

# 데이터마이닝 기법을 이용한 신경망 기반의 화력발전소 보일러 튜브 누설 고장 진단에 관한 연구

## A Study on Fault Diagnosis of Boiler Tube Leakage based on Neural Network using Data Mining Technique in the Thermal Power Plant

김 규 한\* · 이 흥 석\* · 정 희 명\* · 김 형 수\*\* · 박 준 호†

(Kyu-Han Kim · Heung-Seok Lee · Hee-Myung Jeong · Hyung-Su Kim · June-Ho Park)

**Abstract** - In this paper, we propose a fault detection model based on multi-layer neural network using data mining technique for faults due to boiler tube leakage in a thermal power plant. Major measurement data related to faults are analyzed using statistical methods. Based on the analysis results, the number of input data of the proposed fault detection model is simplified. Then, each input data is clustering with normal data and fault data by applying K-Means algorithm, which is one of the data mining techniques. fault data were trained by the neural network and tested fault detection for boiler tube leakage fault.

**Key Words** : Fault detection, Multi-layer neural network, K-Means algorithm

### 1. 서 론

우리나라의 화력발전소들은 급격한 산업화가 진행된 1980년에서 1990년 초반에 대부분 건설되었다. 발전소 설계 수명은 대략 30년 정도로 설계 수명 이후에는 설비 및 주요부품들의 노후화 및 열화 현상이 급격하게 진행되고 있다. 이로 인해 최근 발전소 고장이 과거에 비해 많이 발생하고 있고, 계속 증가할 것으로 예상된다. 2014년 전력거래소 발전소 고장통계 보고서를 참고하면, 2010년 발전소고장건수가 100건을 넘었고, 2013년에는 238건의 고장이 발생하였다. 이는 대단히 많은 경제적 손실과 사회적 비용을 발생시킬 뿐만 아니라 발전소의 안전성에도 많은 악영향을 줄 수 있다. 이러한 부정적인 영향을 감소시키고, 예방하기 위해서, 발전소 고장에 대한 많은 연구가 필요하며, 국내외에서 발전소 고장관련 연구가 꾸준히 진행되고 있다.

국내 발전소 고장진단관련 연구는 원자력발전소를 대상으로 대부분 연구가 이루어졌다. 그리고 1990년대부터 2000년 초반 신경망을 이용한 고장진단 관련 연구가 간간히 이루어 졌고, 그 후 국내에서는 발전소 고장관련 연구가 거의 이루어지지 않았다. 최근 딥 러닝을 이용한 인공지능 관련 연구가 진보적인 성과를 보이면서, 다시 인공지능관련 연구가 다양한 산업분야에서 진행되

고 있다. 발전소와 같이 대규모 산업시스템을 구축하고 있는 시설에서 많은 공정들이 자동화된 시스템을 안정적으로 운영하고 관리하기 위해서는 시스템의 상태를 감시하고 점검할 수 있는 관련 데이터들과 정보를 정확하게 분석하고 처리하는 것은 매우 중요하다. 기존 모델기반의 고장진단방법들은 대상시스템의 상태 추정 또는 파라미터 추정을 바탕으로 시스템 해석을 위한 수학적 모델링을 기초로 하고 있다. 상태추정을 이용한 시스템 모델링 방법으로는 parity checking, kalman filter observer를 이용한 verification of innovation, error detection filter 접근법 등이 있지만 상태추정 접근법의 경우[7], 복잡한 시스템의 상태진단에서 정확한 시스템모델링이 어렵다는 단점이 있다. 반면, 파라미터 추정에 의한 접근법은 상태추정 방법과 비교하여[7, 8], 상대적으로 적용이 간단하고, 대상시스템 및 제어기의 고장분류 및 진단 문제에 직접 적용이 가능하다는 장점이 있다. 그러나 파라미터 추정 방법에서 추정된 파라미터를 이용한 모델 파라미터와 물리적 파라미터의 관계로부터 물리적 파라미터의 변화를 계산하여 대상시스템의 고장종류를 판별하는 방법은[9] 추정된 모델 파라미터와 물리적 파라미터의 관계가 비선형성을 가지기 때문에 두 파라미터의 관계정립을 명확하게 할 수 없다는 문제점이 있다. 또 다른 파라미터 추정법에 근거한 고장진단 연구에서는 미리 대상시스템의 고장모델과 추정모델을 비교하여, 추정된 모델파라미터의 패턴인식을 시스템 고장분류를 위해 사용하였다.[10] 추정 파라미터와 다층신경망을 이용하여 시스템 고장분류를 하는 방법[11]은 발생 가능한 대상시스템의 모든 고장을 모델링하기가 현실적으로 어렵고, 예상하기 어려운 고장을 분류할 수 있는 추가적인 연구가 필요하다.

A. Srinivasan과 국내의 이인수 등은 다층신경망을 이용한 선

† Corresponding Author : Dept. of Electrical and Computer Engineering, Pusan National University, Korea.  
E-mail: parkjh@pusan.ac.kr

\* Dept. of Electrical and Computer Engineering, Pusan National University, Korea.

\*\* Dept. of Electricity, Gyeongnam Nambae University, Korea.

Received : May 11, 2017; Accepted : Augsut 18, 2017

형시스템의 고장진단을 연구하였다.[12, 13] 여기에서는 hopfield 신경망을 이용하여 대상시스템의 파라미터를 추정하고 이를 자율 학습 신경망인 ART1 신경망과 ART2 신경망으로 고장진단시스템을 구현하였다. 그러나 대다수 대형시스템의 파라미터들은 비선형성을 가지며, 제약된 조건에서 시스템파라미터들이 선형성을 가지는 경우에 한해서만 고장분류가 가능하다는 문제점을 가지며, 고장진단 및 분류를 위한 추정된 파라미터들이 각각의 고장 사례 대한 고장의 연관성과 정보를 가지고 있다는 근거가 부족하다.

본 논문에서는 현재 운영중인 화력발전소에서 발생했던 보일러 튜브 누설로 인한 고장 사례들에 대한 주요설비 및 부품들에서 측정된 많은 계측데이터들에 대하여, 고장에 대한 정보를 추출하기 위해서 통계학적인 방법들을 이용하여 데이터를 분석하였다. 발전소 주요설비중 하나인 보일러는 고온 고압의 증기를 만들어, 튜브를 통해 터빈에 증기를 공급한다. 화력발전소에서 보일러관련 고장 중에 튜브 누설 고장이 제일 많이 발생하며, 각 데이터들의 상관관계분석 결과를 바탕으로, 본 논문에서 제안한 신경회로망 기반의 고장 검출 모델의 입력데이터의 수를 감소시켰다. 그리고 각 데이터들을 데이터마이닝의 분류기법 중 하나인 K-Means 알고리즘을 이용하여, 정상상태데이터와 이상상태데이터로 분류함으로써 데이터 기반의 분류가 되도록 하였다. 분류된 데이터 그룹을 이용하여 신경망기반의 보일러 튜브 누설고장 검출 모델을 학습하였고, 다른 시점에서의 보일러 튜브 누설 고장진단에 적용하여 고장발생 이전에 사전고장예측의 가능성을 검토하였다. 이를 바탕으로 본 논문에서 제안한 신경망 기반의 고장 검출모델이 보일러 튜브 누설 고장검출에 적용하여 그 유용성을 확인하였다.

## 2. 본 론

### 2.1 화력발전소의 보일러 및 보일러튜브고장

일반적으로 화력발전소는 석유, 석탄, 가스와 같은 화석연료를 태워서 나온 열로 보일러에서 물을 끓여 고온 고압의 증기를 만든 다음 그 증기를 프로펠러 형상을 한 터빈을 통과시켜 고속의 회전력을 얻은 후 같은 축에 연결된 발전기를 회전시킴으로써 전기를 생산한다. 발전소에서 사용하고 있는 보일러는 물을 가열하여 증기를 만들어 증기가 가지고 있는 열에너지를 터빈에 전달함으로써 터빈의 기계적 에너지로 변환시키는 역할을 하는 중요한 설비이다. 따라서 동시에 다량의 물을 가열해야 하기 때문에 수많은 튜브로 이루어져 있으며, 수냉벽 튜브, 과열기 튜브, 재열기 튜브군으로 구분되어 있다. 이러한 보일러 튜브들은 외면에 흐르는 고온 연소가스의 연소열과 내면에 흐르는 물에 의해 손상이 된다. 연소가스는 1500℃ 이상의 고온으로 황, 바나듐 등의 부식성 가스와 회입자가 포함되어 있어 튜브 외면부식 및 마모 등을 야기시켜서 튜브를 손상시키고 또한, 내면에 흐르는 물에는 부식성 물질과 불순물이 용해되어 있어 증기로의 상태변화 과정에서 석출되어 튜브 벽면에 부착되고 부식을 일으키는 물은 금속온도

를 상승시켜 결국 튜브를 손상시키는 사고의 원인이 되고 있다. 아래의 그림 1은 일반적으로 화력발전소에서 사용되는 관류형 보일러의 구조를 나타내고 있다.[15]




그림 1 일반적인 석탄화력발전소의 보일러 구조

Fig. 1 Typical boiler structure in coal fired power plant

### 2.2 발전소 주요계측데이터의 상관관계분석

본 논문에서는 화력발전소에서 서로 다른 시점에 발생한 보일러 튜브누설로 인한 발전소 고장사례들에 대하여, 계측된 주요센서 데이터들을 분석하였다. 우선 수많은 발전소 계측 데이터들 중에 보일러 튜브 누설 고장과 연관성이 있는 요인(parameter)을 발전소 운영자들이 전문적인 지식과 오랜 경험을 바탕으로 하여 선택하였다. 선택된 요인, 즉 변수들에 대한 상관관계 분석을 통하여, 본 논문에서 제안한 신경망기반의 고장 검출 모델의 최종적인 입력데이터를 선정하여 사용하였다. 상관관계분석은 변수 간의 관계가 얼마나 밀접한지의 정도를 분석하는 통계적인 분산분석 방법이며, 변수들 간의 상관관계를 이용하여 변수를 축약하거나 분류하는데 사용될 수 있다. 일반적으로 두 변수 사이의 상관관계의 정도를 나타내는 값을 상관계수라고 하며, -1과 1사이의 값을 가지며, 상관계수 값이 절대값으로 1에 가까울수록 두 변수 간의 관계가 밀접하다는 것을 의미한다. 아래의 식은 두 변수  $x, y$  사이의 상관계수 계산식을 나타낸 것이다.

$$r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

여기서,  $\bar{x}, \bar{y}$  : 각각  $x, y$ 의 평균값,  $n$  : 데이터 수

표 1은 우리나라 동해2호기 화력발전소에서 보일러 튜브 누설에 인한 발전소 고장이 발생했던 시점에 운영자들이 확인하는 주요계측 변수들이다. 총 변수의 개수는 13개이며, 각 변수의 데이터들은 상관관계 분석을 통해서, 최종적으로 고장 검출을 위한 다중신경망 모델의 입력 변수로 정해진다. 13개의 변수들은 보일러 튜브 누설 고장에 대한 독립 변수들로, 변수들 간 사이에 높은 선형 관계가 존재하는 현상이 발생할 수 있는데, 이 현상을

다중 공선성(Multicollinearity)이라고 한다. 다중 공선성 현상은 높은 상관관계를 보이는 하나의 변수가 관련 시스템이나 모델에 투입될 경우, 나머지 변수들이 갖는 고유한 영향력이 매우 작아질 수 있는 것을 의미한다. 이는 독립 변수가 종속 변수에 미치는 동적인 영향력을 제대로 반영하지 못하는 결과를 초래하게 된다. 다중 공선성 현상의 발생을 방지하기 위하여 미리 변수들 간의 상관 계수를 파악하여 상관관계가 높은 변수들 중 하나 혹은 일부를 제거하거나, 상관관계가 높은 변수들 중 가장 높은 영향력이 있는 독립 변수만을 시스템이나 모델에 적용해야만 한다.

표 1 고장검출을 위한 사용하는 주요 요인

Table 1 Principal parameters for the fault detection

| 데이터                                       | 단위                 |
|-------------------------------------------|--------------------|
| 발전기 출력 (Electric Power of Generation)     | MW                 |
| 주증기 유량 (Main Steam Flow)                  | t/h                |
| 주증기 압력 (Main Steam Pressure)              | kg/cm <sup>2</sup> |
| 주증기 온도 (Main Steam Temperature)           | ℃                  |
| 재열기 압력 (Reheater Pressure)                | kg/cm <sup>2</sup> |
| 재열기 온도 (Reheater Temperature)             | ℃                  |
| 노내 압력 (Furnace Pressure)                  | kg/cm <sup>2</sup> |
| 드럼레벨 (Boiler drum level)                  | m                  |
| 복수기 압력 (Condenser Pressure)               | kg/cm <sup>2</sup> |
| 복수기 보충수 유량 (Condenser Make-up Water Flow) | t/h                |
| 급수 유량 (Feed Water Flow)                   | t/h                |
| 연료량 (Fuel Supply)                         | t/h                |
| 공기량 (Air Supply)                          | m <sup>3</sup>     |

### 2.3. K-Mean 알고리즘을 적용한 신경망기반의 고장 검출 모델

#### 2.3.1. 고장데이터 분류를 위한 K-Means 알고리즘

K-평균(K-Means) 알고리즘은 기계학습(머신러닝, Machine learning) 또는 데이터마이닝에서 주로 활용되고 있는 기법으로서, 전체 데이터를 몇 개의 집단으로 그룹화하여 각 집단의 성격을 파악함으로써 데이터 전체의 구조에 대한 이해를 돕고자 하는 분석법으로 이용된다. 이 알고리즘은 데이터를 특정한 K개의 cluster로 분할하는데, cluster내 유사성은 크게 하고, cluster 간 유사성은 작게 분류를 하는 것이 목적이다. K-Means 알고리즘 구현 방법은 아래의 다음과 같다.

1. K값, 즉 만들어질 전체 클러스터의 개수를 정한다.
2. 데이터 집합에서 무작위(random)로 K개의 인스턴스를 선택하여 그것을 K개의 클러스터의 초기 센터(평균)으로 정한다.
3. 나머지 인스턴스들은 Euclidean distance를 사용하여 각자 가장 가까운 중심값을 가진 클러스터에 배정된다.
4. 각 클러스터마다 그 안에 배정된 모든 인스턴스의 평균값을 구하여 그것을 그 클러스터에 대한 새로운 중심값으로 정한다.
5. 만약 그 새로운 중심값들이 이전 iteration의 중심값들과 일치하면 알고리즘을 끝낸다. 그렇지 않으면, 새로운 중심값으로 단계 3번에서 5번까지 반복한다.

본 논문에서는 화력발전소에서 발생한 보일러 튜브 누설로 인한 발전소 고장사례들에 대하여, 계속된 13개의 주요센서 데이터들을 분석하였다. 이 데이터들은 발전소가 일정한 출력으로 정상 운전 중에 고장이 발생한 시점까지의 데이터로 센서들에 의해 5

분마다 측정되는 값들이며, 하루동안 각 데이터들은 288개의 시계열 측정값들로 구성된다. 그리고 최종적으로 다층신경망기반의 고장 검출 모델에 적용할 10개의 입력 변수들은 정상운전구간을 포함한 고장전까지의 측정된 센서데이터들이며, 데이터마이닝의 분류기법 중 하나인 K-Mean 알고리즘을 이용하여, 각 데이터들을 2개의 그룹으로 군집화(clustering)를 시행하였다. 각 데이터들은 두 집단으로 분류가 되고, 두 그룹의 평균값과 분산값을 기반으로, 정상상태데이터와 이상상태데이터로 분류된 두 집단의 데이터들을 분석한다. 본 논문에서 고장검출을 위한 신경망에 사용될 입력변수들은 모두 두 그룹으로 나누어져 있으며, 분류된 이상상태데이터 그룹은 고장에 대한 정보를 가지고 있어야 한다. 그리고 정상상태데이터 그룹 또한 발전소 정상운전상태에 대한 정보를 가지고 있어야만 한다.

#### 2.3.2. 통계학적 기법을 이용한 분류된 정상상태데이터 그룹과 이상상태데이터 그룹의 판단

K-Means 알고리즘을 이용하여, 각 데이터들이 2개의 그룹으로 나누어진 결과가 정상상태데이터 그룹과 이상상태데이터 그룹으로 분류가 되었는지를 검토해 볼 필요가 있다. 그래서 두 그룹에 대하여 통계학적 기법중 하나인 가설검정을 이용하여 두 그룹의 이질성을 확인해 본다. 가설검정에서 가장 기본적인 사항은 검정하고자 하는 모집단의 모수에 대해 가설을 설정하는 것이다. 가설은 항상 귀무가설(null hypothesis ;  $H_0$ )과 대립가설(alternative hypothesis ;  $H_1$ ) 이 2가지로 설정한다. 가설검정은 표본관찰 또는 실험을 통해 귀무가설( $H_0$ )과 대립가설( $H_1$ )중 하나를 선택하는 과정이라 할 수 있다. 두 가설은 각각의 경우에 따라 결정되는데, 모수에 대한 가설 중 ‘항상 간단하고 구체적인 표현’을 귀무가설로 설정한다. 본 논문에서는 10개의 신경망 입력 데이터들은 각각 2개의 그룹으로 분류가 되어 있고, 모든 입력데이터들은 정상상태데이터와 이상상태데이터 집단이 서로 다르다는 것을 가설검정을 통해 확인한다. 일반적으로 두 집단의 동일성에 대한 가설검정에서 두 집단은 서로 독립이며, 두 집단 모두 정규분포를 따른다는 이 2가지 조건을 전제조건으로 검정을 시행한다.

2011년 동해2호기의 복수기 보충수 유량 데이터에 대한 K-Means 알고리즘으로 인한 결과를 가설검정으로 확인 해 본다. 귀무가설은 “분류된 정상상태데이터의 모집단 평균값( $\mu_1$ )과 이상상태데이터 모집단의 평균값( $\mu_2$ )은 동일하다.” 선정하고, 대립가설은 “이상상태데이터의 모집단 평균값( $\mu_1$ )과 이상상태데이터의 모집단의 평균값( $\mu_2$ )은 서로 다르다.”로 선정된다.

$$H_0 : \mu_1 = \mu_2$$

$$H_1 : \mu_1 \neq \mu_2$$

주어진 가설검정에 대해서 두 표본의 모분산은 동일하다고 가정한다. 그리고 표본관찰을 통해 검정에 필요한 통계량을 구해야 한다. 이와 같이 검정에 이용되는 통계량을 검정통계량 (Test statistic ;  $T(X)$ )이라고 하고, 검정통계량 분포는 항상

가설에서 주어지는 모수가 갖는 분포를 따른다. 귀무가설이 옳다는 전제 하에 표본관찰에 의해 구한 검정통계량의 값이 나타날 가능성이 크면, 귀무가설을 채택하고, 나타날 가능성이 작으면 귀무가설을 기각한다. 여기에서 가능성이 크다 또는 작다의 판단기준을 유의수준 (*Significance level*;  $\alpha$ )이라 한다. 유의수준  $\alpha$ 는 귀무가설이 옳은데도 불구하고 이를 기각하는 확률의 크기를 의미하며, 검정통계량을 구하는 것과는 무관하게 검정을 실시하는 사람의 판단에 따라 결정한다. 일반적으로 1%, 5%, 10% 등의 값을 사용한다.

기각역 (*Critical region*;  $C$ )이란 귀무가설이 옳다는 전제 하에서 구한 검정통계량의 분포에서 확률이 유의수준  $\alpha$ 인 부분을 말한다. 검정통계량의 분포에서 이 영역의 위치는 대립가설에 형태에 따라 다르며, 기각역  $C$ 와 유의수준  $\alpha$ 의 관계에서 귀무가설이 옳다는 전제 하에 검정통계량이 기각역에 속할 확률이 유의수준  $\alpha$ 인 영역이다.

$$T(X) = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad (2)$$

위 식 (2)는 검정통계량값을 나타낸 것이며,  $\bar{X}_1, \bar{X}_2$ 는 두 표본 집단의 평균값,  $\mu_1, \mu_2$ 는 귀무가설에서 모집단의 주어진 평균값을 의미한다.  $\sigma_1^2, \sigma_2^2$ 는 모집단의 분산,  $n_1, n_2$ 는 두 집단의 표본개수이다.

$$S_p^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{(n_1 - 1) + (n_2 - 1)} = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2} \quad (3)$$

두 집단의 표본의 분산을  $S_1^2, S_2^2$ 이라고 하면, 두 집단의 표본의 분산값은 두 집단의 모분산값의 추정량이 된다. 따라서 두 집단의 모분산값은 동일한 값  $\sigma^2$ 으로 나타내고,  $\sigma^2$ 의 추정량을  $S_p^2$ 이라 할 때,  $S_p^2$ 은 위의 식 (3)과 같이  $S_1^2$ 과  $S_2^2$ 의 가중평균을 이용하여 구한다. 본 논문에서는 신경망의 입력변수들이 정상상태데이터 집단과 이상상태데이터 집단으로 나누어져 있고, 두 집단이 서로 다르다는 것을 확인하기 위해서 가설검정을 이용하여, 두 집단의 동일성 여부를 판단한다. 분류된 두 집단의 모분산이 동일하다고 이미 가정하였고, 식 (2)에서  $\sigma$ 의 추정량  $S_p = \sqrt{S_p^2}$ 을  $\sigma$ 에 대입하면,  $T(X)$ 는 아래의 식과 같다.

$$T(X) = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{S_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (4)$$

그림 2는 복수기 보충수 유량의 가설검정을 위한 검정통계량의 t 분포곡선을 나타낸 것이다. 유의 수준 5% 이하에서 양측검정에 대한 t분포의 기각역은 검정색 음영 부분이며, 검정통계량 값  $T(X)$ 이 귀무가설을 기각할 수 있는 영역안에 있으므로, “복수

기 보충수 유량의 정상상태데이터 집단과 이상상태데이터 집단이 동일하다”라는 귀무가설은 기각될 수 있다. 즉, K-Means 알고리즘으로 분류된 두 집단은 서로 다르다는 것을 의미한다. 따라서 복수기 보충수 유량의 경우, 구해진 검정통계량 값과 귀무가설의 기각역을 바탕으로 정상상태데이터 집단과 이상상태데이터집단으로 분류된 결과는 신뢰성을 가진다는 것을 가설검정으로 확인할 수 있다.




그림 2 복수기 보충수 유량의 두 집단의 동일성에 대한 가설검정을 위한 t 분포 곡선

Fig. 2 t distribution curves for hypothesis test for the equality of two groups of condenser make-up water flow

### 2.3.3 고장검출을 위한 다층신경회로망 모델링

그림 3은 본 논문에서 보일러 튜브 누설 고장검출을 위한 다층신경망 모델을 나타낸 것으로, 입력뉴런 10개, 1층의 은닉층을 가지고 있으며, 출력뉴런 또한 1개로 구성되어 있다.




그림 3 보일러튜브누설 고장진단을 위한 다층신경회로망의 구성  
Fig. 3 Structure of multilayer neural network for boiler tube leakage fault detection

출력층이  $(c + 1)$ 개, 은닉층이  $(h + 1)$ 개, 입력층이 1개의 뉴런으로 구성된 일반적인 다층신경망의  $k$ 번째 뉴런의 출력( $z_k$ )은 다음과 같다.

$$z_k = f_2 \left( \sum_{j=1}^h w_{kj} f_1 \left( \sum_{i=1}^d v_{ji} + v_{j0} \right) \right) \equiv f_2(N_k) \quad (5)$$

여기서,  $N_k = \sum_{j=1}^h w_{kj}y_j + w_{k0}$ 이다

그리고,

$$y_j = f_1\left(\sum_{i=1}^d v_{ji}x_i + v_{j0}\right) \equiv f_1(M_j) \quad (6)$$

$$M_j = \sum_{i=1}^d v_{ji}x_i + v_{j0}$$

로 정의된다.

식 (5)에서  $Kf_1$ 과  $f_2$ 는 각각 입력층-은닉층과 은닉층-출력층 관계를 표현한 전달함수(transfer function)를 나타낸다. 출력층  $z_k$ 와 원하는 출력 즉 목표값  $t_k$  사이의 각각의 패턴에 대한 오차함수  $J(V, W)$ 는 식 (7)과 같다.

$$J(V, W) = \frac{1}{2} \sum_{k=1}^c e_k^2 = \frac{1}{2} \sum_{k=1}^c (t_k - z_k)^2 \quad (7)$$

최소 평균 제곱(least mean square) 방법을 이용하여, 오차함수  $J(V, W)$ 를 최소로 하는 연결강도를 구한다. 역전파학습규칙(back propagation learning rule)은 식 (8)과 같이 기울기 강하(gradient descent)에 기반으로 하고 있다.

$$\Delta W = -\eta \frac{\partial J}{\partial W} \quad (8)$$

그리고 출력층과 은닉층간의 연결강도의 변화량  $\Delta w_{kj}$ 는 식 (8)을 기반으로 하여 식 (9)으로 유도된다.

$$\Delta w_{kj} = -\eta \frac{\partial J}{\partial w_{kj}} = \eta \frac{\partial J}{\partial N_k} \frac{\partial N_k}{\partial w_{kj}} = -\eta \delta_k \frac{\partial N_k}{\partial w_{kj}} \quad (9)$$

여기서,  $\delta_k$ 는 식 (10)과 같이 나타낸다.

$$\delta_k = -\frac{\partial J}{\partial N_k} = -\frac{\partial J}{\partial z_k} \frac{\partial z_k}{\partial N_k} = (t_k - z_k) f_2'(N_k) \quad (10)$$

따라서 출력층과 k번째 데이터에 대한 연결강도의 변화량  $\Delta w_{kj}$ 는 식 (11)로 표현된다.

$$\Delta w_{kj} = \eta(t_k - z_k) f_2'(N_k) y_j = \eta \delta_k y_j \quad (11)$$

입력층과 은닉층간의 연결강도 변화량  $\Delta v_{ji}$ 도  $\Delta w_{kj}$ 와 비슷하게 다음과 같이 표현된다. 위의과정을 반복하면 식 (12)와 유사한 형태로 나타낼 수 있다.

$$\Delta v_{ji} = \eta \left[ \sum_{k=1}^c w_{kj} \delta_k \right] f_1'(M_j) = \eta \delta_j x_i \quad (12)$$

여기서,  $\delta_j = f_1'(M_j) \sum_{k=1}^c \delta_k w_{kj}$ 이다.

이와 같이 각 노드간 연결강도의 변화량을 구할 수 있고 이로 인해 매번 연결강도의 갱신으로 학습이 가능하다.[4]

## 2.4 보일러 튜브 누설 고장검출을 위한 시뮬레이션 결과

화력발전소의 주요데이터는 센서들에 의해 5분마다 측정되는 값들이며, K-Means 알고리즘에 사용된 데이터들은 고장시점에서 하루전까지의 데이터를 사용하였다. 각 변수의 데이터갯수는 288개이며, 각 데이터들은 K-Means 알고리즘에 의해 2개의 그룹으로 clustering이 되었다. 각각의 데이터들이 고장에 대한 영향력 유무판단을 위해서 두 집단의 중심점의 차이와 각 그룹의 정규분포 특성을 이용하였다. 이를 바탕으로 발전소에서 고장이 발생한 시점별로 하루전의 데이터에 대해 학습패턴을 구성하여 신경망 기반의 모델을 학습하였다. 특정 시점에 학습된 모델을 이용하여 다른 시점에서의 고장 사례에 대해 적용해 보므로써 보일러 누설고장에 대한 고장검출 가능성을 확인하였다. 그림 4는 K-Means 알고리즘을 적용한 다층신경회로망으로 발전소고장 검출과정을 간략하게 나타낸 순서도이다. 그리고 각 단계별 사례 결과를 아래의 표 2부터 표 5까지 나타내었으며, 고장 검출 결과를 아래의 그림 5, 6으로 보여준다.

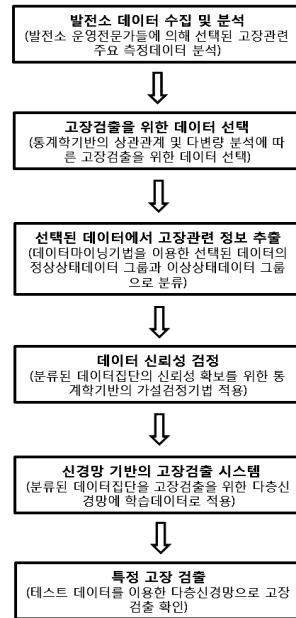


그림 4 K-Means 알고리즘을 적용한 신경망기반의 발전소 고장 검출과정

Fig. 4 The neural network based fault detection process applying K-Means algorithm

첫 번째로 발전소 데이터 수집 및 분석과 고장검출을 위한 데이터 선택단계의 사례로, 표 2는 2011년 보일러 튜브 누설에 인



표 2 보일러 튜브 누설 고장 관련 주요 요인간의 상관계수

Table 2 Coefficient of correlation with principal parameters for the fault detection

|            | 발전기 출력   | 주중기 유량   | 주중기 압력   | 주중기 온도   | 재열기 압력   | 재열기 온도   | 노내압력     | 드럼레벨     | 복수기 압력   | 복수기 보충수 유량 | 급수유량    | 연료량     | 공기량 |
|------------|----------|----------|----------|----------|----------|----------|----------|----------|----------|------------|---------|---------|-----|
| 발전기 출력     | 1        |          |          |          |          |          |          |          |          |            |         |         |     |
| 주중기 유량     | 0.89453  | 1        |          |          |          |          |          |          |          |            |         |         |     |
| 주중기 압력     | -0.35800 | -0.48179 | 1        |          |          |          |          |          |          |            |         |         |     |
| 주중기 온도     | -0.14691 | -0.19588 | 0.17524  | 1        |          |          |          |          |          |            |         |         |     |
| 재열기 압력     | 0.88941  | 0.95912  | -0.41772 | -0.27415 | 1        |          |          |          |          |            |         |         |     |
| 재열기 온도     | -0.05091 | -0.20490 | 0.14846  | 0.17489  | -0.27950 | 1        |          |          |          |            |         |         |     |
| 노내 압력      | -0.01269 | -0.02319 | 0.10069  | 0.01257  | -0.01857 | -0.02442 | 1        |          |          |            |         |         |     |
| 드럼레벨       | -0.20163 | -0.16274 | -0.19556 | -0.03768 | -0.14331 | 0.01273  | -0.06883 | 1        |          |            |         |         |     |
| 복수기 압력     | 0.06376  | 0.35150  | -0.02920 | -0.00567 | 0.43150  | -0.41928 | -0.00344 | -0.01772 | 1        |            |         |         |     |
| 복수기 보충수 유량 | 0.03915  | 0.02217  | -0.00763 | -0.02118 | 0.02004  | 0.01458  | -0.02106 | 0.02855  | -0.04741 | 1          |         |         |     |
| 급수 유량      | 0.74104  | 0.84211  | -0.55219 | -0.14519 | 0.74195  | -0.07517 | -0.02846 | -0.34036 | 0.12244  | 0.00229    | 1       |         |     |
| 연료량        | 0.12164  | 0.18121  | -0.02103 | -0.62003 | 0.20957  | 0.06908  | 0.00304  | -0.00453 | 0.10985  | 0.01608    | 0.15218 | 1       |     |
| 공기량        | 0.40815  | 0.34641  | -0.00867 | -0.05055 | 0.37369  | 0.04102  | 0.00261  | -0.00476 | 0.03597  | 0.02209    | 0.23074 | 0.19877 | 1   |

| 데이터명       | 그룹의 중심값  |             | 그룹에 속한 데이터 개수 |
|------------|----------|-------------|---------------|
|            | 정상데이터 그룹 | 이상데이터 그룹    |               |
| 주중기 압력     | 정상데이터 그룹 | 0.983343731 | 285           |
|            | 이상데이터 그룹 | 0.534014706 | 3             |
| 주중기 온도     | 정상데이터 그룹 | 0.987275699 | 283           |
|            | 이상데이터 그룹 | 0.911886974 | 5             |
| 재열기 온도     | 정상데이터 그룹 | 0.979122048 | 283           |
|            | 이상데이터 그룹 | 0.953391537 | 5             |
| 노내압력       | 정상데이터 그룹 | 0.485520454 | 287           |
|            | 이상데이터 그룹 | 0.939861244 | 1             |
| 드럼레벨       | 정상데이터 그룹 | 0.375770418 | 285           |
|            | 이상데이터 그룹 | 0.430102019 | 3             |
| 복수기 압력     | 정상데이터 그룹 | 0.019829206 | 283           |
|            | 이상데이터 그룹 | 0.005458657 | 5             |
| 복수기 보충수 유량 | 정상데이터 그룹 | 0.003024738 | 280           |
|            | 이상데이터 그룹 | 0.829473113 | 8             |
| 급수유량       | 정상데이터 그룹 | 0.906650329 | 284           |
|            | 이상데이터 그룹 | 0.494510164 | 4             |
| 연료량        | 정상데이터 그룹 | 0.863806883 | 284           |
|            | 이상데이터 그룹 | 0.054305846 | 4             |
| 공기량        | 정상데이터 그룹 | 0.929725671 | 281           |
|            | 이상데이터 그룹 | 0.642042605 | 7             |

표 3 K-Means 알고리즘을 이용한 정상상태데이터와 이상상태데이터 군집화(2011년 동해2호기)

Table 3 Clustering of normal data and abnormal data using K-Means algorithm

한 고장이 발생하기 이전의 동해2호기의 출력 200MW로 정상운전을 하고 있는 대략 한 달간의 데이터들로 상관계수를 구한 상관관계 결과를 나타내고 있다. 정상운전 데이터의 검증을 위해서, 발전 출력데이터의 정규분포를 확인하였다. 상관관계 분석 결과에서 발전기 출력 대비 상관계수가 높은 요인은 주중기 유량, 재열기 압력 및 급수유량 데이터들이다. 일반적으로 상관계수가 0.7 이상이면 변수들간의 연관성이 아주 높다고 판단할 수 있으며, 표2의 결과를 바탕으로 상관계수가 높은 4개의 요인 중에서 급수유량 데이터를 본 논문에서 제안한 고장 검출 모델의 입력으로 사용한다. 보일러 튜브 누설 고장사례에서 이 4개의 요인 중 급수유량 데이터가 고장관련 연관성이 가장 큰 것으로 판단되기 때

문이다. 그래서 본 논문에서 제안하는 보일러 튜브 누설에 관한 고장 검출 모델에 최종적으로 10개의 변수가 입력으로 들어간다.

두 번째, 선택된 데이터에서 고장관련 정보 추출 단계의 사례로, 본 논문에서 고장검출을 위한 신경망에 사용될 입력변수들은 두 그룹으로 나누어져 있으며, 분류된 이상상태데이터 그룹은 고장에 대한 정보를 가지고 있어야 한다. 그리고 정상상태데이터 그룹 또한 발전소 정상운전상태에 대한 정보를 가지고 있어야만 한다. 본 논문에서 두 그룹으로 분류된 신경망의 입력데이터들은 발전소에서 고장이라고 판단한 시점을 기준으로 하루전까지의 데이터, 즉 24시간동안 5분마다 측정된 데이터이며, 하나의 입력변수는 288개의 데이터로 구성되어 있다. 아래의 표는 2011년 동해 2호기 화력발전소에서 발생한 보일러 튜브 누설 고장이 발생했던 사례로, 고장시점부터 하루 전까지의 각 데이터들을 K-Means 알고리즘으로 2개의 그룹으로 군집화한 결과를 나타내고 있다.

세 번째, 분류된 데이터집단의 신뢰성 검정 단계의 사례로, 아래의 표 4는 가설검정을 위한 각 입력별 정상상태데이터 및 이상상태데이터 그룹의 검정통계량과 두 집단의 동일성을 확인하기 위한 귀무가설이 기각될 수 있는 영역 즉 기각역을 나타낸 것이며, 유의수준은 5%로 선정하였다. 그리고 구해진 검정통계량 값과 귀무가설의 기각역을 바탕으로 모든 입력변수들의 정상상태데이터 그룹과 이상상태데이터 그룹으로 분류된 결과는 신뢰성을 가진다는 것을 가설검정으로 확인할 수 있다.

복수기 보충수 유량 데이터 경우 정상상태데이터 집단의 데이터개수는 280개이며, 이상상태데이터 집단의 데이터개수는 8개이다. 일반적으로 가설검정에서 두 집단의 표본의 개수를 동일하게 설정하여 검정을 하기 때문에, 복수기 보충수 유량 데이터에서 정상상태데이터 집단의 데이터 중 8개를 임의로 선택하여, 이상상태데이터 집단의 데이터 개수와 동일하게 맞추었다. 표 4에서 복수기 보충수 유량의 검정통계량 값은  $T(X) = -12.2475$ 이며, 귀무가설을 기각할 수 있는 기각역의 경계값은 2.1447이다.

네 번째, 본 논문에서 구현한 다층 신경망 기반의 고장 검출 시스템 모델에서 고장 검출을 위한 학습 및 적용단계로서, 발전

표 4 고장검출을 위한 분류된 집단의 가설검증을 위한 검정통계량값  $T(X)$  및 기각역 (2011년 동해2호기)

Table 4 The test statistic value and the critical region for the hypothesis test of the classified group for the fault detection

|               | 주증기 압력      |             | 주증기 온도      |             | 재열기 온도      |             | 드럼레벨         |             |
|---------------|-------------|-------------|-------------|-------------|-------------|-------------|--------------|-------------|
|               | 정상상태데이터 그룹  | 이상상태데이터 그룹  | 정상상태데이터 그룹  | 이상상태데이터 그룹  | 정상상태데이터 그룹  | 이상상태데이터 그룹  | 정상상태데이터 그룹   | 이상상태데이터 그룹  |
| 평균            | 0.944457354 | 0.534014706 | 0.981818991 | 0.911886974 | 0.978947864 | 0.953391537 | 0.377049966  | 0.430102019 |
| 분산            | 0.004633169 | 0.021054563 | 0.000160644 | 0.000303268 | 2.11461E-06 | 9.05283E-05 | 1.55858E-06  | 0.000305833 |
| 관측수           | 3           | 3           | 5           | 5           | 5           | 5           | 3            | 3           |
| 공동(Pooled) 분산 | 0.012843866 |             | 0.000231956 |             | 4.63214E-05 |             | 0.000153696  |             |
| 가설 평균차        | 0           |             | 0           |             | 0           |             | 0            |             |
| 자유도           | 4           |             | 8           |             | 8           |             | 4            |             |
| T 통계량         | 4.435578074 |             | 7.260106056 |             | 5.937141343 |             | -5.241032662 |             |
| T 기각치 양측 검정   | 2.776445105 |             | 2.306004135 |             | 2.306004135 |             | 2.776445105  |             |

|               | 복수기 압력      |             | 복수기 보중수 유량   |             | 급수유량        |             | 연료량         |             | 공기량         |             |
|---------------|-------------|-------------|--------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|
|               | 정상상태데이터 그룹  | 이상상태데이터 그룹  | 정상상태데이터 그룹   | 이상상태데이터 그룹  | 정상상태데이터 그룹  | 이상상태데이터 그룹  | 정상상태데이터 그룹  | 이상상태데이터 그룹  | 정상상태데이터 그룹  | 이상상태데이터 그룹  |
| 평균            | 0.02011601  | 0.005458657 | 0.00625285   | 0.829473113 | 0.895937056 | 0.494510164 | 0.830594521 | 0.054305846 | 0.925979877 | 0.642042605 |
| 분산            | 1.19728E-06 | 5.33338E-06 | 0.000168818  | 0.035974177 | 0.001133289 | 0.035599436 | 0.006582755 | 0.0117965   | 0.000121387 | 0.024511642 |
| 관측수           | 5           | 5           | 8            | 8           | 4           | 4           | 4           | 4           | 7           | 7           |
| 공동(Pooled) 분산 | 3.26533E-06 |             | 0.018071498  |             | 0.018366362 |             | 0.009189627 |             | 0.012316514 |             |
| 가설 평균차        | 0           |             | 0            |             | 0           |             | 0           |             | 0           |             |
| 자유도           | 8           |             | 14           |             | 6           |             | 6           |             | 12          |             |
| T 통계량         | 12.825139   |             | -12.24754303 |             | 4.188995424 |             | 11.45220995 |             | 4.786438882 |             |
| T 기각치 양측 검정   | 2.306004135 |             | 2.144786688  |             | 2.446911851 |             | 2.446911851 |             | 2.17881283  |             |

표 5 보일러튜브누설 고장진단을 위한 다층신경회로망의 입, 출력의 처리과정

Table 5 Process of multilayer neural network for boiler tube leakage fault detection

| 시간                 | (신경망)입력     |             |             |             |             |             |             |             |             |             | (신경망)목표값 |
|--------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|-------------|----------|
|                    | X1(주증기압력)   | X2(주증기온도)   | X3(재열기온도)   | X4(노내압력)    | X5(드럼레벨)    | X6(복수기압력)   | X7(보중수유량)   | X8(급수유량)    | X9(연료량)     | X10(공기량)    |          |
| 17-Oct-11 09:15:00 | 0.977574963 | 0.980713974 | 0.977020558 | 0.493750719 | 0.377537085 | 0.018439634 | 0.098709241 | 0.973272851 | 0.862062892 | 0.901064681 | 0        |
| 17-Oct-11 09:20:00 | 0.936048637 | 0.983590093 | 0.978274266 | 0.337288196 | 0.389897572 | 0.01617691  | 0.458934772 | 0.853216202 | 0.710439044 | 0.822543122 | 0        |
| 17-Oct-11 09:25:00 | 0.865865124 | 0.994020499 | 0.976202217 | 0.61494208  | 0.39181374  | 0.013426652 | 0.943235578 | 0.773357267 | 0.647645659 | 0.745901372 | 1        |
| 17-Oct-11 09:30:00 | 0.825241074 | 0.959221463 | 0.969789222 | 0.49340087  | 0.355964254 | 0.009100265 | 0.724755148 | 0.754669525 | 0.593966501 | 0.683676626 | 1        |
| 17-Oct-11 09:35:00 | 0.799313686 | 0.927495855 | 0.962763115 | 0.592537496 | 0.353337611 | 0.0064187   | 0.676403794 | 0.723737362 | 0.60388048  | 0.694670995 | 1        |
| 17-Oct-11 09:40:00 | 0.81505045  | 0.928904237 | 0.958692081 | 0.939861244 | 0.365212765 | 0.004171416 | 0.932179173 | 0.659994173 | 0.217223385 | 0.694629364 | 1        |




그림 5 2011년 동해2호기 고장사례에 대한 고장검출결과  
Fig. 5 Results of fault detection for fault sample in 2011




그림 6 2013년 동해2호기 고장사례에 대한 고장검출결과  
Fig. 6 Results of fault detection for fault sample in 2013

소의 주요측정데이터들이 보일러 튜브누설 고장 진단을 위한 다층신경망의 입력으로 10개의 측정데이터들이 시계열값으로 들어

가고, 목표값으로 고장진단을 위한 0과 1사이의 값으로 출력이 나오는 것을 확인할 수 있다. 이 때 모든 입력변수 데이터들 역시 0과1 사이의 값으로 정규화가 되어 있으며, 같은 시간대에 측정된 입력데이터들은 신경망으로 동시에 들어간다. 그리고 신경망의 출력은 보일러 튜브 누설 고장검출을 위한 0과 1로 표현된 값으로 하나의 데이터가 3번 연속 이상신호를 발생시키거나, 2개 이상의 데이터가 동시에 이상상태 신호가 나타나면, 신경망은 고장검출값인 1을 출력하도록 학습시켰다. K-Means 알고리즘으로 분류된 각 데이터의 이상상태 신호들은 그림 3에서 강조된 글씨체의 숫자로 표시되어 있다.

마지막으로, 특정 고장 검출 결과를 확인하는 단계로, 그림 5, 6는 본 논문에서 제안한 K-Means 알고리즘을 적용한 신경망기반의 고장검출시스템으로 발전소별 고장검출 결과를 나타낸 것이다. 그림 5는 2013년 2월 14일에 동해2호기 발전소에서 발생한 보일러 튜브 누설 고장사례에 대해 하루전의 데이터로 임플러 패턴을 구성하여 학습시킨 후, 2011년 10월 17일 시점의 보일러 튜브 누설고장사례에 적용하여 고장검출 유무를 평가한 결과를 보여주고 있다. 그림 6은 2011년 동해2호기 발전소의 고장사례를 신경망으로 학습시켜, 2013년 동해2호기 보일러 튜브 누설 고장사례로 고장검출 유무를 평가한 결과이다. 신경망의 결과값이 1이면 고장검출이 되는 것을 의미하고, 0이면 검출이 되지 않는 것을 의미한다. 그림을 통해 고장발생 시점 이전(35분전)에 실질적인 고장 판별이 가능함을 알 수 있다.

### 3. 결 론

본 논문에서는 국내 화력발전소에서 발생한 보일러 튜브 누설로 인한 고장사례들을 분석하여, 발전소 가동중의 고장상태진단을 위하여, 데이터마이닝 기법중 하나인 K-Means 알고리즘을 이용하여 고장관련 측정데이터들을 정상상태데이터 그룹과 이상상태데이터 그룹으로 분류하였다. 그리고 분류된 이상상태데이터 그룹의 신뢰성 검토를 위해서, 통계학적 기법중 하나인 가설검정 기법으로 확인하였다. 분류된 정상상태 및 이상상태 데이터 그룹에 대하여 계측기의 측정값인 입력데이터와 정상 또는 이상상태에 대한 출력 데이터를 쌍으로 하여 고장검출을 위한 학습패턴을 구성하였다. 이를 다층신경회로망으로 학습하여 보일러 튜브 누설 고장감지에 적용하였다. 발전소의 고장은 발전소별로 특정 고장의 빈도가 많지 않고 또한 발전소마다 그 유형이 상이한 경우가 많다. 이러한 데이터의 제약으로 본 논문에서는 사례 발전소에 대해 특정 시점에서의 고장사례를 학습패턴으로 구성하고 다른 시점에서의 고장에 대해 테스트데이터로 적용하였다. 결과는 그림 5, 6에 볼 수 있듯이, 고장발생시점 이전시간에 고장감지가 되는 것을 확인할 수 있다. 본 논문에서 제안한 고장검출시스템이 각 발전소에서 발생하는 보일러튜브 누설에 의한 고장을 사전에 검출을 할 수 있는 가능성을 보여주고 있다. 실제 고장사례가 빈번하게 발생하지 않기 때문에, 분석한 데이터들이 고장에 대한 많은 정보를 가지고 있다고 보기 어렵다. 그러나 실제 고장사례의 데이터들을 가지고 사전 고장검출 가능성을 확인함으로써, 향후 사례 데이터의 확보에 따라 예측 성능이 향상될 수 있을 것으로 판단된다. 또한 타 발전소에 대해 적용함으로써 응용을 보다 일반화할 수 있을 것으로 예상된다.

#### 감사의 글

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

#### References

[1] K.Y. Lee, J.H. Park, "Short Term Load Forecasting using Artificial Neural Network", IEEE Trans. Power System, vol. 7, No. 1, pp. 1-8, 1992.

[2] S. Simani, C. Fantuzzi, "Fault diagnosis in power plant using neural networks", Information Sciences 127, pp. 125-136, 2000.

[3] Roozbeh Razavi-Far, Hadi Davilu, Vasile Palade, Caro Lucas, "Model-based fault detection and isolation of a steam generator using neuro-fuzzy networks", Neuro-computing 72, pp. 2939-2951, 2009.

[4] H.S. Han, K.Y. Song, "Electroencephalogram-Based Driver Drowsiness Detection System Using Errors-In-Variables (EIV) and Multilayer Perceptron(MLP)", The Journal of The Korean Institute of Communication Sciences 39(10), pp. 887-895, 2014.10.

[5] C. J. Lee, B. Son, and H. S. Hong, "Improvement of pattern recognition capacity of the fuzzy ART with the variable learning", J. KICS, vol. 38. no. 15, pp. 954-961, 2013.

[6] Behrad Bagheri, Hojat Ahmadi, Reza Labbafi, "Application of Data Mining and Feature Extraction on Intelligent Fault Diagnosis by Artificial Neural Network and k-Nearest Neighbor", ICEM 2010.

[7] P. Smyth, "Hidden markov models for fault detection in dynamic systems," Pattern Recognition, vol. 27, no. 1, pp. 149-164, 1994.

[8] R. Isermann, "Model based fault detection and diagnosis methods," Proc. ACC, pp. 1605-1609, 1995

[9] R. Patton, P. Frank and R. Clark, "Fault Diagnosis in Dynamic Systems Theory and Application", Prentice Hall, 1989.

[10] M. M. Polycarpou and A. T. Vemuri, "Learning methodology for failure detection and accommodation", IEEE Contr. Syst. Mag., pp. 16-24, 1995.

[11] X. Q. Liu, H. Y. Zhang, J. Liu and J. Yang, "Fault detection and diagnosis of permanent-magnet DC motor based on parameter estimation and neural network", IEEE Trans. Ind. Electron, vol. 47, no. 5, pp. 1021-1030, 2000.

[12] A. Srinivasan and C. Batur, "Hopfield / ART-1 neural network-based fault detection and isolation", IEEE Trans. Neural Networks, vol. 5, no. 6, pp. 890-899, 1994.

[13] I.S.Lee, C.J.Yoo, K.Y.Kim "Fault Diagnosis for the Nuclear PWR Steam Generator Using Neural Network" Journal of Fuzzy Logic and Intelligent Systems Vol. 15, No. 6, pp. 673-681, 2005.

[14] K.H. Kim, H.S. Lee, H.M. Jeong, H.Y. Kim, H.S. Lee, J.H. Park "A study on neural network based fault detection system applying the K-Mean algorithm in thermal power plant", The Korean Institute of Electrical Engineers, pp 143-145, November 2016

[15] H.S. Kim, N.K. Jeong, D.S. Kim, S.H. Lee, "Failure Analysis of Waterwall Tubes in Super Critical Boiler", Journal of the Korea Society of Power Engineers, Vol. 7, No. 1, pp. 20~24, 02. 2003.

[16] K.S. Lee, "The concept and trend of fault detection diagnosis and fault tolerance control" Journal of the Korean Institute of Electrical Engineers, Vol. 48, No. 4, April 1999.



[17] N.H. Noh, J.Y. Yoo, "Multivariate analysis theory and practice using SPSS and EXCEL, Jipil Media Co., Ltd., January 2016.

저 자 소 개



**김 규 한 (Kyu-Han Kim)**

1979년 5월 15일생, 2007년 부산대 공대 전자전기통신공학부 졸업, 2011년 동 대학원 전자전기공학과 졸업(공학석사), 2011년~2014년 LG전자 AE제어연구소, 현재 동대학원 박사과정

Tel : 051-510-3188  
Fax : 051-513-0212  
E-mail : cukh79@naver.com



**박 준 호 (June-Ho Park)**

1955년 9월 17일생, 1978년 서울대 공대 전기공학과 졸업, 1980년 동 대학원 전기공학과 졸업(공학석사), 1987년 동 대학원 전기공학과 졸업(공학박사), 현재 부산대 전기컴퓨터공학부 교수

Tel : 051-510-3188  
Fax : 051-513-0212  
E-mail : parkjh@pusan.ac.kr



**이 흥 석 (Heung-Seok Lee)**

1989년 08월 23일생, 2012년 울산대 공대 전자전기컴퓨터공학과 졸업, 2014년 부산대학교 전기공학과 대학원 졸업(공학석사), 2014년~현재, 동 대학원 박사과정

Tel : 051-510-3188  
Fax : 051-513-0212  
E-mail : zznada@naver.com



**정 희 명 (Hee-Myung Jeong)**

1978년 1월 6일생, 2004년 부산대 공대 전자전기컴퓨터공학부 졸업, 2006년 동 대학원 전기공학과 졸업(공학석사), 현재 동 대학원 박사과정

Tel : 051-510-3188  
Fax : 051-513-0212  
E-mail : jeonghm@pusan.ac.kr



**김 형 수 (Hyung-Su Kim)**

1972년 1월 26일생, 1994년 부산대 공대 전기공학과 졸업, 1997년 동 대학원 전기공학과 졸업(공학석사), 2007년 동 대학원 전기공학과 졸업(공학박사), 현재 경남도립 남해대학 조교수

Tel : 055-860-5353  
Fax : 055-860-5351  
E-mail : kimhsu@namhae.ac.kr