는 요소이다. 본 논문에서는 스피들의 고장을 사전에 진단하는 모델을 제안한다. 상태진단 모델 개발에 필요한 데이터셋은 현장에서 발생 가능성이 높은 환경을 모사하여 수집하였고, 경량화를 위해 특징 중요도 기술을 활용했다. 실험 결과 정확도 93.8%, F1-스코어 92.4% 등의 성능을 보였다.

I. 서론

공작기계는 차량, 항공 등 다양한 분야에 필수적으로 사용되는 장비이다. 공작기계는 다양한 요소로 구성되어 있으며, 특히 스피들은 가공품 품질에 직접적인 영향을 주는 요소이다.

스피들은 고장이 발생하기 이전에 상태를 미리 진단해야 한다. 스피들이 파손되면 공작기계를 사용할 수 없어 생산량이 감소하기 때문이다. 이를 위해서는 사전에 스피들 여유분을 확보해야 하는데 규모가 작은 공장에서는 경제적인 이유로 여유분을 확보하기 어렵다. 현재는 현장에서 근로자가 소음을 통해 경험적으로 스피들의 상태를 진단하고 있어, 스피들의 상태를 사전에 진단하기 어렵다.

스피들의 상태 진단을 위해 인공지능을 적용하는 연구가 활발히 진행되고 있다. 인공지능을 사용하기 위해서는 정상과 고장 등으로 라벨링 되어 있는 데이터가 필요하다. 이를 위해 기존에는 인위적으로 파손된 베어링을 스피들에 장착하여 고장 데이터를 획득했다[1-2]. 하지만 이러한 인위적인 데이터는 연구 목적으로는 적합하지만 현장에 적용하기 어려웠다.

현장에 인공지능 모델을 적용하기 위해서는 정확도뿐만 아니라 모델의 크기를 경량화하는 것이 중요하다. 정확도가 아무리 높아도 컴퓨팅 자원이 부족한 환경에서는 해당 인공지능 모델을 사용할 수 없다. 따라서 현장에 적용 가능한 인공지능 모델을 개발하기 위해서는 정확도뿐만 아니라 모델 경량화가 필요하다.

본 논문에서는 현장 적용 가능성이 높은 고장 시나리오를 바탕으로 고장 데이터를 획득하고, 우선순위가 높은 특징을 선정해 정확도 감소는 최소화하면서 모델의 크기를 줄인 상태진단 모델을 제안한다.

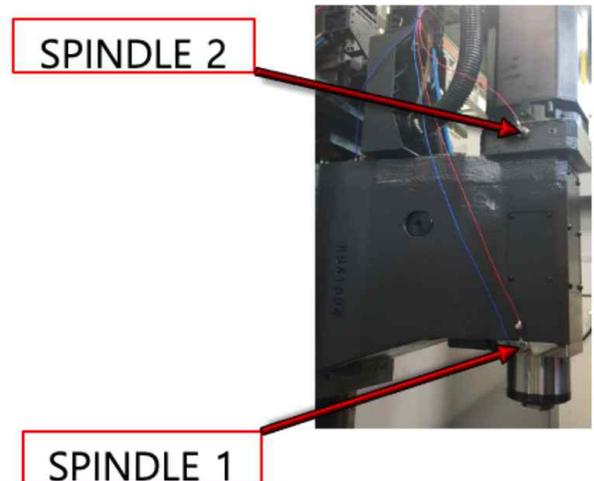
II. 본론

1) 스피들 고장 데이터 획득

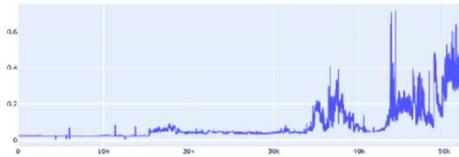
스피들 상태진단용 모델 개발을 위해 가속도 센서를 활용하여 진동 데이터를 획득했다. 가속도 센서는 Dytran社 3055D2 제품을 활용했으며, [그림 1]과 같이 스피들 하단(SPINDLE1)과 상단(SPINDLE2)에 부착했다. 샘플링 레이트는 12.8KHz로 설정해 데이터를 수집했다.

현장에서 발생 가능성이 있는 스피들 고장을 생성하기 위해 스피들을 3,000 RPM으로 고정된 상태에서 절입량을 높여 스피들의 피로도를 높인 후, 피삭재를 가공했다. 피삭재의 한 면을 2번 가공한 후, 소음을 통해 전문가가 스피들의 상태를 진단했다. 그리고 스피들을 공회전하면서 5분 분량의 데이터를 수집했다. 전문가가 스피들을 고장으로 진단할 때까지 반복했다.

[그림 2]는 수집한 데이터의 RMS(Root Mean Square) 값을 시각화한 결과다. 1초 단위(12,800개)로 RMS를 계산했다. 시각화 결과를 보면 초반에는 진동 데이터의 변화가 없다가 시간이 지날수록 점점 진동량이 증가했다. 본 논문에서는 전문가의 상태진단 결과와 진동량을 기준으로 수집 데이터를 정상, 이상, 고장 등 3가지 상태로 구분하여 라벨링했다.



[그림 1] 스피들에 부착한 가속도 센서



(a) 진동센서(SPINDLE 2)



(b) 진동센서(SPINDLE 1)

[그림 2] 수집 데이터 RMS 시각화 결과

2) 데이터 특징 추출

본 논문에서는 머신러닝 모델을 활용해 스피ndl의 상태를 진단한다. 머신러닝 모델을 활용하는 경우 개별 진동 데이터에서는 특징을 추출하기 어렵다. 이를 위해 0.1초 분량(1,280개)으로 윈도우 크기를 설정해 특징 13개¹⁾(min, max, RMS, mean, standard deviation, variance, skew, kurtosis, Q1, Q2, Q3, inter quartile range, overall)를 추출했다.

3) 상태진단 모델 개발

스피ndl의 상태를 진단하기 위해 랜덤 포레스트 모델을 사용했다. 진동 센서 2개와 관련하여 각각 특징 13개를 추출하여 초기 입력 데이터는 26개다. 모든 특징을 사용해도 되지만 현장에 적용하기 위해서는 추론 결과에 영향을 많이 주는 데이터를 선별하여 입력 데이터의 크기를 줄여야 한다. 우선 26개 데이터 모두를 사용해 랜덤 포레스트 모델을 생성하였고, 해당 모델에서 특징 중요도(feature importance)를 계산해 상위 5개에 해당하는 특징을 선정했다. 새로 랜덤 포레스트 모델을 생성할 때는 26개 데이터가 아닌 상위 5개 데이터만 활용했다.

[표 1] 추론 결과에 영향력이 높은 특징 Top5

순번	데이터명	순번	데이터명
1	vib_SP1_overall	4	vib_SP1_IQR
2	vib_SP2_var	5	vib_SP1_std
3	vib_SP1_rms		

[표1]은 추론 결과에 영향을 주는 상위 5개 특징을 보여준다. 스피ndl 위에 부착한 진동센서(SPINDLE 2)보다는 아래에 부착한 진동센서(SPINDLE 1)가 영향력이 높았으며, 특징으로는 overall, var., rms, IQR, std. 등이 영향력이 높았다.

4) 실험결과

제안하는 상태진단 모델을 검증하기 위해 학습 데이터와 추론 데이터를 독립적으로 분리하고, 교차 검증 방식을 사용했다. 검증 지표로는 정확도, 정밀도, 재현율, F1 스코어를 사용했다.

[표 2] 스피ndl 상태진단 모델 검증 결과

입력 파라미터 개수	26개	5개
정확도	93.5%	93.8%
정밀도	92.0%	92.3%
재현율	92.1%	92.4%
F1 스코어	92.0%	92.4%

[표2]는 스피ndl 상태진단 모델 검증 결과를 보여준다. 첫 번째 컬럼은 모든 데이터(26개)를 사용해 상태진단 모델을 만든 경우이고, 두 번째 컬럼은 상위 5개 데이터만을 활용한 결과이다. 실험 결과를 보면 추론 결과에 영향을 주는 상위 5개 데이터만 활용해도 정확도를 유지하는 결과를 보였다.

III. 결론

본 논문에서는 공작기계 스피ndl의 상태 진단 인공지능 모델 학습용 데이터셋 수집을 위해 절입량을 증가하여 스피ndl의 피로도를 높여 고장 데이터를 수집했다. 수집한 데이터셋에서 특징 13개를 추출해 랜덤포레스트 기반 머신러닝 모델을 학습했고, 경량화를 위해 특징 중요도 기술을 활용했다. 실험 결과 영향력이 높은 데이터를 사용해도 상태진단 모델의 성능이 유지되는 것을 확인했다.

ACKNOWLEDGMENT

이 연구는 2021년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임(No. 20007891, 옛지 컴퓨팅 기반 공작기계 핵심요소 상태 진단 및 보안 기술 개발).

참 고 문 헌

- [1] Guo, X., Chen, L. and Shen, C., 2016, "Hierarchical Adaptive Deep Convolution Neural Network and Its Application to Bearing Fault Diagnosis," Measurement, Vol. 93, pp. 490~502.
- [2] Wen, L., Li, X., Gao, L. and Zhang, Y., 2018, "A New Convolutional Neural Network-based Data-driven Fault Diagnosis Method," IEEE Transactions on Industrial Electronics, Vol. 65, No. 7, pp. 5990~5998.

1) Q1, Q2, Q3는 사분위도를 의미하며, 각각 25%, 50%, 70% 지점을 의미함.