

# 배전선로의 고장유형 판별을 위한 적응형 퍼지추론 시스템

## An Adaptive Network Fuzzy Inference System for the Fault Types Classification in the Distribution Lines

정호성 · 신명철

Ho-Sung Jung and Myong-Chul Shin

성균관대학교 전기전자 및 컴퓨터공학부

### 요 약

본 논문에서는 배전선로에서 발생하는 여러 고장유형을 판별하기 위해서 적응형 퍼지추론 시스템을 적용하는 새로운 기법을 제시하였다. 배전선로의 고장과 고장유사현상 데이터를 추출하기 위해서 EMTP를 이용하여 RL부하, 아크로부하, 컨버터부하가 있는 배전계통을 구성하고 여러 형태의 고장과 고장유사현상에 대해 시뮬레이션을 하였다. 이를 통해 얻은 전류파형으로부터 기본파성분, 영상분전류, 짝수 고조파성분의 합, 홀수 고조파성분의 합, 그리고 비정규 고조파성분의 합의 5개의 입력변수를 추출하고 학습을 통해서 각 입력변수의 소속함수의 소속도를 자동으로 결정하였다. 이 적응형 퍼지추론 시스템을 이용한 기법을 평가하기 위해서 학습시와 다른 고장상황을 모의하여 얻은 데이터와 실증시험 데이터를 이용하였다. 결과적으로 제안한 기법은 배전선로에서 발생하는 고장유형을 빠르고 정확하게 판별할 수 있었다.

### ABSTRACT

This paper proposed the new technique for the fault types classification using adaptive network fuzzy inference system in the distribution lines. To acquire the fault and fault-like data, many fault and fault-like conditions in RL load, arc furnace load and converter load were simulated by EMTP. The 5 input of the fundamental frequency component, zero sequence component current, the sum of even harmonics, the sum of odd harmonics, and the sum of sub harmonics were extracted from these simulated current signals and the degree of the membership function were determined automatically by learning. This technique was tested using another simulation data unused learning and actual experiment high impedance fault data. So, it can classify the fault types in the distribution lines fast and accurately.

**Key Words** : ANFIS, Fault Types Classification, Distribution Line, EMTP, Feature Extraction

### 1. 서 론

전력사용의 급증으로 인해 전력시스템의 보호에 대한 관심이 크게 대두되고 있다. 특히, 배전계통은 전기설비가 전기수용가에 밀집되어 있기 때문에 고장발생은 대규모 정전상태뿐만 아니라 인명피해, 화재발생, 그리고, 설비손상 등의 직접적인 문제를 발생시킬 수 있어 보다 신뢰성 있는 계전기법이 요구되고 있다. 그러나, 우리 나라의 배전계통인 다중접지 방식에서 고저항 지락고장(high impedance fault : HIF)이 발생하는 경우에는 일반적인 지락, 단락고장과는 달리 고장전류의 크기가 매우 작아 기존의 과전류 계전기로는 고장검출이 어려운 실정이다. 따라서 이러한 고저항 지락고장 검출을 위해서는 전류의 크기를 이용한 과전류 기법보다는 고장시 발생하는 아크현상으로부터 특정 고조파성분을 분석하는 기법이 이용되고 있다[1,2]. 또한 아크전류의 무작위적이며

불규칙한 특성을 고려한 카오스나 프랙탈 기법, 그리고 특정한 시간 대역에 대한 특정 주파수 분석에 적합한 웨이브렛 등의 연구되고 있다[3,4]. 그러나 이러한 하나의 특정한 고조파성분만을 이용하는 기법은 특정 고조파성분을 발생시키는 다양한 형태의 부하의 급증으로 인해 부하 사용시에 고장과 유사한 신호가 발생하여 계전기의 오동작을 초래하고 있다.

따라서 고장시에 나타나는 하나의 특징으로부터 정확한 고장을 검출하는 데에 어려움이 있어 고장과 고장유사시에 나타나는 다수의 특징을 입력으로 이용하여 신경회로망, 퍼지논리와 같은 인공지능기법에 적용하고 있다. 특히 퍼지논리의 경우에는 불확실한 정보로부터 유용한 정보를 추출할 수 있어 배전계통에서 나타나는 애매모호한 신호로부터 고장을 판별하는데는 매우 우수한 성능을 나타낼 수 있다. 그러나 우수한 성능을 좌우하는 입력력 공간의 퍼지변수의 선정에 있어서는 많은 시행착오를 거쳐야 하며 계통 변화로 인한 입력벡터의 변화에 대해서 정확한 성능을 발휘하기가 쉽지 않다[5-8].

이러한 퍼지논리의 문제를 해결하기 위해서 본 논문에서는 퍼지논리의 경험적인 판단을 요구하는 부분인 입력력 퍼지변수의 선정을 신경회로망의 학습능력으로 보완한 적응형 퍼지추론 시스템을 이용하는 새로운 기법을 제시하였다. 신

접수일자 : 2000년 1월 20일

완료일자 : 2001년 2월 21일

이 논문은 성균관대학교의 1998년도 63학술연구비에 의하여 연구되었음.

경회로망의 학습기능을 적용함으로써 최적의 입출력 공간을 결정할 수 있으며 계통 변화에 대해서도 고장검출에 신뢰성을 확보할 수가 있다. 이를 위해 일반적인 RL부하와 많은 양의 고조파를 발생시키는 아크로부하와 컨버터부하를 모의하고 이러한 부하가 있는 배전계통에서 발생하는 지락, 단락, 고저항 지락고장의 고장현상과 역률개선을 위한 콘덴서 뱅크의 투입과 대규모 부하의 일시적인 투입과 같은 고장유사현상을 EMTP(electromagnetic transients program)를 이용하여 시뮬레이션하여 데이터를 추출하였다. 이렇게 얻은 고장과 고장유사데이터로부터 적응형 퍼지추론 시스템에 적용하기 위해서 기본파성분, 영상분전류, 짝수 고조파성분의 합, 홀수 고조파성분의 합, 그리고 비정규 고조파성분의 합의 5개의 특징벡터를 추출하여 신경회로망을 이용하여 학습시켜 입출력변수의 소속도를 최적화시켰다. 그리고 제안한 알고리즘의 정확한 성능평가를 위해서 고장발생각이나 부하용량 등의 다양한 계통변화에 대한 시뮬레이션 데이터와 고저항 지락고장을 모의한 실증실험 데이터를 이용하여 제안한 고장유형 판별을 위한 적응형 퍼지추론 시스템의 평가하였다.

## 2. 배전선로의 고장유형 판별을 위한 알고리즘

### 2.1 적응형 퍼지추론 시스템

본 논문에서 사용된 적응형 퍼지추론 시스템은 그림 1과 같이 5개의 층으로 구성된 신경회로망의 다층구조의 형태로 되어 있으며, 각 층은 X1 ~ X5의 5개의 입력으로부터 입력 퍼지변수를 만드는 퍼지화 계층, 퍼지연산 계층, 해당 규칙의 활성강도를 정규화하는 계층, 비퍼지화된 선형함수를 출력하는 계층, 마지막으로 출력값의 종합하여 고장여부의 트립신호를 내보내는 출력하는 계층으로 구성된다[9].

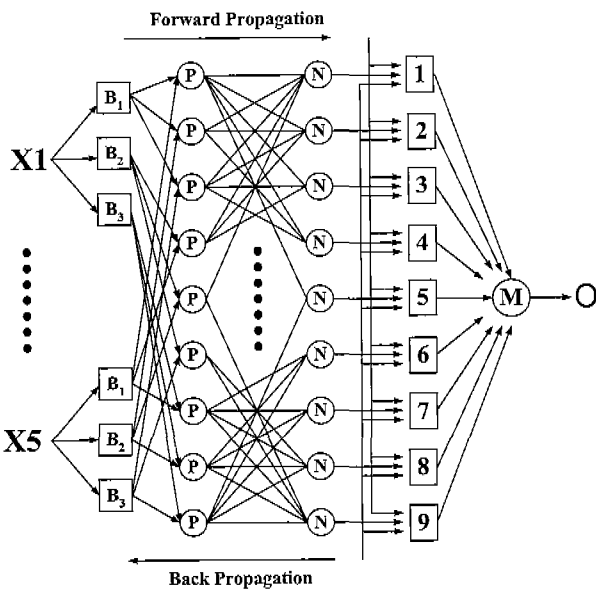


그림 1. 적응형 퍼지추론 시스템의 구조  
Fig 1. The structure of ANFIS

### 2.2 입력변수 선정

적응형 퍼지추론 시스템을 이용하여 배전계통에서 발생하는 지락고장, 단락고장, 고저항 지락고장의 고장현상과 고장 유사현상을 구분하기 위해서는 특징이 있는 입력의 선정이 가장 중요하다. 일반적인 지락, 단락고장이 발생하면 고장전류의 크기가 커지므로 기본파성분의 크기를 이용하여 일반적인 고장여부를 판별할 수 있다. 그러나, 고저항 지락고장인 경우에는 고장전류의 크기가 그리 크게 나타나지 않는데 비해서 아크로부하의 투입시에는 정상상태의 2배 정도의 기동전류가 흐르기 때문에 단순히 기본파전류의 크기만의 비교로는 고장판별이 어렵다. 따라서 고저항 지락고장시의 발생하는 아크 특성으로부터 각 고조파성분을 추출하여 고장전출에 이용하였다. 이를 위해 FFT(fast fourier transform)기법을 이용하여 1[khz]이내의 짝수, 홀수, 비정규 주파수성분을 추출하였다. 단일 고조파성분만으로 고장을 검출하는 경우에는 검출감도가 좋지만 오동작의 발생 빈도가 높아지므로 특정 고조파성분으로 인한 오동작의 발생빈도를 최소화하기 위해서 1[khz]이내의 짝수 고조파성분의 합(120[hz], 240[hz], ..., 960[hz])과 홀수 고조파성분의 합(180[hz], 300[hz], ..., 900[hz]) 그리고 비정규 고조파성분의 합(30[hz], 90[hz], ..., 990[hz])인 복합 고조파성분으로부터 입력변수들을 선정하였다[10]. 또한 영상분전류의 크기를 이용하여 지락고장과 단락고장 그리고 부하불평등을 구분할 수 있도록 입력변수들도 추출하였다.

위의 입력변수는 각 성분의 크기성분을 입력으로 적용하였기 때문에 고장발생 순간이나 부하투입 등의 과도순간에는 크기가 매우 불규칙하게 변하기 때문에 보다 수렴된 특징을 추출하기 위해서 식 (1)과 같은 exponential smooth technique를 이용한 평균값으로 과도상태의 크기변화를 완화시켰다[11].

$$\bar{x}(n+1) = ax(n) + (1-a)\bar{x}(n) \quad (1)$$

여기서,  $\bar{x}(n)$ 과  $\bar{x}(n+1)$ 은 n번째와 n+1번째의 exponential smoothed 평균값이고,  $x(n)$ 은 n번째 실제값이며,  $a$ 는 가중치로서 0에서 1의 값을 가진다.

그림 2는 과도 순간에 많은 동요가 나타나는 1선 고저항 지락고장시의 홀수 고조파성분의 합의 크기를 smooth technique에 적용하기 전, 후의 파형을 비교한 것이다.




그림 2. 원만화 기법  
Fig 2. Smooth technique

그림 2에서 결과에서 보듯이 과도 순간시에 매우 심하게 진동하는 파형을 smooth technique를 적용함으로써 상당히 안정적으로 수렴된 특성을 보여준다. 이러한 필터링 기법을 적용함으로써 퍼지추론 시스템의 고장판별의 속도와 정확성

을 향상시킬 수 있다.

### 2.3 고장유형 판별을 위한 시스템 설계

제안한 적응형 퍼지추론 시스템의 입력변수는 기본과성분의 크기, 영상분전류의 크기, 짝수 고조파성분의 합의 크기, 홀수 고조파성분의 합의 크기, 그리고 비정규 고조파성분의 합의 크기의 5개이며, 하나의 입력변수당 3개(Low, Medium, High)의 가우스함수를 소속함수로 사용하였다. 그리고, 퍼지규칙은 자동으로  $125(m^n = 5^3, m: \text{입력변수의 수}, n: \text{소속함수의 수})$ 개의 규칙이 생성되며 퍼지추론방법은 max-product법을 비퍼지화 방법은 하중평균법을 사용하였다. 학습속도와 수렴정도를 빠르게 하기 위하여 학습단계의 크기(step size)는 여러 값들을 변화시킨 결과 0.1로 선정하였으며 학습 방법은 오류 역전과 학습 알고리즘을 이용하였다. 학습시에 각 입력변수에 적용한 학습패턴의 데이터 수는 과도상태의 수렴정도를 고려하여 고장발생 반주기(8샘플)후의 신호로부터 시작하여 2.5주기(40샘플)의 값을 사용하였다. 출력으로는 표 1과 같이 지지값의 형태로 각 고장유형을 표현하였는데, 지지값이 0인 경우에는 정상상태, 0.3인 경우에는 고저항 지락고장, 0.6인 경우에는 지락고장, 그리고 0.9인 경우에는 단락고장임을 의미한다.

표 1. 고장유형에 따른 지지값  
Table 1. Degree for the fault types

고장유형	정상	고저항지락고장	지락고장	단락고장
지지값	0.0	0.3	0.6	0.9

그림 3은 고장유형 판별을 위한 제안한 적응형 퍼지추론 시스템을 전체적인 동작 순서도이다. 먼저 모델계통에서 대표적인 고장과 고장유사현상의 데이터를 추출하고 이를 오프라인으로 신경회로망으로 학습시켜 최적의 ANFIS를 구현한다. 이렇게 구현된 ANFIS에 계통이나 시뮬레이션 프로그램에서 전류신호를 받아들여 이로부터 5개의 시스템 입력벡터를 추출하고 패턴화하여 매 샘플마다 고장검출과 고장유형을 판별할 수 있도록 하였다. 그러나 매 샘플마다 고장여부를 조사하다보면 순간적인 과도신호나 일시적인 외부 잡음에 의해 계전기가 오동작할 우려가 있기 때문에 이를 위해 지지값으로 수렴되는 출력신호로부터 최종적인 트립신호를 내보내기까지 일정시간의 여유시간을 고려해야만 한다. 따라서 입력패턴에 대한 출력값과 각각의 지지값에 대한 오차가  $\pm 0.1$  이내에 들어오는 순간부터 각 해당 고장유형에 대한 카운터를 시작하여 동일한 출력의 카운터 횟수가 8이상(0.5주기)이 되는 경우에 해당 고장유형의 트립신호를 최종적으로 내보내고 그렇지 않은 경우에는 다시 카운터를 0으로 하여 다음 입력패턴을 받아들이도록 하여 오동작을 방지하였다.

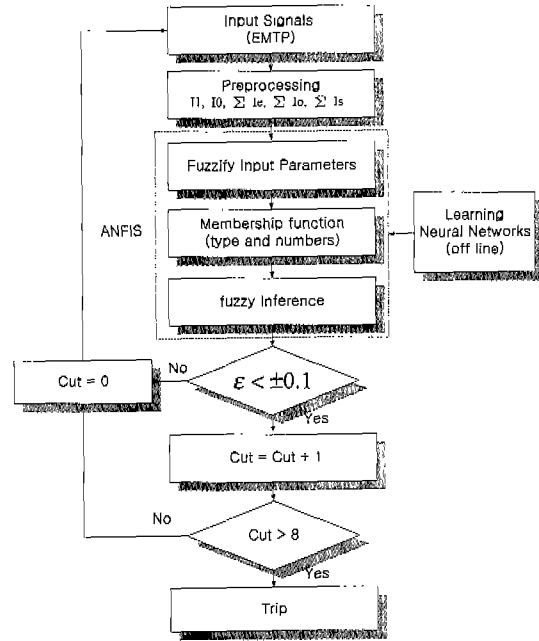


그림 3. 적응형 퍼지추론 시스템을 이용한 고장유형 판별의 순서도

Fig 3. The flowchart of the fault types classification using ANFIS

## 3. 사례 연구

### 3.1 모델계통

배전계통의 고장과 고장유사현상의 데이터를 수집하기 위해 그림 4와 같이 배전선로를 EMTP로 모의하였다. 모델계통은 10[km]의 공장을 갖는 3Φ/22.9[kV] 선로로서 고저항 지락고장 모델은 Buchholz 모델에서 제안된 아크모델을 모의하였다. 그리고 부하의 형태는 일반적인 RL부하, 아크로부하와 단상, 3상 컨버터부하를 배전선로에 분산 배치하여 모의하였으며, 그리고 역률 개선을 위한 콘덴서 뱅크의 모델을 모의하였다[12-14].







그림 4. 모델 계통  
Fig 4. Model system




(a) A상 고저항 지락고장 - RL부하



(b) 3상 단락고장 - 아크로부하



(c) 3상 컨덴서뱅크 투입 RL부하



(d) 부하 증가 - RL부하

그림 5. 시뮬레이션 전류파형

Fig 5. Current signals from simulation

샘플링 주파수는 한 주기당 16샘플, 즉, 1.042[ms]의 시간 간격으로 시뮬레이션을 하여 데이터를 수집하였다. 그림 5는

시뮬레이션으로 얻어진 오동작을 일으키기 쉬운 몇 가지 고장과 고장유사현상에 대한 3상 전류파형이다.

그림 5(a)의 고저항 지락고장이나 5(b)의 초기의 아크로부하 투입시나 그리고 5(d)와 같이 부하의 급증시에 각 상에 나타나는 전류의 크기가 그림 5(b)의 단락고장시에 비해 크게 구분되지 않는다. 그리고 그림 5(b)의 아크로부하 투입이나 5(c)에서 역률 개선을 위해 콘덴서 뱅크를 투입하는 경우에는 상당량의 고조파성분이 섞여 특정 고조파성분만을 이용한 고저항 지락고장 검출의 오동작을 야기할 수 있다. 이와 같이 몇 가지 시뮬레이션 파형에서도 보듯이 고저항 지락고장을 비롯한 여러 고장과 고장유사현상들을 단순한 하나의 파라미터만으로 정확하게 고장유형을 판별하는 것이 어렵다는 것을 알 수 있다.

### 3.2 적응형 퍼지추론 시스템의 학습

적응형 퍼지추론 시스템의 입력변수는 학습을 위하여 0과 1사이의 값으로 정규화를 하였다. 그리고 정규화시에 1이상이 되는 값은 1로 값을 취해 학습이 되도록 하였다. 표 2는 학습에 이용된 각 고장유형에 대한 입력벡터(고장후 8샘플 ~ 40샘플, 2.5주기)중에서 고장발생 후 2주기(24샘플)가 지난 시점에서의 입력변수의 크기를 비교한 것이다. 고장거리 전체 배전선로의 길이의 50% 지점이며 지락고장시의 고장 저항은 1Ω이며 고저항 지락고장은 대략 200Ω 정도로 모의하였다.

표 2. 입력변수의 크기

Table 2. Magnitude of input variables

고장유형		입력변수				
		I1	I0	ΣIe	ΣIo	ΣIs
정상	RL	0.32	0	0	0	0.32
	아크로	0.43	0	0.13	0.1	0.43
	컨버터	0.3	0.16	0.08	0.22	0.29
HIF	RL	0.48	0.34	0.17	0.34	0.49
	아크로	0.5	0.34	0.15	0.34	0.49
	컨버터	0.45	0.42	0.25	0.54	0.48
지락	RL	1	1	0.35	0.01	1
	아크로	1	1	0.45	0.01	1
	컨버터	1	1	0.41	0.22	1
단락	RL	1	0	0.65	0.01	1
	아크로	1	0	0.45	0.01	1
	컨버터	1	0.12	0.52	0.22	1

표 2에서 단락고장과 지락고장시의 기본과성분의 크기는 1이며 고저항 지락고장시에는 0.45~0.5정도의 크기로 수렴하였으며 정상상태시에도 부하에 따라서는 고저항 지락고장과 유사한 크기를 가진다. 영상분전류의 크기는 지락고장시에 1의 값을 가지고 단락시나 정상시에는 0의 값을 가진다. 짝수 고조파의 크기는 고저항 지락고장의 경우에는 0.15~0.25정도로 수렴하나 다른 고장에서는 0.35~0.65의 수렴한다. 홀수 고조파 크기는 고저항 지락고장시에 0.34~0.54의 값을 가지며 컨버터 부하를 사용하는 경우에는 0.22의 값을 가진다. 비정규 고조파의 경우에는 지락, 단락고장시에 1의 값을 가진다.

이러한  $I_1$ ,  $I_0$ ,  $\sum I_{even}$ ,  $\sum I_{odd}$ ,  $\sum I_{sub}$ 의 5개의 입력변

수를 HIGH, MEDIUM, LOW의 3개의 가우스함수를 소속함수로 사용하여 균등하게 영역구분을 하였다. 이러한 학습을 위한 입력변수를 오류 역전파 학습 알고리즘으로 학습시켜 각 입력변수의 소속함수의 영역을 자동으로 최적화 하였다. 그림 6은 학습전, 후의 소속함수의 형태이다.

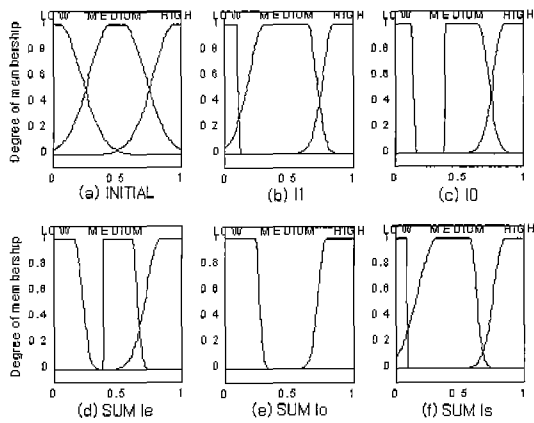


그림 6. 학습전·후의 소속함수


Fig 6. Membership function before and after learning

그림 6 (a)은 각각의 입력변수에 설정된 학습전의 균등하게 분할된 3개의 가우스 소속함수의 형태이며 (b)부터 (f)는 표 2에 선정된 특징벡터를 이용해 학습되어 분할된 입력 변수의 소속함수의 형태를 보여준다. 이를 위한 시스템의 학습횟수는 100번 이였으며 이때 총 오차는 0.0037507이었다.


### 3.3 결과

적응형 퍼지추론 시스템의 성능을 평가하기 위해서 부하의 유형에 따라 학습시와 다른 조건에서 여러 고장상황을 모의하였다. 특히, 고장발생각에 따라서 고조파와 직류성분의 영향이 심하므로 그 영향을 가장 많이 받는 0도와 90도에 대해서 결과를 분석하였다. 그림 7은 고조파의 영향이 가장 심한 전압의 위상이 90도에서 RL부하, RL부하+아크로부하, RL부하+컨버터부하가 연결된 배전계통에 부하증가나 투입, 지락고장, 단락고장, 그리고 고저항 지락고장에 대한 출력 결과로 고장과 부하투입이 14번째 샘플에서 발생하였다

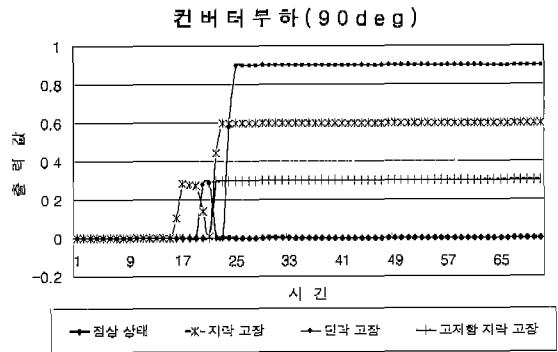
일반적으로 고조파 성분을 입력으로 사용하고 있는 시스템에서는 일반적으로 90도 고장이 발생하는 경우에는 0도 고장에 비해 고조파에 대한 영향이 커짐으로 전반적으로 고장 전출 속도가 늦어지며 동작의 신뢰성에 영향을 받는다. 특히,




(a) RL부하



(b) 아크로부하



(c) 컨버터부하



(d) 고장유사현상

그림 7. 90도 고장시의 결과

Fig 7. Output during 90 degree faults

단락고장에 비해 지락고장의 경우에 그 영향이 심해진다. 위 그림에서 보듯이 초기 과도시에는 실제 적응형 퍼지추론 시스템의 결과값과 해당 고장의 지지값과는 상당한 오차가 발생하다가 점차로 해당 지지값으로 수렴하였다. 그림 7(a)은 RL부하 연결시의 결과로서 정상상태의 경우에는 해당 지지값과 같은 0의 값을 계속 유지하였으며 지락고장의 경우에는 고장발생 후 13샘플(27번째)후부터 0.6인 지지값으로 수렴하였으며 단락고장인 경우에는 고장발생 후 11샘플(25번째)후부터 0.9의 값으로 고저항 지락고장인 경우에도 14샘플(28번째)후부터는 0.3의 지지값으로 수렴하였다. 그림 4(b)에서는 아크로부하의 아크 특성으로 인해 과도상태에서의 지지값의 변화가 매우 심하였지만 고장후 16샘플(30번째)후에는 각 유형의 지지값으로 수렴하였으며, 그림 4(c)는 컨버터부하에서

도 11샘플(25번째)후에는 각각의 지지값으로 수렴하였다. 그림 4(d)는 고장유사현상을 모의하기 위해서 대규모의 RL부하, 아크로부하, 그리고 컨버터부하의 증가 투입과 역률 개선을 위한 콘덴서 뱅크의 투입을 모의하였다. 부하의 증가시나 콘덴서 뱅크 투입시에는 출력값에 전혀 변화가 없는 강인한 특성을 보이고 있으나 아크로부하 투입 초기에는 상당히 큰 전류와 아크특성으로 인해 지지값이 고저항 지락고장시의 지지값과 유사하였으나 오동작 방지를 위한 여유시간 이내에 정상상태의 지지값으로 수렴하였다.

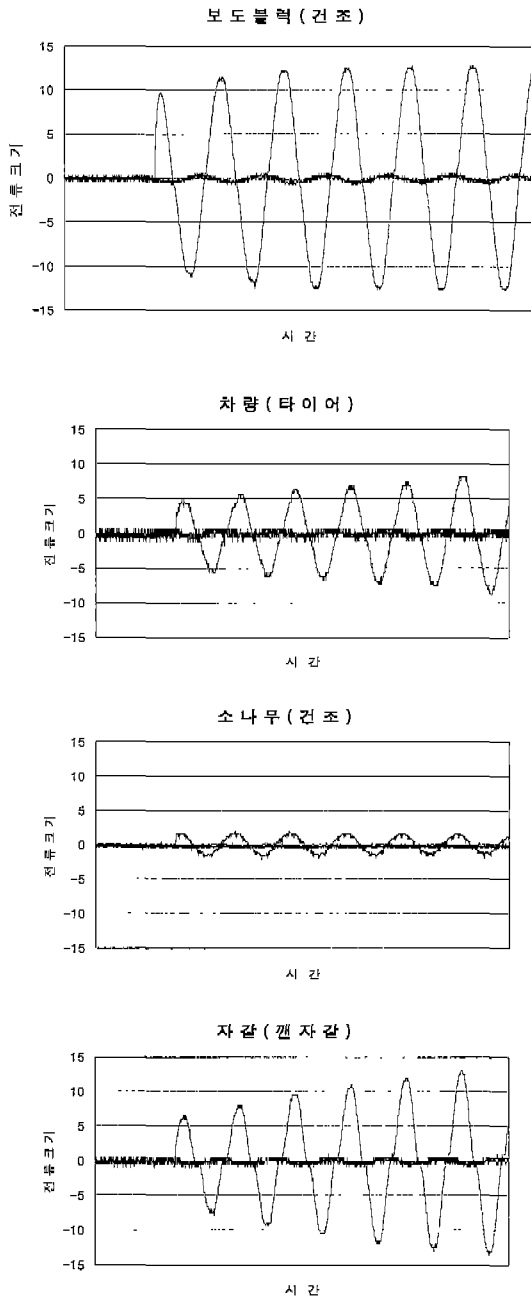


그림 8. 실증실험의 전류파형  
Fig 8. Current Signals from actual experiment

그림 8은 시스템의 성능을 평가하기 위해서 다양한 고장상황하에서 발생하는 고저항 지락고장의 실증시험 데이터 파형

으로 고장발생 전후의 10여주기의 3상 전류파형을 보여준다. 그림 8은 고장시의 접촉점이 건조한 보도블록, 차량의 타이어, 건조한 소나무 그리고 갯자갈에서 발생한 파형으로 시뮬레이션 파형에 비해 고장점의 조건에 따라 고장전류의 크기와 고조파의 함유정도도 약간씩 다를 수 있다. 특히 건조한 상태의 소나무에서 접촉한 형태의 고저항 지락고장 경우에는 거의 고장 특성이 거의 나타나지 않고 있다.




그림 9. 실증시험에 대한 결과  
Fig 9. Output to the actual experiment

그림 9는 위의 4가지 경우의 고저항 지락고장 파형을 적용한 결과로 시뮬레이션 파형에 비해 실증시험 데이터에 많은 고조파 성분을 함유하고 있어 수렴정도의 속도와 정확도에서 약간 떨어짐을 알 수 있다. 고장은 14샘플에서 발생하도록 하였으며 건조한 보도블록이나 차량의 타이어 그리고 갯자갈의 경우에는 고장상태에 따라 수렴정도에는 차이가 있었지만 고장발생 후 16샘플이내에는 지지값인 0.3으로 수렴하였다. 그러나 고장 발생시의 전류파형의 거의 변화가 없는 건조한 소나무 경우에는 전혀 고장을 검출할 수가 없었다.

### 3.4 고찰

본 논문에서 제시한 적응형 퍼지추론 시스템을 이용한 배전선로의 고장유형을 판별하는 기법의 고장검출의 속도와 신뢰성을 평가하기 위해서 본 논문에서 제시한 모델계통을 대상으로 퍼지논리와 신경회로망 기법을 이용하여 그 성능을 비교하였다. 퍼지논리는 고장과 유사현상시에 나타나는 고장 파형의 크기를 이용하여 여러 차례의 시행착오를 거쳐 입력력 퍼지 파라미터를 선정하여 퍼지논리를 구현하였다. 그리고 신경회로망은 적응형 퍼지추론 시스템에 학습시에 이용한 데이터를 적용하여 오류 역전파 학습 알고리즘으로 학습시켰다. 표 3과 4는 이렇게 구현된 적응형 퍼지추론 시스템과 퍼지논리 그리고 신경회로망을 이용하여 모델계통의 여러 조건을 변화시키면서 고장현상과 고장유사현상을 시뮬레이션하여 그 출력결과를 비교한 것이다. 표 3에서는 동작에 수렴속도를 비교한 것이고 표 4에서는 고장유사현상에 대한 오동작 여부에 대한 결과이다. 표 5는 실증시험 데이터를 적용한 결과로서 트립여부와 수렴속도를 비교한 것이다.

표 3에서 보듯이 일반적으로 90도 고장시에 고조파의 영향으로 인해 0도 고장에 비해 세 가지 기법 모두 수렴속도가 느려짐을 알 수 있다. 그리고 퍼지논리나 신경회로망의 경우에는 저저항 고장과 같이 고장현상이 명확한 고장에 대해서는 적응형 퍼지추론 시스템보다 여러 경우에는 신속하게 수렴하기도 하였지만 고저항 지락사고시에 경우와 같이 그 고장현상의 구분이 불분명한 경우에는 수렴속도가 현저히 늦어짐을 알 수 있다. 표 4의 경우에서도 아크로부하나 컨버터부하의 증가 투입시에 그 용량에 따라 오동작을 하는 경우도

표 3. 고장현상 시뮬레이션에 대한 결과  
Table 3. Output for fault condition simulation

고장유형		부하종류	RL	아크로	컨버터
			부하	부하	부하
			고장 발생 후 수렴 샘플수		
0도	지락	적응형 퍼지추론 시스템	8	9	10
		퍼지논리	7	8	7
		신경회로망	6	6	6
	단락	적응형 퍼지추론 시스템	9	9	9
		퍼지논리	8	8	8
		신경회로망	7	7	7
	고저항 지락	적응형 퍼지추론 시스템	11	12	9
		퍼지논리	16	22	17
		신경회로망	12	13	14
90도	지락	적응형 퍼지추론 시스템	13	16	9
		퍼지논리	10	17	9
		신경회로망	10	12	10
	단락	적응형 퍼지추론 시스템	11	9	11
		퍼지논리	9	9	10
		신경회로망	10	9	11
	고저항 지락	적응형 퍼지추론 시스템	14	16	8
		퍼지논리	19	23	19
		신경회로망	16	18	12

표 4. 고장유사현상에 대한 오동작 유무  
Table 4. Maloperation for the fault-like conditions

유사현상	RL부하 증가		아크로 부하증가		컨버터 부하증가		역률개선	
	0도	90도	0도	90도	0도	90도	0도	90도
적응형 퍼지추론 시스템	×	×	×	×	×	×	×	×
퍼지논리	×	×	△	△	△	△	×	×
신경회로망	×	×	×	△	△	△	×	×

(× : 오동작 하지 않음, △ : 오동작 하기도 함)

표 5. 실증실험 데이터의 결과  
Table 5. Output for the actual experiment data

유사현상	보도블록		모래망		자갈		차량		수목	
	건조	습기	반건조	샌자갈	강자갈	타이어	소나무	미루		
적응형 퍼지추론 시스템	6	8	10	9	13	11	×	×		
퍼지논리	5	6	11	10	16	10	×	×		
신경회로망	6	6	12	10	×	×	×	×		

(× : 고장 검출하지 못함)

발생하였다. 표 5의 실증시험 데이터를 적용한 경우에도 고

장의 현상이 분명한 경우에는 퍼지논리나 신경회로망에서도 빠르게 고장을 검출하였으나 그 특징이 불분명한 경우에는 고장을 검출 못하는 경우도 발생하였다. 수목의 경우에는 그림 9에 보듯이 그 고장의 특징이 거의 나타나지 않아 모든 기법에서도 그 고장을 검출할 수 없었다. 위의 결과 비교에서 알 수 있듯이 퍼지논리는 각 입력변수에서의 구분이 불분명한 경우에 고장검출의 수렴속도가 매우 늦어졌으며 신경회로망은 학습에 유사한 형태의 신호에 대해서는 매우 빠르게 고장을 검출하였으나 학습에 적용된 형태와 다른 신호에 대해서는 동작의 신뢰성에 문제를 일으켰다. 하지만 적응형 퍼지추론 시스템의 경우에는 여러 상황에 변화에 대해서도 16샘플(1주기)이내에는 각 지지값에 정확히 수렴하는 신뢰성을 보여 주었다. 결과적으로 수렴시부터 최종적인 고장트립 신호를 내보내기까지 8샘플(1/2주기)의 여유시간까지 고려하여도 최종적으로 24샘플(1.5주기)이내에는 정확하게 고장유형을 판별할 수 있었다.

### 4. 결 론

본 논문에서는 보호계전기법에 최근에 연구되는 인공지능 기법인 신경회로망과 퍼지추론의 장점을 결합한 적응형 퍼지추론 시스템을 이용하여 배전선로에서 발생하는 여러 가지 고장과 고장유사현상을 판별하는 기법을 제안하였다.

제안한 적응형 퍼지추론 시스템을 이용한 배전선로의 고장유형 판별 기법은 일반적인 RL부하, 아크로부하, 컨버터부하상태에서의 고장과 고장유사현상을 분류할 수 있는 입력변수를 선정하였으며 시스템의 입력력 공간을 결정하기 위해서 신경회로망의 역전파 학습 알고리즘을 이용하여 고장유형에 따라 각각의 입력변수의 최적의 임·출력 파라미터를 선정하였다. 그리고 다양한 형태의 부하와 고장유형, 그리고 고장상황의 변화에 시뮬레이션과 실증실험 데이터에 대해서 1.5주기(24샘플)이내에는 신뢰성 있는 계전기의 동작이 가능하였다.

보다 향상된 기법을 위해서는 다양한 형태의 부하모델에 대한 실제적인 모델링이 요구되며 보다 다양한 실증실험 데이터를 이용한 고장과 유사현상의 구분을 위한 특징추출을 통해 적응형 퍼지추론 시스템에 대한 신뢰성을 향상시켜야 할 것이다

### 참 고 문 헌

- [1] Mike Aucoin, "Status of High Impedance Fault Detection", *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-104, no. 3, March, 1985, pp. 638-643.
- [2] B.Don Russell, Ram P.Chinchali and C.J.Kim, "Behaviour of Low Frequency Spectra During Arcing Fault and Switching Events", *IEEE Transactions on Power Delivery*, vol. 3, no. 4, October, 1988, pp. 1485-1491.
- [3] Mamishev, A. V., Russel, B. D., Benner, C. L. "Analysis of High Impedance Faults Using Fractal Techniques", *Proc. of IEEE*, pp. 401-406, 1995.
- [4] Surya Santos, Edward J. Powers, W. Mack Grady, Peter Hofmann, "Power Quality Assessment via Wavelet Transform Analysis", *IEEE Trans. on Power Delivery*, vol. 11, no. 2, April, 1996, pp. 924 - 930

[5] 정호성, 신명철 외, "거리계전기범을 위한 신경회로망 고장패턴 추정기", *대한 전기학회 논문지*, vol. 47, no. 11. 1998. pp. 1804~1811

[6] H. S. Jung, M. C. Shin et al., "An Implementation of Digital Distance Relaying Algorithm Using Neural Network Based Fault Pattern Estimation", *ICEE'99 Hong Kong*, pp. 181-184, 1999.

[7] 한국 전력 연구원, "지능형 보호계전기 연구 개발", 1997.

[8] A. Ferrero, S. Sangiovanni, E. Zappitelli, "A Fuzzy-set Approach to Fault-type Identification in Digital Relaying", *IEEE Trans on PWRD*, vol. 10, no. 1, Jan. 1995, pp. 169 - 175.

[9] Jyh-Shing Roger Jang "ANFIS : Adaptive-Network-Based Fuzzy Inference System", *IEEE Trans. on Systems, Man and Cybernetics*, vol. 23, no. 3, May/June 1993, pp. 665 ~ 667.

[10] 오영택, 김창중, "배전 계통의 고 임피던스 고장 검출을 위한 고조파 변수 성능 평가", *대한 전기학회 논문지*, vol. 47, no. 6. 1998. pp. 727~733

[11] H. J. Newton, "Timeslab : A Time Series Analysis Laboratory", *Pacific Grove, CA: Wordsworth & Books*, 1987

[12] A. T. Johns, R. K. Arrarwal, Y. H. Song, "Improved Technique for Modeling Fault Arcs on Faulted EHV. Transmission System", *IEE Proc.-Gener. Transm. Distrib.*, vol. 141, no. 2, March 1994

[13] V. L Buchholz, et al., "High Impedance Fault Detection Device Tester", *IEEE Transaction on Power Delivery*, vol. 11, no. 1, January. 1996.

[14] Srinivas Vardan, Elham B. Makram, Adly A. Girgis, "A new Time Domain Voltage Source Model for an Arc Furnace Using EMTP", *IEEE Transaction on Power Delivery*, vol. 11, no. 3, July. 1996.

## 저 자 소 개



### 정 호 성 (Ho-Sung Jung)

1995년 : 성균관대학교 전기공학과 학사  
 1998년 : 성균관대학교 대학원 전기공학과 석사  
 현 재 : 성균관대학교 대학원 전기전자 및 컴퓨터공학부 박사과정 수료

주관심 분야 : 전력시스템, 인공지능



### 신 명 철 (Myong-Chul Shin)

1970년 : 성균관대학교 전기공학과 학사  
 1978년 : 연세대학교 대학원 전기공학과 박사  
 1975년~1978년 : 충북대학교 전기공학과 조교수  
 1982년~1983년 : 미국 코넬대학교 전기공학과 방문교수

2000년~2001년 : 미국 펜실바니아 주립대학교 방문교수  
 현 재 : 성균관대학교 전기전자 및 컴퓨터공학부 교수

주관심 분야 : 전력시스템, 컴퓨터응용