

# 산업제어시스템의 운전 환경에서 양상을 순환 신경망을 이용한 비정상 공정 탐지

전남대학교 대학원  
정보보안협동과정  
박사과정 김효석

# 목차

I. 서론

II. 관련 연구

III. 앙상을 순환 신경망을 이용한 비정상 공정 탐지

IV. 실험 및 분석

V. 결론 및 향후연구

# I. 서론

## 1-1. 연구 배경 및 목적

- 사이버 물리 시스템을 통해 현실 세계의 사람·센서·액추에이터 등을 인터넷에 연결하여 제어할 수 있는 환경으로 전환
- 운영 환경의 변화는 공격 접점(Attack Surface)을 확대함으로 산업제어 시스템을 대상으로 하는 사이버 위협의 증가
- 물리적 공정을 연결하는 구간에서 수집 가능한 운전 데이터를 통해 비정상 공정을 탐지하여 운영 가용성·안전성 보장

연도	제작	내용
2010	온조류(이란)	스투кси넷(Stuxnet) 악성코드를 통해 원자력 소PC에 침입, 원자력 제어 시스템을 조작하여 원자로 불안정화.
2011	생수도(한국)	스토커스 시스템의 ID, 비밀번호를 탈취하고 원자로 제어 펌프 시스템을 공격하여 기동 중단.
2012	점유-惊叹(사우디아라비아)	샤먼(Shamoon) 악성코드-공격으로 대규모 PC 3만 대가 살해 및 디트워크 미친.
2014	제칠고(독일)	제어 시스템의 파파로 풍동으로 제어 불능.
2015	전력망(우크라이나)	블랙아웃(Black Energy) 악성코드를 통해 제어 시스템을 종단하여 6시간 동안 22만여 가구 전자 빛살.
2016	온조류(독일)	온전·온수제어 USB 사용 중 악성코드 침입으로 운영 중지.
2017	사-동치(한국)	와나크리트 랜섬웨어(WannaCry Ransomware)에 살해되어 2일 동안 상선 및 조류 중단.
2017	비-신-화-이-언(미국)	미 신경 핑킹으로 끌다스의 비상 사이언이 15시간 동안 기동.
2017	화학-동장(사우디아라비아)	트리톤(TRITON)-공격으로 석유-화학-공정 시설의 기동 중단.
2018	비-도-체-상-선(한국)	상선 설비 일그레이드 중 USB를 통하여 악성코드 유통으로 공격 기동 중단, 손실 초점 약 110억 원.
2019	암로-비-급-상-선(노르웨이)	해상화물에 침입하여 유류, 미국 유로-공정이 미끄러지고 폭-추까지 9개월 이상의 시간이 걸려 회복도 절실했대로 복구하는데 6년.
2019	밸전조(미국-수영권)	수력발전소 설비가 사이버 공격을 받으면서 중단(Shutdown), 19개 주의 전력 공급이 차단.
2020	사-동-치(한국)	Ekans 악성코드 침입으로 사내 네트워크로 침입하여 상선-레인 관리 시스템 장애, 차량 출입 중단.

## 1-2. 연구 내용 및 범위

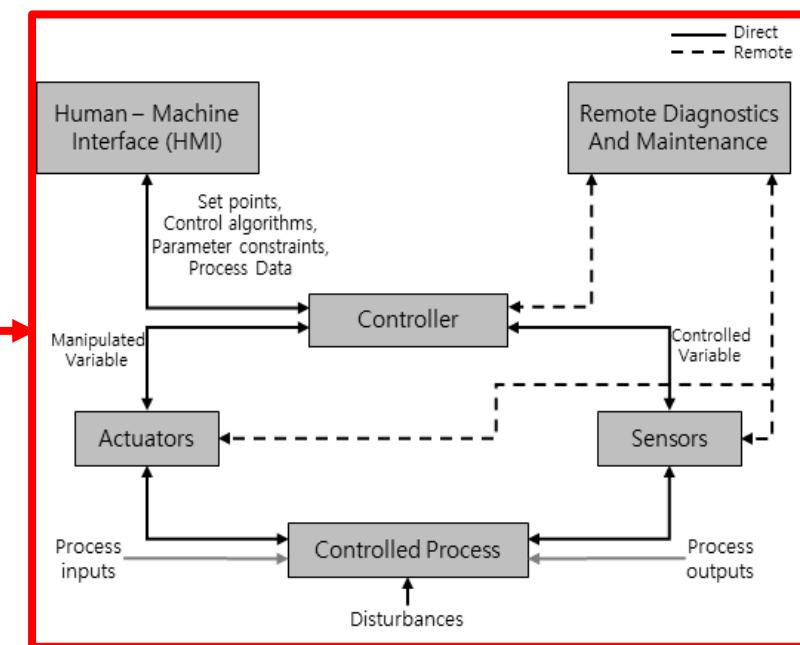
- 산업제어시스템 보안 및 비정상 탐지 연구 조사
- 공개 데이터셋 비교를 통한 데이터 수집
- 산업제어시스템 운영 및 구성요소에 따른 운전 데이터 해석
- 인공지능 모델 학습을 통한 문제 해결 방법 선정(회귀, 예측 모델)
- 산업제어시스템 환경을 고려한 비정상 탐지 모델 생성
- 탐지 모델에서 추출한 예측오차를 통한 비정상 공정 도출

## 1-1. 산업제어시스템 참조 아키텍처 및 구성요소



- 물리적 설비는 Level 0 위치 (액추에이터, 센서 등)
- 물리적 설비의 논리제어장치 (PLC 등)는 Level 1 위치
- 운전데이터는 Level 1~2에서 해석  
(OPC-UA Gateway, PI System 등)

- 산업용 프로토콜 사용  
(Modbus, S/comm, Ethernet/IP(Industrial Protocol), ...)
- 순환 명령 구조  
(센서 측정(+운전자 명령) -> 컨트롤러 해석 / 명령 -> 프로세스 조작)



## II. 관련 연구

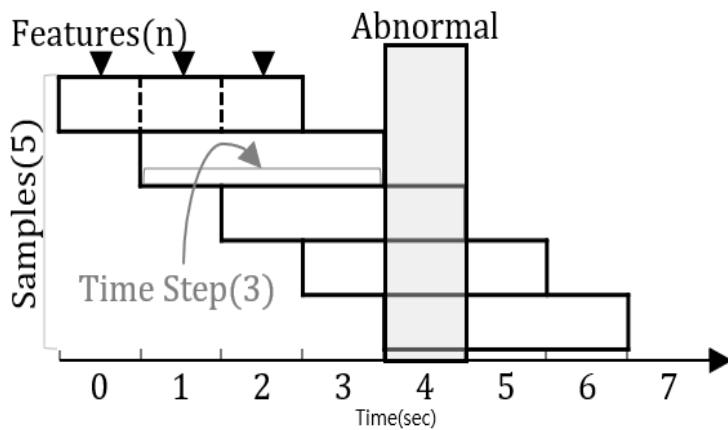
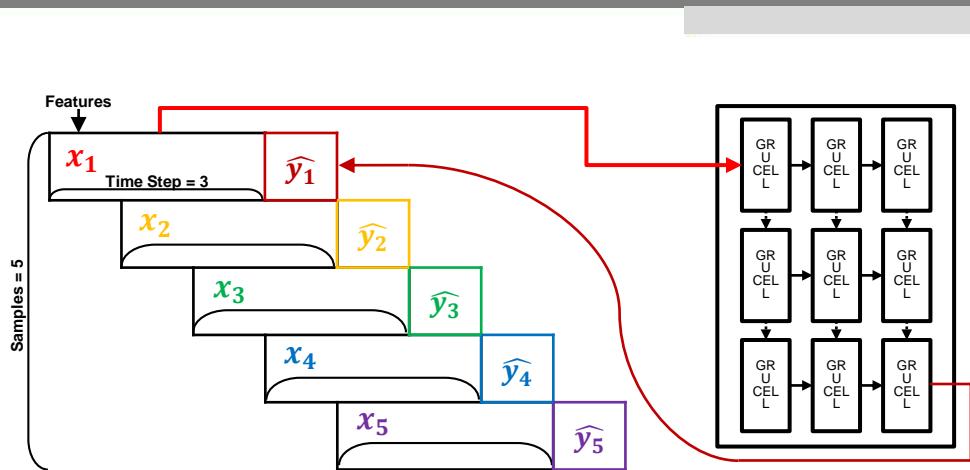
## 1-2. 산업제어시스템 보안 요구사항

- KS 표준의 보안 요구사항 중 시스템 무결성(“통신 무결성”, “결정론적 출력”)과

이 벤트 적시 대응(“지속적인 모니터링”)에 해당하며, 정상 작업의 연속성을 유지 및 보장하여야 함.

## 2-1. 시계열 데이터와 순환 신경망

- 운영 구조에 따라 모든 Point는 현재 값은 다음 값에 영향을 주고, 시간에 흐름에 따라서 변한다.
- 순환 신경망은 시퀀스의 길이에 상관없이 유연한 구조이며, 연속적인 데이터 처리에 적합하다.



```
'input' : tensor([[9.9751e-01, 5.7956e-01, 4.3588e-01, ..., 8.6484e-01, 8.8776e-01, 2.5674e-04],
                  [9.9751e-01, 5.7918e-01, 4.3588e-01, ..., 8.6795e-01, 8.8535e-01, 2.5674e-04],
                  [9.9751e-01, 5.8562e-01, 4.3588e-01, ..., 8.7054e-01, 8.8396e-01, 2.5674e-04],
                  ...,
                  [9.9751e-01, 5.6099e-01, 4.3588e-01, ..., 8.7520e-01, 7.5754e-01, 2.5674e-04],
                  [9.9751e-01, 5.6043e-01, 4.3588e-01, ..., 8.7281e-01, 7.5583e-01, 2.5674e-04],
                  [9.9751e-01, 5.5416e-01, 4.3588e-01, ..., 8.7026e-01, 7.5406e-01, 2.5674e-04]]),
'predict': tensor([9.9744e-01, 5.5319e-01, 4.3593e-01, 4.1077e-01, 5.2651e-01, 9.9953e-01,
                  9.9383e-01, 5.6975e-01, 9.9968e-01, 9.9966e-01, 2.7198e-04, 1.6308e-01,
                  1.6238e-01, 3.9501e-01, 6.1492e-01, 9.8606e-01, 9.9624e-01, 3.7718e-01,
                  4.2834e-01, 2.6622e-01, 3.2905e-01, 5.0664e-01, 2.8673e-01, 2.8645e-01,
                  1.8055e+00, 4.7633e-02, 9.6405e-02, 2.8687e-02, 4.3906e-01, 6.1533e-01,
                  5.1694e-01, 3.8916e-01, 7.2084e-01, 3.5193e-01, 3.4857e-01, 5.8513e-03,
                  1.5504e-03, 8.6702e-01, 7.5447e-01, -3.9041e-05])
```

## 2-2. 양상을 학습 및 모델 결합

### - Voting

- 각 모델의 결과(0,1,0,2,0,1)를 다수결 투표를 통해 최종 결과값(0)을 도출한다.

### - Bagging

- 중복을 허용한 상태로 랜덤 샘플링한 데이터를 학습(Bootstrap), 학습 결과를 평균하여 최종 결과(Aggregation)를 도출

### - Boosting

- 선형 모델의 결과 중 잘못 분류된 데이터에 높은 가중치를 주어 후행 모델에서 재 학습하여 오류를 개선

### - Stacking

- 다양한 이기종 모델에서 얻은 결과를 다음 모델의 학습 데이터로 사용하고 최종 모델에서 예측

### - Buzzer

- 본 논문에서 사용된 “Buzzer”는 학습데이터 순서를 랜덤으로 모두 학습하며 서로 다른 타임스텝을 갖는 내부모델을 생성한다. 내부 모델은 오탐을 억제한 상태이며, 미탐지에 대해 상호보완함

- 좋은 모델을 찾는 것 보다, 높은 탐지 성능을 도출하는 것이 목표

- 우승자를 찾는 것이 아닌, 되도록이면 다 같이 모든 문제를 맞출 수 있도록 함

- 제안 모델은 비정상 상황에 누구든 하나리도 탐지하면 비정상으로 간주하여 성능을 높임

- 오탐이 없으면, 상대적으로 미탐 발생률이 높을 수 있으므로 해당 내용을 개선.

- 오탐이 억제된 모델의 특성상, 비정상으로 탐지 시 정확도가 아주 높음.



출처: <http://www.koreaitimes.com/news/articleView.html?idxno=63684>

## 3-1. 산업제어시스템 데이터셋

No	Dataset	Type	Protocol	Data	
				Format	Anonymization
1)	SecureWaterTreatment(SWaT)	Water Treatment	Modbus/Ethernet/IP	csv	X
2)	KSCyberAttack Datasets	PowerSystem, Gas Pipeline, Water, EMS	Modbus	csv, arf	△
3)	SCADANetwork Datasets	SCADA	Modbus	pcap	X
4)	HAI Dataset	PowerSystem (Boiler, Turbine, Water)	OPC-UA (Modbus, SI, ...)	csv	X

- HAI Dataset을 제외한 기존 데이터셋의 문제
  - 시간 동기화
  - 비정상 상태의 라벨링
  - 환경에 따른 공격의 다양성



Release Version	Data Points /sec	Normal		Abnormal	
		Interval (hour)	Size (MB)	Attack Count	Interval (hour)
IHA2000 (IHA10)	59	177	225	38	123
IHA2103 (IHA20)	78	322	41	50	112

## II. 관련 연구

### 4-1. 산업제어시스템 비정상 탐지 연구 동향

비정상 탐지 모델의 성능 비교 연구

연구자	년도	비교 모델	메이터셋	주요내용
J.Inoue et al.	2017	DNN, LSTM, one-class SVM	SWaT	SVM은 정상 범위를 벗어나는 값을 탐지하는데 과적이나 오탈지를 보고하는 경우가 있으며, 전반적으로 DNN의 성능이 좋음.
SDD Anton et al.	2018	SVM, Random Forest, K-NN, K-means clustering	SCADA network	여러 모델을 사용하여 비정상 탐지에 적합한 모델을 찾아, SVM과 Random Forest가 다른 데이터에 대해서도 잘 수행됨.
SDD Anton et al.	2018	Matrix Profile, SARIMA, LSTM	SCADA network	데브리스 프로파일과 계절성 바이러스 모형은 전위법으로 적절하게 탐지하였고, LSTM은 하루시간이 오래 걸렸지만 데이터의 특성이 크게 의존하는 부분이 있으므로 다른 알고리즘과 함께하여 더 나아더의 적절한 통합이 필요함.
G.Benmeli et al.	2019	SVM, Random Forest, K-NN, One-class SVM, Autoencoder	SWaT	Random Forest와 K-NN은 탐지 정확도가 높게 축성되었으며, 비지도 학습은 대체로 훈련 기간의 압축과 주제 추출에 유익한 것으로 나타남.
S Mokhtari et al.	2021	K-NN, Decision Tree, Random Forest	HAI	정상과 비정상 데이터의 결합형 문제를 SMOTE를 통해 과적합 문제를 해결한 후, 학습하였다. Random Forest가 가장 좋은 성능을 보임.
DKim et al.	2021	SAE, SVDD	HAI	SAE(Stacked Autoencoder), SVDD(Deep Support Vector Data Description)를 비교하였을 때, SAE 모델이 SVDD에 비해 좋은 성능을 보임.

비정상 탐지 기법 연구

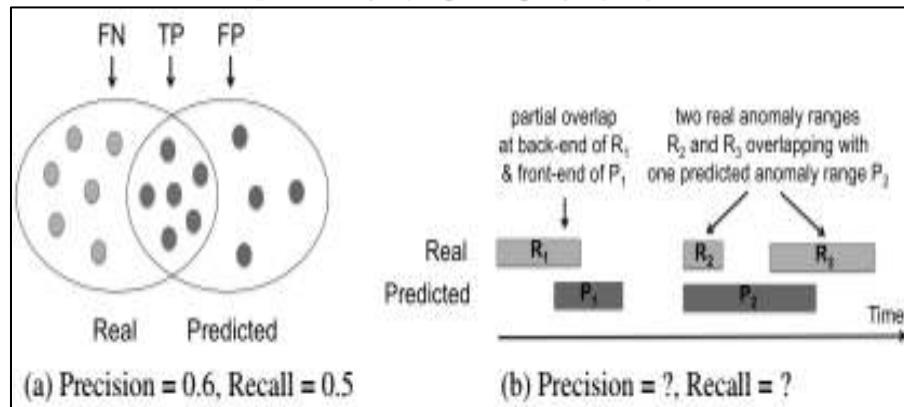
연구자	년도	모델·기법	메이터셋	주요내용
J.Goh et al.	2017	LSTM-RNN, 차이기	SWaT	비정상 예측에 대한 연속값과 실제값의 차이기-특정 인덱스의 초과여부로 판별함.
M.Kravchik et al.	2018	CNN, Z-Score	SWaT	이전 전자에 걸친 예측값과 실제값의 차를 계산한 후, 각 예측 및 실제 값 사이의 절대값을 도출하고, 각 특성을 정규화하여 예측 오류의 가능성이 내부 Z-Score를 통하여 비정상 탐지 함.
D.Li et al.	2019	LSTM-RNN, GAN	SWaT	정상 조건에서 LSTM을 사용하여 대량의 시계열 데이터를 파악하고, GAN을 통하여 새 조건 데이터로 생성된 데이터의 진위를 판별하여 비정상 탐지 함.
J.Kim et al.	2019	Seq-to-Seq	SWaT	정상 데이터셋과 충돌하는 비정상 데이터가 전에 관찰된 값을 사용으로 예측값을 도출하고 예측한 값과 실제값의 차이기-비정상 탐지의 경우 사용함.
Y.Hu et al.	2019	CNN, 드롭아웃-공통 특징-비교 연결	KDD 99, SCADA network	IT-도보-모드-특징은 KDD CUP 99 데이터셋에서 ICS-드롭아웃-특징은 SCADA 데이터셋에서 충돌하여 두 모드의 특징 데이터에 대한 공통된 특징을 비교하고 연결하여 기계학습과 같은 지식 관리를 증명함.
Xingchao Bian	2021	GRU, 차폐-수동식	HAI	GRU를 통하여 예측을 통하여 비정상 탐지하고, 주파수-분석을 통하여 인체값을 통적으로 학습하는 방법을 사용함.
YGKim et al.	2021	SOMAD, 예측모형-비교	SWaT, HAI	SOM(Self-Organizing Map)-을 이용하여 예측모형-비교-학습-그림 그리기-오류-판단의 과정을 축정하여 기계학습을 통하여 비정상을 탐지.

## 4-2. 선행 연구 고찰 및 제한점

- 선행 연구 고찰
  - 학습 방법: 지도 학습, 비지도 학습
  - 문제 정의: 분류, 회귀 문제
  - 탐지 기법: 예측 모형, 누적 모형, 정상 데이터의 일 반 모형 등의 경계(임계값) 설정
  - 성능 평가: 분류 성능 평가 지표를 사용함
- 제한점
  - 이 기종 모델의 탐지 모델 및 탐지 기법에 따라 **비정상 탐지 내용이 상이함**(단일 모델의 한계)
  - **비정상 탐지의 타켓이 전체 공정으로 제한되어 있음**
  - 성능 평가 시, **오탐지에 대한 언급이 부족함**(현실성을 고려하여 오탐지 발생 량 및 기간을 분석해야 함)
  - 분류 모델의 경우, **새로운 유형의 공격을 탐지하기 어려움**
  - 회귀 모델의 경우, **회귀 모델(+산업 환경)에 적합한 성능 평가 지표를 사용해야 함**

## 4-3. 비정상 탐지 성능 평가지표

분류 / 회귀 성능평가의 차이

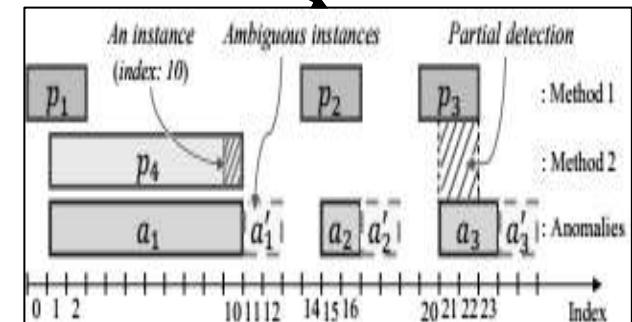


Point Based

Confusion Matrix		Actual	
		Positive	Negative
Predicted (Detected)	Positive (비정상)	True Positive	False Positive
	Negative (정상)	False Negative	True Negative

Classification Evaluation Metrics

Range Based



TaPR (Time-series Aware Precision and Recall)

### III. 앙상을 순환 신경망을 이용한 비정상 공정 탐지

#### 1-1. 비정상 탐지 연구에 대한 고려사항

- 실험 데이터는 HAI 20.07, 21.03이며, 성능평가지표는 TaPR을 사용한다.

HAI 21.03을 기준으로 작성하며, HAI 20.07은 특징 선택 및 앙상을 구성 시에 HAI 21.03과 비교를 위해 실험한다.

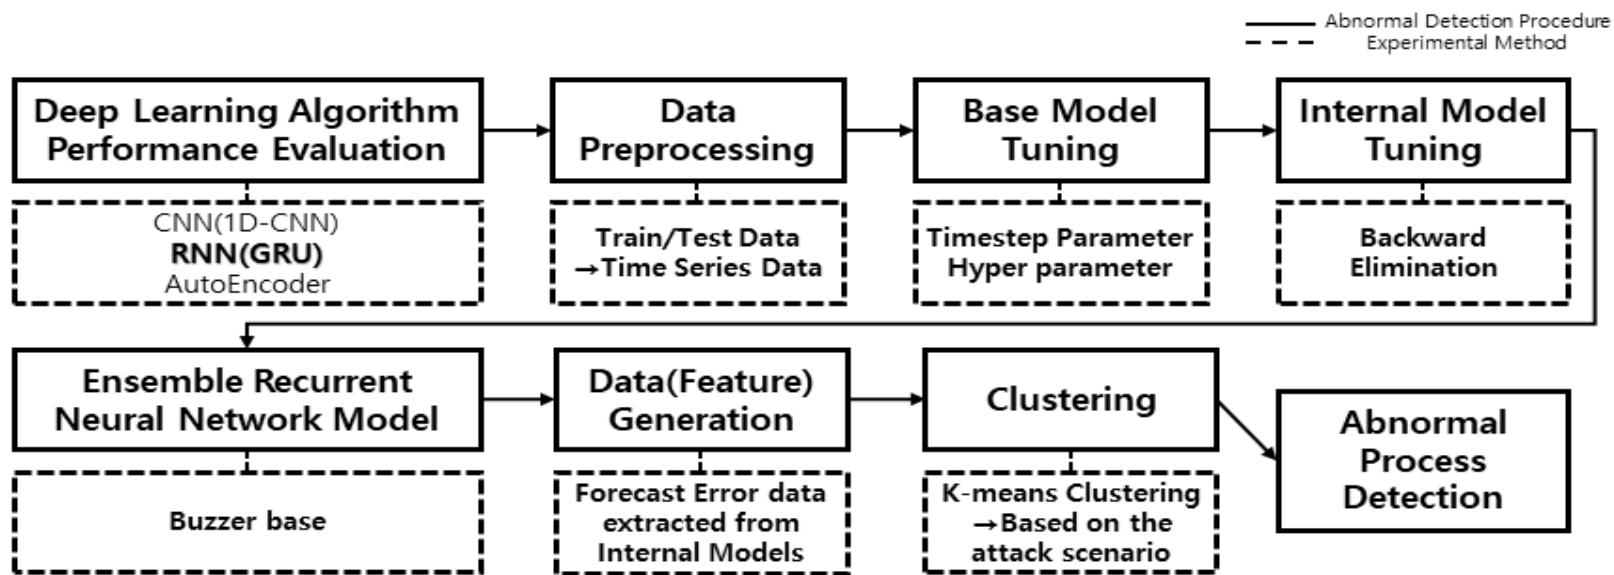
또한, 분류 성능평가지표를 일부 포함한다.

- 데이터 구조는 시계열 데이터를 기반으로 한다.
- 정상 데이터만을 학습한다.
- 학습에 사용되는 특징은 운전 데이터의 포인트(Point)를 변경하지 않거나 본래의 데이터로 복원이 가능하도록 한다.
- 산업제어시스템의 구성요소 변경 및 교환 등을 고려하여 모든 포인트를 포함하여 비지도 학습 기반 회귀 예측 모델을 사용한다.
- 학습된 모델의 예측값과 실제값의 차이를 평균하여 정상과 비정상을 식별한다.
- 탐지 모델은 되도록 오탐이 발생하지 않도록 임계값을 조정한다.
- 비정상 탐지 후 앙상을 모델을 구성하는 내부 모델들의 평균예측오차를 통해 비정상 탐지를 유발시킨 공정을 도출한다.

### III. 앙상블 순환 신경망을 이용한 비정상 공정 탐지

#### 2-1. 비정상 공정 탐지 전체 흐름도

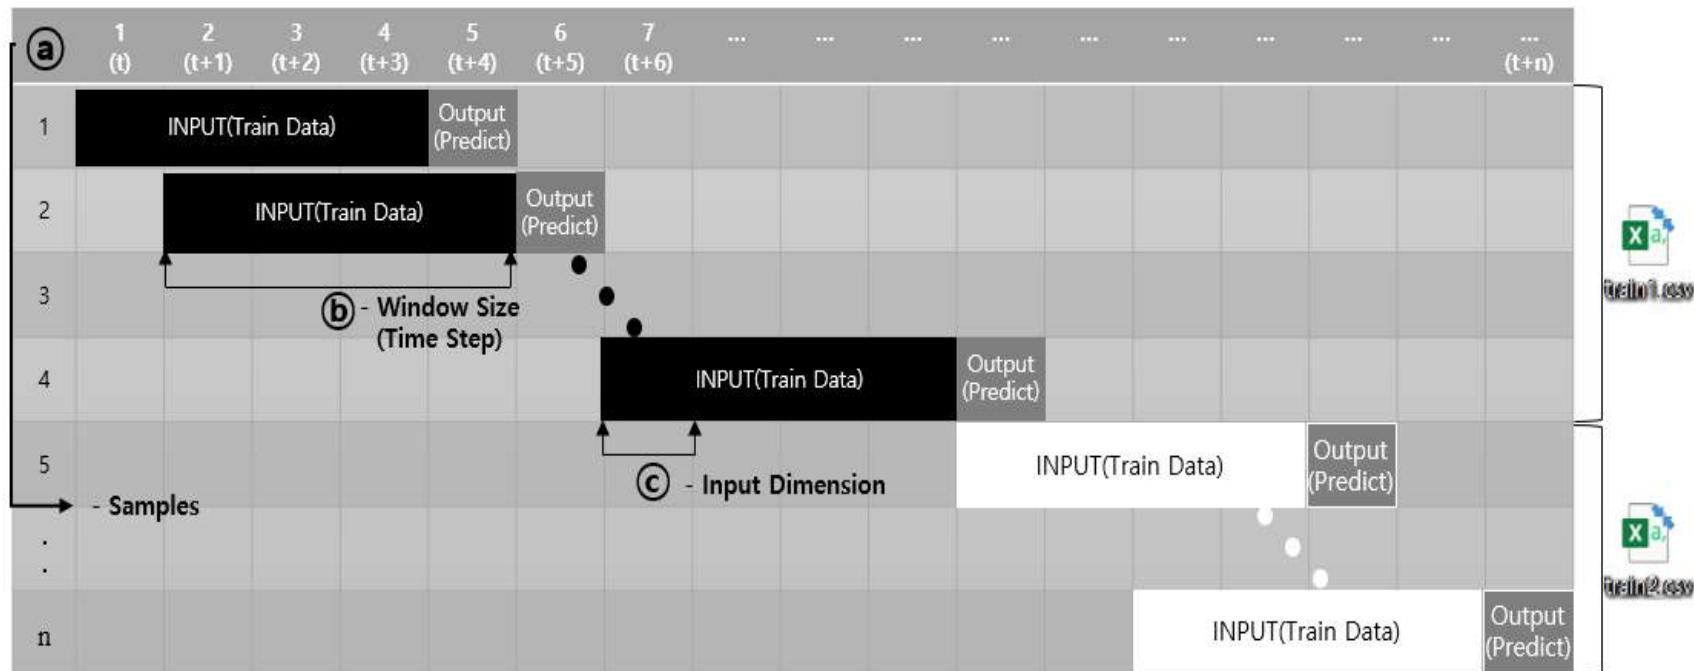
- 학습 데이터 전처리
- 순환 신경망을 기반으로 하는 기초, 내부, 앙상블 모델 학습 후 비정상 탐지
- 앙상블 순환 신경망 모델의 예측 오차 데이터 생성
- 공격 시나리오 기준으로 평균 예측 오차 데이터를 K-평균 클러스터링하여 비정상 공정 도출



### III. 앙상블 순환 신경망을 이용한 비정상 공정 탐지

#### 3-1-1. 학습데이터 전처리

- Null/NaNs 값 확인
- 데이터 스케일링
  - Min-Max Normalization
- 시계열 데이터로 변환



### III. 앙상블 순환 신경망을 이용한 비정상 공정 탐지

#### 3-1-2. 기초 모델 생성(모델 튜닝)

- 파라미터
  - TimeStep
- 하이퍼파라미터
  - Cell, Layer, Epoch, ...

No	Parameter	Range	Select
1	Time Step	29 ~ 119	55 ~ 59
2	RNN	LSTM, GRU	Stacked GRU
3	Cell(Node)	100 ~ 300	200
4	Hidden Layer	2 ~ 4	3
5	Epoch	30 ~ 80	50
6	Batch Size	250 ~ 2000	2000
7	Activation Function	Relu	Relu
8	Loss Function	MSE, MAE	MAE
9	Optimizer	RMSProp, Adam, AdamW	AdamW
10	Dropout	0.1 ~ 0.3	X
11	Data Shuffle	True, False	True

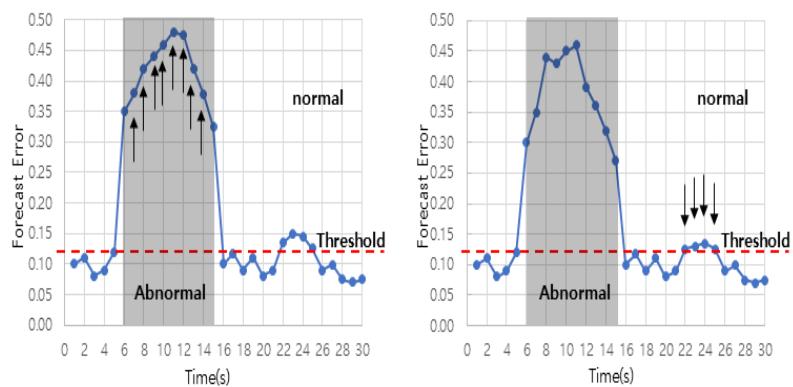
### III. 앙상블 순환 신경망을 이용한 비정상 공정 탐지

#### 3-1-3. 내부 모델 생성(특징 선택)

- 후진 제거법(Backward Elimination): 전체 특성을 포함

시킨 상태에서 독립변수(설명변수)를 하나씩 제거하여  
설명력이 가장 작은 변수를 제거.

- 검증 시, 특정 특성을 제거한 상태에서 학습데이터를  
다시 모델에 입력하여 최대 오차값과 평균 오차가 낮  
게 나타나면 설명력이 가장 작은 변수로 판단.



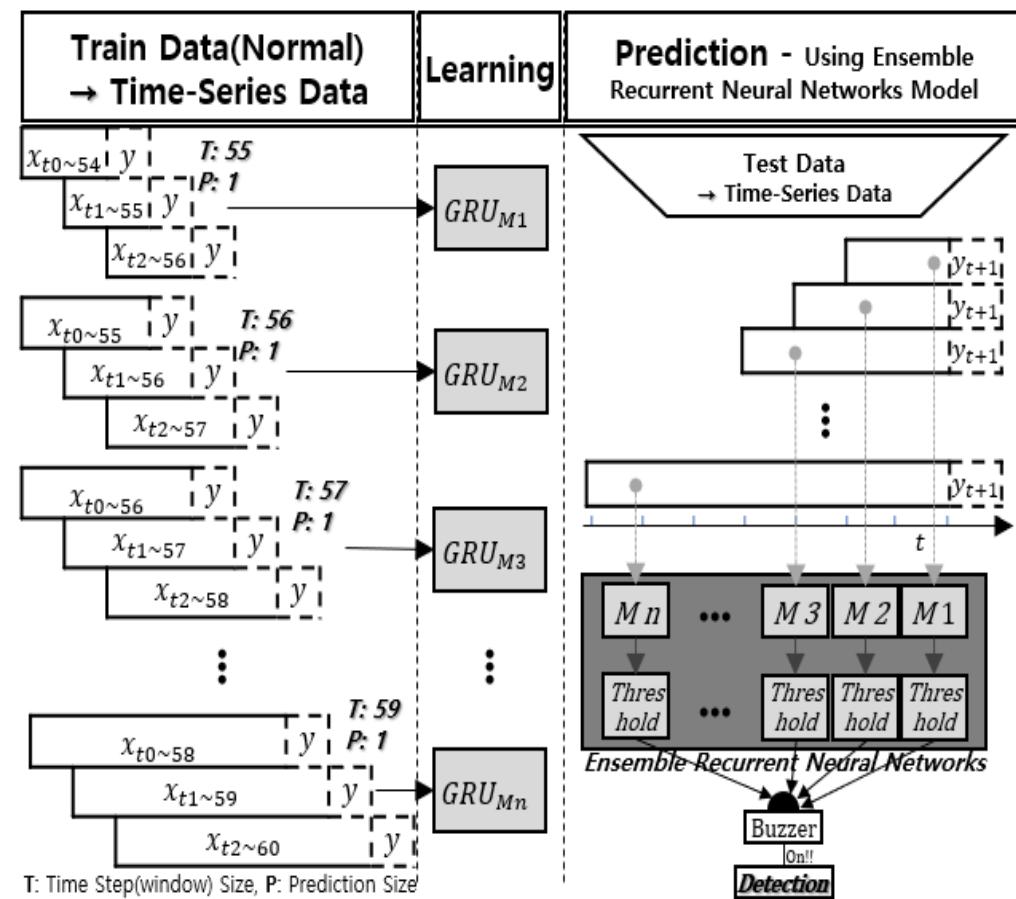
Drop(D)	Features	1Round						2Round						3Round					
		Train Data			Test Data			D	Test Data			P	Test Data			D			
		MAE	Max	Mean	F1	TaP	TaR		F1	TaP	TaR		F1	TaP	TaR				
P1_B2004	3.754	0.062	0.008	0.918	0.978	0.864		0.925	0.979	0.876		0.919	0.975	0.868					
P1_B2016	3.707	0.061	0.008	0.915	0.978	0.860		0.909	0.947	0.874		0.916	0.949	0.886					
P1_B3004	3.749	0.061	0.008	0.908	0.971	0.854		0.916	0.976	0.862		0.911	0.977	0.853					
P1_B3005	3.749	0.062	0.008	0.899	0.976	0.833		0.907	0.973	0.850		0.907	0.971	0.851					
P1_B4002	3.830	0.061	0.008	0.918	0.974	0.868		0.921	0.971	0.875		0.916	0.960	0.876					
P1_B4005	3.736	0.061	0.008	0.920	0.976	0.869		0.920	0.966	0.878		0.919	0.975	0.870					
P1_B400B	3.705	0.061	0.008	0.922	0.969	0.880		0.925	0.978	0.878		0.934	0.976	0.896					
P1_B4022	3.713	0.062	0.008	0.909	0.956	0.866		0.924	0.975	0.878		0.923	0.972	0.878					
P1_FCV01D	3.768	0.061	0.008	0.920	0.977	0.869		0.927	0.978	0.881		0.921	0.971	0.876					
P1_FCV01Z	3.719	0.061	0.008	0.921	0.977	0.871		0.922	0.968	0.880		0.912	0.955	0.872					
P1_FCV02D	3.644	0.061	0.008	0.925	0.978	0.878	V	-	-	-	-	-	-	-	V				
P1_FCV02Z	3.760	0.062	0.008	0.911	0.967	0.862		0.922	0.971	0.878		0.919	0.952	0.889					
P1_FCV03D	3.725	0.062	0.008	0.887	0.968	0.819		0.901	0.956	0.852		0.923	0.972	0.879					
P1_FCV03Z	3.726	0.061	0.008	0.907	0.973	0.849		0.920	0.978	0.869		0.924	0.981	0.874					
P1_FTO01	3.738	0.061	0.008	0.909	0.952	0.869		0.912	0.950	0.877		0.914	0.957	0.875					
P1_FTO01Z	3.701	0.061	0.008	0.909	0.965	0.859		0.923	0.981	0.871		0.927	0.964	0.892					
P1_FTO02	3.723	0.061	0.008	0.914	0.961	0.872		0.921	0.974	0.874		0.930	0.972	0.891					
P1_FTO02Z	3.739	0.060	0.008	0.919	0.974	0.869		0.923	0.975	0.876		0.924	0.976	0.877					
P1_FTO03	3.725	0.061	0.008	0.906	0.959	0.859		0.919	0.970	0.874		0.923	0.978	0.874					
P1_FTO03Z	3.726	0.061	0.008	0.900	0.962	0.846		0.917	0.969	0.871		0.924	0.978	0.876					
P1_LCV01D	3.716	0.060	0.008	0.904	0.979	0.840		0.903	0.964	0.850		0.914	0.982	0.856					
P1_LCV01Z	3.733	0.061	0.008	0.918	0.976	0.867		0.909	0.958	0.865		0.915	0.962	0.872					
P1_LIT01	3.730	0.061	0.008	0.915	0.979	0.859		0.925	0.986	0.872		0.929	0.986	0.878					
P1_PCV01D	3.716	0.061	0.008	0.914	0.975	0.859		0.921	0.970	0.877		0.920	0.977	0.869					
P1_PCV01Z	3.710	0.061	0.008	0.913	0.978	0.857		0.915	0.976	0.862		0.907	0.953	0.865					
P1_PCV02Z	3.683	0.061	0.008	0.913	0.975	0.858		0.921	0.965	0.881		0.920	0.973	0.872					
P1_PIT01	3.735	0.060	0.008	0.914	0.965	0.868		0.929	0.982	0.883	V	-	-	-	V				
P1_PIT02	3.699	0.062	0.008	0.919	0.977	0.867		0.933	0.979	0.890		0.928	0.970	0.890					
P1_TIT01	3.706	0.061	0.008	0.919	0.971	0.873		0.914	0.958	0.874		0.913	0.959	0.872					
P1_TIT02	3.706	0.061	0.008	0.910	0.961	0.864		0.924	0.975	0.878		0.930	0.973	0.889					
P2_24Vdc	3.030	0.060	0.007	0.902	0.956	0.854		0.925	0.976	0.879		0.920	0.969	0.877					
P2_CO_rpm	3.500	0.060	0.008	0.879	0.959	0.811		0.875	0.959	0.805		0.885	0.975	0.811					
P2_HILOut	3.295	0.060	0.007	0.915	0.974	0.864		0.926	0.980	0.878		0.921	0.967	0.880					
P2_SIT01	3.529	0.057	0.008	0.921	0.980	0.868	V	-	-	-	-	-	-	-	V				
P2_SIT02	3.543	0.057	0.008	0.914	0.975	0.860		0.902	0.959	0.851		0.925	0.980	0.876					
P2_VT01	3.509	0.055	0.008	0.913	0.978	0.856		0.913	0.954	0.875		0.919	0.972	0.871					
P2_VXT02	3.590	0.054	0.008	0.919	0.976	0.869	V	-	-	-	-	-	-	-	V				
P2_VXT03	3.632	0.052	0.008	0.918	0.982	0.862		0.930	0.977	0.886		0.925	0.974	0.880					
P2_VYT02	3.592	0.055	0.008	0.919	0.974	0.870	V	-	-	-	-	-	-	-	V				
P2_VYT03	3.650	0.051	0.008	0.905	0.963	0.854		0.904	0.925	0.884		0.931	0.978	0.887					
P3_FIT01	3.664	0.062	0.008	0.914	0.973	0.863		0.924	0.973	0.880		0.927	0.978	0.880					
P3_LCP01D	3.709	0.063	0.008	0.910	0.955	0.869		0.930	0.983	0.882		0.925	0.975	0.880					
P3_LCV01D	3.697	0.061	0.008	0.912	0.961	0.867		0.917	0.976	0.865		0.921	0.975	0.872					
P3_LIT01	3.727	0.062	0.008	0.917	0.973	0.867		0.920	0.962	0.882		0.928	0.980	0.881					
P3_PIT01	3.702	0.065	0.008	0.913	0.971	0.862		0.914	0.956	0.876		0.930	0.982	0.883					
Result	3.407	0.042	0.075	0.917	0.980	0.862		0.929	0.982	0.883		0.929	0.982	0.883					

### 3-1-4. 앙상블 생성 및 탐지

- 기초 모델을 통해 사용할 파라미터의 범위를 정하고, 내부 모델을 통해 불필요한 특징을 제거한 상태.

- 타임스텝 값의 조정(입력크기가 달라짐)과 학습데이터를 랜덤하게 하여 다수의 내부 모델을 생성함.

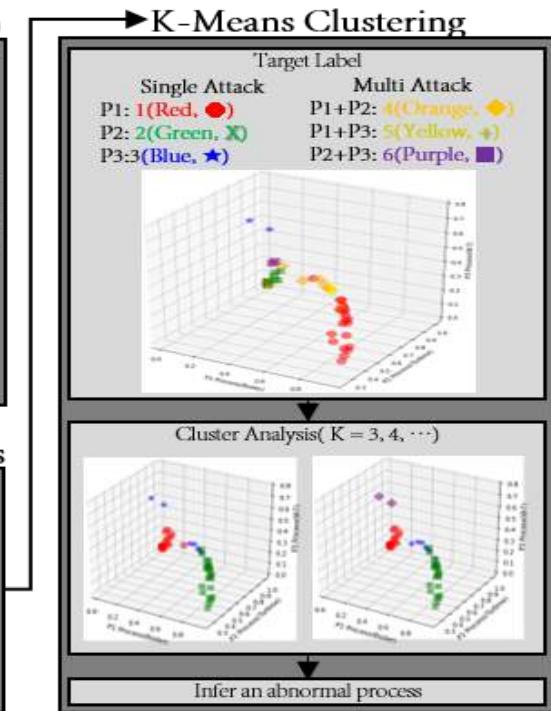
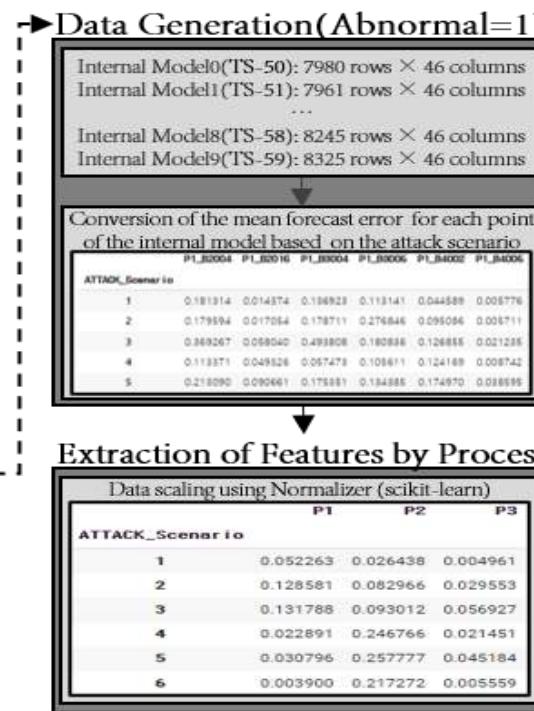
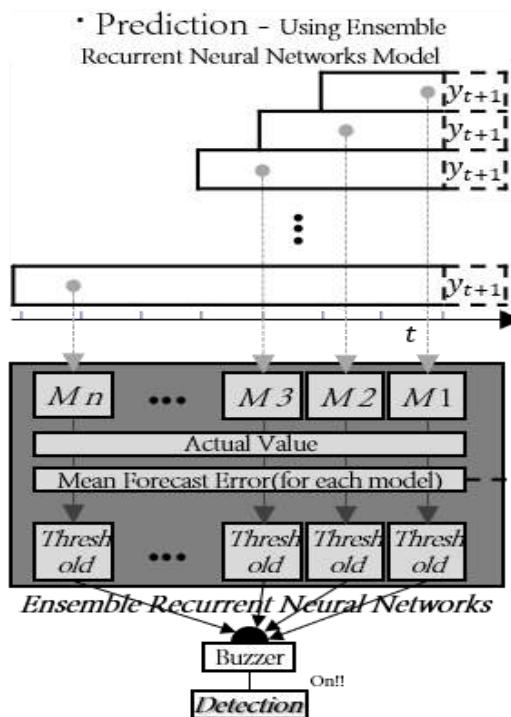
- 생성된 내부 모델들을 하나의 앙상블 모델로 표현하고 내부 모델 중 하나라도 비정상 탐지한다면, 현재의 공정이 비정상임을 나타냄.



### III. 양상을 순환 신경망을 이용한 비정상 공정 탐지

#### 4. 예측 오차를 통한 비정상 공정 도출

- 양상별 모델을 구성하는 내부 모델들의 평균 예측오차를 추출
  - 공격 시나리오 기준으로 공정별 특징 추출 (+ 데이터 전처리)
  - K-평균 클러스터링을 이용하여 비정상 공정 도출



### III. 앙상블 순환 신경망을 이용한 비정상 공정 탐지

#### 4-1. 예측 오차 데이터 생성

- 앙상블 모델을 구성하는 내부 모델들의 평균 예측오차를 추출
- 공격 시나리오 기준으로 공정별 특징 추출 (+ 데이터 전처리 (L2 Norm, Normalizer()) )

ATTACK_Scenario	P1_B2004	P1_B2016	P1_B3004	P1_B3005	P1_B4002	P1_B4005	P1_B4008	P2_YT01	P2_VXT03	P2_VYT03	P3_FIT01	P3_LCP010	P3_LCY010	P3_LIT01	P3_PIT01
1	0.181314	0.014374	0.136923	0.113141	0.044589	0.005776	0.008552	0.093358	0.050935	0.088062	0.014054	0.015088	0.015361	0.018378	0.012305
2	0.179594	0.017054	0.178711	0.276846	0.095086	0.005711	0.010013	0.046807	0.035764	0.028124	0.018382	0.018587	0.020487	0.014751	0.023455
3	0.369267	0.058040	0.493808	0.180836	0.126855	0.021235	0.040594	0.108136	0.080433	0.082114	0.061747	0.063751	0.071088	0.056792	0.056103
4	0.113371	0.049326	0.057473	0.105611	0.124169	0.008742	0.015826	0.224880	0.098385	0.134702	0.039473	0.030922	0.059281	0.024136	0.049189
5	0.213090	0.090661	0.175351	0.134385	0.174970	0.038595	0.064461	0.455745	0.309935	0.210328	0.104782	0.154827	0.170785	0.089031	0.137136
6	0.654932	0.174796	0.302713	0.217384	0.306808	0.055369	0.115892	38.251709	1.599811	2.946987	0.275056	0.236618	0.258245	0.174578	0.182290
7	0.499504	0.144781	0.704358	0.389715	0.175348	0.044734	0.084165	0.358778	0.196522	0.221415	0.284600	0.293395	0.227157	0.171073	0.228820
45	0.679196	0.187215	0.238444	0.194122	0.264031	0.042543	0.119857	31.572697	1.486504	2.439092	0.525656	0.475315	0.517937	0.166855	0.263446
46	0.180618	0.031953	0.266935	0.177822	0.109886	0.009384	0.019743	0.763549	0.156193	0.158103	0.081442	0.050005	0.054584	0.031154	0.052002
47	0.676618	0.039418	0.059151	0.407713	0.113893	0.004706	0.006590	0.049395	0.023903	0.032556	0.011236	0.010274	0.016888	0.012129	0.009587
48	0.244380	0.071419	0.650316	0.207284	0.132003	0.025727	0.056189	0.121719	0.110030	0.087055	0.082197	0.097312	0.091032	0.067659	0.041666
49	0.703345	0.229879	0.271998	0.196001	0.274860	0.057348	0.122385	37.097295	0.611514	1.863674	0.434213	0.499639	0.422004	0.245772	0.459216
50	0.394192	0.052422	0.274889	0.251128	0.152265	0.015094	0.030063	0.334189	0.107207	0.218108	0.061835	0.061339	0.064299	0.072813	0.051756

ATTACK_Scenario	P1	P2	P3
1	0.052263	0.026438	0.004961
2	0.128581	0.082966	0.029553
3	0.131788	0.093012	0.056927
4	0.022891	0.246766	0.021451
5	0.030796	0.257777	0.045184
6	0.003900	0.217272	0.005559

$$X_{P1} = \frac{0.052263}{\sqrt{0.052263^2 + 0.026438^2 + 0.004961^2}} = \frac{0.052263}{0.058779} = 0.88914$$

$$X_{P2} = \frac{0.026438}{\sqrt{0.052263^2 + 0.026438^2 + 0.004961^2}} = \frac{0.026438}{0.058779} = 0.44978$$

$$X_{P3} = \frac{0.004961}{\sqrt{0.052263^2 + 0.026438^2 + 0.004961^2}} = \frac{0.004961}{0.058779} = 0.08440$$

### III. 양상을 순환 신경망을 이용한 비정상 공정 탐지

## 4-2. 예측 오차 데이터 분석

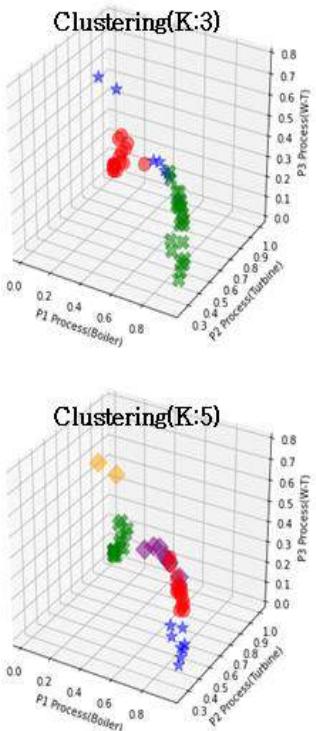
- 상관관계 분석: 동일 공정 내 Point 간 양의 상관관계가 확인, 일부 Point는 타 공정에서도 상관관계가 나타남
  - 공격 시나리오별 공정의 평균 예측 오차 데이터를 생성하여 세부공정 (P1, P2, P3) 을 탈지하는 것이 적절함

Target Process	P1	P1	P1	P2	P2	P2	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P1	P3	P3
Target Point	B2016	B2006	LCV101B	SCO	AutoSD	VTR01	B2016	LCV101B	B2006	FT01	PCV01B	VTR01	B2004	FT01	PCV01D	AutoSD	LCV01D	FT01	PCV01H	RTR	PCV01M	SCO	LCV01H	FT01	PCV01N	LCV101B	
Attack Point	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25		
F1L_B2004	0.06	0.28	0.34	0.06	0.07	0.02	0.03	0.22	0.33		0.32	0.02	0.15	0.2	0.62	0.05	0.05	0.17	0.56	0.03	0.2	0.02	0.23	0.16	0.07		
F1L_B2016	0	0.03	0.05	0.03	0.03	0	0.01	0.05	0.05		0.02	0.01	0.04	0.06	0.04	0.02	0.03	0.06	0.04	0.03	0.03	0.01	0.03	0.03	0.06		
F1L_B3004	0.05	0.28	0.45	0.03	0.06	0.01	0.05	0.49	0.28		0.15	0.01	0.57	0.42	0.08	0.03	0.04	0.55	0.05	0.03	0.11	0.01	0.21	0.16	0.03		
F1L_B3005	0.04	0.43	0.17	0.06	0.05	0.01	0.03	0.25	0.33		0.14	0	0.13	0.2	0.33	0.04	0.02	0.13	0.36	0.03	0.29	0	0.16	0.18	0.03		
F1L_B4002	0.01	0.15	0.12	0.07	0.06	0.01	0.01	0.11	0.24		0.09	0	0.15	0.15	0.06	0.03	0.03	0.12	0.07	0.01	0.11	0.01	0.07	0.17	0.06		
F1L_B4006	0	0.01	0.02	0	0.01	0	0	0	0.01	0.02		0.01	0	0.01	0.02	0.01	0.01	0.01	0	0	0.01	0	0.01	0.02	0		
F1L_B4008	0	0.02	0.04	0.01	0.02	0	0.01	0.03	0.04		0.02	0	0.03	0.04	0.01	0.01	0.02	0.04	0	0.01	0.02	0	0.02	0.03	0		
F1L_B4022	0.01	0.08	0.06	0.03	0.03	0.01	0.01	0.07	0.14		0.04	0	0.08	0.08	0.03	0.01	0.02	0.08	0.04	0.02	0.05	0	0.04	0.06	0.07		
F1L_FCV01D	0	0.02	0.03	0.01	0.02	0	0.01	0.01	0.02		0.01	0	0.02	0.03	0	0.01	0.01	0.02	0	0.01	0.02	0	0.01	0.01	0		
F1L_FCV01E	0	0.02	0.03	0.01	0.02	0	0.01	0.02	0.03		0.02	0	0.01	0.03	0	0.01	0.01	0.02	0	0.01	0.02	0	0.02	0.01	0		
F1L_FCV04D	0	0.01	0.05	0	0.06	0	0.01	0.04	0.03		0.04	0.01	0.03	0.07	0	0.01	0.02	0.02	0	0.04	0.04	0.01	0.02	0.02	0		
F1L_FCV04E	0.02	0.31	0.3	0.02	0.02	0	0.03	0.32	0.27		0.65	0	0.24	0.48	0.14	0.02	0.01	0.24	0.15	0.01	0.7	0	0.51	0.37	0.02		
F1L_FCV05E	0.02	0.26	0.2	0.04	0.04	0	0.02	0.14	0.31		0.56	0.01	0.1	0.25	0.17	0.02	0.02	0.11	0.21	0.02	0.42	0	0.15	0.21	0.02		
F1L_FT01	0.03	0.1	0.25	0.01	0.03	0	0.03	0.11	0.14		0.04	0	0.25	0.16	0.11	0.01	0.01	0.31	0.01	0.01	0.05	0	0.15	0.1	0.03		
F1L_FT01C	0.01	0.09	0.12	0.02	0.03	0	0.02	0.06	0.16		0.02	0	0.13	0.13	0.05	0.01	0.01	0.16	0.05	0.01	0.04	0	0.07	0.09	0.01		
F1L_FT02	0	0.02	0.02	0.01	0.03	0	0.01	0.03	0.05		0.03	0	0.02	0.03	0.01	0.01	0.03	0	0.01	0.01	0.02	0	0.02	0.01	0		
F1L_FT02C	0	0.01	0.03	0.01	0.03	0	0.01	0.03	0.03		0.03	0	0.03	0.04	0	0.01	0.02	0.03	0	0.01	0.02	0	0.02	0.01	0		
F1L_FT03	0.03	0.37	0.13	0.04	0.03	0	0.02	0.17	0.3		0.05	0	0.09	0.15	0.25	0.03	0.02	0.09	0.26	0.02	0.18	0	0.28	0.07	0.04		
F1L_FT05C	0.02	0.39	0.11	0.03	0.03	0	0.02	0.14	0.18		0.07	0	0.09	0.14	0.23	0.03	0.02	0.07	0.24	0.02	0.14	0.01	0.25	0.1	0.03		
F1L_LCV01D	0.01	0.18	0.29	0.02	0.02	0	0.06	0.52	0.15		0.17	0	0.23	0.25	0.12	0.02	0.01	0.34	0.14	0.01	0.22	0	0.2	0.26	0		
F1L_LCV01E	0.01	0.01	0.22	0.02	0.02	0	0.07	0.22	0.14		0.04	0	0.23	0.18	0.09	0.02	0.01	0.28	0.1	0.01	0.07	0	0.11	0.15	0.01		
F1L_LT01	0.03	0.15	0.4	0.03	0.05	0	0.04	0.2	0.35		0.15	0	0.4	0.39	0.08	0.02	0.03	0.38	0.02	0.02	0.1	0	0.18	0.43	0.02		
F1L_FCV01D	0.05	0.1	0.06	0.01	0.01	0	0.02	0.09	0.08		0.03	0	0.08	0.07	0.37	0.01	0.01	0.09	0.35	0.01	0.05	0	0.04	0.1	0.03		
F1L_FCV01E	0.04	0.15	0.06	0.02	0.02	0	0.02	0.12	0.1		0.04	0	0.08	0.09	0.36	0.02	0.01	0.09	0.32	0.02	0.09	0	0.05	0.08	0.02		
F1L_FCV02C	0.99	0	0	0	0	0	0.99	0	0		0	0	0	0.01	0	0	0	0	0	0	0	0	0	0	0.01		
F1L_FT02C	0	0.01	0.03	0.01	0.02	0	0.01	0.03	0.05		0.04	0	0.02	0.05	0	0.03	0.04	0	0	0.01	0	0.02	0.04	0			
F1L_LT01C	0.01	0.05	0.06	0.03	0.02	0	0.01	0.05	0.07		0.03	0	0.05	0.05	0.01	0.01	0.05	0.01	0.01	0.04	0	0.03	0.03	0.03			
F1L_LT01D	0	0.01	0.02	0	0.02	0	0	0.02	0.01		0.01	0	0.02	0.01	0	0	0.01	0.01	0	0.01	0.02	0	0.02	0.02	0.01		
F2_24V6	0.02	0.17	0.13	0.09	0.11	0.01	0.01	0.12	0.15		0.08	0.01	0.11	0.13	0.08	0.03	0.11	0.12	0.08	0.13	0.02	0.01	0.08	0.16	0.07		
F2_C0_R01	0.02	0.09	0.09	0.35	0.81	0.22	0.01	0.09	0.1		0.05	0.22	0.12	0.09	0.08	0.84	0.97	0.09	0.05	0.97	0.22	0.12	0.15	0.64			
F2_HILout	0.02	0.09	0.12	0.08	0.06	0.01	0.01	0.08	0.11		0.06	0.01	0.08	0.07	0.06	0.05	0.06	0.07	0.06	0.01	0.07	0.05	0.04	0.45			
F2_SIT02	0.04	0.07	0.07	0.46	0.49	0.23	0.02	0.06	0.09		0.03	0.23	0.1	0.07	0.04	0.48	0.08	0.06	0.03	0.09	0.23	0.12	0.09	0.2			
F2_VT01	0.03	0.07	0.01	0.12	0.16	0.34	0.03	0.1	0.11		0.06	0.95	0.28	0.08	0.06	0.15	0.13	0.08	0.04	0.11	0.06	0.95	0.42	0.12	0.18		
F2_VT05	0.02	0.06	0.07	0.05	0.11	0.04	0.01	0.05	0.08		0.04	0.07	0.07	0.03	0.08	0.06	0.07	0.06	0.04	0.06	0.02	0.05	0.06	0.07			
F2_VT05C	0.03	0.04	0.08	0.07	0.07	0.07	0.02	0.05	0.07		0.04	0.05	0.07	0.06	0.03	0.09	0.06	0.06	0.02	0.05	0.04	0.05	0.05	0.08			
F3_FT01	0	0.03	0.08	0.02	0.04	0.01	0.02	0.05	0.05		0.02	0.02	0.04	0.04	0.01	0.02	0.04	0.03	0.04	0.01	0.03	0.23	0.15				
F3_LCP01D	0	0.03	0.06	0.02	0.05	0.01	0.02	0.05	0.05		0.02	0.02	0.05	0.04	0.01	0.02	0.03	0.05	0.01	0.03	0.02	0.03	0.12	0.49			
F3_LCV01D	0.01	0.03	0.07	0.03	0.06	0.01	0.02	0.05	0.05		0.02	0.01	0.05	0.03	0.04	0.06	0.01	0.04	0.03	0.01	0.03	0.12	0.49				
F3_LT01	0	0.01	0.02	0.05	0.03	0	0.01	0.04	0.06		0.03	0	0.04	0.03	0.01	0.02	0.04	0.01	0.02	0.01	0.02	0.08	0.02				
F3_PFT01	0	0.04	0.05	0.03	0.05	0.01	0.02	0.04	0.04		0.01	0.02	0.03	0.01	0.03	0.02	0.02	0.02	0.01	0.02	0.02	0.03	0.33	0.14			

### III. 앙상블 순환 신경망을 이용한 비정상 공정 탐지

## 4-3. K-평균 클러스터링을 이용한 비정상 공정 도출

- K-평균 클러스터링을 이용하여 평균 예측오차를 통해 비정상 공정을 도출함
- K값은 공정의 수를 최소값(3)으로 공격시나리오의 타입(단일:3, 복합:3 = 6)을 최대 값으로 사용(K = 3 ~ 6)



Target Process	Cluster		K:3		K:4		K:5		K:6	
	Result	Process	Data	Process	Data	Process	Data	Process	Data	Process
P1	1	P1	20	P1	19	P1	11	P1	11	P1
	2		2	P3	3	P1	3	P1	1	P1
	4						8	P1	8	P1
	5								2	P1
P2	0	P2	11	P2	11	P2	11	P2	11	P2
P3	2	P3	2	P3						
	3				2	P3	2	P3	2	P3
P1+P2	0	P2	4	P2	3	P2	3	P2	3	P2
	2	P1   P3	4	P3	5	P1	5	P1	5	P1
P1+P3	1	P1	3	P1	3	P1	3	P1	3	P1
P2+P3	0	P2	3	P2	3	P2	3	P2	3	P2

#### IV. 실험 및 분석

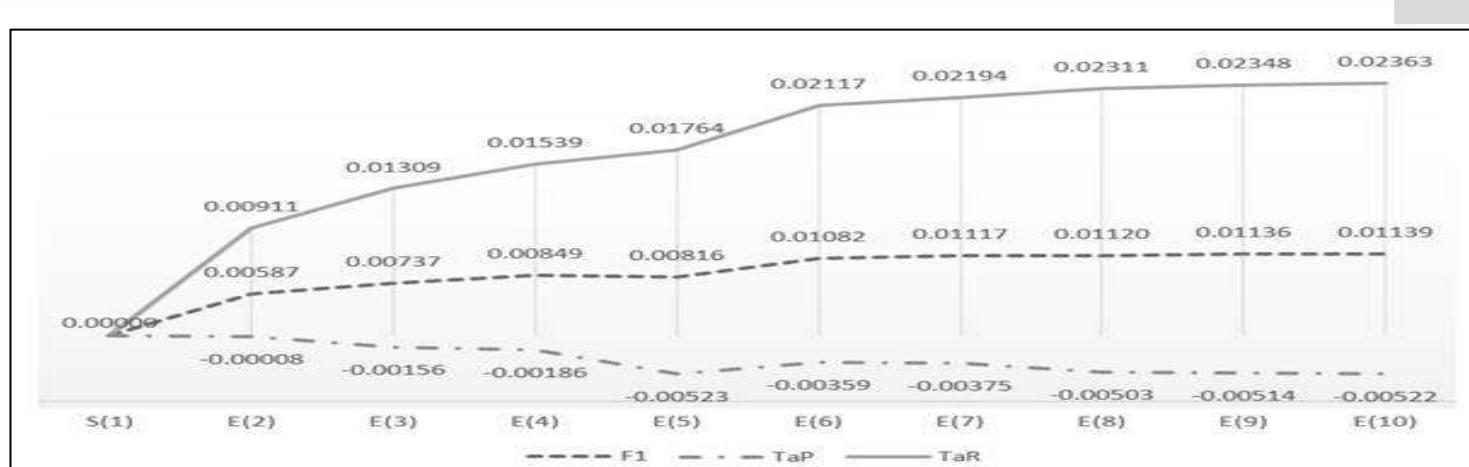
## 1. 기초, 내부, 양상률 모델 탐지 성능 평가

- 딥러닝 알고리즘 성능 : **83.40%** (RNN > CNN > AE)
- 기초모델(모델 튜닝) : 91.60%
- 내부모델(특징 선택) : 92.90%
- 양상률 모델(내부모델 5개) : 93.80%
- 양상률 모델(내부 모델 10개) : 94.04%

RNN(GRU) Model	Threshold	TaPR			
		F1-Score	TaP	TaR	Detected
Initial Model	0.075	83.40%	97.70%	72.70%	-
Basic Model	0.045	91.60%	97.90%	86.10%	47/50
Internal Model	0.045	92.90%	98.20%	88.30%	48/50
Ensemble Model (5 internal models)	0.045	93.80%	97.70%	90.20%	48(+1)/50
Ensemble Model (10 internal models)	0.045	94.04%	97.68%	90.66%	48(+1)/50

#### IV. 실험 및 분석

## 2. 내부 모델을 확장한 양상을 모델 성능 비교

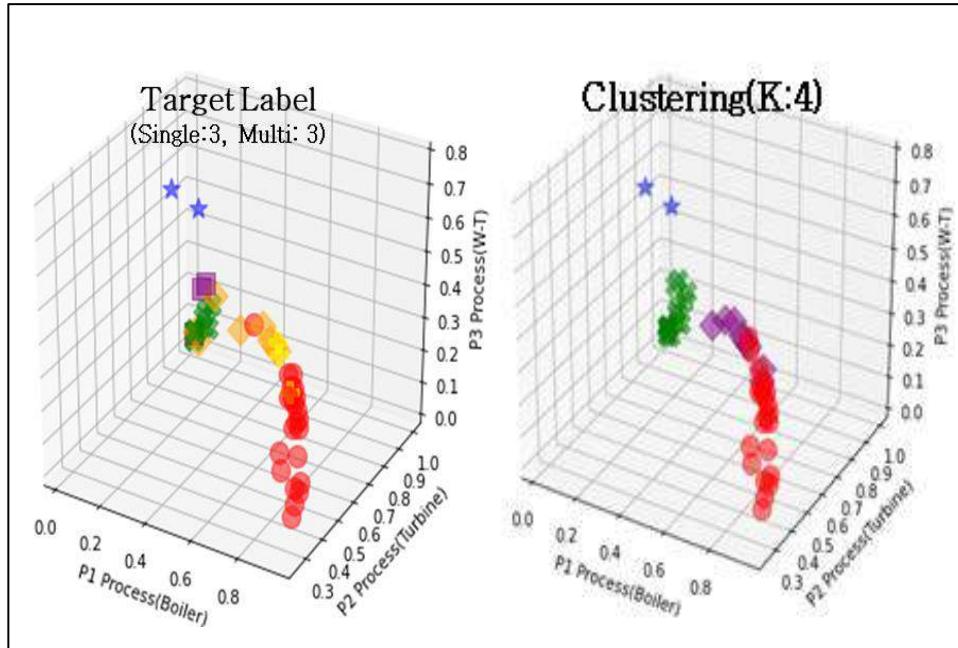


Ensemble / TimeStep		eTaPR(detect: 48)						CEM	
		F1		TaP		TaR		F1	
		Result	Inc/Dcc	Result	Inc/Dcc	Result	Inc/Dcc	Result	Inc/Dcc
S(1)	59	0.929	0	0.982	0	0.883	0	0.73645	0
E(2)	59 + 58	0.93487	0.00587	0.98192	-0.00008	0.89211	0.00911	0.74308	0.00663
E(3)	E(2) + 57	0.93637	0.00150	0.98044	-0.00148	0.89609	0.00398	0.74548	0.00240
E(4)	E(3) + 56	0.93749	0.00112	0.98014	-0.00030	0.89839	0.00230	0.74768	0.00220
E(5)	E(4) + 55	0.93716	-0.00033	0.97677	-0.00337	0.90064	0.00225	0.74864	0.00096
E(6)	E(5) + 54	0.93982	0.00266	0.97841	0.00164	0.90417	0.00353	0.75179	0.00315
E(7)	E(6) + 53	0.94017	0.00035	0.97825	-0.00016	0.90494	0.00077	0.75275	0.00096
E(8)	E(7) + 52	0.94020	0.00003	0.97697	-0.00128	0.90611	0.00117	0.75321	0.00046
E(9)	E(8) + 51	0.94036	0.00016	0.97686	-0.00011	0.90648	0.00037	0.75460	0.00139
E(10)	E(9) + 50	0.94039	0.00003	0.97678	-0.00008	0.90663	0.00015	0.75493	0.00033

#### IV. 실험 및 분석

### 3. 예측오차를 통한 비정상 공정 도출

- 단일공격 = P1: 1(Red, '●'), P2: 2(Green, 'X'), P3: 3(Blue, '★')
- 복합공격 = P1+P2: 4(Orange, '◆'), P1+P3: 5(Yellow, '+'), P2+P3: 6(Purple, '■')



Attack Scenario(50)		Clustering(K-means: 4)		
Type	Detected(49)	Data	Target	Result
Single	22	19	P1	1(P1)
		3		2(P1)
	11	11	P2	0(P2)
	2	2	P3	3(P3)
Multi	8	5	P1+P2	2(P1)
		3		0(P2)
	3	3	P1+P3	1(P1)
	3	3	P2+P3	0(P2)

## 4. 실험 결과 분석

### - 비정상 탐지

- 딥러닝 모델 중 순환 신경망(GRU)을 이용한 모델이 적합
- 양상을 모델을 구성하는 오탐이 억제된 내부 모델은 공격이 끝난 지점 이후를 일정 기간(timestep) 비정상 탐지 하지만, 이 외에는 오탐지는 미 발생하였고 50개의 시나리오 중 49개를 탐지
- 최종 성능은 94%이며, 기존에 발표된 논문의 성능보다 향상됨.
- 미 탐지에 대한 추가 탐지 방법이 강구되어야 함.

### - 비정상 공정 도출

- 양상을 순환 신경망을 구성하는 내부 모델(단일)의 예측오차를 통한 비정상 공정을 도출하기 어려웠으며, 다수의 내부 모델의 오차 평균을 이용하는 것이 적절하게 클러스터링 되었음.
- 단일 공격 및 복합 공격의 유형, 공격 횟수, 공격에 대한 파급력, 공정에 미치는 영향도 등을 달리하여 다양한 유형의 공격 시나리오가 추가된 상태에서 추가 연구가 필요해 보임.

## 1. 결론

- 비정상 공정을 탐지하여 운영 안정성을 보장하기 위한 연구를 진행하였음
- 운전 데이터를 시계열 데이터로 변환하였으며, 회귀 예측 모델을 사용함.
- GRU 기반으로 하는 비정상 탐지 모델은 오탐율 억제하여 정밀도(Precision)이 높은 상태를 유지함.
- 먼저 형태의 양상을 순환 신경망을 구성하여 미탐지에 대해 상호보완적 동작하도록 함.
- 비정상 탐지 후 예측 오차를 통한 비정상 세부 공정을 도출하여 대응 범위를 축소함.

## 2. 향후연구

- 데이터 측면
  - 다양한 정상 상황의 데이터를 수집해야 하며, 정상 상황에 대한 데이터 균형이 필요하다.
  - 정상 공정으로 복원 시, 시계열 데이터의 타임스텝 내에 비정상 데이터가 존재함으로 공격 종료 시점을 명확히 구분할 필요가 있다. (선택사항)
- 탐지 모델 측면
  - 오탐이 억제된 임계값을 자동으로 설정할 수 있는 구체적인 방안(자동화)이 필요하다.
  - 입력 데이터의 크기를 동적으로 받아들이고 내부적으로 학습할 수 있는 구조가 필요하다.
- 보안 측면
  - 비정상 탐지 후 비정상 공정에 대한 정의가 필요하다.(기계/전기 오류, 물리적 손상, 사이버 공격 등)
  - 비정상 탐지 된 내용이 공정 운영 간 어느정도 심각도(상, 중, 하)를 갖는지 정의 할 필요가 있다.

## 참고문헌

# Q & A

감사합니다.