

AE-SOM을 이용한 EVA 생산 공정 이상 검출 및 진단

박병언*[†] · 지유미* · 심예슬** · 이규황** · 이호경**

*포항공과대학교 화학공학과
37673 경북 포항시 남구 청암로 77
**LG화학 기술연구소

34122 대전광역시 유성구 문지로 188

(2020년 3월 10일 접수, 2020년 4월 12일 수정본 접수, 2020년 4월 30일 채택)

Fault Detection and Diagnosis for EVA Production Processes Using AE-SOM

Byeong Eon Park*[†], Yumi Ji*, Ye Seul Sim**, Kyu-Hwang Lee** and Ho Kyung Lee**

*Department of Chemical Engineering, Pohang University of Science and Technology, 77, Cheongam-ro, Nam-gu, Pohang-si, Gyeongsangbuk-do, 37673, Korea

**LG Chem Research Park, 188, Munji-ro, Yuseong-gu, Daejeon, 34122, Korea

(Received 10 March 2020; Received in revised form 12 April 2020; accepted 30 April 2020)

요 약

본 연구에서는 auto-encoder와 self-organizing map을 결합한 auto-encoder with self-organizing map(AE-SOM) 기법을 이용하여 EVA 생산공정의 이상을 검출 및 진단하였고, Granger의 인과분석을 통해 이상 검출 데이터의 이상 전파 방향을 확인하였다. 분석 데이터는 1년 7개월 간의 조업데이터를 이용하였으며, autoclave 반응기의 조업 변수를 주로 분석하였다. 데이터 전처리 과정에서 데이터의 표준화를 먼저 진행하고, 조업의 각 grade의 sample 수를 동일하게 200개 임의로 추출하였다. 이후 AE-SOM을 적용하여 각 grade의 best matching unit (BMU)를 도출하였다. 각각의 BMU를 기준으로 조업 데이터가 얼마나 벗어났는지를 기준으로 데이터의 이상을 판별하였다. 공정 이상이 발견될 시 이상원인을 contribution plot을 이용하여 확인하였고 이상원인 변수의 인과성을 Granger의 인과분석을 통해 분석하였다. 그 결과 조업 시 발생한 2번의 섯다운의 전조를 모두 검출하였으며 이상이 발생한 원인변수에서 기인한 공정 이상의 전파 방향을 분석하였다.

Abstract – In this study, the AE-SOM method, which combines auto-encoder and self-organizing map, is used to detect and diagnose faults in EVA production process. Then, the fault propagation pathways are identified using Granger causality test. One year and seven months of operation data were obtained to detect faults of the process, and the process variables of the autoclave reactor are mainly analyzed. In the data pretreatment process, the data are standardized and 200 samples of each grade are randomly chosen to obtain a fault detection model. After that, the best matching unit (BMU) of each grade is confirmed by applying AE-SOM. The faults are determined based on each BMU. When a fault is found, the most causative variable of the fault is identified by using a contribution plot, and the fault propagation pathway is identified by Granger causality test. The prognostic of the two shutdowns is detected, and the fault propagation pathway caused by the faulty variable was analyzed.

Key words: Fault Detection, Fault Isolation, Auto-encoder, Self-organizing map

1. 서 론

Ethylene Vinyl Acetate (EVA)는 Ethylene과 Vinyl Acetate (VA)가 반응하여 생성되는 물질로서, 발포, 전선, 태양광, 필름 등의 생산에

원료로 사용된다. Ethylene과 VA 비율(grade)에 따라 자기점착성, 균일성, 투과성, 내구성 등이 달라지며, 이에 따라 생산제품이 달라진다. 그 공정의 개략적인 구조는 Fig. 1과 같다.

EVA 생산 공정 중 첫 단계에서 원료인 ethylene은 반응 압력 조건을 만족시키기 위해 두 개의 압축기(primary compressor, secondary compressor)를 거치게 된다. 두개의 압축기를 지나면서 섞인 원료는 개시제(initiator)와 함께 총 11개의 단으로 구성된 autoclave reactor로 들어가 유리기 중합반응(free radical polymerization reaction)이 일어난다(Fig. 2). 여기서 VA의 비율에 따라 원하는 특성을 가진 EVA

[†]To whom correspondence should be addressed.

E-mail: bepark@postech.ac.kr

[‡]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.

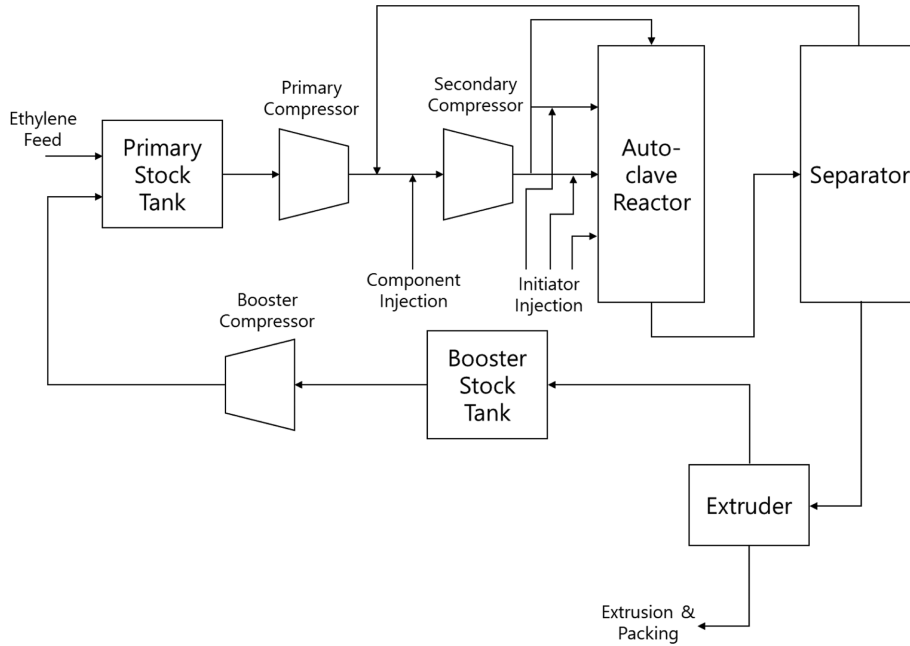


Fig. 1. Process diagram of EVA production process.

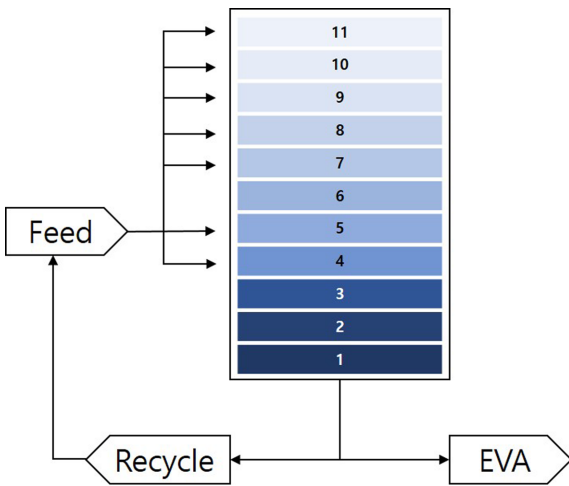


Fig. 2. Schematic of the autoclave reactor.

가 생성된다. EVA 생산 공정에서는 유리기 중합반응 외에도 분해 반응(decomposition reaction)이 일어나 EVA 생산 반응의 효율을 감소시키게 된다. 이 반응은 발열 반응으로 반응기 자체의 온도를 높여, 그 결과 공정을 섣다운시키는 문제를 야기한다. 이 때문에, 경제적인 측면과 안전성 측면에서 EVA 생산공정의 autoclave reactor 공정 이상진단에 관한 연구가 필요하다.

기존에 다변량 통계적 공정 모니터링(multivariate statistical process monitoring, MSPM) 방법을 이용한 연구가 진행되어 왔다. 대표적으로 주성분분석(principal component analysis, PCA)를 이용하여 autoclave 반응기의 이상을 검출하는 방법[1,2], autoclave 반응기의 열평형에 기반하여 반복 주성분분석(iterative PCA)을 이용한 방법[3]이 있다. 이러한 방법들은 비교적 간단하게 공정의 이상을 검출한다는 장점이 있지만, grade가 바뀌며 반응 조건이 바뀌는 상황에서는 적용하기 힘들다는 단점이 있다. 또한 이 방법들은 데이터에 담겨진 비선형적 의미를 추출하기 어려우며, 주성분분석의 경우 최근 주목받는

딥러닝 기반의 방법들에 비해 낮은 이상 검출 성능을 보이는 것으로 알려져 있다[4]. 최근에는 비선형적인 특징과 함께 성능이 좋은 기법에 대한 연구가 진행되었으며, 딥러닝 기반의 이상진단 방법으로 autoencoder with self-organizing map (AE-SOM)을 이용한 방법이 개발되었다[5,6]. 이 방법은 비지도 학습 중 하나인 autoencoder (AE)와 다변수를 2차원 평면에 투영하는 self-organizing map (SOM)이 결합된 방법이다. 기존에 많이 사용되는 선형 모델(주성분분석, 독립성분분석(independent component analysis, ICA), 부분최소자승법(partial least squares, PLS) 등)에 비해 더 좋은 이상 검출 성능을 보이고 있다.

그러므로, 본 연구에서는 딥러닝 기법 중 하나인 AE-SOM을 사용하여 EVA 생산공정 autoclave 반응기에서 발생하는 공정 이상의 검출 및 진단 모델을 구축하고 섣다운 전조를 검출 및 원인 진단하였다. 기존에 사용되는 AE-SOM 기반의 이상진단 방법[7]이 있으나 시간에 따라 grade가 변경되는 본 연구에서는 경우에는 적용할 수 없었다. 따라서 다양한 조업상황의 best matching unit (BMU)를 도출하여 변동되는 grade에 대응하였다. 각 grade의 BMU를 이용하여 공정이상의 지표인 dissimilarity를 계산하여 새로운 데이터가 이상인지 아닌지 판단한다. 만약 dissimilarity가 정상 조업 상태에서 설정된 control limit을 넘어 이상 데이터가 검출된다면 그 시점에서 그 이상의 원인 변수를 찾기 위해 공정 이상에 대한 변수의 기여도(contribution)를 contribution plot을 이용하여 확인한다. 이후 contribution plot에서 확인된 이상 원인 변수와 모든 조업 변수의 Granger의 인과관계를 계산하여 이상 원인의 인과관계를 확인하여 최종 이상 원인 변수를 도출한다.

2. 방법

2-1. Autoencoder (AE)를 이용한 feature 추출

AE-SOM을 이용하여 공정의 이상 검출을 하기 위한 첫 단계에

서 AE를 이용하여 공정의 특징을 반영하는 feature를 추출한다. 기존에 feature 추출을 위해 많이 사용되는 PCA와 ICA 등의 방법은 선형 모델을 기반으로 하므로 데이터의 비선형 특성을 고려할 수 없으나, AE의 경우 활성화함수를 사용한 다중 layer 구조를 통해 비선형 특성까지 고려할 수 있다[8]. 본 연구에서 사용된 AE는 hidden layer가 1개인 sparse AE를 여러 개 합친 stacked AE이다. Stacked AE의 기본 단위인 sparse AE에서는 다른 인공지능망 구조와 달리 input과 output이 동일하게 되도록 encoder와 decoder의 가중치(W)와 바이어스(b)를 찾는다. Sparse AE의 encoding 과정은 아래와 같다[8].

$$a^{(l)} = f(z^{(l)}) \tag{1}$$

$$z^{(l+1)} = W^{(l,1)} a^{(l)} + b^{(l,1)} \tag{2}$$

그리고 decoding 과정은 아래와 같다.

$$a^{(n+1)} = f(z^{(n+1)}) \tag{3}$$

$$z^{(n+1)} = W^{(n-1,1)} a^{(n+1)} + b^{(n-1,2)} \tag{4}$$

여기서, $a^{(l)}$ 은 l 번째 층의 출력, $z^{(l)}$ 은 l 번째 층의 입력의 가중치 합, $b^{(l,1)}$ 은 l 번째 층의 1번째 뉴런의 바이어스, $W^{(l,1)}$ 은 l 번째 층에서의 1번째 뉴런의 파라미터 그리고 함수 f 는 인공지능망의 활성화함수(activation function)이다. 일반적인 인공지능망의 경우 활성화함수로 sigmoid 함수가 주로 사용되지만 sigmoid 함수의 경우 layer가 많아 질수록 back propagation algorithm 적용시 gradient가 사라지는 현상이 생기게 되어 학습 성능을 보장하기 힘들다. 이를 피하기 위해서는 기울기가 일정한 활성화함수인 saturated linear transfer function (satlin), rectified linear unit (ReLU)등을 사용해야 한다. 본 연구에서는 ReLU을 사용하여 이 문제를 해결하였다. 이후 데이터 학습 과정을 통해 input과 output을 가장 같게 하는 encoder와 decoder의 W 와 b 의 값을 최적화 알고리즘을 이용하여 찾을 수 있다. 이후 추출된 feature를 다음 AE의 input으로 정하여 deep layer 구조를 구축할 수 있다[9].

AE의 feature 추출 성능을 보장하기 위해서는 최적의 layer 개수와 각 layer에 해당하는 뉴런의 개수를 정해야 할 필요가 있다. 일반적으로 AE의 첫번째 layer에서는 데이터의 개략적인 정보를 추출하고, 두번째 이후의 layer에서는 데이터의 패턴을 분석한다. 그러므로 본 연구에서는 2개의 layer를 이용하여 AE를 구축하였고 각 layer의 뉴런의 개수는 뉴런 개수가 증가하여도 오차가 크게 줄어들지 않는 개수의 뉴런을 선택하였다.

2-2. Self-organizing map (SOM)을 이용한 조업 상태 분류 및 공정이상 검출

EVA 생산 공정 특성상 다양한 grade가 존재하며, 조업 데이터에 존재하는 grade 변수가 실제 생산하길 원하는 생산물의 grade가 아닌 조업 상태 기반의 grade이기 때문에 조업자가 원하는 grade의 상태를 명확히 알 수 없다는 단점이 있다. 또한, grade 변경 중에 그 사이의 grade가 나타나는 문제가 있으므로 실제 존재하는 grade인지 아닌지에 대한 불확실성이 존재한다(Fig. 3). 그러므로, 공정의 상태를 지정해줘야 하는 지도학습(supervised learning)의 일종인 Softmax classifier를 사용하기 힘들다는 문제를 가진다. 그러므로, 본 연구에서는 일정 지속시간 이하의 grade를 갖는 sample을 제거

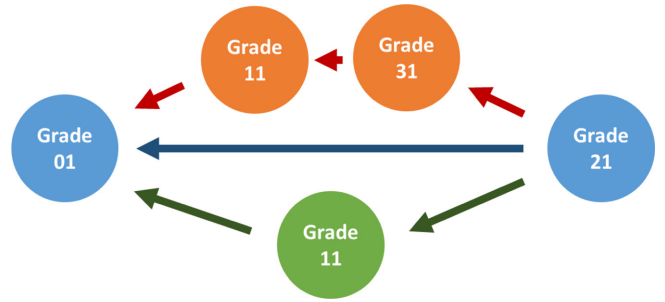


Fig. 3. Example of grade changing in EVA production processes. red: actual grade changing, blue: target grade changing, grade: ideal grade changing.




Fig. 4. Structure of AE-SOM.

한 후, 다양한 딥러닝 분류 방법 중에 비지도학습(unsupervised learning)의 일종인 autoencoder (AE)와 Self-organizing map (SOM)이 결합된 AE-SOM 방법을 사용하였다. AE-SOM 방법은 AE가 추출한 feature에 SOM을 적용하여 데이터의 군집을 확인하는 방법이다 (Fig. 4).

SOM은 다차원 데이터의 비선형성을 고려한 2차원 SOM 평면에 투영하여 데이터의 군집을 확인하는 방법으로, 기존의 clustering 방법에 대해 이와 같은 차별점 및 이점을 가진다. SOM을 학습시키기 위해 먼저 임의의 개수를 가진 격자 및 뉴런의 개수를 정한다. SOM의 뉴런 개수를 정하는 방법은 아래의 식과 같다[10].

$$M \approx 5\sqrt{N} \tag{5}$$

여기서 N 은 sample의 개수, M 은 뉴런의 개수이다. 정방형 격자를 가진 뉴런을 사용한다면 가로 세로의 뉴런의 개수는 \sqrt{M} 이다. 이후, 각 뉴런을 실제 데이터와 가장 근접한 위치가 되도록 업데이트 한다. 각 뉴런에서의 뉴런의 가중치를 업데이트하는 식은 다음과 같다.

$$w_j^{t+1} = w_j^t + \mu \lambda_x^{t'} [x - w_j^t] \tag{6}$$

여기서, w_j 는 j 뉴런에서의 가중치이고 μ 는 learning rate이며 가중치 업데이트 반복 횟수가 커질수록 학습속도를 줄이는 역할을 한다. 그리고, λ 는 각 뉴런에서 학습데이터와 가까운 값은 크게 멀리 떨어진 값은 작게 업데이트 하게 하며, 괄호안의 부분은 가중치 업데이트의 방향을 나타낸다. 일정 횟수의 뉴런 위치 업데이트 이후 뉴런과 데이터의 위치가 가까워지면 업데이트를 중지하고 이때 중지한 뉴런을 best matching unit (BMU)라 한다.

공정 운전 데이터의 군집을 SOM을 이용하여 확인 후 새로 추가된 조업데이터가 정상 조업 상태인지 아니면 이상 조업 상태인지를 확인해야 한다. 이때 필요한 개념이 dissimilarity이다. Dissimilarity는 각 군집의 중점의 BMU를 기준으로 새로운 sample의 BMU와의

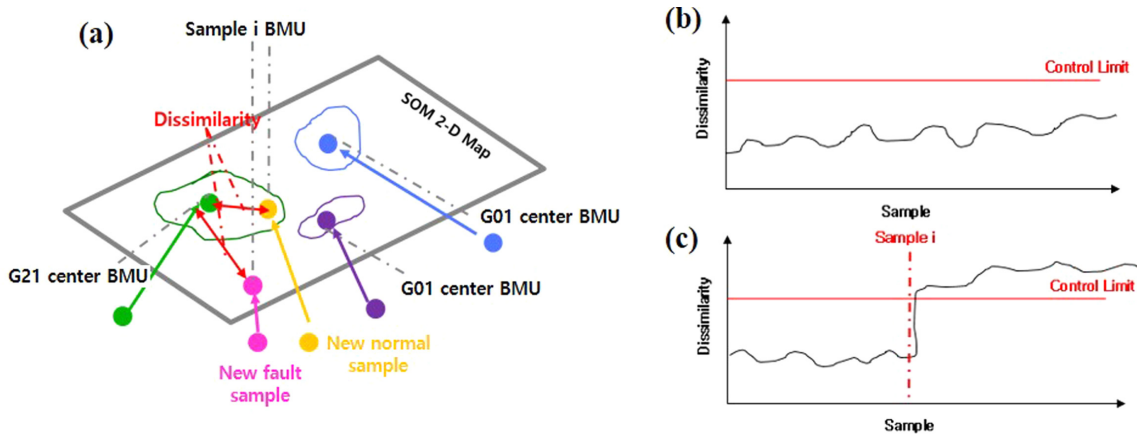


Fig. 5. Fault detection using dissimilarity. (a) SOM, (b) normal operation data, (c) abnormal operation data.

거리를 나타낸다[4,6]. 즉, 군집의 중심에서 새로운 sample이 얼마나 떨어져 있는지를 나타내는 지표이다. 이 값이 커진다면 새로운 sample은 평소 조업상태와는 다른 조업상태를 보인다는 것으로, 공정의 이상이 있다고 판단한다(Fig. 5). Dissimilarity를 계산하는 식은 다음과 같다.

$$Dissim = \|C^i - C\| = \sqrt{\sum_{j=1}^2 (C_j^i - C_j)^2} \quad (7)$$

여기서, C_j^i 는 각 sample의 BMU를 C 는 군집의 중심 BMU를 의미한다. 여기서 계산된 dissimilarity의 control limit은 정상 운전 데이터의 kernel density estimation으로 추정할 수 있다. 본 연구에서는 grade라는 다양한 운전조건이 존재하므로, 각 grade별 BMU의 중심을 정하고 조업중인 grade상의 BMU의 중심에서 현재 sample의 BMU 까지의 거리를 dissimilarity로 계산하였다. 또한 그에 따라 각 grade에 따른 control limit을 설정하였다.

Dissimilarity를 이용하여 공정의 이상을 감지했다면 어떤 변수가

dissimilarity의 이상 거동에 기여하였는지를 분석하는 과정이 필요하다. PCA기반 방법과 비슷하게 SOM에서도 contribution plot을 구하여 각 변수의 이상에 대한 기여도를 판별한다. SOM의 contribution plot은 정상 운전 상태의 dynamic loading vector를 계산하고 새로운 sample의 dynamic loading vector와 정상 운전 상태일때의 dynamic loading vector의 차이를 계산하여 구할 수 있다(Fig. 6). Dynamic loading vector는 PCA의 loading vector와 비슷한 개념이나 데이터를 주성분 평면에 사영하는 것이 아닌 dissimilarity 평면에 사영하는 것이 PCA와 다른 점이다. 그러므로, 각 sample에 해당하는 loading vector가 존재하여 dynamic하다는 특성을 갖는다. Dynamic loading vector를 계산하는 방법은 아래와 같다.

$$V^i = (X^i)^{-1} Dissim$$

$$V = [v_1 \ v_2 \ \dots \ v_j] \quad (8)$$

여기서, V^i 는 i 번째 sample에서의 dynamic loading vector이고, X 는 i 번째 sample이다. 그리고 i 번째 sample의 j 번째 변수의 contribution

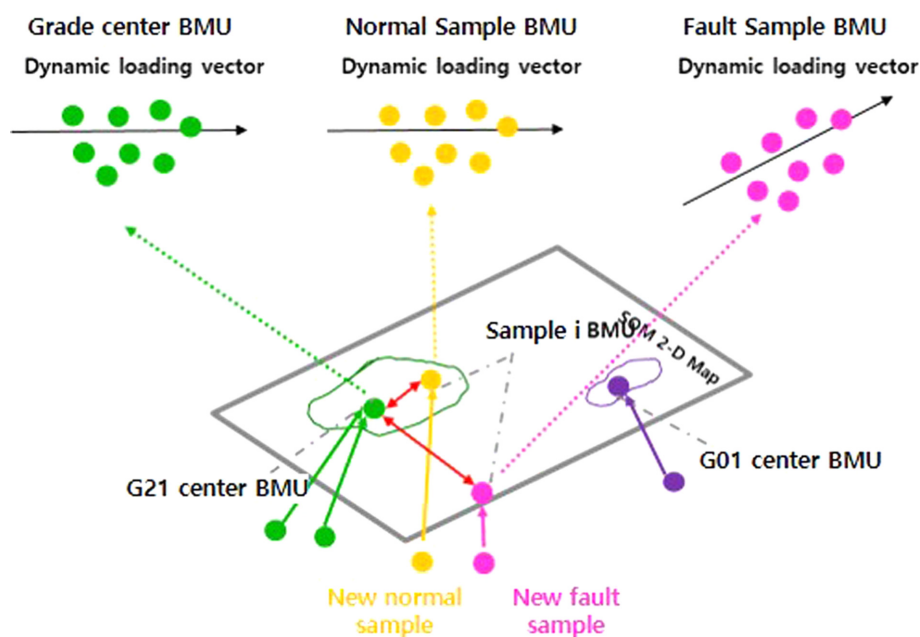


Fig. 6. Illustration of contribution to abnormal operation based on dynamic loading vector.

은 다음과 같이 계산된다.

$$cont_j = (v_j^i - v_j)^2 \tag{9}$$

여기서, v_j^i 는 i 번째 sample의 j 번째 dynamic loading vector, v_j 는 정상 운전데이터에서 추출한 dynamic loading vector의 j 번째 변수이다. Dissimilarity의 이상치가 발생하였을 때 만약 어떤 변수의 contribution이 높다면 그 변수가 평소 조업 값과 다른 값을 보이게 되므로, 그 변수를 이상의 원인으로 진단하게 된다.

2-3. Granger causality를 이용한 변수 인과관계 확인

대부분의 화학공정은 다양한 공정 변수를 가지고 있고 공정 변수 서로가 영향을 주고 있으므로 한 변수가 일으킨 공정이상이 다른 변수에 영향을 주어 그 변수에도 이상을 발생시킬 수 있다. 또한, 공정 이상의 원인으로 검출된 변수가 다른 변수의 영향을 받아 이상의 원인이 되었을 수 있다. 그러므로 공정의 이상의 원인으로 지목된 변수를 SOM의 contribution plot을 이용하여 검출해낸 후, 그 변수가 다른 변수에 끼칠 영향이나 그 변수가 다른 변수로부터 받은 영향을 분석하는 것이 필요하다. 이때 사용할 수 있는 것이 Granger causality를 확인하는 방법이다[11]. 이 방법에서 변수 X 가 변수 Y 의 시계열 예측에 사용될 수 있는지를 판별하여 변수 X 와 Y 간의 인과관계(causality)를 평가한다. 이때 변수 X 가 변수 Y 의 시계열 예측에 사용될 수 있다면 ‘변수 X 는 변수 Y 에 Granger cause 하다.’고 할 수 있고 변수 X 가 변수 Y 의 원인이라고 간주할 수 있다[12]. 두 변수 간의 Granger causality는 아래 모델의 파라미터를 구함으로써 확인할 수 있다.

$$X(t) = \sum_{l=1}^k a_{1,l} X(t-l) + \sum_{l=1}^k a_{12,l} Y(t-l) + e_1(t) \tag{10}$$

$$Y(t) = \sum_{l=1}^k a_{21,l} X(t-l) + \sum_{l=1}^k a_{22,l} Y(t-l) + e_2(t)$$

여기서, X 와 Y 는 각 변수이다. a_{11} 와 a_{12} 는 X 와 Y 가 X 에 미치는 영향, a_{21} 와 a_{22} 는 X 와 Y 가 Y 에 미치는 영향이다. 파라미터 a 의 값은 l 의 시간 지연을 가진 Autoregressive(AR)모델링을 함으로써 얻을 수 있다.

2-4. 데이터 전처리

실제 공정에서 획득한 조업데이터에는 조업 조건에 따라 다양한 단위가 존재하여, 측정된 데이터를 바로 분석하는 것은 값이 큰 특정 변수에 가중치가 가해진 분석이 될 수 있다는 문제가 있다. 또한 EVA 공정 특성상 grade에 따른 sample의 개수가 달라서 grade를 따로 분리하지 않는다면 특정 조업조건에 모델이 과적합(overfitting)될 수 있다. 그러므로 데이터의 전처리 과정을 통해 EVA 생산공정에서 발생하는 각 변수 및 grade의 가중치를 동일하게 하여 공정의 이상 검출 및 진단 모델의 적합성을 향상시킬 필요가 있다. 이를 위해 AE에 training data로 사용되는 조업데이터는 모든 조업 변수의 값을 0과 1사이의 값으로 표준화하여 데이터의 단위를 제거한다. 이후 AE에서 추출된 feature는 각 grade의 영향을 동일하게 하기 위해 200개 이상의 sample을 갖는 grade에서 200개의 sample을 임의로 추출한다. 추출된 각 grade의 feature를 합쳐서 SOM의 training data를 생성한다(Fig. 7).

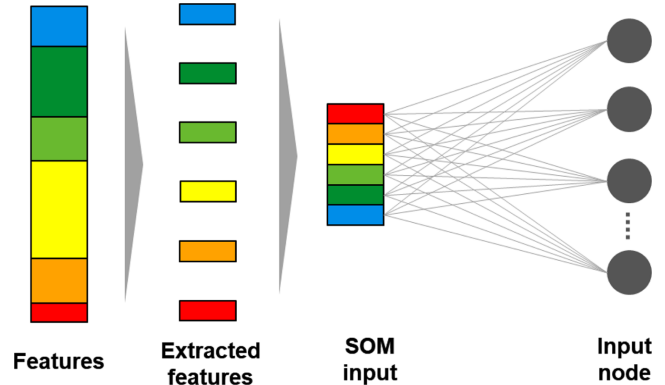


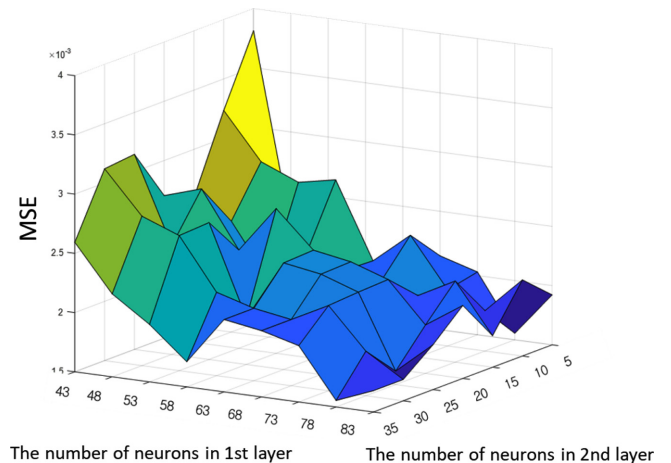
Fig. 7. Illustration of the data pretreatment.

3. 결 과

조업 데이터는 1년 7개월 간의 autoclave reactor의 데이터를 사용하였으며 주요 변수로는 반응기 조업과 밀접하게 관련된 36개의 변수를 사용하였다(Table 1). 데이터의 feature를 추출하기 전, 변수 간의 단위를 차이를 제거하기 위해 데이터를 0과 1사이의 값으로 표준화하였다. 본 연구에서는 일반적으로 사용되는 layer의 개수의 최소값인 2개, 뉴런의 개수는 최소 MSE를 나타내는 값으로 결정하였다. 최소 MSE로 각 layer의 뉴런의 개수를 정하기 위해 뉴런의 개수를 바꿔가면서 input과 output의 MSE를 계산하였다(Fig. 8). 첫번째 layer에서 73에서 78개의 뉴런 개수가 넘어갈수록 MSE가 커지고 있어 첫번째 layer의 뉴런의 개수는 76개로 결정하였다. 76개의 첫번째 layer에서 32개의 2번째 layer가 가장 작은 MSE를 보

Table 1. Process variables

Variable #	Description
1-7	Feed flow rate
8-11	Initiator flow rate
12-15	Feed temperature/pressure
16-31	Reactor temperature
32	Outlet pressure
33	EVA production rate
34	Modifier flow rate
35, 36	Grade



The number of neurons in 1st layer The number of neurons in 2nd layer
Fig. 8. Variation of MSE with the number of neurons.

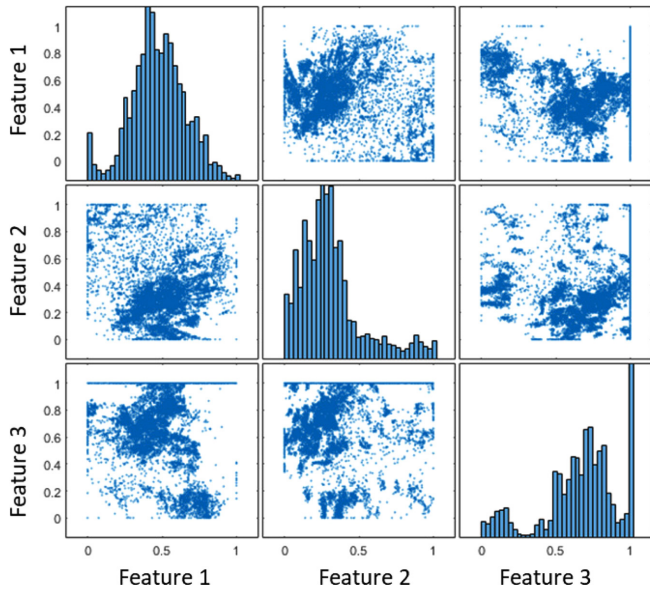


Fig. 9. Three features out of twenty-one from the operation data.

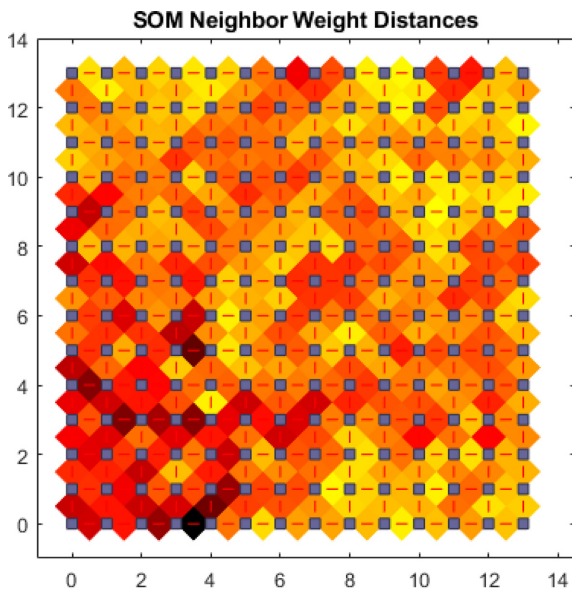


Fig. 10. Weight distances of the operation data. Darker colors represent larger weights.

이므로, 2번째 layer의 뉴런은 32개로 결정하였다. 앞서 구축한 AE를 기반으로 전처리된 데이터를 AE의 training data로 사용하여 feature를 추출하였다(Fig. 9).

AE를 이용하여 추출한 36개의 feature 중 변동 없는 값을 나타내는 feature 15개를 제거하였다. 남은 21개의 feature를 이용하여 공정의 grade 당 200개의 sample을 추출하고 SOM을 위한 training data set을 만들었다. 이후 이 데이터를 이용하여 SOM을 구축하고 뉴런간 거리를 계산하였다(Fig. 10). 각 grade 별로 노드에 해당하는 sample의 개수를 확인 결과 각 grade 별로 어느정도 군집이 형성되어 있는 것을 확인할 수 있다(Fig. 11). 다음으로 셋다운 부근 데이터의 dissimilarity를 계산하였다(Fig. 12). Dissimilarity의 값이 2550번째 sample에서 셋다운 발생까지 95% control limit을 위반한 것을 확인하여, 셋다운의 전조현상을 검출했다고 간주하였다. 이후 발생한 두번째의 셋

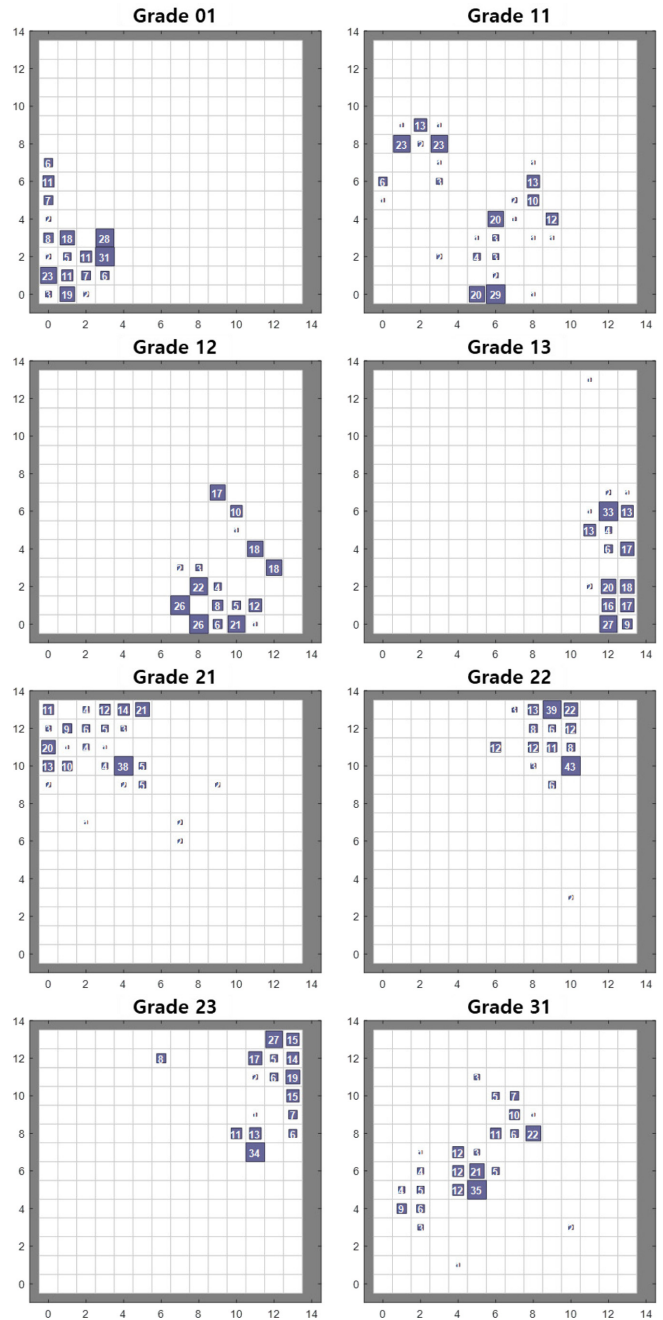


Fig. 11. The number of samples that hit each node by the grade (01, 11, 12, 13, 21, 22, 23 and 31).

다운 역시 첫번째 셋다운에 너무 가까이 있기 때문에 첫번째 셋다운의 영향으로 발생하였다고 판단하였다. 이후 dissimilarity의 값 상승에 기여한 변수를 확인하기 위해, 공정의 전조가 발생한 부근의 contribution 계산하였다(Fig. 13). 분석 결과 변수 14번 변수(feed temperature/pressure)가 전조로 발견된 dissimilarity에 기여가 큰 것으로 확인되었다. 실제 14번 변수 그래프 역시 급격한 상승이 있어, 이상의 전조라고 판단하였고 그러므로 셋다운의 원인이라고 판단하였다(Fig. 14).

셋다운의 원인으로 지목된 14번 변수가 다른 변수에 영향을 주었는지 혹은 다른 변수에 영향을 받았는지 알기 위해 모든 조업변수의 Granger causality 관계를 계산하였다(Fig. 15). 14번 변수의

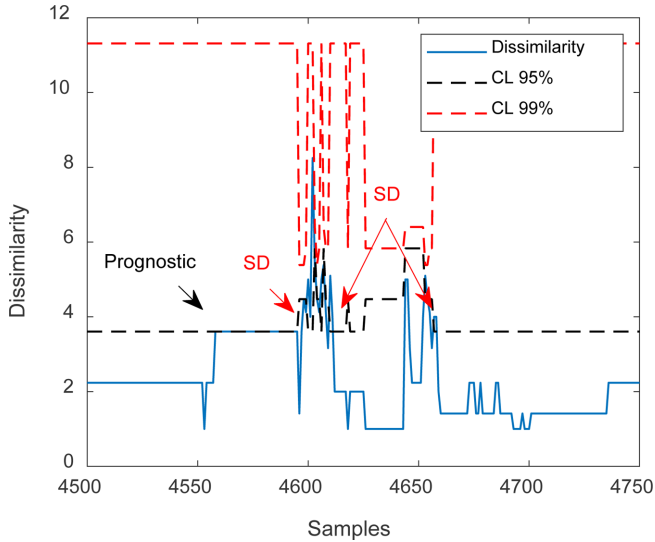


Fig. 12. Dissimilarity near the shutdowns (SD) and control limits (CLs).




Fig. 13. Contribution of the samples obtained when the shutdown prognostic is detected.




Fig. 14. Abnormal behavior of the variable 14 (feed temperature/pressure) near the shutdowns.




Fig. 15. Granger's causality network of the 35 process variables (arrow direction: direction of causality, arrow width: magnitude of causality, red arrow: mutual causality).

경우 다른 변수에 영향을 주지도 않고 받지도 않는 것으로 확인되었다. 그러므로, 일정한 주기로 유지되던 14번 변수 feed temperature/pressure의 급격한 변화가 섯다운의 단독 원인으로 간주할 수 있다.

4. 결 론

이번 연구에서 딥러닝 방법인 AE-SOM을 이용하여 EVA 생산 공정의 autoclave reactor의 섯다운의 전조 현상을 검출하는 방법을 제안하였다. 공정 운전데이터의 feature를 추출하기 위해 AE를 사용하였으며, 추출된 feature를 SOM으로 분석하여 조업 grade 별로 일정한 군집이 있는 것을 확인하였다. Grade별 군집을 이용하여 autoclave reactor의 이상 전조를 검출하였으며 이상의 원인을 contribution 분석을 통해 14번 변수 feed temperature/pressure로 확인하였다. 이후 그 변수의 이상 전과 관계를 도출하기 위해 다른 변수와의 Granger의 인과관계를 확인하였다. 그 결과 14번 변수는 다른 변수에 영향을 주거나 받는 것이 없는 단독 원인인 것으로 판단 되었다.

References

1. Sharmin, R., Shah, S. L. and Sundararaj, U., "A PCA Based Fault Detection Scheme for an Industrial High Pressure Polyethylene Reactor," *Macromolecular Reaction Engineering*, **2**(1), 12-30(2008).
2. Kumar, V., Sundararaj, U., Shah, S. L., Hair, D. and Vande Griend, L. J., "Multivariate Statistical Monitoring of a High-pressure Polymerization Process," *Polymer Reaction Engineering*, **11**, 1017-1052(2003).
3. Sivalingam, G., Soni, N. J. and Vakil, S. M., "Detection of Decomposition for High Pressure Ethylene/vinyl Acetate Copolymerization in Autoclave Reactor Using Principal Component Analysis on Heat Balance Model," *The Canadian Journal of Chemical Engineering*, **93**(6), 1063-1075(2015).
4. Lv, F., Wen, C., Bao, Z. and Liu, M., "Fault Diagnosis Based on Deep Learning," *Proceedings of the American Control Conference*,

- 2016 July. Boston. USA, 6851-6856(2016).
5. Yu, H., Khan, F., Garaniya, V. and Ahmad, A., "Self-organizing Map Based Fault Diagnosis Technique for Non-gaussian Processes;" *Industrial and Engineering Chemistry Research*, **53**(21), 8831-8843(2014).
 6. Lv, F., Wen, C., Liu, M. and Bao, Z., "Weighted Time Series Fault Diagnosis Based on a Stacked Sparse Autoencoder;" *Journal of Chemometrics*, **31**(9), 1-16(2017).
 7. Yu, H., Khan, F. and Garaniya, V., "Risk-based Fault Detection Using Self-organizing Map;" *Reliability Engineering and System Safety*, **139**, 82-96(2015).
 8. Hinton, G. E. and Salakhutdinov, R. R., "Reducing the Dimensionality of Data with Neural Networks;" *Science*, **313**, 504-507 (2006).
 9. Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H., "Greedy Layer-wise Training of Deep Networks;" *Advances in Neural Information Processing Systems*, 153-160(2007).
 10. Tian, J., Azarian, M. H. and Pecht, M., "Anomaly Detection Using Self-organizing Maps-based k-nearest Neighbor Algorithm;" In *Proceedings of the European Conference of the Prognostics and Health Management Society*, 1-9(2014).
 11. Ahmed, U., Ha, D., Shin, S., Shaukat, N., Zahid, U. and Han, C., "Estimation of Disturbance Propagation Path Using Principal Component Analysis (PCA) and Multivariate Granger Causality (MVGCC) Techniques;" *Industrial and Engineering Chemistry Research*, **56**(25), 7260-7272(2017).
 12. Granger, C. W. J., "Investigating Causal Relations by Econometric Models and Cross-spectral Methods;" *Econometrica: Journal of the Econometric Society*, 424-438(1969).