



무오류의 디지털 트랜스포메이션

측정센서 고장 감시 시스템

석규한

(주)테크다스 www.techdas.co.kr

4차 산업혁명은 센서로부터 시작되었다고 해도 과언이 아니다. 산업 현장에서 사물인터넷 기술이 적용되면서, 스마트 시스템들이 지속적으로 개발되고 있다. 기계 성능 감시, 운전 정보 제공, 고장 예측, 설비 관리 등 다양한 목적을 위해 온라인 시스템들이 활용되며, 이러한 어플리케이션들의 고도화는 센서가 다양한 정보를 정확하게 측정할 수 있는 능력 덕분이다. 이러한 기술들은 공장의 신뢰성 향상에 큰 기여를 하고 있다.

센서에 대한 의존도가 높은 만큼 센서 고장은 값비싼 어플리케이션을 무용지물로 만들고, 결과적으로 플랜트의 성능을 저하시킨다. 특히 안전이나 환경, 품질과 관련된 경우, 물질적, 시간적 손실 또는 인명 사고의 원인이 되기도 한다. 역설적으로, 사고를 예방하기 위해 설치한 센서가 사고의 원인이 될 수도 있다. 한 통계에 따르면 사고의 90%는 센서 고장을 비롯한 사소한 결함에서 시작된다고 한다. 이러한 결함을 조기에 발견하여 적시에 조치하면 큰 문제가 없지만 그렇지 못하면 사고로 발전할 수 있다.

센서의 데이터를 실시간으로 분석하여 이상 징후를 탐지하고 예방하는 <센서 고장 탐지 및 오지시 보정> 기술을 통해, 센서 고장으로 인한 피해를 예방하고 플랜트 조업 안전성을 확보하며 생산성을 극대화하기 위해 무결점의 디지털 트랜스포메이션을 구축하고자 한다.

1. 센서 사고 사례 분석

프랑스 정부 주관으로 정유, 제철, 화학, 식품 플랜트에서 1981년부터 2009년까지 약 20년 동안 발생했던 사고 사례를 분석한 적이 있다.¹ 그 결과에 의하면 센서 고장으로 다양한 사고가 발생하였으며, 그 중에서 위험 물질 누출이 전체의 62%로 가장 많았다.

¹ Accident Analysis of Industrial Automation, Part 1/3, French Ministry of Ecology, Sustainable Development and Energy



그림 1. 플랜트 산업에서 센서 고장으로 인한 사고

사고를 가장 많이 일으킨 센서 종류는 온도나 압력 등이 포함된 Physical Parameter 센서로 전체의 43%를 차지했다. 그리고 개별적인 센서에서는 레벨 센서가 가장 많은 사고를 유발했다. 프랑스 정부는 [처음 설치 시에 적합한 센서를 선택할 것이 중요하지만, 이보다는 유지보수를 충분히 실시할 것이 더 중요하다](#)고 제안한다.

반면에 ARC Advisory Group 이 실시한 조사에 의하면 [센서 유지보수의 50%는 과잉](#)이라고 판단한다. 그 이유는 주기적 일괄적으로 유지보수가 이루어지기 때문이라고 한다. 이로 인해 과다 비용이 지출되어 정작 필요한 곳은 등한 시 된다는 의견도 있다. 두 조사를 종합하면 모든 센서를 대상으로 하기보다는 필요한 센서에 대해서만 선택적으로 유지보수를 실시하는 상태에 기반한 유지보수(Condition Based Maintenance)가 필요하다.

2. 센서 고장 유형

샘플링 라인의 막힘, 전선의 단락이나 접속 불량, 센서 파울링, 센서의 단절, 유틸리티 차단, 프로브 부식 열화, DB 결함 등 센서 고장을 일으키는 원인은 다양하다. 샘플링 시스템의 막힘이나 전선의 단락과 같이 사전 징후 없이 급작스럽게 나타나는 물리적 변화보다는 파울링이나 부식과 같이 사용 연한과 관계없이 서서히 발생하는 이상은 잘 관찰하면 징후를 사전에 포착할 수 있기 때문에 고장감시 기술의 대상이 된다.

보통 센서 고장을 아래와 같이 7가지로 구분한다?

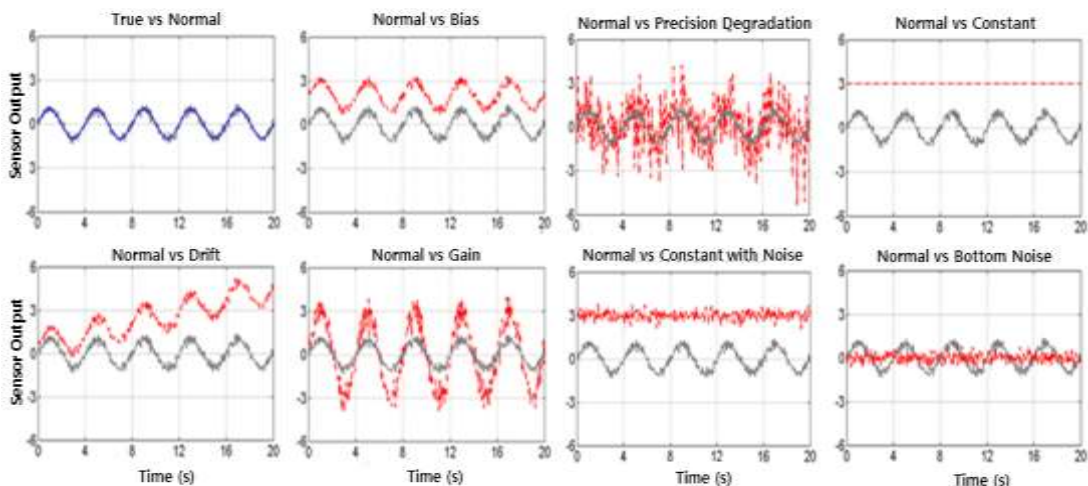


그림 2. 센서 고장 유형

² Ting-Hua Yi¹, Hai-Bin Huang¹, and Hong-Nan Li, Development of sensor validation methodologies for structural health monitoring: a comprehensive review, Measurement 2017

이 중에서 몇가지 유형에 대해 센서 고장 감지가 어려운 이유를 설명하고자 한다.

- **센서 점진적 변화(Sensor Drift):** 가장 흔한 고장으로 시간이 진행되면서 서서히 변하기 때문에 High/Low 방식의 기존 경보체계로는 초기에 감지하기 어렵다.
- **센서 편향(Sensor Bias) 오차:** 플랜트가 돌발 가동 정지나 비정상적인 부하 변동으로 인해 물리적인 충격이 가해지면 센서의 정렬이 비틀어져 편향오차를 가질 수 있다. 편향 정도가 기존 경보체계의 범위 내에 존재하면 기존 경보체계로는 감지하지 못한다.
- **센서 고착(Sensor Stuck):** 먼지 등의 이물질이 침적되면 센서 신호가 고착된다. 센서 출력이 정상 운전 영역에 머무르면 기존 경보체계로는 감지하지 못한다.

3. 기존 경보 체계

공장 운전에 사용하는 DCS(Distributed Control System)나 PLC(Programmable Logic Control)의 경보체계는 센서 값이 경계치를 벗어날 때 경보를 발행하는 단순한 방식이다. 이 방식을 창시자³의 이름을 따서 Shewhart Control 이라 부르는데, 대부분의 DCS 나 PLC 가 채택한 이 경보체계는 1930 년에 고안된 방식이다.




그림 3. 전통적 알림 방식인 Shewhart Control Chart

위 그림의 Shewhart Control Chart 에서 경계치 $k\sigma$ 에서 k 는 표준편차의 배수를, σ 는 센서 측정값의 표준편차를 의미한다. 여기서 제 1종 오류와 제 2종 오류를 설명할 필요가 있다.

- **제 1종 오류:** 그림 5의 오른쪽 화살표 지시 영역으로 정상을 이상으로 판단하는 거짓 알람 오류
- **제 2종 오류:** 그림 5의 왼쪽 화살표 지시 영역으로 이상을 정상으로 판단하는 미탐지 오류

k 를 크게 하여 정상 구간을 늘리면 제 1종 오류를 줄일 수 있지만, 제 2종 오류가 증가한다. 반대로 k 를 작게 하여 정상 구간을 줄이면 제 2종 오류를 줄이는 대신에 제 1종 오류가 증가한다.




그림 4. 제어 경계치와 경보 오류

³ Walter A. Shewhart, 1899~1967, 미국 태생의 물리학자 겸 엔지니어, 통계학자로 통계적 품질제어 창시자

따라서 최적의 k를 결정하여 오류를 합리화하는 것이 필요하다. Shewhart Control의 경계치를 결정하는데 있어서 주로 영국의 EEMUA⁴가 제시한 가이드라인을 따른다. EEMUA는 운전자의 업무부하를 고려하여 경보 수준 별로 개수를 제시하는데, 이를 기준으로 k를 결정한다. 경보 수준에 따라 경보 음(Horne)을 달리하여 시급성을 구분한다.

표 1. 경보 범위 설정 가이드라인

경보 수준	설정 기준
Emergency Priority	매우 드물게
High Priority	Shifty 당 5회 이하
Medium Priority	시간 당 동안 2회 이하
Low Priority	시간 당 10회 이하

4. 센서 고장감지 기법

기존에는 Reference 측정값을 기준으로 센서 측정값의 평균, 표준편차 등을 계산하고, 일정한 기준치와 비교하여 센서 오작동을 탐지하였다. 최근 센서 기술의 발달, 사물인터넷 기술의 발전, 그리고 센서로부터 나오는 빅데이터들을 빠르게 처리할 수 있는 컴퓨터 성능의 향상으로 공장 이상이나 고장을 정밀하게 예측하는 것이 가능하게 되었다. 기존의 방법은 단순하고 직관적이지만, 센서 데이터의 패턴을 분석하는 AI 기술은 더욱 정확하고 효율적이다.

미국의 한 대학에서 조사한 바에 따르면 AI 솔루션의 적용으로 적용하지 않았을 때보다 무려 20배의 빠른 속도로 센서의 고장을 감지 했다고 한다.⁵ 이러한 경보체계의 개선은 궁극적으로 제 1종 오류와 제 2종 오류를 동시에 줄일 수 있게 한다.




그림 5. 경보체계 개선과 판단 오류 감소

센서 고장감지 기법은 잔차 분석(Residual Analysis) 기법과 패턴인식(Pattern Recognition) 기법이 있다.

⁴ Engineering Equipment & Materials Users Association

⁵ Abnormal situation management: Challenges and opportunities in the Big Data Era, Computers and Chemical Engineering, 2016

- **잔차 분석 기법:** 잔차 분석 기법은 새로운 데이터가 입력되면 변수 간의 관계를 이용하여 학습한 모델로 각 변수를 예측하고, 예측값과 측정값의 잔차를 통해 고장을 감지하는 기법이다. 센서가 정상이면 잔차가 작고 시간이 지나면서 0에 수렴하지만, 센서에 고장이 있다면 잔차가 크고 시간이 지나더라도 0에 수렴하지 않는다. 이러한 원리를 이용하여 센서 고장을 판단한다.
- **패턴 인식 기법:** 패턴 인식 기법은 새로운 데이터가 입력되면 변수 간의 관계를 이용하여 패턴을 구하고, 학습한 모델 패턴과 비교하여 센서 고장의 발생을 판단하는 기법이다. 패턴 인식 기법은 3 단계로 진행되는데, 먼저 패턴 파라미터를 통해 고장 센서가 있는지 감시하고, 어느 센서가 고장인지 식별하고, 식별한 고장 센서의 오지시 값을 보정한다.




그림 6. 잔차(측정값-예측값)를 이용한 센서 고장감지

잔차 분석법의 한 예는 미국 Expert Microsystems 사의 SureSense^{®6}이며, 패턴인식 기법의 한 예는 (주)테크다스의 PTO-Valert[™]이다. SureSense[®]는 플랫폼 형태로 제공되고, PTO-Valert[™]는 파이썬 프레임워크 형태로 제공된다. 따라서 정형화된 문제는 SureSense[®]를, 비정형화된 문제는 PTO-Valert[™]를 사용하는 것이 좋다.

SureSense[®]는 우주 왕복선의 센서 고장 감시 목적으로 '96년에 NASA에서 개발한 소프트웨어로 ESEE(Expert State Estimation Engine) 알고리즘을 사용한다.⁷ 참고로 GE의 Smart Signal은 MSET(Multivariate State Estimation Technique)을 사용하는데 두 알고리즘은 비슷한 방식이다. PTO-Valert[™]는 주성분분석법을 기반으로 Hotelling의 T2와 SPE, 공현도 조사 등을 사용하며, 파이썬 코딩하여 시스템을 구성한다.

SureSense[®]와 PTO-Valert[™]를 4가지의 센서 고장 문제에 적용하여 고장 감지 성공률을 비교하였는데, 아래 그래프와 같이 성능이 매우 유사하였다.

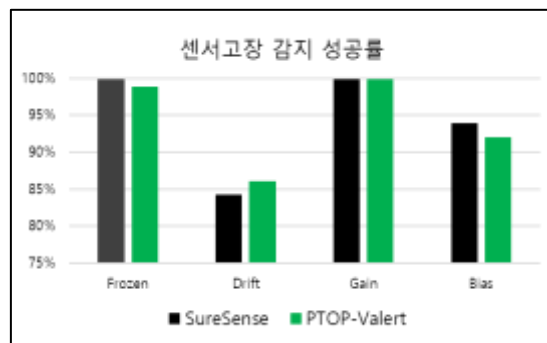


그림 7. SureSense[®]와 PTO-Valert[™] 적용 결과 비교

⁶ SureSense Virtual SME, Premier Advanced Pattern Recognition System, Expert MicroSystems

⁷ Technical Review of On-Line Monitoring Techniques for Performance Assessment, Volume 1: State-of-the-Art, University of Tennessee, 2006

적용 사례

1) 드럼 레벨 센서 드리프트 고장

SureSense®는 그림 8과 같이 고장 센서의 셀을 붉게 만들어 경보를 발행한다. 본 사례는 드럼의 레벨 센서, 즉 그림 8에 의하면 U-105의 고장이 의심되는 경우이다.




그림 8. 탱크 레벨 관리 SureSense 화면

별도의 트랜드로 확인 가능하며, 그림 9의 우측 트랜드는 훈련된 패턴 인식 모델을 이용하여 예측한 값(붉은색 점)과 실제 측정된 값(파란색 점)을 나타낸 것이다. 그림에서 두 값의 차이가 서서히 증가하는데 이는 전형적인 센서 드리프트 유형이다. 그림 9의 좌측 트랜드는 패턴 인식 모델의 훈련 트랜드로 측정값과 예측값이 중첩되어 있다.




그림 9. SureSense 학습 결과(좌) 및 센서 드리프트 고장(우)

2) 배관 막힘 현상

㈜테크다스의 PTOV-Valert™의 적용 사례이다. 화학 공장에서 일부 성분이 자연적으로 반응하여 고분자 물질이 생성되기도 하는데, 이로 인해서 배관이 막혀서 공장 가동이 정지된 사례이다. 배관 막히고 있다는 사실을 조기에 감지하면 스트레이너 청소, 펌프 스위치, 병렬 설비의 부하 배분 등을 통해 사전 대처가 가능하지만, 실기하여 많은 양의 고분자 물질이 쌓여서 운전이 불가능하게 된 사례이다.

PTOV-Valert™의 SPE(Squared Prediction Error) 신호에 의해 문제 발생 초기에 고장 발생을 감지하였다. 그림 9의 시계열 추이도에서 09시에 SPE 신호가 붉은색 경계선(99% 신뢰구간)을 벗어나서 이상 신호로 인식하였다.




그림 10. SPE 시계열 추이도; 09시에 이상 신호 발생

공헌도 조사를 통해 이상 신호의 원인을 진단한 결과 유량계가 고장으로 나타났다.




그림 11. 공헌도 조사에 의한 원인 인자 도출(보안을 위해 변수 명을 삭제함)

유량의 트렌드는 그림 12와 같으며 09시에 고장이 발생하였으나, 운전자가 간과하여 가동 정지에 이르게 되었다.




그림 12. 유량 시계열 추이도; 09시에 이상 신호 발생

3) 납사분해 공장 Quench 에 점도 이상

본 사례는 PTOP-Valert™의 적용 사례로, 납사분해 공장의 Pyrolysis Fractionator 는 분해가스를 QO로 급랭하여 부가반응을 억제하고 폐열을 회수하는 공정이다. QO의 점도가 높으면 열전달이 제대로 이루어지지 못하므로 점도를 일정 값 이하로 유지하여야 한다. 점도는 실험실에서 분석하여 제공하는 값으로, 실시간 모니터링을 위하여 가상센서를 개발하여 사용하였다. 시계열 추이도는 아래 그림과 같다. 점도가 기준치를 초과한 원인을 진단하고자 한다.




그림 13. QO 점도의 가상센서 예측값 시계열 추이도(보안을 위해 축의 범위를 삭제함)

공헌도 조사를 통해 QO 점도 이상의 원인을 진단한 결과 아래 그림과 같이 3 개의 변수(x6, x7, x8)가 지목되었다. x6과 x7 이 작고, x8 이 커서 발생한 것으로 분석되었다.



그림 14. 공헌도 조사에 의한 원인 인자 도출(보안을 위해 변수 명을 삭제함)

변수 x6, x7, x8의 온도 트렌드는 그림 15와 같이 공현도 조사 결과와 일치하였다.

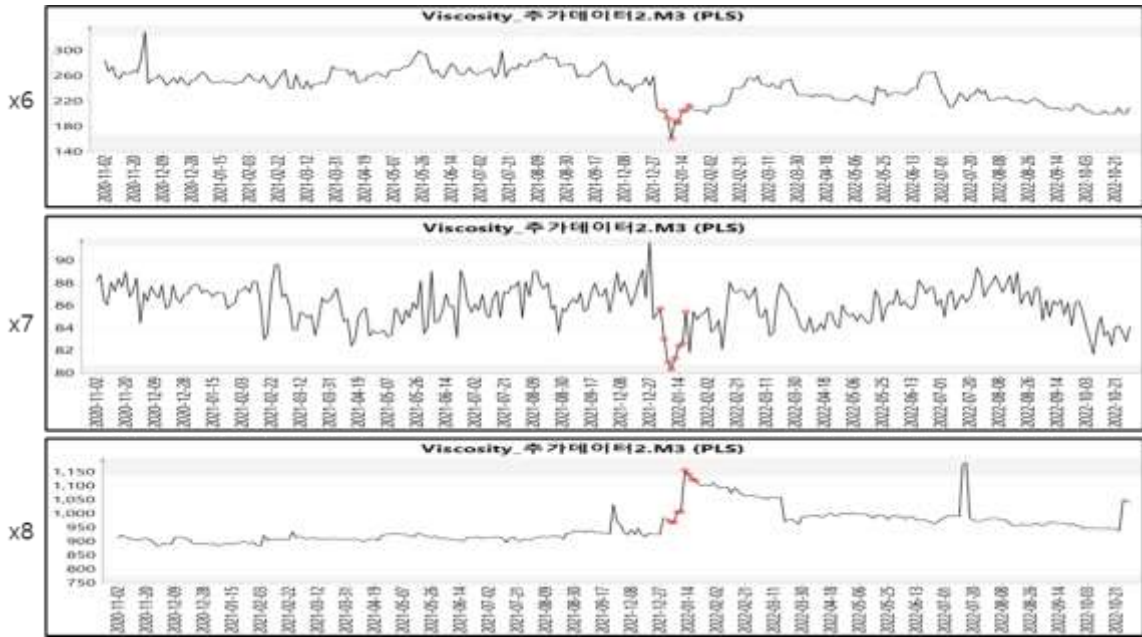


그림 15. QO의 점도 영향인자 시계열 추이도(보안을 위해 변수 명을 임의로 부여함)

5. 결론

미국 Expert Microsystems 사의 SureSense[®]나 (주)테크다스의 PTOp-Valert[™]을 센서 고장 감시 사례를 통해 소개하였다. 방법론도 중요하지만, 이보다는 머신러닝 기법이나 소프트웨어보다 현장의 도메인 지식을 어떻게 확보하느냐가 중요하다. (주)테크다스의 그간 경험에 의하면, 도메인 지식 습득 vs. 프로그램 구성의 시간 투자 비율이 3:1 정도가 적합하다.

제조 공장의 AI 머신러닝 분야에서 Sensor Validation 이 가장 확실한 성공 분야이다. Sensor Validation 을 통해 센서의 신뢰도와 함께 조업 안전성 확보하고, 무효의 디지털 트랜스포메이션 구축을 기대한다.

석규한 선임연구원

010-2540-5629 / asdm159@techdas.co.kr

(주)테크다스 www.techdas.co.kr

서울특별시 금천구 디지털 1로 204, 510 호 (가산동, 가산반도아이비밸리) (우편번호: 08502)

Tel. 82 (0)2 865 1313 Fax. 82 (0)2 865 1311