

신경회로망을 이용한 과도파형의 기본파성분 추출에 관한 연구

論文
43~4~3

A Study on the Extraction of Fundamental Frequency Components in the Transient Wave Signals Using Artificial Neural Networks

申明澈* · 李福求**
(Myong-Chul Shin · Bock-Ku Lee)

Abstract—This paper presents a filtering method using neural networks to extract fundamental frequency components of the transient wave signals in power systems. Based on the ability of multilayer feedforward neural networks to approximate any continuous function, a neural networks mapping filter is proposed for the protective distance relaying systems to extract the effective components efficiently. A characteristic feature of this mapping filter is composed of the multilayer perceptron neural networks which are trained by using random signals and those are mapped to the DFT filtering computational structure by GDR(Generalized Delta Rule). The advantage of this approach is demonstrated by the random waves and the fault transient wave signals of EMTP(electromagnetic transients program) in power systems fault conditions. The proposed method is compared with the conventional method and the simulation results show the efficiency of the neural networks.

Key Words : Neural Networks Mapping Filter(신경회로망 맵핑필터), Digital Distance Relaying(디지털 거리계전), GDR(일반화 델타규칙)

1. 서 론

그 규모가 대형화, 초고압화 되고 있는 전력계통의 사고에 따른 급격한 불안정한 상태가 발생하였을 경우 이에 신속히 대처하기 위해서는 고속의 보호계전 시스템의 적용이 필연적이다[1]. 이를 위한 보호계전 시스템은 릴레이 입력신호의 왜곡에도 불구하고 고장을 신속정확하게 감지하여야 한다. 그런데 대부분의 디지털 거리계전 알고리즘은 기본파 성분에 기초하여 계통의

고장 상태와 고장지점을 추정·판단[1-4][11]하므로 보호계전 알고리즘의 신뢰도와 속도는 보호계전시스템의 왜곡된 입력신호에서 기본파 성분을 얼마나 신속하고 정확하게 추출 하느냐에 따라 결정된다. 그러므로 디지털 계전기법은 기본파 성분을 추출하는데 있어 알고리즘의 연산부담이 결정적인 제한요소로 작용하여 이를 개선하기 위해 주로 수치적인 연산 수를 감소시키거나 데이터 윈도우(data window)의 크기를 줄이는 방법으로 DFT(discrete fourier transform), DHT(discrete hartley transform), BPF(block pulse fuction), FIR(finite impulse response), Kalman filter 등의 순차적(sequential) 기법[2-5]을 이용하고 있다. 이는 근본적으로 순차적인 처리방식으로 한 샘플윈도우(sample window) 내의 입력데이터를 동시에 모두 동작 시킬 수 없는 구조적인 제한조건을 가

*正會員 : 成均館大 工大 電氣工學科 教授·工博

**正會員 : 忠南專門大學 制御計測科 專任講師

接受日字 : 1993年 5月 23日

1次修正 : 1993年 9月 25日

2次修正 : 1994年 1月 20日

3次修正 : 1994年 3月 15日

지고 있다. 윈도우 길이 N 즉, 샘플 윈도우내의 데이터 수가 증가함에 따라 곱셈의 처리시간 (processing time)도 DFT와 FFT의 경우, 각각 N^2 , $N \log_2 N$ 으로 되는데 알고리즘의 성능이 병렬 구조를 갖는다 하더라도 역시 순차적인 형식으로서 실시간(real time)처리에 문제점을 갖는다 [5]. 또한 과도 noise가 포함된 측정신호를 상태 변수 모델로 변환한 후 Kalman filter를 이용하여 기본과성분을 추출하는 방법[3]은 Kalman gain등의 필터계수를 구하고, on-line으로 실시간 처리를 하는데는 상당한 난점을 내재하고 있으며, 특히 high-impedance 고장의 경우 정확한 기본과 성분을 추출하는데 많은 문제점을 내포하고 있다. 이와같이 지적된 문제점을 신경회로망을 이용하여 해결하려는 연구가 시도 되어 주로 high-impedance 고장[8][9]과 사고형태 판별[12][13]에 대하여 적용하였는데, 이는 계통내의 전압, 전류의 사고유형을 패턴화하여 고장구간과 사고형태를 판단하는 것으로 과도파형의 기본과 성분을 추출하여 정확한 고장지점을 추정하기 위한 거리계전 시스템에는 적용하지는 못하였다[7][13].

따라서 본 논문에서는 신경회로망을 이용한 패턴인식(pattern recognition) 보호계전기법을 구현하기 위한 선행단계로서, 패턴인식 시스템의 특징추출(feature extraction)단계인 과도파형의 기본과성분 필터링 방법에 신경회로망의 특성 [10]인 고도의 병렬처리(massive parallelism), 적응학습(adaptive learning), 결함 극복능력(fault tolerance), 맵핑(mapping)성능[6],[14-17] 및 일반화특성(generalization)을 이용하여 임의의 필터링 함수를 근사화(approximation)시킬 수 있는 신경회로망 맵핑필터(neural networks mapping filter)를 구성하여 기본과성분을 효율적으로 추출할 수 있도록 시도하였다. 이를 위해 맵핑 신경회로망의 한 형태로서 임의의 함수 f 를 $A \subset R^n \rightarrow R^m$, 즉 n 차원의 Euclidean 공간의 유한 부분집합 A 를 m 차원의 Euclidean 공간의 $f(A)$ 로 근사화시키는 맵핑을 할 수 있는 다층퍼셉트론 신경회로망(multilayer perceptron neural networks)을 이용하였으며, 또한 입출력 공간의 출력패턴을 역전파 학습알고리즘인 GDR (generalized delta rule)을 이용하여 DFT 계산 구조로 맵핑하였다. 아울러 랜덤파형(random wave signals)을 학습용 파형으로하여 입출력 공간의 특성을 맵핑시키는데 중요한 역할을 하는

적절한 은닉층(hidden layer)의 층수와 유니트수를 선정하였다. 이와같이 구성된 신경회로망 맵핑필터를 학습되지 않은 임의의 랜덤파형에 적용함으로써 기본과성분을 효율적으로 추출할 수 있었다. 또한 제시된 신경회로망 맵핑필터의 성능을 평가하기 위하여 EMTP(electromagnetic transients program)를 통하여 얻은 전력계통의 고장 데이터를 과도파형으로 사용하여 신경회로망 필터링 알고리즘을 적용하고 결과를 종래의 DFT 방법을 적용한 결과와 비교, 검토하였다.

2. 다층퍼셉트론 신경회로망의 맵핑

신경 회로망 응용에 있어서 널리 사용되고 있는 다층 퍼셉트론 역전파 모델은 입력 x_k 에 대한 원하는 출력 y_k 를 수행하는 임의의 전달함수 $f(x_k)$ 의 기능을 갖으며 (x_1, y_1) , (x_2, y_2) , ... (x_k, y_k) 의 근사화를 수행시킬 수 있게 되는데 이와같은 신경회로망의 맵핑 수행과정은 다음 식(1~7)과 같다[6]. 입출력층과 은닉층의 3개의 층으로 구성된 다층퍼셉트론 신경 회로망을 이용하여 GDR에 의해 함수 $f(x) = (f_1(x), f_2(x), \dots, f_m(x))$ 의 각 좌표에 대한 함수 $f_1(x)$ 을 근사화시키는 경우를 고려하면 Fourier 급수이론에 의해 다음의 식이 성립한다[6].

$$\int_{[0,1]^n} |f_1(x) - \sum_k C_{1k} \exp(j2\pi k \cdot x)|^2 dx < \delta_1 \quad (1)$$

여기서 $[0,1]^n$ 은 n 차원의 단위입방체이며, 임의의 주어진 오차 δ_1 범위 내에서 계수 C_{1k} 가 존재하게 되는데 이는 $f_1(x)$ 의 복소 Fourier 급수의 cosine항과 sine항이 신경 회로망에 의해 임의의 원하는 정도의 오차범위 이내로 근사화[14~17]될 수 있음을 나타낸다. 그러므로 이를 증명하기 위하여 sine, cosine함수를 맵핑하는데 총 m 개의 출력유니트에서 유니트 1을 고려하면 그 1번째 유니트출력은 다음과 같다.

$$\sum_{i \in H} V_{1i} S \left(\sum_{j=0}^n W_{1j} x_j \right) \quad (2)$$

여기서 H 는 은닉층의 유니트 수이며, V_{1i} 및 W_{1i} 는 각각 출력유니트 1과 은닉유니트 i 사이의 연결강도(connection weight), 은닉유니트 i 와 입력유니트 j 사이의 연결강도이다. 또한 V_{1i} 는 f_1 의 신경회로망 맵핑을 위한 sine과 cosine의 근사화함

수 S의 계수로서 역할을 한다.

그러므로 $j2\pi k \cdot x = u(k, x) = U$ 로 하고, $\sum_{j=0}^n W_j x_j = \beta_j(u(k, x) - \alpha_j)$ 라고 하면 $x \in [0, 1]^n$ 에서 $\sin(u(k, x))$ 또는 $\cos(u(k, x))$ 을 근사화하기 위해 은닉층에 적절한 유니트수를 갖는 부분집합(subset) H_k 를 고려하면 오차 δ_2 범위 내에서 다음과 같이 근사화 된다.

$$|\sin(u(k, x)) - \sum_{i \in H_k} V_{i1} S(\beta_j(u(k, x) - \alpha_j))| < \delta_2 \quad (3)$$

여기서 β 및 α 는 실상수이며, 이것은 만약 H_k 가 임의의 함수(sine)를 맵핑하기 위한 적절한 은닉층 유니트의 수를 포함 한다면 이 식(3)은 항상 만족 될 수 있음을 나타낸다. 즉, 학습에의해 은닉층에 적절한 유니트의 처리요소(processing element)를 갖는 H_k 와 알맞은 α, β, V_{i1} 를 선택 할 때 각 유니트의 출력은 모든 입력 $x \in [0, 1]^n$ 에 대하여 $\sin(u(k, x))$ 또는 $\cos(u(k, x))$ 의 δ_2 범위 내에서 만족됨을 알 수 있다.

그러므로 f_1 의 Fourier급수에 대한 신경회로망의 맵핑은 출력유니트 l이 은닉층 유니트로부터 sine과 cosine 부분집합 H_k 의 입력을 받기 때문에 sine(또는 cosine)계수인 V_{i1} 와 C_{i1} 의 실수부와 허수부에 대한 곱으로 구해진다. 따라서 sine과 cosine함수의 계수를 각각 $a(l, k)$, $b(l, k)$ 라고 하고, 출력 유니트 l의 출력을 $y'_l(x)$ 라고 하면 다음과같이 성립된다.

$$f_1(x) - y'_l(x) = \sum_{k \in H_k} [a(l, k)\{\sin(u(k, x)) - M(\alpha, \beta, V_{i1}, x)\} + b(l, k)\{\cos(u(k, x)) - M'(\alpha, \beta, V_{i1}, x)\}] \quad (4)$$

여기서 M' 은 H_k 의 cosine항 이다. 그러므로 임의의 원하는 범위내의 δ_1 과 δ_2 를 충분히 작게하여 평균자승오차 ϵ 를 $\epsilon \cong 0$ 로 취한다면 식(5)와 같이 근사화 된다.

$$\int_{|0, 1|^n} |f(x) - y'(x)|^2 dx < \epsilon \quad (5)$$

따라서 맵핑된 임의의 함수에 대한 오차의 제곱적분 특성인 평균자승오차 가 0에 근사화 되어 원하는 정도의 오차범위 안에서 임의의 함수를 맵핑 시킬 수 있음을 알 수 있다.

3. 신경회로망의 맵핑에 의한 기본파 성분 추출

3.1 신경회로망 맵핑필터의 구성

신경회로망을 이용하여 필터링함수를 구현하기 위해 임의의 필터링 구조를 DFT, FIR, BPF, DHT등의 필터링함수의 맵핑기능을 갖도록 하기 위해 역전파학습 알고리즘인 GDR을 이용하여 학습시키면 신경회로망이 임의의 필터링 함수를 구현 할 수 있게 된다. 그 적용될 신경회로망 맵핑필터는 그림 1과 같이 구성되어 신경회로망 필터링 함수의 특성을 갖도록 구현 하였다.

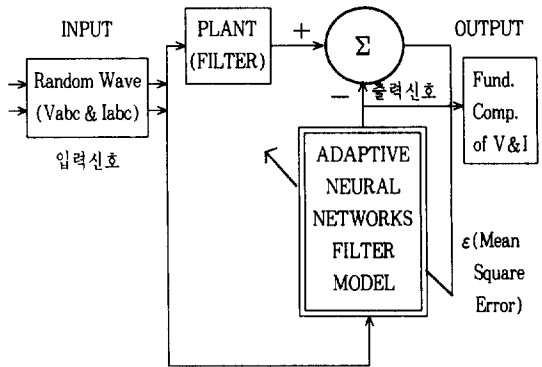


그림 1 신경회로망 맵핑필터 모델링
Fig. 1 Neural networks mapping filter modeling

그림 1에서 신경회로망 맵핑필터 모델은 효율적으로 기본파 성분을 추출 할 수 있도록 한 샘플 윈도우내의 입력데이터를 동시에 모두 동작 시킬 수 있는 다층 퍼셉트론 역전파 신경회로망으로 구성하고 지도학습(supervised learning)의 출력패턴인 목표필터(target filter)는 가장 안정된 필터링 특성을 보이는 DFT 필터링 계산구조로 맵핑시켰다. 여기서 임의의 과도파형에 대한 기본파성분을 추출할 수 있는 신경회로망 맵핑필터를 모델링 하기 위해 신경회로망은 완전연결(full connected) 구조로 구성하였으며, 또한 학습을 통하여 주어진 입출력 공간에 대한 가장 적절한 은닉층의 층수와 유니트수를 선정한다. 이때 사용된 신경회로망 맵핑필터의 입력 랜덤 파형의 식은 다음과 같다.

$$x(k) = \sum_{i=1}^n [\text{amp}(i) * \sin(2\pi ki/N + \text{phase} * 2\pi)] \quad (6)$$

(단, $k=0, 1, \dots, N-1$)
여기서, $\text{amp}(i) = (1.0/4^{i-1}) * \text{rand}()$ (7)
 $\text{phase} = \text{rand}()/32767$ (8)

으로 n 은 고조파 차수, N 은 한주기당 샘플수, $\text{rand}()$ 는 최대 32767의 난수를 나타낸다. 이와 같이 선정된 적절한 은닉층의 층수와 유니트수는 2장에서 기술한 바와 같이 신경회로망이 출력패턴에 대한 맵핑특성으로 기본파성분을 추출하는데 중요한 역할을 하게 된다. 또한 입력층 유니트 수는 sampling rate 에 따라 주기당 샘플수로 결정되며 출력층 유니트수는 추정될 파라미터 수 즉, 기본파성분을 포함하여 추출하고자 하는 고조파 수에 따라 결정된다. 이와같이 구성된 신경회로망 맵핑필터는 신경회로망의 일반화특성(generalization)에 따라 학습되지 않은 불평형 과도상태의 전압, 전류성분의 과도파형으로부터 고도의 병렬처리 방식으로 기본파 또는 고조파성분을 효율적으로 추출한다.

3.2 신경회로망에 의한 기본파 성분추출

다층 퍼셉트론 역전파 신경회로망은 맵핑 신경회로망의 한 형태로서 정보처리 오퍼레이션이 입력 벡터 x 에 대하여 수학적 맵핑 또는 함수 f 의 출력 벡터 y 를 근사화시키는 뉴로컴퓨팅(neurocomputing)을 수행한다. 즉, $y=f(x)$ 와 같은 임의의 함수를 맵핑 할 수 있다. 따라서 임의의 과도파형을 필터링하여 기본파 페이저 성분을 추출하기 위한 임의의 필터링 구조에 신경회로망의 맵핑기능을 적용하면 필터링 기능을 수행하는 신경회로망 맵핑필터가 모델링 된다. 그러므로 이와같이 모델링된 신경회로망 맵핑필터를 이용하면 과도상태의 파형으로부터 기본파성분을 효율적으로 추출할 수 있다. 이를위한 임의의 필터링 구조를 fourier 변환을 기초로한 DFT 구조로 맵핑한다면 다음과 같이 기본파성분을 추출한다. 임의의 과도상태 파형을 주기당 동일 간격으로 N 번 샘플링하여 얻은 디지털입력신호를 $x(k)$ 라고 하면 각 샘플입력에 대한 DFT 출력은 다음과 같다.

$$X(n) = \sum_{k=0}^{N-1} x(k) \exp(-j2\pi kn/N) \quad (n=0, 1, \dots, N-1) \quad (9)$$

$$= \sum_{k=0}^{N-1} x(k) W_N^{kn} \quad (10)$$

여기서 W_N^{kn} 는 $W_N^{kn} = \exp(-j2\pi kn/N)$ 인 회전인자(twiddle factor)로서 복소평면상 단위원의 원주상을 $1/N$ 원주씩 움직이는 점을 표시한다. 또한 n 은 각각의 고조파수이며 입력신호 $x(k)$ 에

대한 DFT는 기본파성분 및 각 고조파성분의 스펙트럼(spectrum)을 나타낸다. 그러므로 DFT는 시간영역의 $x(k)$ 를 주파수영역의 $X(n)$ 으로 변환하며 $n=1$ 일때인 기본파성분을 추출한다.

또한 입력층 유니트수를 N , 적절한 은닉층의 층수와 유니트 수를 H 로 하고, 출력층 유니트수를 n 개로 하여 n 차 고조파까지 추출할 수 있도록 구성된 신경회로망을 학습을 통하여 임의의 과도파형에 대한 기본파 및 고조파성분을 추출할 수 있도록 맵핑된 신경회로망은 다음과 같이 기본파성분을 추출 한다. 이때의 출력 $X'(n)$ 은 입력 $x = [x(0), x(1), \dots, x(N-1)]^T$ 와 각 층사이의 유니트 연결강도 $W_{nhk} = [w_n, v_h, \dots, u_k]$ 에 대한 sigmoid 함수로서 임의의 연속함수의 선형특성을 맵핑할 수 있으므로 다음과 같다.

$$X'(n) = \psi \left(\sum_n W_n \psi \left(\sum_h v_h \psi \left(\dots \psi \left(\sum_k u_k x(k) \right) \right) \right) \right) \quad (11)$$

$$\cong \psi \left[\sum_{k=0}^{N-1} W_{nhk} x(k) \right] = \sum_{k=0}^{N-1} \alpha W_{nhk} x(k) \quad (12)$$

여기서 ψ 는 준선형인 sigmoid 함수이며, α 는 sigmoid 함수의 선형영역이다.

그런데 신경회로망의 입출력공간에서 신경회로망의 맵핑출력이 필터링함수의 출력패턴에 대하여 원하는 정도의 오차범위 안에서 근사화 될 수 있으므로 식(10)과 식(12)는 다음과 같이 성립한다.

$$\sum_{k=0}^{N-1} x(k) W_N^{kn} \cong \sum_{k=0}^{N-1} \alpha W_{nhk} x(k) \quad (13)$$

따라서 연결강도 αW_{nhk} 는 DFT의 회전인자 W_N^{kn} 로 맵핑된 계수로서의 역할을 하며, 신경회로망 출력은 과도파형에 대한 기본파성분 및 각 고조파성분의 주파수 스펙트럼을 나타낸다. 그러므로 이와같은 신경회로망의 맵핑기능으로 임의의 과도파형에 대한 기본파 성분을 효율적으로 추출한다.

4. 시뮬레이션 및 결과 고찰

제안한 알고리즘을 이용하여 전력계통의 과도파형에 대한 기본파성분을 추출하기 위해, 먼저 랜덤파형에 대한 기본파성분을 효율적으로 추출할 수 있도록 신경회로망 맵핑필터를 구성하였다. 그다음 이와같이 구성된 맵핑필터를 이용하여 학습하지 않은 임의의 랜덤파형에 적용하여 그 성능을 평가하였으며, 아울러 EMTP에서 얻

은 전력계통 고장 발생시의 과도파형에 대하여 적용하고 결과를 종래의 DFT 방법을 적용한 결과와 비교, 검토하였다. 신경회로망을 이용한 응용의 경우 그 특성을 충분히 살리기 위해서는 신경회로망 컴퓨터를 사용해야 하지만 아직 신경회로망 하드웨어 구현이 제한된 상태이므로 IBM-PC 호환기종인 32bit 486 컴퓨터에서 이와 같은 시뮬레이션을 수행하였다.

4.1 시뮬레이션 방법

다층퍼셉트론 역전파신경회로망을 이용하여 기본파성분을 추출하기 위해, 전력계통의 사고시 발생하는 과도파형을 신경회로망에 학습시킨다는 것은 고장의 종류 및 고장점등 사고상황이 매우 다양하기 때문에 많은 난점이 내재한다. 따라서 이와같은 문제점을 해결하기 위해서는 임의의 랜덤파형으로부터 기본파 성분을 추출할 수 있도록 하는것이 필요하다. 이를위해 임의의 랜덤파형에 대하여 기본파성분을 추출할 수 있

도록 GDR을 이용하여 맵핑필터를 구성하였으며, 이와같이 구성된 맵핑필터를 임의의 랜덤파형 및 과도파형에 적용하였다.

이와같은 신경회로망을 이용한 기본파성분 추출 필터링 실행과정을 그림 2에 도시 하였다. 학습 모드(training mode)에서 그림 1과 같이 모델링된 신경회로망 맵핑필터를 구성하고, 그다음 운영모드(operation mode)에서 임의의 랜덤파형 및 전력계통의 사고시 발생하는 과도파형에 대하여 적용 하였다. 먼저 학습모드의 신경회로망 맵핑필터가 임의의 과도파형 입력에 대하여 원하는 기본파성분을 출력할 수 있도록 식 (6)의 랜덤파형을 고조파 차수를 5로 하고 주기당 12 샘플로 샘플링하여 신경회로망의 입력에 적합하도록 -1~1사이로 정규화(normalization)한 그림 3과 같은 200개의 랜덤파형을 신경회로망의 학습용 입력파형으로 사용하였다.

그다음 이와같은 랜덤파형을 DFT 방법을 통하여 기본파 또는 각 고조파 성분을 추출하였다. 그리고 이를 출력패턴으로하여 그림 1과 같이 모델링된 신경회로망 맵핑필터를 DFT 필터링 구조로 입출력 공간을 맵핑시켰다. 이때 사용된 역전파학습 알고리즘인 GDR의 학습률은 0.9, 모멘텀은 0.7로 하였다. 이와같이 구성된 신경회로망 맵핑필터는 운영모드에서 임의의 파형을 입력으로하여 신경회로망의 고도의 병렬처리 특성과 일반화 특성에 의해 기본파 또는 각 고조파 성분을 효율적으로 추출한다.

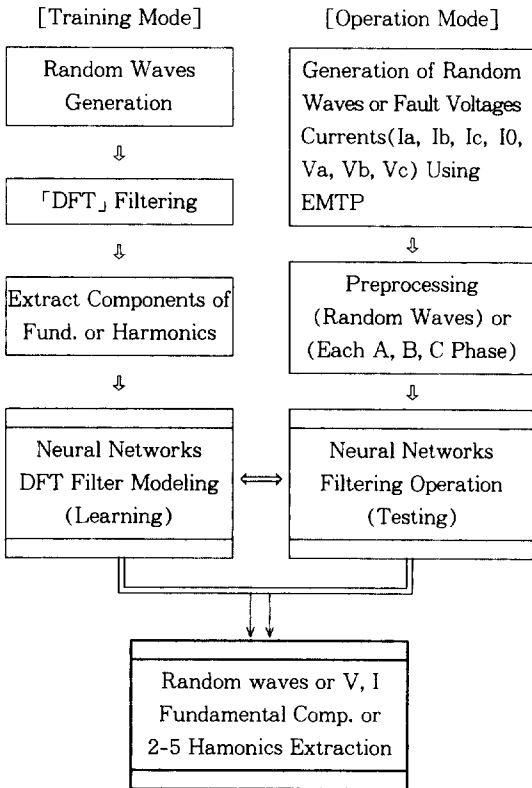


그림 2 신경회로망의 필터링 실행과정
Fig. 2 Processing of neural networks filtering




그림 3 랜덤 파형
Fig. 3 Random wave signals

4.2 신경회로망 맵핑필터 은닉층의 층수 및 유닛 수의 선정

신경회로망 맵핑필터 구조의 입력층 유닛수는 sampling rate에 따라 결정되는데 본 연구에서는 주기당 12샘플로 샘플링하여 12개의 입력 유닛으로 하였고 출력층 유닛 수는 1개로 하여 기본과성분만을 추출하도록 하였다. 또한 은닉층의 층수 및 유닛 수는 신경회로망의 입력력 특성을 맵핑하는데 중요한 역할을 한다. 따라서 이와같은 신경회로망의 입력력 특성이 기본과성분을 출력패턴으로 하기 위한 적절한 은닉층 층수와 각 은닉층의 유닛수를 선정하기 위하여 그림 3과같은 랜덤패형을 입력으로 학습하여 이에 대한 신경회로망의 평균자승오차(mean square error) 측면에서 살펴보았다. 먼저 한개의 은닉층을 갖는 경우 신경회로망의 은닉층 유닛수를 변화 시키면서 학습횟수 5000회를 기준으로 실험한 학습결과는 표 1과 같은 평균자승오차를 보였으며, 그다음 다층의 은닉층을 갖는 경우 각 유닛의 수에 대한 학습횟수 5000회 및 10000회를 기준으로 실험한 학습결과는 표 2같은 평균자승오차를 보였다.

한개의 은닉층 유닛수가 45개인 경우 평균자승오차가 가장 작아 한개의 은닉층으로 구성한 경우에는 적절한 구조임을 표 1로부터 알 수 있다. 또한 은닉층의 층수에 따른 실험결과는 한

표 2 다층의 은닉층을 갖는 은닉층의 층수에 따른 평균자승오차

Table 2 Mean square error according to multi-hidden layers

은닉층의 층수 (Hidden Layer Number)	각 은닉층의 유닛 수 (Unit Number of HL)	평균자승 오차 학습횟수 : 5000 (Mean Square Error IN:5000)	평균자승 오차 학습횟수 : 10000 (Mean Square Error IN : 10000)
1	45	0.000251	0.000181
2	11-14	0.000036	0.000022
3	6-6-7	0.000067	0.000043
4	6-6-7-7	0.000036	0.000020
5	6-6-7-7-7	0.000044	0.000023

개의 은닉층으로 구성된 유닛수 45개인 경우보다 평균자승오차가 현격히 감소함을 표 2로부터 알 수 있으며, 은닉층이 4층인 경우 입력층에 가까운 순서로 은닉층 유닛 수가 각각 6, 6, 7, 7에서 가장 작은 평균자승오차를 보였다. 학습패턴에 대하여 오차가 적은 이와같은 구조들이 테스트 패턴에 대하여도 2층과 4층의 은닉층 유닛수에서 동일한 결과를 나타내었으며 본 연구에서는 연산효율 측면을 고려하여 표 2와 같은 2층의 은닉층 유닛수를 갖는 신경회로망을 맵핑필터의 구조로 선정하였다. 이와같이 구성된 신경회로망 맵핑필터의 학습상태를 살펴보면 그림 4와 같으며, 이는 그림 3과 같은 학습용 랜덤패

표 1 1층의 은닉층 유닛수에 따른 평균자승오차 (학습횟수 : 5000)

Table 1 Mean square error according to units of one hidden layer(learning iteration number : 5000)

은닉층 유닛수 (Hidden Layer Unit Number)	평균자승 오차 (Mean Square Error)	은닉층 유닛수 (Hidden Layer Unit Number)	평균자승 오차 (Mean Square Error)
1	0.028501	20	0.000362
2	0.013163	25	0.000348
3	0.001137	30	0.000295
4	0.000867	35	0.000366
5	0.000633	40	0.000307
6	0.000464	45	0.000251
7	0.000462	50	0.000364
8	0.000430	55	0.000312
9	0.000339	60	0.000280
10	0.000525	65	0.000347
15	0.000600	70	0.000263




그림 4 신경회로망 맵핑필터의 기본과 성분 추출 학습상태

Fig. 4 Neural networks mapping filter learning state of fundamental frequency components extraction

형에 대하여 윈도우 No. 한개 마다 한개 랜덤파형의 기본파성분 추출 학습상태를 나타내는 것으로 DFT 방법으로 얻은 기본파성분의 목표치와 신경회로망 맵핑필터의 학습출력이 거의 일치하여 학습이 잘되었음을 보여 주고있다.

4.3 신경회로망 맵핑필터의 기본파성분 추정결과 및 고찰

4.3.1 랜덤파형에 대한 기본파성분 추정

이와같이 구성된 신경회로망 맵핑필터의 성능을 평가하기 위하여, 학습된 랜덤파형이 아닌 임의의 랜덤파형의 각각에 대하여 적용하였다. 그림 5는 학습되지 않은 랜덤파형 50개를 대상으로 신경회로망 맵핑필터의 출력결과를 나타낸 것으로, 임의의 랜덤파형에서 추출된 기본파성분과 DFT 방법에 의한 결과와 비교하였다. 그림 5에서 알 수 있는 바와 같이 계산 알고리즘에 의하지않고 학습에 의한 보간성능(interpolation)으로 학습하지않은 임의의 랜덤파형에서 기본파성분을 효율적으로 추출하고 있음을 보여주고있다.

4.3.2 과도파형에 대한 기본파성분 추정

과도파형의 기본파성분을 추출하기 위해 제안된 신경회로망 맵핑필터를 전력계통의 고장 발생






그림 5 랜덤파형의 기본파성분 추출에 대한 신경회로망 맵핑필터와 DFT 방법과의 비교

Fig. 5 Comparison of neural networks mapping filter with DFT algorithm in the extraction of fundamental frequency components of random wave signals

생시의 불평형 과도파형에 적용하였다. 일반적으로 고장이 전압의 침투치 부근에서 발생하였을 경우에 고조파의 함유율이 가장 높으며 고장 전압이 영점근처를 통과하는 순간에 고장이 발생하였을 경우는 직류 offset이 가장 현저하게 나타난다. 따라서 최악의 조건인 고장발생각 0° 인 경우와 90° 인 경우의 과도파형을 적용해 봄으로써 그 성능을 검증 할 수 있다. 이를 위하여 12개의 입력층 유니트로 구성된 신경회로망 맵핑필터의 입력에 알맞도록, EMTP에서 주기당



(a)



(b)

그림 6 (a) A상 지락고장 전류 P.U. 순시치(고장 발생각 0°)

(b) 신경회로망 맵핑필터에 의한 기본파성분 추출파형

Fig. 6 (a) Phase current at A phase to ground fault(fault angle 0°)

(b) Extracted fundamental frequency components by neural networks mapping filter





그림 7 기본과성분 추출에 대한 신경회로망 맵핑필터와 DFT 방법과의 비교 (고장발생각 0°시의 A상 지락 경우)

Fig. 7 Comparison neural networks mapping filter with DFT algorithm for fundamental frequency component extraction (A phase ground fault at fault angle 0°)

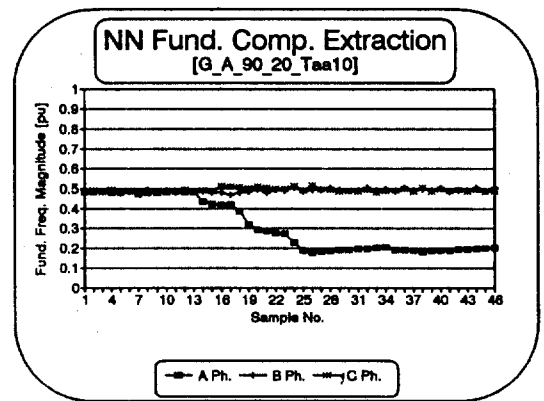
12샘플로 샘플링하여 얻은 상기와 같은 과도파형을 정규화하여 한 샘플씩 이동하는 moving 윈도우 방식으로 입력하였으며 이에 대한 신경회로망 맵핑필터의 출력은 그림 6, 8와 같이 기본과성분을 추출하였다. 또한 그림 7, 9에 본 연구에서 제안한 신경회로망 필터링 알고리즘과 DFT 방법을 이용한 결과를 비교, 제시하였다.

그림 6(a)는 200[km]의 공장을 갖는 전력계통의 20[km] 지점에서 고장발생각 0°의 1선 A상 지락고장인 경우의 전류 과도파형이며 그림 6(b)는 이와같은 과도파형에서 신경회로망 맵핑필터에 의해 추출된 기본과성분을 보여 주고있다. 이를 검증하기 위하여 그림 7은 DFT 방법과 비교한 것으로서 신경회로망의 입출력 맵핑특성으로 기본과성분이 효율적으로 추출되었음을 알 수 있으며, 또한 직류 offset성분이 많이 포함된 과도상태의 파형에 대하여 신경회로망 맵핑필터의 출력이 DFT 방법보다 더욱 안정된 특성을 보이고 있음을 알 수 있다.

또한 20[km] 지점에서 고장발생각 90°의 A상 1선 지락고장인 경우의 각 상의 전압인 그림 8(a)와 같은 과도파형에 대하여 신경회로망 맵핑필터에 의해 추출된 기본과 성분은 그림 8(b)와 같이 나타났으며, 이와같이 추출된 기본과성분을



(a)



(b)

그림 8 (a) A상 지락고장 전압 P.U. 순시치(고장발생각 90°)

(b) 신경회로망 맵핑필터에 의한 기본과 성분 추출파형

Fig. 8 (a) Phase voltage at A phase to ground fault(fault angle 90°)

(b) Extracted fundamental frequency components by neural networks mapping filter

검증하기 위하여 DFT 방법에 의한 출력과 비교한 그림 9는 전혀 학습되지 않은 과도파형으로부터 기본과성분이 효율적으로 추출되는 신경회로망의 일반화특성(generalization)을 잘 나타내고 있다.

4.4 결과 고찰

본 연구에서는 신경회로망을 이용하여 전력계

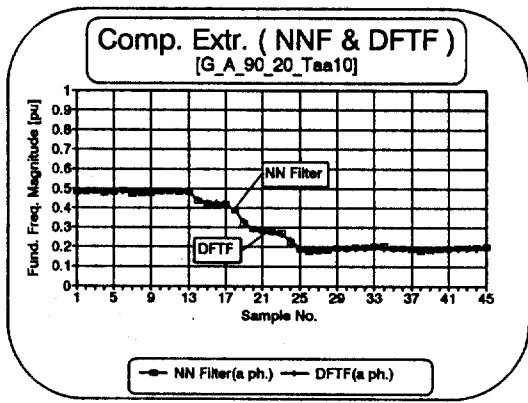


그림 9 기본파성분 추출에 대한 신경회로망 맵핑필터와 DFT 방법과의 비교 (고장발생 각 90° 시의 A상 지락 경우)

Fig. 9 Comparison neural networks mapping filter with DFT algorithm for fundamental frequency component extraction (A phase ground fault at fault angle 90°)

통의 고장 발생시의 과도파형에 대한 기본파성분을 효율적으로 추출하기 위해 임의의 함수를 맵핑 시킬 수 있는 다층퍼셉트론 신경회로망을 이용하였으며, 랜덤파형을 학습파형으로 하여 DFT 같은 기본파성분을 추출하는 신경회로망 맵핑필터를 구성하였다. 이와 같이 구성된 맵핑필터의 효율성을 검토하기 위하여 학습되지 않은 임의의 랜덤파형에 적용하여 보았다. 또한 직류 offset이 가장 현저하게 나타나는 고장전압이 영점근처를 통과하는 순간의 과도파형과 고장이 전압의 침두치 부근에서 발생하였을 경우의 고조파 함유율이 가장 높은 과도파형에 대하여 실험하였다. 실험결과인 그림 5~그림 9에서 알 수 있는 바와 같이 학습되지않은 랜덤파형 뿐 만 아니라 전력계통 고장상태에서 최악의 조건인 고장발생각 0°와 90°근처인 상황에서도 기본파성분을 추정할 수 있도록 맵핑된 신경회로망 맵핑필터는 신경회로망의 일반화특성에 따라 학습에 의한 보간성능으로 랜덤파형 및 과도파형에 대한 기본파 성분을 효율적으로 추출함으로써 그 효율성이 입증되었으며, 아울러 다양한 고장패턴에 대한 비선형 요소를 함유한 모호한 정보에 대해서도 강력한 분석능력을 가지고 있어서 유효한 기본파성분을 추정할 수 있음을 알 수 있

었다. 또한 신경회로망을 하드웨어로 구현한 경우 신경회로망 맵핑필터의 수치적 연산단계는 샘플윈도우 내의 입력데이터를 동시에 모두 처리하는 고도의 병렬처리에 의해, 입력샘플수에 관계없이 입력층과 은닉층, 은닉층간, 그리고 은닉층과 출력층 사이의 3단계로써, DFT방법의 12 단계 보다 적으며 FFT의 2의 거듭제곱의 입력 샘플수에 무관하게 되고 보다 정확한 응답을 얻기위해 윈도우내의 샘플수를 확대하는 경우 더욱 효율적 고속연산이 가능함을 알 수 있다. 따라서 이와같은 신경회로망 맵핑필터는 다양한 고장상황에 대하여도 보호계전시스템의 입력에 필요한 기본파성분을 효율적으로 추출해 내며 학습한 지식을 기초로한 신경회로망의 일반화특성, 측정잡음에 대한 강건성을 보임을 입증하였다. 그리고 이와같은 결과는 고조파 차수가 5차까지 포함된 200개의 한정된 랜덤파형을 학습패턴으로 결과를 얻었으나 좀더 다양하고 많은 학습패턴을 사용하는 경우에 더욱 향상된 응답을 얻을 수 있을 것이다.

5. 결 론

본 연구에서는 신경회로망을 이용한 보호계전 기법을 구현하기 위한 선행단계로서, 필터링 방법에 신경회로망의 특성인 고도의 병렬처리, 적응학습, 결함 극복능력과 맵핑특성을 이용하여 임의의 필터링 함수를 근사화 시킬 수 있는 신경회로망 맵핑필터를 구성하여 일반화특성으로 기본파성분을 효율적으로 추출할 수 있도록 시도함으로써 다음과 같은 결론을 얻었다.

(1) 다층퍼셉트론 신경회로망을 이용하여 효율적으로 기본파성분을 추출하는 방법을 제안하였다.

(2) 랜덤파형을 학습파형으로하여 임의의 과도파형에서 기본파성분만을 추출할 수 있는 적절한 은닉층의 층수와 유닛 수를 선정하여 신경회로망 맵핑필터를 구성하였다.

(3) 전력계통의 고장을 EMTP에 의하여 시뮬레이션된 과도파형으로부터 제안한 신경회로망 맵핑필터에 의하여 기본파성분을 효율적으로 추출할 수 있음을 보였다.

(4) 학습한 지식을 기초로한 신경회로망의 일반화특성, 측정잡음에 대한 강건성으로 보호계전 시스템의 입력에 필요한 기본파성분을 악조건인

고장상황에서도 효율적으로 추출해냄으로써 적용 타당성을 입증하였다.

따라서 신경회로망 하드웨어에 구현하는 경우 디지털 거리계전기법에 효과적으로 이용될 수 있는 기본과 추출기법을 제시함으로써 기존의 아날로그 보호계전방식 및 디지털 보호계전방식의 필터링에 대한 종래의 문제점을 개선할 수 있을 것으로 기대된다.

참 고 문 헌

- [1] The Electricity Council, Power system prototion, vol. I, II, Peter Pergrinus Ltd., 1981.
- [2] A.G.Phadke, M.Ibrahim, T.Hibka, "Fundmental basis for distance relaying with symmetrical components," IEEE Trans. on PAS, vol. PAS-96, no. 2, pp. 635~646, March/April 1977.
- [3] A.A.Girgis, "A New kalman filtering based digital distance relay," IEEE Trans. on PAS, vol. PAS-101, no. 9, September, 1982
- [4] G.C.Kakoti, H.K.Verma, "New algorithms microprocessor-based distance relaying," Electric Power Systems Research, 15, pp. 233-238, 1988.
- [5] A.D.Culhane, M.C.Peckerar, "A neural net approach to discrete hartley and fourier transforms," IEEE Trans. on CAS, vol. 36, no. 5, pp. 695~703, May 1989.
- [6] Robert Hecht-Nielsen, "Theory of the backpropagation neural networks," IJCNN, vol. I, pp. 593~605, 1989.
- [7] Yoshikazu Fukuyama, Yoshiteru Ueki, Kazuhiro Kaneko, "Development of expert system for analyzing fault in power systems using artificial neural network based waveform recognition," IEE Japan, vol. 111-B, no. 7, pp. 735~742, 1991.
- [8] Sonja Ebron, David L.Lubkeman, Mark White, "A neral network approach to the detection of incipient faults on power distribution feeders," IEEE TPWD, vol. 5, no. 2, pp. 905~914, April 1990.
- [9] A.F. Sultan et al, "Detection of high impedance arcing faults using a multi-layer perceptron," IEEE TPWD, vol. 7, no. 4, pp. 1871~1877, 1992.
- [10] D.E. Rumelhart, J.L. McClelland and The PDP Research Group, Parallel distributed processing, vol.1,2, MIT Press, 1986.
- [11] 신명철, 이복구, 성낙환, "전력계통의 실시간 대칭성분 계산을 위한 알고리즘에 관한 연구," 성균관대학교 논문집, 과학기술편 제38집 no. 1, pp. 75~80, 1987
- [12] 신명철, 김철환, 권기백, 이복구, "신경회로망을 이용한 송전선로의 고장 판별에 관한 연구," 대한전기학회 논문지, vol. 42, no. 11, pp. 67-77, 1993.
- [13] N.Kandil, V.K.Sood, K.Khorasani, R.V. Patal, "Fault identification in an AC-DC transmission system using neural networks," IEEE Trans. Power System, vol. 7, no 2, 1992.
- [14] R. Hect-Nielsen, "Kolmogorov's mapping neural network existence theorem," Proc. IEEE IJCNN, Vol. III, pp. 11~14, 1987
- [15] Ken-ichi Funahashi, "On the approximate realization of continuous mappings by neural networks," Neural Networks vol. 2, pp. 183~192, 1989.
- [16] Lee K. Jones, "Constructive approximations for neural networks by sigmoid functions," Proc. IEEE, vol. 78, no. 10, pp. 1586~1589, October 1990.
- [17] Kurt Hornik, "Multilayer feedforward networks are universal approximator," Neural Networks, vol. 2, pp. 359~366, 1989.
- [18] B.Widrow, S.D.Stearns, Adaptive signal processing, Prentice Hall, 1983.
- [19] C.Klimisauskas, "Neural nets and noise filtering," Dr. Dobb's Journal, pp. 32~48, Jan. 1989.