

## 머신러닝 기법을 활용한 LDPE 공정의 이상 감지

이창송 · 이규황<sup>†</sup> · 이호경

LG화학 기술연구원  
34122 대전광역시 유성구 문지로 188  
(2020년 1월 29일 접수, 2020년 3월 2일 수정본 접수, 2020년 3월 6일 채택)

## Fault Detection in LDPE Process using Machine Learning Techniques

Changsong Lee, Kyu-Hwang Lee<sup>†</sup> and Hokyoung Lee

LG Chem Research Park, 188, Moonji-Ro, Yuseong-Gu, Daejeon, 34122, Korea  
(Received 29 January 2020; Received in revised form 2 March 2020; accepted 6 March 2020)

### 요 약

머신러닝 기법을 활용하여 LDPE (Low Density Polyethylene) 공정의 이상을 사전 감지하고, 설비의 수명을 예측할 수 있는 기술을 소개한다. 안전성과 생산성 극대화를 위해, 화학 공정의 예상치 못한 이상을 사전에 감지하고 예방하는 것은 매우 중요하다. LDPE 공정은 3,000 kg/cm<sup>2</sup>g 이상까지 증압되는 고압 공정이기 때문에, ESD (Emergency Shutdown)가 발생하면 예상치 못한 부동이 발생하고, 그에 따른 보수 기간 증가로 인한 생산성 손실이 발생한다. 고압 공정의 주요 변수들의 운전 데이터를 수집하고, 비지도학습 머신러닝 기술을 활용하여, ESD의 사전 감지 모형을 개발하였다. 4회의 ESD를 2.4일 전에 감지하는 결과를 얻을 수 있었다. 더불어, 물리적으로 의미 있는 핵심 변수들을 활용하면, 고압 설비의 수명을 예측할 수 있음을 확인할 수 있었다.

**Abstract** – We propose a machine learning-based method for proactively detecting faults in LDPE processes and predicting equipment lifespan. It is important to detect and prevent unexpected faults in chemical processes in order to maximize safety and productivity. Since LDPE process is a high-pressure process up to 3,000 kg/cm<sup>2</sup>g or more, once ESD occurs, it can result in productivity loss due to increased maintenance periods. By collecting key variables operation data of the process and using unsupervised machine learning methods, we developed a fault detection model which detected 4 ESDs 2.4 days prior to the occurrence. In addition, it was confirmed that the life expectancy of a hyper compressor can be predicted by using the physically significant key variables.

**Key words:** Machine learning, Unsupervised learning, Principal component analysis, Hotelling's T<sup>2</sup>, LDPE, Fault detection, Emergency shutdown (ESD)

### 1. 서 론

일반적인 화학 공정의 경우, 최적의 공정 조건에서 원하고자 하는 최종 생성물을 얻기 위하여 환경적 영향, 안전성, 생산성, 품질 등 여러 사항들을 고려해야 한다. 특히 안전성의 확보는 생산성과 품질의 저하와 직, 간접적으로 연관되어 있는 이슈이므로 매우 중요하게 다루어야 함은 당연하다.

화학공장에서도 보다 안전성이 우수한 공정을 갖추기 위해서는 이상의 원인을 조기에 감지하고 원인을 해결하여, 생산과 품질에 영

향이 없도록 유지하는 능력을 갖추는 것이 필요하다. 여기서 말하는 이상은 물리적 고장, 교란, 작업자의 오류 등의 이유로 말미암아, 공정이 정상 상태를 벗어나는 경우를 의미한다. 예상치 못한 센서 및 제어기의 고장(malfunction), 오염(fouling), 막힘(blockage), 누출(leaking), 원료의 변화, 유틸리티의 변화 등이 이에 해당한다.

화학 공정 내에는 많은 순환 흐름과 제어 루프가 존재하기 때문에 이상을 감지하는 것은 쉽지 않다. 화학 공정의 이상을 감지 및 진단하는 방법은 공정 지식을 얻는 방법에 따라 모델 기반과 데이터 기반 방법으로 나누어지며, 각각 지식의 형태에 따라 정량적, 정성적 방법으로 나눌 수 있다[1-3]. 모델 기반 방법론은 공정을 에너지, 물질 수지식 등을 비롯한 물리, 화학적인 이론에 기반하여 모델링 한 후, 실제 데이터와 예측 결과를 비교하여 이상의 원인을 진단하는 방법이다. 하지만 이러한 방법은 공정에 대한 해석적 모델을 구축해야 하므로 쉽지 않다. 최근에는 이를 대체하면서 비교적 간단한

<sup>†</sup>To whom correspondence should be addressed.

E-mail: amine@lgchem.com

\*이 논문은 POSTECH 이인범 교수님의 정년을 기념하여 투고되었습니다.  
This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (http://creativecommons.org/licenses/by-nc/3.0) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

데이터 기반 방법론이 각광 받고 있으며, 본 논문에서는 이 데이터 기반 방법론을 적용한 연구 결과를 소개하도록 하겠다. 이러한 방법들은 공정의 정상 상태 데이터를 이용하여 정상 상태의 고유 패턴을 설정한다. 그리고 발생 가능한 모든 이상에 대해 정상 상태의 고유 패턴과 구분이 되는 패턴을 설정하게 된다. 공정에서 실제 이상이 발생했을 경우, 데이터의 패턴을 계산하여 기존의 패턴과 비교함으로써 이상의 발생 유무 및 그 종류를 판별하게 된다. 정상과 이상에 대한 정보가 명확할 때는 지도 학습 방법을 사용하며, 회귀 분석, Support Vector Machine 등의 전통적 방법들[4]부터 최근 각광 받고 있는 Random Forest 등 앙상블 방법들[5]과, 신경망 이론을 기반으로 하는 딥러닝 방법들[6]을 사용할 수 있다. 하지만, 정상과 이상에 대한 정보가 명확하지 않을 때는 비지도 학습 방법을 사용하게 되며, 일반적으로 주성분 분석(Principal Component Analysis, PCA) 및 다양한 군집 분석 방법들을 흔히 사용한다[6-8].

### 1-1. 이상 감지 및 진단

일반적인 이상 감지 및 진단 모형의 개발 과정은 다음과 같다. Step1: 정상 데이터로 모형화, Step2: 정상과 이상 데이터 구분 여부 판단(이상 감지), Step3: 이상의 종류 구분(이상 진단)의 단계로 개발한다.

이 과정에서 특히 중요한 것은 첫 번째 step의 정상 데이터 모형화 과정과, 세 번째 step의 이상들의 구분 과정, 즉 이상 진단 가능성의 판단 여부이다. 첫 번째 step이 중요한 이유는 순수한 정상 데이터를 추출해 내기가 예상보다 쉽지 않기 때문이다. ‘정상’의 정의에는 다양한 제약 조건들을 전제로 한다. 많은 grade들이 있으며, 시간이 지남에 따라 공정의 표준 운전 조건 및 원, 부원료의 recipe가 지속적으로 변화한다. 장기적 관점에서 robust한 감지 및 진단 모형을 만들기 위해서는 이러한 제약 조건들을 최대한 고려한 상태에서 이상들을 분류할 수 있어야 하며, 그러기 위해서는 ‘정상’에 대한 정

의를 대단히 신중하게 해야 한다.

Fig. 1은 일반적인 주성분 분석을 진행한 그래프이며, 공정의 Normal mode의 패턴이 다른 두 경우를 보여준다. 푸른 색의 점들이 Normal 운전이며 붉은 색의 점은 abnormal 운전이다. (a) 그래프는 normal mode가 하나인 경우이고, (b) 그래프는 normal mode가 여러 개인 경우이다. 각각의 경우에 따라 정상과 이상의 구분 기준이 달라지는 것은 당연하다.

또 중요한 것은 세 번째 step의 이상들을 구분하는 것이다. 화학 공정에서 발생하는 이상들은 매우 다양하다. 위치 별, unit 별, 이상 발생 type 별로 다양하게 발생하는 이상들의 패턴을 구분하는 것은 대단히 중요하다. 아래의 Fig. 2에서처럼 붉은 색으로 표시된 이상들을 구분하는 과정을 일반적으로 Fault Diagnosis(이상 진단)라고 한다. 상대적으로 두 번째 step처럼 정상과 이상을 구분하는 과정은 Fault Detection(이상 감지)이라고 한다.

### 1-2. 이상 감지 모니터링

개발된 이상 감지 모형의 robustness가 확보 되면, 다음과 같은 과정으로 이상 감지 모형을 활용할 수 있다. Step1: 정상 모형에서 신뢰 구간 이탈, Step2: 기여 인자 추출, Step3: 기여 인자들의 개선 방향 결정 및 개선의 순서로 모니터링한다.

이러한 과정을 Fig. 3에서 설명하고 있다. 주성분 분석 그래프를 이용하여 핵심적인 주성분(Principal Components)을 모니터링한다. 비정상 event가 발생하면, 신뢰 구간을 벗어난다. 신뢰 구간을 벗어난 순간부터 현장에는 이상 발생 alarm을 주게 되고, 운전 조건 중 어떤 인자가 영향을 주었는지 기여도 그래프 등을 통해 확인할 수 있으며, 이 인자들의 적절한 개선을 통해 정상 운전으로 원복할 수 있다. 기여도 그래프는 통계적 거리인 Mahalanobis 거리에 기반하여 계산된다.

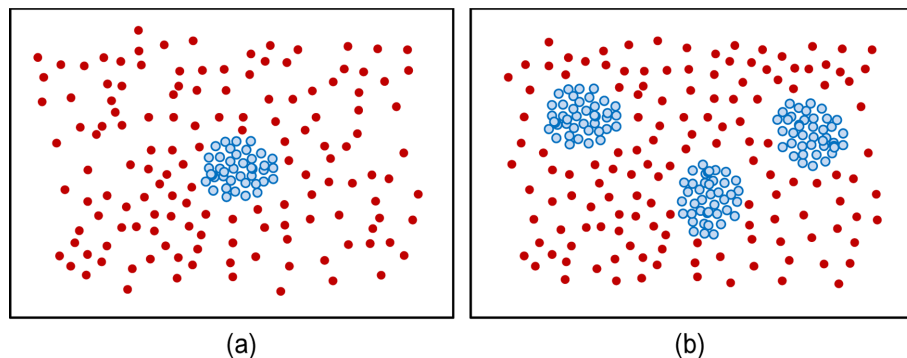


Fig. 1. (a) One normal mode, (b) Multiple normal mode.

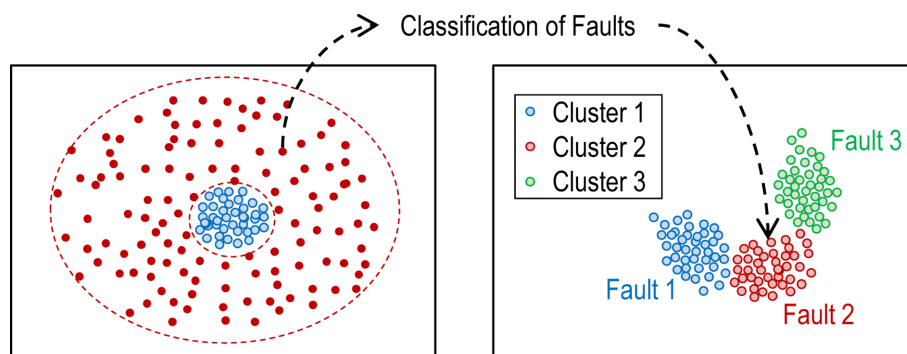


Fig. 2. Concept of fault diagnosis modeling.

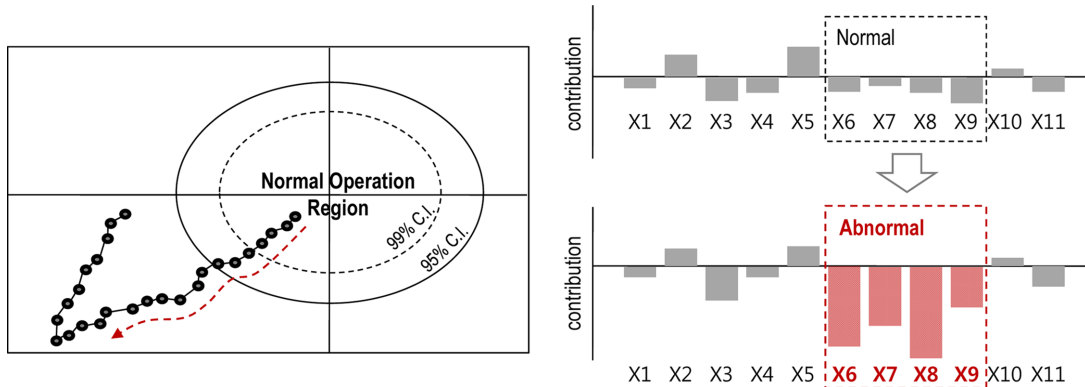


Fig. 3. Fault detection monitoring using principal component analysis.

## 2. 방법론

### 2-1. 주성분 분석(Principal Component Analysis, PCA)

PCA는 차원 축소를 위해 사용하는 다변량 통계 방법으로, 데이터 세트의 가장 중요한 정보를 유지하면서 상관 관계가 있는 원래 변수를 주성분이라고 하는 상관 관계가 없는 변수로 변환하는 방법이다. PCA는 변수의 선형 조합을 통해 변수 세트의 공분산 구조를 설명한다. 수학적으로, PCA는 데이터 행렬  $X \in \mathbb{R}^{n \times m}$ 에서 얻은 상관 행렬의 공분산의 eigenvector decomposition이다. X의 공분산 행렬은 (1)로 정의되며, 그 분해는 (2)로 표현된다[6].

$$\text{cov}(X) = \frac{X^T X}{n-1} \quad (1)$$

$$X = TP^T = \tilde{X} + E \quad (2)$$

여기서  $T \in \mathbb{R}^{n \times m}$  및  $P \in \mathbb{R}^{m \times m}$ 는 각각 Score 및 Loading 행렬이다. 행렬  $\tilde{X}$  및  $E$ 는 각각 PCA 모델의  $X$  및 residual part의 추정치를 나타낸다.

### 2-2. Hotelling의 $T^2$

공정 시스템 모니터링에 PCA 모델을 사용하는 경우, 일반적으로 Hotelling의  $T^2$  및  $Q$  (또는 SPE) 통계 방법을 활용한다.  $T^2$  지표는 주성분 sub-space 내에서 평균 및 공분산의 변동성을 측정하도록 설계된 투영의 squared Mahalanobis 거리이다.  $Q$  통계량은 PCA 모형으로 설명되지 않는 부분을 설명하는 지표이다. 실시간 프로세스 모니터링을 수행할 때, 새로운 샘플 벡터  $x$ 가 들어오면, PCA 모델을 사용하여 주성분 sub-space에 투영되고, (3)과 같이  $T^2$  지표를 계산하여 현재 상태를 모니터링할 수 있다[6].

$$T^2 = \sum_{i=1}^l \frac{t_i^2}{\lambda_i} \quad (3)$$

$t_i$ 는  $xP^T$ 의  $i^{\text{th}}$  vector

## 3. LDPE 공정의 이상 감지 및 수명 예측

### 3-1. LDPE 공정 개요

LDPE는 homo-polymer, copolymer 및 첨가제 포함 제품을 비롯하여 광범위한 용도와 가공에 적용된다. 일반적으로, 필름용, 압출 코팅용, injection molding용, cable & wire용, blow molding용으로

구분되어 생산된다.

LDPE는 5단계(1차 압축기 → 2차 압축기 → 중합 반응기 → 압출기 → 포장)로 생산된다. 5단의 1차 압축기는 에틸렌을 250 kg/cm<sup>2</sup>g로 압축시키고, 개시제(산소)와 개질제(propionaldehyde와 propylene)를 주입 받는다. 1차압축기에서 토출되는 에틸렌은 고압 순환 시스템의 에틸렌 순환가스와 공단량체(vinyl acetate)가 혼합되고, 2단의 2차 압축기에서 250 kg/cm<sup>2</sup>g를 최대 3200 kg/cm<sup>2</sup>g까지 가압시킨다. 두 개로 나뉘어진 에틸렌 스트림은 압축되어 1차 반응기와 2차 반응기로 분리, 공급되어 폴리에틸렌을 생산하게 된다. 본 논문에서는 고압 공정인 고압 압축기에 국한하여 이상 감지 모형 개발 및 수명 예측 방법에 대해 소개한다. 고압 압축기의 경우, 설비 정비를 위하여 의도적으로 공장을 Shutdown하는 계획 정지(Process Shutdown, PSD)를 주기적으로 진행하나, 공정의 갑작스런 이상 발생으로 인하여 자동으로 Shutdown 되는 비계획 정지(Emergency Shutdown, ESD)가 간혹 발생하여, 예상하지 못한 공장 정지로 인한 생산량 저하, 부품 수급 차질 등의 문제가 일어난다. 이에 ESD의 사전 감지가 가능한지 분석을 진행하였다.

### 3-2. 비지도학습 기법을 이용한 ESD 사전 감지

#### 3-2-1. 데이터

LDPE 공장의 고압 압축기(Hyper Compressor)에서 발생한 4회의 ESD를 대상으로 비지도학습 머신러닝 기법을 활용한 검출이 가능한지 분석을 진행하였다. 데이터는 1분 간격의 1년 분량을 활용하였으며, 525,600개의 관측치를 대상으로 하였다.

LDPE 공장에서 발생한 ESD의 경우, 발생한 시점의 기록은 있으나, ESD가 발생하면 바로 공정 부동으로 이어지기 때문에, 가동 중의 운전 데이터로는 정상과 이상을 구분할 수 없다. 이러한 점 때문에 임의로, ESD 발생 5일 전을 이상 의심 기간으로 가정하고, ESD 1~4로 labeling 하였다. 우리는 비지도학습 방법으로 clustering만 할 것이므로, labeling은 편의상 한 것으로 큰 의미가 있는 것은 아니다.

Table 1은 비지도 학습 모형화에 사용한 공정 변수 리스트이다. LDPE의 고압 압축기는 1차 압축기와 2차 압축기로 구분되는데, 압력 수준이 낮고 ESD와 위치적으로 무관한 1차 압축기 변수들은 모두 제외하였다. 변수 군은 크게 보면, 온도(흡입 온도, 단 별 최대 온도, 베어링 온도 등), 압력(흡입, Stage 간, 방출 압력 등)이 대부분이며, 다방 공정(Polytropic Process)의 열역학적 이론을 기반으로, 압축기 효율과 같은 가공 변수를 추가적으로 개발하여 반영하였다. 온도 및 압력과 같은 공장에서 직접 측정하고 있는 Raw Data 뿐만 아

Table 1. List of process variables

	Variables	Stage 1	Stage 2
Temperature	Suction	4	4
	Discharge	4	4
	Frame Bearing	4	6
	Hyper Frame Bearing	4	6
Pressure	Leak Gas	1	
	Suction	2	
	Interstage	2	
	Discharge	3	
Flowrate	Oil	2	
	Total Flow	1	
Developed Index	Compressor Efficiency	4	4

나라, 이러한 물리, 화학적인 feature들을 해당 분야에 대한 지식을 기초로 하여 반영할 때, 보다 좋은 결과를 얻을 수 있는 것으로 알려져 있으며[9], 이는 그 분야에 대한 specific한 domain knowledge가 있어야만 가능한 것이라 할 수 있겠다.

### 3-2-2. 비지도 학습 모형화 결과

앞서 언급한 55개의 변수들을 사용하여 PCA를 진행하였으며, 4개의 비계획 정지 직전의 데이터들이 정상 데이터들과 구분되는지 확인해보았다. 모두 6개의 차원으로 92%를 설명하는 PCA 모형이 만들어졌으며, Fig. 4의 3차원 그래프처럼 3개의 핵심 특징을 사용할 경우, 상당한 양의 이상 데이터(그래프의 붉은 점선 원 영역의 dot 들)를 99% 신뢰구간을 기준으로 정상 데이터와 구분할 수 있었다.

주성분 분석의 결과에 기반하여 다변량 관리 지표인 Hotelling의  $T^2$  지표를 개발하였으며, ESD 사전 감지가 가능한지 Fig. 5와 같이 확인하여 보았다. 모형의 검증은 2가지의 방식으로 진행하였는데, 첫번째는 이상을 구분하는지, 그리고 ESD가 발생하기 얼마 전에 구분되는지의 여부이다. 두번째는 정상 데이터의 false alarming 여부이다. 이 부분은 정상데이터로 예상되는 기간의 데이터에 대해 모델링과 테스트의 비율을 7:3으로 나누어 진행하였으며, 대체로 0.05% 수준으로, 모델링과 테스트에서 비슷하게 발생하였다. 본 논문에서는 첫번째 방식의 검증만을 언급하는데, 그 이유는 2번째의 false alarming의 경우, 기본적으로 라벨링되어 있지 않은 데이터에 대해 주관적으로 정상과 이상을 구분하는 것에 대한 모호함 때문이다.

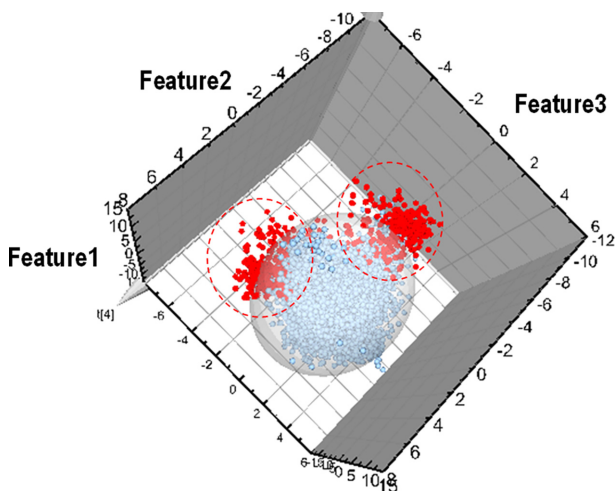
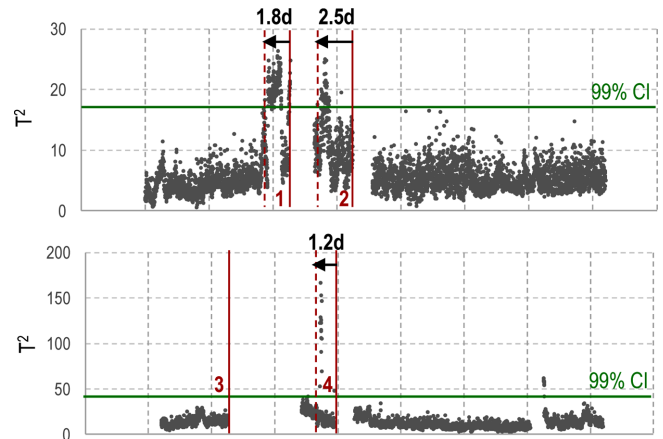


Fig. 4. Fault detection results using key principal components.

Fig. 5.  $T^2$  monitoring results.

첫번째 방식의 검증 결과, ESD 1은 1.8일 전, ESD 2는 2.5일 전, ESD 4는 1.2일 전부터 99% 신뢰 구간을 벗어나기 시작한다. 하지만, ESD 3은  $T^2$  지표로는 감지되지 않았다.

2개의 운전 모드, 4개의 ESD에 대해, 비지도학습 방법을 적용하여, 사전 감지 성능을 확인한 결과, 4회 중 3회의 ESD 감지가 가능하였으며, 감지가 된 경우에는 평균적으로 1.8일 전에 감지되는 것으로 판단하였다.

### 3-2-3. 변수 추가 및 조합 최적화로 사전 감지 성능 개선

이상 감지 성능 개선과 검출되지 않는 ESD 3의 검출을 위한 새로운 접근이 필요하였다. Hotelling의  $T^2$  분석의 특성 상, 실제로 영향 주지 않는 변수의 반영으로 사전 감지 성능을 하락시킬 수 있기 때문에, 2가지의 접근을 통해, 이의 개선을 도모하였다.

먼저 변수의 추가이다. 공장에서 신규 설치하여 운영 중이던, 실린더 별 leak gas 변수 8개를 추가하였고, 크게 A-Side와 B-Side로 대칭 운전되는 고압 압축기의 양측 온도 차( $\Delta T$ ) 8개를 계산하여 반영하였다. 두 번째는 반영 변수 조합의 최적화이다. 2차 고압 압축기는 1단과 2단 두 번에 걸쳐 연속 압축하는데, 1단은 250 kg/cm<sup>2</sup>g 수준, 2단은 3200 kg/cm<sup>2</sup>g 수준으로 2단이 10배 이상의 고압 공정 이므로, 이상 발생 위험이 훨씬 높으며, 실제로도 대부분의 ESD가 2단에서 발생한다. 이에 1단과 관련된 대부분의 인자들을 제외하였다.

1단 변수들을 제외한 채, 각 변수 군들의 조합을 바꿔가며, 감지 성능 개선 여부를 확인하였다. 최적의 조합은 Table 2와 같이 확인되었다. 특징적인 것은 ESD 3과 4의 경우, 신규 반영된 leak gas flow 변수들과 흡입 및 인터스테이지 압력의 영향을 크게 받는다는 것이었다.

성능 개선의 지표를 세분화하였다. Alarm 지속 기간이 얼마나 유지되어야 비정상으로 볼 것인가는 매우 논란이 될 수 있는 문제이므로, alarm 지속 10분부터 60분까지 6단계로 세분화하여, 이상이 사전 감지되는 시점을 계산하였다. Fig. 6의 왼 쪽은 기존의 감지 성능 결과이고, 오른 쪽은 개선된 감지 성능이다. 가장 특징적인 것은 ESD 3이 감지 된다는 것이고, 두 번째는 평균 1.8일 전 감지되던 성능이 평균적으로 2.4일 전으로 개선되었다는 것이다.

### 3-3. 수명 예측 지표의 개발

LDPE 공장은 실린더의 부품 교체 등을 위해 정기적인 PSD를 주

**Table 2. Optimal combination of variables to maximize fault detection performance**

Variables		Stage 1	Stage 2
Temperature	Suction	4	4
	Discharge	4	4
	Frame Bearing	4	6
	Hyper Frame Bearing	4	6
Pressure	Leak Gas		1
	Suction		2
	Interstage		2
	Discharge		3
Flowrate	Oil		2
	Leak Gas Flow	4	4
	Total Flow		1
Developed Index	Compressor Efficiency	4	4
	$\Delta T$	4	4

ESD 1, 2  
 +  ESD 3, 4  
 Red Variables Newly Included

기적으로 실시한다. 이런 경우, 실제로 설비 상태가 괜찮음에도 과하게 설비 및 부품을 교체하는 일이 일어날 수 있고, PSD를 실시하면 부동을 해야 함으로 생산성 하락을 가져올 수 있다. 그러므로 ESD 예방도 중요하지만, 압축기의 수명을 예측하여 최적의 주기로 PSD를 진행하는 것이 매우 중요하다. ESD 사전 감지 분석을 위해 2차 분석에서 반영했던 leak gas flow 변수들 중 2단의 고압 실린더 각각에 설치된 leak gas flow 변수 4개와 total flow 변수 1개만을 활용하여, Hotelling의  $T^2$  인자를 개발한 결과는 Fig. 7과 같다.

분석 결과 특이한 점은 PSD 및 ESD 발생 시점까지  $T^2$  값이 대체로 증가하다가, PSD, 혹은 ESD 발생으로 인한 정비 후에 값이

하락하고, 다시 지속적으로 증가한다는 것이다. Leak flow는 변수 간 상관 관계가 존재하며, 이러한 물리적인 상관성에 기인한 변수 간의 공선성 특성이 다변량 지표화 되었을 때, 물리적 의미를 잘 종합해서 보여주는 것으로 이해 된다. 상태가 좋지 않은 설비의 확인은 개별 실린더의 leak gas 단변량 monitoring으로 가능할 것으로 예상된다. 분석 결과를 통해, LDPE와 같은 고압 공정의 경우, 고압 압축기의 leak gas flow 변수에 기반한 다변량 지표의 적절한 활용으로 실린더 부품의 수명을 예측할 수 있음을 알 수 있다.

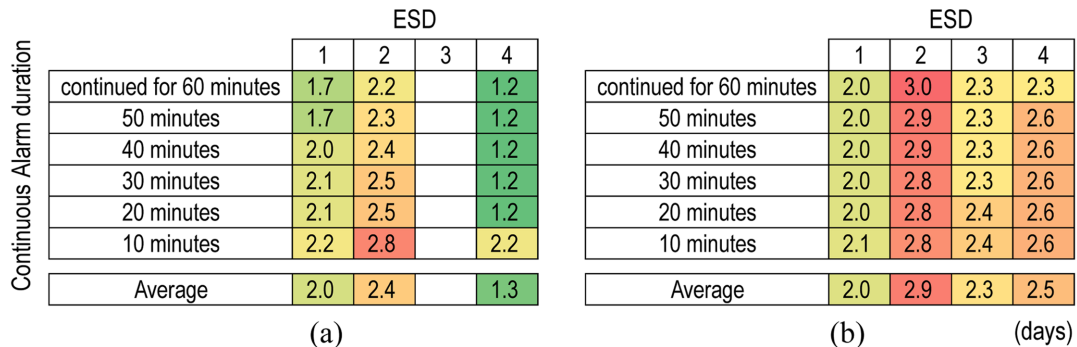
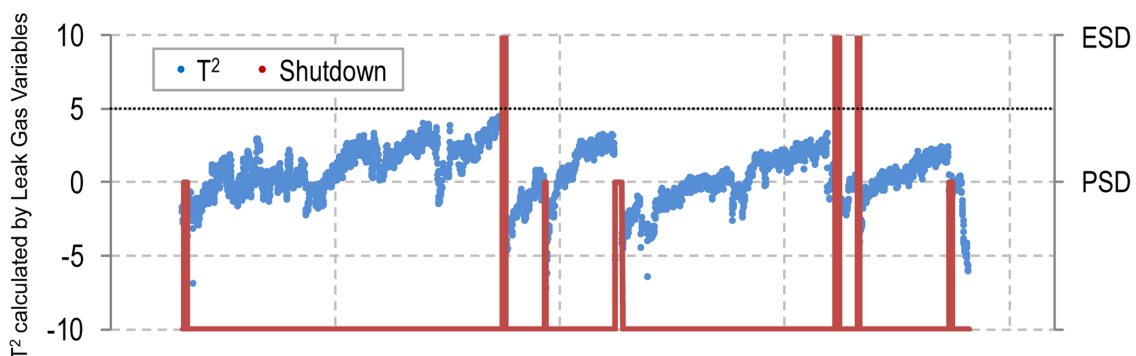
#### 4. 결 론

본 논문에서는 LDPE 공장의 2차 압축기의 ESD(비계획 정비) 사전 감지 및 수명 예측 내용을 소개하였다.

LDPE 공장은 에틸렌 가스를 최대 3200 kg/cm<sup>2</sup>까지 압축하여 반응기에 투입, 반응시키는 공정으로, 고압 공정인 이유로 안전 이슈가 매우 중요한 공정이다. 이에 고압 압축기의 주요 인자들을 수집하여, ESD의 사전 감지가 가능한지 비지도학습의 주성분 분석법 및 Hotelling의  $T^2$  지표를 활용하여 분석을 진행하였다.

최초 55개의 인자들을 활용하여 모형화 하였으며, 그 결과, 4회의 ESD 중 3회가 평균 1.8일 전에 감지되었다. 성능 개선을 위해 Leak gas flow 및 대칭으로 위치하는 실린더의 좌우 온도차 등의 신규 변수를 추가하여, 71개로 변수를 확대하였으며, 변수 군들의 조합을 변경하면서, 사전 감지 성능 개선이 극대화되는 최적의 조합을 탐색하였다. 크게 영향이 없을 것으로 예상되는 1단의 변수들을 모두 제외하고, ESD 별로 다른 조합으로  $T^2$ 을 개발한 결과, 감지되지 않았던 특정 ESD의 감지가 가능해졌으며, 사전 감지 성능도 평균 2.4일 전으로 개선되었다.

Leak gas flow 변수들만으로  $T^2$ 을 개발한 결과, 이  $T^2$  값이 PSD

**Fig. 6. Comparison of before and after improvement: (a) before, (b) after.****Fig. 7. Monitoring compressor life index developed with leak gas flow variables.**

및 ESD 직후 지속적으로 증가하고, PSD나 ESD가 발생 후 정비를 하게 되면, 다시 감소하는 것을 확인할 수 있었다. 이 지표를 적절히 활용하면, 고압 압축기 설비의 수명 지표로 활용할 수 있을 것으로 기대한다.

## References

1. Venkatasubramanian, V., Rengaswamy, R., Yin, K. and Kavuri, S. N., "A Review of Process Fault Detection and Diagnosis: Part I: Quantitative Model-based Methods," *Comput. Chem. Eng.*, **27**, 293-311(2003).
2. Venkatasubramanian, V., Rengaswamy, R. and Kavuri, S. N., "A Review of Process Fault Detection and Diagnosis: Part II: Qualitative Models and Search Strategies," *Comput. Chem. Eng.*, **27**, 313-326(2003).
3. Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N. and Yin, K., "A Review of Process Fault Detection and Diagnosis: Part III: Process History Based Methods," *Comput. Chem. Eng.*, **27**, 327-346(2003).
4. Li, H., Wang, H. and Fan, W., "Multimode Process Fault Detection Based on Local Density Ratio-weighted Support Vector Data Description," *Ind. Eng. Chem. Res.*, **56**, 2475-2491(2017).
5. Gajjar, S. and Palazoglu, A., "A Data-driven Multidimensional Visualization Technique for Process Fault Detection and Diagnosis," *Chemometrics and Intelligent Laboratory Systems*, **154**, 122-136 (2016).
6. Zhang, Z. and Zhao, J., "A Deep Belief Network Based Fault Diagnosis Model for Complex Chemical Processes," *Comput. Chem. Eng.*, **107**, 395-407(2017).
7. Liu, K., Fei, Z., Yue, B., Liang, J. and Lin, H., "Adaptive Sparse Principal Component Analysis for Enhanced Process Monitoring and Fault Isolation," *Chemometrics and Intelligent Laboratory Systems*, **146**, 426-436(2015).
8. Adedigba, S. A., Khan, F. and Yang, M., "Dynamic Failure Analysis of Process Systems Using Principal Component Analysis and Bayesian Network," *Ind. Eng. Chem. Res.*, **56**, 2094-2106(2017).
9. He, Q. P. and Wang, J., "Statistical Process Monitoring as a Big Data Analytics Tool for Smart Manufacturing," *Journal of Process Control*, **67**, 35-43(2018).