

## 퍼지신경망을 이용한 배전계통의 고장유형 판별 기법

정호성\*, 최상열\*, 김호준\*, 신명철\*, 이복구\*\*, 서희석\*\*\*

\*성균관대학교 전기전자 컴퓨터공학부, \*\*명지전문대학 전기과, \*\*\*두원공과대학 전기과

### The Fault Types-Classification Techniques in the distribution system using Adaptive Network Fuzzy Inference System

Ho-Sung Jung\*, Sang-Youl Choi\*, Ho-Joon Kim\*, Myong-Chul Shin\*, Bock-Ku Lee\*\*, Hee-Seok Suh\*\*\*

\*SungKyunKwan Univ., \*\*MyungJi College, \*\*\*DooWon College

**Abstract** - This paper proposed the technique of the fault-types classification using Adaptive Network Fuzzy Inference System in the distribution system. Fault and fault-like data in the linear RL load, arc furnace load and converter load were extracted by EMTP. These were characterized into 5 input variables and fuzzified automatically by learning. This technique was tested using another fault data unused learning.

### 1. 서 론

배전계통은 전기설비가 전기수용가에 밀집되어 있기 때문에 고장발생은 대규모 정전사태 뿐만 아니라 인명피해, 화재발생, 그리고, 설비손상 등의 직접적인 문제를 발생시킬 수 있어, 보다 신뢰성 있는 계전기에 대한 필요가 요구되고 있다. 그러나, 다중접지 배전계통에서 고저항 지락고장(high impedance fault : HIF)이 발생하는 경우에는 일반적인 지락, 단락고장과는 달리 고장전류의 크기가 작아 기존의 과전류 계전기로는 정확한 고장검출이 어려운 실정이다[1]. 따라서 이러한 고장검출을 위해서 고장신호로부터의 특정 고조파성분을 분석하는 기법이 연구되어 왔다[2]. 그러나 고조파를 발생시키는 다양한 부하의 급증으로 인해 고장신호의 유사한 형태의 신호가 발생하여 계전기의 오동작을 초래하고 있다. 최근에는 이러한 문제를 해결하기 위해서 신경회로망, 퍼지논리과 같은 인공지능기법[3]과 불규칙한 특성을 고려한 카오스나 프랙탈 기법, 그리고 웨이브렛 등의 기법이 연구되어 오고 있다.

본 논문에서는 퍼지논리와 신경회로망을 접목한 퍼지신경망을 이용하여 배전계통에서 발생하는 고장신호와 고장유사현상 신호로부터 여러 형태의 특징을 추출하고 이를 학습시켜 지식화하여 고장검출과 유형을 판별하는 기법을 제안하였다. 이를 위해 일반적인 RL부하와 고조파를 발생시키는 아크로부하와 컨버터부하가 연결된 상황에서 발생하는 지락, 단락, 고저항 지락고장의 고장현상과 역률 개선을 위한 콘텐서 맹크의 투입과 대규모 부하의 일시적인 투입과 같은 고장유사현상을 EMTP를 이용하여 시뮬레이션하여 고장과 고장유사현상에 대한 데이터를 추출하였다. 이렇게 추출한 데이터에서 기본파성분, 영상전류성분, 짹수고조파, 훌수고조파, 그리고 sub고조파성분을 추출하여 특징화하고 이를 퍼지신경망에 적용하여 그 성능을 평가하였다.

### 2. 퍼지신경망을 이용한 알고리즘

#### 2.1 퍼지신경망의 구조

퍼지신경망은 퍼지논리를 기반으로 하여 신경회로망을 적용한 것으로 신경회로망의 학습능력을 이용하여 미리 설계된 퍼지논리의 소속함수를 최적화시키고 입출력 이득을 조정하는 기법이다[4]. 본 논문에 사용된 퍼지신경

망은 5개의 층으로 구성된 신경회로망의 다층구조의 형태로 되어 있다. 각 층은 퍼지변수를 만드는 퍼지화 계층, min이나 product연산을 하는 퍼지연산 계층, 해당 규칙의 활성강도를 정규화하는 계층과, 여러 파라미터를 이용하여 비퍼지화된 선형함수를 출력하는 계층, 마지막으로 출력값의 총합을 출력하는 계층으로 구성된다. 소속함수의 소속도를 결정하는 파라미터와 비퍼지화 계층에서 선형함수로 출력하는데 사용하는 파라미터는 신경회로망의 오류 역전파 학습 알고리즘에 의하여 조정된다. 퍼지추론 방법은 Sugeno가 제안한 혼합법을 사용하였으며, 후전부 소속함수를 입출력 선형관계식으로 표현하여 비퍼지화를 추론기관에 포함시킨 형태를 가진다. 이러한 퍼지신경망을 이용한 알고리즘은 기존의 경험적인 퍼지이론을 이용한 기법에 비해 여러 입력변수들을 오류 역전파 알고리즘을 이용하여 각 소속함수와 입출력 이득을 학습을 통해 자동으로 최적화하므로 배전계통에서 발생하는 고저항 지락고장을 포함한 여러 고장상태와 고장유사상태의 구분에 훨씬 효과적이다.

#### 2.2 입력변수의 도출

퍼지신경망의 퍼지추론을 위해서는 적절한 입력변수의 추출이 필수적이다. 배전계통에서 나타나는 현상은 크게 지락고장, 단락고장, 고저항 지락고장의 고장현상과 고장유사현상으로 구분할 수 있다. 일반적으로 고장이 발생하면 고장전류가 커지므로 정상과 고장은 기본파성분으로 구분할 수 있다. 그러나, 고저항 지락고장은 고장전류의 크기가 작은데 비해 아크로부하의 투입시에는 정상상태의 2배정도의 기동전류가 흐르기 때문에 단순히 기본파전류의 크기만의 비교로는 고장판별이 어렵다. 따라서 고저항 지락고장시의 발생하는 고조파성분을 분석하여 고장을 판별하여야 한다. 따라서 1(khz)이내의 주파수를 DFT기법을 이용하여 각 차수별로 주파수 분석을 하였다. 일반적으로 단일 고조파성분만으로 고장을 검출하는 경우에는 검출감도가 좋지만 오동작의 발생빈도가 높아지므로 특정 고조파성분으로 인한 오동작의 발생빈도를 최소화하기 위해서 1(khz)이내의 짹수 고조파성분의 합(120[Hz], 240[Hz], ..., 960[Hz])과 훌수 고조파성분의 합(180[Hz], 300[Hz], ..., 900[Hz]) 그리고 sub 고조파성분의 합(30[Hz], 90[Hz], ..., 990[Hz])인 복합 고조파성분으로부터 입력변수를 추출하였다. 또한 영상분전류의 크기를 이용하여 지락고장과 단락고장 그리고 부하불평등을 구분할 수 있도록 입력변수를 도출하였다.

위의 5개의 입력변수들은 각 성분의 크기만을 이용했기 때문에 고장발생 순간이나 부하투입 등의 과도순간에는 고조파성분의 크기가 너무 불규칙하게 변하기 때문에 보다 수렴된 특징을 추출하기 위해서 식 (1)과 같은 smooth technique를 이용하여 과도상태의 고조파의 크기변화를 완화시켰다.

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

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

### 2.3 퍼지신경망의 학습

제안한 퍼지신경망의 퍼지 입력변수는 기본파성분의 크기, 영상분전류의 크기, 짹수 고조파성분의 합의 크기, 훌수 고조파성분의 합의 크기, 그리고 sub 고조파성분의 합의 크기의 5개의 입력변수이며, 하나의 입력변수당 3개(LOW, MEDIUM, HIGH)의 가우스함수를 소속함수로 사용하였다. 그리고, 퍼지규칙은 퍼지신경망에 의하여 총  $125(m^n = 5^3, m: \text{입력변수의 수}, n: \text{소속함수의 수})$ 개의 규칙이 자동생성이 되며 퍼지추론방법은 Max - product법을 비퍼지화 방법은 하중평균법을 사용하였다. 학습속도와 수렴정도를 빠르게 하기 위하여 학습단계의 크기(Step Size)를 0.1로 설정하였다. 학습시에 각 입력변수의 학습패턴은 과도상태의 수렴정도를 고려하여 고장발생 반주기(8샘플)후의 신호로부터 시작하여 총 2.5주기(40샘플)의 값을 사용하였다. 출력값으로는 각 고장유형에 따라 지지값으로 표현하였는데, 지지값이 0인 경우에는 정상상태, 0.3인 경우에는 고저항지락고장, 0.6인 경우에는 저락고장, 그리고 0.9인 경우에는 단락고장임을 의미한다. 위와 같이 구성된 퍼지신경망은 매 샘플마다 고장의 판별 여부를 조사하게 되는데 고장직후나 스위칭현상시의 과도상태에 대해서 오동작을 방지하기 위해서 해당 목표출력과 오차가  $\pm 0.1$ 이내에 들어오는 순간부터 해당 고장유형에 대한 카운터를 시작하여 동일한 출력의 카운터 횟수가 8이상이 되는 경우에 해당 고장유형의 트립신호를 내보내도록 구성하였다. 그림 1은 전체적인 퍼지신경망을 이용한 고장유형 판별의 구성도이다.

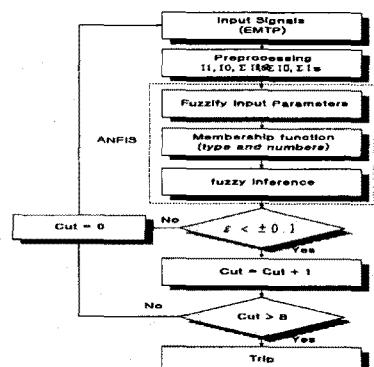


그림 1. 퍼지신경망을 이용한 고장유형 판별의 구성도

### 3 시뮬레이션

#### 3.1 모델개통

배전계통의 고장과 고장유사현상의 데이터를 수집하기 위해 그림 2와 같이 배전선로를 EMTP로 모의하였다. 모델계통은 10[km]의 길장을 갖는  $3\Phi/22.9(\text{kV})$  선로모델로서 고저항 지락고장모델은 Buchholz모델에서 제작된 아크모델을 모의하였으며, 아크로부하와 단상, 3상 컨버터부하와 역률 개선을 위한 콘텐서 뱅크의 모델을 모의하였다.

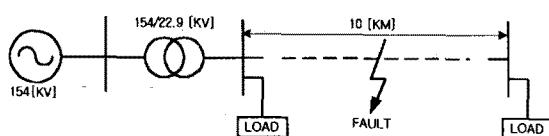


그림 2. 모의계통 모델

샘플링 주파수는 한 주기당 16샘플, 즉, 1.042[ms]의 시간간격으로 시뮬레이션을 하여 데이터를 수집하였다.

#### 3.2 입력패턴 추출

퍼지신경망의 입력변수는 퍼지신경망의 학습을 위하여 0과 1사이의 값으로 정규화를 하였다. 그리고 정규화시에 1이상이 되는 값은 1로 값을 취하였다. 표 1은 고장발생 후 2주기(24샘플)가 지난 시점에서 학습에 이용된 각 고장유형에 따른 입력변수의 크기를 비교한 것이다.

표 1. 입력변수의 크기

고장유형	입력변수	High				
		I1	I0	$\Sigma I_e$	$\Sigma I_o$	$\Sigma I_s$
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 1에서 단락고장과 지락고장시의 기본파성분의 크기는 1이며 고저항 지락고장시에는 0.45~0.5정도의 크기로 수렴하였으며 정상상태에서도 부하에 따라 고저항지락고장과 유사한 크기를 가진다. 영상분전류의 크기는 지락고장시에 1의 값을 가지고 단락시나 정상시에는 0의 값을 가진다. 짹수 고조파의 크기는 고저항 지락고장의 경우에는 0.15~0.25정도로 수렴하나 다른 고장에서는 0.35~0.65의 수렴한다. 훌수 고조파 크기는 고저항 지락고장시에 0.34~0.54의 값을 가지며 컨버터부하를 사용하는 경우에는 0.22의 값을 가진다. sub고조파의 경우에는 지락, 단락고장시에 1의 값을 가진다.

#### 3.3 퍼지신경망의 학습결과

퍼지신경망은  $I_1, I_0, I_{even}, I_{odd}, I_{sub}$ 의 5개의 입력변수에 HIGH, MEDIUM, LOW의 3개의 가우스함수를 소속함수로 사용하여 영역구분을 하였다. 그림 3은 학습전후의 소속함수의 형태이다.

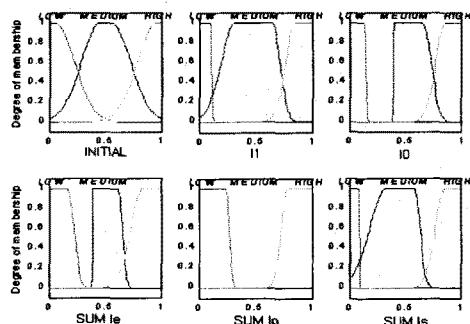


그림 3. 학습전·후의 소속함수

그림 3의 첫 번째 그림은 균등하게 분할된 3개의 가우스함수의 학습전의 소속함수의 형태이며 나머지 5개의 그림은 학습 후에 각각의 입력변수에 따라 자동으로 분할된 소속함수를 나타내었다. 퍼지신경망의 학습횟수는

100번이였으며 이때 총오차는 0.0037507이였다.

### 3.3 시뮬레이션 결과

퍼지신경망의 성능을 평가하기 위해서 부하의 유형별로 학습시에 사용하지 않은 고장상황을 모의하여 성능을 평가하였다. 그림 4는 RL부하, RL부하+아크로부하, RL부하+컨버터부하의 경우에 부하투입과 지락고장, 단락고장, 그리고 고저항 지락고장과 고장유사현상에 대한 출력 결과를 나타내었다.

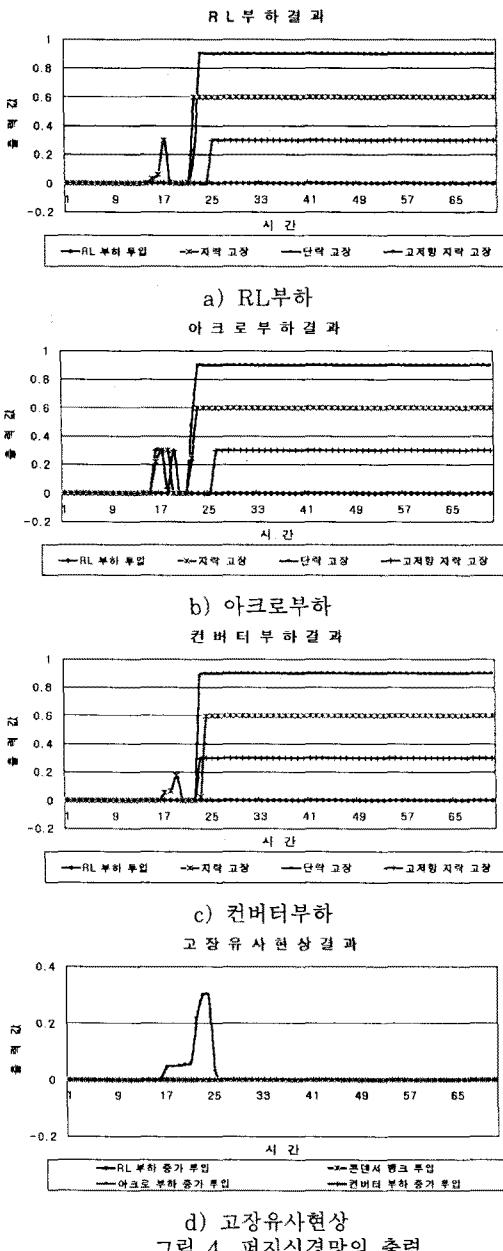


그림 4. 퍼지신경망의 출력  
Figure 4. Output results of the fuzzy neural network

그림 4는 고장과 부하투입이 14번째 샘플에서 발생한 것으로 과도시에는 실제 퍼지신경망의 결과값과 지지값과는 상당한 오차가 발생하다가 점차로 해당 지지값으로 수렴함을 알 수 있다. 그림 4(a)는 RL부하의 결과로 고장발생후 10샘플(22번째)후에는 각 고장유형의 지지값으로 수렴함을 알 수 있다. 그림 4(b)는 아크로부하의 아크 특성으로 인해 과도상태에서의 지지값의 변화가

심하였지만 고장후 14샘플(26샘플)후에는 각 유형의 지지값으로 수렴함을 알 수 있다. 그럼 4(c)는 컨버터부하의 결과로서 12샘플(24샘플)후에는 각각의 지지값으로 수렴하였다. 그럼 4(d)는 고장유사현상을 모의하기 위해서 대규모의 RL부하, 아크로부하, 그리고 컨버터부하와 역률 개선을 위한 콘덴서 뱅크의 투입을 모의하였다. 특히 아크로부하 투입시 과도 초기에는 지지값이 고저항 지락고장사의 지지값과 유사하였으나 곧 정상상태의 지지값으로 수렴하였다.

위의 퍼지신경망을 이용한 고장유형 판별 기법에서는 일반적인 RL부하, 아크로부하, 컨버터부하, 그리고, 고장유사현상에 대해서 여러 상황에 변화에 대해서도 16 샘플이내에는 각 지지값에 정확히 수렴하였다. 물론 고조파원을 심하게 발생시키는 부하에서는 고장발생이나 부하원의 대규모 투입시에 과도상태의 지지값의 변화가 심하였지만 최종적인 고장트립을 위한 8샘플 허용범위를 두어 오동작을 방지하였으며 이러한 8샘플의 허용범위까지 고려한다고 해도 24샘플이내에는 정확한 고장유형을 판별할 수 있었다.

## 4. 결 론

본 논문에서는 보호계전기법에 최근에 연구되는 인공지능기법인 신경회로망과 퍼지추론의 장점을 접목한 퍼지신경망을 이용하여 배전계통에서 발생하는 여러 가지 고장의 유형과 고장유사현상을 판별하는 기법을 제안하였다.

제안한 퍼지신경망을 이용한 배전계통의 고장유형 판별 기법의 결론을 요약하면 퍼지신경망을 이용하여 일반적인 RL부하, 아크로부하, 컨버터부하상태에서의 고장과 고장유사현상을 분류할 수 있는 입력변수를 선정하였으며 퍼지신경망의 입출력 공간을 결정하기 위해서 신경회로망의 역전파 학습 알고리즘을 이용하여 고장유형에 따라 각각의 입력변수의 최적의 입·출력 파라미터를 선정하였다. 그리고 다양한 형태의 부하와 고장유형, 그리고 고장상황의 변화에 대해서도 1.5주기(24샘플)이내에는 신뢰성 있는 계전기의 동작이 가능하였다.

보다 향상된 기법을 위해서는 다양한 형태의 부하모델에 대한 실증적인 모델링이 요구되며 실계통 데이터를 이용한 고장과 유사현상의 구분을 위한 특징추출을 통해 퍼지신경망에 대한 신뢰성을 향상시켜야 할 것이다.

이 논문은 성균관대학교의 1998년도 63학술연구비에 의하여 연구되었음.

## (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] 한국 전력 연구원, "지능형 보호계전기 연구 개발", 1997.
- [4] 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.
- [5] 오영택, 김창종, "배전 계통의 고 임피던스 고장 측출을 위한 고조파 변수 성능 평가", 대한 전기학회 논문지, Vol. 47, No. 6, 1998, pp 727~733
- [6] H.J. Newton, "Timeslab : A Time Series Analysis Laboratory", Pacific Grove, CA: Wordsworth & Books, 1987