

전력계통의 패턴인식형 거리계전기법에 관한 연구 A Study on the Pattern Recognition based Distance Protective Relaying Scheme in Power System

이복구* · 윤석무** · 박철원*** · 신명철****

Bock-Ku Lee*, Sug-Moo Yoon**, Chul-Won Park***, Myong-Chul Shin****

* 명지전문대학 전기과

** 충남전문대학 제어계측과

*** 국립원주전문대학 전기과

**** 성균관대학교 전기전자 및 컴퓨터공학부

요약

본 논문에서는 패턴인식 형태로 구성된 거리계전시스템에 신경회로망을 적용한 새로운 형태의 거리계전기법이 제시되었다. 제안된 거리계전기법은 패턴인식 단계인 두 개의 블록으로 구성되었다. 첫 단계에서는 과도신호의 특징 파라미터인 기본파성분을 효율적으로 추출하기 위해 신경회로망을 이용한 필터링 방법이 적용되었으며, 두 번째 단계에서는 첫단계에서 추출된 기본파성분을 입력으로 고장형태를 신속하고 정확하게 판별 분류 될 수 있도록 신경회로망을 이용한 고장패턴 추정기가 개발 적용되었으며, 아울러 고장판별에 따라 고장점을 효율적으로 추정될 수 있도록 하였다. 적용 시스템의 각 단계는 함수 근사화, 보간성능 및 패턴분류 등의 능력이 뛰어난 다층 퍼셉트론의 역전파 학습 알고리즘이 적용 되었다. 제시된 기법의 성능을 입증하기 위하여 EMTP 시뮬레이션을 하여 얻은 다양한 과도 고장파형의 계전신호를 활용하여 시험하였으며, 그 결과 제시된 기법은 학습되지 않은 임의의 패턴에 대하여 적응성을 가지고 효율적으로 고장점이 추정될 수 있었으며, 고장발생후 3샘플 이내에서 고장형태가 신속하고도 정확하게 판별되었다.

ABSTRACT

In this paper, a new distance relaying scheme is proposed. Artificial neural networks are applied to the distance relaying system composed of pattern recognition based. The proposed distance relaying scheme has two blocks of pattern recognition stages to estimate the fundamental frequency and to classify the fault types. In the first block, a filtering method using neural networks called a neural networks mapping filter(NMF) is presented to efficiently extract the features. And in the second block, the estimator called neural networks fault pattern estimator(NFPE) is also presented to classify the fault types by the extracted effective features obtained from NMF. Each block of these applied schemes is trained by back-propagation algorithm of multilayer perceptron and show the fast and accurate pattern recognition by ability of multilayer neural networks. The test result of this approach are obtained the good performance from the fault transient wave signals of EMTP(electromagnetic transients program) in the various fault conditions of power systems.

Key Word : Pattern Recognition, Distance Relaying, Mapping Filter, Fault Pattern Estimator, Back-Propagation Algorithm

1. 서 론

전력시스템의 사고에 따른 피해범위의 최소화와

정상운전상태로 환원하는 복구능력의 극대화를 위해 핵심시스템 중의 하나인 계통의 보호, 제어 및 진단기능을 담당하는 보호계전시스템에 대한 중요

*이 논문은 1996년도 한국학술진흥재단의 공모과제 연구비에 의하여 연구되었음.

성이 더욱 증가되어, 사고검출의 다양화 및 신속화, 감시제어기능, 보수점검의 합리화등이 요구된다. 이에따라 보호계전 시스템은 계전입력신호의 왜곡에도 불구하고 고장을 신속정확하게 감지하여야 한다. 대부분의 디지털 거리계전 알고리즘은 기본과 성분에 기초를 두고 최적의 직교함수를 적용하여 계통의 고장상태와 고장지점을 추정, 판단하므로 알고리즘의 신뢰도와 속도는 보호계전시스템의 왜곡된 입력신호에서 기본과 성분을 얼마나 신속하고 정확하게 추출 하느냐에 따라 결정된다. 그런데 기계식 및 아나로그 방식에서 벗어나 연구된 기존의 디지털 계전기법은 aliasing, picket-fence effect 등의 단점이외에도 알고리즘의 연산부담과 더불어 동작속도가 결정적인 제한요소로 작용한다. 이를 개선하기 위해 주로 수치적인 연산 수를 감소시키거나 데이터 윈도우의 크기를 줄이는 방법 등이 사용되었다[1, 2, 3]. 그러나 이 계전알고리즘은 폰 노이만 방식의 순차적처리(sequential processing)기법으로 계통의 조건과 서비스의 상태변화에 대응하기 어렵고 계전시스템의 동작속도에도 한정된 조건을 가지고 있다[9]. 따라서 계통의 상황변화에 적용성을 갖고 신속, 정확히 처리 할 수 있는 새로운 방식이 요구되어 근래에는 인공지능(artificial intelligence) 이론을 중심으로한 지능형 디지털 보호 계전방식이 연구되고 있다. 이에 신경계통을 모방한 병렬처리 구조형으로서 학습에 의해 noise에 강인(robust)한 비선형 추출 기능등 많은 장점으로 복잡한 신호처리(signal processing)와 패턴인식(pattern recognition)을 적용하는데 널리 이용되고 있는 신경회로망(artificial neural network)을 이용하여 고장의 초기 검출 및 고저항 아크고장을 검출하는 알고리즘이 연구되었고[11, 12], 거리계전시스템의 동작속도를 개선하는 알고리즘이 적용제시되었다[10]. 그러나 이러한 기법들은 정확한 고장형태 판별 및 분석에는 미흡한 기능을 가지고 있으며, 신경회로망의 입력패턴 형성을위한 선행단계에서 수치적 연산부담을 안고 있다.

그런데 거리계전시스템은 계전입력신호로부터 고장의 고유패턴이 어떤 부류에 속하는 패턴인지 를 분석하여 분류, 판별하고, 고장의 발생여부, 형태 및 거리를 추정하고 적절한 트립(trip) 신호를 내보내는 일종의 패턴인식 시스템이다. 이와같은

거리계전시스템을 본 연구에서는 패턴인식시스템 구조로서 전처리(preprocessing)단계, 특징추출(feature extraction)단계과 분류(classification)단계의 세단계로 구성하였으며, 패턴인식시스템의 전체 동작속도를 증진시키기 위해 주요한 두 단계인 특징추출과 분류단계에 각각 신경회로망을 적용하여 신속하게 기본과 성분을 추정하고, 연속적으로 고장형태를 판별할 수 있도록 하는 일련의 패턴인식시스템으로 구성된 패턴인식형 거리계전기 법을 제안하였다. 특징추출단계에서는 필터링특성을 갖는 적절한 구조의 신경회로망 맵핑필터(neural network mapping filter : NMF)에의하여 신속하게 특징 파라미터(feature parameter)인 기본과 성분이 추출되며, 또한 분류단계에서는 출력된 전류의 기본파성분을 입력패턴으로 하는 신경회로망 고장패턴추정기(neural network fault pattern estimator : NFPE)에 의하여 고장상태, 고장종류가 고속으로 판별된다. 아울러 판별된 고장종류에 따라 특징추출단계에서 출력된 전압, 전류의 기본파성분으로부터 고장점의 거리정보가 산정된다. 제시된 기법의 성능을 검증하기 위하여 전자 과도해석 프로그램인 EMTP(electro magnetic transients program)로 시뮬레이션하여 얻은 다양한 과도 고장파형의 계전신호를 활용하여 평가하였으며, 그 결과 제시된 기법은 학습되지 않은 임의의 패턴에 대하여 적응성을 가지고 효율적으로 고장점을 추정할 수 있었으며 3샘플 이내에서 고장형태를 신속하고도 정확하게 판별하였다.

2. 패턴인식을 위한 신경회로망의 적용

2.1 패턴인식

패턴인식은 외부세계의 다양한 대상인 패턴을 종류별로 분류요약하여 개념에 대응시켜 인식하는 것이다. 즉, 입력영역(input domain)에서의 다양한 특징패턴 데이터와 출력영역(output domain)의 특정패턴 데이터 사이의 맵핑과정으로 다양한 입력특징패턴을 종류별로 유한개의 영역으로 분할하여 각 영역에 각각 유한개의 이산집합인 개념에 대응시키는 작업이다. 이때 각각의 특징패턴은 공간적 또는 시간적으로 분포되어 있으며 관측에 의해 유한차원의 벡터로 근사적으로 나타낼 수 있다. 따라서 많은 정보를 가진 패턴으로부터 인식에 본질적

으로 유효한 정보를 추출하고, 클래스(class)의 분류와 카테고리(category)화를 위한 특징 파라미터의 선택과 평가가 중요한 과제이다[7, 8].

또한, 입력되는 패턴이 어떤 부류에 속하는 패턴 인지를 분류판별하는 것을 목적으로 하는 일반적인 패턴인식은 특징추출 단계와 분류단계의 두 단계로 구성된다. 특징추출 단계에서는 입력패턴으로부터 서로 다른 부류에 속하는 패턴을 잘 구별해 줄 수 있는 N개의 원소로 된 특징 파라미터를 구하여 특징패턴을 형성한다. 분류 단계에서는 M개의 부류중에서 주어진 N개의 특징 파라미터로 구성된 특징패턴에 가장 유사한 것을 찾아내는 작업을 수행 한다. 패턴인식은 크게 클래스를 알 수 없는 미지의 경우와 이미 클래스를 알고 있는 경우로 나눌 수 있다. 전자는 미지의 대상집합을 무엇인가의 의미로 닮은 것끼리 같은 종류로 한데 묶어 요약하여 이해하는 일종의 개념형성으로 분류이다. 그리고 클래스를 알고 있는 경우는 좁은 의미에서의 패턴인식으로 이미 알고있는 클래스에 관한 지식에 바탕을 두고 주어진 대상이 어떠한 클래스에 속하는가 판정하는 것으로 식별이라고 표현한다. 이와같은 패턴인식을 수행하는 방법은 원형정합(template matching), 통계적(statistical) 및 구문론적(syntactic) 방법 등이 연구되어 왔고, 최근에는 신경회로망을 이용하거나 퍼지이론(fuzzy theory)을 이용한 방법과 신경회로망과 퍼지이론의 장점을 결합하거나 외형적인 유사성을 결합한 융합이론(fusion theory) 등이 활발히 연구되고 있다. 본 연구에서는 신경회로망을 이용한 방법으로 계통의 고장발생 시의 패턴인식을 거리계전시스템에 적용되었다.

2.2 신경회로망의 특성

신경회로망은 뉴런(neuron)과의 상호연결에 의한 분산기억(distributed memory)과 적용학습으로 고도의 병렬처리성에 의해 신속한 신호처리를 할 수 있을 뿐만아니라, 임의의 입력 N 차원공간을 출력 M 차원공간으로 맵핑, 즉 그림1과 같이 임의의 함수 $f(\cdot)$ 를 $X_n \subset R^n \rightarrow R^M$ 으로 맵핑시킬 수 있으며 신경회로망의 입출력 공간의 맵핑특성에 따라 연상기억(associative memory), 필터, 변환(transform), 분류, 인식(perception), 최적화(optimization)등의 기능을 수행 할 수 있다[4, 5].

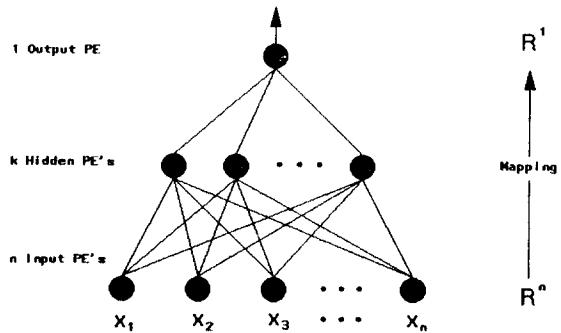


그림 1 신경회로망의 맵핑특성

Fig. 1 Mapping characteristics of neural networks

또한 계통의 사고시에 다양한 noise를 함유한 비선형 입력정보로부터 고차의 비선형함수로서의 해를 출력할 수 있는 특성이 있다. 따라서 신경회로망으로 구성된 패턴인식 시스템은 기존의 패턴인식 시스템에 비하여 다음과 같은 장점이 있다. 첫째, 신경회로망의 고도의 병렬처리성으로 신속한 처리가 가능 하다. 둘째, 입력패턴이 미리 학습된 패턴에 비해 약간 손상된 형태일지라도 잘 인식해 낼 수 있다. 세째, 학습되지 않은 새로운 입력패턴에 대해서도 가장 비슷한 부류의 패턴을 찾아낼 수 있다. 네째, 구조가 간단하여 프로그램 과정에서 복잡한 소프트웨어 코딩이 필요없이 단지 유니트(unit, processing element)간의 연결링크(connection link)에 대한 연결강도(weight)만을 학습시키면 되는 편의성이 있다. 본 연구에서는 맵핑 신경회로망의 한 형태로서 다층퍼셉트론(multilayer perceptron) 신경회로망을 이용하여 입출력 공간을 구성하였으며, 학습법칙은 역전파(back-propagation)학습알고리즘인 GDR(generalization delta rule)을 이용하였으며, 이때 활성화 함수(activation function)로는 시그모이드함수를 사용하였다[6, 7].

2.3 패턴인식시스템의 신경회로망 적용

신경회로망을 이용하여 패턴인식시스템을 구현하는데는 세가지 방법이 있다. 첫째는 입력 패턴을 직접 신경회로망에 입력하여 패턴을 인식하도록 하는 방법이고 둘째는 일반적인 패턴인식시스템의 구조에서 분류단계만을 신경회로망으로 대치하는 방법이며, 세째는 특징추출과 분류단계에 각각

신경회로망을 적용하는 방법이다. 첫번째 방법은 특징추출 단계를 거치지 않고 신경회로망에 의해 구해질 수 있다고 보는 방법으로 이상적 이긴 하지만, 실제통에 많은 noise를 포함하고 있어 적용하기에는 효율적이지 못하며, 반면에 두번째 방법은 특징 파라미터의 크기를 제한하여 소수의 입력만을 사용할 수 있기 때문에 일반적인 시스템에서는 채택 할 수 있으나 특징추출 단계에서 사용되는 알고리즘이 복잡처리에 부적합한 단점이 있다. 즉 많은 연산부담이 요구되는 특징추출 단계를 순차적 연산에 의해 처리해야 한다면 시스템 전체의 처리속도를 향상시킬 수 없으므로 보호계전시스템에서의 신경회로망을 이용하는 장점을 살릴 수 없다. 따라서 중요한 성능평가요소인 고속성이 요구되는 거리계전시스템을 위해 본 연구에서는 특징 추출과 분류단계에 각각 신경회로망을 적용하는 세번째 방법의 패턴인식기법이 적용되었다.

3. 패턴인식형 거리계전기법

3.1 시스템의 구성

전력시스템의 사고는 고장발생시에 고장의 상태, 고장의 형태 및 고장 거리에 따라 고유의 패턴을 가지고 있는데, 거리계전 시스템은 CT 및 PT를 통하여 A/D 변환기로부터 입력되는 그 고유의 패턴이 어떤 부류에 속하는 패턴인지를 분석하여 분류, 판별하고 상태를 추정하는 것으로 고장의 발생여부, 형태 및 거리를 추정하고 적절한 트립신호를 내보내는 일종의 패턴인식 시스템이다. 이와같은 거리계전 시스템을 본 연구에서는 신경회로망을 도입하여 그림 2와 같은 패턴인식시스템으로 구성되었다.

그림 2는 제시된 패턴인식형 거리계전시스템의 블록도이며, 시스템의 구성은 전처리단계, 특징 추출단계, 분류단계로 구성되었다. 거리계전시스템은 고속성이 중요한 성능평가 요소이므로 시스템 전체의 처리속도를 향상시키기 위하여 신경회로망을 추출단계와 분류단계의 각각에 모두 적용하는 패턴인식 기법으로 그림 2와 같이 구성되었다.

이와같이 구성된 시스템의 각 단계별 적용 방법은 다음과 같다. 첫째, 전처리단계는 입력되는 전압, 전류의 계전입력신호가 신경회로망의 입력에 알맞도록 하고 -1과 1사이로 정규화(normalization)

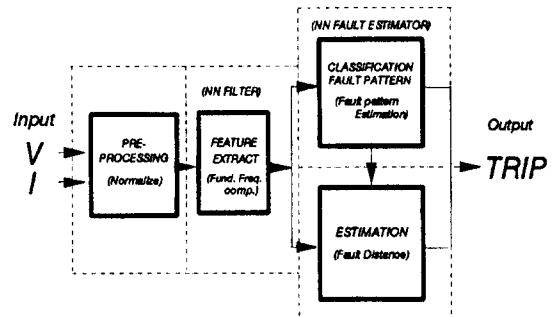


그림 2 패턴인식형 거리계전시스템 블록도

Fig. 2 Block diagram of pattern recognition based distance relaying system

시키며 둘째, 특징추출단계는 전처리된 입력패턴으로부터 서로 다른 부류 즉, 각 고조파에 속하는 패턴을 잘 구별해 줄 수 있는 특징 파라미터를 구한다. 그런데 전력계통 고장 발생시에 나타나는 noise가 함유된 전압, 전류파형으로부터 기본파성분이 가장 우세한 성분이며, 일반적인 거리계전 알고리즘을 적용할 수 있으므로 특징 파라미터로 기본파성분을 선택하였으며, 이와같은 기본파성분을 추출 할 수 있도록 필터링특성을 갖는 신경회로망 맵핑필터가 적용되었다. 셋째, 분류 단계는 고장패턴추정과 고장점추정 단계로서 선행단계에서 추출된 특징파라미터인 전류의 기본파성분으로 구성된 고장과도 패턴을 입력패턴으로 고장상태 및 고장형태가 판별된다. 이때 신경회로망 고장패턴추정기가 적용제시되었다. 아울러 판별된 고장종류에따라 추정된 전압, 전류의 기본파성분으로부터 고장점의 거리가 추정된다.

3.2 특징 파라미터 추출을 위한 맵핑필터

패턴인식시스템의 특징추출단계에 적용되는 신경회로망 맵핑 필터를 구현하기위해 신경회로망의 맵핑특성을 이용하여 필터링함수의 특성을 갖도록 신경회로망을 학습시켜 필터를 구현하였다. 학습 패턴 형성을 위해 전력계통의 사고시 발생되는 과도파형을 신경회로망에 학습시킨다는 것은 고장의 종류 및 고장 점등 사고상황이 매우 다양하기 때문에 많은 난점이 내재한다. 따라서 다양한 고장과도파형에서 특정 파라미터인 기본파 성분을 추출할 수 있도록 임의의 랜덤파형으로 학습패턴을

형성 하였다. 맵핑 신경회로망의 일종인 다층퍼셉트론을 사용하여 학습하였으며 역전과 학습알고리즘인 GDR을 이용하여 목표필터(target filter)인 DFT(discrete fourier transform)로 그림 3과 같이 맵핑필터를 구성하였다[13].

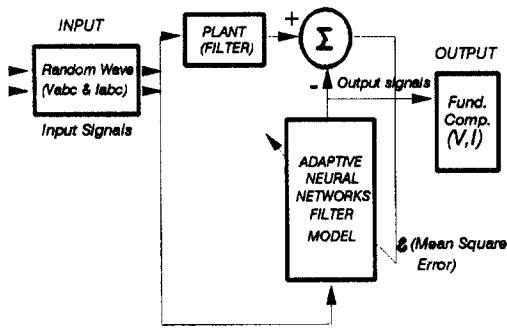


그림 3 신경회로망 맵핑필터 모델링

Fig. 3 Neural networks mapping filter modeling

학습에 사용된 입력 랜덤파형은 다음 식(1)과 같다.

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

여기서

$$\text{amp}(i) = \sum_{m=1}^n (1.0 / m^{1/2}) * \text{rand}()$$

$$\text{phase} = \text{rand}() / 32767$$

이다. n은 고조파 차수. N은 한주기당 샘플수, 그리고 $\text{rand}()$ 는 난수를 나타내며 랜덤파형은 최대 32767의 크기와 2π 이내의 위상을 갖는다. 신경회로망은 완전연결(full connected) 구조로 구성되었으며 학습을 통하여 주어진 입출력 공간에 대한 적절한 은닉층의 수와 유니트수가 선정된다. 이는 신경회로망이 출력패턴에 대한 맵핑특성으로 기본파성분을 추출하는데 중요한 역할을 한다. 또한 입력층의 유니트수는 샘플링률(sampling rate)에 따라 주기당 샘플수로 결정되며, 출력층의 유니트수는 추정 될 파라미터수 즉, 기본파성분을 포함하여 추출하고자 하는 고조파 수에 따라 결정된다. 이와같이 구성된 맵핑필터는 신경회로망의 고도의 병렬처리, 일반화(generalization)특성 및 보간(interpolation)성능에 따라 선형 및 비선형 필터링 특성을 갖게 되며, 학습하지 않은 임의의 랜덤파형

및 EMTP로 시뮬레이션된 전력계통의 과도파형에 적용되었다.

3.3 고장패턴 추정을 위한 신경회로망

패턴인식시스템의 분류단계에 적용되는 신경회로망 고장패턴 추정기는 특정추출단계의 맵핑필터로부터 추출된 전류 기본파 성분의 실효치를 입력 패턴으로 하여 고장의 상태 및 형태를 추정하기 위하여 신경회로망을 맵핑필터와 같이 다층퍼셉트론으로 구성하였고 학습은 GDR을 이용하였다. 신경회로망 고장패턴추정기의 입력패턴은 동작속도를 증진시키기 위하여 각 상의 기본파성분 전류 I_a , I_b , I_c 와 영상분전류 I_0 의 실효치를 연속 3 샘플씩 취한 12샘플 패턴윈도우 크기로 결정하여 12개의 입력 유니트에 대응되도록 표 1과 같이 구성하였다. 여기서 지락과 단락을 구분하기 위하여 영상분전류를 도입하였으며 t는 고장 순간을 나타낸다.

표 1 기본파성분 입력패턴

Table 1 Input pattern of fundamental component

| A-Phas Fund. Current | B- Phase Fund Current | C-Phase Fund.Current | Zero Sequence Fund. Current |
|--------------------------------|--------------------------------|--------------------------------|--------------------------------|
| $I_a(t-1)$ $I_a(t)$ $I_a(t+1)$ | $I_b(t-1)$ $I_b(t)$ $I_b(t+1)$ | $I_c(t-1)$ $I_c(t)$ $I_c(t+1)$ | $I_0(t-1)$ $I_0(t)$ $I_0(t+1)$ |
| No.1 No.2 | No.3 No.4 | No.5 No.6 | No.7 No.8 No.9 No. 10 11 12 |

목표출력 패턴은 출력층을 4개의 유니트로 구성하여 각상의 기본파성분 전류 I_a , I_b , I_c 와 영상분 I_0 에 대응시켰으며, 출력층의 각 유니트가 정상상태 일때 0, 고장상태 일때 1로 하고 지락고장인 경우 영상분 유니트가 1, 단락고장인 경우 0으로 하여 4개의 출력층 유니트를 갖는 신경회로망으로 표2와 같이 맵핑 하였다.

이와같이 구성된 신경회로망을 이용한 고장패턴 추정기는 입력 층과 출력층이 각각 12개와 4개의 유니트로 이루어지고 완전연결(full connected) 구조로 구성되었으며 주어진 입출력 패턴에 대한 적절한 은닉층의 수와 유니트수는 학습에 의해서 선정된다. 고장 입력패턴에 따라 고장 출력패턴으로 맵핑된 신경회로망 고장패턴추정기는 임의의 고장

표 2. 고장패턴추정기의 출력패턴

Table 2. Output Pattern of fault pattern estimator

| Output Units | | | | Meaning |
|----------------|----------------|----------------|----------------|-----------------------|
| O _a | O _b | O _c | O _u | |
| 1 | 0 | 0 | 1 | A-phase ground fault |
| 0 | 1 | 0 | 1 | B-phase ground fault |
| 0 | 0 | 1 | 1 | C-phase ground fault |
| 1 | 1 | 0 | 1 | AB-phase ground fault |
| 0 | 1 | 1 | 1 | BC-phase ground fault |
| 1 | 0 | 1 | 1 | AC-phase ground fault |
| 1 | 1 | 0 | 0 | AB-phase short fault |
| 0 | 1 | 1 | 0 | BC-phase short fault |
| 1 | 0 | 1 | 0 | AC-phase short fault |
| 1 | 1 | 1 | 1 | Three-phase fault |
| 0 | 0 | 0 | 0 | None fault |

패턴이 입력되었을 경우 표 2 중의 하나의 출력패턴으로 분류되고 신속히 고장형태를 추정 판별하게 된다. 또한 고장점의 거리추정은 고장패턴추정기의 출력인 고장형태에 따라 특징추출단계에서 추출된 전압, 전류의 기본파성분에 의해 계전기에서 본 고장점의 임피던스 Z_f 가 산정된다[2].

4. 시뮬레이션 결과 및 고찰

4.1 모델계통 적용 및 학습

제안된 패턴인식형 신경회로망 거리계전기법을 검증하기위해 선택한 모델계통은 154[KV], 송전선으로서 최대 200[Km]의 길장을 갖으며, 전자 과도 해석 프로그램인 EMTP를 이용하여 정상상태 및 과도상태의 각종류의 고장유형, 고장거리, 고장점 저항, 그리고 고장 발생각에 따른 전압과 전류의 데이터를 얻었다. 그림 4는 EMTP 모델계통을 나타낸 것이다.

모델시스템의 선로정수는 EMTP 선로정수루틴을 이용하여 한 주기당 30도 간격(1.38[ms])으로 12번 샘플링하여 데이터를 얻었으며 한샘플씩 이동하는 moving 윈도우 방식으로 모델계통이 시뮬



그림 4 모델시스템

Fig. 4 Model system

레이션되었다. 고장시 발생되는 과도현상에 대한 실험 조건은 표 3, 표 4와 같다.

표 3 특정 파라미터 추출을 위한 실험조건

Table 3 Experimental condition for feature extraction

| Simulation | 학습조건 | 시험조건 |
|----------------------|---------------------------|--|
| Fault | Random | 20, 100, 180 |
| Fault Type | Random | 1LG:(A, B, C) 2LG:(AB, BC, AC) LLS:(AB, BC, AC) ILG : (ABC) |
| Sampling Rate [S/C] | 12 | 12 |
| Fault Angle [Degree] | Random | 0°, 60°, 90° |
| Fault Impedance[Ω] | Random | 2, 50 |
| System Frequency[Hz] | 60 + Harmonics Power(m,n) | 60 |
| Total No. of Fault | 500 | 99 |

패턴인식시스템의 특징추출단계에 적용된 신경회로망 맵핑필터의 학습패턴을 형성하기 위해 식(1)에서 랜덤파형의 한 주기당 동일간격으로 12샘플로 샘플링하고 관련된 고조파 차수 n 을 5로하여 신경회로망의 입력에 적합하도록 -1과 1사이로 정규화한 500개의 랜덤파형인 표 3의 학습조건으로 학습용 입력 패턴을 형성하였다. 입력패턴에 대한 출력은 기본파성분의 실효치로 패턴을 형성하여 맵핑필터를 학습하였다. 그런데 고장점의 거리를 산정하기 위해서는 기본파성분 페이서의 실수부와 헤수부를 각각 추출 하는 별도의 맵핑필터를 구성해야 하지만 다음 단계인 고장패턴추정에서 직접 이용 할 수 있으며, 우선적으로 기본파성

표 4. 고장패턴추정을 위한 실험조건

Table 4. Experimental condition for fault pattern estimation

| Simulation | 학습조건 | 시험조건 |
|----------------------|--|--|
| Fault Distance [Km] | 100 | 20, 100, 180 |
| Fault Type | 1LG:(A, B, C) 2LG:(AB, BC, AC) LLS:(AB, BC, AC) 1LG : (ABC) | 1LG:(A, B, C) 2LG:(AB, BC, AC) LLS:(AB, BC, AC) 1LG : (ABC) |
| Sampling Rate [S/C] | 12 | 12 |
| Fault Angle [Degree] | 60° | 0°, 60°, 90° |
| Fault Impedance[Ω] | 2 | 2, 50 |
| System Frequency[Hz] | 60 | |
| Total No. of Fault | 165 | |

분의 실효치로 피상임피던스에 대한 고장거리를 산정하여 1선지락인 경우를 평가해봄으로써 제안된 기법의 가능성을 검토할 목적으로 선택되었다. 이와같이 구성된 신경회로망 맵핑필터의 구조는 입력층이 12개의 샘플링수에 대응되는 12개 유니트로, 출력 층이 기본파성분의 실효치에 대응되는 1개의 유니트(unit)로 이루어져 있고, 은닉층의 층 수는 2개이며, 첫번째 은닉층의 유니트수는 11개이고 두번째 은닉층의 유니트수는 13개이다. 이는 은닉층의 수를 2개 이내로 하고 각층의 유니트의 수, 학습률과 관성항을 가변하면서 수렴오차가 2.4×10^{-5} 이내에 수렴될때 얻은 시뮬레이션 결과이며 학습률과 관성항은 0.9와 0.7로 결정 되었다. 이와같이 구성된 맵핑필터는 고장발생시 발생되는 표 3의 시험조건 인 과도파형에 적용된다. 즉, 랜덤파형으로 학습 된 신경회로망을 시험조건의 과도파형에의 적용 결과를 살펴본다.

또한 패턴인식시스템의 분류단계에 적용된 신경회로망을 이용한 고장패턴추정기는 패턴인식시스템의 특징추출단계인 맵핑필터로부터 추출된 전류의 실효치중에서 표 4의 학습조건으로 이루어진 165개의 입력패턴으로 학습되었다. 입력층과 출력층의 유니트수는 표 1과 표 2의 입출력패턴에 따라 각각 12개와 4개의 유니트로 이루어지고 학습

에의해 결정된 은닉층의 층수는 2개이며, 첫번째와 두번째의 은닉층 유니트수는 각각 10개이다. 이는 맵핑필터와 같이 은닉층의 수를 2개 이내로 하고 각층의 유니트의 수, 학습률과 관성항을 가변하면서, 수렴오차가 4.33×10^{-4} 이내에 수렴될때 얻은 시뮬레이션 결과이며 학습률과 관성항은 0.9와 0.7로 결정되었다. 이와같은 패턴인식형 거리계전기법을 수행하기 위한 전체적인 시뮬레이션 블록도는 그림 5와 같다

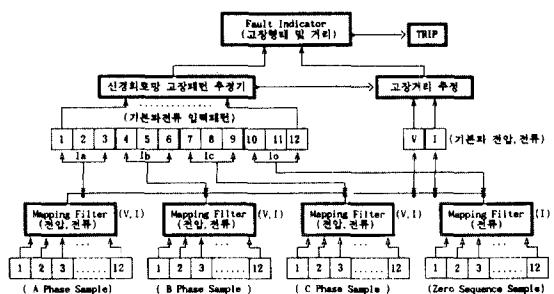


그림 5. 시뮬레이션 블럭도

Fig. 5 Simulation block diagram

4.2 맵핑필터의 기본파성분 추정결과 및 고찰

본절에서는 학습되지 않은 임의의 랜덤파형과 표 3의 EMTP 과도파형을 맵핑필터에 적용하여 신경회로망 맵핑필터의 성능을 평가하였다. 그림 6은 학습되지 않은 99개의 랜덤파형을 대상으로 신경회로망 맵핑필터의 추정결과를 나타낸 것으로, 임의의 랜덤파형에서 추출된 기본파성분과 DFT 방법에 의한 결과와 비교하였다. 여기서 X축은 12샘플링된 99개의 랜덤파형 윈도우 수를 나타내며, Y축은 추정된 기본파성분의 크기를 나타낸다. 그림 6에서 나타낸 바와같이 임의의 랜덤파형의 기본 파성분의 크기가 DFT 방법에 의한 결과와 거의 동일한 값으로, 전혀 학습되지 않은 랜덤파형의 기본파성분이 효율적으로 추출되었음을 알 수 있다.

또한 과도파형의 기본파성분을 추출하기 위해 맵핑필터를 전력시스템의 고장 발생시의 불평형과도파형에 적용하였다. 일반적으로 고장이 전압의 첨두치 부근에서 발생하였을 경우에 고조파의 함유율이 높으며 고장전압이 영점근처를 통과하는

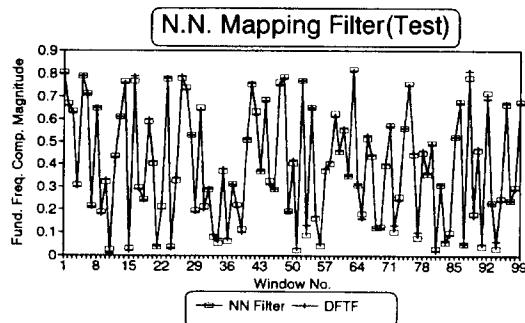


그림 6 랜덤파형의 기본파성분 추출에 대한 맵핑필터와 DFT 방법과의 비교

Fig. 6 Comparison of mapping filter with DFT in the extraction of fund. frequency component of random wave signals

순간에 고장이 발생하였을 경우는 직류 offset이 현저하게 나타난다. 따라서 약조건인 고장발생각 0°인 경우와 90°인 경우의 과도파형을 적용함으로써 그 성능을 평가하였다.

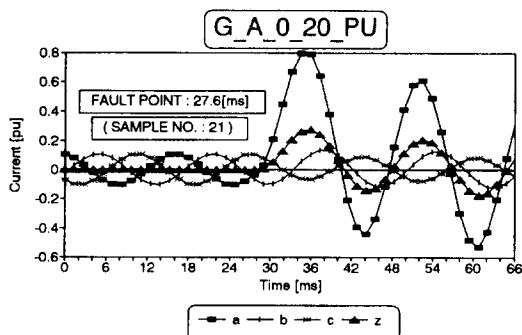


그림 7 A상 지락고장 전류 P.U. 순시치(고장발생각 0°)

그림 7은 모델시스템의 20[km] 지점에서 고장 발생각 0°에서 발생한 1선 A상 지락고장인 경우의 고장 전류파형을 주기당 12샘플로 샘플링하고 패턴인식시스템의 전처리단계에서 정규화된 순시치 과도파형이다. 고장시간은 27.6[ms]이며 샘플수로는 21번째 샘플인 고장발생각 0° 근처에서 고장이 발생하였으며, 직류 offset이 포함되어 있음을 알 수 있다. 그림 8은 이와 같은 그림 7의 과도파형

을 신경회로망 맵핑필터에 moving 윈도우 방식으로 입력하여 출력된 기본파성분 추출결과를 나타내며 DFT에 의한 결과와 비교되었다. 이는 신경회로망의 비선형 맵핑특성과 일반화 특성에 의해 전혀 학습되지 않은 과도파형으로부터 기본파성분이 추출되었음을 나타내고 있으며, 또한 직류 offset 성분이 많이 포함된 과도상태의 파형에 대하여 맵핑필터의 출력이 DFT 방법보다 더욱 안정된 특성을 나타내고 있음을 알 수 있다. 그림 9는 모델계통의 20[km] 지점에서 고장 발생각 90°에서 발생한 1선 A상 지락고장인 경우의 고장 전압파형을 주기당 12샘플로 샘플링하고 패턴인식시스템의 전처리단계에서 정규화된 순시치 과도파형이다. 고장시간은 31.74[ms]이며 샘플수로는 24번째 샘플인 고장발생각 90° 근처에서 고장이 발생하였으며, 샘플링효과에 의해 높은 고조파성분은 저감되지만 낮은 고조파성분에 의해 파형이 원형의 모습을 나타내고 있음을 알 수 있다. 그림 10은 이와 같은 그림 9의 과도파형을 신경회로망 맵핑필터에 moving 윈도우 방식으로 입력하여 출력된 기본파성분 추출 결과를 나타내며 DFT에 의한 결과와

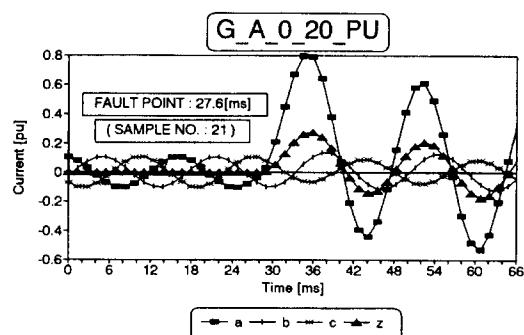


그림 8 기본파성분 추출에 대한 맵핑필터와 DFT와의 비교

Fig. 8 Comparison mapping filter with DFT for fund.

frequency component extraction

비교되었다. 이는 신경회로망의 보간성능과 일반화 특성에 의해 전혀 학습되지 않은 과도파형으로부터 기본파성분이 고장발생각 0도의 경우와 같이 효율적으로 추출되었음을 나타내고 있으며, 또한 직류 offset 성분이 적은 과도상태의 파형에 대하여 신경회로망 맵핑필터의 출력이 DFT 방법과 같은 안정된 특성을 나타내고 있음을 알 수 있다.

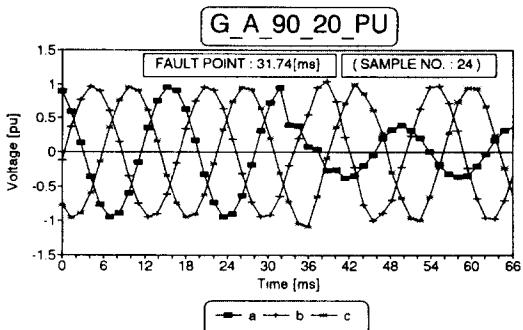


그림 9 A상 지락고장 전압 P.U.순시치(고장발생각 90°)
Fig. 9 Ph. voltage at A ph. to ground fault(fault 90°)

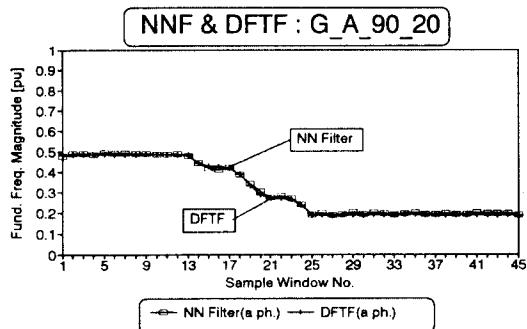


그림 10 전압 기본파성분추출의 맵핑필터와 DFT의 비교(90°)
Fig. 10 Comparison mapping filter with DFT for voltage fund. frequency component extraction(fault 90°)

4.3 고장패턴추정기의 고장판별 결과 및 고찰

본 절에서는 고장상황의 상태를 판별하는 신경회로망 고장패턴추정기의 실험결과를 악조건의 고장상황인 고장발생각 0도와 90도 경우의 각종 사고를 검증하므로써 그 성능을 평가하였다.

그림 11은 신경회로망 맵핑필터를 통하여 추출된 각상과 영상분 전류의 3개의 샘플윈도우에 대응 입력되는 12개의 입력층 유니트로 구성된 신경회로망 고장패턴 추정기에 한샘플씩 이동하는 moving 윈도우 방식으로 입력한 고장패턴 추정결과를 나타낸 것이다. 여기서 X축은 각상과 영상분을, Y축은 샘플윈도우 수를, 그리고 Z축은 고장패턴추정기의 출력을 나타낸다.

이 그림은 그림 7과같은 1선 A상 지락고장인 경우의 고장패턴 추정결과로서 고장 샘플윈도우(fault sample window)인 샘플윈도우 No. 8-10이내

의 10번째이후 샘플윈도우수에서 A상과 영상분의 신경회로망 출력유니트가 갑자기 0에서 1로 바뀌는 패턴을 보이고 있는데 이는 곧 A상 지락고장 사고임을 알 수 있다. 마찬가지로 그림 12는 3상고장인 경우의 추정결과로서 A상은 11번째이후 샘플윈도우수에서, BC상은 12번째이후 샘플윈도우

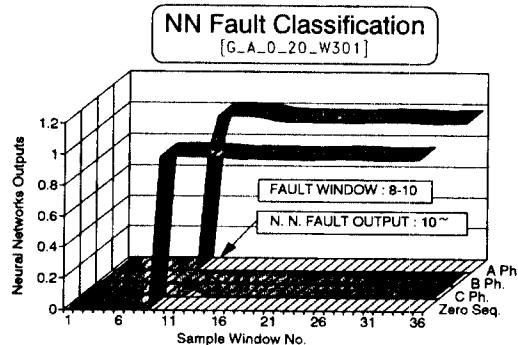


그림 11 고장패턴추정기의 A상 1선지락 고장출력패턴
(고장발생각 0°)
Fig. 11 Output of fault pattern estimator at A phase to ground fault (fault inceptioned at 0°)

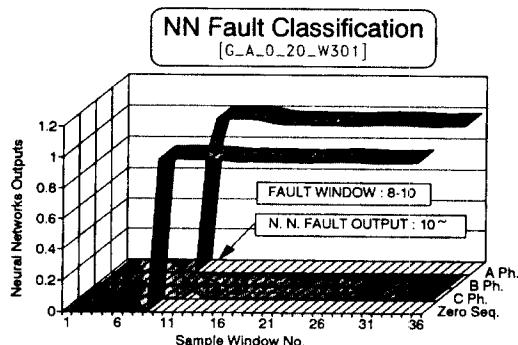


그림 12 고장패턴추정기의 3상고장 출력패턴 (고장발생각 0°)
Fig. 12 Output of fault pattern estimator at 3 phase fault (fault inceptioned at 0°)

수에서 모두 출력유니트가 갑자기 0에서 1로 바뀌는 패턴을 나타내고 있는데 이것은 곧 3상 고장임을 알 수 있으며 신경회로망의 맵핑특성으로 사고상황의 고장패턴을 고장후 3샘플이 내에서 정확히 판별함을 알 수 있다. 그림 13은 고장발생각 90도의 1선 A상 지락고장인 경우의 고장패턴 추정결과를 나타낸 것으로, 고장 샘플윈도우수인 샘플포

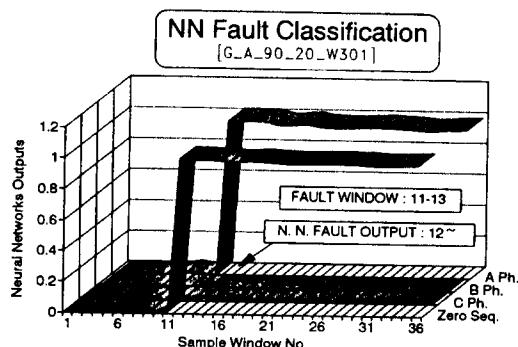


그림 13 고장패턴추정기의 A상 1선지락 고장 출력패턴(고장발생각 90°)

Fig. 13 Output of fault pattern estimator at A phase to ground fault (fault incepted at 90°)

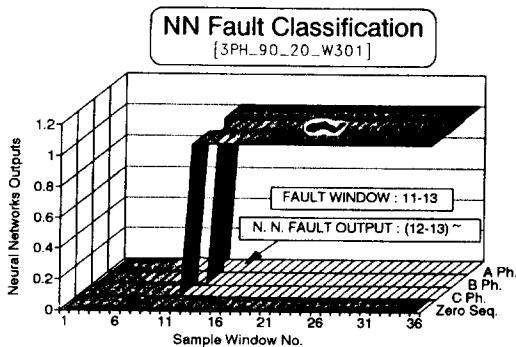


그림 14 고장패턴추정기의 3상고장 출력패턴(고장발생각 90°)

Fig. 14 Output of fault pattern estimator at 3 phase fault (fault incepted at 90°)

인트 11-13내의 12번째이후 샘플포인트에서 A상과 영상분의 신경회로망 출력유니트가 갑자기 0에서 1로 바뀌는 패턴을 나타내고 있는데 이는 곧 A상 지락고장 사고임을 알 수 있다. 또한 그림 14는 3상고장인 경우의 고장판별 결과로서 고장패턴을 12-13번째이후 샘플 포인트에서 정확히 판별하고 있다. 이는 고장종류에 따른 전류의 크기 및 상태변화, 고장발생각에 의해 발생되는 고조파 및 offset의 영향에 무관하게 신경회로망 고장패턴 추정기가 고장발생후 3샘플 이내에서 고장상태를 고장형태별로 신속하고도 정확히 판별하고 있음을 나타내고 있다. 아울러 고장거리 및 고저항 접지사고에 대해서도 동일한 결과를 나타내었다.

4.4 고장점의 거리추정 결과 및 고찰

패턴인식시스템의 분류단계에 적용된 신경회로망 고장패턴추정기에서 판별된 고장종류에 따라 신경회로망 맵핑필터를 통하여 추출된 기본파성분 전압, 전류의 실효치로 피상임피던스에 대한 고장거리를 추정하였으며 A상 1선지락 고장의 고장거리에 대하여 DFT 방법과 실험결과를 피상임피던

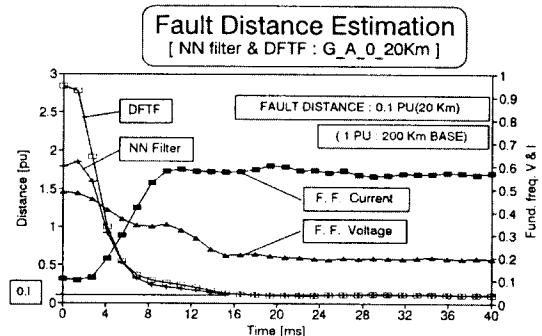


그림 15 A상 지락사고의 고장점의 거리추정(20 Km)

Fig. 15 Fault distance estimation A ph. to ground fault at 20Km

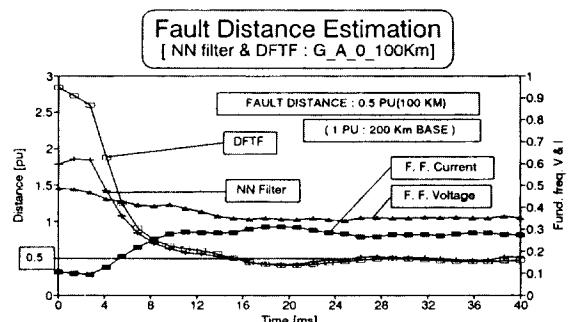


그림 16 A상 지락사고의 고장점의 거리추정(100Km)

Fig. 16 Fault distance estimation A ph. to ground fault at 100Km

스로 비교하였다. 그림 15와 그림 16은 고장발생각 0도의 고장거리의 추정결과로서 DFT로 추출된 결과와 함께 나타내었으며, 아울러 맵핑 필터로부터 출력된 기본파성분의 전압과 전류를 함께 우측 Y축기준으로 표시하여 비교되었다. 이는 계전시스템에서 본 고장거리가 각각 전체 200[Km](1 per unit : pu)의 긍장을 갖는 모델시스템의 10[%] 및

50[%] 지점인 20[Km](0.1 pu)와 100[Km](0.5 pu)에서 고장발생각 0도인 27.6[ms]에서 고장이 발생한 경우의 결과로, DFT에의한 결과와 수렴상태가 거의 동일하나 과도상태에서 미소한 안정된 특성을 보이고 있으며, 사고지점인 0.1 pu와 0.5 pu에 사고후 각각 16.6[ms]와 24[ms]에서 수렴하여 고장점의 거리가 짧을수록 빠른 일반적인 수렴특성을 나타내고 있음을 알 수 있다.

5. 결 론

본 논문에서는 패턴인식 형태로 구성된 거리계전시스템에 신경회로망을 적용한 패턴인식형 거리계전기법이 제안되었다. 제안된 기법을 랜덤파형 및 EMTP를 이용하여 얻은 다양한 고장 상황의 과도파형에 대하여 적용한 결과 다음과 같은 결론을 얻었다.

(1) 고속성이 요구되는 필터링 방법에 신경회로망을 도입하여 맵핑필터를 구성함으로써 특징추출단계에서 요구되는 수치적 연산부담을 감소시켰다.

(2) 랜덤파형을 학습패턴으로 구성된 신경회로망 맵핑필터가 학습되지 않은 랜덤파형 및 비선형 요소를 포함하는 고장발생시의 과도파형에 대하여도 효율적으로 특징 파라미터인 기본파성분을 추출함으로써 유효성이 입증되었다.

(3) 분류단계에 적용된 신경회로망 고장패턴추정기는 고장발생각에 의해 발생된 고조파 및 직류 offset의 영향, 전류의 크기 및 형태변화, 그리고 고저항 접지사고등 다양한 사고상황에서도 고장형태를 정확히 판별함을 확인하였다.

(4) 맵핑필터로부터 출력된 전류 기본파성분의 실효치를 입력패턴으로 하도록 구성된 신경회로망 고장패턴추정기는 고장형태을 고장발생후 3샘플(1/4주기)이내에서 고속으로 판별하였으며, 효율적으로 고장점의 거리가 산정될 수 있음을 확인하였다. 따라서 본 논문에서 제안된 기법은 앞으로 기본파성분 페이서의 실수부와 허수부를 추출하는 맵핑필터를 더하여 더욱 정밀한 고장점이 추정될 수 있으며 3샘플 이내에서 고장형태를 신속하고도 정확하게 판별하게 되었다. 그러나 추후 연구과제로는 전압과 전류의 연산에 의하지 않고 고장점의 거리를 실효치로도 더욱 신속하게 나타낼 수 있는 신경회로망이 연구되어야 할 것이다.

참 고 문 헌

- [1] A. T. Johns, S.K. Salman, Digital protection for power systems, Peter Peregrinus Ltd., 1995.
- [2] A. G. Phadke, J.S. Thorp, Computer relaying for power systems, RSP 1988.
- [3] S. R. Kolla, "Digital protection of transmission line using block pulse function," Int. J. Electrical Power & Energy System, vol. 10, no. 4, pp. 274-276, 1988.
- [4] Robert Hecht-Nielsen, "Theory of the backpropagation neural networks," IJCNN, vol. I, pp. 593~605, 1989.
- [5] K. Hornik, "Multilayer feedforward networks are universal approximator." Neural Networks, vol. 2, pp.359-366, 1989.
- [6] PDP Research Group, Parallel distributed processing, vol. 1-2, MIT Press, 1986.
- [7] Y. H. Pao, Adaptive pattern recognition and neural networks, Addison-Wesley, 1989.
- [8] R. J. Schalkoff, Pattern recognition : statistical, structural and neural approaches, John Wiley & Sons, Inc., 1992.
- [9] 박종근, 김일동 외 1인, "신경회로망과 퍼지논리를 이용한 보호계전기 지능화 기초연구", 대한전기학회 하계학술대회 논문집(B), pp. 911-914, 1994. 7.
- [10] 조경래, 강용철 외 4인, "신경회로망을 이용한 초고압 송전선 거리계전기 동작속도 개선 방법", 대한전기학회 논문지, vol. 46, no. 4, pp.475-481, 1997.
- [11] Ebron, S., Lubkeman, D. and White, M. "A Neural network approach to detection of incipient faults on power distribution feeders.", IEEE Trans, PD., vol. 5, no. 2, pp. 905-914 1990. 4.
- [12] A. Sultan et al., "Detection of high impedance arcing faults using a multilayer perceptron", IEEE Trans, PD., vol. 7, No. 4, pp. 871-1877, 1992. 10.
- [13] 신명철, 이복구, "신경회로망을 이용한 과도파형의 기본파성분 추출에 관한 연구," 대한전기학회 논문지, vol. 43, no. 4, pp.553-563, 1994.

[14] A. D. Culhane et al., "A neural net approach to discrete hartley and fourier

transforms", IEEE Trans. CAS., vol. 36, no. 5, pp. 695-703, 1989.



이복구 (Bock-Ku Lee) 정회원
1982년: 성균관대학교 전기공학과 졸업
1986년: 성균관대학교 대학원 전기공학과(석사)
1994년: 성균관대학교 대학원 전기공학과(박사)
1986년 ~ 1990년: 금성산전 연구소 주임연구원
1991년 ~ 1993년: 충남전문대학 제어계측과 조교수

현재: 명지전문대학 전기과 조교수

주관심 분야: 지능제어 및 컴퓨터응용, 패턴인식, 신호처리, 지능보호계전 등

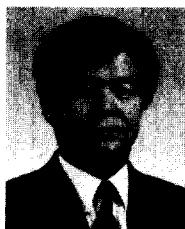


박철원 (Chul-Won Park) 정회원
1988년: 성균관대학교 전기공학과 졸업
1990년: 성균관대학교 대학원 전기공학과(석사)
1996년: 성균관대학교 대학원 전기공학과(박사)
1989년 ~ 1993년: 금성산전 연구소 주임연구원
현재: 국립 원주전문대학 전기과 전임강사

주관심 분야: 퍼지시스템, 지능제어 및 컴퓨터응용, 지능보호계전, 신호처리 등



윤석우 (Sug-Moo Yoon) 정회원
1981년: 성균관대학교 전기공학과 졸업
1983년: 성균관대학교 대학원 전기공학과(석사)
1993년: 성균관대학교 대학원 전기공학과(박사)
1983년 ~ 1990년: 해군사관학교 전기공학과 조교수
현재: 충남전문대학 제어계측과 부교수
주관심 분야: 병렬처리 및 컴퓨터응용, 지능제어, 지능보호계전, 신호처리 등



신명철 (Myong-Chul Shin) 정회원
1970년: 성균관대학교 전기공학과 졸업
1978년: 연세대학교 대학원 전기공학과(박사)
1970년 ~ 1975년: 한국전력 계통운용부 근무
1975년 ~ 1978년: 충북대학교 전기공학과 교수
1982년 ~ 1983년: 미국 코넬대학 전기공학과 객원교수
현재: 성균관대학교 전기전자 및 컴퓨터공학부 교수
주관심 분야: 전력지능제어 및 컴퓨터응용, 지능보호계전, 패턴인식, 병렬처리 등