



## 전기부하 패턴분류를 위한 신호처리 기법에 관한 연구

### A Study on the Signal Processing Techniques for Pattern Classification of Electrical Loads

임용배\* · 김동우\* · 진상민\*\* · 조성원\*\*†

Young Bae Lim, Dong Woo Kim, Sangmin Jin, and Seongwon Cho<sup>†</sup>

\*한국전기안전공사 전기안전연구원, \*\*홍익대학교 전자전기공학부

\*Electrical Safety Research Institute, a subsidiary of Korea Electrical Safety Corporation

\*\*School of Electrical and Electronics Engineering, Hongik University

#### 요 약

최근 사물인터넷 기반의 재해예방 기술이 개발되고 있다. 본 논문에서는 사물인터넷 기반의 공동주택용 자율전기안전관리 기술 개발을 위하여 부하 전류 파형을 FFT와 MFCC를 이용하여 신호변환 후 신경회로망 모델에 적용하여 정확도가 개선된 전기 부하 패턴분류 시스템을 제안한다. 오실로스코프와 CT를 이용하여 측정된 전기 부하의 전류 파형을 FFT 알고리즘을 적용한 후 신경회로망을 이용하여 단일부하패턴 분류 실험을 하였다. 본 연구를 통하여 부하의 특성을 파악함으로써 고장에 대해 보다 신속하고 정확하게 대처할 수 있을 것으로 예측된다.

키워드 : 전기부하, MFCC, 인공 신경망, 패턴분류, 신호처리

#### Abstract

Recently several techniques for disaster prevention based on IoT(Internet of Things) are being developed. In this paper, a new smart pattern classification method for electric loads is proposed. CT(Current Transformer) data are extracted from electric loads, and then the sampled CT data are converted using FFT and MFCC. FFT and MFCC data are used for the input data of neural networks. Experiments were conducted using FFT and MFCC data for 7 kinds of electric loads. Experiments results indicate the superiority of MFCC in comparison to FFT.

Key Words : Electric Load, MFCC, Neural Networks, Pattern Classification, Signal Processing

Received: Sep. 5, 2016  
Revised : Sep. 30, 2016  
Accepted: Oct. 13, 2016  
<sup>†</sup>Corresponding authors  
swcho@hongik.ac.kr

## 1. 서 론

전기에 대한 에너지 의존도가 급격히 높아짐에 따라 증가된 전력사용은 전기화재 등 재해에 대한 잠재적 위험성을 증가시켰다. 최근 디지털 기술의 발전으로 정보통신기술을 접목한 사물인터넷 기반의 재해예방기술이 개발되고 있으나, 현재 초기단계에 있다[1]. 전기안전분야에서는 전기재해예방을 위해 종래의 분전반 기능에 과전류, 누설전류, 아크 등 전기안전 상태에 대한 위험요소를 실시간으로 계측, 분석 할 수 있는 스마트분전반 기반 기술이 개발되고 있다[2-3]. 그러나 아크고장 등의 재해요소 판정에 있어서, 재해요소 감지 및 판단의 정확성을 높이기 위해서는 부하의 동작상태 및 종류를 구별할 수 있도록 측정된 데이터를 사물인터넷 기반으로 전송할 수 있는 기술 개발이 필요하다. 이에 본 논문에서는 공동주택용 단위 고객별 자율전기안전관리 기술 개발을 위한 부하별 전류파형을 이용한 부하패턴 분류 알고리즘을 제안한다. 특히, 단일 부하 전류파형으로부터 데이터를 추출하여 신호처리 기법인 FFT와 MFCC를 이용한 신호변환 후 신경회로망 모델에 적용함으로써 정확도가 높은 시스템을 구현하는 방법을 제안한다.

## 2. 관련 연구

본 논문은 2016년도 산업통상자원부의 재원으로 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20151210000050)  
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.

### 2.1 FFT(Fast Fourier Transform)

일반적으로 시간축상의 N개의 이산 신호로부터 DFT(Discrete Fourier Transform)스펙트럼을 얻기 위해서는 N의 제곱의 연산량이 필요하다. 이는 DFT의 N개의 요소마다 N번의 합과 복수의 곱셈이 필요하기 때문이다. 만약 N이 128이라면 16384번의 합산과 복소수의 곱셈이 필요하며, N이 256이라면 65536번의 합산과 복소수의 곱셈이 필요하다. 따라서 N 제곱의 연산량이 필요한 DFT를 실시간 처리하기에는 어려움이 있다.

FFT는 이러한 연산량문제를 해결하기 위해 개발된 알고리즘이다. FFT를 사용하면 N제곱의 연산량을  $M \log_2 N$ 에 처리할 수 있다. DFT 계산을 FFT로 대체하면  $\log N / N$ 의 연산량 감소율을 얻을 수 있다. 만약 N이 128이라면 약 18배, N이 256이라면 약 32배의 연산량 감소 효과를 갖는다.

FFT의 원리는 다음과 같다. 만약 푸리에 변환을 알고자 하는 신호의 샘플개수 N이 2의 m승이라고 하면, N개의 샘플신호를 식(1)과 같이 차례로 홀수 번째 샘플열과 짝수 번째 샘플열의 2개의 샘플열로 분류할 수 있다.

$$\begin{aligned}
 g_1 : f_0, f_2, \dots, f_{N-2} & \Rightarrow g_1 = f_{2l} \\
 h_l : f_1, f_3, \dots, f_{N-1} & \Rightarrow h_l = f_{2l+1} \\
 l & = 0, 1, \dots, \frac{1}{2}N-1
 \end{aligned}
 \tag{1}$$

위 두 샘플열  $g, h$ 는 각각 N/2개의 샘플을 가지며 NT/s의 주기를 갖는다.

### 2.2 MFCC(Mel-frequency cepstral coefficients)

Mel-frequency cepstrum(MFC)은 단구간 신호의 파워스펙트럼을 표현하는 방법 중 하나로, 비선형적인 Mel스케일의 주파수 도메인에서 로그파워스펙트럼에 코사인변환(Cosine Transform)을 취함으로써 얻을 수 있다. MFCC는 여러 MFC들을 모아 놓은 계수들을 의미한다. 그림 1은 MFCC 과정을 나타낸다.




그림 1. MFCC 과정  
Fig. 1. Process of MFCC

MFCC의 처리 절차는 FFT(Fast Fourier Transform)를 수행하여 주파수영역으로 변환하고 변환된 값들을 미리 설정된 MFCC(멜

캡스트럼) 대역필터뱅크를 통과시킨 후, 로그화, DCT(Discrete Cosine Transform)을 거치면 한 프레임 당 M개의 계수 값들을 구할 수 있다. 이 값들이 부하패턴신호의 특징정보들이다. Mel Filter Bank 프레임당 너무 많은 양의 데이터 값이 존재하므로 적절한 파라미터를 뽑기 위해 FFT한 결과를 갖고 필터뱅크를 거쳐서 각 필터뱅크의 에너지를 구하게 되는 것이다.

일반적으로 사용되는 필터뱅크의 가장 평이한 형태는 균일(Uniform)필터뱅크이다. 여기서의 l번째 대역통과 필터의 중앙 주파수 값,  $f_l$ 는 식(2)과 같이 정의 되어 있다[5].

$$f_l = \frac{F_s}{N}i, 1 \leq i \leq Q
 \tag{2}$$

위 식에서  $F_s$ 는 음성 신호의 샘플링 주파수, N은 샘플링 주파수를 등간격으로 나눈 균일 분포 필터들의 수이다. 또 실제 필터들의 수를 나타내는 Q는 다음 조건을 만족한다.

$$Q \leq N/2
 \tag{3}$$

위 조건에서 등호는 음성 신호의 전체 주파수 범위가 분석에 사용될 때 성립한다. 또한 l번째 필터의 대역  $b_l$ 는 일반적으로 다음의 성질을 만족한다.

$$b_l \leq F_s/N
 \tag{4}$$

이때 등호는 인접한 필터 채널들과 주파수 중첩부분이 없다는 것을 의미한다. 부등호는 인접한 필터 채널이 중첩하다는 뜻이다. 만약  $b_l \leq F_s/N$ 이면 음성 스펙트럼의 일부분의 정보가 의미를 상실하게 되어 올바른 분석이 이루어질 수 없다.

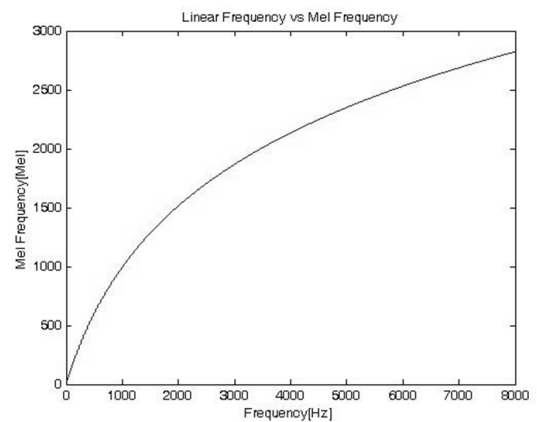


그림 2. 멜주파수와 주파수와의 관계  
Fig. 2. Relation graph between mel-frequency and frequency

하지만 실험에 사용할 Mel Filter Bank는 비균일(Nonuniform) 필터뱅크이다. 비균일 필터뱅크를 디자인 하는 경우에는 주대역 단위를 직접적으로 사용하는 방법이 있다. 주대역을 따른 필터들의 배치는 인지적 연구에 기반을 두고 있다. 이 필터들의 간격은 1000 Hz 미만의 주파수에서는 선형적이며 그 이상에서는 로그단위에 가깝다.

실험에서는 식(5)의 멜 공식을 이용하여 멜 주파수 영역으로 옮긴 다음 멜 주파수 영역에서 등간격으로 나눈 후 다시 주파수 영역으로 변환해 사용하였다.

$$mel = 2579 \log_{10} \left( 1 + \frac{f}{700} \right) \quad (5)$$

DCT는 필터뱅크를 거쳐서 나온 출력간의 상관관계를 없애주고 파라미터의 특징을 모아주는 역할을 한다. 하나의 프레임에 MFCC를 적용할 경우 필터뱅크의 개수만큼 특징벡터 값이 나오게 된다. 특징 추출 처리는 필터뱅크 수만큼 나온 특징차수에서 작은 차수부터 필요한 개수만큼 선택하는 것이다[6].

MFCC를 구하기 위한 과정을 식으로 표현하면 다음과 같다.

$$y^{(m)}(k) = \sum_{m=1}^M \log |Y_t| \cos \left( k \left( m - \frac{1}{2} \right) \frac{\pi}{M} \right) \quad (6)$$

$$k = 0, 1, \dots, L$$

위에서  $y_t^{(m)}$ 은 filter bank에서 얻어진 출력이고 여기에 logarithm을 취하고 DCT를 수행하여 특징벡터  $y_t^{(m)}(k)$ 를 구한다.

### 2.3 역전파 신경망

그림 3은 본 논문에서 사용된 인공 신경망 구조를 나타낸다. 인공 신경망 학습을 위해 역전파 학습 알고리즘(Backpropagation Algorithm)을 사용하였다.




그림 3. 인공신경망의 구조  
Fig. 3. Structure of neural networks

역전파 학습 알고리즘은 미분의 반복 규칙을 여러번 반복적으로

적용하여 확률 근사치 프레임 워크와 관련지음으로써 유도해낼 수 있다. Rumelhart 등이 일반화 델타규칙(Generalized delta rule)이라고 불리는 역전파 학습 알고리즘을 제안하였다. 이것은 퍼셉트론 모델의 제한점을 극복했으며, 십여년간 침체했던 신경회로망 연구를 중흥시키는 계기가 되었다. 하지만 역전파 학습 알고리즘에도 단점들이 있다. 첫째, 이 알고리즘은 수렴에 종종 실패하고 지역 최소 값에 봉착한다. 둘째, 비지역성, 동시성, 감독과 긴 훈련 시간 등으로 생물학적인 신경회로망과는 상당한 차이점이 있다는 것이다. 셋째, 불연속 시뮬레이션에서 항상 수렴하는 것이 아니라는 것이다. 즉, 초기의 상태를 어떻게 선택하느냐에 따라 진동하거나, 최악의 경우 발산하기도 한다.

역전파 학습 알고리즘이 수렴할 경우에도 지역 최소 오류(Local minimum error) 수렴하기도 한다. 하지만, 가중치 공간의 차원이 매우 클 경우에는 지역 최소 값이 거의 생기지 않는다는 것도 생각해볼 수 있다. 역전파 학습 알고리즘은 통계학이 오래 전부터 탐구한 추정(estimation) 방법을 구현하는 효과적인 방법을 제시하고 있다[7-10].

역전파 학습 알고리즘의 기본 원리는 다음과 같다. 입력층이 각 뉴런에 입력 패턴을 주며, 이 신호는 각 뉴런에서 변환되어 중간층에 전달되고 최우에 출력층에서 신호를 출력하게 된다. 이 출력 값과 기댓값을 비교하여 차이를 줄여나가는 방향으로 가중치를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 가중치를 조정해 나간다.

지도학습에서는 입력 및 원하는 출력(목표 출력)패턴(벡터)이 신경망에 지시된다. 역전파 학습 알고리즘을 이용한 신경망의 학습은 3단계로 이루어진다.

1단계로 학습 입력 패턴을 신경망에 입력하여 출력을 구하고, 2 단계는 출력과 목표치 사이의 차이 즉, 오차를 구하고, 3단계에서는 오차 값이 없는 경우에는 학습이 일어나지 않고, 오차 값이 존재할 경우에는 그 값을 역방향으로 전파시키면서 오차 값의 크기를 감소시키는 방향으로 출력층의 가중치 및 은닉층의 가중치를 변경한다.

이런 학습 단계의 역전파로 인해 역전파 학습 알고리즘이 순환 구조의 신경회로망이라고 오해하기 쉬우나 단지 학습 과정에서만 오차가 관련된 출력이 역방향으로 전파되며, 학습이 완료되고 실제 응용 시에는 입력이 순방향으로 진행되면서 출력이 나오는 순방향 신경회로망 구조임을 분명히 해둘 필요가 있다. 또 역전파 학습 알고리즘은 학습에 상당히 많은 시간을 소요하게 되지만, 일단 학습이 끝나면 응용 단계에서 매우 빠르게 결과를 출력한다.

역전파 학습 알고리즘은 일반 델타 규칙 학습법과 마찬가지로 출력층 오차신호를 이용하여 은닉층과 출력층간의 가중치를 변경하고, 또한 출력층 오차신호를 은닉층에 역전파하여 입력층과

은닉층간의 가중치를 변경하는 학습 방법이다.

먼저, 학습시킬 p개의 학습패턴쌍  $(x_1, s_1), (x_2, s_2), \dots, (x_p, s_p)$ 를 선정하고 나서, 초기 가중치  $v, w$ 를 임의의 작은 값으로 초기화하며, 학습률 선정 방법에 의거하여 적절한 학습률  $\alpha$ 를 결정한다. 학습 패턴쌍으로 차례로 입력하여 가중치를 변경하면서 학습해나간다. 역전파 학습 알고리즘은 시그모이드 함수를 활성화 함수로 사용한다. 또 목표치  $s$ 와 최종 출력  $y$ 를 비교하여 제곱 오차  $E$ 를 구한다.

$$E = \frac{1}{2}(s - y)^2 \tag{7}$$

또한, 다음 식

$$\begin{aligned} \delta_{yi} &= (s_i - y_i)y_i(1 - y_i) \\ \delta_{yi} &= \frac{1}{2}(s_i - y_i)(1 - y_i^2) \end{aligned} \tag{8}$$

에 의해 출력층의 오차신호  $\delta_y$ 를 구한다.

$$\begin{aligned} \delta_{zj} &= \alpha'_f(\neq T_{zj}) \sum_{i=1}^m \delta_{yi} w_{ij} \\ \Delta v_{zj} &= \alpha \delta_{zj} x_k = \alpha \alpha'_f(\neq T_{zj}) x_k w_{ij} \end{aligned} \tag{9}$$

를 이용하여 은닉층에 전파되는 오차신호를  $\delta_z$  구한다.

k 학습 단계에서의 은닉층과 출력층간의 가중치 변화량  $\Delta w(k)$  및 입력층과 은닉층간의 가중치 변화량  $\Delta v(k)$ 를 구한다.

$$\begin{aligned} \Delta w(k) &= \alpha \delta_y z \\ \Delta v(k) &= \alpha \delta_z x \end{aligned} \tag{10}$$

k+1 단계에서의 은닉층과 출력층간의 가중치  $w(k+1)$ 와 입력층과 은닉층간의 가중치  $v(k+1)$ 을 구한다.

$$\begin{aligned} w(k+1) &= w(k) + \Delta w(k) = w(k) + \delta_y z(k) \\ v(k+1) &= v(k) + \Delta v(k) = v(k) + \delta_z z(k) \end{aligned} \tag{11}$$

학습 패턴쌍을 반복 입력하여 연결강도를 변경하며, 오차가 특정범위보다 적어지면 학습을 종료한다[11].

### 3. 구현 및 실험결과

본 논문에서는 전기 부하 전류 DATA를 취득하기 위해 TELEDYNE IECROY 640zi 오실로스코프(Oscilloscope)와 전기부하 전류를 측정할 수 있는 CT를 이용하여 실험에 사용하였다

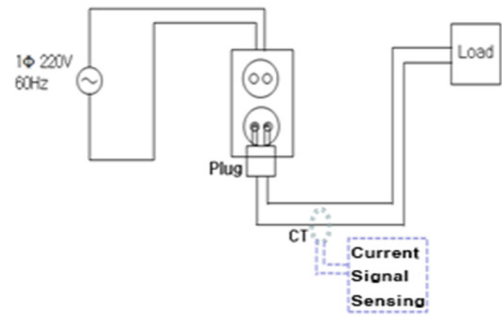


그림 4. 부하 전류 파형 측정  
Fig. 4. Measurement of load current waveform

(그림 4 참조). 표 1에 있는 패턴분류대상 부하 총 7개의 전류파형을 취득하였고 그림 5부터 그림 11까지는 오실로스코프를 이용해 실험에 사용된 전류 파형들이다.

표 1. 패턴분류대상 부하(총 7종)  
Table 1. Types of loads for pattern classification

Number	Type of Load
1	Television
2	Computer
3	Refrigerator
4	Electric Heater
5	Fluorescent Light
6	Air Conditioner
7	Microwave




그림 5. 컴퓨터 전류 파형  
Fig. 5. Current waveform of computer




그림 6. 전기히터 전류 파형  
Fig. 6. Current waveform of electric heater




그림 7. 형광등 전류 파형  
Fig. 7. Current waveform of fluorescent light




그림 8. 전자레인지 전류 파형  
Fig. 8. Current waveform of microwave




그림 9. TV 전류 파형  
Fig. 9. Current waveform of television




그림 10. 냉장고 전류 파형  
Fig. 10. Current waveform of refrigerator




그림 11. 에어컨 전류 파형  
Fig. 11. Current waveform of air conditioner

대해 오차가 최소화되도록 학습한 후, 신호처리 방법에 대한 인공 신경망의 분류 성능을 비교 평가한다.

FFT와 MFCC를 이용하여 신호처리 한 데이터를 신경망 모델에 적용시킴으로써 부하 패턴을 분류하는 시스템을 구현하였다. 인공신경망을 이용하여 각각의 가전제품의 부하패턴을 예측하기 위해서는 입력값을 주어야한다. 앞서 언급한 통해 FFT, MFCC 신호처리 기법들을 이용하여 입력 변수로 사용하였다.

각각의 전기부하 전류 파형에서 약 250만개 전류 데이터 값들 중 한 주기인 0.0167초 구간에서 샘플링하여 128개의 데이터와 512개의 데이터를 추출하여 FFT, MFCC 신호처리 기법들을 적용하여 비교 실험하였다.

전기부하 종류에 따라 15개의 데이터 세트를 구성하였고, 그 중 10개는 학습을 위한 데이터로 사용하였으며, 5개는 테스트 데이터로 정확도를 평가하기 위하여 사용하였다.

표2 와 표3 은 전류 파형에서 데이터를 추출한 값과 FFT, MFCC 신호처리된 데이터를 각각 128개와 512개의 경우로 나누어 신경회로망에 학습시킨 후 테스트한 실험결과이다.

표 2. 128개 데이터 실험결과  
Table 2. The Experimental Results for 128 Data

	None	FFT	MFCC
Number of Error	4/35	4/35	3/35
Rate of Accuracy	0.8857	0.8857	0.9143

표 3. 512개 데이터 실험결과  
Table 3. The Experimental Results for 512 Data

	None	FFT	MFCC
Number of Error	3/35	3/35	1/35
Rate of Accuracy	0.9143	0.9143	0.9714

본 논문의 목적은 전기 부하 패턴 분류에 최적의 신호처리 방법을 분석하는 것이다. 이를 위한 가장 일반적인 방법은 학습에 사용된 자료와는 별도로 다른 테스트 데이터를 이용하여 부하 분류 정확도를 평가하는 것이다. 인공 신경망을 학습 데이터에

128개의 데이터의 경우, 신호처리를 하지 않은 데이터와 FFT를 사용하여 신호처리 한 데이터의 정확도는 0.8857로 분류 정확도가 동일하였으며, MFCC를 적용한 데이터는 0.9143로 조금 더 좋은 결과가 나온 것을 알 수 있다.

더 많은 512개의 데이터를 추출한 경우의 실험결과는 신호처리를 하지 않은 데이터와 FFT를 적용한 데이터는 0.9143의 정확도를 나타내었고, MFCC를 적용한 데이터는 0.9714의 정확도를 보여주었다. 128개의 데이터를 추출해서 실험을 했을 때보다 512개의 데이터를 사용한 경우에 좀 더 향상된 분류 정확도를 얻을 수 있음을 알 수 있다.

### 5. 결론 및 향후 연구

본 논문에서는 공동주택용 단위 고객별 자율전기안전관리 기구 개발을 위한 부하별 전류 데이터를 이용하여 부하패턴 분류 알고리즘을 연구하였다.

신호처리 알고리즘으로 가장 많이 사용되는 FFT와 음성인식에서 자주 사용되는 알고리즘인 MFCC를 비교하여 실험을 하였다. FFT와 MFCC를 적용하지 않은 데이터로 실험을 한 경우와 FFT를 적용한 경우보다 MFCC를 적용하여 신호변환한 데이터를 이용한 부하분류가 보다 향상된 정확도를 보여주었다. 데이터 크기를 128에서 512개로 확대하여야는 경우, 처리 시간은 좀 더 길어지지만, 분류 정확도는 향상 될 수 있음을 알 수 있었다.

본 연구결과는 부하패턴 분류 기술을 이용한 고장부하 검출을 위한 부하확인 판단오류를 최소화하는 기술연구에 활용 될 수 있다.

### References

[1] D. S. Moon and S. H. Kim, "Study on Artificial Neural Network Based Fault Detection Schemes for Wind Turbine System", *Journal of Korean Institute of Intelligent Systems*, Vol. 22, No. 5, pp. 603-609, October 2012.

[2] H. W. Moon, Y. B. Lim, D. W. Kim, S. Lee, and M. Choi, "A Study on Standardization of Smart Distribution Board for Electrical Safety", *The Transactions of The Korean Institute of Electrical Engineers*, Vol 65, No1, pp. 227-231, 2016.

[3] W. S. Ko and H. J. Lee, "A Plan for Construction of the National Electrical Safety Network to Prevent Electrical Disasters", *Proceedings of Spring Conference of The Korean Institute of Electrical Engineers*, pp. 216-218, April 2009.

[4] S. Soliman and M. Srinath, *Continuous and Discrete Signals and System*, Prentice Hall, 1998.

[5] L. Muda, M. Begam and I. Elamvazuthi, "Voice Recognition

Algorithms using Mel Frequency Cepstral Coefficient (MFCC) and Dynamic Time Warping (DTW) Techniques", *JOURNAL OF COMPUTING*, Vol. 2, ISSUE 3, MARCH 2010.

[6] N. Dave, "Feature Extraction Methods LPC, PLP and MFCC in Speech Recognition", *International Journal for Advance Research in Engineering and Technology*, Vol. 1, ISSUE VI, July 2013.

[7] X. Yu, M.O. Efe, O. Kaynak, "A general backpropagation algorithm for feedforward neural networks learning," *IEEE Trans Neural Network*, Vol. 13, No.1, pp 251-254, 2002

[8] O. Jesus and M. Hagan, "Backpropagation Algorithms for a Broad Class of Dynamic Networks, *IEEE Transactions on Neural Networks*, Vol. 18, No. 1, January 2007.

[9] V. Joseph, Rajapandian, N. Gunaseeli, "Modified Standard Backpropagation Algorithm with Optimum Initialization for Feedforward Neural Networks", *JISE, GA, USA*, Vol. 1, No. 3, July 2007.

[10] W. D. Kim and S. K. Oh, "Design of Optimized Radial Basis Function Neural Networks Classifier with the Aid of Principal Component Analysis and Linear Discriminant Analysis", *Journal of Korean Institute of Intelligent Systems*, Vol. 22, No. 6, pp. 735-740, December 2012.

[11] S. Kosbatwar and S. Pathan, "Pattern Association for Character Recognition by Backpropagation Algorithm Using Neural Networks", *IJCSES*, Vol. 3, No. 1, February 2012.

### 저자 소개



#### 임용배(Yong-Bae Lim)

1994년 : 원광대학교 전기공학과 학사

1998년 : 홍익대 전기제어공학과 석사

2007년 : 홍익대 전기정보제어공학 박사

현재 : 한국전기안전공사 전기안전연구원 책임연구원

관심분야 : Electrical Safety based on IoT

Phone : +82-63-716-2870

E-mail : tree@kesco.or.kr



**김동우(Dong-Woo Kim)**

1996년 : 인하대학교 전기공학과 학사  
1998년 : 인하대학교 전기공학과 석사  
현재 : 한국전기안전공사 전기안전연구원 선임  
연구원

관심분야 : Smart Evaluation for Electrical Safety  
Phone : +82-63-716-2872  
E-mail : klove@kesco.or.kr



**조성원(Seong-Won Cho)**

1982년 : 서울대학교 학사  
1987년 : Purdue University 석사  
1992년 : Purdue University 박사  
현재 : 홍익대 전자전기공학부 교수

관심분야 : Signal Processing, Pattern Recognition  
Phone : +82-2-3141-9540  
E-mail : swcho@hongik.ac.kr



**진상민(Sang-Min Jin)**

2013년 : 홍익대 전자전기공학부 학사  
2016년 : 홍익대 전기정보제어공학과 석사

관심분야 : Pattern Classification, Neural Network, Signal Processing,  
Phone : +82-2-320-1493  
E-mail : relax38@naver.com