



마할라노비스 거리를 이용한 증기보일러 튜브의 고장탐지방법

Fault Detection Method for Steam Boiler Tube Using Mahalanobis Distance

유정원* · 장재열** · 유재영*** · 김성신*†

Jungwon Yu, Jaeyel Jang, Jaeyoung Yoo, and Sungshin Kim†

*부산대학교 전자전기컴퓨터공학과, **한국동서발전, ***(주)지오네트

*Department of Electrical and Computer Engineering, Pusan National University

**Korea East-West Power Co., Ltd.

***XEONET Co., Ltd.

요약

화력발전소의 설비들은 매우 높은 온도와 압력의 환경에서 운전되므로, 설비고장은 상당한 인적·물적 손실로 이어진다. 그러므로 발전설비의 비정상적인 동작 상태를 사전에 확인할 수 있는 고장탐지 시스템이 필수적이다. 본 연구에서는, 화력발전소 증기보일러의 고장탐지를 위해서 마할라노비스 거리(Mahalanobis distance, MD)를 이용하였다. MD 기반의 고장탐지방법에서는, 비정상샘플은 정상샘플들로부터 멀리 떨어져 있다고 가정한다. 정상상태로 동작중인 대상시스템으로부터 수집된 다변량 샘플을 이용하여 평균벡터와 공분산행렬을 계산하고, MD값의 문턱값을 설정한다. 검증단계에서는, 평균벡터와 검증샘플들 간의 MD를 구한 후, 계산된 MD 값이 미리 설정된 문턱값보다 높으면 알람신호가 발생하게 된다. MD 기반의 고장탐지방법의 성능을 검증하기 위해서, 200MW 유연탄 화력발전소의 증기보일러 튜브누설로 인해서 발전정지 된 사례를 사용하였다. 실험결과는 MD 기반의 고장탐지기법이 발전정지가 발생하기 이전의 이상징후를 성공적으로 탐지할 수 있음을 보여준다.

키워드 : 증기보일러 튜브, 마할라노비스 거리, 고장탐지

Abstract

Since thermal power plant (TPP) equipment is operated under very high pressure and temperature, failures of the equipment give rise to severe losses of life and property. To prevent the losses, fault detection method is, therefore, absolutely necessary to identify abnormal operating conditions of the equipment in advance. In this paper, we present Mahalanobis distance (MD) based fault detection method for steam boiler tube in TPP. In the MD-based method, it is supposed that abnormal data samples are far away from normal samples. Using multivariate samples collected from normal target system, mean vector and covariance matrix are calculated and threshold value of MD is decided. In a test phase, after calculating the MDs between the mean vector and test samples, alarm signals occur if the MDs exceed the predefined threshold. To demonstrate the performance, a failure case due to boiler tube leakage in 200MW TPP is employed. The experimental results show that the presented method can perform early detection of boiler tube leakage successfully.

Key Words : Steam boiler tube, Mahalanobis distance, Fault detection

Received: May, 9, 2016

Revised: Jun, 15, 2016

Accepted: Jun, 16, 2016

†Corresponding authors

sskim@pusan.ac.kr

1. 서론

화석연료를 연소시켜서 전기를 생산하는 화력발전소는, 유독한 배기가스를 배출함에도 불구하고 여전히 중요한 발전원 중에 하나이다[1]. 최근 증가하는 전력수요로 인해 발전설비의 용량과 구조는 더욱더 크고 복잡해지고 있다. 화력발전소와 같이 규모가 큰 산업공정에서, 온라인모니터링과 고장진단은 발전설비의 안전성, 신뢰성, 유용성을 위해 매우 중요하다[2]. 고장(Fault)이란, 대상시스템의 다양한 모니터링변수(ex. 압력, 온도, 유량, etc.)들 중에서, 단 하나의 변수라도 정상동작범위를 벗어난 상태로 정의된다. 원격 모니터링 시스템, 상호관계시스템, 비동기 카운터, 화력발전소 등을 대상으로 고장탐지 및 진단에 대한 연구가 활발히 진행되었다 [3-6]. 고장은 시스템의 예기치 못한 기능변화 또는 심각한 장애가 발생해서 요구되는 제 기능을 수행하지 못하는 상황을 초래할 수 있다. 따라서 모니터링변수들의 복잡한 패턴을 분석하여 발전소의 동작상태를

본 연구는 2015년도 산업통상부의 재원으로 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(No. 20151110200040)

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.

감시하고, 고장발생 초기단계에 그것을 식별하여 발전운전원이 적절한 시정조치를 취할 수 있게 해주는 고장탐지시스템이 필수적이다. 발전소에 구축된 분산제어시스템(Distributed control system, DCS)에 의해서 매우 방대한 운전이력데이터의 지속적인 수집 및 관리가 가능하고, 이 데이터는 설비건강정보 및 유지보수와 관련된 지식을 추출하기 위해서 적절히 분석되어야 한다. 현재 통계적 방법 또는 머신러닝과 같은 데이터마이닝 기법을 발전소 고장탐지·진단을 위해서 적용한 연구가 활발히 진행되고 있다[7-10].




그림 1. 2006년부터 2015년까지 대한민국 발전설비의 연간 비계획정지 건수[11].
 Fig. 1. The number of power plants' unplanned shutdowns in the years 2006-2015 in South Korea [11].

화력발전소의 주요설비들(ex. 증기보일러, 증기터빈, 발전기, etc.)은 매우 높은 온도와 압력의 환경에서 운전된다. 예를 들어 200 MW 유연탄 화력발전소 증기터빈의 정격속도는 약 3600rpm 이고, 발전기전압은 약 20kV이며, 증기보일러에서 생산되어 터빈으로 공급되는 주증기 압력과 온도는 약 169.8kg/cm²과 538°C이다. 이처럼 주요발전설비들이 매우 위험한 환경에서 운전되므로, 시스템의 고장은 상당한 인적·물적 손실로 이어질 수 있다. 그림 1은 발전 6사 및 민간 발전사를 포함한 발전설비의 연간 비계획정지 건수통계이다[11]. 그림 1에서의 비계획정지는, 전력설비 정지관리기준의 발전설비 불시정지에 해당한다. 연간 비계획정지 건수는 2010년에 처음으로 100건을 넘어 113건이 발생하였고, 2015년에는 166건의 고장이 발생하였다. 발전설비의 고장건수는 발전설비용량 증가, 설비 노후화 등의 원인으로 꾸준히 증가하고 있는 추세이다.

본 연구에서는, 화력발전소 증기보일러의 고장탐지를 위한 마할라노비스 거리(Mahalanobis distance, MD) 기반 방법을 제안한다. 여러 가지 거리측정(ex. Euclidean distance, etc.)을 위한 방법들 중에서 MD가 사용된 이유는, MD가 변수간 공분산의 크기에 따라 가중치를 고려하여 거리계산을 할 수 있다는 장점이 있기 때문이다. MD를 이용한 고장탐지기법은, 고장샘플이 정상샘플들로부터 멀리 떨어져 있다고 가정하며, 다변량샘플을

다변량으로 변환하여 고장탐지를 수행한다. 정상상태로 동작중인 대상시스템으로부터 수집된 학습샘플들을 이용하여 MD계산을 위한 평균벡터와 공분산행렬을 계산한다. 고장발생 유무를 판단하기 위한 MD의 문턱값은 백분위수를 이용하여 설정된다. 검증단계에서는, 새로운 검증샘플과 평균벡터간의 MD를 구한 후, 그 값이 미리 정의된 문턱값 보다 높으면 고장이 발생했다고 판단한다. MD기반의 고장탐지기법은, 대상시스템에 대한 사전지식이 필요 없고, 오직 과거의 운전이력데이터만을 필요로 한다는 장점이 있다. 학습단계에서 정상시스템의 과거데이터를 이용하여 평균벡터와 공분산행렬 만을 계산하면 되므로 구현이 간편하고, 온라인 모드로 동작 시 계산속도가 빠르다는 장점이 있다.

MD기반 고장탐지기법의 성능을 검증하기 위해서, 200MW 유연탄 화력발전소 증기보일러의 튜브누설로 인해서 비계획정지가 발생된 사례를 사용하였다. 실험결과는 제안된 방법이 비계획정지 직전의 고장을 성공적으로 탐지할 수 있음을 보여준다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는, MD를 이용한 고장탐지기법에 대해서 설명한다. 3장에서는 대상시스템인 200MW 유연탄 화력발전소에 대해서 간략히 요약하고, 4장에서는 실험결과에 대해서 논의한다. 마지막으로 5장에서는 결론 및 향후연구과제에 대해서 서술한다.

2. 마할라노비스 거리를 이용한 고장탐지

정상상태로 운전 중인 대상시스템으로부터 n 개의 m 차원 다변량 샘플 $\mathbf{x}^i = [x_1^i \dots x_m^i]^T \in R^{m \times 1}$, $i = 1, \dots, n$ 이 수집되었다고 가정하자. 즉, 정상샘플들로 구성된 학습데이터 행렬 \mathbf{X} 는 아래와 같이 준비된다.

$$\mathbf{X} = [\mathbf{x}^1 \mathbf{x}^2 \dots \mathbf{x}^n]^T = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_m^1 \\ x_1^2 & x_2^2 & \dots & x_m^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^n & x_2^n & \dots & x_m^n \end{bmatrix} \in R^{n \times m}. \quad (1)$$

평균벡터와 공분산행렬을 계산하기 전에, 먼저 행렬 \mathbf{X} 의 각 성분들에 아래와 같이 Z스코어 표준화과정[12]을 적용한다.

$$X'_{p,q} = \frac{X_{p,q} - m_q}{\sigma_q}, \quad (2)$$

여기서 $X_{p,q}$ 와 $X'_{p,q}$ 는 각각 표준화 적용 전과 후의 행렬 \mathbf{X} 의 p 번째 행 q 번째 열의 성분이고, m_q 와 σ_q 는 각각 행렬 \mathbf{X} 의 q 번째

열벡터 성분들의 평균과 표준편차이다. 표준화 과정이 적용되는 이유는, m 개 변수들의 평균과 표준편차가 서로 다르기 때문이다. 표준화 과정을 적용한 후, 평균벡터 $\bar{x} \in R^{m \times 1}$ 의 j 번째 성분 \bar{x}_j 와 공분산행렬 $S \in R^{m \times m}$ 의 p 번째 행 q 번째 열의 성분은 각각 다음과 같이 계산된다.

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_j^i, \quad j = 1, \dots, m, \quad (3)$$

$$S_{p,q} = \frac{1}{n-1} \sum_{i=1}^n (x_p^i - \bar{x}_p)(x_q^i - \bar{x}_q), \quad p, q = 1, \dots, m \quad (4)$$

임의의 샘플 x 와 \bar{x} 간의 MD는 다음과 같이 계산된다[13].

$$MD(x) = \sqrt{(x - \bar{x})^T S (x - \bar{x})} \quad (5)$$

MD의 문턱값을 설정하기 위해서, n 개의 정상샘플 $x^i, i = 1, \dots, n$ 를 이용하여 $MD(x^i)$ 를 계산한다. 본 연구에서는, 전문가의 사전지식에 의해서 계산된 $MD(x^i)$ 의 99번째 백분위수를 MD의 문턱값 T_{99th} 으로 설정하였다. 검증단계에서는, 샘플의 MD 값이 미리 정의된 T_{99th} 보다 크거나 같을 경우, 즉, $MD(x_{new}) \geq T_{99th}$ 인 경우에 알람신호가 생성된다. 그림 2는 MD를 이용한 고장탐지 절차를 보여준다.

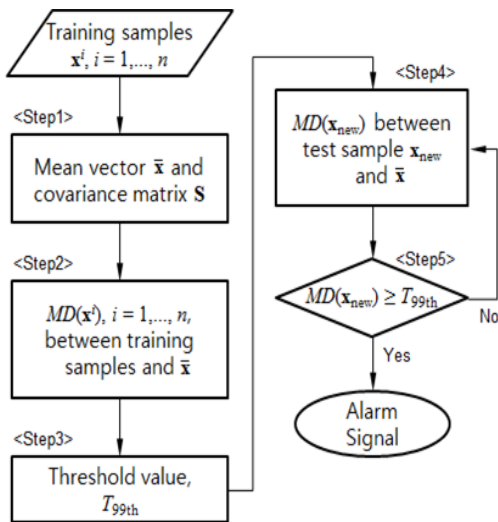


그림 2. 마할라노비스 거리를 이용한 고장탐지 절차.
Fig. 2. Mahalanobis distance based fault detection procedures.

3. 대상시스템: 200MW 유연탄 화력발전소

유연탄 화력발전소에서는, 연료로 사용되는 유연탄을 연소시켜 얻어진 열에너지를 이용하여 물을 증기로 변환시킨 후, 생성된

증기로 터빈을 회전시켜서 전기를 생산한다. 대상시스템인 증기보일러의 간략화된 계통도는 그림 3과 같다. 증기보일러는 연료를 연소시켜 발생한 열에너지로 물을 끓여서 증기를 발생시키는 장치이다. 보일러는 카르노사이클이 현실적으로 구현된 열역학 증기사이클인 랭킨사이클을 따른다 [14]. 증기는 기계적 에너지를 생성하기 위한 중요한 매체로, 풍부한 물로부터 발생시킬 수 있으며, 발전설비의 재료와 크게 반응하지 않고, 발전소에서 요구되는 온도에 안정적이다[15]. 보일러급수는 터빈으로부터의 추기에 의한, 직렬로 배치된 급수가열기와, 고온의 배기가스에 의한 절탄기에 의해서 예열된 후 드럼으로 공급된다. 이러한 예열과정은 발전소 계통 전체의 효율을 향상시킨다. 드럼의 역할은 두가지인데, 증기로 변환될 물을 공급하며, 증발기에서 만들어진 증기를 임시 저장한다. 증발기에 의해서 만들어진 포화증기는 약간의 수분을 포함하고 있는데, 과열기는 포화증기를 고온고압의 순도가 높은 과열증기로 만들어 터빈으로 공급한다.




그림 3. 유연탄 화력발전소 증기보일러의 간략화된 계통도.
Fig. 3. Simplified schematic diagram of steam boiler in thermal power plant.

3.1 보일러 튜브 누설

보일러 내부의 튜브 고장은 소리 또는 물을 운반하는 튜브의 고장을 나타내는 보충수 증가 또는 재열기와 과열기 튜브고장에 의한 과열기와 재열기의 드래프트 증가에 의해서 감지될 수 있다 [16]. 튜브 고장은 스케일링, 수벽의 부식 및 균열, 화벽의 부식 및 침식, 과열과 크리프에 의한 응력파괴, 진동 및 열 피로에 의한 균열, 용접부 결함 등의 원인 때문에 발생할 수 있다[17]. 튜브의 아주 작은 구멍에 의한 누출은 일반적으로 급수통제시스템의 적절한 여분 때문에 용인될 수 있으며, 해당 결함은 계획 정지에 의해서 시정할 수 있다. 그러나 이와 같은 상태로 보일러가 계속 가동될 경우, 결국 다량의 가압된 유체가 유출되어 근처의 튜브에도 상당한 손상이 발생할 수 있다.

4. 실험 결과

본 연구에서는, 보일러 튜브누설로 인해 비계획정지가 발생했던 사례에 MD기반의 고장탐지기법을 적용하여 성능을 검증한다. 해당 사례는 200MW 유연탄 화력발전소 DCS의 DB로부터 수집되었고, 전문가에 의해서 13개의 모니터링 변수가 튜브누설 탐지를 위해 선택되었다. 각 샘플들은 5분 간격으로 기록되었으며, 총 4045개의 샘플들 중에서, 2880개의 샘플이 학습샘플로 사용되고, 나머지 1165개의 샘플은 검증샘플로 사용된다. 학습샘플들은 평균벡터과 공분산행렬의 계산, 문턱값 설정을 위해서 사용되고, 검증샘플을 고장탐지기법의 성능검증을 위해서 사용된다. 표 1은 보일러 튜브 누설을 탐지하기 위해서, 전문가 지식에 의해서 선택된 13개의 변수이다.

표 1. 보일러 튜브 누설을 탐지하기 위한 13개의 모니터링 변수
Table 1. Summary of 13 monitored variables for leakage detection of boiler tubes.

	Description	Unit
X_1	Generator output	MW
X_2	Steam flow	t/h
X_3	Main steam pressure	kg/cm ²
X_4	Main steam temperature	°C
X_5	Reheater pressure	kg/cm ²
X_6	Reheater temperature	°C
X_7	Furnace pressure	kg/cm ²
X_8	Drum level	m
X_9	Condenser pressure	kg/cm ²
X_{10}	Condenser make-up flow	t/h
X_{11}	Feedwater flow	t/h
X_{12}	Fuel supply	t/h
X_{13}	Air supply	m ³ /h




그림 4. 학습샘플들의 MD값의 분포.
Fig. 4. Distribution of MD values of training samples.

그림 4는 학습샘플들과 평균벡터간의 $MD(x^i), i = 1, \dots, 2880$ 의 분포를 보여준다. 그림 4에서 빨간색 굵은 곡선은 히스토그램을

커널 평활화한 선이고, 빨간색 세로 점선은 $MD(x^i)$ 의 99번째 백분위수이며, 그 값은 6.9787이다. 그림 4에서 확인할 수 있듯이, 계산된 T_{99th} 의 분포는 오른쪽 꼬리가 더 긴 형태이고, 좌우 비대칭이다.

그림 5는 검증샘플들에 대해서 계산된 MD 값과 발생된 알람신호를 보여준다. 그림 5에서, 보일러 튜브누설로 인해 발전정지 된 시점은 굵은 빨간색 세로 점선으로 표시되어 있고, 학습샘플들에 의해서 계산된 문턱값 T_{99th} 는 빨간색 가로 점선으로 표시되어 있다. 대상시스템이 정상일 경우, MD 값은 문턱값 보다 작고, 그렇지 않을 경우에는 문턱값 보다 높다. 그림 5의 (b)에서 몇 번의 지속성 없는 알람이 발생하였는데, 이러한 알람은 실제 DCS에 적용될 경우, 거짓알람으로 간주되어




그림 5. 검증샘플에 대한 고장탐지 결과:
(a) MD 값 (b) 알람신호.

Fig. 5. Results of fault detection for test samples: (a) MD value (b) Alarm signal.




그림 6. 그림 5의 고장구간 1을 확대한 그림:
(a) MD 값 (b) 알람신호.

Fig. 6. Enlargement of fault region 1 in Fig. 5:(a) MD value (b) Alarm signal.

예외처리 된다. 알람신호가 집중적으로 발생하는 고장구간(Fault region)은 투명한 빨간색 영역으로 표시되어 있으며, 해당 부분을 확대한 그림은 각각 그림 6과 7이다. 첫 번째 고장구간은, 발전정지가 발생하기 약 66시간전에 해당하고, 약 3시간동안 알람신호가 집중적으로 발생하였다. 두 번째 고장구간에서는, 발전정지 바로 직전에 약 30분 동안 MD 값이 급격히 상승하여 알람신호가 발생하였다.




그림 7. 그림 5의 고장구간 2를 확대한 그림: (a) MD 값 (b) 알람신호.

Fig. 7. Enlargement of fault region 2 in Fig. 5: (a) MD value (b) Alarm signal.




그림 8. 고장구간 1에 해당하는 고장샘플 (X축: 증기유량, Y축: 주증기압력).

Fig. 8. Fault samples in fault region 1 (X axis: steam flow, Y axis: main steam pressure).




그림 9. 고장구간 2에 해당하는 고장샘플 (X축: 복수기보충수유량, Y축: 증기유량).

Fig. 9. Fault samples in fault region 2 (X axis: condenser make-up flow, Y axis: steam flow).

그림 8과 9는 그림 5의 고장구간 1과 2에 해당하는 고장샘플들을 각각 2차원 공간에서 보여준다. 그림 8과 9에서, 검은색 원은 학습샘플들을 나타내고, 빨간색 원은 고장구간의 고장샘플에 해당한다. 그림 8로부터, 고장구간 1은 증기유량이 정상적인 범위(570-640t/h)보다 높아서 알람신호가 발생한 구간임을 알 수 있다. 그림 9에서는, 복수기 보충수 유량이 급증하여 알람신호가 발생했음을 확인할 수 있다. 고장구간 2는 잠재적인 장애가 발생하기 이전의 사전징후구간에 해당한다.

4. 결론 및 향후연구과제

본 논문에서는, 화력발전소 증기보일러 튜브누설을 탐지하기 위해서 MD 기반의 고장탐지방법을 사용하였다. 정상샘플을 이용하여 평균벡터와 공분산행렬을 계산하고, 고장발생여부를 판단하기위한 문턱값을 설정하였다. 검증단계에서는, 새로운 샘플과 평균벡터간의 MD를 계산한 후, 그 값이 미리 계산된 문턱값보다 크거나 같으면 고장이 발생했다고 간주하고 알람신호가 발생하게 된다. 사용된 방법은 구현이 간단하고, 온라인 모드로 동작 시 속도가 빠르다는 장점이 있기 때문에, 센서단계에서의 의사결정이 요구되는 환경에서도 사용되기에 적합하다. 성능검증을 위해서, 200MW 유연탄 화력발전소에서 수집된, 보일러 튜브누설로 인해서 발전정지 된 사례를 사용하였다. 실험결과는 MD 기반의 고장탐지방법이 비계획정지가 발생하기 직전의 이상징후를 성공적으로 사전탐지 할 수 있음을 보여준다.

본 연구에서는, 공정 모니터링 절차 중에서, 고장탐지단계만을 고려하였다. 향후과제는 고장과 관련된 변수를 식별하거나 고장유형을 확인할 수 있는 단계까지 제안된 방법을 확장하는 것이다. 또한 다양한 발전정지사례를 수집하여 성능을 검증하고, 실제 DCS에 현장적용 가능성을 검토할 예정이다.

References

- [1] K. Y. Chen, L. S. Chen, M. C. Chen and C. L. Lee, "Using SVM based method for equipment fault detection in a thermal power plant," *Comput. in Ind.*, vol. 62, no. 1, pp. 42-50, Jan. 2011.
- [2] F. Li, B. R. Upadhyaya and L. A. Coffey, "Model-based monitoring and fault diagnosis of fossil power plant process units using group method of data handling," *ISA Trans.*, vol. 48, no. 2, pp. 213-219, Apr. 2009.
- [3] Y. G. Kim and H. J. Choi, "Design of Intelligent State Diagnosis

System for TMS Using Neuro-Fuzzy,” *Journal of the Korean Institute of Intelligent Systems*, vol. 11, no. 8, pp. 695-700, Dec. 2001.

[4] Y. H. Cho, S. W. Ryu and K. G. Ahn, “A System Development for Remotely Controlling Windows and Doors in Mobile Environment,” *Journal of the Korean Institute of Intelligent Systems*, vol. 25, no. 4, pp. 334-341, Aug. 2015.

[5] S. W. Kwak and J. M. Yang, “Fault Diagnosis and Tolerance for Asynchronous Counters with Critical Races Caused by Total Ionizing Dose in Space,” *Journal of the Korean Institute of Intelligent Systems*, vol. 22, no. 1, pp. 49-55, Feb. 2012.

[6] S. H. Yoo, “A Fault Detection System Design for Boiler-Turbine Control System of Thermal Power Plant,” *Journal of the Korean Institute of Intelligent Systems*, vol. 25, no. 6, pp. 615-620, Dec. 2015.

[7] X. Wang, L. Ma and T. Wang, “An optimized nearest prototype classifier for power plant fault diagnosis using hybrid particle swarm optimization algorithm,” *Int. J. of Elect. Power & Energy Syst.*, vol. 58, pp. 257-265, Jun. 2014.

[8] K. Rostek, Ł. Morytko and A. Jankowska, “Early detection and prediction of leaks in fluidized-bed boilers using artificial neural networks,” *Energy*, vol. 89, pp. 914-923, Sep. 2015.

[9] F. Di Maio, P. Baraldi and E. Zio, “Fault detection in nuclear power plants components by a combination of statistical methods,” *IEEE Trans. Reliab.*, vol. 62, no. 4, pp. 833-845, Oct. 2013.

[10] M. Fasta and T. Palmé, “Application of artificial neural networks to the condition monitoring and diagnosis of a combined heat and power plant,” *Energy*, vol. 35, no. 2, pp. 1114-1120, Feb. 2010.

[11] Korea Power Exchange, “Statistics of power plants' unscheduled shutdowns,” Available: <http://www.kpx.or.kr/www/selectBbsNttList.do?key=21&bbsNo=152>, March 11, 2016, [Accessed: May 3, 2016]

[12] D. T. Larose, *Discovering knowledge in data: an introduction to data mining*, John Wiley & Sons, 2005.

[13] J. Han, M. Kamber and J. Pei, *Data mining: concepts and techniques*, Elsevier, 2011.

[14] D. Flynn, *Thermal power plant simulation and control*, IET, 2003.


[15] A. K. Raja, *Power plant engineering*, New Age Int., 2006.

[16] D. Sarkar, *Thermal power plant design and operation*, Elsevier,

2015.

[17] J. E. Oakey, *Power plant life management and performance improvement*, Elsevier, 2011.

저 자 소 개



유정원(Jungwon Yu)

2012년 : 부산대학교 전자전기공학부 공학사
 2014년 : 부산대학교 공과대학
 전자전기컴퓨터공학과 공학석사
 2014년~현재 : 부산대학교 대학원
 전자전기컴퓨터공학과
 박사과정

관심분야 : Fault Detection, Diagnosis and Prognosis
 Phone : +82-51-510-2367
 E-mail : garden0312@pusan.ac.kr



장재열(Jaeyel Jang)

2003년 : 한서대학교 컴퓨터정보학과 학사
 2013년 : 고려대학교 정보보호대학원 석사
 ~현재 : 한국동서발전 기술정보처
 기술전문센터 차장

관심분야 : 다변수제어, Big Data Analysis
 Phone : +82-70-5000-8037
 E-mail : zanggre250@ewp.co.kr



유재영(Jaeyeong Yoo)

1982년 : 연세대학교 전기공학과 공학사
 1983년~1991년 : LS산전(주) 선임연구원
 ~현재 : (주)지오네트 부사장

관심분야 : Process Controller Design, Fault Diagnosis
 Phone : +82-70-4360-9802
 E-mail : joeyoo@xeonet.co.kr



김성신(Sungshin Kim)

1986년 : 연세대학교 전기공학과 공학석사

1996년 : Georgia Inst. of Technology, 전기 및
컴퓨터공학부 공학박사

1998년~현재 : 부산대학교 전기컴퓨터공학부
교수

관심분야 : Intelligent System, Intelligent Robot, Fault Diagnosis and
Prediction

Phone : +82-51-510-2374

E-mail : sskim@pusan.ac.kr