

인공지능형 가정용 배전반 시스템의 구현

이 주 원 · 이 상 배

A study on implementation of Artificial Intelligence Digital Switch Board System

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.

제 1 장 서 론

오늘날 전자산업의 발전으로 사회는 정보화, 도시 기능의 고도화, 다양화되고 있으며, 산업 사회의 발전에 큰 기여를 하고 있는 분야 중의 하나가 전기(電氣)라고 말해도 과언이 아니다. 그러나 전기는 많은 이점을 제공함으로 인하여 꼭 필요하지만, 전기 화재, 감전사고, 전력 점침 원 및 수리공을 가장한 범죄 등의 많은 재해를 가져오기도 한다. 그리고 경제적인 측면에서 보면 무분별한 전기 사용으로 인하여 외화 낭비를 초래할 수도 있으며, 이를 문제의 대부분은 일반 가정의 전력 시스템에서 발생한다고 볼 수 있다. 근본적으로 가정의 전력시스템 관리는 가

정용 배전반에서 이루어 진다. 따라서 이를 문제들을 예방하기 위해 전자식 배전반 시스템 개발이 필요하다.

그러나 현재의 가정용 배전반 시스템은 기계식 전력량계, 차단기, 누전 차단기 등으로 이루어져 있으며, 기계식 전력량계는 부하전류, 부하전압, 역률을 자장의 세기로 변환하여 기계식 바퀴로 계수하기 때문에 정밀도가 낮고, 월 전력량을 매달 한번씩 검침원이 직접 검침해야 하므로 생산직 근로자의 고 임금 추세에 따른 생산원가 절감, 생산성 향상, 전력 검침 및 수리를 가장한 범죄의 범죄예방이란 측면에서 관찰하면 합리적이지 않다. 이러한 문제들을 해결하기 위해서 최근 전자식 배전반을 여러 기업체에서 개발하여 상용화하고 있다. 전자식 배전반의 기능은 마이크로 프로세서를 이용하여 전압, 전류, 위상 등의 아날로그 신호를 디지털 신호처리한 후 연산을 수행하고, 연산 처리 결과인 적산 전력을 원격으로 검침할 수 있으며, 또한 차단 기능을 프로그램으로 개발하여 계절에 따른 대기 온도에 의해 차단기 특성변화에서도 과전류와 누전을 방지할 수 있게 하여 전력관리에 상당한 효율개선과 높은 신뢰도를 제공하고 있다. 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 구현하기는 매우 어렵고, 실제로 그 기능을 구현하더라도 시스템의 가격과 시스템의 부피가 대형화되기 때문에 일반 소비자 측면에서는 합리적이지 않다. 이와 같은 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 대표적으로 퍼지 논리와 신경회로망이다. 퍼지 논리는 인간의 추론 방법을 구현하기 때문에 인간의 지능을 표현하기가 매우 쉽고 복잡한 환경에서도 그 성능은 우수하다^[2]. 신경회로망은 패턴인식과 예측능력이 매우 뛰어나며, 그 능력은 여러 논문에서 입증되었다^[1].

본 연구에서는 월 전력량 예측과 전기화재 발생을 예측하기 위한 스파크 검출에 신경회로망을 사용하였다. 본 논문의 구성을 살펴보면 제 2장에서는 신경회로망의 개요, 학습 알고리즘 설명 그리고 패턴인식의 신경회로망 모델과 신경회로망을 이용한 예측모델을 논의하였다. 그리고 제 3장에서는 일반적인 가정용 배전반 시스템과 인공지능형 가정용 배전반 시스템의 구조와 하드웨어 구조를 제시하였다. 그리고 제 4장에서는 인공지능형 가정용 배전반 시스템을 구현하고 실험을 한 후 그 결과를 나타내었으며, 끝으로 제 5장에서는 결론을 서술하였다.

제 2 장 신경회로망의 일반적인 개요와 학습 알고리즘

2.1 다층 신경회로망의 구조와 학습

인간의 뇌는 수많은 뉴런으로 서로 연결되어 있다. 따라서 인간의 뇌와 유사한 인공적인 신경회로망은 다층 구조라 할 수 있고, 서로 연결된 뉴런에 의해서 더욱 더 좋은 성능을 발휘할 수 있다. 일반적으로 신경회로망이 크면 클수록 더 큰 연산 용량을 필요로 한다. 뉴런을 층에 배열하는 것은 뇌의 일부분인 계층화된 구조를 흡내낸 것이다. 패턴 인식과 시스템 인식, 또는 제어와 같은 응용에서 가장 일반적으로 사용되는 신경회로망 구조는 오류 역전파(error back-propagation) 알고리즘을 갖는 다층 신경회로망(Multi layered neural network)이다. 전형적인 다층 신경회로망은 그림 1에 나타내었다.

그림 1에서 각각의 원은 하나의 뉴런들을 나타낸다. 이 신경회로망은 x 라는 입력 벡터를 갖는 입력층과 y 라는 출력 벡터 갖는 출력층으로 이루어지며 입력층과 출력층 사이의 층을 우리는 보통 은닉층(hidden layer)이라 한다. 여기서 O_i , O_j , O_k 는 입력층, 은닉층과 출력층들의 각 뉴런 출력이고, 입력층과 은닉층 사이의 웨이트를 W_{ji} , 은닉층과 출력층 사이의 웨이트를 W_{kj} 로 표기한다. 모든 정보는 신경회로망의 웨이트에 저장되며, 학습과정 동안 웨이트 W_{ji} , W_{kj} 의 성분은 계속적으로 새로운 정보로 바뀌어 진다.

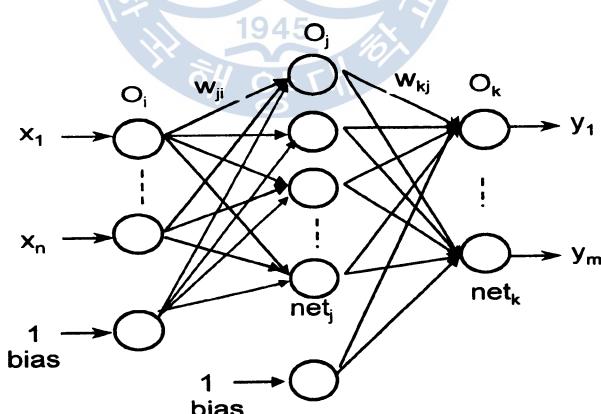


그림 1. 다층 신경회로망의 구조

일반적으로 새로운 정보를 변경하는 신경회로망의 대표적인 알고리즘은 오류 역전파 알고리즘이다. 오류 역전파 알고리즘은 신경회로망의 각 뉴런에 의해 계산된 최종 출력층 뉴런의 출력과 바라는 출력사이의 오차를 자승하여 최소화시키는 최소평균자승법(least-mean square)이다.

오류 역전파 학습 알고리즘의 원리는 먼저 입력층에서는 신경회로망의 입력 x 를 은닉층으로 보낸다. 두번째로 은닉층의 뉴런들은 각각의 입력층으로부터 입력된 값과 웨이트들의 곱을 합

산합과 동시에 활성화함수를 통해 연산된 결과를 출력층으로 보낸다. 출력층은 은닉층과 같은 뉴런 연산을 하여 출력한다. 이 때 신경회로망의 출력값과 바라는 목표값과의 차이를 구하여, 이 차를 오차라고 말한다. 이 오차를 최소화하기 위해 각 층에 있는 웨이트의 오차 벡터함을 편미분하여 웨이트를 조정한다. 다시 말해 출력층의 출력과 바라는 목표값의 오차를 구한 후 출력층에서 은닉층으로, 은닉층에서 입력층으로 역전파하여 오차에 따른 웨이트 변화량에 의해 웨이트들을 조정하며 이것을 오류 역전파라고 말한다.

오류 역전파 학습 알고리즘을 수식적으로 나타내면 다음과 같고, 먼저 입력층, 은닉층, 출력층의 뉴런 출력은 (2), (4), (6)과 같다.

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

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

$$\text{net}_j = \sum_k W_{kj} O_i \quad (3)$$

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

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

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

여기서 사용한 f 는 활성화 함수이며, net_i , net_j , net_k 는 이전의 뉴런 출력과 현재 층에 있는 웨이트들과의 곱을 합산한 값이고 λ 는 활성화 함수의 기울기이다. 신경회로망을 학습시키기 위해 신경회로망의 출력값과 바라는 목표값과의 차인 오차를 구해야 하며 이 오차를 구하는 수식은 (7)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 음의 기울기방향(negative gradient direction)으로 변화시켜야 한다. 따라서 웨이트 변화를 음의 기울기 방향으로 오차에 대한 웨이트의 방향 벡터를 편미분함으로써 웨이트 변화량을 구할 수 있다. 각 층에 있는 웨이트 변화량을 구하면 다음과 같다.

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

여기서 η 는 학습 속도를 나타내는 상수이며 이것을 학습률이라 한다. 그리고 (8)을 연쇄 규칙(chain rule)을 사용하여 아래와 같이 간단하게 쓸 수 있다.

$$\begin{aligned}\frac{\partial E}{\partial W_{kj}} &= \frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial net_k} \frac{\partial net_k}{\partial W_{kj}} \\ &= \frac{\partial \frac{1}{2}(D_k - O_k)^2}{\partial O_k} \frac{\partial f(net_k)}{\partial net_k} \frac{\partial W_{kj}O_j}{\partial W_{kj}}\end{aligned}\quad (9)$$

여기서, 활성화 함수 f 가 선형함수라고 가정하면, 웨이트 변화량 ΔW_{kj} 는 다음의 식과 같다.

$$\Delta W_{kj} = \eta(D_k - O_k)O_j \quad (10)$$

은닉층에 대한 웨이트의 변화량도 오차를 최소화하기 위해 웨이트를 음의 기울기 방향으로 변화시켜 준다.

$$\Delta W_{ji} = -\eta \frac{\partial E}{\partial W_{ji}}, \quad \eta > 0 \quad (11)$$

(11)을 연쇄 규칙을 사용하여 아래와 같이 간단하게 쓸 수 있다.

$$\begin{aligned}\frac{\partial E}{\partial W_{ji}} &= \frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial net_k} \frac{\partial net_k}{\partial O_j} \frac{\partial O_j}{\partial W_{ji}} \\ &= \frac{\partial \frac{1}{2}(D_k - O_k)^2}{\partial O_k} \frac{\partial f(net_k)}{\partial net_k} \frac{\partial W_{kj}O_j}{\partial O_j} \frac{\partial W_{ji}O_i}{\partial W_{ji}}\end{aligned}\quad (12)$$

(12)에 의해 입력층과 은닉층사이에 있는 웨이트의 변화량은 다음의 식으로 나타내어진다.

$$\Delta W_{ji} = \eta(D_k - O_k)W_{ki}O_i \quad (13)$$

따라서 웨이트의 변화는 다음과 같다.

$$W_{ji} = W_{ji} + \Delta W_{ji} \quad (14)$$

$$W_{kj} = W_{kj} + \Delta W_{kj} \quad (15)$$

신경회로망을 학습시킬 때 초기 웨이트는 작은 무작위 값으로 설정하고 이런 초기화는 최종 출력에 영향을 미치므로 보통 일반적으로 초기 웨이트는 -0.5에서 0.5사이의 값을 주로 사용한다. 그리고 오류 역전파 알고리즘의 수렴 정도는 학습률에 의해서도 달라질 수 있다. 학습률은 신경회로망의 구조와 응용 목적에 따라 각각 달리 선택되고 일정한 기준이 없으며 보통 0에서 1사이의 값을 사용한다. 만약 큰 학습률을 사용하면 오버슈트가 일어날 수 있고 작은 학습률을 사용하면 학습속도가 느려질 수 있으므로 위에서 제시한 범위 내에서 적절히 선택해야 한다.

2.2 시간 지연 신경회로망(Time-Delay Neural Network)

음성신호, 측정된 신호파형, 제어신호 등을 샘플링하면 이산시간 수열의 형태로 표현된다.

이산시간 수열로 나타난 입력신호에 대하여 출력응답을 나타내기 위해 신경회로망의 입력에 시간적인 지연요소를 포함하여야 한다. 그러기 위해 개개의 이산 신호의 샘플에 대하여 신경회로망의 입력에 시간지연요소 z^{-1} 를 부가하여 그 변화를 학습하는 방법의 신경회로망이 시간 지연 신경회로망(TDNN : Time-Delay Neural Network)이다.

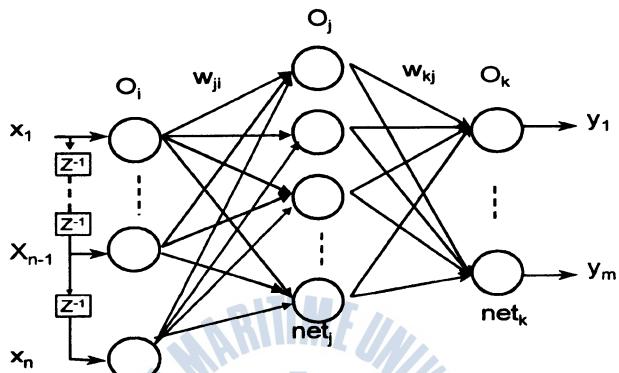


그림 2. 시간 지연 신경회로망의 구조

시간 지연 신경회로망은 디지털 신호처리에서 필터로 사용되는 FIR 필터(Finite Impulse Response Filter)의 구조와 유사하며 그 구조는 그림 2에 나타내었고, 일반적으로 학습은 오류 역전파 학습방법을 사용한다. 여기서 신경회로망의 입력벡터는 $[x_1, x_2, \dots, x_{n-1}, x_n]$ 이다. 시간지연 신경회로망은 주로 패턴인식, 음성인식, 시간에 따른 데이터 변화 예측, 플랜트 제어 등에 많이 사용되고 있으며 본 연구에서는 전기 스파크 신호를 검출하는데 사용하였다.

2.3 자동회귀 신경회로망(Auto Regressive Neural Network)

실세계의 정보환경과 과학기술은 급격히 발전하고 있으며 모든 학문분야에서는 불확실성을 포함한 현실적인 문제들을 가능한 빨리 근접한 해를 얻고자 노력하고 있다. 특히 시계열 예측 문제에서는 관측치로부터 불확실성 및 복잡도가 높아 주어진 문제 해결을 위한 정형화된 예측 방법을 얻는 것은 어려운 것으로 알려져 있다. 그러나 과거의 축적된 지식과 경험을 바탕으로 다가올 미래 상황을 예측하는 문제는 실세계에 산재해 있어 연구되어야 할 과제이다. 주어진 문제의 관측치로부터 문제 현상을 나타내는 결정 방정식을 알 수 있다면 현재의 관측치로부터 다음 미래사황을 예측할 수 있다. 그러나 결정방정식을 알 수 없다면 시스템의 행위변화와 현재 상태정보로부터 미래 변화를 알아내는 방법이 필요하다. 이를 위해 지금까지 개발된 산업 및 기업의 시계열 예측 및 진단 모델들은 전통적 통계 기법에 두고 있다. 일반적으로 시계열 자료를 이용하여 미래 예측을 행하는 전통적인 방법으로 Box-Jenkins 방법이 있으며, 대표적으로 자동회귀 모델, 이동평균 모델, 자동회귀 이동 평균 모델 등이 있다^[21].

그러나 통계적 시계열 분석에 근거한 예측 및 판단은 관측치 변화에 대한 적응이 어려우며, 자료가 갖는 분포에 대한 가정이 전제되어야 하고, 계량적인 변화와 정성적인 변수가 혼합되어 있는 경우는 성과가 좋지 않다. 그 이유는 단순회귀 또는 다중 회귀 모델, 연립방정식, 단일 다변량 모델 및 상태 공간 모델들에 근거하기 때문에 모델의 비적용성, 제약적인 가정의 요구, 처리의 복잡성 및 예측의 비정확성등의 단점들이 존재한다. 이러한 단점을 보완하기 위해 주로 인공 지능 기법의 장점을 이용하여 예측 오차 개선과 비선형적인 시계열에 적응하여 예측하는 모델에 관한 연구가 활발히 진행되고 있다.

신경회로망을 이용한 시계열 예측에서는 자동회귀 모델을 기본하고 있으며, 자동회귀 예측 모델은 현재 시간 이전의 관측치와 현재 시간의 예측 오차로 결정되는 모델이다. 자동회귀 예측 모델에 대한 모델 식은 (16)으로 표현된다.

$$x_t = a_0 + a_1 x_{t-1} + a_2 x_{t-2} + \dots + a_p x_{t-p} + e_t \quad (16)$$

여기서 x_t 는 예측치, a_1, a_2, \dots, a_p 는 예측을 위한 상수, e_t 는 이전의 관측치 $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ 와 현재 시간 t 에서 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 쉽지가 않다. 따라서 예측은 비선형적인 관측에 적응하기 위해 이들 상수도 적응을 해야한다. 이런 관점에서 전통적인 예측 모델에 신경회로망을 접목함으로써 비선형적인 관측치에 대해 적응할 수 있으며 예측결과는 전통적인 방법보다 더 나은 결과를 얻을 수 있다.

이 모델을 신경회로망으로 구현하면 시간지연 신경회로망과 유사하고 단층 신경회로망의 구조를 가진 자동회귀 예측 신경회로망은 그림 3으로 표현된다.

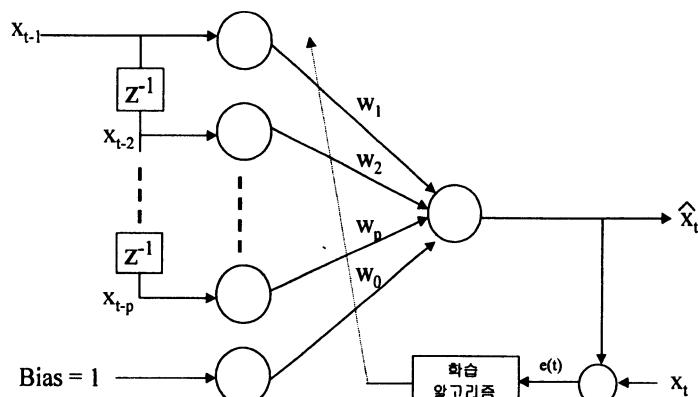


그림 3. 자동회귀 예측 신경회로망의 구조

여기서 \hat{x}_t^i 는 예측치이며, w_p 는 신경회로망의 웨이트이다. 그리고 신경회로망의 학습 알고리즘은 오류 역전파 알고리즘을 사용한다. 신경회로망의 학습에 의해 전통적인 자동회귀 모델의 예측 상수 a_p 들을 추정할 수 있다. 즉, 신경회로망의 웨이트 w_p 는 a_p 가 되는 것이다.

예측한 결과를 평가하기 위해 오차의 평균치를 백분율로 환산하여 나타내며, 평균 오차의 백분율 P_e 는 다음의 식(17)으로 표현된다.

$$P_e = \frac{1}{N} \sum_{i=1}^N \frac{|x_t^i - \hat{x}_t^i|}{x_t^i} \times 100 \quad (17)$$

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

제 3 장. 인공지능형 가정용 배전반 시스템의 구조

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

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.

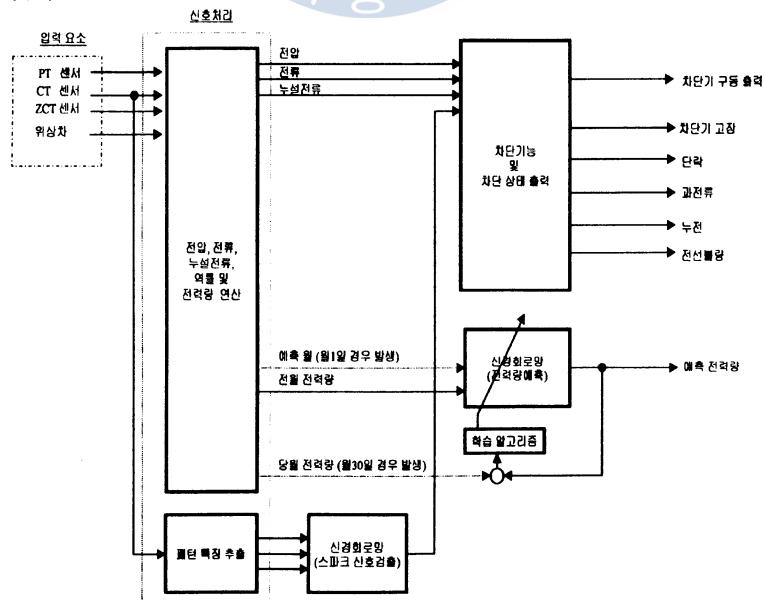


그림 4. 인공지능형 가정용 배전반 시스템의 구성도

인공지능형 가정용 배전반 시스템의 구조는 그림 4에 나타내었다.

3.1 스파크 신호 분석

인입된 두 선로는 옥내의 내선으로 시설된다. 이 두 선로는 장기간의 사용으로 노후화 옥내 내선 공사 중에 발생하는 전선의 피복 손상 및 부하전류에 따른 전선 재질 변화로 선로간의 절연파괴가 이루어진다. 이 절연 파괴로 인한 두 선로간에 습기와 먼지에 의해 스파크(불꽃) 발생으로 화재의 발생가능성이 높다. 따라서 두 선로간의 스파크 발생을 검출하기 위해 부하전류 파형의 진폭 특징을 추출한다. 그리고 발생한 스파크 신호를 분석하기 위해 부하의 유형에 따라 선로의 피복 손상부에 5[%] 농도의 식염수를 적하할 경우에 부하전류를 측정하였으며, 측정된 부하전류 신호는 그림 5, 그림 6, 그림 7, 그림 8에 나타내었다. 측정된 부하전류 신호를 분석하면 스파크 발생의 주파수 대역은 대략 500[Hz] 안에 큰 에너지를 가지는 특성을 알 수 있었다.

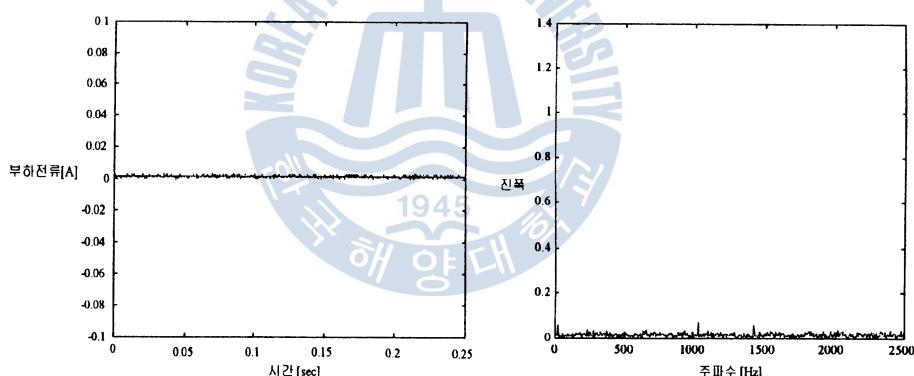


그림 5. 무부하 전류파형 및 주파수 스펙트럼(스파크 無)

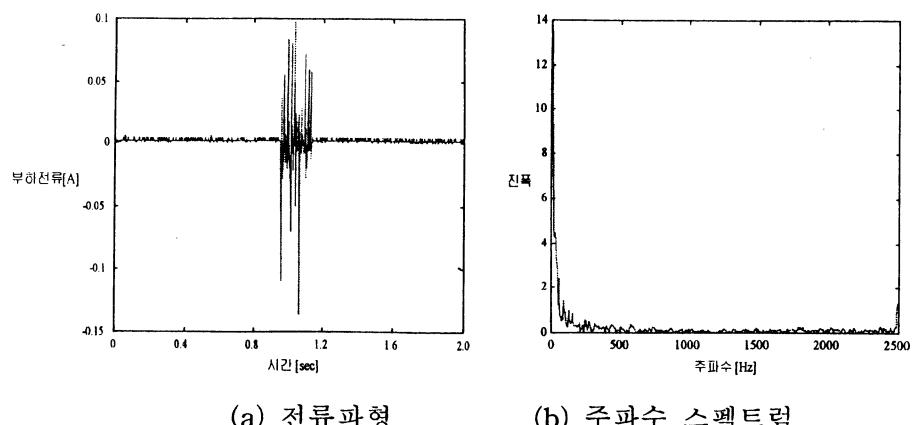


그림 6. 무부하전류 파형 및 주파수 스펙트럼(스파크 有)

스파크 검출을 위해 스파크 신호를 주파수 영역에서 진폭을 추출하여 신경회로망으로 인식할 수 있으나, 스파크 신호가 매우 짧은 임펄스 신호이고, 주파수 영역에서 진폭의 특징들을 마이크로 프로세스로 연산하기에는 많은 시간이 소요된다. 따라서 이런 어려운 점을 극복하기 위해 본 논문에서는 저속의 마이크로 프로세서에서도 스파크 검출이 가능하게 스파크 신호를 반파경류와 적분하여 스파크 신호의 변화를 저속화하고 스파크 신호의 포락선을 얻을 수 있게 하였고, 이 포락선을 패턴으로 하여 스파크를 검출하였다.

스파크 신호 패턴은 신경회로망의 학습을 통해 인식한 후 학습된 다음에 신경회로망의 정보를 이용하여 실제 선로 상에 스파크 발생을 검출하며, 검출된 신호는 차단기능에 입력시킨다. 차단기는 이 신호를 받아 차단시키고, 이 신호를 전선 결함으로 추정하여 관리자에게 알린다.

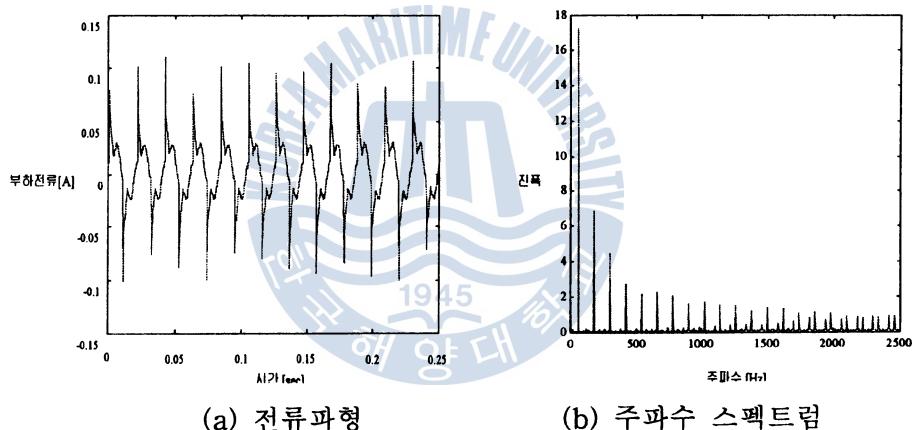


그림 7. 부하전류(선풍기+형광등) 파형 및 주파수 스펙트럼(스파크 : 無)

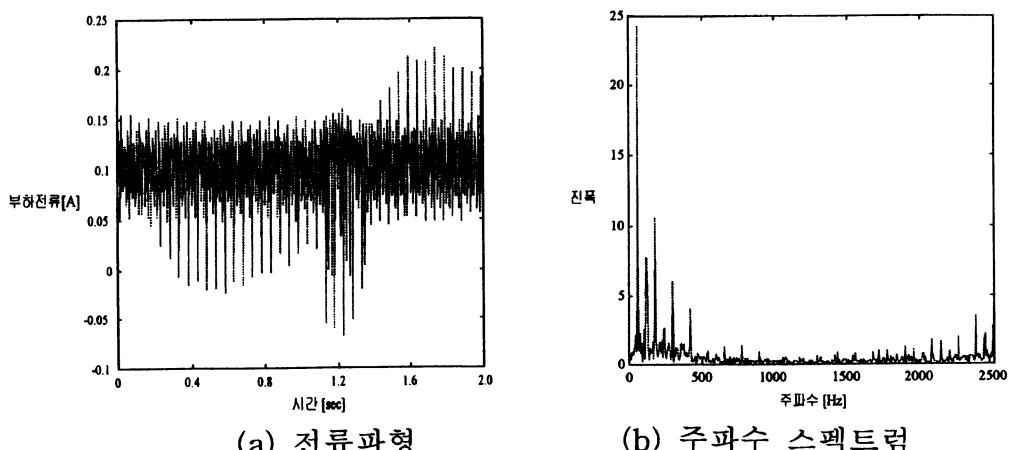


그림 8. 부하전류(선풍기+형광등) 파형 및 주파수 스펙트럼(스파크 : 有)

3.2 월 수요전력량 예측 기능

수요 전력량 예측은 전력 설비의 에너지 관리, 유지·보수, 증설 등의 측면에서 매우 중요한 역할을 한다. 각 가정에서 월간 사용되는 수요 전력량을 예측을 하기 위한 이 기능은 지난 월에 대한 부하 전력과 현재 월의 부하전력에 의하여 다음 월에 사용할 전력량을 예측한다. 다음 월의 부하 전력량을 예측하기 위해 자동회귀 예측 신경회로망 모델을 사용한다.

제 4 장. 인공지능형 가정용 배전반 시스템의 구현 및 실험

본 장에서는 3장에서 필요한 기능을 구현하기 위한 하드웨어적인 구조를 설명한 것이다. 이 시스템의 기능인 전력 적산, 차단기능, 통신 기능을 위한, 주 프로세서는 8비트 마이크로 프로세스인 인텔사의 MCS8051을 사용하였으며, AD변환기(Analog to Digital Converter)는 아날로그 디바이스사(Analog Device Company)의 AD574를 사용하였고, 카운터는 인텔사의 8253을 사용하였다.

구성된 시스템은 그림 9, 그림 10에 나타내었으며, 이 시스템을 이용하여 실험한 결과를 다음의 항목에 나타내었다.

전력 적산은 1초의 60번으로 부하전류와 부하전압, 역률을 측정하여 연산하였으며 이 연산의 결과는 유효 전력량이 나타나게 하였다. 적산 전력량 유효전력량을 계속 누적하여 구하였다.

여기서 부하전압과 부하전류를 1초에 60번을 측정하기 위해 60Hz 주파수 발생기로부터 출력되는 펄스에 의해 마이크로 프로세서는 인터럽트(interrupt)를 받게 하였고, 마이크로 프로세서의 인터럽트 처리를 전력적산 알고리즘으로 처리하였다.

부하전압, 부하전류, 누설전류의 디지털값을 측정하기 위해 12-비트 AD변환기를 사용했고, 이때 1 비트에 대응하는 양자화 값이 2.44[mV]이므로 측정된 부하전압의 디지털값에 244[mV]를 곱하여 실제 부하전압을 얻었고, 부하전류는 측정된 디지털 값에 2.44[mV]를 곱하고, 누설전류는 0.244[mV]를 곱하여 실제 부하전류와 누설전류를 구하였다. 그 결과를

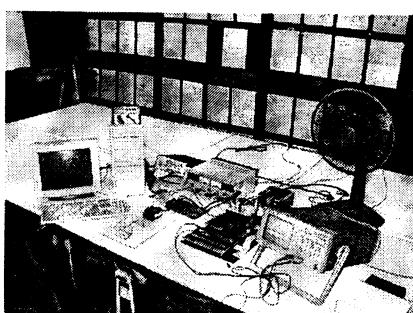


그림 9. 인공지능형 가정용 배전반 시스템

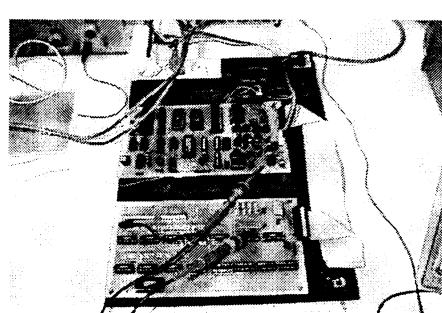


그림 10. 센서회로, 디스플레이회로 및 마이컴
실험장치

표1에 나타내었다.

표 1. 전력량 연산 결과 (시간 t가 1[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

그리고 차단기능은 KS 차단기 규격에 의해 차단 알고리즘으로 프로그램 되었고, 부하전류를 1[ms] 간격으로 증가시켜 그때의 부하전류가 차단기의 정격전류 3[A]보다 크면 차단 시간을 누적하였으며, 그 누적된 값이 KS 규격의 차단기 정격에 따른 값일 때 차단기의 차단과 함께 차단원인을 디지털 출력포트로 출력하며, 차단출력 신호로 차단기의 솔레노이드를 구동시켜 차단기를 트립(trip)시켰다. 누전 차단 기능의 특성은 누전차단기 정격을 30[mA]로 설정하여 차단 한 결과 양호한 차단특성을 가졌다.

차단기 고장 여부는 차단기가 차단 신호를 받은 시간부터 1초 후에 계속해서 부하전압이 들어오면 차단기 고장으로 간주하여 차단기 고장을 표시하였다.

4.1 스파크 검출 기능

스파크 검출을 위해 입력 뉴런 30개, 은닉층 뉴런 4개, 출력 뉴런이 1개인 신경회로망이 구조는 그림 11과 같고, 신경회로망의 활성화 함수는 선형함수를 사용하였다. 그리고 신경 회로망을 학습시키기 위한 스파크 패턴 추출은 그림 12의 구조로 IBM PC를 이용하여 패턴을 구하였다. 여기서 패턴을 추출하기 위한 샘플링 시간(sampling time)은 0.01[ms]로 하였고, 학습하기 위한 패턴 수는 18개를 구하였다.

패턴을 추출할 때 부하를 선풍기, 냉장고, 형광등을 사용하였으며, 대표적인 스파크 패턴을 그림 13, 그림 14, 그림 15, 그림 16에 나타내었다.

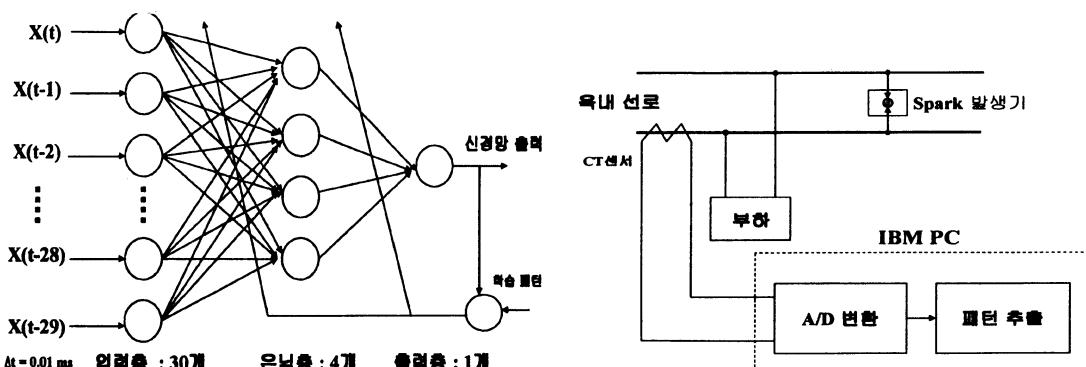


그림 11. 스파크 패턴의 학습을 위한 신경망 구조

그림 12. 스파크 패턴 추출을 위한 구성도

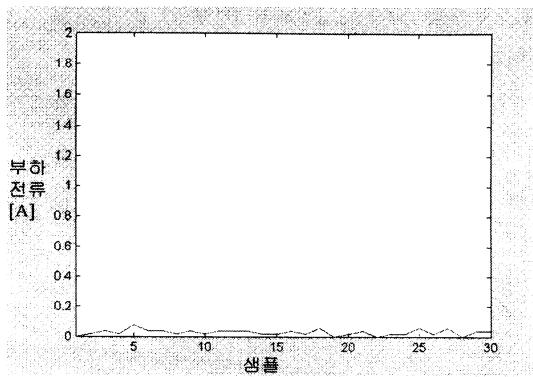


그림 13. 전류파형(부하 : 무부하, 스파크 : 無)

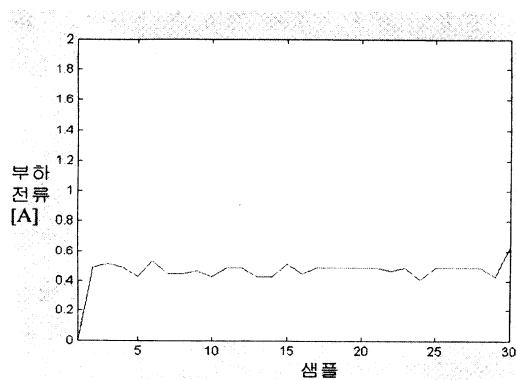


그림 14. 전류파형(부하 : 선풍기, 스파크 : 無)

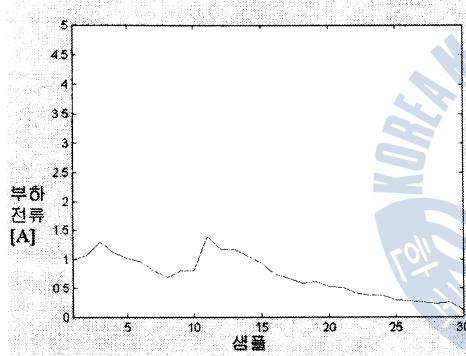


그림 15. 전류파형(부하 : 무부하, 스파크 : 有)

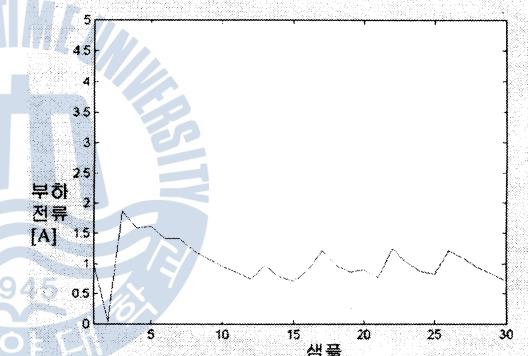


그림 16. 전류파형(부하 : 선풍기, 스파크 : 有)

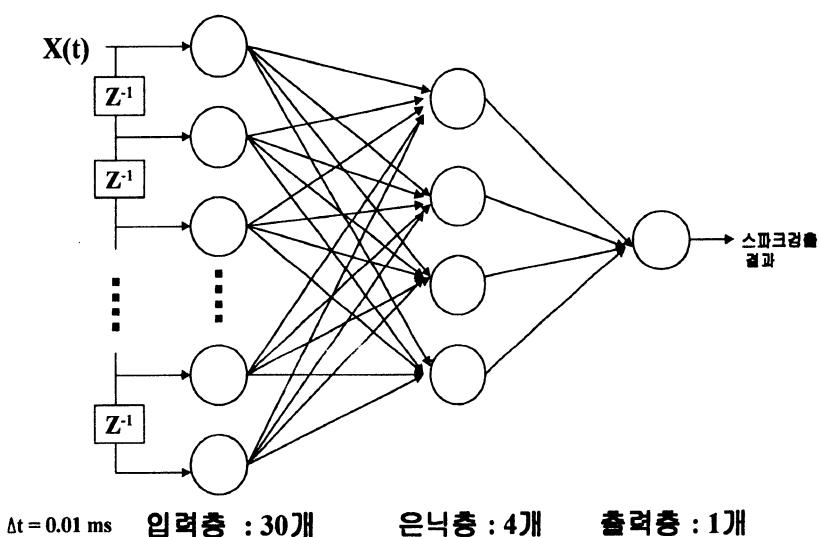


그림 17. 스파크 검출을 위한 신경망 구조

추론한 스파크 패턴을 학습 오차 0.01, 학습률 0.02, 활성화 함수의 기울기 0.002인 신경회로망으로 학습한 결과, 학습횟수 16791일 때 우수한 패턴인식 특성을 나타내었다.

18개의 스파크 패턴으로 학습된 신경회로망의 웨이트를 IBM PC에 그림 17의 신경회로망으로 구성하였다. 실제 스파크 패턴을 농도가 5[%]의 소금물을 적하하여 발생시켰을 때 부하전류를 신경회로망 $x(t)$ 에 입력한 다음 출력 뉴런의 결과에 의해 스파크를 검출하였다.

그림 17의 신경회로망에서 스파크를 검출한 결과 뛰어난 검출 성능을 보였고, 부하를 각각

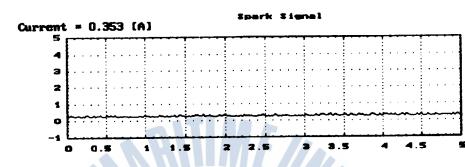


그림 18. 무부하, 스파크 無

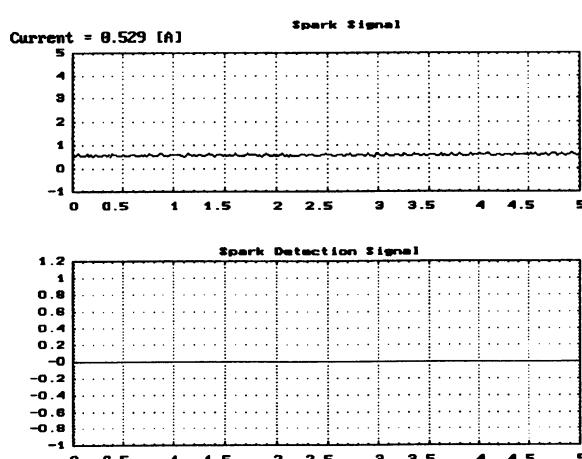


그림 19. 부하(선풍기), 스파크 無

변경했을 때도 스파크를 정확하게 검출하였다. 대표적인 결과를 그림 18, 그림 19, 그림 20, 그림 21에 나타내었다.

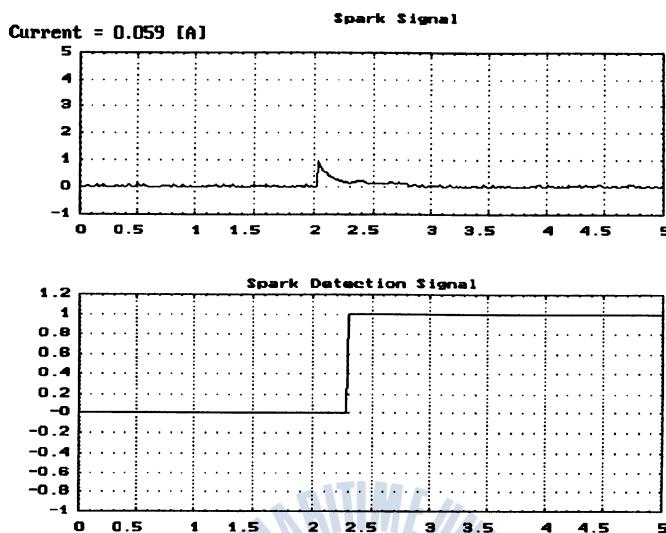


그림 20. 무부하, 스파크 行

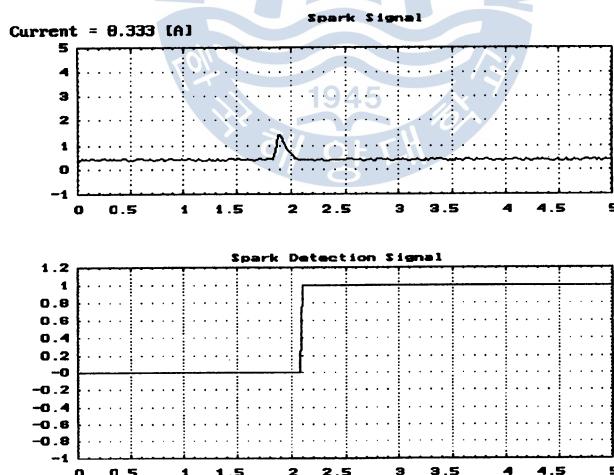


그림 21. 부하(선풍기), 스파크 行

4.2 월 수요전력량 예측 기능

월 수요전력량 예측을 위해 전력 검침기와 직렬 통신하여 IBM 호환 PC는 이전 월의 전력을 수신할 수 있게 하였다. 수신된 전력량과 예측할 월을 입력요소로 하여 입력뉴런 5개, 출력뉴런 1개의 구조를 가진 신경회로망으로 학습하였고, 신경회로망 학습의 초기 웨이트를 무작위의 값으로 설정하면 예측 오차를 줄이기 위한 적응 시간이 오래 걸리기 때문에 초기 웨이트를 이

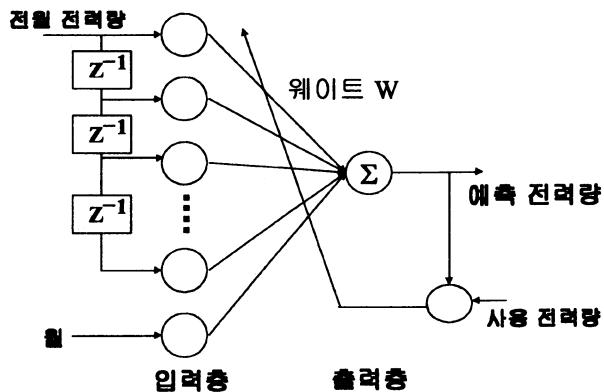


그림 22. 전력량 예측을 위한 신경망 구조

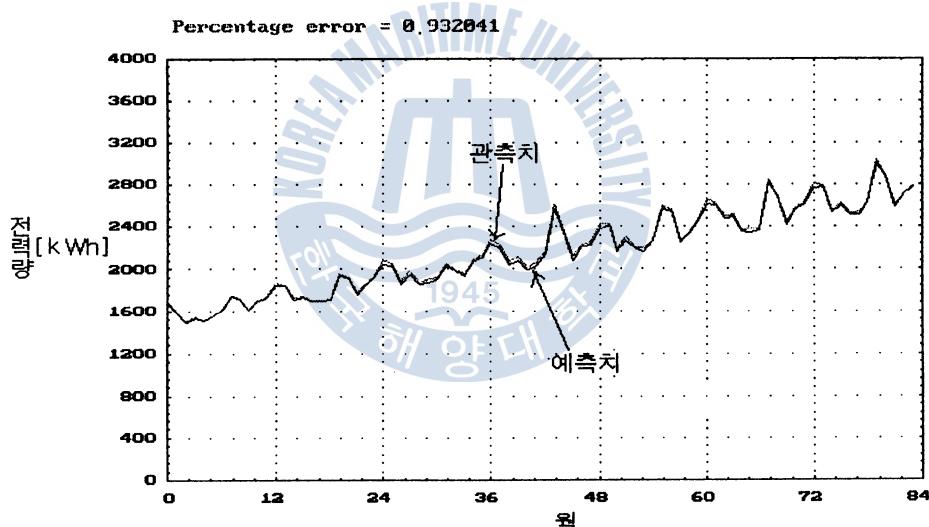


그림 23. 전력량 예측 결과

전 연도 전력량 12개의 데이터를 off-line에서 학습한 뒤 초기 웨이트로 하였다. 그리고 학습률 0.4, 활성화 함수의 기울기 0.05로 설정하여 on-line으로 예측하고 학습하였다. 또한 예측은 월 초에 예측하고 학습은 월말에 학습하였으며, 학습과 예측을 위한 신경회로망 구조는 그림 22와 같다.

그림 22의 구조를 이용하여 월 전량을 예측하기 위해 1998년 에너지 통계 연보의 수용가 전력량 데이터를 이용하여 평가하였는데, 그 결과 평균예측 오차율이 0.93[%]로 뛰어난 성능을 보였다(그림 23).

제 5 장 결 론

본 논문에서는 현재의 가정용 배전반 시스템의 문제점을 개선하기 위해 배전반 시스템에 인공지능의 기법 중 하나인 신경회로망을 도입하여 옥내 전선 선로의 결함으로 나타나는 절연 퍼복 손상에 의한 스파크를 검출하여 전기 화재 발생을 미연에 방지할 수 있음을 확인하였다. 보다 효율적인 에너지관리를 하도록 자동회귀 신경회로망을 온-라인 상에서 예측한 결과, 기존의 예측 방법보다 뛰어난 성능을 얻을 수 있었다. 그리고 일반적인 전자식 가정용 배전반 시스템의 기능인 원격 전력검침, 전력량 적산, 차단기능 등을 구현하여 시스템을 소형화와 시스템 관리의 효율성이 향상됨을 실험 결과에서 알 수 있었다. 더군다나 시간적 경제적인 측면에서의 장점으로도 부각될 수 있음을 결과로 확인하였다.

결론적으로 인공지능 방법인 신경회로망은 매우 간단하며, 짧은 시간에 빠른 연산을 할 수 있어 패턴인식, 진단시스템, 그리고 비선형인 데이터를 예측하는 예측 시스템에 대해 보다 효과적이고, 성능이 뛰어나다는 것을 실험 결과로 확인 할 수 있었다. 그리고 본 논문에서 제안된 방법으로 배전반 시스템 및 전기선로의 결함을 진단하거나 예측하는 분야에 널리 활용될 수 있으리라 본다.

향후 연구 방향은 본 논문을 기초로 하여 전력 시스템의 누전위치 추정, 옥내선로의 접촉 불량 위치 검출 등에 대해 연구하여 보다 더 지능적인 방법을 추가하여 그 결과를 제시하는 것이다.

참 고 문 헌

- [1] Jacek M. Zurada "introduction to Artificial Neural System" Systems." West Publishing Company, pp. 26-235, 1992.
- [2] Lefteri H. Tsoukalas, Robert E. Uhrig. "Fuzzy and Neural Approaches in Engineering." John Wiley & Sons, Inc., pp. 1-7, 1992.
- [3] K. S. Narendra and A. M. Annaswamy, "Stable Adaptive Systems." Englewood Cliffs, NJ: Prentice-Hall, 1989.
- [4] P. G. Gallman and K. S. Narendra, "Identification of nonlinear systems using a Uryson model", Becton Center, Yale University, New Haven, CT, tech. rep. CT-38, Apr. 1971; also Automatica, Nov. 1976.
- [5] L. Ljung and T. Soderstrom, "Theory and Practice of Recursive Identification." Cambridge, MA: M.I.T. Press, 1985.
- [6] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators", Dept. Economics, University of California, San Diego, CA, discussion pap., Dept. Economics, June 1988.
- [7] K. S. Narendra and K. Parthasarathy, "A diagrammatic representation of back propagation", Center for Syst. Sci., Dept. of Electrical Eng., Yale University, New Haven, CT, tech. rep. 8815, Aug. 1988.

- [8] G. C Goodwin, P. J. Ramadge, and P. E. Caines, "Discrete time multivariable adaptive control" , IEEE Trans. Automat. Contr., vol. 25, pp. 49-456, June 1980.
- [9] M. Roberts, Twelve Neural Networks Cliches, AI EXPERT, August 1988.
- [10] F. Chorlton, "Text Book of Dynamics" , Ellis Horwood, pp. 203-204, pp. 247-249, 1963.
- [11] R. P. Gorman and T. J. Sejnowski, "Learned classification of sonar targets using a massively parallel network" , IEEE Trans. Acoust., Speech, Signal Processing, Vol. 36, No. 7, pp. 1135-1140, July 1988.
- [12] T. J. Sejnowski and C. R. Rosenberg, "Parallel networks that learn to pronounce English text" , Complex Syst., Vol.1 pp. 145-168, 1987.
- [13] K. S. Narendra and K. Parthasarathy, "Neural networks and dynamical systems. Part I: A gradient approach to Hopfield networks" , Center Syst. Sci., Dept. Electrical Eng., Yale University, New Haven, CT, tech. rep. 8820, Oct. 1988.
- [14] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators" , Dept. Economics, University of California, San Diego, CA, discussion pap., Dept. Economics, June 1988.
- [15] M. Minsky and S. Paper, Perceptrons, MIT Press, 1969.
- [16] Y. Chen and F. Bastani, "ANN with Two Dendrite Neurons and Weight Initialization" , Proc. IJCNN, Baltimore, Vol.III, pp. 139-146, 1992.
- [17] C. Koch, T. Poggio, "Multiplying with Synapses and Neurons" , in Single Neuron Computation, T. Mckenna, J. Davis, and S. F. Zonnetzer[eds.], pp. 3165-3455, 1992.
- [18] Jacek M. Zurada, Introduction to Artificial Neural Systems., West Publishing Company, pp. 163-235, 1993.
- [19] Chin-Teng Lin, C.S.George Lee, "Neural Fuzzy Systems", Prentice Hall, Inc., 1996.
- [20] 최태원, "신경회로망을 이용한 옥내배선의 트래킹 식별에 관한 연구", 경남 대학교 박사 학위논문, 1995.
- [21] 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.