

진동신호 기계학습을 통한 프레스 금형 상태 인지

홍석관[†] · 정의철¹ · 이성희¹ · 김옥래¹ · 김종덕²

한국생산기술연구원 금형성형연구부^{1,†}

(주)대성파인텍 기술연구소²

State recognition of fine blanking stamping dies through vibration signal machine learning

Seok-Kwan Hong[†] · Eui-Chul Jeong¹ · Sung-Hee Lee¹ · Ok-Rae Kim¹ · Jong-Deok Kim²

Department of Molding & Metal Forming R&D, Korea Institute of Industrial Technology^{1,†}

Technology Laboratory, DAESUNG FINE TEC Co., LTD.²

(Received December 09, 2022 / Revised December 27, 2022 / Accepted December 31, 2022)

Abstract: Fine blanking is a press processing technology that can process most of the product thickness into a smooth surface with a single stroke. In this fine blanking process, shear is an essential step. The punches and dies used in the shear are subjected to impacts of tens to hundreds of gravitational accelerations, depending on the type and thickness of the material. Therefore, among the components of the fine blanking mold (dies), punches and dies are the parts with the shortest lifespan. In the actual production site, various types of tool damage occur such as wear of the tool as well as sudden punch breakage. In this study, machine learning algorithms were used to predict these problems in advance. The dataset used in this paper consisted of the signal of the vibration sensor installed in the tool and the measured burr size (tool wear). Various features were extracted so that artificial intelligence can learn effectively from signals. It was trained with 5 features with excellent distinguishing performance, and the SVM algorithm performance was the best among 33 learning models. As a result of the research, the vibration signal at the time of imminent tool replacement was matched with an accuracy of more than 85%. It is expected that the results of this research will solve problems such as tool damage due to accidental punch breakage at the production site, and increase in maintenance costs due to prediction errors in punch exchange cycles due to wear.

Key Words: Fine blanking, Machine learning, Residual life, Tool wear

1. 서론

파인블랭킹(fine blanking)은 Fig. 1, 2와 같이 한번의 스트로크(stroke)로 성형품 두께의 대부분을 매끄러운 전단면으로 가공할 수 있는 프레스 가공 기술이다. 여러 가지 성형 공정이 복합적으로 필요한 제품의 경우 blanking, bending, offset bending, coining 등의 공정이 포함된 프로그레시브(progressive) 파인블랭킹 금형을 사용하면 별도의 후가공 없이 생산성을 현저히 향상시킬 수 있다¹⁾.

이러한 파인블랭킹 공정에서 전단(shear)은 필수적으로 수행되는 단계이다. 전단에 사용된 펀치(punch)와 다이(die)는 소재의 종류, 두께 등에 따라 수직에서 수백 중력가속도(g)의 충격을 받게 된다. 따라서 파인블랭킹 금형 구성품 중에서 펀치와 다이는 수명이 가장 짧은 부품에 속한다.

실제 생산 현장에서는 펀치와 다이의 마모뿐만 아니라 돌발적인 펀치의 파손 등 다양한 형태의 금형 손상이 발생한다. 대표적인 손상으로 Fig. 3에 나타난 마와 같이 마모(wear), 소성변형(plastic deformation), 치핑(chipping), 균열(cracking), 골링(galling)이 있다. 이러한 금형의 손상이 생산 중에 발생하면 금형의 2차 손상뿐만 아니라 성형 장비까지 고장을 일으키는 피해가 발생할 수 있다. 이를

1. 한국생산기술연구원 금형성형연구부

[†] 교신저자: 한국생산기술연구원 금형성형연구부

E-mail: skhong@kitech.re.kr

방지하기 위해서 이물 감지 센서 등 안전장치를 갖추고 있지만 기능이 제한적이고 근본적인 문제해결 방법은 아니다.

최근 인공지능의 성능이 비약적으로 발전하여 이를 활용한 기술들이 다양한 분야에서 발표되고 있다²⁾.




Fig. 1 Shear tools and cutting surface for (a) normal stamping and (b) fine blanking



Fig. 2 Product by (a) fineblanking and (b) normal stamping

본 연구는 보전 엔지니어링(maintenance) 분야에서 예지보전(predictive maintenance) 기술에 초점이 맞추어져 있다. 예지보전은 ‘장비 상태에 대한 전문가적 진단을 통해 수명을 미리 예지하고 고장 발생 이전에 미리 보수하여 전체 시스템의 원활한 운영을 보장하는 유지보수 방법’으로 정의된다³⁾. 여기서 전문가적 진단이란 작업 현장의 다양한 신호들을 사람이 오감(五感, five senses)을 통해 감지하는 것이 현재 방법이라면 본 연구에서는 인공지능을 통해 감지하는 것을 목표로 한다.



Fig. 3 Most Frequent Failure Mechanisms in Sheet Metal Tooling

한편, 프레스 가공에서 펀치 또는 다이의 수명은 Fig. 4와 같이 매우 다양한 요인 즉, 소재, 금형, 성형 장비, 주변 환경 등 수많은 변수에 반응하기 때문에 이를 사전에 예측하는 것은 매우 어렵다. Hamnli 등(2009)은 FEM을 활용하여 펀치의 마모와 버(burr)의 상관관계를 분석하였고 이를 통해 마모와 생산비용을 계산하였다⁴⁾. Sari 등(2017)은 프레스 금형으로부터 진동신호를 수집하고 주파수 분석을 통해 펀치의 타발수와 진동신호를 동기화 시켰다⁵⁾. Ubhayaratne 등(2017)은 펀치의 마모정도를 구분할 수 있는 음향신호를 분석하였다⁶⁾. 본 연구에서는 파인블랭킹 성형물의 버 크기, 타발수, 진동신호를 수집하고 이들 데이터셋을 기계학습하여 해당 버 크기에 대한 진동 신호를 인지하는 알고리즘을 정립하였다.

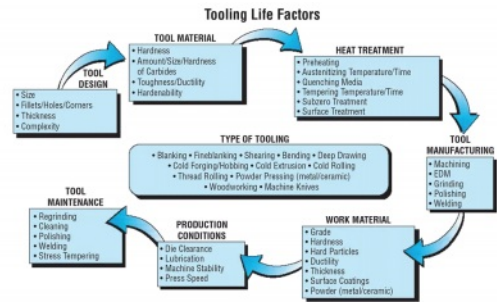


Fig. 4 Factor affecting on tool life: Böhler-Uddeholm

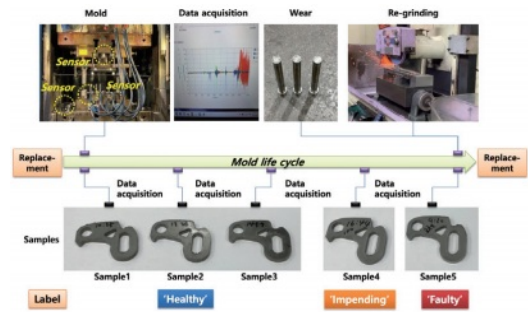


Fig. 5 Experimental setup and labeling signal

2. 데이터셋 생성

2.1. 파인블랭킹 금형 및 센서 설치

파인블랭킹 성형기는 FB400-FD(MORI)가 사용되었고 금형은 가로 37mm, 세로 31mm, 두께 3mm 크기의 자동차 도어락(door lock) 부품 성형용이며 금

형 상부(V1)와 하부(V2)에 진동센서(100mV/g, PCB Piezotronics) 하나씩 설치하였다. 그 밖에 음향 센서(50mV/Pa, CRY Sound) 하나는 금형 외곽에 설치하였다. Fig. 5에 현장금형과 센서의 설치 위치, 샘플 수집의 구간 및 라벨링 정보를 나타내었다.

2.2. 신호 저장 및 라벨링

새금형(편치) 교체 후 금형의 수명이 다할 때까지를 한 주기로 볼 때 한 주기를 5구간으로 나누어 성형 샘플과 신호를 수집하고 버(burr) 크기를 측정하였다. 금형 교체 시점의 버 크기는 기업마다 기준이 다르지만 본 시험 제품의 경우 불량품 발생 시 제품의 버의 크기를 기준으로 Fig. 6에 보이는 바와 같이 버 크기가 0.6mm 이상에서 금형을 교체하는 것으로 정하였다.

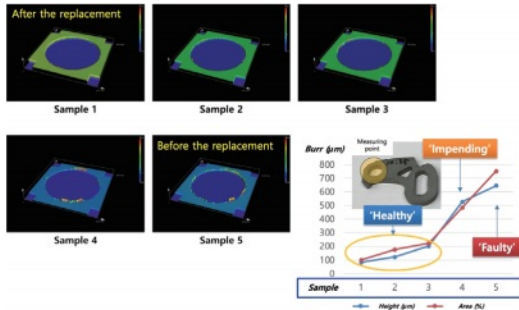


Fig. 6 The result of measuring the burr size of the sample according to tool wear

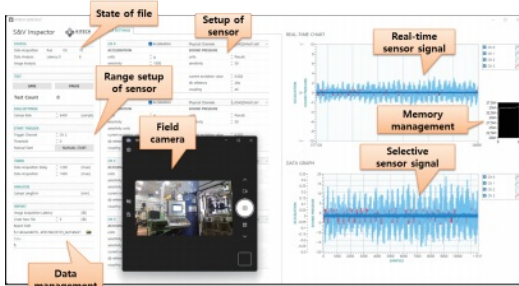


Fig. 7 Data collection and processing module

신호는 DAQ(NI9234, NATIONAL INSTRUMENTS - TS CORP.)를 통해 PC로 입력된다. 입력된 신호는 인공지능 학습 목적에 맞게 Fig. 7에 나타난 데이터 처리기(LabVIEW, NATIONAL INSTRUMENTS CORP.)에서 처리 후 csv파일로 저장된다. 샘플링속

도(sampling rate)는 6,400 Hz로 금형 수명 한 주기를 모두 저장하면 방대한 크기의 데이터 용량이 되기 때문에 데이터 처리기에서 음향신호를 트리거로 사용하여 선택적으로 필요한 부분만 저장한다.




Fig. 8 Real-time data set creation result and data volume




Fig. 9 Labeled vibration signal of (a) V1 and (b) V2

Fig. 8에 보이는 것처럼 프레스 공정한 사이클에 18,880개의 데이터가 선택적 처리를 통해 저장된다. 5 사이클 신호가 하나의 csv 데이터셋 파일(94,400개)로 저장되고 모든 구간(5개 샘플)의 데이터 파일이 50개이므로 센서 하나당 총 4,720,000개의 데이터가 기계학습에 사용된다. 기계학습을 위한 라벨링(labeling)은 처음 3개의 샘플 신호는 금형의 정상상태(버 크기 0.5mm 이하)를 의미하는 'Healthy'로 마지막 금형 교체 전 샘플 신호는 교체 임박(버 크기 0.5mm 이상 0.6mm 이하)을 의미하는 'Impending'으로 마지막 금형교체 시(버 크기 0.6mm 이상) 샘플 신호는 'Faulty'로 라벨링 하였다. 신호 라벨링은 매트랩(MATLAB®) 프로그램을 이용하였으며 최종 매트랩에서 기계학습을 위해 앙상블로 변환된다. 여기서 앙상블(ensemble)은 다양한 상태에서 시스템을 측정 또는 시뮬레이션하여 만든 데이터 세트의 모음을 의미한다. Fig. 9에 라벨링된 데이터의 진동신호 파형을 볼 수 있다.

3. 특징 추출 및 기계학습

3.1. 특징 추출

금형의 마모상태를 인지하기 위해서는 인공지능 학습에 이용할 다양한 특징(feature)를 신호로부터 추출해야 한다. 먼저, 시간 영역 특징(time-domain features) 중에서 통계적 특징(statistical features)인 평균(mean), 평균제곱근편차(rms), 표준편차(standard deviation), 형상계수(shape factor), 첨도(kurtosis), 왜도(skewness)와 충격특징(impulsive features)인 파고울(crest factor), 충격계수(impulse factor), 공차계수(clearance factor), 피크값(peak value)와 하모닉 특징(harmonic features)인 신호 대비 잡음비(signal-to-noise ratio), 전고조파 왜곡(total harmonic distortion), SINAD를 추출하였다. 다음 주파수 영역 특징(frequency-domain features) 중에서 피크 진폭(peak amplitude), 피크 주파수(peak frequency), 밴드 파워(band power)를 추출하였다.

주파수 영역(frequency domain)에서 신호의 특징을 추출하기 위해서는 파워 스펙트럼(power spectrum) 분석이 선행되어야 한다. 이를 위해 시계열 신호를 자기회귀 모델(autoregressive model)을 사용하여 Fig. 10과 같이 파워 스펙트럼을 추정하였다. 자기회귀 모델은 시계열 자료의 통계적인 분석을 위해 주로 이용되는 방법으로서, 어떤 시간 단계의 자료가 그 이전 시간 단계의 자료들의 선형 조합과 임의의 오차의 합에 의해서 표현되는 모델이며 다양한 종류의 서로 다른 시계열 패턴을 매우 유연하게 다룰 수 있는 장점이 있다.




Fig. 10 Power spectrum of signal (a) V1 and (b) V2




Fig. 11 Histogram chart for (a) V1-SINAD and (b) V1-SNR

3.2. 기계학습 및 평가

금형 신호를 효과적으로 학습하기 위해서는 앞서 추출된 32가지의 다양한 특징 중에서 성능 순위를 정하고 유의미한 특징만 선별해서 사용해야 한다. Fig. 11은 특징의 상태를 나타내는 히스토그램이며 구별 성능이 가장 우수한 2개의 특징을 나타내었다. 각 라벨링에 해당하는 색이 겹치지 않을수록 효과적인 특징임을 나타낸다. Fig. 12와 같이 3개 이상의 라벨을 구별할 때 효과적인 일원분산분석(one-way ANOVA)법으로 구별 성능의 순위를 정하였으며 상위 5위안의 특징만 인공지능 학습에 이용하였다. 가장 구별성능이 높은 특징은 V1(상부 진동신호)의 신호 대 잡음 및 왜곡비를 나타내는 SINAD(signal to noise and distortion ratio)이었으며 다음으로 신호 대 잡음비를 나타내는 SNR(signal to noise ratio)이 다른 특징보다 상대적으로 우수한 구별성능을 보였다.

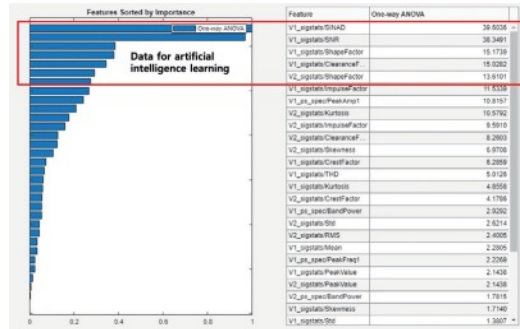


Fig. 12 Features sorted by importance

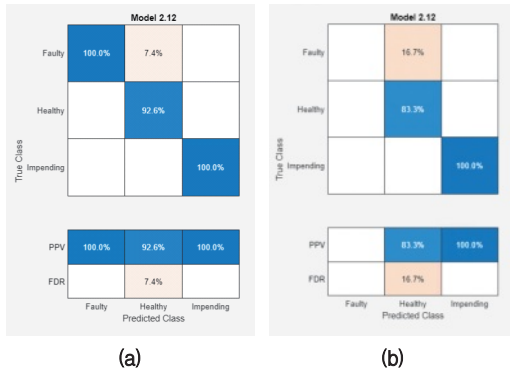


Fig. 13 Confusion matrix for (a) validation and (b) test

선별된 특징을 다양한 기계학습 모델로 학습을 수행하였다. 가장 정확도가 높은 학습 모델은 SVM(support vector machine)과 kNN(k-nearest neighbor) 알고리즘이었다. SVM 알고리즘은 이질적인 서로 다른 집단간의 상대적인 거리를 최대화할 수 있는 기준면(hyperplane)을 통해 분류하는 방식이다. kNN은 새로 받아들인 데이터를 판단해야 할 경우, 기존에 학습한데이터와 비교하여 가장 가까운 거리의 k개의 데이터의 분류값으로 받아들이는 알고리즘이다. kNN은 k값에 따라 분류 성능이 민감하게 반응하는 반면 SVM은 과적합에 민감하지 않고 오류 데이터에 영향을 적게 받는 장점이 있다. 따라서 본 연구에서는 SVM 알고리즘을 적용하였다.

Fig. 13은 알고리즘의 구별 정확도를 나타내는 혼합 차트(confusion chart)를 보여준다. SVM 알고리즘으로 검증(validation) 정확도가 95.3%로 예측되었고, 데이터 수의 10%로 시험(test)을 수행한 결과 85.7%의 정확도를 보였다. 이때 설정한 하이퍼파라미터(hyperparameters)값은 Table 1에 표기하였다.

Table 1 SVM model hyperparameters

Options	Values
Kernel fuction	Gaussian
Box constraint level	1
Kernel scale	2
Multiclass method	One-vs-One

4. 결론 및 토의

본 연구는 인공지능을 통해 편치의 수명을 예측하기 위한 예지보전(predictive maintenance) 기술 개

발의 일환으로 수행되었다. 기술의 적용 분야는 프레스 금형이며 특히, 파인블랭킹 공정에서 금형의 마모 상태 정도를 인지하기 위한 방법을 연구하였다. 실험에 사용된 금형은 실제 기업에서 양산 중인 금형을 대상으로 하였고 생산활동에 최소한의 간섭 즉, 센서 설치를 위한 금형의 설계 변경, 작업자의 활동 반경의 방해 등을 피하도록 노력하였다. 또한, 생산 중인 금형의 마모를 측정하는 것은 매우 어렵기 때문에 성형품의 버(burr)를 측정하여 편치 또는 다이의 수명을 측정하였다. 버 크기와 편치(또는 다이)의 마모가 직접적인 상관관계가 있다는 것은 이미 알려진 사실이다. 버 크기가 기준치에 도달했을 때 편치를 교체 또는 재 연삭하는 데 그 시점뿐만 아니라 바로 전 시점의 진동신호도(시험 정확도 기준) 85% 이상 구별할 수 있었다. 다이 플레이트부의 진동신호 보다는 편치 플레이트부의 진동신호가 마모도를 구별하는 데 더 효과적이었으며 신호 대 잡음 및 왜곡비(SINAD)와 신호 대 잡음비(SNR)에 대한 특징이 파인블랭킹 금형의 마모도를 가장 잘 구별하는 것을 확인할 수 있었다.

본 연구의 결과를 통해 생산 현장에서 발생하고 있는 돌발적인 편치의 파손에 의한 금형 손상, 마모에 의한 편치 교환 주기의 예측 오차로 인한 유지비용 증가 등의 문제를 해결할 수 있을 것으로 기대한다.

후기

본 논문은 한국생산기술연구원 기관주요사업 "Add-on 모듈 탑재를 통한 지능형 뿌리공정 기술개발(KITECH EO-22-0005)" 의 지원으로 수행한 연구입니다.

참고문헌

- 1) Zheng, Q., Zhuang, X., & Zhao, Z. State-of-the-art and future challenge in fine-blanking technology. Production engineering, 13(1), pp. 61-70. 2019.
- 2) Lee, J. H., Shin, J., & Realf, M. J. Machine learning: Overview of the recent progresses and implications for the process systems engineering field. Computers & Chemical Engineering, 114, pp. 111-121. 2018.
- 3) Achouch, M., Dimitrova, M., Ziane, K., Sattarpanah

- Karganroudi, S., Dhouib, R., Ibrahim, H., & Adda, M. On predictive maintenance in industry 4.0: Overview, models, and challenges. *Applied Sciences*, 12(16), pp. 8081. 2022.
- 4) Hambli, R., Soulat, D., & Chamekh, A. Finite element prediction of blanking tool cost caused by wear. *The International Journal of Advanced Manufacturing Technology*, 44(7), pp. 648-656. 2009.
- 5) Sari, D. Y., Wu, T. L., & Lin, B. T. Preliminary study for online monitoring during the punching process. *The International Journal of Advanced Manufacturing Technology*, 88(5), pp. 2275-2285, 2017.
- 6) Ubhayaratne, I., Pereira, M. P., Xiang, Y., & Rolfe, B. F. Audio signal analysis for tool wear monitoring in sheet metal stamping. *Mechanical Systems and Signal Processing*, 85, pp. 809-826. 2017.

저자소개

홍 석 관 (Seok-Kwan Hong)



- 2015년 8월: 단국대학교 기계공학과 (공학박사)
- 2004년 3월~현재: 한국생산기술연구원, 금형성형연구부, 선임연구원

< 관심분야 >
프레스 공정 해석, 사출 공정 해석, 최적화, 인공지능

정 의 철 (Eui-Chul Jeong)



- 2014년: 단국대학교 기계공학 학사
- 2016년: 단국대학교 대학원 기계공학 열유체 석사
- 2022년: 단국대학교 대학원 기계공학 열유체 박사
- 2022년 8월~현재: 한국생산기술연구원 금형성형연구부, 포스트닥터

< 관심분야 >
사출성형 및 금형, 탄소복합소재

이 성 희 (Sung-Hee Lee)

[정회원]



- 1998년 8월: 홍익대학교 기계공학과 (공학박사)
- 2002년 7월~2006년 12월: 한국생산기술연구원 선임연구원
- 2010년 12월~2014년 1월: 한국생산기술연구원 부친금형센터 센터장
- 2014년 1월~2015년 3월: 한국생산기술연구원 한국금형센터 그룹장
- 2007년 1월~현재: 한국생산기술연구원 금형성형연구부, 수석연구원

< 관심분야 >
고분자성형 및 금형, 급속가열, 복합재료, 전산모사/최적화

김 옥 래 (Ok-Rae Kim)



- 2010년 8월: 인천대학교 기계공학과 (공학박사)
- 1989년 3월~현재: 한국생산기술연구원, 금형성형연구부, 수석연구원

< 관심분야 >
금형, 사출성형, 사출성형해석, 정밀측정

김 종 덕 (Jong-Deok Kim)



- 1981년 2월: 서울대학교 공과대학 기계공학과
- 1982년 3월~2019년 5월: 한국생산기술연구원, 금형기술연구그룹, 수석연구원
- 2019년 5월~현재: (주)대성파인텍 기술연구소, 소장

< 관심분야 >
파인블랭킹 성형 기술, 판재 성형 기술, 급속 3D 프린팅 기술