

## 적응 뉴로 퍼지 추론 시스템을 이용한 고임피던스 고장 검출

### Detection of High Impedance Fault Using Adaptive Neuro-Fuzzy Inference System

임화영 · 유창완 · 고재호 · 홍대승 · 배영철\*

Wha-Yeong Yim, Chang-Wan Ryu, Jae-Ho Ko,  
Dae-Seung Hong and Young-Chul Bae\*

광운대학교 제어계측학과, \*여수대학교 전기공학과

#### ABSTRACT

A high impedance fault(HIF) is one of the serious problems facing the electric utility industry today. Because of the high impedance of a downed conductor, under some conditions these faults are not easily detected by over-current based protection devices and can cause fires and personal hazard. In this paper, a new method for detection of HIF which uses adaptive neuro-fuzzy inference system(ANFIS) is proposed. Since arcing fault current shows different changes during high and low voltage portion of conductor voltage waveform, we firstly divided one cycle of fault current into equal spanned four data windows according to the magnitude of conductor voltage. Fast fourier transform(FFT) is applied to each data window and the frequency spectrum of current waveform are chosen as inputs of ANFIS, after input selection method is preprocessed. Using staged fault and normal data, ANFIS is trained to discriminate between normal and HIF status by hybrid learning algorithm. This algorithm adapted gradient descent and least square method and shows rapid convergence speed and improved convergence error. The proposed method represent good performance when applied to staged fault data and HIFLL(high impedance like load) such as arc-welder.

**Key words :** High impedance fault, High impedance fault detector, Backpropagation, FFT, ANFIS

#### 1. 서 론

전력계통에서의 배전선로는 많은 수용가에 직접 전력을 공급하는 설비로서 지역적으로 방대하고, 복잡하며, 다양한 외적 환경에 노출되어 있어서 사고위험이 많다. 배전선로에서 발생하는 고장 중에 일반적인 저임피던스에 의한 과전류 고장은 그 고장 전류가 커서 쉽게 검출할 수 있으나 이와는 다르게 고장 전류의 크기가 작아 이를 검출하지 못하는 경우가 있는데 이를 고임피던스 고장(High Impedance fault)이라고 한다. 고임피던스 고장은 배전선로가 대지나 수목등에 접촉됐을 때 미소한 전류가 대지로 흐르게 되나, 현재의 보호 계전기의 고장 검출 기준에 크기가 미달되어 보호차단 되지 않는 상태의 고장이다. 이러한 고임피던스 고장사고를 효과적으로 감지하기 위하여 본 논문에서는 적응 뉴로 퍼지 추론 시스템(Adaptive Neuro Fuzzy Inference System, ANFIS)을 이용해 적용하였다. 고임피던스 고장의 특성은 배전선 구조, 부하량과 형태, 날씨, 지락시 대지의 표면 절연상태 즉 아스팔트, 자갈, 모래등 조건에 따라 고장전류의 크기

나 모양이 영향을 받아 고장현상이 매우 다양한 형태로 나타나지만 이들의 사고는 대부분 아크를 동반하므로, 아크 지락전류는 전압 파형의 파고치 부근에서 발생되는 점에 확인하여 1주기의 전류 파형을 전압의 파고치 부근과 다른 부분으로 4등분하여 각 구간별 고조파 전류의 분포변화를 추출하여 이를 적응 뉴로 퍼지 추론 시스템에 입력시켜 고장 검출을 시도하였다. 이 때 입력요소의 선정은 Direct exhaustive search 기법과 Sequential forward selection 기법을 사용하여 입력의 요소를 줄였으며, 파라미터 학습에는 최급강하법(Steepest Gradient Method)과 최소자승법(Least Square Algorithm)이 결합된 Hybrid learning algorithm을 적용하였으며, 한국전력공사에서 실측한 고임피던스 고장 데이터를 써서 고장검출 성능 및 정확도를 높이고 활용할 수 있는 가능성을 연구하였다.

#### 2. 아크성 고장 전류 및 부하 전류

개폐 서어지나 리액턴스 및 캐패시터의 투입, 차단

시에도 고조파 성분의 부하전류가 흐르게 되어 기준의 1주기 전체에 대한 주파수 분포특성을 고려한 검출기법으로는 아크성 고장전류 검출이 극히 제한적이다. 실계통보호를 위해서는 고임피던스 고장전류와 건전선로에서의 고조파 전류를 구분하여 검출하는 것이 필수적으로 요구되며, 특히 아크지락 고장 상태일 때와 같은 아크성 전류가 흐르게 되는 부하전류(용접, 아크로)와의 구별이 명확히 이루어져야 한다.

일반적으로 계통에서 발생되는 고조파 성분의 전류는 선로의 동 특성에 의해 동일 주파수의 감쇄진동이 수반되며 이상전압 현상과 같은 것은 감쇄가 빨라서 곧 소멸하나, 고임피던스 고장은 아크로 인한 불규칙 점멸로 인해 동일한 현상을 불규칙적으로 오래 지속시킨다. 또한, 고임피던스 고장시 아크성 전류는 매 주기마다 전압이 높을 때 발생하기 시작하여 서서히 소멸하는 특성을 보이는 반면에, 캐패시터 스위칭 전류는 짧은 기간동안 지속되는 현상을 보이며 회로 정수와 전압 파형 변화에 웅동하는 구별된 특성을 가지고 있다. 따라서, 본 논문에서는 아크성 전류를 검출하기 위해 전류 파형의 매 주기마다 전압이 높은 파고치부근과 나머지 전압이 낮은 부분으로 분류하여 한

주기를 4개의 데이터 윈도우(data window)로 그림 1과 같이 구분하였다.

각 윈도우별로 전류데이터를 FFT(Fast Fourier Transform)하여 고조파 성분의 전류 크기와 위상 변화를 포함한 데이터로 정량화하였다. 한 주기 내에서 파고치 구간(윈도우 1, 윈도우 3)과 저전압 구간(윈도우 2, 윈도우 4)의 고조파 전류의 변화 특성을 고장 검출 인자로 사용하였다.

아크 부하전류와 아크 지락전류는 전압의 순시차가 높을 때 처음 흐르게 되는 특성은 같으나 아크부하는 아크발생과 지속의 안정성을 유지하기 위해 리액턴스가 큰 변압기 등을 통해 공급되는 것이 다르므로 아크 부하전류는 같은 전류 파형의 주기가 반복되어 안정성을 유지하는 반면에 아크 지락전류는 반복 특성이 없다. 따라서, 이러한 특성의 차이를 고조파 분포로 나타내고 적용 뉴로 퍼지추론 시스템의 학습을 통해 구별하도록 시도하는 것이다.

### 3. 적용 뉴로 퍼지 추론 시스템 [15]

고임피던스 고장 전류의 비선형-비대칭 특성을 정확하게 모델링하고, 다양한 패턴을 체계적으로 분류하여 검출한다는 것은 불가능하다. 그렇기 때문에 계통 전문가의 지식과 축적된 기술을 기반으로, 다양한 고장 전류의 특징을 학습을 통해 축적할 수 있는 지적인 고장 검출 시스템이 필요하다. 본 논문에서는 Sugeno 퍼지 추론시스템을 전방향네트워크 형태로 구조화한 적용 뉴로 퍼지 추론시스템을 구현하여, 전문가의 경험 및 지식을 반영할 수 있는 퍼지 시스템의 장점과 신경망의 학습 능력을 결합한 새로운 고임피던스 고장 검출법을 제시하였다.

#### 3.1 적용 뉴로 퍼지 추론 시스템

입력이  $x, y$ 이고 출력이  $f$ 인 1차 Sugeno 퍼지 모델이 식(1)과 같은 2개의 퍼지 규칙으로 구성되면

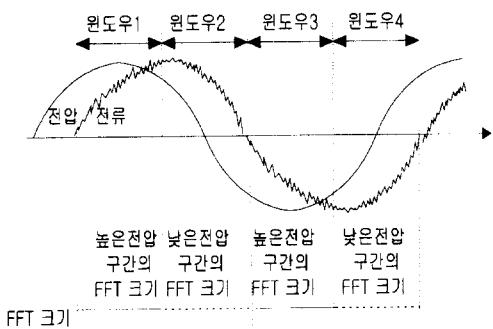


그림 1. 전압 파형의 크기에 의한 데이터 윈도우 분할  
Fig. 1. Devided Data window by the Amplitude of voltage

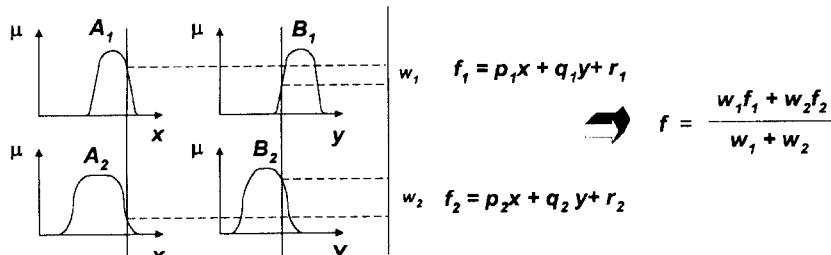


그림 2. Sugeno 퍼지 추론 시스템  
Fig. 2. Sugeno fuzzy inference system

Rule 1: If  $x$  is  $A_1$  and  $y$  is  $B_1$ , then  $f_1 = p_1x + q_1y + r_1$

Rule 2: If  $x$  is  $A_2$  and  $y$  is  $B_2$ , then  $f_2 = p_2x + q_2y + r_2$

(1)

입출력 관계식은 추론 과정을 통해 그림 3처럼 유도된다.

그림 2을 전방향 네트워크로 등가화 한 것이 적응 뉴로 퍼지 추론 시스템으로 그림 3에 보였다.

그림 3과 같이 적응 뉴로 퍼지 시스템은 5개의 층으로 구성되며 첫 번째 층의 Layer 1은 그림 2와 같은 소속 함수를 가지며 본 논문에서 사용한 소속함수는 식(2)와 같은 종형 함수 (bell function)를 이용하였다.

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^2 b} \quad (2)$$

Layer 4의 추력은 정규화된 Layer 3의 출력  $\bar{w}_i$ 와 결론부 파라미터  $\{p_i, q_i, r_i\}$ 를 이용해 식(3)과 같이 계산되고 최종 출력은 이들의 합으로 계산된다.

$$O_{4,i} = w_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad (3)$$

여기서 학습시켜야 할 파라미터는 Layer 1과 Layer 4에 존재한다. 이러한 적응 뉴로 퍼지 추론 시스템에 다양한 실측 고장 파형 및 정상 파형을 입력시켜서, IF-THEN 규칙에 의해 Layer 1의 출력이 정해지며, 최종 출력이 고임피던스 고장시 +1로 정상시에 -1이 되도록 다양한 실측 고장파형 및 정상 파형을 대상으로 학습 시켰다. 또한 파라미터의 학습에 표 4에 보

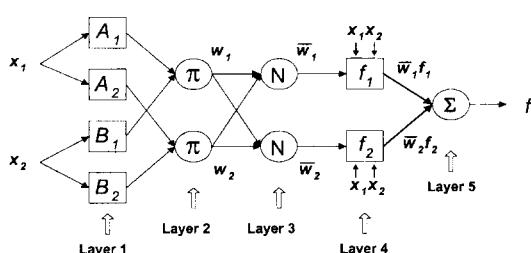


그림 3. 적응 뉴로 퍼지 추론 시스템의 구조  
Fig. 3. Architecture of adaptive neuro fuzzy inference system

표 1. 복합 학습 알고리즘  
Table 1. Hybrid learning algorithm

	전 방향 (Forward Pass)	역 방향 (Backward pass)
조건부 파라미터	Fixed	Gradient descent
결론부 파라미터	Least-Square Estimator	Fixed
평가 대상	Node Outputs	Error signals

인 복합 학습 알고리즘(Hybrid Learning Algorithm)을 적용하여 학습 시간을 크게 단축시켰다.

즉, 조건부 비선형 소속함수의 파라미터는 신경망의 대표적 학습방법인 최급강하법(GradientDescent Method)을 적용하고, 결론부의 선형파라미터는 최소자승 알고리즘(Least Squares Algorithm)으로 개선하여 선형과 비선형 특성을 함께 표현하는데 적합하도록 하였다.

### 3.2 입력 선정 방법

고임피던스 고장 데이터는 지락시 접촉 매체가 보도블럭, 아스팔트, 자갈, 모래 등으로 다양한 조건에서 주기당 64샘플씩 측정한 것이며 아크부하전류와 샘플링간격이 동일하다. 전압위상별로 1주기의 전류 데이터를 4개의 데이터 원도우로 분리하여 1/2 주기마다 FFT를 계산한 후 DC~7조파, 즉 8개 요소 모두를 적응뉴로 퍼지 추론 시스템의 입력으로 사용하면 파라미터가 2352개로 파라미터의 수가 너무 많아 학습 시에 수렴 속도가 매우 느리므로 입력의 수를 줄여 학습속도를 높일 수 있다.

본 논문에서는 검출 성능에 영향을 주는 주된 고조파 성분만을 입력 선정(inputselection)기법을 통해 선정하여 파라미터의 개수를 크게 감소시켜 학습시간을 단축시켰으며, 수렴오차에는 큰 차이가 없도록 하였다. 입력 선정 기법으로는 Direct exhaustive search법과 sequentialforward selection 법을 모두 적용하였으며, 각 기법의 주된 장, 단점을 정리하여 표 2에 나

표 2. 입력 선정 기법  
Table 2. Input selection method

Method	장 점	단 점
Sequential forward selection	시간 단축	local optimal 추정 가능
Full optimal search	정확한 optimal	시간이 오래 걸림

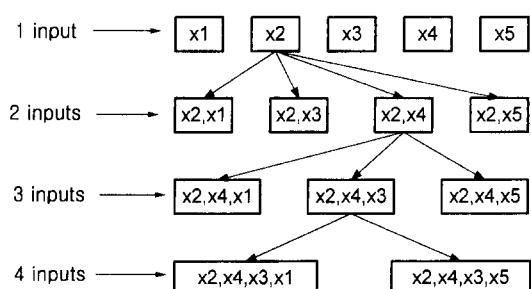


그림 4. 순차적 전방향 입력 선정  
Fig. 4. Sequential forward input selection

타내었다.

Sequential forward selection은 최소 입력 조합으로부터 학습 오차가 가장 적은 조합을 기준으로 입력개수를 증가시키는 방법이며 그림 4에 보였다.

**표 3. 고임피던스 고장 검출 인자 선정 결과**  
Table 3. Result of fault detection component for HIF

입력 갯수	Sequential forward selection		전체파 라미터 수	
	(입력 조합) 오차	(최적조합) 오차		
2개	(2,3) 0.095478 (2,4) 0.145076 (2,5) 0.164032 (2,6) 0.142794 (2,7) 0.138879 (2,8) 0.119832 (3,4) 0.278456 (3,5) 0.267946 (3,6) 0.169598 (3,7) 0.227772 (3,8) 0.280942 (4,5) 0.431702 (4,6) 0.175623 (4,7) 0.259802 (4,8) 0.380626 (5,6) 0.201379 (5,7) 0.291550 (5,8) 0.363462 (6,7) 0.194465 (6,8) 0.160747 (7,8) 0.300385	0.095478(2,3)	0.095478(2,3)	24
3 개	(2,3,4) 0.050946 (2,3,5) 0.089339 (2,3,6) 0.076693 (2,3,7) 0.085032 (2,3,8) 0.067076	0.050946(2,3,4)	0.042762(2,3,6)	50
4개	(2,3,4,5) 0.045606 (2,3,4,6) 0.032988 (2,3,4,7) 0.040086 (2,3,4,8) 0.041285	0.0032988 (2,3,4,6)	0.0032988 (2,3,4,6)	104
5 개	(2,3,4,6,5) 0.025320 (2,3,4,6,7) 0.025407 (2,3,4,6,8) 0.022594 0.022594 (2,3,4,6,8)	0.022594 (2,3,4,6,8)	0.022594 (2,3,4,6,8)	222
6 개	(2,3,4,6,8,5) 0.021121 (2,3,4,6,8,7) 0.021057	0.021057 (2,3,4,6,8,7)	0.021057 (2,3,4,6,8,7)	484
7 개	(2,3,4,6,8,7,5) 0.020945 0.020945	0.020945 (2,3,4,6,8,7,5)	0.020945 (2,3,4,6,8,7,5)	1066

Full optimal search란 입력 개수별로 가능한 모든 입력 조합을 구성하는 것이며 정확한 optimal을 구할 수 있으나, 선정 시간이 매우 오래 걸리는 단점이 있다.

Sequential forward selection과 Full optimal search를 HIF 검출을 위한 적용 뉴로 퍼지 추론 시스템의 입력 선정에 적용한 결과를 표 3에 나타냈다.

표에서 두 기법 모두 동일한 결과를 보였으며, 입력을 5개 이상 조합하면 수렴 오차에 큰 차이가 없으면서도 파라미터 개수가 크게 증가하였다. 즉, (2,3,6,7,8) = {1조파, 2조파, 5조파, 6조파, 7조파}의 조합이 고장 검출에 가장 효과적인 검출 변수임을 알 수 있으며, 이 때의 파라미터의 개수는 기존의 신경 회로망을 이용한 검출 기법에 사용된 개수(Ref [11] 800–22,800개, Ref [14] 668개)보다 크게 감소하였으나 검출 성능에는 차이가 없었다.

따라서 본 논문에서는 고임피던스 고장검출에 사용할 ANFIS 구조를 입력 요소 5개로 하고 각 입력 요소마다 소속함수를 2개씩 설정하여 규칙개수가 32개인 적용 뉴로 퍼지 시스템을 구성하여 적용하였다.

#### 4. 고임피던스 고장 검출 알고리즘의 적용

한국전력 공사에서 시행한 (자갈, 모래) 인공지락 사고 시험에서 실측한 데이터로부터 고장전과 고장후의 전압 및 전류 파형을 그림 5에 나타냈다. 전압, 전류 파형은 PT와 CT 2차측에서 260  $\mu$  sec 간격으로 12 bit A/D 변환기를 써서 측정한 것이며, 2차측의 크기로 표시하였다.

전류 파형을 전압의 파고치 부분과 저전압 부분에서 FFT를 수행하여 고조파 성분의 크기를 그림 6에 비교해 보였다.

그림에서 점선은 전압이 파고치 부근일 때 전류의 고조파 성분 크기를 나타낸 것이고, 실선은 낮은 부분

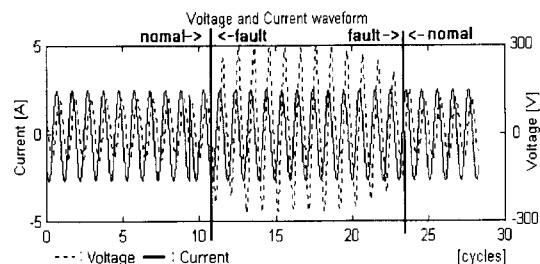


그림 5. 전압 및 전류 파형  
Fig. 5. Voltage & Current waveform

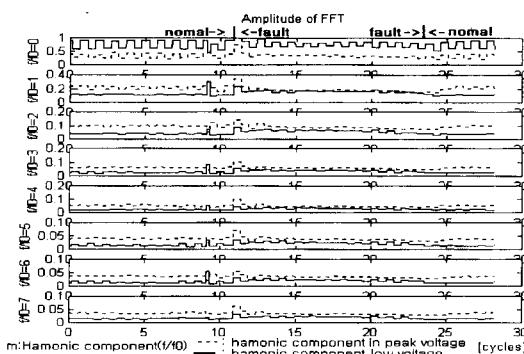


그림 6. 전류 파형의 전압위상별 고조파 성분의 크기  
Fig. 6. Magnitude of harmonics of current waveform as voltage-phase

의 전압에서 고조파 성분의 크기를 나타낸 것이다. 각 고조파 성분의 크기는 1주기 동안의 실효치(rms)를 기준으로 정규화 하였다. 고임피던스 고장시는 전압이 파고치일 때 고조파 전류가 더 크게 나타나고, 정상 전류에 대해서는 저전압 구간에서 더 크게 나타남을 알수 있다. 고임피던스 고장은 전류크기 변화가 작지만 고조파 성분의 분포가 달라지는 특성을 보이고 있으며 전압 파형의 부분별로도 다른 양상을 나타내고 있다.

본 논문에서는 전압이 파고치 부근일 때와 낮은 부분일 때의 고조파 전류 크기의 차를 고장 검출 변수로써 적응 뉴로 퍼지 추론 시스템에 입력시켜 고장을 판별도록 시도하였다. 고저항 지락 고장의 모의 실험은 폭 넓은 고장 특성을 가지도록 다양한 대상 즉, 보도블럭지락, 자갈 지락, 모래 지락 등에서 실측된 데이터를 적응 뉴로 퍼지 추론 시스템의 학습에 적용하였다. 고장 전류 파형들을 전압 위상별로 7조파까지 계산하여 중요 인자만을 입력 선정 기법을 써서 추출한 후, 적응 뉴로 퍼지 추론 시스템의 입력으로 인가하여 출력이 1이 되도록 학습시켰다. 또한 건전한 상태에서의 데이터에 대하여도 같은 조건의 고조파 성분 크기를 입력시켜 출력이 -1이 되도록 학습시켰다.

각종 고임피던스 고장 전류의 데이터 중 고장 파형과 건전 파형의 일부만을 순차적으로 적용하여 적응 뉴로 퍼지 추론 시스템을 학습 시켰으며, 학습에 사용된 데이터를 표 5에 보였으며, 이를 복합 알고리즘을 적용하여 500 epoch 동안 적응 뉴로 퍼지 추론 시스템을 학습 시켰을 때 각 고장별로 정확히 검출하는 성능을 보였으며 특히, 학습에 제외된 아스팔트, 나무, 보통토사의 고장파형과 고장이 아닌 아크부하 전류도 정확하게 판별하는 우수한 성능을 보였다.

표 5. 학습에 사용된 데이터  
Table 5. Learned data

	전전 구간	고장 구간	비고
보도블럭	45 cycle	20 cycle	c상 지락
자갈모래	45 cycle	35 cycle	c상 지락
모래	45 cycle	40 cycle	c상 지락
아스팔트	40 cycle		
나무	40 cycle		
보통토사	40 cycle		

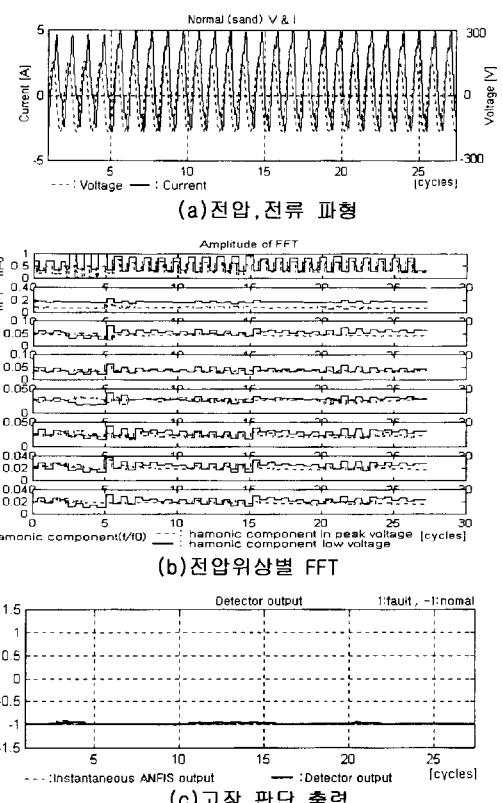


그림 7. 모래 지락시 건전상의 (a) 전압, 전류 파형, (b) 전압 위상별 FFT, (c) 고장 판단 출력  
Fig. 7. Normal phase that fault occurred on sidewalk (a) Vltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

다음 그림 7~12는 각 고임피던스 고장 및 건전 파형(전압, 전류)과 전압 위상별 전류의 고조파 성분, 고장검출 성능을 보인 것이다. 전압 및 전류 파형(그림 7~12의(a))은 PT와 CT 2차 측에서  $260\mu\text{sec}$  간격으로 A/D 변환기를 써서 측정한 것이며, 2차측 크기로 표시했다.

그림 7은 모래에 C상이 지락시, 건전 A상 파형에

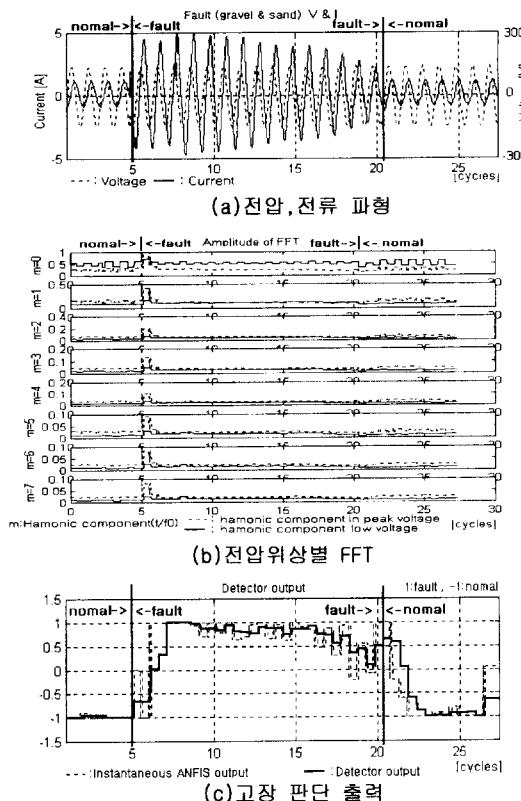


그림 8. 자갈, 모래 지락시 고장상의 (a) 전압, 전류 파형, (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 8. Fault phase that fault occurred on a mixture of gravel & sand (a) Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

고장 판별을 시도한 것으로 부하 특성 때문에 전전상의 전류 파형(그림 (a)의 점선)도 고조파 성분을 포함하고 있으나 고장 판단 출력이 -1로 정확하게 고장이 아님을 검출하였다.

그림 8은 자갈, 모래 고장이 5 cycle에서 개시된 후 16 cycle 지속되다가 정상상태로 되돌아가는 경우를 대상으로 고장 검출 판별을 시도한 것이다. 5 cycle 이후에 고장 판단 출력이 +1이 되어 정확히 검출된 상태로 지속되다가 사고가 제거됨에 따라 정상 상태로 환원되고 있음을 보이고 있다.

그림 9(a)는 배전선로가 보도블록에 지락시 파형을 보인 것으로 고장 전류의 크기가 아크의 발생과 소호에 따라 미소하게 진동하고 있음을 알 수 있으며, 각 원도우별로 FFT하여 그림 9(b)에 보였다. 고장 판단 출력은 적용 뉴로 퍼지 추론 시스템의 출력이 4 cycle 동안 연속해서 HIF(+1)일 때 +1이 되도록 현시점부터 이전 출력 값을 누적시켜 나타냈으며, 이는 실계통에서 발생할 수 있는 순간적인 과도 현상에 의한 오동작을 방지하기 위함이다.

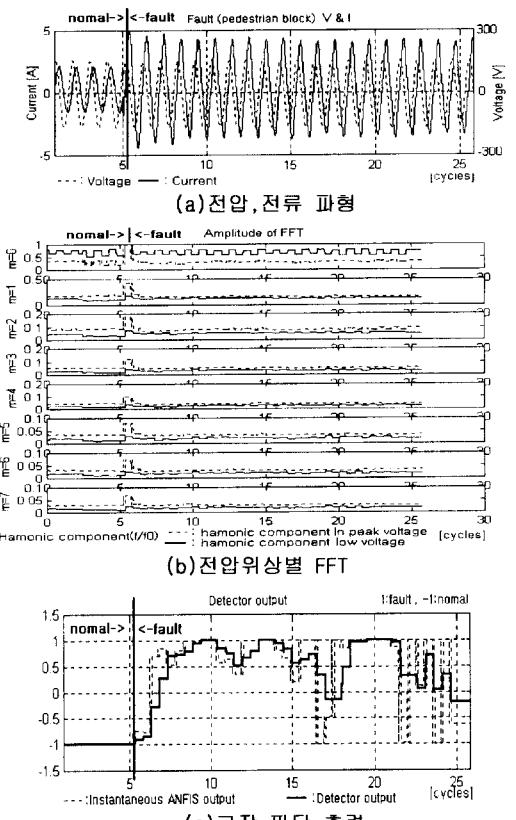


그림 9. 보도블럭 지락시 고장상의 (a) 전압, 전류 파형, (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 9. Fault phase that fault occurred on pedestrian block (a) Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

계통에서 발생할 수 있는 순간적인 과도 현상에 의한 오동작을 방지하기 위함이다.

그림 9(a)는 배전선로가 보도블록에 지락시 파형을 보인 것으로 고장 전류의 크기가 아크의 발생과 소호에 따라 미소하게 진동하고 있음을 알 수 있으며, 각 원도우별로 FFT하여 그림 9(b)에 보였다. 고장 판단 출력은 적용 뉴로 퍼지 추론 시스템의 출력이 4 cycle 동안 연속해서 HIF(+1)일 때 +1이 되도록 현시점부터 이전 출력 값을 누적시켜 나타냈으며, 이는 실계통에서 발생할 수 있는 순간적인 과도 현상에 의한 오동작을 방지하기 위함이다.

장 상태가 4 cycle 이후에 발생하여, 고장 전류의 크기가 아크의 발생과 소호에 따라 미소하게 진동한 모래 고장의 경우에도 고장임을 판별하여 고장 판단 출력이 부분적으로 감소하긴 하였으나 +1에 근접한 값으로 나타나는 성능을 보였다.

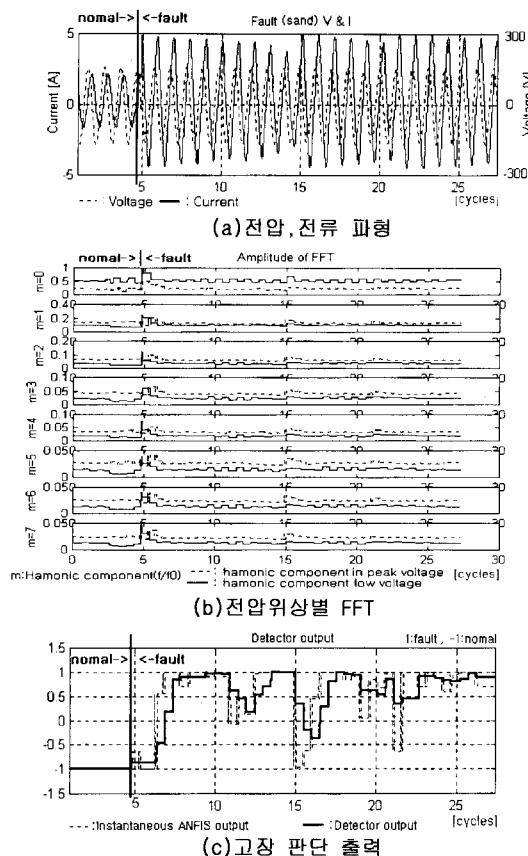


그림 10. 모래에 지락시 고장상의 (a) 전압, 전류 파형, (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 10. Fault phase that fault occurred on sand(a) Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

배전선로가 토사에 지락한 고장 유형은 적응 뉴로 페지 추론 시스템의 학습시 제외된 고장 파형이었으나, 고장 판단 출력은 이를 정확하게 검출하는 우수한 성능을 보였다.

그림 12(a)는 배전 선로가 나무에 지속적으로 접촉하였을 때의 고장 파형을 보인 것으로, 학습에 제외된 고장 형태임에도 불구하고 정확하게 검출하였다.

또한 아크 지락 전류와 유사한 정상적인 아크부하 전류를 대상으로 실측하여 적응 뉴로 페지 추론 시스템의 판별 성능을 평가해 보았다.

순간적으로 아크 부하전류가 흐르는 경우의 전류 파형에 적용한 결과를 그림 13에 나타냈다. 이 경우는 아크부하가 연속해서 계속 흐르지 않고 순간 순간 잠시 동안만 아크부하 전류가 흐르는 경우로, 아크부하의 순간 순간에는 약간의 출력 변동이 있으나 고임피

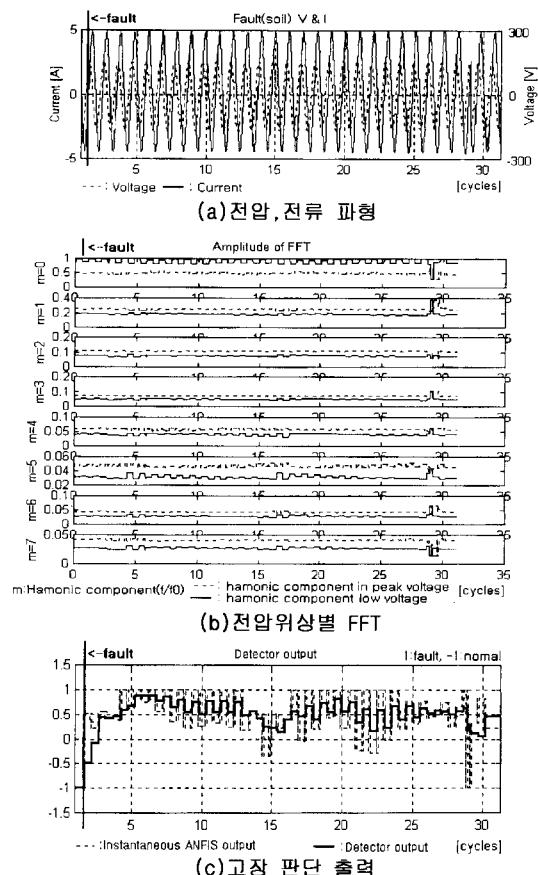


그림 11. 토사에 지락시 고장상의 (a) 전압, 전류 파형, (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 11. Fault phase that fault occurred on earth (a) Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

던스고장사고와는 구별되는 특성으로 나타나고 있다.

아크 부하전류가 계속 흐르는 경우는 그림 14에 전압 파형과 함께 보였으며, 고임피던스 고장과는 뚜렷이 구별되는 양상을 나타내고 있다.

아크 부하전류가 흐르기 시작하는 시점은 고임피던스고장 전류와 유사한 특성을 가지고 있어서 사고로 판별해 가는 특성을 보이다가 반복되는 전류파형으로부터 사고가 아닌 부하로 판별해 내는 과정을 보이고 있다.

## 6. 결 론

본 논문에서는 학습 능력을 가진 적응 뉴로 페지 추론 시스템을 전력계통의 고임피던스고장 판별에 적용하였다. 고임피던스 고장 현상은 그 고장전류의 크

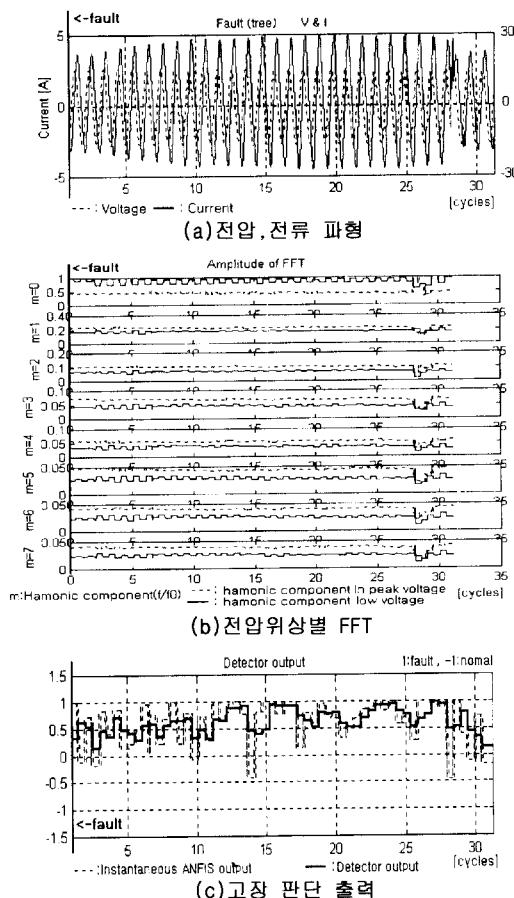


그림 12. 나무에 접촉시 고장상의 (a) 전압, 전류 파형, (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 12. Fault phase that fault occurred on tree (a) Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

기는 작지만 도체의 전압이 과고치에 가까울 때 아크 성 고장전류가 흐르게 되는 특성에 차안하여 전압파형의 부분별로 전류파형의 고조파 성분을 추출하여 고장을 판별하도록 하였다. 고임피던스 고장실험에서 실측된 여러 유형의 고임피던스 사고에 대하여 전압이 높은 과고치에서의 고주파전류 분포와 전압이 낮은 구간에서의 고주파 전류 분포의 차이를 적용 뉴로 퍼지 시스템의 입력으로 사용하여 학습함으로서 정확도가 높은 고저항 사고검출 성능을 얻었다. 또한 Sequential forward selection 방법에 의해 입력요소를 줄여서 학습 파라미터  $p$ 의 개수를 줄일 수 있었으며, 학습방법에는 복합 학습 알고리즘(Hybrid Learning Algorithm)을 적용하여, 빠른 수렴 속도 및 다양한 형태의 고저항 고장에 대해 복잡한 수식적 해석이 없이도 검

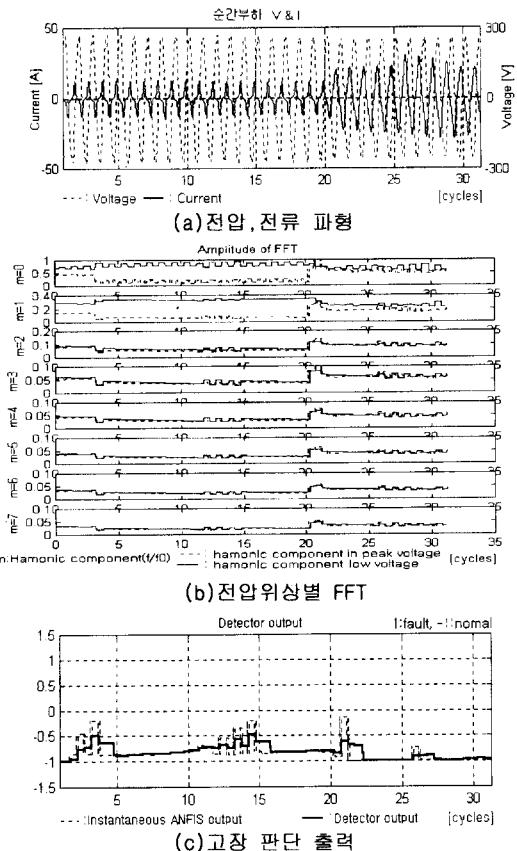


그림 13. 순간 아크 부하시 (a) 전압, 전류 파형 (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 13. Instantaneous arc load (a) Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

출이 가능하고, 학습하지 않은 고장 유형에 대해서도 정확하게 판별하는 우수한 성능을 보였다. 또한 아크 고장 전류와 유사한 아크 부하전류도 구분하여 검출함을 확인하였다.

본 논문에서 제시한 검출 기법은 숙련된 계통 전문가의 경험적인 지식 및 축적된 기술을 활용하여 소속 함수의 파라미터를 초기화 한 후, 수집된 고장 파형의 특성을 학습시켜 파라미터를 최적화하므로 상황에 따라 적응적인 고장 검출이 가능하였으며 이를 시뮬레이션으로 검증하였다.

## 감사의 글

본 연구는 1998년도 광운대학교 연구지원에 의하여 이루어진 연구로서, 관계부처에 감사 드립니다.

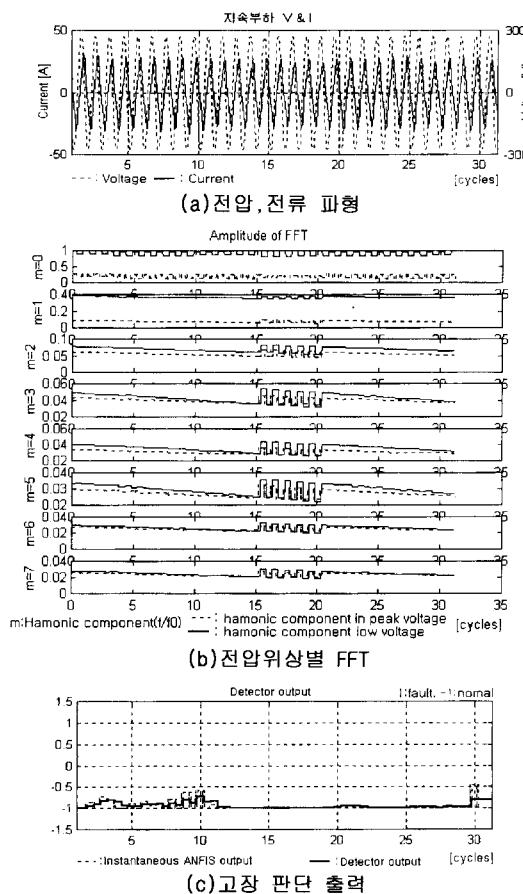


그림 14. 지속 악기 부하시 (a) 전압, 전류 파형 (b) 전압 위상별 FFT, (c) 고장 판단 출력

Fig. 14. Lasting arcload (a)Voltage & Current waveform, (b) FFT as phase of voltage, (c) Output of a fault detector

## 참고문헌

- [1] B. Mike Aucoin and B. Don Russell, "Detection of Distribution High Impedance Faults Using Burst Noise Signals Near 60 Hz", *IEEE Transactions on Power Delivery*, Vol. PWRD-2, No. 2, pp. 342-348, Apr. 1987
- [2] S. J. Balser, K. A. Clements and D. J. Lawrence, "A Microprocessor-based Technique for Detection of High Impedance Faults", *IEEE Transactions on Power Delivery*, Vol. PWRD-1, pp. 252-258, Jul. 1986.
- [3] Huand, C. L., Chu, H. Y., Chen, M. T. "Algorithm comparision for high impedance fault detection based on staged fault test", *IEEE Trans on Power Delivery*, Vol. 3, No. 4, Oct. 1988.
- [4] Russel, B. D., Chinchali, R. P. "A digital signal processing algorithm for detecting arcing faults on power distribution feeders", *IEEE Trans. on Power Delivery*, Vol. 4, No. 1, Jan. 1989.
- [5] Kwon, W. H., Lee, G. W., Park, Y. M. "A Study for the improvement of the protection relay scheme on multi grounded distribution system", *KEPCO Project Final Report*, KRC-85A-JO5, 1987.
- [6] A. F. Sultan, G. W. Swift, & D. J. Fedirchuk, "Detection of High Impedance Arcing Faults Using a Multi-Layer Perceptron", *IEEE Trans on Power Delivery*, Vol. 7, No. 4, Oct. 1992, pp. 1871-1877.
- [7] S. E bron, D. L. Lubkeman, & M. White, "A Neural Network Approach to the Detection of Incipient Faults on Power Distribution Feeders", *IEEE Trans on Power Delivery*, Vol. 5, No. 2, April, 1990, pp. 905-914.
- [8] D. Baigent, & E. Levenhaft, "Microprocessor-Based Protection Relays: Design and Application Examples", *IEEE Trans on Industry Application*, Vol. 29, No. 1, Jan/Feb. 1993, pp. 66-71.
- [9] 임화영, 박찬국, 류창완, 고재호, "배전자동화를 위한 적응보호시스템 연구", 기초 전력 공학 공동 연구소 중간 보고서, 96-중-01, 1997. 8.
- [10] Ko, J. H., Ryu, C. W., Yim, W. Y, "Detection of High Impedance Faults using Neural Nets and Chaotic Degree", Proc. of EMPD '98, *IEEE, Singapore*, Vol. 2, March, 1998, pp. 399-404.
- [11] 이화식, 박준호, 한중길, "배전계통에서 신경회로망을 이용한 고저항 지락사고 검출기법에 관한 연구", 대한전기학회 논문지 제45권 제11호, 1996년 11월.
- [12] 이종범, 정창호, 백영기, 김일동, 한경남, "송전계통 고저항 지락사고에 대한 보호계전기 시험 및 특성분석에 관한 연구", 대한전기학회 논문지 제47권 제4호, 1998년 4월.
- [13] 오용택, 김창종, "배전 계통의 고 임피던스 고장 검출을 위한 고조파 변수 성능 평가", 대한전기학회 논문지 제47권, 제6호, pp. 1998년 6월.
- [14] 최해술, 강승호, 김철환, 신명철, 정우곤, 이복구, "신경회로망을 이용한 고저항 지락사고 검출에 관한 연구", 대한전기학회 논문지 제47권 제7호, 1998년 7월.
- [15] Jang, J. R., Sun, C. T., Mizutani, E. "Neuro-Fuzzy and Soft Computing", Prentice Hall, 1997.
- [16] 전력계통의 고임피던스 고장 검출 기법에 관한 연구. A Study on HighImpedanceFault Detection IN Power System. 저자 : 任化永, 柳昌完, 高載虎.



임화영 (Wha-Yeong Yim)

1973년 : 한양대학교 전기과 졸업  
 1976년 : 동 대학원 전기 공학과 졸업  
 (석사)  
 1984년 : 동 대학원 전기 공학과 졸업  
 (공학박사)  
 1982년~1998년 : 광운대학교 전기광학과 교수  
 1988년~현재 : 광운대학교 재어계측공학과 교수



류 창완 (Chang-Wan Ryu)

1992년 : 광운대 제어계측공학과 졸업  
1994년 : 동 대학원 제어계측공학과  
졸업(석사)  
현재 : 동 대학원 제어계측공학과 박사  
과정 수료



고재호 (Jae-Ho Ko)

1995년 : 광운대 제어계측공학과 졸업  
1997년 : 동 대학원 제어계측공학과  
졸업(석사)  
현재 : 동 대학원 제어계측공학과 박사  
과정 수료



홍대승 (Dae-Seung Hong)

1992년 : 광운대 제어계측공학과 졸업  
1994년 : 동 대학원 제어계측공학과  
졸업(석사)  
1994년~1997년 12월 : 기아정보 시스템  
현재 : 동 대학원 제어계측공학과 박사  
과정



배영철 (Young-Chul Bae)

1984년 : 광운대 전기공학과 졸업  
1986년 : 동 대학원 전기 공학과 졸업  
(석사)  
1997년 : 동 대학원 전기 공학과 졸업  
(공학박사)  
1986년 2월~1991년 9월 : 한국전력공사  
1991년 9월~1997년 9월 : 산업기술정보  
원 책임연구원  
1997년 9월~현재 : 국립 여수대학교 전기 및 반도체 공학과 교수