

Explainable Artificial Intelligence for Root Cause Failure Analysis in Manufacturing System: CNN & CAM

Yoon Sang Cho

2019. 04. 05

DMQA Seminar


목차

- 연구 개요
- 문제 정의
- 제안 방법론
- 실험 결과
- 결론 및 향후 연구

연구 개요

❖ 최근 여러 분야의 제조공정이 복잡해지고 고도화 되는 추세


➢ 가공: 공정 내 미세한 원인으로부터 발생하는 품질 불량을 탐지하기 어려운 실정



연구 개요

❖ 제조 공정 내 품질 예측 및 원인분석 중요성


- 품질 예측: 미세한 불량 원인을 조기에 탐지하여 제품불량 방지
- 원인 분석: 품질에 영향을 주는 최적 및 혐의 공정 조건을 반영하여 공정 수행



연구 개요

❖ 다채널 센서 데이터 분석 필요성

- 가공공정 내 다양한 공정 상황을 면밀히 반영할 수 있는 센서데이터 분석 필요
- Fault Detection & Classification(FDC) 기반 품질 예측 및 원인분석 방법론 연구




기존 연구


❖ 변수 선택이 가능한 회귀 모형, 트리 모형

- 다양한 공정별 센서 데이터 내 패턴 자체를 모델링 하기 어려움
- 대용량 데이터에 강건하고 시계열 특성을 효과적으로 반영하는 데 무리

회귀 모형



트리 모형




Decision Tree
Algorithms

본 연구에서는 다채널 센서데이터를 인지하기 적합한
딥러닝을 사용하여 불량률을 예측하고, 원인 분석 방법론을 소개 하고자 함.

문제 정의

❖ 다채널 센서 데이터 기반 불량률 예측 및 원인분석 방법론 제안

- 원인분석: 불량률(y)에 영향을 주는 변수(센서) 선택 및 원인 구간 탐색
- 분석 절차




CNN: Convolutional Neural Networks

CAM: Class Activation Mapping

분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집


- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터 수집

- 제품이 각 공정마다 이동하며 가공될 때 설비에서 발생하는 센서 데이터를 수집
- 제조공정 내 센서 데이터 수집과정



분석 데이터

❖ 제조공정 내 센서 데이터: 제품별 2차원 센서 데이터

- 설명변수(X): 공정별 센서데이터
- 반응변수(y): 불량률

		공정 1				...	공정 K				
	Timestamp	센서 1	...	센서 6	...	센서 P-5	...	센서 P	불량률		
제품 1	1								0		
	2										
	...										
	99										
	100										
제품 2	1								1		
	2										
	...										
	99										
	100										
...	...	...	...	...	...	...	...	...			
제품 999	1								54		
	2										
	...										
	99										
	100										
제품 1000	1								55		
	2										
	...										
	99										
	100										

분석 데이터


❖ 제조공정 내 센서 데이터: 제품별 2차원 센서 데이터

- 설명변수(X): 공정별 센서데이터
- 반응변수(y): 불량률

Time	센서1	센서2	센서3	...	센서P-2	센서P-1	센서P
1							
2							
	제품 1, 불량률 0						
99							
100							
1							
2							
	제품 2, 불량률 1						
99							
100							
1							
2							
							
99							
100							
1							
2							
	제품 N, 불량률 55						
99							
100							



불량률(y) 분포



예측모델: 합성곱 신경망


❖ CNN 회귀 모델 구조

- 관측치 단위: 각 제품 ID, 학습 단위: Time window
- Dense Layer: 1, Activation function: 'linear'

Time	센서1	센서2	센서3	...	센서P-2	센서P-1	센서P
1	제품 1, 불량률 0						
2							
99							
100							
1	제품 2, 불량률 1						
2							
99							
100							
1	제품 N, 불량률 88						
2							
99							
100							

학습 단위 (window)


CNN 회귀 모델




예측모델: 합성곱 신경망

❖ CNN 회귀 모델 구조

- 관측치 단위: 각 제품 ID, 학습 단위: Time window
- Dense Layer: 1, Activation function: 'linear'



CNN 회귀 모델



예측모델: 합성곱 신경망


❖ CNN 회귀 모델 구조

- 관측치 단위: 각 제품 ID, 학습 단위: Time window
- Dense Layer: 1, Activation function: 'linear'

Time	센서1	센서2	센서3	...	센서P-2	센서P-1	센서P
1							
2							
	제품 1, 불량률 0						
99							
100							
1							
2							
	제품 2, 불량률 1						
99							
100							
1							
2							
							
99							
100							
1							
2							
	제품 N, 불량률 88						
99							
100							

학습 단위
(window)

CNN 회귀 모델



예측모델: 합성곱 신경망


❖ CNN 회귀 모델 구조

- 관측치 단위: 각 제품 ID, 학습 단위: Time window
- Dense Layer: 1, Activation function: 'linear'

Time	센서1	센서2	센서3	...	센서P-2	센서P-1	센서P
1							
2							
	제품 1, 불량률 0						
99							
100							
1							
2							
	제품 2, 불량률 1						
99							
100							
1							
2							
							
99							
100							
1							
2							
	제품1000, 불량률 88						
99							
100							

학습 단위
(window)

CNN 회귀 모델



예측모델: 합성곱 신경망


❖ CNN 회귀 모델 구조

- 관측치 단위: 각 제품 ID, 학습 단위: Time window
- Dense Layer: 1, Activation function: 'linear'

Time	센서1	센서2	센서3	...	센서P-2	센서P-1	센서P
1							
2							
	제품 1, 불량률 0						
99							
100							
1							
2							
	제품 2, 불량률 1						
99							
100							
1							
2							
99							
100							
1							
2							
	제품 1000, 불량률 88						
99							
100							

학습 단위
(window)

CNN 회귀 모델




→ 분류모델과 다른점

예측성능: 합성곱 신경망

❖ 합성곱 신경망(Convolutional Neural Network, CNN)

- 학습데이터 및 검증용 데이터에서 충분한 모델 적합도 및 예측 성능을 확인
- 예측모델 기반 원인을 분석하는 데 당위성을 가짐.

학습데이터		검증데이터	
MAE	R2	MAE	R2
4.52	0.85	5.67	0.73




충분한 예측 성능 확인, 예측 값에 대한 원인분석 진행.

원인분석 방법론

❖ Class Activation Map(CAM) 활용

- 이미지 데이터 기반 CNN 모델에 적용되는 Visualization 기법
- 예측한 값에 대하여 추출된 특징들의 중요도를 확률적으로 표시
- 데이터 구조를 가장 잘 설명하는 마지막 Convolution layer 의 featuremap을 사용
- Global Average Pooling 이후 Fully Connected Layer로부터 예측 시 가중치를 적용




Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2921-2929).

원인분석 방법론

❖ Class Activation Map(CAM) 활용

- 이미지 데이터 기반 CNN 모델에 적용되는 Visualization 기법
- 예측한 값에 대하여 추출된 특징들의 중요도를 확률적으로 표시
- 데이터 구조를 가장 잘 설명하는 마지막 Convolution layer 의 featuremap을 사용
- Global Average Pooling 이후 Fully Connected Layer로부터 예측 시 가중치를 적용




Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2921-2929).

원인분석 방법론

❖ Class Activation Map(CAM) 활용

- 이미지 데이터 기반 CNN 모델에 적용되는 Visualization 기법
- 예측한 값에 대하여 추출된 특징들의 중요도를 확률적으로 표시
- 데이터 구조를 가장 잘 설명하는 마지막 Convolution layer 의 featuremap을 사용
- Global Average Pooling 이후 Fully Connected Layer로부터 예측 시 가중치를 적용




Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2921-2929).

원인분석 방법론

❖ Class Activation Map(CAM) 활용

- 이미지 데이터 기반 CNN 모델에 적용되는 Visualization 기법
- 예측한 값에 대하여 추출된 특징들의 중요도를 확률적으로 표시
 - 2차원 형태인 제품 및 공정별 센서데이터에 적용
 - CAM 내 높은 중요도를 갖는 부분을 중요변수 및 원인구간으로 설정




Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2921-2929).

원인분석 방법론

❖ Class Activation Map(CAM) 활용

- 이미지 데이터 기반 CNN 모델에 적용되는 Visualization 기법
- 예측한 값에 대하여 추출된 특징들의 중요도를 확률적으로 표시
 - 2차원 형태인 제품 및 공정별 센서데이터에 적용
 - CAM 내 높은 중요도를 갖는 부분을 중요변수 및 원인구간으로 설정



Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2921-2929).

원인분석 방법론


❖ CNN 및 Class Activation Map(CAM) 적용

- CNN학습 및 각 관측치 마다 CAM 적용
- 원인분석: (1) 변수선택, (2) 원인 구간 선택


제품1 데이터

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11

학습된 CNN* 회귀 모델



제품 1에 대한
Class Activation Mapping




원인분석 방법론

❖ CNN 및 Class Activation Map(CAM) 적용

- CNN학습 및 각 관측치 마다 CAM 적용
- 원인분석: (1) 변수선택, (2) 원인 구간 선택

제품1에 대한 CAM

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11



→ 제품 1을 불량률 0으로 예측했다면 어느 부분을 보고 예측했는지 확률적으로 높게 표시


원인분석 방법론

❖ CNN 및 Class Activation Map(CAM) 적용

- CNN학습 및 각 관측치 마다 CAM 적용
- 원인분석: (1) 변수선택, (2) 원인 구간 선택

제품1에 대한 CAM

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11



→ 제품 1을 불량률 0으로 예측했다면 어느 부분을 보고 예측했는지 확률적으로 높게 표시

원인분석 방법론

❖ CNN 및 Class Activation Map(CAM) 적용

- CNN학습 및 각 관측치 마다 CAM 적용
- 원인분석: (1) 변수선택, (2) 원인 구간 선택

제품별
2차원 데이터

제품1

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11

제품2


Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11

...



제품 1000

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11


학습된 CNN 회귀 모델
및 Class Activation Mapping



제품별
CAM



...



원인분석 방법론

❖ CNN 및 Class Activation Map(CAM) 적용

- CNN학습 및 각 관측치 마다 CAM 적용
- 원인분석: (1) 변수선택, (2) 원인 구간 선택

제품별
2차원 데이터

제품1

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11

제품2


Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11

...



제품 1000

Time	센서1	센서2	센서3	센서4	센서5	센서6	...	센서P
1	12	24	92	15	8	74	...	11
2	21	21	07	51	12	11	...	12
3	12	24	92	15	8	74	...	11
4	21	21	07	51	12	11	...	12
5	65	11	10	3	7	07	...	13
...	...	...	...	...	...	...	...	...
96	65	11	10	3	7	07	...	13
97	21	21	07	51	12	11	...	12
98	65	11	10	3	7	07	...	13
99	21	21	07	51	12	11	...	12
100	12	24	92	15	8	74	...	11


학습된 CNN 회귀 모델
및 Class Activation Mapping



제품별
CAM




...



원인분석 방법론

❖ CNN 및 Class Activation Map(CAM) 적용


- CNN학습 및 각 관측치 마다 CAM 적용 후 합산 → Global-CAM
- 원인분석: (1) 변수선택, (2) 원인 구간 선택



원인분석 방법론

❖ CNN 및 Class Activation Map(CAM) 적용


- CNN학습 및 각 관측치 마다 CAM 적용 후 합산 → Global-CAM
- 원인분석: (1) 변수선택, (2) 원인 구간 선택



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석

- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의




→ Column별 확률을 모두 더한 값을 변수(센서) 중요도로 정의

원인분석 방법론

❖ Global-CAM 기반 원인분석

- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원지구간으로 정의




→ 센서 ID 120 부근 가장 중요했던 20개 변수를 선택

센서 1	센서 2	센서 3	센서 4	센서 5	...	센서158	센서159	센서160	센서161	센서162
10100.8	10100.8	10100.8	10100.8	10100.8	...	29475.9	29475.9	29475.9	29475.9	29475.9

원인분석: CNN 변수선택

❖ 상위 20개 주요 변수선택

➤ 변수 중요도 분포 및 선택된 변수(센서) ID



CNN 및 Global-CAM


주요변수	
센서	108
센서	109
센서	110
센서	111
센서	112
센서	113
센서	114
센서	115
센서	116
센서	117
센서	118
센서	119
센서	120
센서	121
센서	122
센서	123
센서	124
센서	125
센서	126
센서	127

원인분석: CNN 변수선택

❖ 선택된 변수들의 대표(Best, Worst) 센서 데이터 분석

불량률이 가장 '적었던' 제품에 대한 센서데이터
불량률이 가장 '높았던' 제품에 대한 센서데이터

➤ 동일한 경로 및 지시 조건에서 발생한 시그널 데이터




원인분석: CNN 변수선택

❖ 선택된 변수들의 대표(Best, Worst) 센서 데이터 분석

불량률이 가장 '적었던' 제품에 대한 센서데이터
불량률이 가장 '높았던' 제품에 대한 센서데이터

➤ 동일한 경로 및 지시 조건에서 발생한 시그널 데이터




원인분석 방법론

❖ Global-CAM 기반 원인분석

- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의


Global-CAM



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석


- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의



원인분석 방법론

❖ Global-CAM 기반 원인분석

- ① 변수선택: column별 확률들을 합한 값을 변수 중요도로 정의
- ② 원인 구간 선택: 선택된 변수 내 높은 확률 값을 보이는 구간을 원인구간으로 정의




원인분석: CNN 원인구간 선택

❖ 선택된 변수들의 대표(Best, Worst) 센서 데이터 분석


➤ 동일한 경로 및 지시 조건에서 발생한 센서 데이터

불량률이 '적었던' 100개 제품에 대한 센서데이터
불량률이 '높았던' 100개 제품에 대한 센서데이터

센서 123




센서 126



결론 및 향후 계획

❖ 다체널 센서데이터 기반 제조공정 내 원인분석 방법론

- ① 분석 데이터: 2차원 형태 다변량 시계열 데이터 구축
- ② CNN 회귀 모델: 연속형 반응변수(불량률)를 예측하는 CNN 모델 디자인
- ③ Global-CAM: 학습된 CNN 회귀 모델에 **Global-CAM**을 도출
- ④ 원인분석방법론: **Global-CAM** 을 기반으로 한 원인분석



결론 및 향후 계획

❖ 요약

- 제안방법론: CNN 기반 불량률 예측 및 원인분석 방법론을 제안
- 충분한 모델 설명력과 검증용 데이터에 대한 예측 성능 확인
- Global-CAM개념을 활용하여 중요변수 선택한 결과 LASSO와 부분적으로 일치
- 선택된 변수(센서)와 원인구간에 해당하는 대표 패턴 도출

❖ 기대효과

- 사전조치: 정확한 품질 예측으로 공정 수행 후 불필요한 계측을 줄이는 데 기여
- 사후조치: 불량 원인 센서 및 구간을 시각적으로 보여주며 우선적 조치
- 향후 공정 파라미터를 조절 시 기준이 되는 자료로 활용하며 안정된 공정 수행 유지

❖ 향후 계획

- 기타 XAI 알고리즘과 성능 비교: RNN + Attention Mechanism
 - 예측 값에 대한 원인 시점 도출(실험중)

감사합니다.

Q & A

별첨

원인분석 방법론

❖ Class Activation Map(CAM)

- f_k : k 채널의 값들 중 (x,y) 에 위치한 값(GAP를 취하기 전에 위치한 feature map)
- F_k : GAP를 취한 값
- S_c : Softmax
- P_c : Softmax 확률값

$$\text{CAM} \rightarrow M_c(x, y) = \sum_k w_k^c f_k(x, y)$$

$$\begin{aligned} S_c &= \sum_k w_k^c F_k \\ &= \sum_k w_k^c \sum_{x,y} f_k(x, y) \\ &= \sum_k \sum_{x,y} w_k^c f_k(x, y) \end{aligned}$$

$$P_c = \frac{\exp(S_c)}{\sum_k \exp(S_c)}$$

$$S_c = \sum_{x,y} M_c(x, y)$$