

# 인공지능형 전자식 배전반 시스템의 구현에 관한 연구

이 주 원\* · 이 상 배

A study on hardware implementing the digital switch board system within door using Artificial intelligence.

Ju-Won Lee\* · Sang-Bae Lee

## Abstract

In this paper, the neural network, one of the artificial intelligence scheme, is used to improve the conventional electric switch board. This system is implemented and experimented with hardware. The neural networks used in this paper have two purposes. First, the neural network is used to detect the electrical spark generated from broken insulation of electric wire by decrepit or electrical damage in an electric wire of indoors. Second, the auto regressive neural network is used to predict the electrical load in month so that a management of energy can be administered effectively. The resultant method exhibits higher performance than the conventional method.

## 1. 서 론

오늘날 전자산업의 발달로 사회는 정보화, 고도화, 다양화되고 있으며, 사회 발전에 큰 기여를 하고 있는 분야가 전기(電氣)라고 말할 수 있다. 한편 전기는 인간의 생활에 꼭 필요하지만, 전기 화재, 전력 점침원 및 수리공을 가장한 범죄 등의 많은 재해를 가져오기도 한다. 그리고 경제적인 측면에서 보면 무분별한 전기 사용이 외화 낭비에 대표적이라고 할 수 있으며, 이들 대부분의 문제는 일반 가정의 전력 시스템을 바탕

---

\* 한국해양대학교 전자통신공학과

으로 발생된다고 볼 수 있다. 일반적으로 가정의 전력시스템 관리는 가정용 배전반에서 이루어진다. 따라서 이들 문제들을 예방하기 위해 전자식 배전반 시스템 개발이 필요하다.

그러나 현재의 전자식 배전반 시스템은 가정내의 전력 시스템 상태를 진단하거나 전기화재 예측, 월 수요전력량 예측 등을 할 수 있는 기능이 없다. 현재의 전자식 배전반 시스템에 전기화재 예측기능과 시스템 진단기능, 월 수요전력량 예측기능을 구현하기가 매우 어렵고, 실제로 그 기능을 구현하더라도 그 기능의 처리속도가 고속화가 되어야 되기 때문에 시스템의 가격과 시스템의 부피가 대형화되므로 일반 소비자 측면에서는 맞지 않다. 하지만 이 전자식 배전반 시스템의 단점을 해결할 수 있는 방법은 인간의 지능을 구현한 인공지능 기법을 사용하는 것이다. 인공지능의 방법은 매우 간단하며, 짧은 시간에 빠른 연산을 할 수 있어 전기화재 예측이나 전력량 예측 기능이 없는 일반적인 전자식 배전반 시스템의 단점을 보완할 수 있다. 인공지능 기법들은 여러 가지가 있으나 그 대표적으로 페지논리와 신경회로망이다. 본 연구에서 월 전력량 예측과 전기화재 발생을 예측하기 위한 스파크 검출을 신경회로망을 사용하였다.

## 2. 다층 신경회로망의 구조와 학습

인간의 뇌는 수 많은 뉴런으로 서로 연결되어 있다. 따라서 인간의 뇌와 유사한 인공적인 신경회로망은 다층 구조라 할 수 있고, 서로 연결된 뉴런에 의해서 더욱 더 좋은 성능으로 수행할 수 있다. 일반적으로 더욱 큰 망은 큰 연산 용량을 제공하며, 뉴런을 층에 배열하는 것은 뇌의 일부분인 계층화된 구조를 흉내낸 것이다. 패턴 인식과 시스템 인식, 또는 제어와 같은 응용에서 가장 일반적으로 사용되는 신경회로망은 오류역전파 (Error Back-Propagation) 알고리즘을 갖는 다층 신경회로망이다. 전형적인 다층 신경회로망은 그림 1에 나타내었다.

그림 1에서 각각의 원은 뉴런이다. 이 신경회로망은  $x$ 라는 입력 벡터를 갖는 입력층과  $y$ 라는 출력 벡터를 갖는 출력층으로 이루어지며 입력층과 출력층 사이의 층을 은닉층이라 한다. 오류역전파 학습 알고리즘을 수식적으로 나타내면 다음과 같다.

먼저 입력층, 은닉층, 출력층의 뉴런 출력은 식(2), 식(4), 식(6)과 같다.

$$\text{net}_i = x_i \quad (i = 1, 2, 3, \dots, n) \quad (1)$$

$$O_i = \lambda f [\text{net}_i] \quad (2)$$

$$\text{net}_j = \sum_j W_{ji} O_i \quad (3)$$

$$O_j = \lambda f [\text{net}_j] \quad (4)$$

$$\text{net}_k = \sum_k W_{kj} O_j \quad (5)$$

$$O_k = \lambda f [\text{net}_k] \quad (6)$$

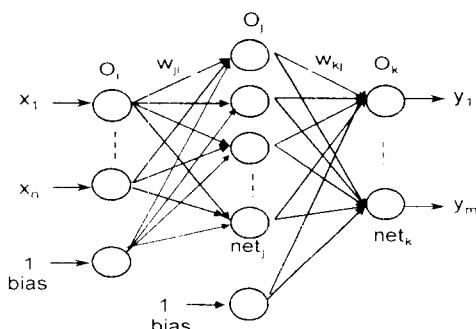


그림 1. 다층 신경회로망의 구조

여기서 사용한  $f$ 는 활성화 함수이며,  $\text{net}_j$ ,  $\text{net}_k$ 는 이전의 뉴런 출력과 현재 층에 있는 웨이트(weight)를 곱을 합산한 값이고  $\lambda$ 는 활성화 함수의 기울기이다. 신경회로망을 학습시키기 위해 신경회로망의 출력값이 바라는 목표값과의 차이인 오차를 구해야 하며 이 오차를 구하는 수식은 식(8)에 나타내었다.

$$E = \frac{1}{2} \sum_k (D_k - O_k)^2 \quad (7)$$

학습의 목적은 웨이트를 조정하여 오차  $E$ 를 최소화하는 것이므로 웨이트의 조정에 대하여 살펴보면 오차를 최소화하기 위해 웨이트를 유의 경사방향(negative gradient direction)으로 변화시켜야 한다. 따라서 각 층에 있는 웨이트 변화량을 구하면 다음과 같다.

여기서  $\eta$ 는 학습 속도를 나타내는 상수이며 이것을 학습률이라 한다. 그리고 활성화 함수  $f$ 가 선형함수라고 가정하면 각 층의 웨이트 변화량은 다음과 같다.

$$\Delta W_{kj} = -\eta \frac{\partial E}{\partial W_{kj}}, \quad \eta > 0 \quad (8)$$

$$\Delta W_{kj} = \eta (D_k - O_k) O_j \quad (9)$$

$$\Delta W_{ji} = -\eta \frac{\partial E}{\partial W_{ji}}, \quad \eta > 0 \quad (10)$$

$$\Delta W_{ji} = \eta(D_k - O_k)W_{ki}O_i \quad (11)$$

$$W_{ji} = W_{ji} + \Delta W_{ji} \quad (12)$$

$$W_{kj} = W_{kj} + \Delta W_{kj} \quad (13)$$

### 3. AR(AutoRegressive) 신경회로망

일반적으로 시계열 자료를 이용하여 미래 예측을 행하는 전통적인 방법으로 Box-Jenkins 방법이 있으며, 대표적으로 AR 모델, MA 모델, ARMA 모델 등이 있다.

신경회로망을 이용한 시계열 예측에서는 AR 모델을 기본하고 있으며, AR 모델은 현재 시간 이전의 관측치와 현재 시간의 예측 오차로 결정되는 모델이며, 모델은 식 (14)로 표현된다.

$$x_t = a_0 + a_1 x_{t-1} + \dots + a_p x_{t-p} + e_t \quad (14)$$

여기서  $x_t$ 는 예측,  $a_0, a_1, \dots, a_p$ 는 예측을 위한 상수,  $e_t$ 는 현재 시간  $t$ 에서 예측 오차이다.

이 모델에서 이전의 데이터인 관측치로 현재의 값을 정확하게 예측하려면 예측을 위한 상수를 알아야 한다. 이 상수를 알기 위해 통계적 방법으로 추정해야하며, 만약 관측치가 비선형적이면 이 상수를 계산하기가 쉽지 않고, 비선형적인 관측에 적응하기 위해 이들 상수도 적응을 해야한다. 이런 관점에서 전례적인 예측 모델에 비선형에 강한 신경회로망을 접목하므로 비선형적인 관측치에 대해 적응할 수 있으며 예측 오차를 전례적인 방법보다 더 나은 결과를 얻을 수 있다.

이 모델은 그림 2와 같은 AR 신경회로망으로 표현된다.

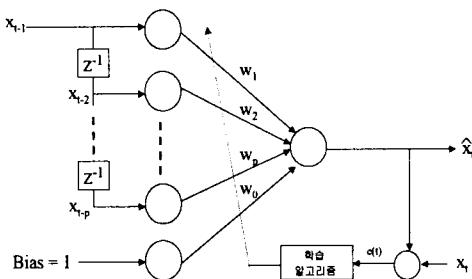


그림 2. AR 신경회로망 모델

여기서  $\hat{x}_t^i$ 는 예측치이며,  $w_p$ 는 신경회로망의 웨이트이다. 그리고 신경회로망의 학습 알고리즘은 오류역전파 알고리즘을 사용한다. 신경회로망의 학습에 의하여 전례적인 AR 모델의 예측 파라미터인 상수  $a_p$ 들을 추정할 수 있다.

예측한 결과를 평가하기 위해 오차의 평균치를 백분율로 환산하여 나타내며, 평균 오차의 백분율  $P_e$ 는 다음의 식(18)로 표현된다.

$$P_e = \frac{1}{N} \sum_{i=1}^N \frac{|x_t^i - \hat{x}_t^i|}{x_t^i} \cdot 100 \quad (18)$$

여기서 N은 예측한 데이터의 총수이고,  $\hat{x}_t^i$ 는 i번째 예측한 값,  $x_t^i$ 는 i번째 바라본 예측치이다.

#### 4. 인공지능형 가정용 배전반 시스템의 구조

인공지능형 전력 겸침기의 구조는 일반적인 전자식 전력량계 및 전자식 차단기와 유사한 구조를 가지게 하였으며, 부하전류, 부하전압, 누설전류의 센서 출력을 입력 변수로 하여 월 수요 전력량을 적산한다.

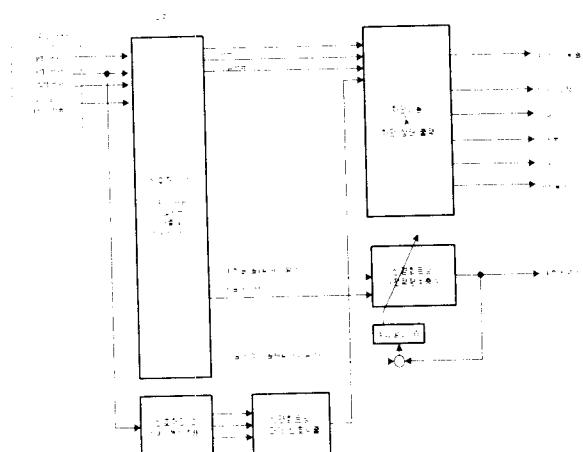


그림 3. 인공지능형 가정용 배전반 시스템의 구조

그리고 부하전류와 누설전류의 변화 상태인 과전류, 단락, 누전에 따라 차단기를 차단하는 기능을 통합함과 동시에 월 수요전력량 예측과 옥내 선로의 결함을 검출하기 위하여 신경회로망을 적용한 것이다.

인공지능형 가정용 배전반 시스템의 구조는 그림 3에 나타내었다.

## 5. 인공지능형 가정용 배전반 시스템의 구현 및 실험

이 시스템의 기능인 전력적산, 차단기능, 통신 기능을 위한 전력 검침기의 하드웨어를 구현한 것을 그림 4에 나타내었고, 주 프로세서는 8비트 마이크로 프로세서인 인텔사의 MCS8051을 사용하였으며, AD변환기(Analog to Digital Converter)는 아날로그 디바이스사의 12비트인 AD574를 사용하였고, 카운터는 인텔사의 i8253을 사용하였다.

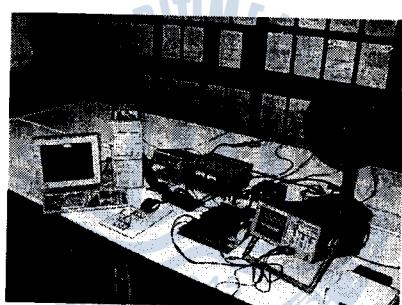


그림 4. 인공지능형 가정용 배전반 시스템의 전체 구성도

### 5.1 일반적인 기능

부하전압, 부하 전류, 누설전류의 디지털값을 측정한 디지털 비트값에 1-비트 양자화값을 곱하여 실제 부하 전압, 부하전류, 누설전류를 구하였다. 그 결과를 표 1에 나타내었다.

표 1. 전력량 연산결과 (시간  $t=1[\text{sec}]$ 인 경우)

부하전압[V]		부하전류[A]		역률		유효 전력량[Wh]	
표준치	측정치	표준치	측정치	표준치	측정치	표준치	측정치
220.0	220.1	0.5	0.499	0.96	0.961	105.6	105.55

과전류 차단기능은 차단기의 정격전류를 3[A]로 설정하여 차단구동 출력을 릴레이(relay)를 통해 차단기 내부의 솔레노이드를 구동시켜 트립(trip)시켰다.

누전차단 기능의 특성은 누전차단기의 정격을 30[mA]로 설정하여 과전류 차단방법과 동일한 방법으로 차단하였다.

## 5.2 스파크 검출 기능

스파크 감출을 위해 입력뉴런 30개, 은닉층 뉴런 4개, 출력뉴런을 1개의 구조인 신경회로망구조를 그림 5에 나타내었고, 신경회로망의 활성화함수는 선형함수를 사용하였다. 그리고 신경회로망을 학습시키기 위해 스파크 입력패턴 추출을 위해 그림 6의 구조로 IBM PC를 이용하여 패턴을 구하였다. 여기서 패턴을 추출하기 위한 샘플링시간 0.01[ms]로 각 부하에 따라 패턴수는 18개로 구하였다.

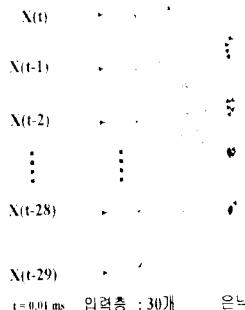


그림 5. 스파크 패턴의 학습을 위한 신경망 구조

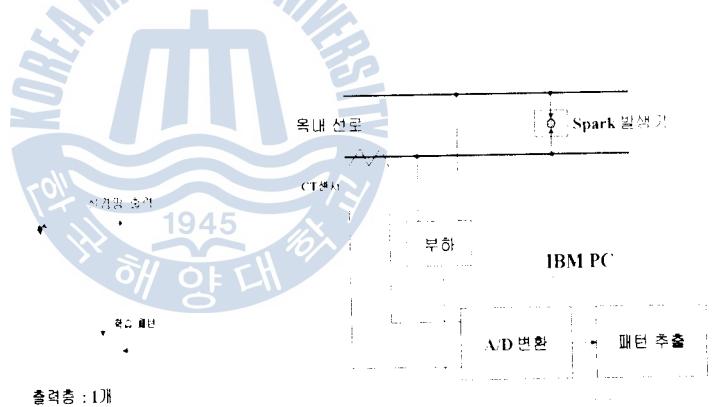


그림 6. 스파크 패턴 추출을 위한 구성도

추출한 스파크패턴은 학습 오차 0.01, 학습률 0.02, 활성화함수의 기울기 0.002, 학습횟수 16791회 때 보다나은 패턴인식 특성을 나타났다.

18개의 스파크패턴으로 학습된 신경회로망의 웨이트를 IBM PC에 그림 7의 신경회로망을 구성하여 임의로 실제 스파크패턴을 5[%] 소금물을 적하하여 발생시켰을 때 부하전류를 신경회로망  $x(t)$ 에 입력한 다음 출력뉴런의 결과에 의해 스파크를 검출하였다.

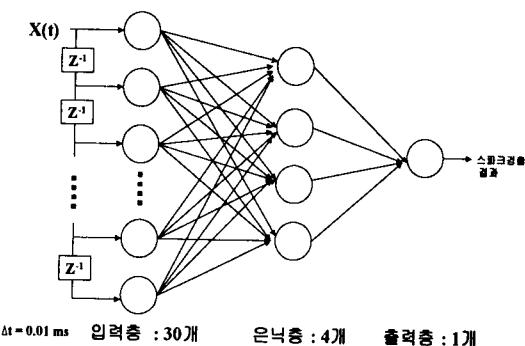


그림 7. 스파크 검출을 위한 신경망 구조

그림 7의 신경회로망에서 스파크검출을 한 결과 뛰어난 검출 성능을 보였고, 부하를 각각 변경했을 때도 스파크검출은 정확하게 검출하였다. 대표적인 결과를 그림 8, 그림 9에 나타내었다. 그림에서 세로 축은 부하전류이고 가로축은 시간이다.

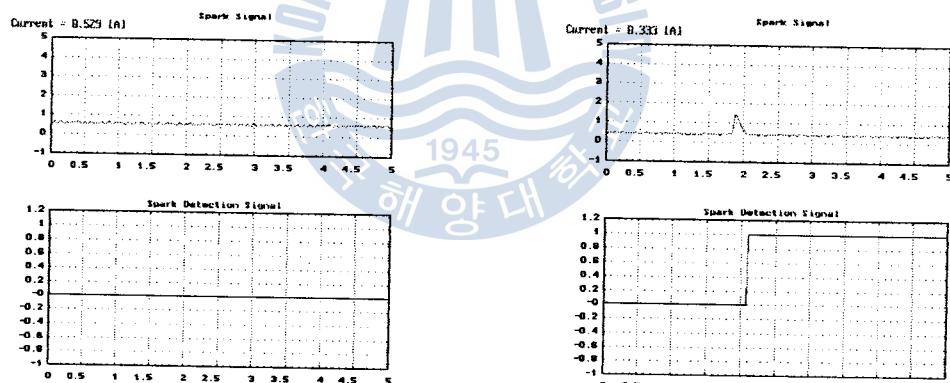


그림 8. 스파크 검출 결과  
(부하:선풍기, 스파크 無)

그림 9. 스파크 검출 결과  
(부하: 선풍기, 스파크: 有)

### 5.3 월 수요 전력량 측 기능

월 수요 전력량 예측을 위해 전력 검침기와 직렬통신하여 IBM 호환 PC는 이전 월의 전력을 수신할 수 있게 하였다. 수신된 전력량과 예측 입력 요소로 하여 입력뉴런 5개, 출력뉴런 1개의 구조를 가진 신경회로망(그림 10)으로 학습하였고, 초기 웨이트를 무작위의 값을 설정하면 예측오차를 줄이기 위한 적응시간이 오래 걸리기 때문에 초

기웨이트를 이전연도 전력량 12개의 데이터를 off-line에서 학습한 뒤 이것을 초기 웨이터로 하였다. 예측평가를 위해 1998년 에너지 통계 년보의 수용가 전력 데이터(1991~1997년)를 이용하였다. 그리고 이 초기 웨이트로 월 전력 예측을 on-line 예측 및 학습한 결과인 평균 예측 오차율이 0.93[%]의 우수한 성능을 나타내었다.

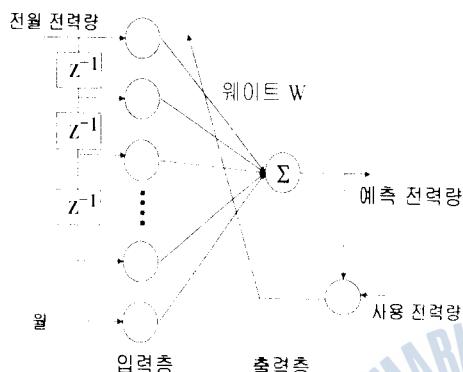


그림 10. 전력량 예측을 위한 신경망  
구조

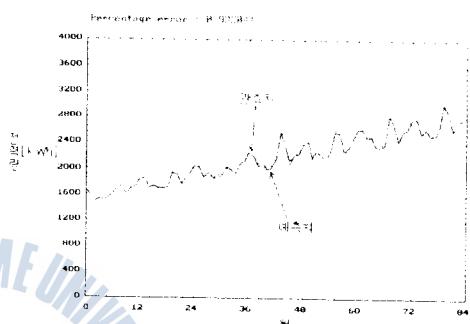


그림 11. 월 수요전력량 예측 결과

## 6. 결 론

본 연구에서 시스템 구현과 신경회로망을 이용하여 옥내선로의 결합을 추정할 수 있는 선로상의 소파크 검출을 정확한 결과를 얻을 수 있었고, 월 수요전력량을 신경회로망을 이용함으로서 보다 나은 예측성능을 얻었다.

본 논문의 응용범위는 가정용 배전반 시스템 뿐만 아니라 자가 변전시스템에서도 응용되어 효율적인 에너지관리와 전기시설의 결합을 사전에 검출할 수 있으리라 본다.

## 참고 문헌

- [1] Chin-Teng Lin, C.S.George Lee, "Neural Fuzzy Systems", Prentice Hall, Inc., 1996.
- [2] 최태원, "신경회로망을 이용한 옥내배선의 트랙킹 식별에 관한 연구", 경남 대학교 박사 학위논문, 1995.
- [3] T.W.S.Chow, C.T.Leung, "Nonlinear autoregressive integrated neural network model for short term load forecasting", IEE Proc.-Gener. Transm. Distrib, vol. 143, No 5. September 1996.

