

마할라노비스 거리와 독립성분분석을 이용한 다변량 공정 고장탐지 방법에 관한 연구

정승환*, 김성신**

Fault Detection Method for Multivariate Process using Mahalanobis Distance and ICA

Seunghwan Jung*, Sungshin Kim**

요약 화학공정, 기계공정, 발전소와 같은 다변량 공정은 여러 설비들이 복잡하게 연결되어 운영되기 때문에 특정 시스템에 고장이 발생하면 전체 공정에 치명적인 영향을 미칠 수 있다. 또한, 공정 데이터는 불안정한 환경에서 계속되므로, 데이터에 이상치가 포함될 가능성이 크다. 따라서 계속된 데이터의 이상치를 제거하고 시스템의 고장을 사전에 탐지할 수 있는 모니터링 기술이 필수적이다. 본 논문에서는 여러 종류의 공정에서 고장탐지를 수행하기 위해 다이나믹 공정과 다변량 공정 모델에서 생성된 데이터를 이용하였다. 다이나믹 공정은 자기회귀 특성을 가지는 공정을 모델링한 것이고 다변량 공정은 특정 센서의 고장이 발생했을 때 상황을 묘사한 공정이다. 본 논문에서는 두 공정에서 생성된 데이터에 마할라노비스 거리를 이용하여 데이터에 포함된 이상치를 제거한 후, 독립성분분석을 적용하여 고장탐지를 수행하였다. 제안된 방법의 성능 비교를 위해 기존의 단일모델 ICA와 성능을 비교하였다. 실험결과, 제안된 방법이 기존의 ICA 보다 다이나믹 공정의 바이어스 데이터의 경우에 0.84%p, 드리프트 데이터의 경우 6.82%p 성능이 개선되었다. 다변량 공정의 경우 3.78%p 성능이 개선되었으므로, 제안된 방법이 우수한 고장탐지 성능을 보였다.

Abstract Multivariate processes, such as chemical and mechanical process, power plants are operated in a state where several facilities are complexly connected, the fault of a particular system can also have fatal consequences for the entire process. In addition, since process data is measured in an unstable environment, outlier is likely to be included in the data. Therefore, monitoring technology is essential, which can remove outlier from measured data and detect failures in advance. In this paper, data obtained from dynamic and multivariate process models was used to detect fault in various type of processes. The dynamic process is a simulation of a process with autoregressive property, and the multivariate process is a model that describes a situation when a specific sensor fault. Mahalanobis distance was used to remove outlier contained in the data generated by dynamic process model and multivariate process model, and fault detection was performed using ICA. For comparison, we compared performance with and a conventional single ICA method. The proposed fault detection method improves performance by 0.84%p for bias data and 6.82%p for drift data in the dynamic process. In the case of the multivariate process, the performance was improved by 3.78%p, therefore, the proposed method showed better fault detection performance.

Key Words : fault detection, ICA, Mahalanobis distance, multivariate process, outlier removal.

This work was supported by BK21PLUS, Creative Human Resource Education and Research Programs for ICT Convergence in the 4th Industrial Revolution

*Department of Electrical and Electronics Engineering, Pusan National University

**Corresponding Author: Department of Electrical Engineering, Pusan National University (sskim@pusan.ac.kr)

Received January 29, 2021

Revised January 29, 2021

Accepted February 04, 2021

1. 서론

고장(fault)이란, 시스템의 다양한 공정 모니터링 변수들 중에서, 단 하나의 변수라도 시스템의 정상동작 범위를 벗어난 경우를 의미한다[1]. 다변량 공정(기계 및 화학공정, 발전소 등)은 여러 시스템이 복잡하게 연결되어 운영되기 때문에, 시스템에 고장이 발생하면 전체 공정에 치명적인 영향을 미칠 수 있다. 예를 들어, 공장 내의 기계시스템들은 하중이 계속 작용하는 환경에서 마모, 균열 결함, 성능 저하로 인한 손상이 필연적으로 발생하고, 이는 치명적인 사고나 사용 중단 상태를 유발한다[2]. 발전소의 경우, 인적·금전적 손실을 유발하는 대형사고 또는 운전 중인 발전소를 갑작스럽게 정지하는 비계획정지로 이어질 수 있다. 따라서 설비의 고장을 사전에 탐지하여 사고를 예방할 수 있는 고장탐지 기술이 필요하다.

간의 상관관계가 높은 다변량 공정에 적합한 이상치 제거 방법이다. 이러한 특성을 이용하기 위해 본 논문에서는 마할라노비스 거리를 이용하여 이상치를 제거하였다.

차원축소를 위해 주로 이용되는 기법은 주성분분석(principal component analysis, PCA)과 독립성분분석(independent component analysis, ICA)이다. PCA는 은닉변수들이 가우시안 분포를 따르고, ICA는 비가우시안 분포를 따른다고 가정한다[3]. 일반적으로 공정의 환경 및 특성으로 인해 비가우시안 분포를 따르는 경우가 많으므로, 본 논문에서는 ICA 기반 고장탐지를 수행하였다.

ICA는 고장탐지를 위한 많은 연구에 이용되었다. Jong-Min Lee[3]는 Wenfu Ku[4]가 제안한 다이나믹 공정 모델에 ICA를 적용하여 고장탐지를 수행하였다. Žvokelj[5]는 베어링 고장탐지를 위해 ICA를 적용하였고, Ajami[6]는 화력발전소 터빈의 고장탐지에 이용하였다. 최근 연구로, Liu[7]는 ICA를 이용하여 three-tank 시스템의 고장을 탐지했고, Zhang[8]은 화력발전소 고장탐지를 수행했다. 본 논문에서는 자기회귀(autoregressive, AR) 특성을 가지는 공정을 모델링한 다이나믹 공정과 특정 센서 고장이 발생했을 때의 상황을 묘사한 다변량 공정에서 생성된 각 데이터에 MD를 적용하여 이상치를 제거한 후 ICA 기반 고장탐지를 수행하였고, ICA 단일모델과 성능을 비교하였다.

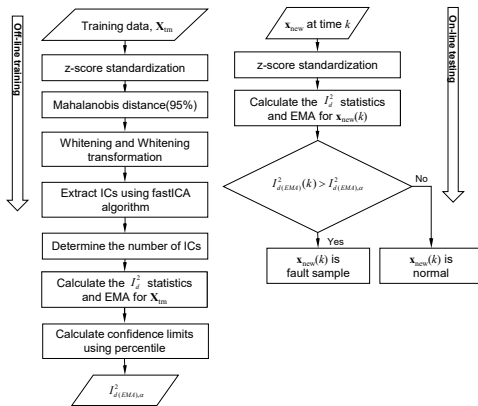


그림 1. 제안된 방법의 고장탐지 순서도.
Fig. 1. Schematic diagram for fault detection using proposed method.

일반적으로 다변량 공정 데이터는 불안정한 환경에서 채취되므로 데이터에 이상치(outlier)가 포함될 가능성이 크고, 불필요한 변수들을 제거할 필요가 있다. 이상치 제거를 위해 주로 거리 측정 방법들이 이용된다. 여러 종류의 거리 측정 방법들 중에서 마할라노비스 거리(Mahalanobis distance, MD)는 각 변수들의 공분산의 크기에 따라 가중치를 고려하여 거리를 계산하기 때문에, 공정변수들

2. 고장탐지 방법

그림 1은 본 연구의 고장탐지 절차를 표현한 다이어그램이다. 오프라인 과정에서는 정상데이터인 다변량 학습데이터에 MD를 적용하여 이상치를 제거한다. 이상치가 제거된 데이터에 ICA를 적용하여 통계량과 지수이동평균(exponential moving average, EMA)를 계산한 후에, 고장선언을 위한 문턱값을 계산한다. 온라인 과정에서는 검증 데이터에 대한 통계량과 EMA를 계산하여 사전에 계산된 문턱값과 비교함으로써 고장탐지를 수행한다.

2.1 마할라노비스 거리(MD)

대상 공정의 변수 개수가 m 개고 샘플링된 데이터 개수가 n 개일 때, 계속된 다변량 학습데이터 행렬 \mathbf{X} 는 $[\mathbf{x}^1 \mathbf{x}^2 \cdots \mathbf{x}^n]^T \in R^{n \times m}$ 로 구성되고, 데이터 벡터 \mathbf{x}^i 는 $[x_1^i \cdots x_m^i]^T \in R^{m \times 1}$, $i = 1, \dots, n$ 가 된다. MD를 적용하기 전에 각 변수들의 평균과 표준편차를 동일하게 설정하기 위해 z -점수 표준화를 적용한다. 표준화를 적용한 후, 평균벡터와 공분산 행렬을 계산한다. 평균벡터는 아래의 식 (1)로, 공분산 행렬은 식 (2)로 계산된다.

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_j^i, \quad j = 1, \dots, m \quad (1)$$

$$\mathbf{S}_{p,q} = \frac{1}{n-1} \sum_{i=1}^n (x_p^i - \bar{x}_p)(x_q^i - \bar{x}_q), \quad (2)$$

$$p, q = 1, \dots, m$$

평균벡터와 공분산 행렬이 계산되면, 아래의 식 (3)을 통해 MD가 계산된다.

$$MD(\mathbf{x}) = \sqrt{(\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{S} (\mathbf{x} - \bar{\mathbf{x}})} \quad (3)$$

일반적으로 이상치를 제거하기 위한 문턱값을 10%, 5% 또는 1%로 설정한다. 본 실험에서는 최적의 문턱값을 설정하기 위해 10%, 5%, 1%로 문턱값을 각각 설정하여 성능비교를 수행하였다. 10%로 설정했을 경우에는 고장과 관련된 정보를 함유한 데이터까지 제거되었기 때문에 성능이 하락했다. 1%로 설정했을 경우에는 이상치로 간주되는 데이터가 적기 때문에 성능이 개선되지 않았다. 반면에, 5%로 설정했을 때는 불필요한 이상치만 적절히 제거되었기 때문에 개선된 성능을 보였다. 따라서 본 논문에서는 MD로 계산된 데이터를 내림차순으로 정렬한 뒤에, 5%에 해당되는 데이터를 제거하였다.

2.2 독립성분분석(ICA)

ICA는 변수들 사이의 상관관계를 제거하기 위해 먼저 화이트닝을 수행한다. 화이트닝은 벡터 $\mathbf{x}(k)$ 의 공분산 행렬을 계산하고 고유값 분해를 수행한다. 공

분산 행렬과 고유값 분해 과정은 식 (4)와 같다.

$$\mathbf{R}_x = E[\mathbf{x}(k)\mathbf{x}^T(k)] = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T, k = 1, \dots, n \quad (4)$$

$\mathbf{\Lambda}$ 는 대각행렬 $diag(\lambda_1, \dots, \lambda_m)$ 로, 대각성분들이 내림차순 $\lambda_1 > \dots > \lambda_m$ 으로 정렬된 공분산 행렬 \mathbf{R}_x 의 고유치로 구성된다. 고유값 분해가 적용된 뒤에, 식 (5)을 통해 화이트닝 변환을 수행한다.

$$\mathbf{z}(k) = \mathbf{Q}\mathbf{x}(k) = \mathbf{Q}\mathbf{A}\mathbf{s}(k) = \mathbf{B}\mathbf{s}(k) \quad (5)$$

여기서, 행렬 \mathbf{Q} 는 $\mathbf{Q} = \mathbf{A}^{-1/2}\mathbf{U}^T$ 이고, $\mathbf{A}^{-1/2}$ 는 대각성분들 $\lambda_1^{-1/2}, \dots, \lambda_m^{-1/2}$ 로 구성된 대각행렬이다. 식 (4)과 (5)에 의해 벡터 $\mathbf{z}(k)$ 와 행렬 \mathbf{R}_x 는 각각 아래와 같이 변환될 수 있다.

$$\mathbf{R}_z = E[\mathbf{z}(k)\mathbf{z}^T(k)] = \mathbf{B}E[\mathbf{s}(k)\mathbf{s}^T(k)]\mathbf{B}^T \quad (6)$$

$$\mathbf{R}_z = \mathbf{B}E[\mathbf{s}(k)\mathbf{s}^T(k)]\mathbf{B}^T = \mathbf{B}\mathbf{B}^T = \mathbf{I} \quad (7)$$

여기서, 행렬 \mathbf{B} 는 직교행렬이고, 식 (5)에 의해 행렬 \mathbf{R}_z 는 항등행렬이 된다. $\mathbf{s}(k)$ 와 행렬 \mathbf{W} 는 각각 아래의 식 (8)과 (9)로 표현된다.

$$\hat{\mathbf{s}}(k) = \mathbf{B}^T \mathbf{z}(k) = \mathbf{B}^T \mathbf{Q} \mathbf{x}(k), k = 1, \dots, n \quad (8)$$

$$\mathbf{W} = \mathbf{B}^T \mathbf{Q} \quad (9)$$

행렬 \mathbf{B} 의 각 칼럼벡터 \mathbf{b}_i 는 i 번째 독립성분 $\hat{s}_i(k) = (\mathbf{b}_i)^T \mathbf{z}(k)$ 이 최대의 비가우시안 특성을 가지도록 초기화 및 업데이트 되어야 한다. 본 논문에서는 Hyvärinen[9]이 제안한 fastICA 알고리즘을 이용하여 행렬 \mathbf{B} 를 계산하였다.

2.3 독립성분 개수 설정

ICA는 PCA와 다르게 독립성분들의 정렬방법과 개수를 설정할 수 있는 확립된 기준이 존재하지 않는다. 독립성분을 정렬하기 위한 방법으로 L_2 -norm[2], L_∞ -norm[10], 비가우시안 특성[11] 등을 이용한 방법들이 제안되었지만, 독립성분의 개수를 결정하기 위한 명확한 기준은 제시되지 않았다. 따라서 독립성분의 개수를 결정하기 위해 일반적인

로 PCA에서 결정된 주성분의 개수만큼 독립성분을 선택한다. 본 논문에서는 간단하고 효과적인 L_2 -norm을 이용하여 독립성분들을 정렬한 후에, PCA에서 선택된 주성분의 개수와 동일하게 독립성분 개수를 설정하였다. 독립성분의 개수가 결정되면, 해당 개수만큼 행렬 \mathbf{W} 는 차원 축소(\mathbf{W}_d)되고 분해된다. ($\mathbf{W} = [\mathbf{W}_d, \mathbf{W}_e]$)

2.4 통계량과 지수이동평균

본 논문에서는 Jong-Min Lee[12]이 제안한 I_d^2 통계량을 탐지 지수로 이용하였다. I_d^2 통계량은 차원 축소된 독립성분들의 변량을 의미하며 식 (10)으로 계산된다. $\hat{\mathbf{s}}_{n,d}(k)$ 는 $\mathbf{W}_d \mathbf{x}(k)$ 를 의미한다.

$$I_d^2(k) = \hat{\mathbf{s}}_{n,d}(k)^T \hat{\mathbf{s}}_{n,d}(k) \quad (10)$$

본 논문에서는 통계량의 추세를 고려하기 위해 EMA를 아래의 식 (11)로 계산하였다.

$$\begin{aligned} EMA(1) &= TS(1) \\ EMA(k) &= \alpha TS(k) + (1-\alpha)EMA(k-1), \quad (11) \\ & k \geq 2 \end{aligned}$$

$TS(k)$ 는 통계량이고 $\alpha = 2/(b+1)$ 는 평활인자이며, b 는 window size이다.

2.5 고장선언을 위한 문턱값 설정

통계량 값이 동일하더라도 문턱값에 따라 고장탐지 성능 차이가 발생한다. 따라서 연구자들은 일반적으로 95, 99번째를 문턱값으로 설정하여 반복적인 실험을 통해 최적의 문턱값을 정한다. 본 논문에서는 95번째, 99번째 백분위수를 고장선언을 위한 문턱값으로 설정하여 성능을 비교한 결과, 99번째 백분위수가 가장 좋은 성능을 보였기 때문에, 99번째 백분위수를 문턱값으로 설정하였다. 백분위수에 대한 EMA에 적용되며, EMA가 문턱값을 넘어서면 고장알람이 발생된다.

3. 대상시스템 및 데이터

본 논문에서는 Wenfu Ku[9]가 제안한 다이내믹 공정 모델과 Alcalá[13]가 제안한 다변량 공정 모델에서 생성된 데이터를 이용하였다. 생성된 정상데이터는 학습에 이용되었고, 고장데이터는 아래의 3.1절과 3.2절에서 소개한 방법으로 생성된다.

3.1 다이내믹 공정 모델

$$\mathbf{z}(k) = \begin{bmatrix} 0.118 & -0.191 & 0.287 \\ 0.847 & 0.264 & 0.943 \\ -0.333 & 0.514 & -0.217 \end{bmatrix} \mathbf{z}(k-1) + \quad (12)$$

$$\begin{bmatrix} 1 & 2 \\ 3 & -4 \\ -2 & 1 \end{bmatrix} \mathbf{u}(k-1)$$

$$\mathbf{y}(k) = \mathbf{z}(k) + \mathbf{v}(k), \quad (13)$$

$$\mathbf{x}(k) = [\mathbf{y}^T(k) \mathbf{u}^T(k)]^T$$

$$\mathbf{u}(k) = \begin{bmatrix} 0.811 & -0.226 \\ 0.477 & 0.415 \end{bmatrix} \mathbf{u}(k-1) + \quad (14)$$

$$\begin{bmatrix} 0.193 & 0.689 \\ -0.320 & -0.749 \end{bmatrix} \mathbf{w}(k-1)$$

\mathbf{z} 는 시스템의 상태 방정식을 의미하고, \mathbf{u} 는 입력, \mathbf{y} 는 출력이다. \mathbf{w} 는 -2에서 2까지 범위를 가지는 균등분포를 따르는 랜덤벡터이다. \mathbf{v} 는 평균과 분산이 각각 0와 0.1인 잡음벡터이며, $\mathbf{x}(k)$ 는 5개의 변수($\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \mathbf{u}_1, \mathbf{u}_2$)로 구성된다. 본 논문에서는 정상 및 고장데이터를 200개씩 생성하여 학습 및 검증하였다. 고장데이터를 생성하기 위해 아래의 방법으로 바이어스와 드리프트를 각각 적용하였다.

바이어스: 시간 $k=51, \dots, 200$ 구간에서 k 가 1씩 증가할 때 마다, w_1 값에 3씩 증가.

드리프트: 시간 $k=51, \dots, 149$ 구간에서 k 가 1씩 증가할 때 마다, w_1 값에 0.05씩 누적하여 증가.

3.2 다변량 공정 모델

$$\begin{bmatrix} \chi_1 \\ \chi_2 \\ \chi_3 \\ \chi_4 \\ \chi_5 \\ \chi_6 \end{bmatrix} = \begin{bmatrix} -0.3441 & 0.4815 & 0.6637 \\ -0.2313 & -0.5936 & 0.3545 \\ -0.5060 & 0.2495 & 0.0739 \\ -0.5552 & -0.2405 & -0.1123 \\ -0.3371 & 0.3822 & -0.6115 \\ -0.3877 & -0.3868 & -0.2045 \end{bmatrix} \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} + N(0,1) \quad (15)$$

위의 수식 (15)은 다변량 공정 모델의 상태 방정식을 의미한다. 전체 변수 개수는 6개이며, 랜덤변수 t_1, t_2, t_3 은 각각 $[0, 2], [0, 1.6], [0, 1.2]$ 의 범위를 가지고 균등분포를 따른다. 잡음(noise)은 평균이 0, 분산이 1인 정규분포를 따르는 잡음벡터이다. 본 논문에서는 정상데이터 2000개, 고장데이터 1000개를 생성하여 학습 및 검증을 수행하였다. 아래의 방법으로 첫 번째 변수와 세 번째 변수에 드리프트와 바이어스를 적용하여 한 개의 고장데이터 셋을 생성하였다.

χ_1 : 시간 $k=51, \dots, 149$ 구간에서 k 가 1씩 증가할 때마다, w_1 값에 0.02씩 누적하여 증가. (드리프트)

χ_3 : 시간 $k=51, \dots, 200$ 구간에서 k 가 1씩 증가할 때마다, w_1 값에 3씩 증가. (바이어스)

4. 실험결과

그림 2와 그림 3은 각각 다이나믹 공정 및 다변량 공정 데이터에 제안된 방법을 적용하여 고장탐지를 수행한 모니터링 차트이다. 차트에서 검은색 실선은 I_d^2 통계량을 의미하고, 자주색 실선은 통계량에 대한 EMA이며, 빨간색 점선은 고장선언을 위한 문턱값을 의미한다. 두 공정에 대한 실험결과는 아래의 4.1절과 4.2절에서 분석된다.

4.1 다이나믹 공정에 대한 실험결과

바이어스 데이터에 대한 실험결과인 그림 2-(a)

에서 대략 시간 50부터 EMA가 지속적으로 문턱값을 넘어서는 것을 확인할 수 있다. 뿐만 아니라, 드리프트 데이터에 대한 결과인 그림 2-(b)에서도 고장이 발생한 유사한 시간에 EMA가 문턱값을 넘어섬으로써, 제안된 방법이 고장을 효과적으로 탐지하는 것을 확인할 수 있다.




그림 2. 다이나믹 공정에 대한 모니터링 차트
(a) 바이어스 데이터, (b) 드리프트 데이터.

Fig. 2. Monitoring charts for dynamic process
(a) bias data, (b) drift data.

4.2 다변량 공정에 대한 실험결과

그림 3에서 시간 1부터 500까지의 구간에서 EMA가 문턱값을 넘어서지 않는 것을 확인할 수 있다. 고장이 발생한 시간 501부터는 EMA가 문턱값을 넘어섬으로써, 다변량 공정에서도 제안된 방법이 효과적으로 고장을 탐지하는 것을 확인할 수 있다.




그림 3. 다변량 공정에 대한 모니터링 차트
Fig. 3. Monitoring chart for multivariate process

4.3 제안된 방법의 성능검증

표 1. 고장탐지 성능비교 테이블
Table 1. The table for comparison of fault detection performance

System	Data	ICA (conventional)		MD+ICA (proposed)	
		Type 1 error	Type 2 error	Type 1 error	Type 2 error
dynamic process [6]	bias	0	3.29	0.26	2.19
	drift	11.43	41.88	14.14	32.35
multivariate process [11]	bias+drift	0	4.90	0	1.12

표 1은 두 공정에서 생성된 데이터에 제안된 방법(MD+ICA)과 비교방법(ICA)을 적용했을 때의 고장탐지 성능을 비교한 것이다. 표 안의 모든 수치는 소수점 세 번째 자리에서 반올림한 값이고, 볼드체 수치는 두 방법과 비교했을 때 더 우수한 성능을 보인 실험에 대한 예리이다. type 1 error와 type 2 error는 각각 거짓알람률과 미탐지률을 의미한다.

거짓알람은 고장탐지 모델이 고장을 선언했지만 시스템에 고장이 발생하지 않은 경우이고, 미탐지는 시스템에 실제로 고장이 발생했지만 모델이 이를 탐지하지 못한 경우를 의미한다. 두 종류의 예리들 중에 미탐지가 시스템에 더 치명적이므로, type 2 error가 더 중요하게 고려된다. 표 1에서 다이나믹 공정의 바이어스 데이터의 경우에 제안된 방법의 type 1 error가 0.26%p 만큼 높지만 type 2 error가 1.1%p 만큼 낮으므로, 제안된 방법의 성능이 0.84%p 더 좋다고 할 수 있다. 드리프트 데이터

의 경우에는 제안된 방법의 type 1 error가 비록 2.71%p 높지만 type 2 error가 9.53%p 낮으므로, 전체 6.82%p 만큼 성능이 개선됐다. 마지막으로 다변량 공정에서는 제안된 방법의 type 2 error가 3.78%p 개선된 것을 확인할 수 있다.

5. 결론

다변량 공정에 발생한 고장을 사전에 탐지하지 못할 경우에는 대형사고 또는 비계획정지로 이어질 수 있다. 따라서 공정의 안전성과 신뢰성을 확보하기 위해 발생한 고장을 사전에 탐지할 수 있는 기술이 필요하다. 본 논문에서는 자기회귀 특성을 가지는 다이나믹 공정과 센서의 고장을 묘사한 다변량 공정에서 생성된 데이터에 MD를 적용하여 이상치를 제거 한 후, ICA를 통해 고장탐지를 수행하였다. 제안된 방법의 성능검증을 위해 기존 ICA 단일모델과 성능을 비교하였다. 실험결과, 제안된 방법이 다이나믹 공정의 바이어스 데이터에서 0.84%p, 드리프트 데이터의 경우 6.82%p 만큼 성능이 개선되었고, 다변량 공정에서는 3.78%p 만큼 기존 ICA 보다 우수한 고장탐지 성능을 보였다. 향후 연구는 다양한 공정에서 효과적인 고장탐지를 위해 DICA, KICA를 적용하여 성능을 검증할 예정이다.

REFERENCES

- [1] J. Yu, J. Jang, J. Yoo, and S. Kim, "Fault detection method for steam boiler tube using Mahalanobis distance," Journal of Korean Institute of Intelligent Systems, vol. 26, pp. 246-252, 2016.
- [2] Y. H. Lee, K. J. KIM, S. I. Lee, and D. J. Kim, "Seq2Seq model-based prognostics and health management of robot arm," The Journal of Korean Institute of Information, Electronics, and Communication Technology, vol. 12, no. 3, pp. 242-250, 2019.
- [3] J. M. Lee, C. K. Yoo, and I. B. Lee, "Statistical monitoring of dynamic processes based on dynamic independent component

analysis," Chemical Engineering Science, vol. 59, pp. 2995-3006, Jul. 2004.

[4] W. Ku, R. H. Storer, and C. Georgakis, "Disturbance detection and isolation by dynamic principal component analysis," Chemometrics and Intelligent Laboratory Systems, vol. 30, pp. 179-196, 1995.

[5] M. Žvokelj, S. Zupan, and I. Prebil, "EEMD-based multiscale ICA method for slewing bearing fault detection and diagnosis," Journal of Sound and Vibration, vol. 370, pp. 394-423, 2016.

[6] A. Ajami, and M. Daneshvar "Data driven approach for fault detection and diagnosis of turbine in thermal power plant using Independent Component Analysis(ICA)," International Journal of Electrical Power & Energy, vol. 43, pp. 728-735, 2012.

[7] M. Liu, Y. Liao and X. Li, "Data-driven fault detection of three-tank system applying MWAT-ICA," Journal of Shanghai Jiaotong University (Science), vol. 25, no. 5, pp. 659-664, 2000.

[8] S. Zhang, and C. Zhao, "Hybrid independent component analysis (H-ICA) with simultaneous analysis of high-order and second-order statistics for industrial process monitoring," Chemometrics and Intelligent Laboratory Systems, vol. 185, no. 15, pp. 47-58, 2019.

[9] A. Hyvärinen, "Fast and robust fixed-point algorithm for independent component analysis," IEEE Trans. Neural Networks, vol. 10, no. 3, pp. 626-634, 1999.

[10] A. D. Back, and A. S. Weigend, "A first application of independent component analysis to extracting structure from stock returns," International Journal of Neural Systems, vol. 8, no. 4, pp. 473-484, 1997.

[11] A. Hyvärinen, "Survey on independent component analysis," Neural computing surveys, vol. 2, pp. 94-128, 1999.

[12] J. M. Lee, C. K. Yoo, and I. B. Lee, "Statistical process monitoring with

independent component analysis," Journal of Process Control, vol. 14, no. 5, pp. 467-485, 2003.

[13] C.F. Alcalá, and S. J. Qin, "Analysis and generalization of fault diagnosis methods for process monitoring," Journal of Process Control, vol. 21, no. 3, pp. 322-330, 2011.

저자약력

정 승 환(Seunghwan Jung)

[정회원]



- 2016년 신라대학교 컴퓨터공학(공학사)
- 2019년 부산대학교 전기전자컴퓨터공학(공학석사)
- 2019년~현재 부산대학교 전기전자공학(공학박사과정)

〈관심분야〉 고장탐지 및 진단, 기계학습, 데이터 마이닝

김 성 신(Sungshin Kim)

[정회원]



- 1986년 연세대학교 전기공학(공학석사)
- 1996년 Georgia Institute of Technology 전기 및 컴퓨터 공학(공학박사)
- 1998년~현재 부산대학교 전기공학부 교수

〈관심분야〉 지능시스템, 지능로봇, 고장진단 및 예측