

독립성분분석을 이용한 다변량 공정에서의 고장탐지 방법

정승환¹ · 김민석¹ · 이한수¹ · 김종근¹ · 김성신^{2*}

Fault Detection Method for Multivariate Process using ICA

Seunghwan Jung¹ · Minseok Kim¹ · Hansoo Lee¹ · Jonggeun Kim¹ · Sungshin Kim^{2*}

¹Ph.D. student, Department of Electrical and Computer Engineering, Pusan National University, Pusan, 46241 Korea

^{2*}Professor, Department of Electrical and Computer Engineering, Pusan National University, Pusan, 46241 Korea

요 약

대규모 발전소나 화학공정과 같은 다변량 공정은 매우 위험한 환경에서 운전되기 때문에 고장이 발생하면 심각한 인적·물적 손실이 발생할 수 있다. 따라서 시스템의 고장을 사전에 탐지할 수 있는 온라인 모니터링 기술이 필수적이다. 본 논문에서는 세 가지의 다른 다변량 공정 데이터에 ICA를 적용하여 고장탐지를 수행하였고, PCA와 성능을 비교하였다. ICA 기반의 고장탐지 절차는 크게 오프라인 과정과 온라인 과정으로 나뉜다. 오프라인 과정에서는 시스템이 정상일 때 계속된 데이터를 이용하여 고장판별을 위한 문턱 값을 설정한다. 그리고 온라인 과정에서는 실시간으로 계속되는 질의벡터에 대한 통계량을 계산한 후, 계산된 통계량과 사전에 정의된 문턱 값과 비교하여 고장을 판별한다. 본 논문에서 이용한 세 가지의 다변량 공정 데이터에 실험한 결과, ICA 기반 고장탐지 방법이 시스템의 고장을 사전에 탐지하였고, PCA 보다 우수한 고장탐지 성능을 보여주었다.

ABSTRACT

Multivariate processes, such as large scale power plants or chemical processes are operated in very hazardous environment, which can lead to significant human and material losses if a fault occurs. On-line monitoring technology, therefore, is essential to detect system faults. In this paper, the ICA-based fault detection method is conducted using three different multivariate process data. Fault detection procedure based on ICA is divided into off-line and on-line processes. The off-line process determines a threshold for fault detection by using the obtained dataset when the system is normal. And the on-line process computes statistics of query vectors measured in real-time. The fault is detected by comparing computed statistics and previously defined threshold. For comparison, the PCA-based fault detection method is also implemented in this paper. Experimental results show that the ICA-based fault detection method detects the system faults earlier and better than the PCA-based method.

키워드 : 고장탐지, 공정 모니터링, 독립성분분석, 다변량 공정.

Keywords : fault detection, process monitoring, independent component analysis, multivariate process

Received 13 December 2019, Revised 21 December 2019, Accepted 1 January 2020

* Corresponding Author Sung-Shin Kim(E-mail:sskim@pusan.ac.kr, Tel:+82-51-510-2374)

Professor, Department of Electrical Computer Engineering, Pusan National University, Busan, 46241 Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.2.192>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

화력발전소나 화학 공정과 같은 다변량 공정은 매우 복잡한 절차로 운전되므로 단변량 공정에 비해 대상 시스템을 분석하기 어렵다. 이러한 다변량 공정은 시간이 지날수록 그 규모가 커지고 복잡해지고 있기 때문에 잠재적 위험성 또한 증가하고 있다. 여기서 잠재적 위험성은 시스템에서 발생할 수 있는 고장(fault)을 의미한다. 특히 화력발전소는 고온·고압의 환경에서 동작하기 때문에 고장이 발생하면 시스템의 실패(failure)로 이어질 수 있으므로 심각한 인적·물적 손실이 발생할 수 있다. 따라서 다변량 공정에서의 고장을 대비하기 위해, 발전사들은 온라인 모니터링 시스템을 운영하고 있다. 온라인 모니터링 시스템은 실시간으로 시스템의 상태를 감시할 수 있기 때문에, 복잡한 공정에서 시스템의 고장탐지를 위해 유용하게 운영된다.

MSPM(Multivariate Statistical Process Monitoring)은 다변량 공정에서 고장탐지를 위한 통계적 온라인 모니터링 방법이다. 위 방법은 대용량 데이터를 실시간으로 계측 및 저장하고 저장된 데이터를 기반으로 고장탐지를 위한 유용한 정보를 추출한다. 이렇게 추출된 정보를 이용하여 시스템의 고장과 비정상적인 행동(abnormal behavior)을 사전에 탐지한다. MSPM은 일반적으로 아래의 절차대로 진행된다:

- (1) 시스템이 정상일 때 계측된 과거 데이터(historical data)를 학습하여 데이터 기반의 고장탐지 모델 수립.
- (2) 실시간으로 계측되는 데이터를 (1)단계에서 수립된 고장탐지 모델에 입력.
- (3) 과거에 학습된 고장탐지 모델이 입력된 실시간 데이터를 분석하여 대상 시스템이 정상인지, 비정상인지 판단.
- (4) 대상 시스템이 고장이라고 판단될 시에, 고장에 기여한 변수를 식별.
- (5) 식별된 고장변수를 기반으로 고장의 원인을 확인 및 제거.

일반적으로 다변량 공정에서 계측된 데이터는 잡음과 변수들 간의 높은 상관관계를 가지고 있다. 따라서 주어진 데이터가 함유하고 있는 잡음을 제거하고, 높은 상관관계를 효과적으로 다룰 수 있는 모델을 구축하는 것이 매우 중요하다. MSPM을 위한 대표적인 고장탐지 모델은 PCA(Principal Component Analysis)와 ICA

(Independent Component Analysis)가 있다. PCA와 ICA는 대표적인 통계적 다변량 차원축소 기법으로 데이터의 특징을 추출하기 위해 주로 이용된다[1]. 두 기법의 주된 차이점은 각 기법에서 가정되는 은닉변수들의 분포이다. PCA는 은닉변수들(latent variables)이 가우시안 분포를 따른다고 가정되고, ICA는 비 가우시안(non-Gaussian) 분포를 따른다고 가정된다.

Jong-Min Lee[2]는 Wenfu Ku가 제안한 다변량 공정 모델[3]에 ICA를 이용하여 고장탐지에 관한 연구를 수행하였고, Manabu Kano[4]는 PCA를 이용하여 고장탐지를 수행하여 성능을 검증하였다. PCA와 ICA는 그 외의 다양한 산업 환경에서 고장탐지를 위해 연구되어 왔다[5-7]. 본 저자도 실제 화력발전소 고압급수가열기에서 계측된 데이터에 PCA와 ICA를 각각 적용하여 고장탐지 성능을 검증하였다[8, 9]. 본 논문에서는 [8, 9]에서 수행된 고압급수가열기에 대한 실험결과와 [3]에서 제안한 다변량 공정모델에서 ICA를 적용하여 도출된 성능을 각각 PCA와 비교하여 분석하였다.

고장탐지 절차는 크게 오프라인(off-line)과정과 온라인(on-line)과정으로 나뉜다. 본 연구의 전체적인 고장탐지 절차는 아래의 그림 1과 같다. 먼저, 오프라인 과정에서 시스템이 정상일 때 계측된 다변량 학습데이터에 z-점수 표준화(z-score standardization)를 적용한다. 표준화 기법을 적용하는 이유는 다 변량 데이터의 경우에 각 변수의 범위(range)가 다르기 때문에 모든 변수의 범위를 동일하게 맞추기 위함이다. z-점수 표준화가 적용된 데이터에 화이트닝(whitening)과 화이트닝 변환(whitening transformation)을 수행한다. 그리고 fastICA 알고리즘을 이용해서 독립성분들을 추출하고 적절한

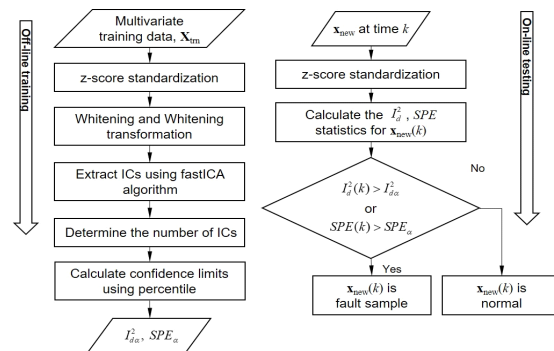


Fig. 1 Overall procedure for fault detection using ICA algorithm.

독립성분의 개수를 설정한다. 최적의 독립성분의 개수가 결정되면 I_d^2 , SPE(squared prediction error) 통계량을 계산한 뒤에, 백분위수(percentile)를 이용하여 계산된 각 통계량에 대한 문턱 값을 설정한다. 여기서 문턱 값은 대상 시스템이 정상인지 비정상인지 판별하기 위한 문턱 값을 의미한다. 온라인 과정에서는 실시간으로 예측되는 질의벡터에 대해서 z-점수 표준화를 적용하여 각 변수의 범위를 동일하게 설정한다. 그리고 표준화가 적용된 질의벡터에 대한 I_d^2 , SPE 통계량을 계산한 뒤에 계산된 각 통계량이 사전에 정의된 문턱 값을 넘어서면 시스템의 고장으로 판별한다.

II. 고장탐지방법

2.1. 독립성분분석(ICA)

ICA는 다변량 데이터를 통계적 독립성분으로 변환시키는 기법이다[10]. 독립성분들은 서로 통계적으로 독립이고, 비 가우시안 분포를 따른다고 가정된다[2]. ICA기반 모니터링 방법은 표준화가 적용된 데이터 벡터에 화이트닝과 화이트닝 변환을 적용하는 것으로 시작한다. 화이트닝은 벡터 $\mathbf{x}(k)$ 에 대한 공분산 행렬을 계산하고 고유값 분해를 수행함으로써, 공정변수들 사이의 교차상관관계를 제거하는 단계이다. 공분산 행렬과 고유값 분해는 아래의 식 (1)에 의해 정의된다.

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

여기서, E 는 기댓값(expectation)이고 \mathbf{A} 는 대각행렬 $\mathbf{A} = \text{diag}(\lambda_1, \dots, \lambda_m)$ 로 대각성분 $\lambda_1, \dots, \lambda_m$ 들이 내림차순 $\lambda_1 > \dots > \lambda_m$ 으로 정렬된 공분산 행렬 \mathbf{R}_x 의 고유치로 구성된다. 고유값 분해가 적용된 뒤에, 아래의 식 (2)에 의해 화이트닝 변환을 수행한다.

$$\mathbf{z}(k) = \mathbf{Q}\mathbf{x}(k) = \mathbf{Q}\mathbf{A}\mathbf{s}(k) = \mathbf{B}\mathbf{s}(k) \quad (2)$$

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 (1)과 (2)에 의해 벡터 $\mathbf{z}(k)$ 와 행렬 \mathbf{R}_x 는 각각 아래와 같이 변환될 수 있다.

$$\mathbf{R}_x = E[\mathbf{z}(k)\mathbf{z}^T(k)] = \mathbf{B}E[\mathbf{s}(k)\mathbf{s}^T(k)]\mathbf{B}^T \quad (3)$$

$$\mathbf{R}_x = \mathbf{B}E[\mathbf{s}(k)\mathbf{s}^T(k)]\mathbf{B}^T = \mathbf{B}\mathbf{B}^T = \mathbf{I} \quad (4)$$

여기서, 행렬 \mathbf{B} 는 직교행렬이고, 식 (2)에 의해 행렬 \mathbf{R}_x 는 항등행렬이 된다. $\mathbf{s}(k)$ 는 식 (5)로 추정할 수 있고, 행렬 \mathbf{W} 와 \mathbf{B} 의 관계는 식 (6)으로 표현된다.

$$\hat{\mathbf{s}}(k) = \mathbf{B}^T\mathbf{z}(k) = \mathbf{B}^T\mathbf{Q}\mathbf{x}(k), k = 1, \dots, n \quad (5)$$

$$\mathbf{W} = \mathbf{B}^T\mathbf{Q} \quad (6)$$

행렬 \mathbf{B} 를 계산하기 위하여, 각 칼럼벡터 \mathbf{b}_i 는 i 번째 독립성분 $\hat{s}_i(k) = (\mathbf{b}_i)^T\mathbf{z}(k)$ 이 최대의 비 가우시안 특성을 가지도록 초기화 되고 업데이트 되어야 한다. 비 가우시안 특성을 측정할 수 있는 방법은 kurtosis와 negentropy가 있다. 본 논문에서는 negentropy기반으로 비 가우시안 특성을 측정할 수 있는 fastICA 알고리즘을 이용하였다. 이 알고리즘은 Hyvärinen이 제안한 알고리즘[10]으로 ICA를 이용하는 연구자들이 널리 사용하고 있는 검증된 알고리즘이다. 본 논문에서는 fastICA 알고리즘을 이용하여 행렬 \mathbf{B} 를 계산하고, 식 (5)과 (6)을 각각 이용하여 벡터 $\hat{\mathbf{s}}(k)$ 와 행렬 \mathbf{W} 를 계산한다.

2.2. 독립성분 개수 설정

PCA는 변량을 기준으로 주성분들을 정렬한 뒤에 그 개수를 설정한다. 그러나 ICA에서는 성분들의 정렬방법과 개수를 설정할 수 있는 확립된 방법이 존재하지 않는다. 따라서 연구자들은 L_2 놈(norm) [2], L_∞ 놈 [11], 비 가우시안 특성[12] 등을 이용한 방법들을 제안하였다. 본 논문에서는 위 방법들 중에서, 간단하지만 좋은 결과를 산출해주는 L_2 놈을 이용하여 독립성분들을 정렬하였다. 그리고 독립성분의 개수는 PCA에서 CPV (Cumulative Percentage Variance)를 이용하여 선정된 주성분의 개수와 동일하게 설정하였다. 독립성분의 개수가 결정되면, 결정된 독립성분의 개수만큼 행렬 \mathbf{W} 는 차원 축소되고 분해된다. ($\mathbf{W} = [\mathbf{W}_d, \mathbf{W}_e]$) 행렬 \mathbf{W}_d 는 차원이 축소된 행렬(dominant)이고 행렬 \mathbf{W}_e 는 차원이 축소되고 남은 행렬(excluded)이다.

2.3. 통계량(탐지지수)

본 논문에서 이용한 통계량은 I_d^2 , SPE 통계량이다. I_d^2 통계량은 차원이 축소된 독립성분들의 통계량을 의미

하고, SPE 통계량은 근사오차의 크기를 의미한다. 각 통계량은 아래의 식으로 계산된다.

$$\hat{I}_d^2(k) = \hat{\mathbf{s}}_{n,d}(k)^T \hat{\mathbf{s}}_{n,d}(k) \quad (7)$$

$$SPE(k) = (\mathbf{x}(k) - \hat{\mathbf{x}}(k))^T (\mathbf{x}(k) - \hat{\mathbf{x}}(k)) \quad (8)$$

여기서, $\hat{\mathbf{x}}$ 는 $\hat{\mathbf{x}} = \mathbf{Q}^{-1} \mathbf{B}_d \hat{\mathbf{s}}(k) = \mathbf{Q}^{-1} \mathbf{B}_d \mathbf{W}_d \mathbf{x}(k)$ 이고 $\hat{\mathbf{s}}_{n,d}(k) = \mathbf{W}_d \mathbf{x}(k)$ 이다.

2.4. 통계량의 문턱 값 : 백분위수

본 논문에서는 고장을 판별하기 위한 문턱 값을 계산하기 위해서 백분위수를 이용하였다. 백분위수는 계산된 통계량에 대해 적용되며, 99번째 백분위수를 고장판별을 위한 문턱 값으로 설정하였다.

III. 대상 시스템: 다변량 공정 모델

3.1. 다변량 공정모델

$$\mathbf{z}(k) = \begin{bmatrix} 0.118 & -0.191 & 0.287 \\ 0.847 & 0.264 & 0.943 \\ -0.333 & 0.514 & -0.217 \end{bmatrix} \mathbf{z}(k-1) + \begin{bmatrix} 1 & 2 \\ 3 & -4 \\ -2 & 1 \end{bmatrix} \mathbf{u}(k-1) \quad (9)$$

$$\mathbf{y}(k) = \mathbf{z}(k) + \mathbf{v}(k), \mathbf{x}(k) = [\mathbf{y}^T(k) \mathbf{u}^T(k)]^T \quad (10)$$

$$\mathbf{u}(k) = \begin{bmatrix} 0.811 & -0.226 \\ 0.477 & 0.415 \end{bmatrix} \mathbf{u}(k-1) + \begin{bmatrix} 0.193 & 0.689 \\ -0.320 & -0.749 \end{bmatrix} \mathbf{w}(k-1) \quad (11)$$

본 논문에서 이용한 데이터는 Wenfu Ku[3]가 제안한 다변량 공정 모델을 이용하여 생성한 데이터이다. 모델은 위의 식 (9)-(11)로 정의된다. 여기서, \mathbf{z} 는 시스템의 상태 방정식을 의미하고, \mathbf{u} 는 입력, \mathbf{y} 는 출력이다. 입력 \mathbf{w} 는 -2에서 2사이 구간의 균등분포를 따르는 랜덤벡터이다. 출력 \mathbf{y} 는 \mathbf{z} 와 랜덤 잡음벡터 \mathbf{v} 를 합한 것과 동일하다. 벡터 \mathbf{v} 의 각 성분들의 평균과 분산은 각각 0와 0.1이며, 벡터 $\mathbf{x}(k)$ 는 5개의 변수($\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \mathbf{u}_1, \mathbf{u}_2$)로 구성되어 있다. 본 논문에서는 정상데이터와 고장데이터를 각각 200개씩 생성하여 학습 및 검증하였다. 고장데이터는 아래의 방법으로 바이어스(bias)와 드리프트(drift)를 각각 적용하여 생성하였다.

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

방법 2. 시간 $k=51, \dots, 149$ 구간에서 k 가 1씩 증가할 때 마다, w_1 값에 0.05씩 누적하여 증가. (드리프트)

방법 1을 이용하여 생성된 데이터는 램프함수 형태를 가지는데, 이는 실제 산업 현장에서 갑작스러운 고장으로 인해 계속되는 데이터의 변동 폭이 큰 상황을 묘사한 것이다. 방법 2로 생성된 데이터는 서서히 증가하는 모습을 띄는데, 이는 시스템의 작은 결함으로 인하여 고장의 크기가 점점 커지는 현상을 묘사한 것이다.

IV. 실험 결과

4.1. 고장탐지 결과

그림 2는 위의 방법 1을 이용하여 생성된 바이어스 데이터에 ICA를 적용하여 수행된 고장탐지 결과이고, 그림 3은 방법 2로 생성된 드리프트 데이터에 대한 실험 결과이다. 그림 2, 3에서 검은색 선은 각 통계량을 의미하고 빨간색 점선은 백분위수를 이용하여 설정된 문턱 값을 의미한다. 위의 방법 1, 2에서 확인할 수 있듯이, 시스템의 고장은 대략 시간 50부터 발생시켰지만, 그림 2, 3에서 SPE 통계량은 발생한 고장에 의한 변화는 크게




Fig. 2 Result of fault detection for bias data.




Fig. 3 Result of fault detection for drift data.

보이지 않는다. 반면에 I_d^2 통계량은 바이어스 데이터의 경우 대략 시간 50부터 지속적으로 문턱값을 넘어서는 것을 확인할 수 있다. 드리프트 데이터의 경우에는 대략 시간 50부터 지속적으로 증가하다가 시간 100에서 문턱값을 넘어서고, 고장의 효과가 제거되는 시간 150부터는 통계량이 낮아져서 다시 정상 데이터의 형태를 가지는 것을 확인할 수 있다. 따라서 I_d^2 통계량은 두 종류의 데이터에 대해서 모두 고장의 영향에 반응함으로써, 대상 시스템의 고장을 효과적으로 탐지하는 것을 확인할 수 있다.

표 1은 바이어스, 드리프트 데이터와 급수가열기 데이터[8, 9]에 대해서 각각 ICA와 PCA의 고장탐지 성능을 비교한 표이다. 표 1에서 모든 수치는 소수점 두 번째 자리에서 반올림한 값이고, 볼드체로 표시된 수치는 가장 우수한 성능을 보인 통계량에 대한 성능 수치이다. T1과 T2는 각각 거짓알람 비율(type 1 error)과 미탐지 비율(type 2 error)을 의미한다. 일반적으로 고장탐지 모델의 성능을 정량화하기 위해서 통계적 가설검정을 이용한다. 거짓알람은 실제 시스템의 고장이 발생하지 않았지만 통계량이 문턱 값을 넘어서는 경우를 의미하고, 미탐지는 실제 고장이 발생했지만 모델이 고장을 탐지 못한 경우를 의미한다. 거짓알람과 미탐지는 서로 트레이드-오프(trade-off) 관계이며, 미탐지가 시스템에 치명적이므로, 거짓알람보다 더 고려된다. 표 1을 보면 알 수 있듯이, ICA는 I_d^2 통계량이 SPE 통계량보다 성능이 우수하지만, PCA는 SPE 통계량이 더 우수한 성능을 보여준다. ICA의 I_d^2 통계량과 PCA의 SPE 통계량의 성능을 비교하면, I_d^2 통계량이 전체적으로 bias 데이터의 경우에는 4.5, drift 데이터의 경우에는 2.4만큼 더 우수한 성능을 보인다. 급수가열기 데이터의 경우엔 ICA보다 PCA의 SPE 통계량이 0.5만큼 더 좋은 성능을 보였지만, ICA의 I_d^2 통계량에 대한 T2가 2.5만큼 낮으므로, ICA의 성능이 더 좋다고 할 수 있다.

Table. 1 Comparison of fault detection performance.

Data	ICA				PCA			
	I_d^2		SPE		T^2		SPE	
	T1	T2	T1	T2	T1	T2	T1	T2
Bias data	2.1	8.2	2.2	88.9	2.14	71.1	1.7	13.1
Drift data	5.8	38.5	2.6	89.9	3.1	76.8	3.5	43.2
Feedwater heater	4.4	16.3	0	68.1	4.3	38.3	1.5	18.7

일반적으로 ICA와 PCA의 모델 선정 기준은 공정변수들의 가우시안 분포를 따르는지에 대한 유무이다. 따라서 관련 연구자들은 정규성 검정(Normality test)을 통해 먼저 변수들의 분포를 확인한 후, 모델을 선정한다. 본 논문에서는 위 아이디어를 착안하여 콜모고로프-스미르노프 검정(Kolmogorov-Smirnov test)을 이용한 정규성 검정을 통해 변수들의 분포를 확인함으로써, 두 기법간의 성능 차이의 이유를 분석하였다. 유의수준을 5% (0.05)로 설정하여 실험을 수행한 결과, 두 종류의 데이터에 대해서 다음과 같은 결과가 도출되었다: 1)다변량 공정 데이터에 대한 각 변수들의 p값: [2.2017e-13, 1.9382e-26, 5.2545e-16, 0.0027, 0.0117]; 2)급수가열기 데이터에 대한 각 변수들의 p값: [5.4768e-19, 4.2092e-52, 1.1854e-05, 3.7624e-08, 7.8270e-09]. 본 실험에서 설정한 유의수준을 고려하면 모든 변수들이 표준 정규분포를 따른다는 귀무가설이 기각되었으므로, ICA가 PCA보다 고장탐지 성능이 더 우수한 이유를 검증할 수 있었다.

V. 결 론

본 논문에서는 ICA를 이용한 다변량 공정에서의 고장탐지 방법에 대해서 소개하였고, PCA와 성능을 비교하였다. 실험 결과, ICA가 PCA보다 우수한 고장탐지 성능을 보였다. ICA는 은닉변수들이 비 가우시안 분포를 따르고, 통계적으로 서로 독립이라고 가정된다. 첫 번째 가정은 ICA의 고질적인 문제점으로 분석되고 있다. 향후 연구에서는 다이나믹 공정에 강력한 DICA와 이상점(outlier)에 강력한 KICA를 이용하여, 기존의 ICA와 고장탐지 성능을 비교 분석할 예정이다.

ACKNOWLEDGEMENT

This research was funded and conducted under 『the Competency Development Program for Industry Specialists』 of the Korean Ministry of Trade, Industry and Energy (MOTIE), operated by Korea Institute for Advancement of Technology (KIAT). (No. P0008473, The development of high skilled and innovative manpower to lead the Innovation based on Robot) and was supported by BK21PLUS, Creative Human Resource Development Program for IT Convergence.

REFERENCES

[1] J. S. Oh, "Straight Line Detection Using PCA and Hough transform," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 22, no. 7, pp. 227-232, Feb. 2018.

[2] 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.

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

[4] M. Kano, S. Hasebe, I. Hashimoto, and H. Ohno, "A new multivariate statistical process monitoring method using principal component analysis," *Computer and Chemical Engineering*, vol. 25, pp. 1103- 1113, 2001.

[5] M. Z. Sheriff, M. Mansouri, M. N. Karim, H. Nounou, and M. Nounou, "Fault detection using multiscale PCA-based moving window GLRT," *Journal of Process Control*, vol. 54, pp. 47-64, 2017.

[6] F. Zhou, J. H. Park, and Y. Liu, "Differential feature based hierarchical PCA fault detection method for dynamic fault," *Neurocomputing*, vol. 202, pp. 27-35, 2016.

[7] M. Zvokelj, 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.

[8] S. Jung, M. Kim, J. Jang, J. Yoo, and S. Kim, "Fault detection and Diagnosis for High Pressure Feedwater Heater using Principal Component Analysis," *Journal of Korean Institute of Intelligent Systems*, vol. 27, no. 2, Nov. 2017.

[9] S. Jung, B. Kim, J. Jang, J. Yoo, and S. Kim, "Fault detection method for high pressure feedwater heater in thermal power plant using independent component analysis," *Proceedings of KIIS Autumn Conf*, vol. 28, no. 3, Nov. 2018.

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

[11] 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.

[12] A. Hyvarinen, "Survey on independent component analysis," *Neural computing surveys*, vol. 2, no. 4, pp. 94-128, 1999. *Control*, vol. 68, pp. 129-144, 1999.



정승환(SeungHwan Jung)

2016년 신라대학교(공학사)
 2019년 부산대학교(공학석사)
 2019년~현재 부산대학교(공학박사과정)
 ※관심분야 : Fault Detection,
 Diagnosis and Prognosis
 Machine learning, Data mining



김민석(Minseok Kim)

2017년 신라대학교(공학사)
 2019년 부산대학교(공학석사)
 2019년~현재 부산대학교(공학박사과정)
 ※관심분야 : Fault Detection,
 Diagnosis and Prognosis,
 Regression Analysis.



이한수(Hansoo Lee)

2010년 부산대학교(공학사)
 2013년 부산대학교(공학석사)
 2013년~현재 부산대학교(공학박사과정)
 ※관심분야 : Intelligent System,
 Machine Learning,
 Data Analysis.



김종근(Jonggeun Kim)

2012년 부산대학교(공학사)
 2014년 부산대학교(공학석사)
 2017년~현재 부산대학교(공학박사과정)
 ※관심분야 : Data Mining, Intelligent Control,
 System Modelling,
 Fault Diagnosis.



김성신(Sungshin Kim)

1986년 연세대학교(공학석사)
 1996년 Georgia Inst. of Tech.(공학박사)
 1998년~현재 부산대학교 전기컴퓨터공학부 교수
 ※관심분야 : Intelligent System,
 Intelligent Robot,
 Fault Diagnosis & Prediction.