


설비 이상현상 감지와 진단을 위한 인공지능 모델 **실적용**에 대한 연구

2018 KEPIC-week

(주) 리얼웹
전희철

한국수력원자력
김진우

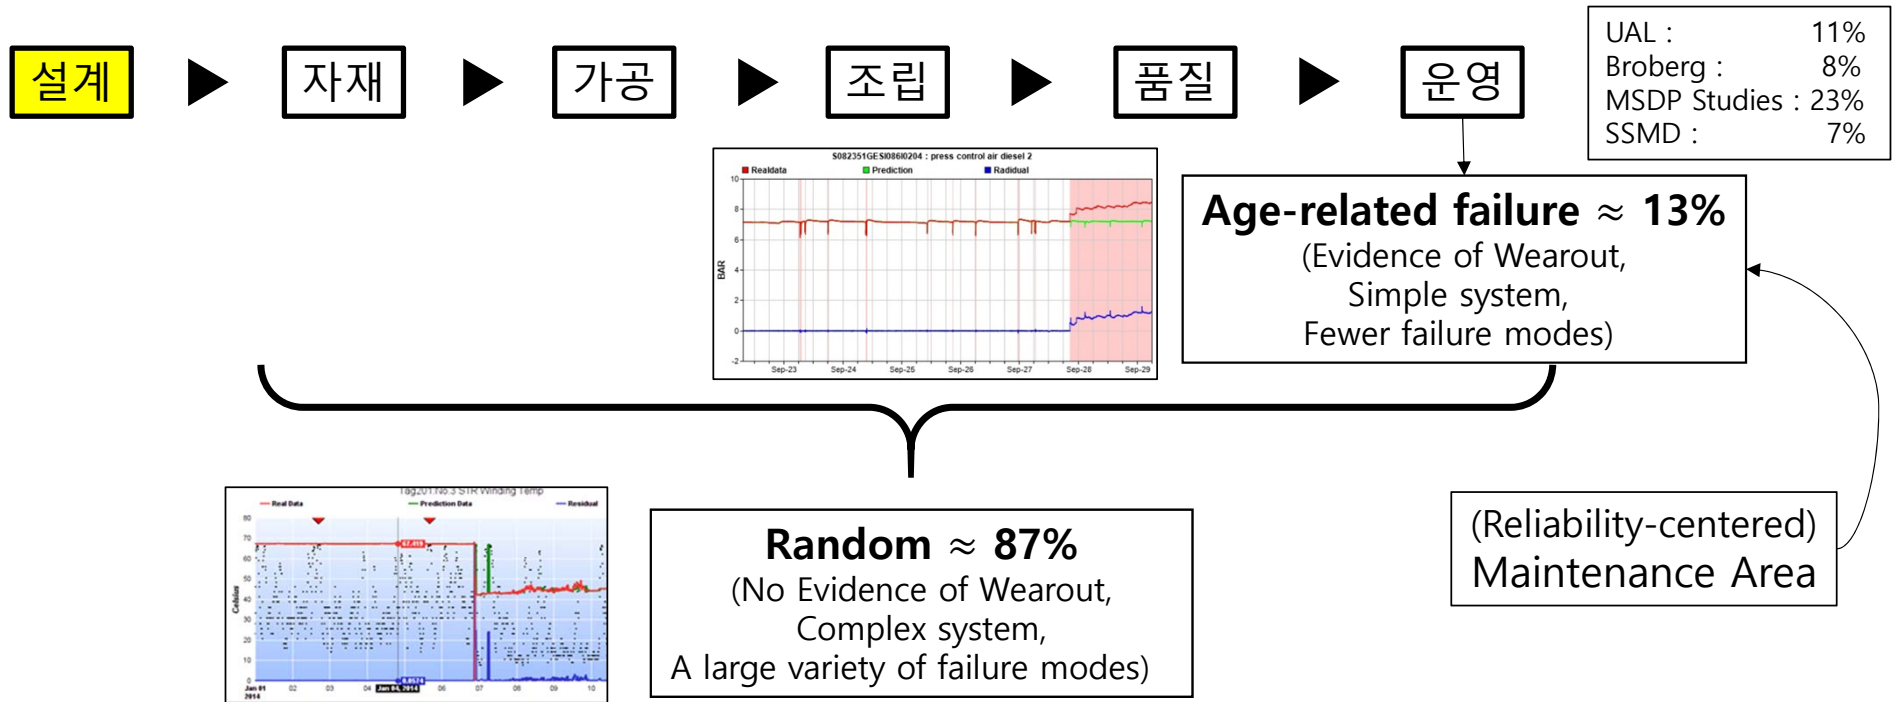


Contents

- 1. Equipment Failure Randomness**
- 2. AI & CBM**
- 3. Anomaly Detection**
- 4. Anomaly Base Expert System**
- 5. Conclusions**

1. Equipment Failure Randomness

▶ 대부분의 Failure는 Random : 확연한 전조 증상을 파악하기 어려운 상태에서 발생

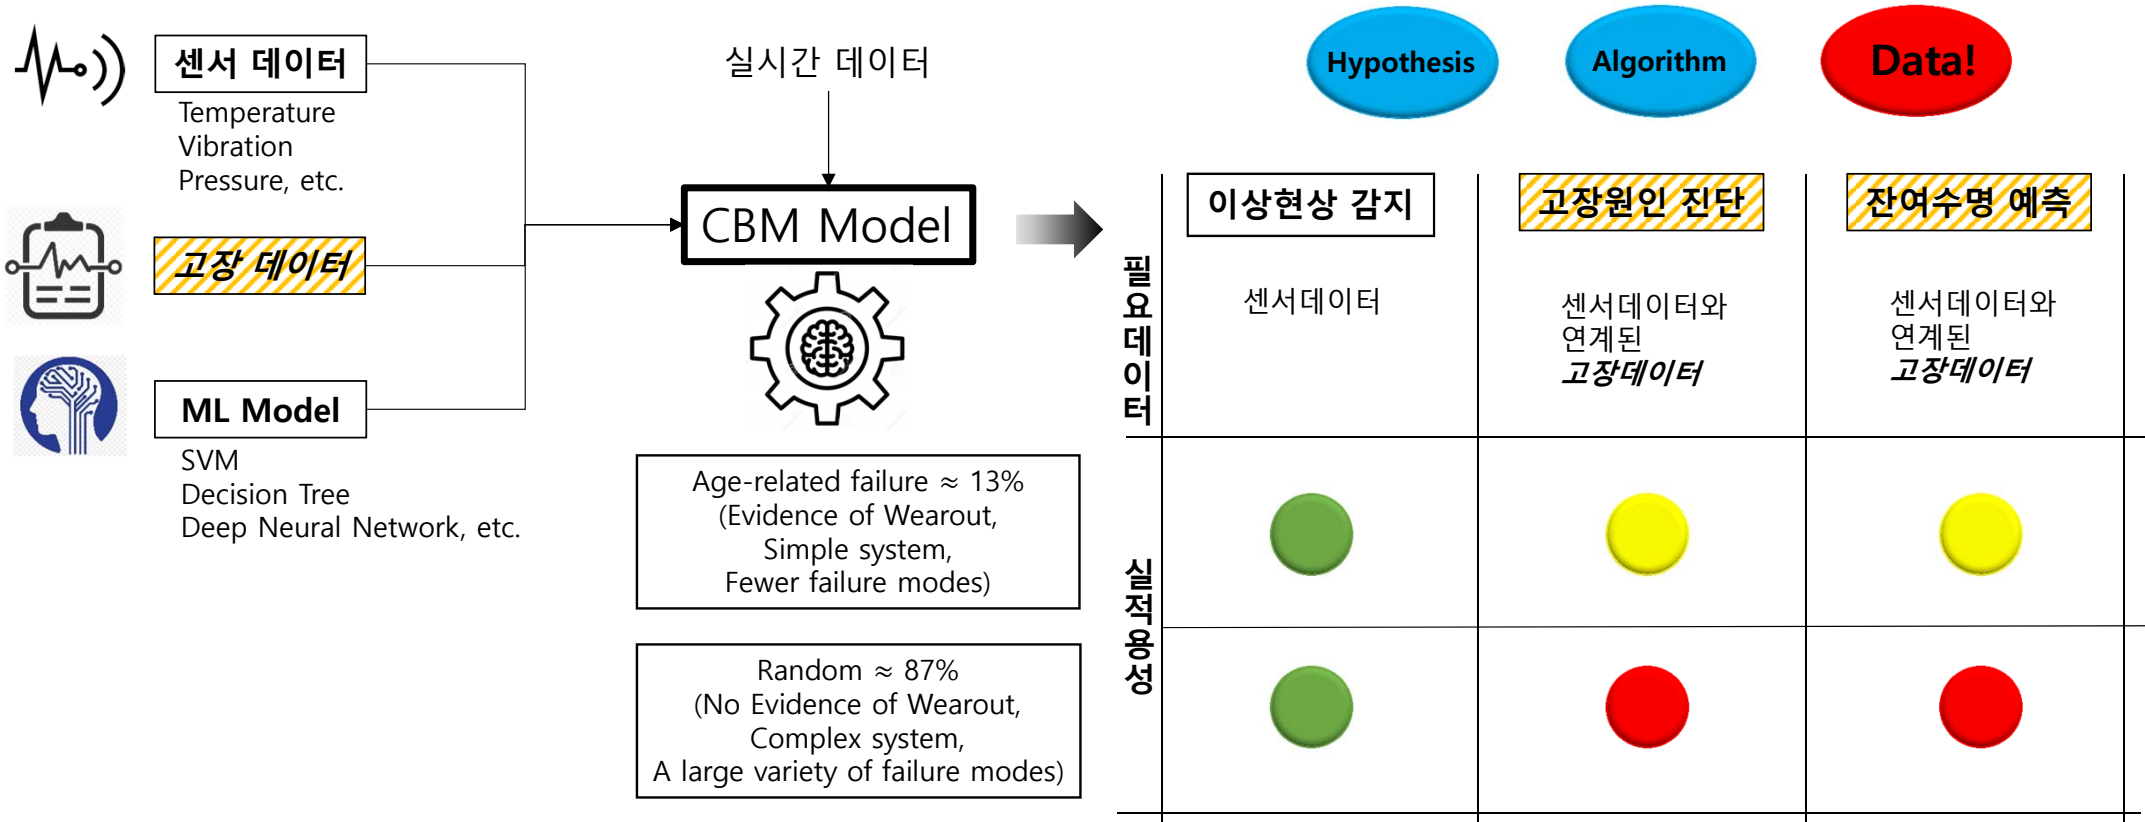


Wearout : "there is a *marked* increase in the conditional probability of failure"

(Reliability-centered Maintenance Handbook, NAVAL SEA SYSTEMS COMMAND, 2007)

2. AI & CBM

▶ AI Machine Learning Model(ML)을 이용한 CBM¹⁾



1) Condition based maintenance

2. AI & CBM

▶ How many examples(data) do we need for ML?


Hoeffding's Inequality (Proven by Wassily Hoeffding, 1963)

$$P[|\mu - \nu| > \epsilon] \leq 2e^{-2\epsilon^2 N}$$

↑ 확률
 ↑ Sample을 통해 얻은 결과
 ↑ 실제 결과 (모름)
 ↑ 오차
 ↑ Sample 데이터 개수

Sample을 통해 얻은 결과와 실제 상황 결과에 대한 **신뢰도**는 sample데이터 개수와 밀접한 관계에 있다

조사대상 : 전국 만 19세 이상 남녀 1000명



표본오차 : 95% 신뢰수준 ±3.1%

정확도(1 - ε)	신뢰도(P)	Sample 개수
95%	±3.1%	830
90%	±1.0%	270
90%	±90.0%	40
90%	±10.0%	150
80%	±10.0%	38

40개의 sample로 90% 정확도를 가진다면 신뢰도는?

2. AI & CBM

▶ How many examples(data) do we need for ML?

In Machine Learning,

$$P[| E_{in} - E_{out} | > \epsilon] \leq 2Me^{-2\epsilon^2 N}$$

↑ ↑ ↑ ↑ ↑ ↑

확률 Training Data를
이용해 얻은 결과 실제 결과
(모름) 오차 Hypothesis
개수 Sample
개수

M

여러 개의 가설을 통해 얻은, 최적화 결과에 따른 penalty.

복잡한 모델일수록, sample 개수가 작을 경우, training error와 test error 차이가 많이 발생한다.

이런 현상이 나오는 이유 :

1개의 동전을 10회 던져서 앞면만 10회 나올 확률 ~ 0.1%

1000개의 동전을 각 각 10회 던져서, 1개 이상의 동전이 10회 연속 앞면만 나올 확률 ~ 63%

동일한 데이터를 가지고 이것 저것 수많은 가설을 test하면, in sample error는 줄어들지만 신뢰도는 떨어진다

2. AI & CBM

▶ How many examples(data) do we need for ML?


$$P[|\mu - \nu| > \epsilon] \leq 2e^{-2\epsilon^2 N}$$

↑ 확률 ↑ Sample를 통해 얻은 결과 ↑ 실제 결과 (모름) ↑ 오차 ↑ Sample 데이터 개수

General Bound(worst case) :

- 데이터가 서로 독립적이고, random하다는 것을 가정
- 실제로는 데이터의 확률 분포에 따라 훨씬 작은 데이터 개수(N)로, 신뢰도(P)를 만족시킬 수 있다

$$P[|\mu - \nu| > \epsilon]$$



이항분포($\nu = 0.1$) 데이터 개수에 따른 신뢰도

* 데이터에 대한 확률 분포를 미리 알고 있는 경우(random이 아닌 경우), 필요 데이터 개수를 이론적으로 구할 수 있다

예) 데이터 분포가 이항분포이고 확률이 0.1인 경우(즉, 임의의 데이터를 취할 경우, 맞을 확률이 1/10인 경우), 신뢰도 만족을 위한 필요 데이터 개수는 General Bound보다 훨씬 작다.

- VC Dimension을 구할 수 있는 경우 필요 데이터 개수는 General Bound보다 작아질 수 있다(ex. Polynomial Fit, SVM 등의 수학적 모델)


예) Polynomial Fit(N 차원)의 경우, generalization에 필요한 데이터 개수는 $(N + 1) \times 10$

- **확률 분포를 모르는 복잡한 문제???**
 → **데이터 개수가 지나치게 작을 경우 신뢰도에 심각한 문제 발생**

2. AI & CBM

▶ How many examples(data) do we need for ML?

데이터 개수에 따른 예측 정확도와 신뢰도(Hoeffding's Inequality)



Machine Learning을 활용한 진단

❖ 데이터 확률 분포를 모름

→ 데이터 분포를 random으로 가정하면, N = 40 이하는 의미 없음

❖ N > 40의 의미

→ 동일한 진단에 대해 유사한 센서 데이터 변화 패턴이 40회 이상 발생해야 함

→ 다양한 원인 별로 상기한 데이터 확보가 필요함

→ 발생 가능성이 매우 낮고, **실 데이터** 획득이 현실적으로 어려움

→ **Generalization이 매우 어려움!**

2. AI & CBM

▶ How many examples(data) do we need for ML?

특화된 영역* : 회전 기기 진동 시그널을 이용한 진단

❖ Rotation machinery vibration research

Vibration signal

Feature Extraction/Selection

Failure Pattern Training

Failure Diagnosis

- ✓ Proven by Lab generated (simulated) data (Not real data!)
- ✓ Limited failure modes

→ Reliable AND Applicable to the **REAL SITUATION?**

Noisy

Unstable mount, Unstable load
Lubricant characteristics change,
Connect to the other machines, etc.

- 운영중인 설비를 통해 $N > 40$ 이상의 실 데이터 획득은 현실적으로 매우 어려움

→ 실 상황 적용에 대한 검증 거의 불가능

- 실험실 데이터는 이상적인 환경에서 한 개 혹은 두 개의 기계에서 추출
 - Biased
 - 하나의 고장 모드에 대해 수백개의 data set 추출, 실 상황에서는 1개의 데이터임
 - 결과가 신뢰성 있게 다른 기계에도 적용된다는 검증 없음

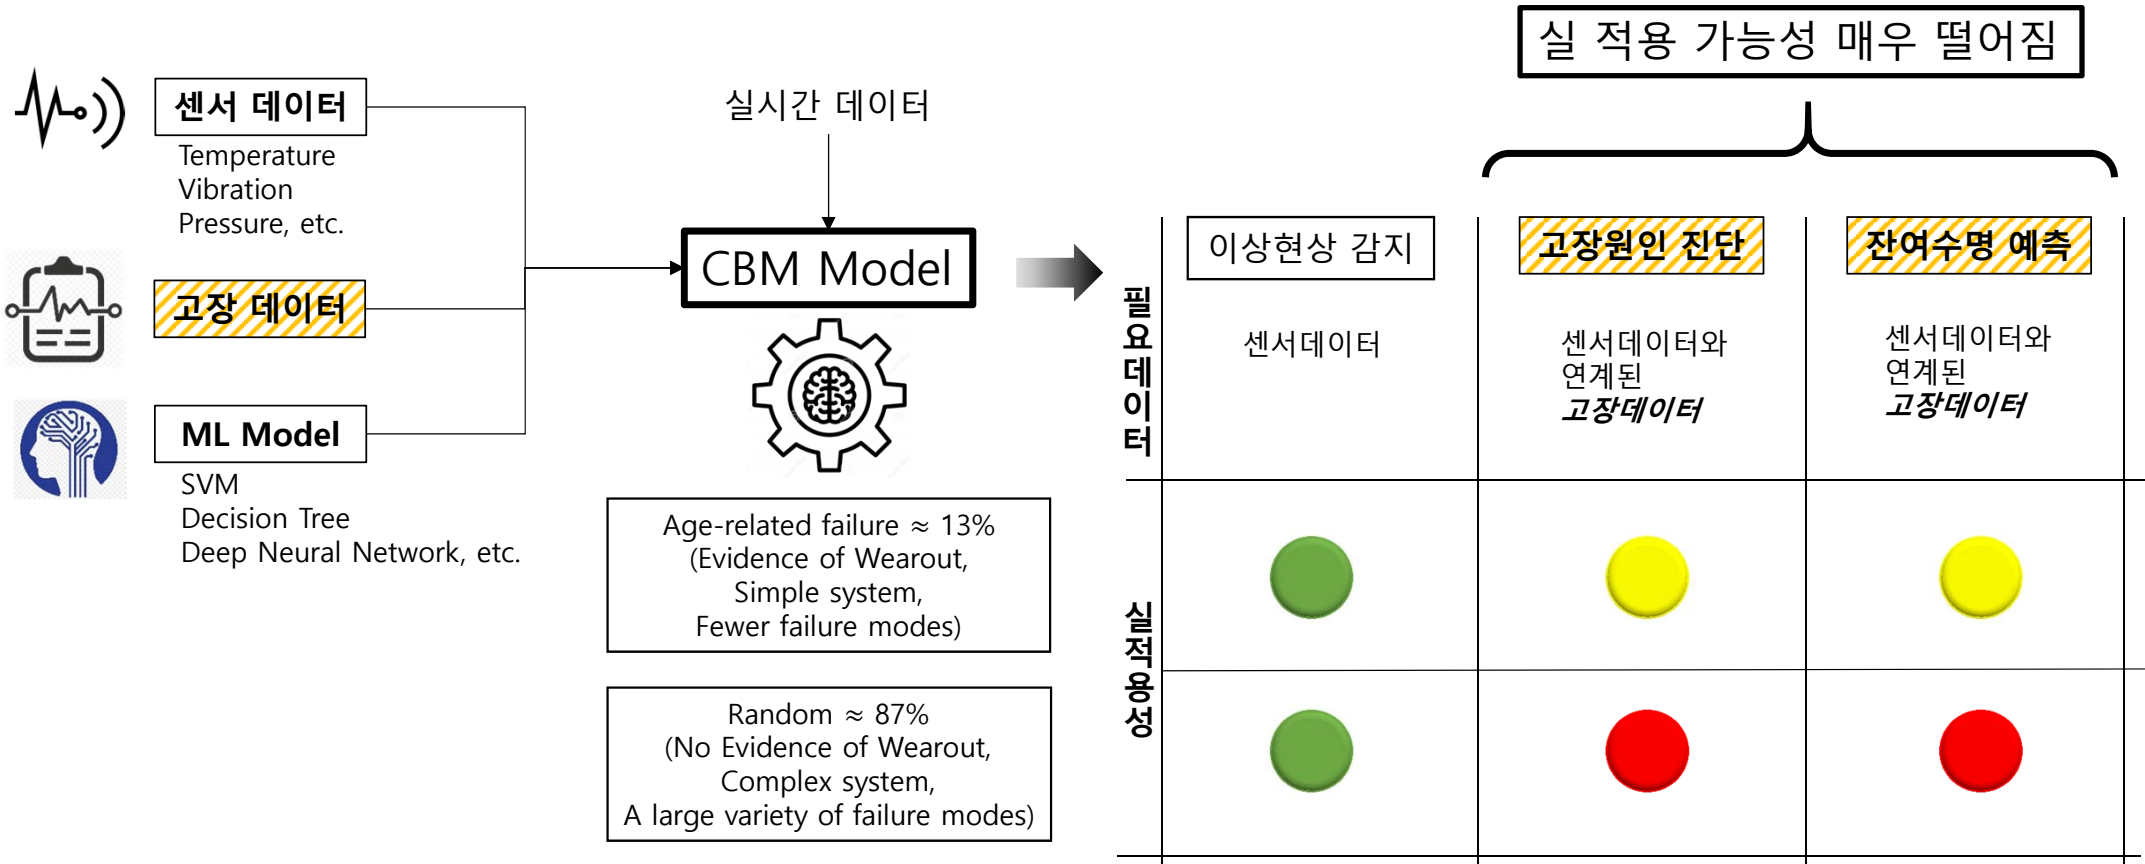
- 일부 소수의 고장 모드만 고려
 - 타 고장 모드가 추가될 경우, 효과성 검증 못함
 - 타 고장 모드 추가 시 모델을 재 작성 해야 함

- Data set이 작을 경우, **Overfit** 가능성이 매우 높음
 - **Not machine learning, memorize everything**
 - 특히, Deep Neural Network(CNN/RNN 등)의 경우 파라미터 개수가 크게 증가하여(수천개 ~ 수억개) 많은 data set이 필요함

* 회전 기기 고장 중 이상 진동으로 고장이 판별되는 경우는 **7.25%** (Based on OREDA (Offshore Reliability Data) DB, ISO 14224, 신뢰도 및 위험도 기반 유지보수 기법 도입방안연구, 한국지역난방공사 /한국기계 연구원, 2015)

2. AI & CBM

▶ AI Machine Learning Model을 이용한 CBM 실 적용성



2. AI & CBM

▶ 고장 원인 진단

Data 획득이 어려운 상황 → ML은 실 적용성이 떨어짐 → Well-proven technology(Expert system/Fuzzy logic)

AI History

Dartmouth College Workshop(1956)



Herbert A. Simon



John McCarthy



Marvin Minsky



Arthur L. Samuel


"machines will be capable, within twenty years, of doing any work a man can do"(H.A.Simon)
 "within a generation ... the problem of creating 'artificial intelligence' will substantially be solved"(M. Minsky)

미 의회 예산 삭감 ('1974)

- checkers strategies(1954)
- proving logical theorems(1964)
- speaking English(1965)


AI Winter '1980

Lisp Market Failure ('1987)



Expert System

Second AI Winter '2000




Focus on Specific Task

- Logistics
- Data Mining
- Medical Diagnosis, etc.

Computing Power
 Ties AI with other fields
 Mathematical methods
 Scientific Standards

'2015



Machine Learning

- Jeopardy! Quiz Show
- Watson
- Xbox
- AlphaGo

Computing Power
 Large Amount of Data
 Advanced Algorithms

Most Successful Engineering Applications

- Planning
- Expert System
- Statistical Learning

AI Problem Solving/Planning

Knowledge Representation : Expert System Fuzzy Logic

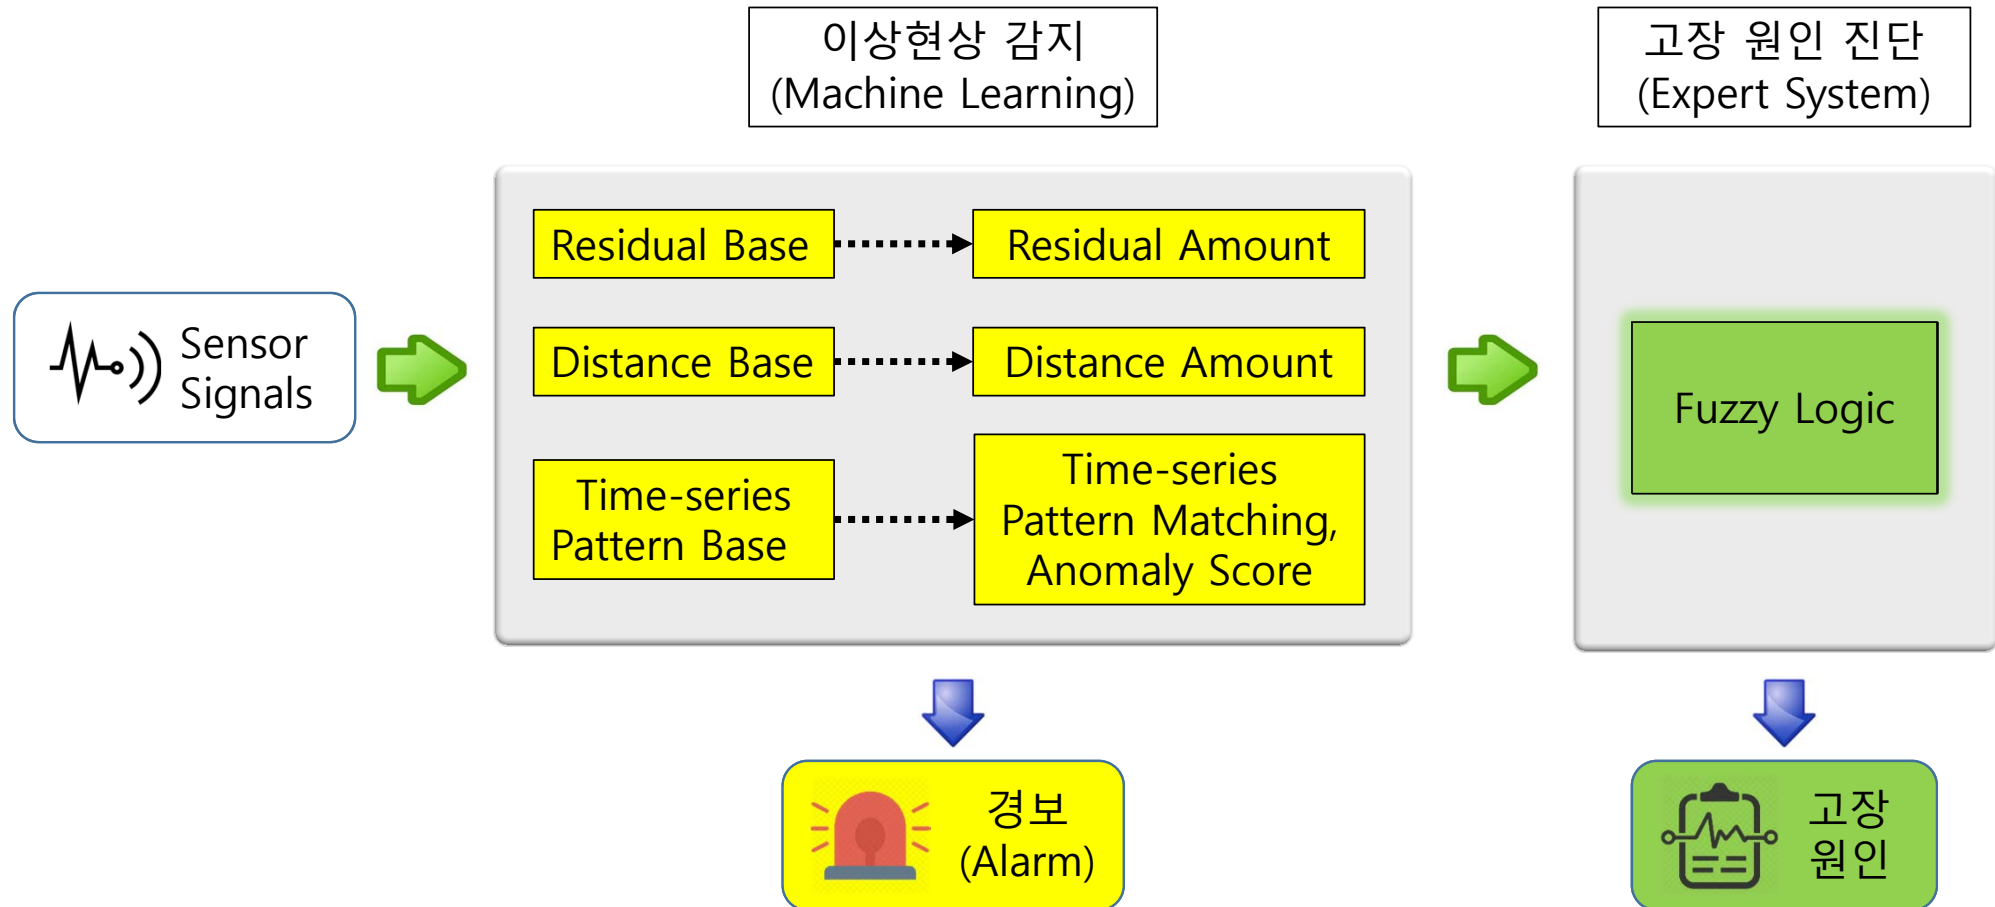
Machine Learning : Artificial Neural Network

Statistical Learning

Deep Learning

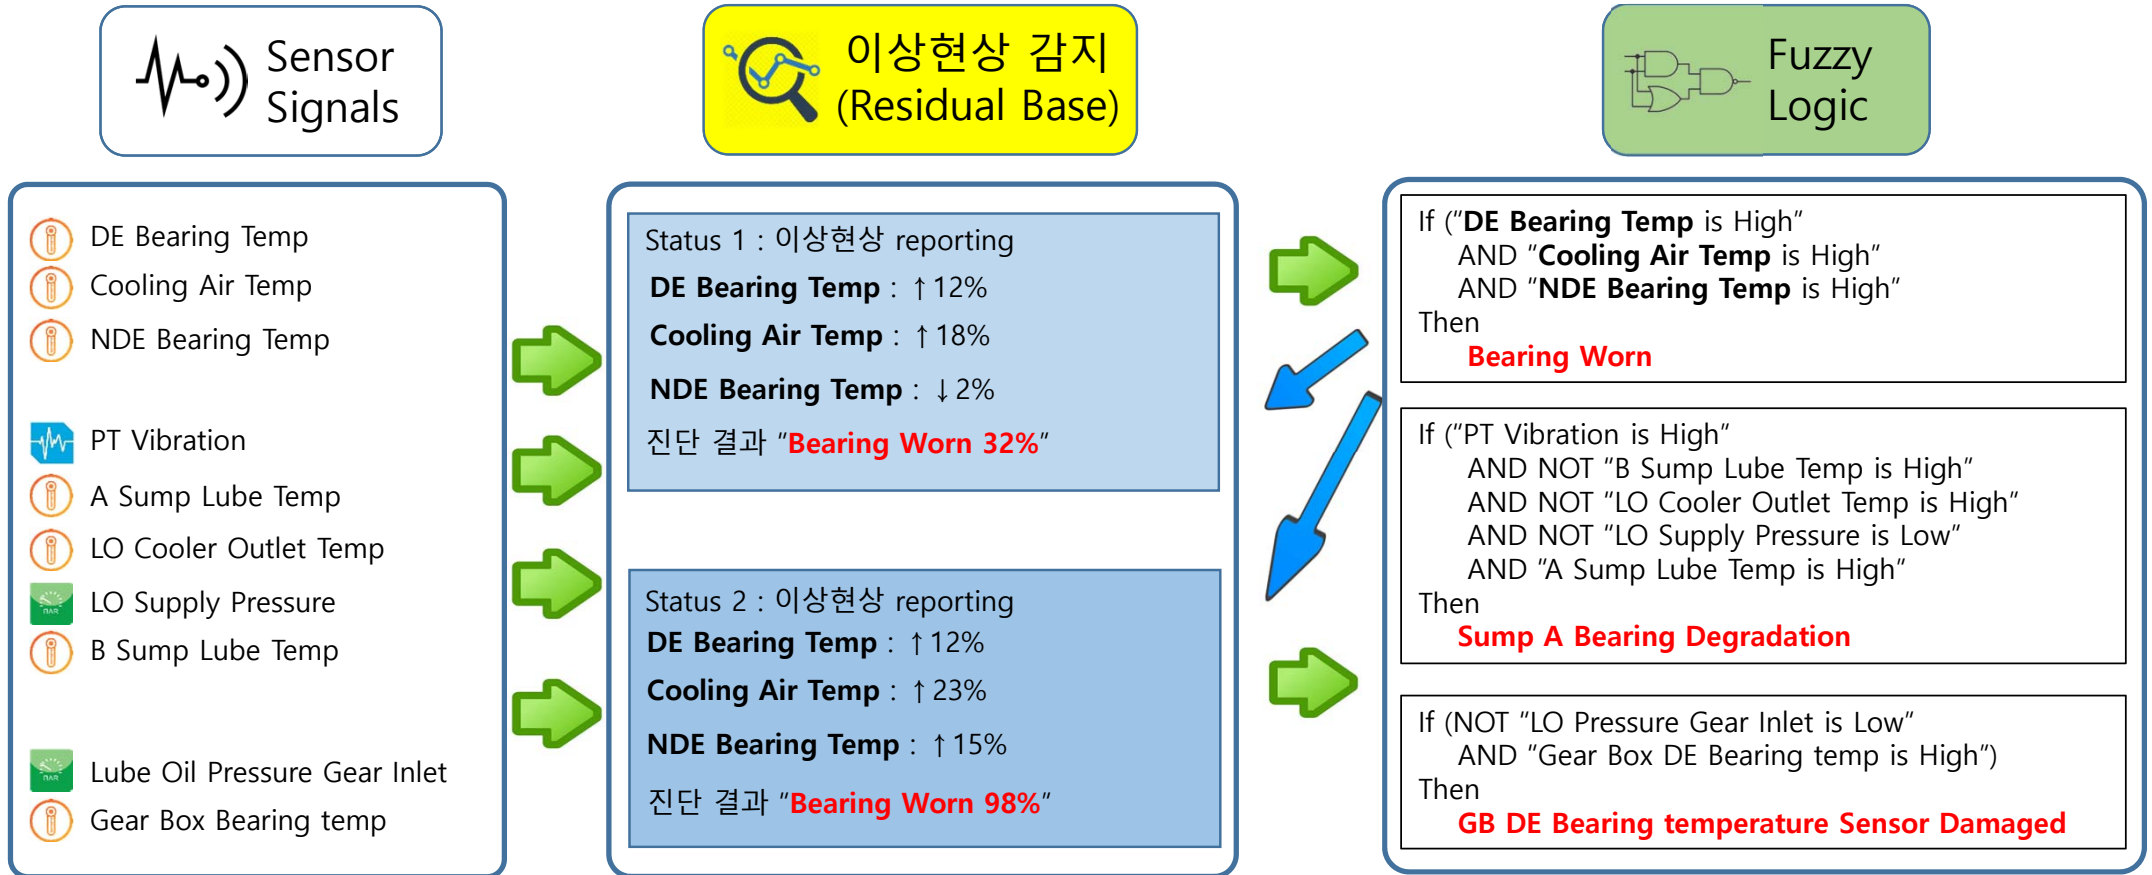
2. AI & CBM

▶ 이상현상 감지 / 고장 원인 진단



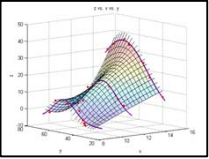
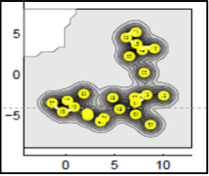
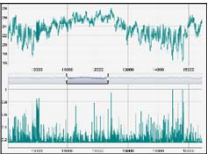
2. AI & CBM

▶ 이상현상 감지 / 고장 원인 진단 (예시)



3. Anomaly Detection

▶ 이상현상 감지 3가지 기법

Type	Reasoning base	Restrictions/ Demerits	Key Differences	비고
Regression 	공간 (N-d space)	최소 4개 이상의 센서 센서들 간에 높은 상관 관계를 가지고 있어야 함 보간 오류(interpolation error)는 제거되어야 함	<ul style="list-style-type: none"> • 모델 작성 생산성 • 테스트 에러 • 노이즈 민감도 • 응답속도 	가장 널리 사용되는 방법 상관 관계가 낮은 센서는 노이즈 역할을 하게 되어 정확도가 떨어짐 진동 센서에 regression을 적용할 경우, 1개의 센서에 대한 statistical feature set(time/frequency domain)을 변수로 사용(보통 수십 개)
One-class classification 	공간 (2-d space)	노이즈 제거를 위해 보통 2개의 센서를 묶어 pair로 적용 많은 메모리 용량을 차지함		N개의 sensor에 적용할 경우, $[N * (N-1) / 2]$ 개의 model이 필요함 상관 관계 지수가 낮아 regression을 적용할 수 없는 센서에 적용
Time-series pattern analysis 	시간	1개의 센서별로 적용	<ul style="list-style-type: none"> • 모델 작성 생산성 • 테스트 에러 	잔차 없이 고장이 발생할 수 있는 경우 적용 학습에 상대적으로 많은 시간 소요 → 주요 센서에만 적용

3. Anomaly Detection

Regression

Gas Turbine
(발전소)

✓

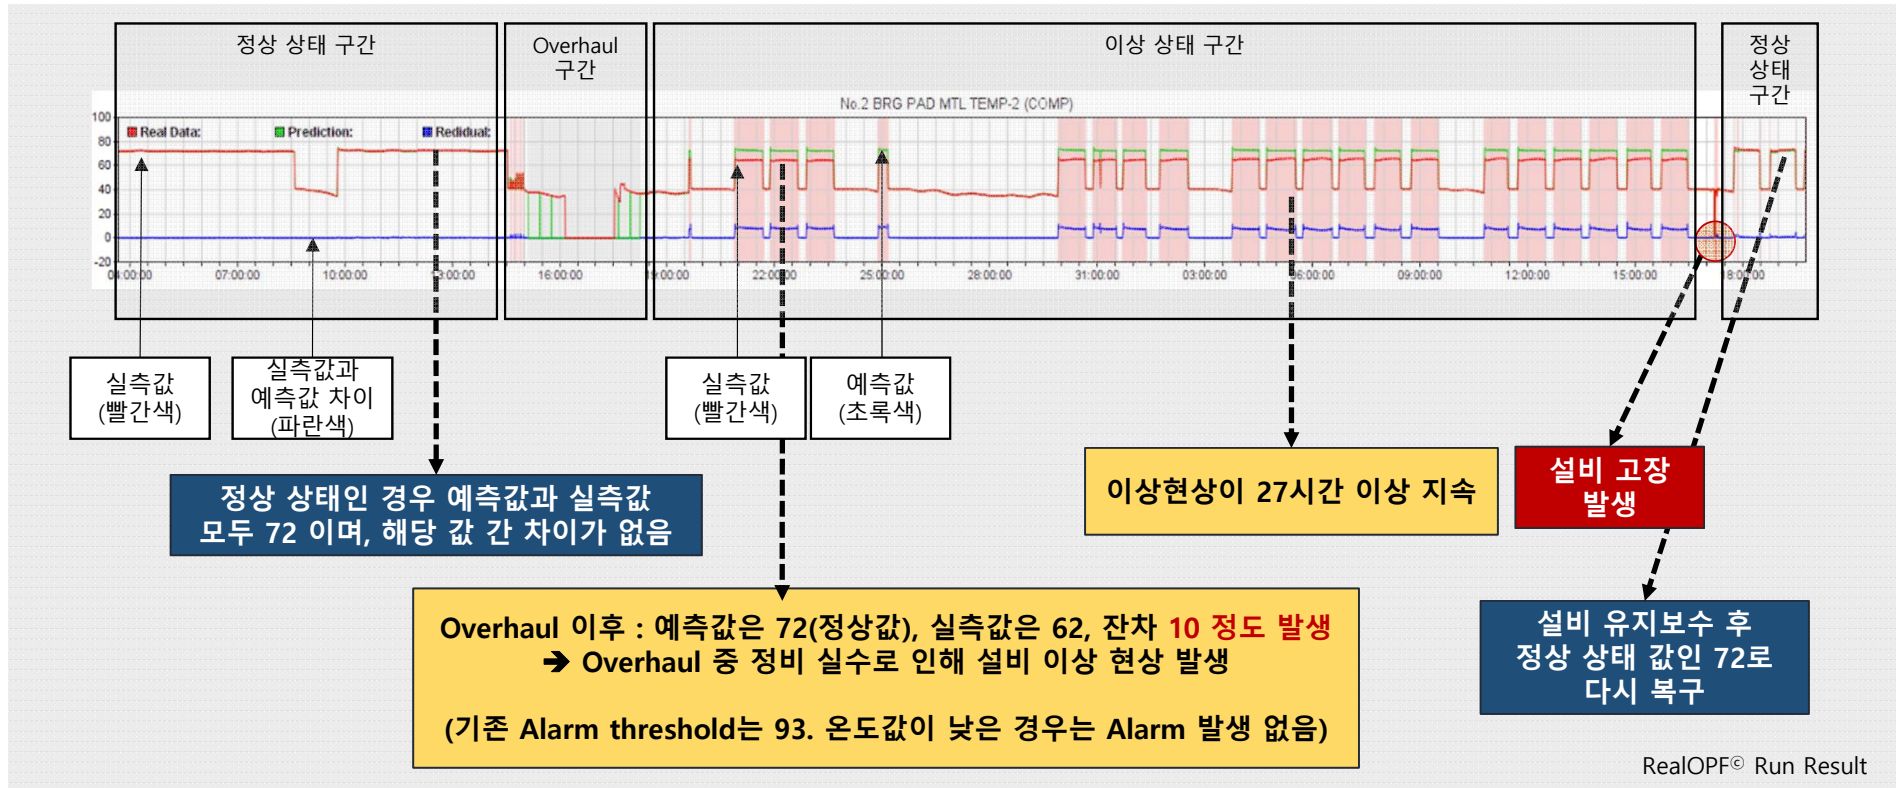
Wearout증상 없음
- Overhaul 직후
- 잔차 증가 거의 없음

✓

온도 센서값이 낮아도
고장 발생

✓

잔차 평균 13.9%



3. Anomaly Detection

▶ One-class Classification



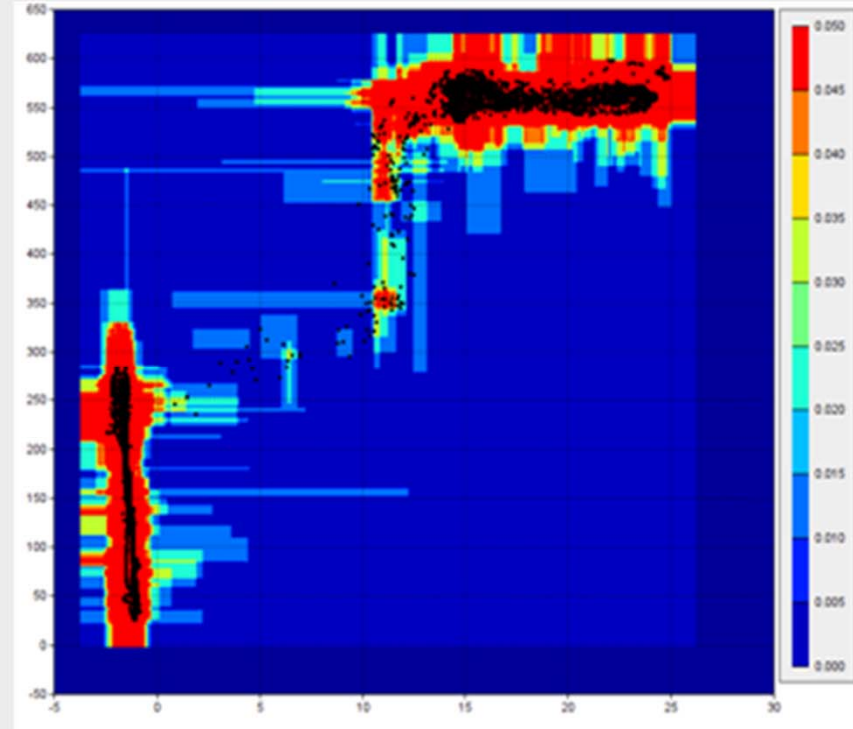
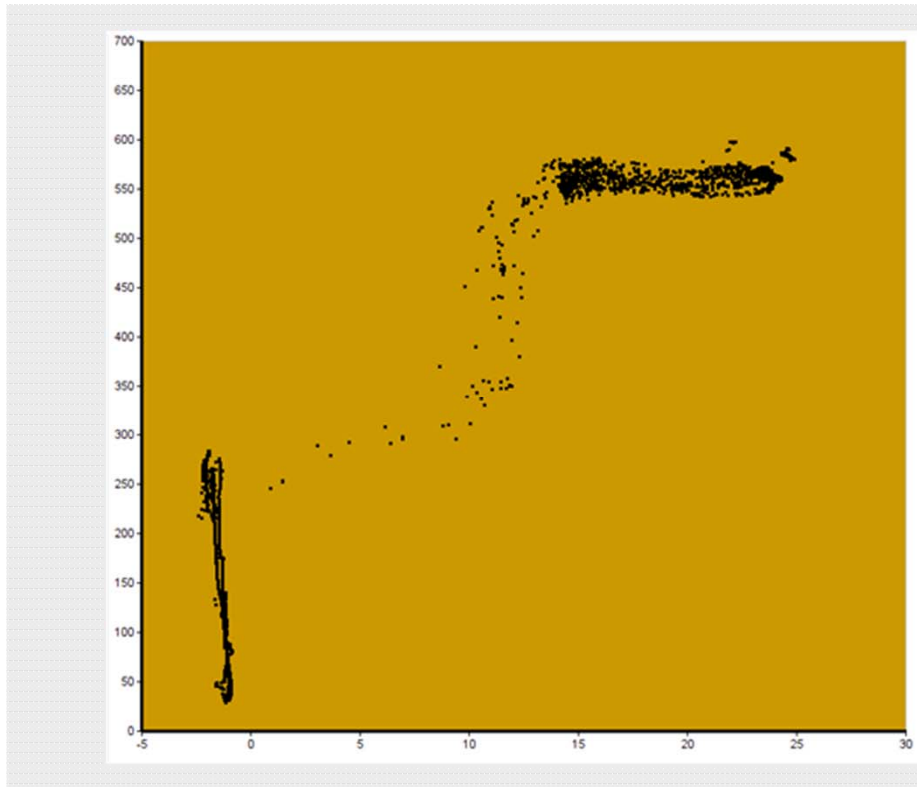
2개 센서의 산포도



타 센서들과 낮은 상관 관계 (Pearson's r 0.6 이하)



Classification 영역 밖의 센서 데이터가 지속적으로 발생할 경우 Alarm 발생

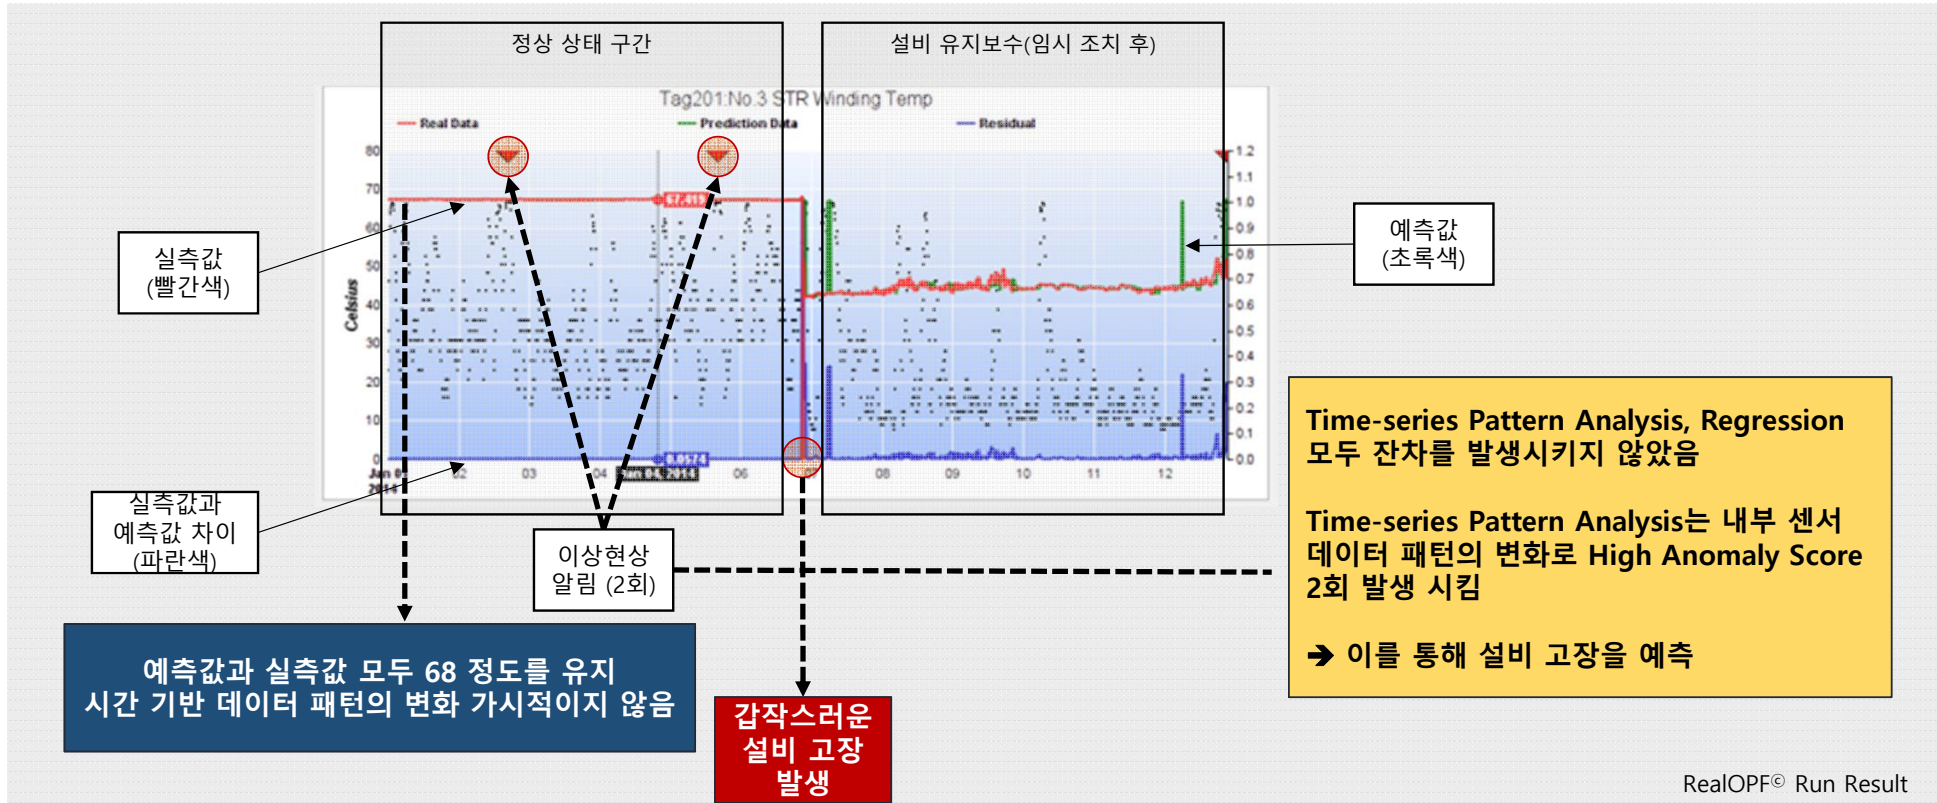


RealOPF© Run Result

3. Anomaly Detection

▶ Time-series Pattern Analysis


- Condensate Pump (발전소)
- ✓
Wearout 증상 없음
- ✓
센서 잔차 거의 없음
- ✓
Time-series Analysis에 의한 High Anomaly Score 2회 발생



RealOPF© Run Result

4. Anomaly Base Expert System

Overview



Sensor **Anomaly**
Low/High

- Sensor High
- Sensor Low

Fuzzy Rules

- IF, THEN
- AND/OR/NOT

Standard Cause of Failure

- Standard Language

Corrective Action Statements

- Manual
- History




Knowledge Acquisition System

- Rule Base
- Standard Cause of Failure
- Corrective Action Statements
- Manual rule Setting
- Auto-rule Generation

Fuzzy Logic System

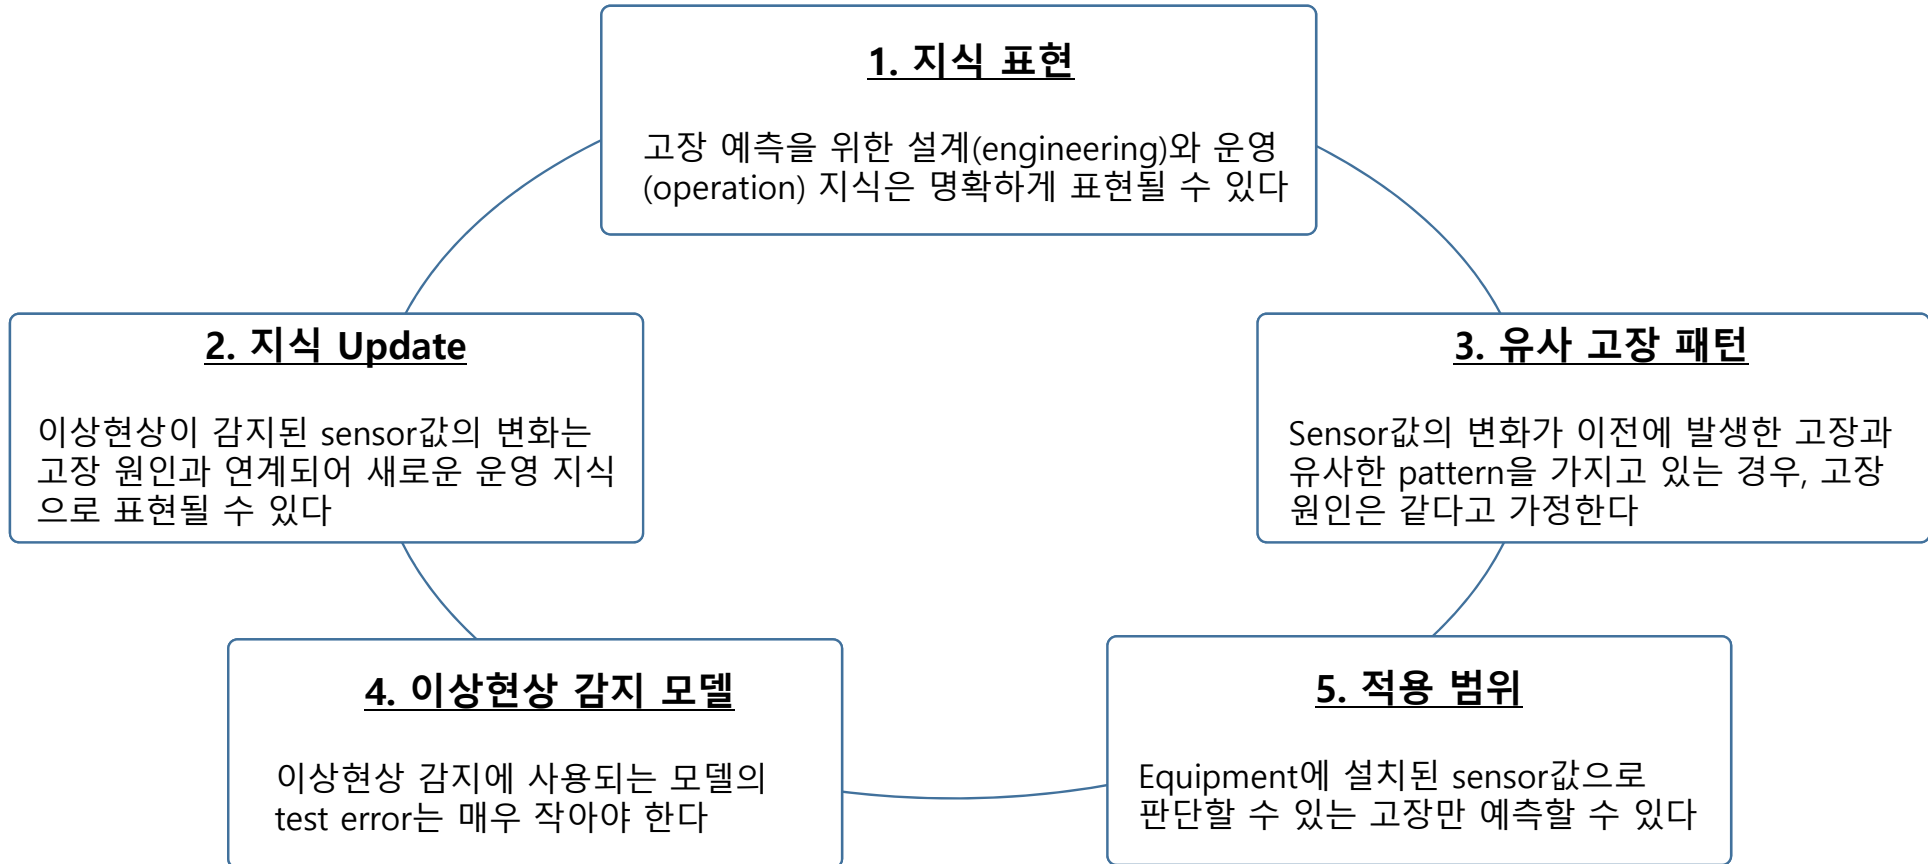
- Sensor Anomaly Analysis
- Inference Engine
- Membership Function
- Deffuzzification



구분	지식 기반 진단	ML 기반 진단
필요데이터 량	-	각 failure mode별 40개 이상
새로운 고장 모드 추가	고장 지식/데이터만 추가	모델 재작성
진단 정확도	<ul style="list-style-type: none"> 고장 지식 데이터 량 	데이터 량
진단 결과에 대한 설명	명확하게 설명	설명할 수 없음
동종의 타 기기에 적용	모델 재사용	모델 재작성
적용 한계점	지식 도출이 어렵다	데이터 확보가 어렵다

4. Anomaly Base Expert System


► Assumptions



4. Anomaly Base Expert System

▶ Assumption : 1

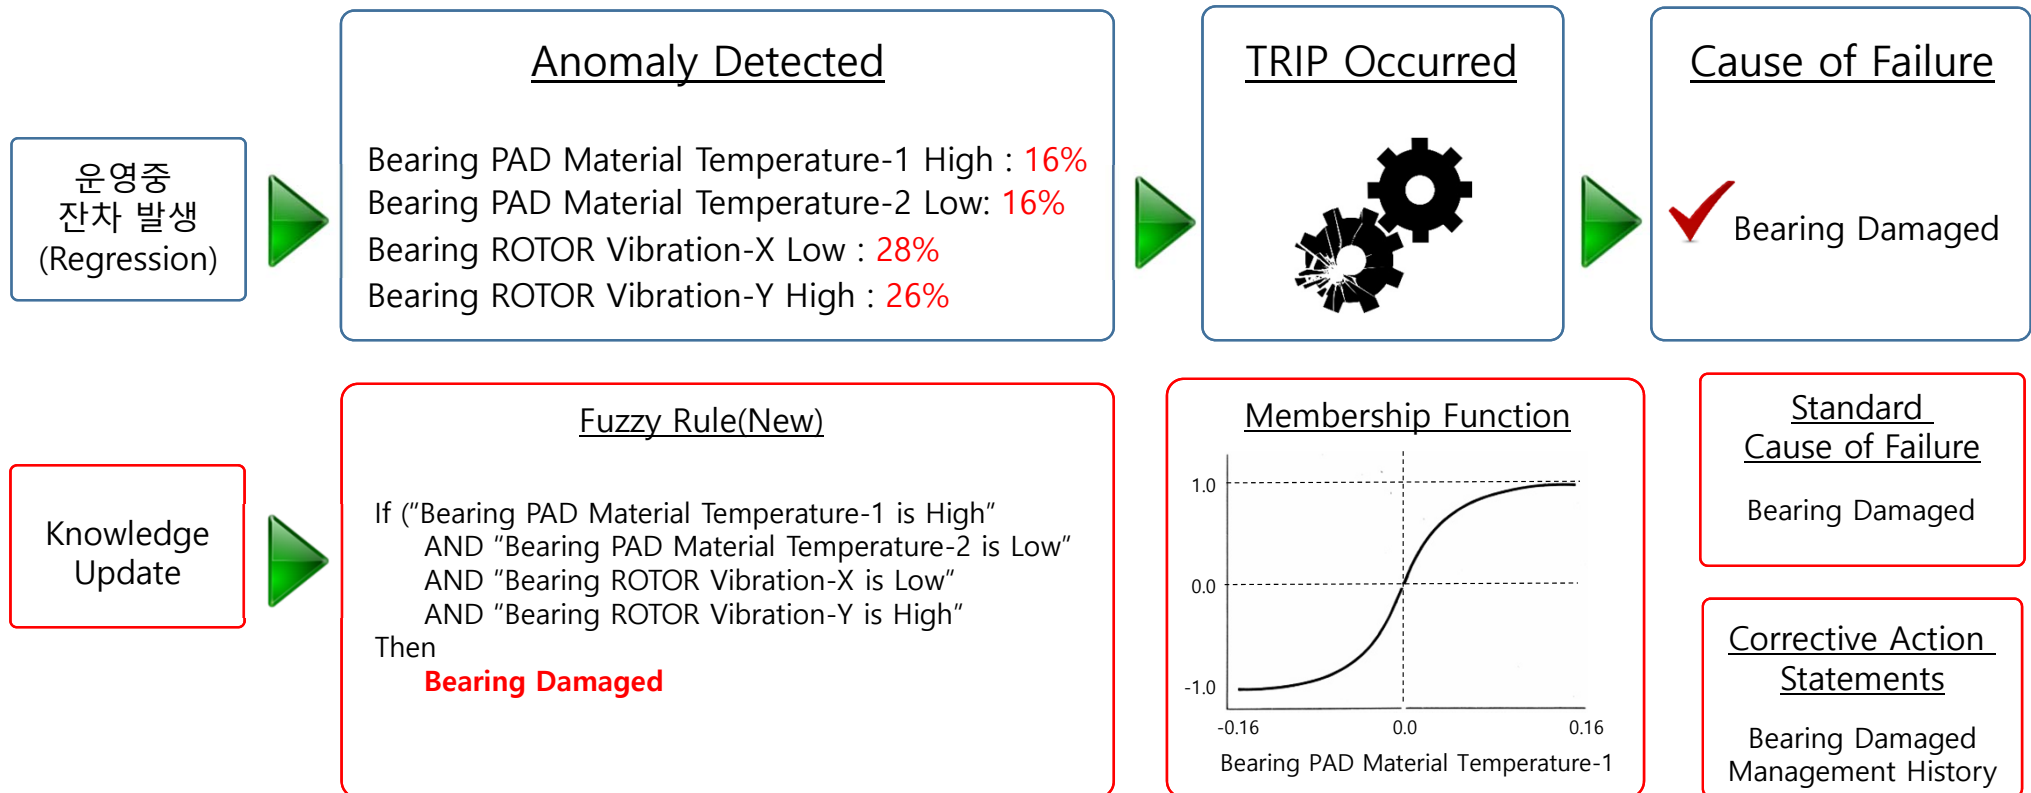
고장 예측을 위한 설계(engineering)와 운영(operation) 지식은 명확하게 표현될 수 있다(operation manual, diagnosis manual, 운영 know-how 등)



4. Anomaly Base Expert System

► Assumption : 2

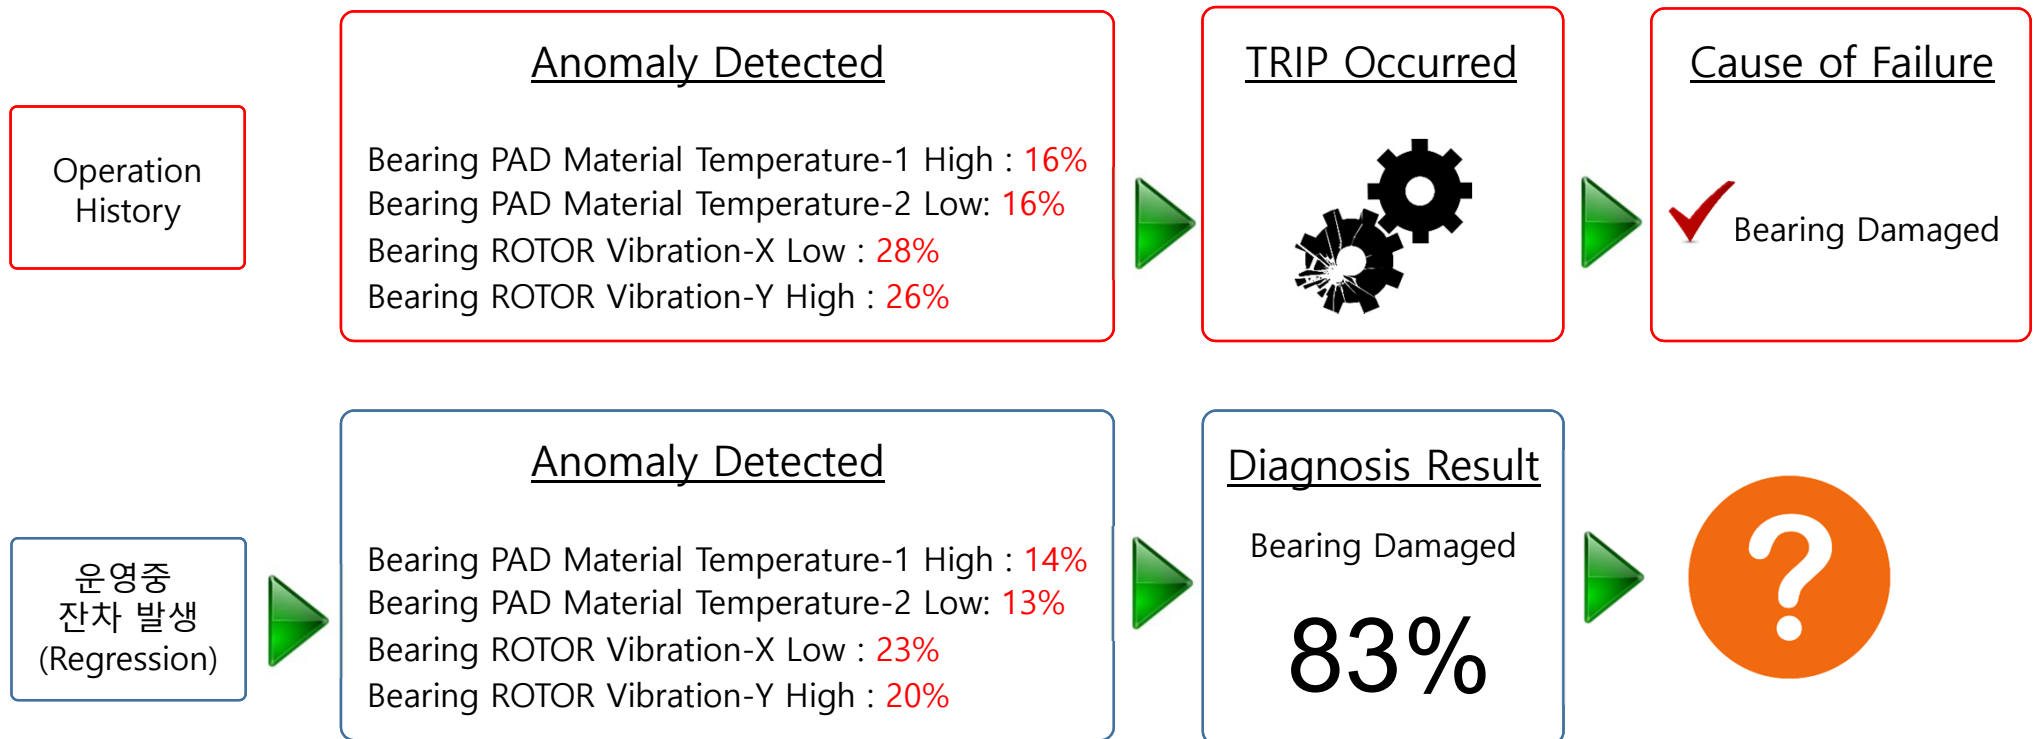
명확하게 표현되지 않은 고장의 경우(설계/운영 지식이 없는 경우), 이상현상이 감지된 sensor값의 변화는 고장 원인과 연계되어 새로운 운영 지식으로 표현될 수 있다



4. Anomaly Base Expert System

▶ Assumption : 3


Sensor값의 변화가 이전에 발생한 고장과 유사한 pattern을 가지고 있는 경우, 고장 원인은 같다고 가정한다. 단, 유사한 pattern의 다른 고장 원인이 판별될 경우, 지식은 update될 수 있다



4. Anomaly Base Expert System

Assumption : 4

이상현상 감지에 사용되는 model의 test error는 매우 작아야 한다($\approx 5\%$ 이하). Test error가 클 경우, FALSE/TRUE ALARM 및 진단 오류 발생 가능성이 높다



이상현상 감지 모델 정확도에 따른 신뢰도

실데이터 기준 모델 오차가 10%인 경우(붉은색), 잔차 기준을 20%로하면 50% 신뢰도, 잔차 기준 30%로하면 67%신뢰도임

신뢰도가 떨어질수록 FALSE/TRUE ALARM 발생 빈도가 높아지고, 진단 오류가 발생함

이상현상 감지를 통한 고장 사전 예측 및 진단

- 고장 발생 이후 원인을 파악하는 것이 아님 **X**
 - Random failure를 모두 포함(명확한 고장 징후 발생 이전)
- ➔ **실 고장 발생시 잔차가 30%인 경우, 잔차 30% 발생 이전에 이상현상 및 원인을 판단할 수 있어야 함**

Anomaly Base Expert System의 핵심은 정교한 이상현상 감지 모델. 실용적인 측면에서 보면,

- Regression Model – Test Error 5% 이하
- One-Class Classification Model – Test Error 5% 이하
- Time-series Pattern Analysis – Test Error 3% 이하

5. Conclusions

- ▶ **ML을 활용한 센서 데이터 기반 이상현상 감지는 다양한 방법을 통해 실 적용될 수 있다**
 - Regression / One-class Classification / Time-series Pattern Analysis
- ▶ **ML을 활용한 센서 데이터 기반 설비 고장 진단/잔여수명 예측의 경우,**
 - Wear-out없이 random하게 발생하는 대부분의 고장($\approx 87\%$)에 실 적용하기 어렵다
- ▶ **센서 데이터 기반 고장 진단의 경우 Anomaly Base Expert System은 다음 조건하에 실 적용 될 수 있다**
 - 설계/운영 지식을 통한 센서 데이터 변화와 고장 연계
 - 운영 중 발생한 고장과 센서 데이터 이상현상 pattern의 지식화
 - 고장 발생시 센서 이상현상 pattern은 반복될 경우 유사한 고장을 발생
 - Anomaly Detection Model의 Test Error는 매우 작아야 함($\approx 5\%$ 이하)