

Developing a deep learning-based fault detection model for plastic injection molding for car parts companies

Gyeongho Kim, Jae Gyeong Choi, Minjoo Ku, Hyewon Cho, Sunghoon Lim

Department of Industrial Engineering, Ulsan National Institute of Science and Technology (UNIST)


sunghoonlim@unist.ac.kr

2021. 05. 21. (Friday)

Kim, Gyeongho, Jae Gyeong Choi, Minjoo Ku, Hyewon Cho, and Sunghoon Lim†. "A multimodal deep learning-based fault detection model for a plastic injection molding process." *Expert Systems with Applications* (Under Review)

플라스틱 사출성형 공정 (plastic injection molding process)

- 플라스틱 합성 수지를 높은 온도로 녹여 금형에 주입 후, 냉각 과정을 거쳐 성형이 실행되는 과정
- 자동차 부품, 생활용품 등의 플라스틱 제품 제작에 사용
- 대량생산에 적합하지만, 내부 공정의 복잡성으로 인해 금형의 가공 정도, 재료 사출 시 온도 및 속도, 압력 등의 다양한 변수의 미세 설정 및 최적화가 필요함
- 변수는 서로 비선형적으로 연결되어 있어 상관성 해석 및 적합한 변수 설정의 어려움이 있음



사출기 구조



플라스틱 사출성형 공정 불량 예측(fault detection)의 필요성

문제점

- 미성형, 가스자국 등의 불량 발생 과다 (불량율 4%)
- 불량 발생 원인 분석이 어렵고 사출기 별 다양한 변수(온도, 압력 등) 설정이 필요하여, 그에 따른 인력 비용이 과다 발생 (비가동 손실)
- 현장 경험만을 바탕으로 사출기의 설정 값을 조정하여, 환경 변화에 따른 불량률 예측 및 조정이 어려움



불량현상의 예: 플로우마크(좌), 기포(우)

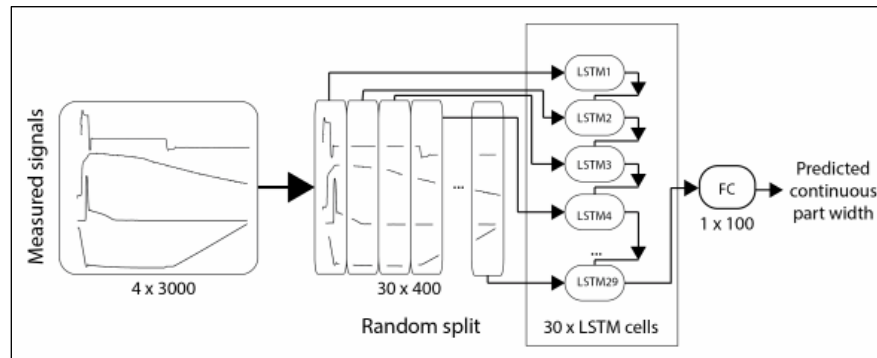
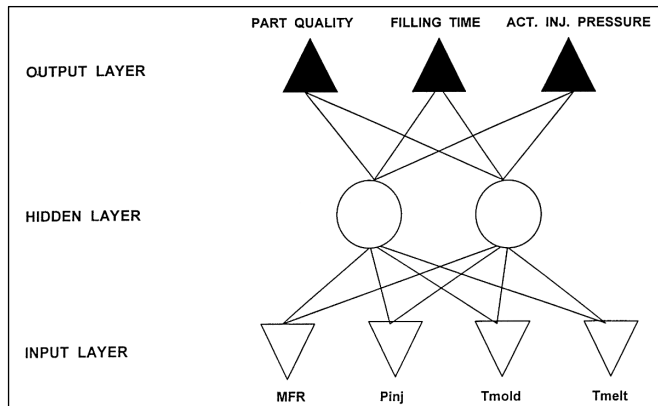
개선 방안

- 다변량 플라스틱 사출성형 공정 데이터에서의 제품 불량 예측을 위한 deep learning 기반의 예측 모델을 개발
- 특히 deep learning 기반의 예측 모델 개발을 통해, false detection (불량을 양품으로, 혹은 양품을 불량으로 잘못 예측) 감소와 실시간 불량 예측을 가능하게 함

선행연구

플라스틱 사출성형 공정에서의 불량 검출

- Neural network 기반의 접근 방법 (Sadeghi, 2000)
 - 4개의 multivariate 변수를 입력으로 받음
 - Backpropagation network로 모델 구성
 - 공정 시간 감소, 공정 상황 및 조건 최적화 목적
- Deep learning 기반의 접근 방법 (Nagorny et al., 2017)
 - 불량 검출을 위해 데이터 특성에 따라 아래와 같이 다른 딥러닝 모델을 적용
 - 열화상 이미지에 2 CNN 2 FC 네트워크 구조 적용
 - 시계열 정보를 담은 신호 데이터에 LSTM 모델 적용




- Sadeghi, B. H. M. "A BP-neural network predictor model for plastic injection molding process." *Journal of materials processing technology* 103, no. 3 (2000): 411-416.
- Nagorny, Pierre, Maurice Pillet, Eric Pairel, Ronan Le Goff, Jérôme Loureaux, Marlène Wali, and Patrice Kiener. "Quality prediction in injection molding." In *2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, pp. 141-146. IEEE, 2017.


선행연구

플라스틱 사출성형 공정에서의 불량 검출 (시계열 데이터)

- CNN 기반의 ensemble 모델 (Fawaz et al., 2020)
 - Google에서 개발한 CNN 기반의 Inception-v4 구조에 시계열 특성을 고려하는 모델을 고안
 - 기존의 최고 성능을 보이던 HIVE-COTE 모델과 비슷한 성능을 유지함과 동시에 모델을 경량화 함으로써 계산 속도를 높임



- LSTM과 CNN 의 병렬 결합 (Karim et al., 2017)
 - 맥락 정보(context vector)를 이용하여, 주변 정보에 집중하는 Attention 메커니즘 적용을 통한 성능 향상
 - 데이터를 미리 학습시키고, 학습된 모델을 기반으로 기존 데이터에 재학습을 시키는 전이 학습(transfer learning) 방식으로 성능 향상
 - 복잡한 전처리나 feature engineering을 요구하지 않음

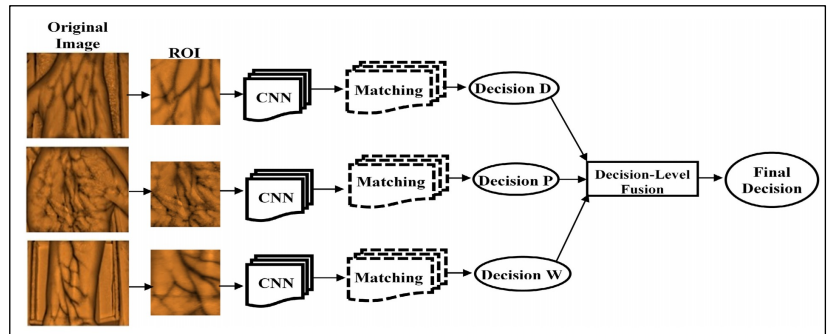
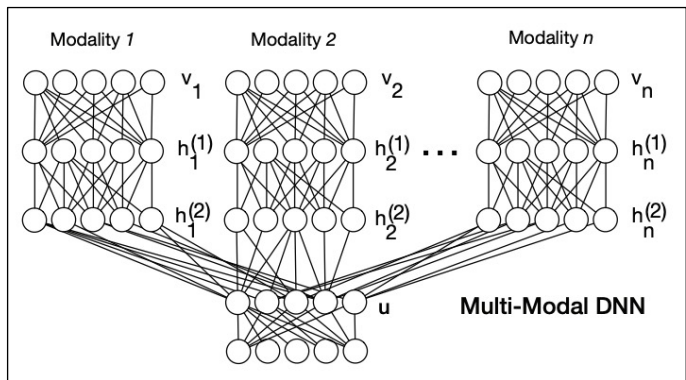


- Fawaz, Hassan Ismail, Benjamin Lucas, Germain Forestier, Charlotte Pelletier, Daniel F. Schmidt, Jonathan Weber, Geoffrey I. Webb, Lhassane Idoumghar, Pierre-Alain Muller, and François Petitjean. "Inceptiontime: Finding alexnet for time series classification." *Data Mining and Knowledge Discovery* 34, no. 6 (2020): 1936-1962.
- Karim, Fazle, Somshubra Majumdar, Houshang Darabi, and Shun Chen. "LSTM fully convolutional networks for time series classification." *IEEE access* 6 (2017): 1662-1669.

선행연구

Deep learning 기반의 multimodal 학습 방법

- 표현(초기)단계 결합 (Radu et al., 2018)
 - Modality-Specific Architecture Deep Neural Networks (MA-DNNs)
 - 여러 센서로 수집된 정보를 표현단계에서 결합시킴
 - 적은 표현력(정보량)을 가진 센서는 다른 센서가 포함한 복잡하고 풍부한 정보를 통해 보완되는 효과가 있음
- 결정단계 결합 (Toygar et al., 2020)
 - 신체의 여러 부위(multimodal) 정맥 이미지 데이터를 각각의 CNN 모델에 학습시키고, 결정 단계에서 앞서 사용된 모델들을 결합함
 - 다양한 생체 특정 데이터의 비교 실험에서 단일 부위만으로 학습한 모델보다 높은 정확도를 보임



- Radu, Valentin, Catherine Tong, Sourav Bhattacharya, Nicholas D. Lane, Cecilia Mascolo, Mahesh K. Marina, and Fahim Kawsar. "Multimodal deep learning for activity and context recognition." *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 1, no. 4 (2018): 1-27.
- Toygar, Önsen, Felix O. Babalola, and Yiltan Bitirim. "FYO: a novel multimodal vein database with palmar, dorsal and wrist biometrics." *IEEE Access* 8 (2020): 82461-82470.

플라스틱 사출성형 공정 데이터


- 울산광역시 소재의 자동차 부품 제조업체
- 자동차 앞유리 사이드 몰딩 사출성형 공정



공정 변수 조건		내용
독립변수	온도 관련	스크류/실린더, 수지, 금형, 건조, 유압, 주변 환경
	압력 관련	충진 압력, 보압, 배압(계량시 발생하는 압력), 이형 압력, 형개 압력, 형체 압력
	시간 관련	충진 시간, 보압 시간, 냉각 시간, 건조 시간
	속도 관련	사출 속도, 스크류 회전 속도, 형개 속도, 이형(이젝팅) 속도
	양 관련	계량, 이형량, 쿠션량
종속변수	불량 여부	Y: 양품, N: 불량품 (Labeled), 표시 없음 (Unlabeled)

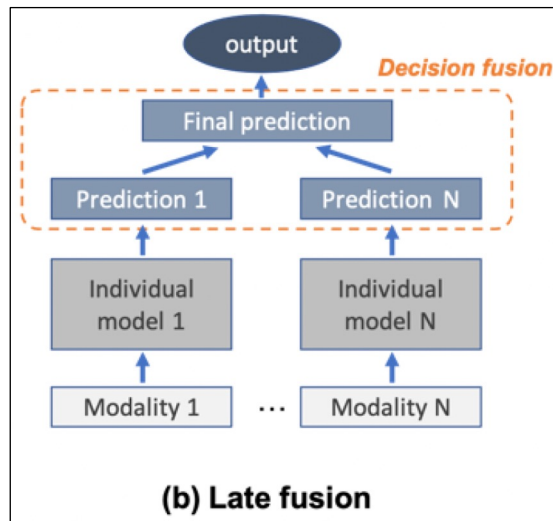
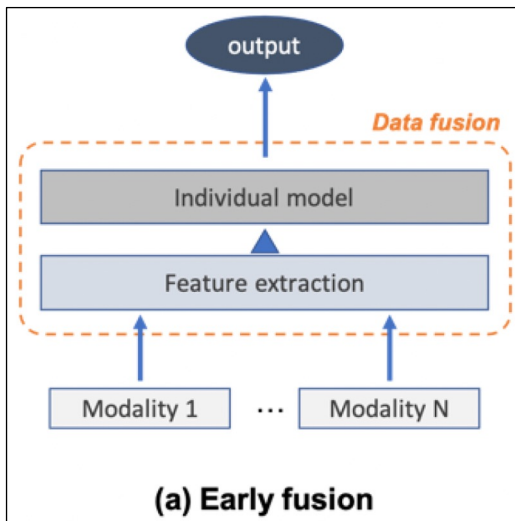
플라스틱 사출성형 공정 데이터

- 두가지 종류의 센서(stress-endurable sensor 및 general sensor)를 사용하여, 생산되는 제품 개별 불량 데이터 수집
- 수집 방식
 - Stress-endurable sensor : 0.2초마다 제품의 내부 온도 측정, 한 변수당 약 300개의 time stamp를 가진 시계열 데이터 생성
 - General sensor : 온도, 압력, 시간, 위치 등의 정보 수집, 한 변수당 1개의 값을 가진 데이터 생성
- 제품별 시계열 특성을 가진 데이터(multivariate time series data)와 일반 형태의 데이터(tabular data)를 모두 수집 가능



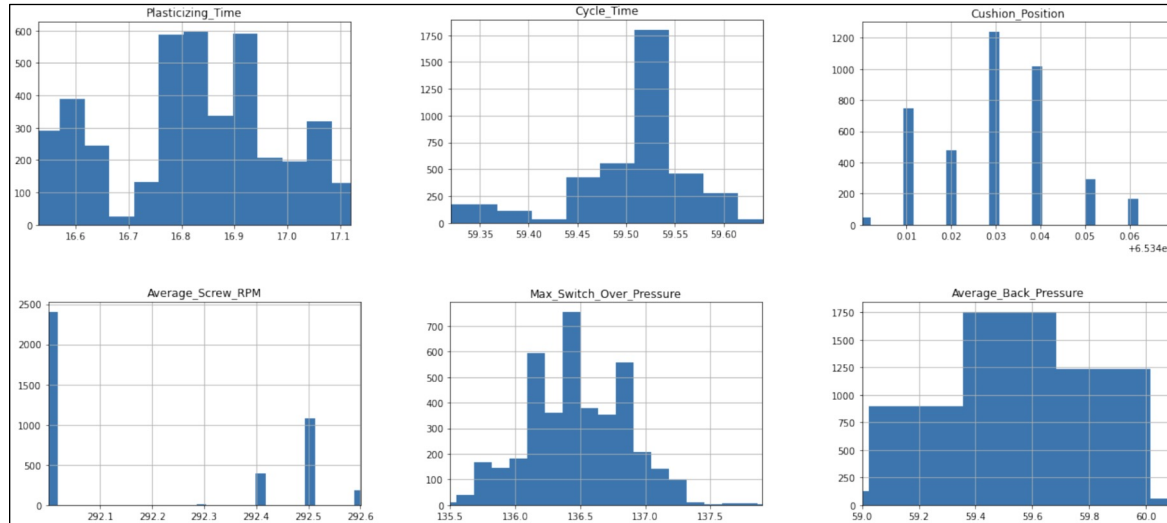
Multimodal 데이터를 활용한 학습 (Multimodal Learning)

- 한 공정에서 수집된, 특성이 다른 두 형태의 데이터(예: time series data, tabular data)를 결합하여 학습 모델 성능을 향상시킴
- 모델 결합 위치에 따라 크게 두가지로 구분함
 - Early fusion: 다른 종류의 데이터를 다른 학습 모델들을 표현단계(low-level, representation-level)에서 결합
 - Late fusion: 다른 종류의 데이터를 다른 학습 모델들을 결정단계(decision-level)에서 결합




데이터 전처리

- 공정 데이터 특성상, 센서 오작동 가능성이 있으므로 비이상적인 계측치를 가지는 제품 데이터를 제거함
- 신경망(neural network)에는 -1~1 범위 값이 학습에 용이하므로, 다양한 센서별 계측치의 범위를 동일하게 만드는 정규화(normalization) 작업 수행
- 사용 가능한 전체 23개의 변수가 모두 연속형(continuous) 변수임




데이터 종류별 적용한 예측 알고리즘

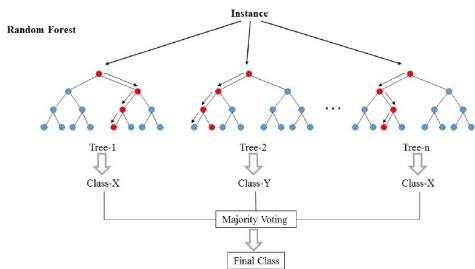
(1) 기존 방법론 (conventional approaches)




Support Vector Machine (SVM)




Naïve Bayes (NB)



Random Forest (RF)



Dynamic Time Warping (DTW)




LightGBM

데이터 종류별 적용한 예측 알고리즘

(2) Deep learning 기반 방법론 (deep learning-based approaches)

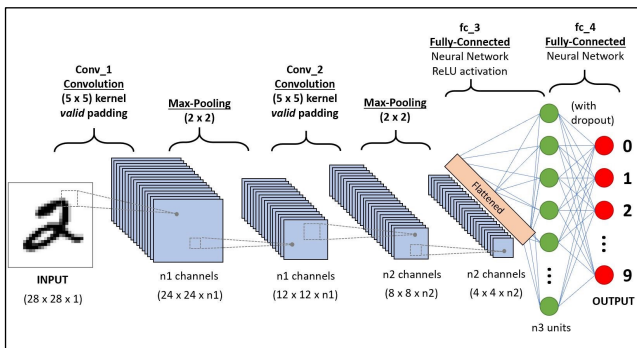
Multi-Layer Perceptron (MLP)

- 입력층과 출력층 사이에 다수의 은닉층을 쌓고, 비선형함수(sigmoid, ReLU 등)를 층마다 적용함
- 은닉층의 개수를 늘리거나 층별 노드의 개수를 늘림으로써 더욱 복잡한 함수를 근사할 수 있음




1-D Convolutional Neural Network (CNN)

- 이미지 처리 등에 활용되는 CNN 모델의 일종으로, 시계열 데이터를 1-D 형식의 벡터의 입력으로 처리하여 convolution filter를 반복적으로 적용함
- 다수의 convolution 연산을 수행함으로써 데이터에 내재한 유의미한 시계열적 패턴 등을 자동으로 학습함



Gated Recurrent Unit (GRU)

- 순환신경망(recurrent neural network)의 일종으로, 시계열 형식의 데이터 속 장기 의존적인 패턴을 학습하기 위한 내부 매커니즘(gate)이 존재함
- 데이터별 시간 순서대로 반복적으로 GRU 셀이 계산을 수행하며, 최종적으로 시계열 전체의 유의미한 패턴을 학습하게 됨.



모델 성능 평가 지표

정확도(accuracy), 정밀도(precision), 재현율(recall), F_1 score를 사용하여 모델의 성능 평가 진행

- 정확도: 모델의 예측 중 실제 양/불 여부와 일치하는 비율
- 정밀도: 모델이 불량으로 예측한 결과 중 실제 불량에 해당하는 비율
- 재현율: 전체 실제 불량 중 모델이 옳게 예측한 비율
- F_1 score: 정밀도와 재현율을 동시에 고려함 → 최종 비교를 위한 성능 지표로 선택

$$Accuracy = \frac{TrueNegatives + TruePositive}{TruePositive + FalsePositive + TrueNegative + FalseNegative}$$

$$precision = \frac{True\ Positives\ (TP)}{True\ Positives\ (TP) + False\ Positives\ (FP)}$$

$$recall = \frac{True\ Positives\ (TP)}{True\ Positives\ (TP) + False\ Negatives\ (FN)}$$

$$F_1 = 2 \cdot \frac{precision \cdot recall}{precision + recall}$$

예측 방법론 비교 (1): General sensor data

- 일반 형태의 데이터(tabular data)만 사용한 불량 예측 모델의 성능 평가
- 사용 모델 : SVM, NB, RF, LightGBM, MLP

Model	Precision	Recall	Accuracy	F ₁ score
SVM	0.3846	0.5000	0.9676	0.4347
NB	0.1470	0.5000	0.9154	0.2272
RF	0.5714	0.4000	0.9776	0.4705
LightGBM	0.8000	0.4000	0.9825	0.5333
MLP	0.8333	0.5000	0.9851	0.6250

예측 방법론 비교 (1): Stress-endurable sensor data

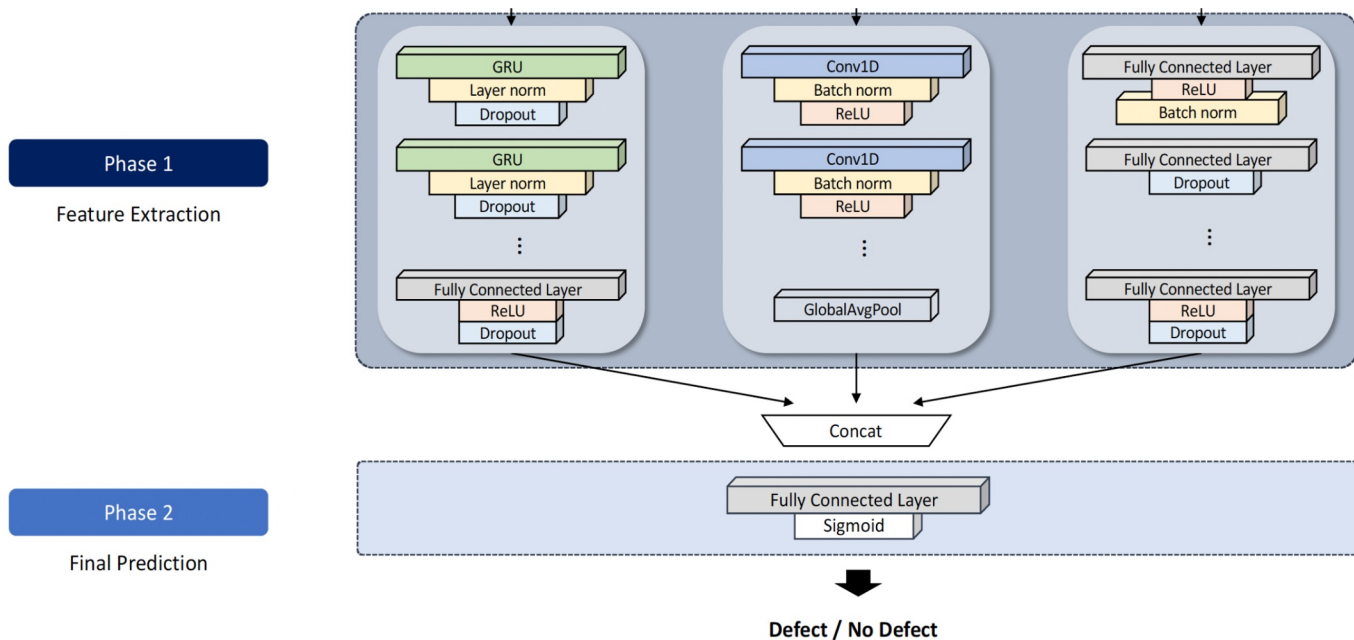
- 시계열 데이터(time series data)만을 활용한 불량 예측 모델 성능 평가
- 사용 모델 : SVM, RF, DTW, GRU, 1-D CNN

Model	Precision	Recall	Accuracy	F ₁ score
SVM	0.3333	0.3000	0.9676	0.3157
RF	0.3636	0.4000	0.9676	0.3809
DTW	0.2727	0.3000	0.9626	0.2857
GRU	0.4615	0.6000	0.9726	0.5217
CNN	0.4000	0.4000	0.9702	0.4000

[Proposed model] 데이터 융합을 위한 통합적 모델 (Multimodal deep learning-based fault detection model)

- 서로 다른 특성을 가진 여러 종류의 데이터를 동시에 활용함
- Early fusion multimodal learning 방식 선정

결정단계(decision-level)가 아닌, 알고리즘을 통해 변형된 형태(low-level)에서 데이터의 융합을 통한 불량 예측 모델의 표현력 제고



예측 방법론 비교 (2): Early fusion & Late fusion

- Type [A]

기존 방법론을 이용한 Late fusion multimodal model (결정 단계(decision-level)에서의 융합을 통한 예측 모델)

Type	Method	Precision	Recall	Accuracy	F ₁ score
[A]	SVM-SVM	0.5000	0.1000	0.9751	0.1666
	SVM-RF	0.4166	0.5000	0.9701	0.4545
	SVM-DTW	0.3076	0.4000	0.9626	0.3478
	NB-SVM	0.1470	0.5000	0.9154	0.2272
	NB-RF	0.3636	0.4000	0.9676	0.3809
	NB-DTW	0.2727	0.3000	0.9626	0.2857
	RF-SVM	1.0000	0.4000	0.9850	0.5714
	RF-RF	0.4375	0.7000	0.9701	0.5384
	RF-DTW	0.4117	0.7000	0.9676	0.5185
	LightGBM-SVM	0.3571	0.5000	0.9651	0.4166
	LightGBM-RF	0.4615	0.6000	0.9726	0.5217
	LightGBM-DTW	0.3571	0.5000	0.9651	0.4166

예측 방법론 비교 (2): Early fusion & Late fusion

- Type [B] : 기존 방법론 및 deep learning 기반 방법론을 이용한 Late fusion multimodal model
- Type [C] : Deep learning 기반 방법론을 이용한 Late fusion multimodal model

Type	Method	Precision	Recall	Accuracy	F ₁ score
[B]	SVM-GRU	0.4615	0.6000	0.9726	0.5217
	SVM-CNN	0.3636	0.4000	0.9676	0.3809
	NB-GRU	0.4615	0.6000	0.9129	0.5217
	NB-CNN	0.1842	0.7000	0.9154	0.2916
	RF-GRU	0.4666	0.7000	0.9726	0.5600
	RF-CNN	0.6666	0.6000	0.9825	0.6316
	LightGBM-GRU	0.5000	0.7000	0.9751	0.5833
	LightGBM-CNN	0.4615	0.6000	0.9726	0.5217
	MLP-SVM	0.8333	0.5000	0.9851	0.6250
	MLP-RF	0.4285	0.6000	0.9701	0.5000
	MLP-DTW	0.4000	0.6000	0.9676	0.4800
[C]	MLP-GRU	0.4666	0.7000	0.9726	0.5600
	MLP-CNN	0.5000	0.7000	0.9751	0.5833


예측 방법론 비교 (2): Early fusion & Late fusion

- Type [D] : 두개의 deep learning 기반 방법론을 이용한 Early fusion multimodal model (표현 단계(low-level)에서의 융합을 통한 예측 모델)
- Type [E] : 세개의 deep learning 기반 방법론을 이용한 Early fusion multimodal model (Proposed model)

Type	Method	Precision	Recall	Accuracy	F ₁ score
[D]	MLP+GRU	1.0000	0.5000	0.9876	0.6667
	MLP+CNN	0.6667	0.6000	0.9826	0.6316
[E]	MLP+GRU+CNN (proposed)	1.0000	0.6000	0.9900	0.7500

전체 결과 분석

- 한가지 종류의 데이터만을 사용한 불량 예측 모델보다 다양한 종류의 데이터를 융합한 불량 예측 모델의 성능이 더 높음
- 결정 단계에서의 융합 (late fusion) 보다 표현 단계에서의 융합(early fusion)을 활용한 모델의 예측 성능이 더 우수함
- 또한, 다양한 deep learning 방법론을 기반으로 통합적인 융합을 활용하는 것이 가장 좋은 성능을 냄



결론

- Multimodal deep learning-based fault detection model 개발을 통해, 플라스틱 사출성형 공정 데이터에서의 정확한 제품 불량 예측이 가능하였음
- 특히, 개발된 Multimodal deep learning-based fault detection model은 두 가지 종류의 센서(stress-endurable sensor 및 general sensor)를 통해 수집한 시계열 데이터(time series data)와 일반 데이터(tabular data)를 모두 사용하여, 제품 불량 예측의 성능을 높일 수 있었음
- 다양한 종류의 데이터를 결정단계에서의 융합(late fusion)이 아닌, 표현단계에서의 융합(early fusion)을 통해 예측 모델의 성능을 더 높일 수 있었음



THANK YOU

FIRST IN CHANGE