

신경회로망을 이용한 고저항 고장 검출

*한 중길, 이 화석, 윤 재영, 양 장호, 박 준호
부산대학교 공과대학 전기공학과

High Impedance Fault Detection Using Neural Networks

*J. G. Han, H. S. Lee, J. Y. Yun, K. H. Yang, J. H. Park
Dept. of Electrical Engineering, Pusan National University

Abstract : High impedance fault can not be easily detected by conventional method. But if it would not be detected and cleared quickly, it can result in fires, and electric shock.

In this paper, ANN, which has learning capability, is used for high impedance fault detection. The potential of the neural network approach is demonstrated by simulation using KEPCO's measured data. Among ANN models used in this paper, CPN shows better result than BPN in respect of convergence and reliability.

1. 서론

최근 전력수요의 급증에 따라 송배전설비는 점차 대형화되는 추세이며 지역적으로 광범위하게 신재되어 있어 전력계통의 보호 시스템 세기가 복잡해지고 계통의 고장 양상도 다양해지고 있다. 일반적으로 대부분의 전력공급체계가 금속선으로 이루어져 있는데, 배전선로 사고의 약 11%정도를 차지하는 단선 사고의 고저항고장(high impedance fault : HIF)은 고장발생시 고장지점의 아크(arc)를 동반한 높은 저항때문에 고장전류가 작게 흐르는 특성을 가지고 있다. 이러한 고장은 검출이 용이하지 않아서 인명안전과 및 화재등과 같은 전기재해로 유발될 수 있다[1-10].

고장이 발생하면 금전소의 운전원은 계전기(relay)나 차단기(circuit breaker)의 경보(alarm) 및 동작(operation)정보로부터 고장내용을 판단하고 계통복구를 위한 조작을 수행한다. 그런데, 단락 및 지각고장이 발생했을 때 동작하는 과정계전기는 배전선 말단사고 또는 고저항 저락단선 사고시에 부동작하는 사례가 많이 발생하고 있으며 더욱기 대도시 인가밀집지역은 절연전선을 주로 사용하기 때문에 단선지역에서 고저항 저전류로 인한 고장이 발생할 여지가 점차 증가되고 있어 기존의 과정류 보호장치로는 검출이 불가능하다.

이 문제를 해결하기 위해 현재까지 여러 가지 고저항 저락고장 검출방법들이 제안[3-9]되었으나 민족한민한 성능은 인지 못하였다.

근래에 각광을 받기 시작한 신경회로망은 복잡한 구조를 갖는 시스템의 상세한 정보 없이도 입, 출력 데이터만으로 학습(learning)과정을 통하여 그 특성과 구조를 근사화할 수 있는 학습능력, 강인성, 일반화, 기능 및 병렬분산처리(parallel distributed processing)등의 특성을 가지고 있다.

본 논문에서는 여러 응용분야에 널리 사용되고 있는 역전파 회로망(back-propagation network : BPN)과 특히 수평속도에 장점을 가지고 패턴 분류기로 잘 알려진 카운터 프로파게이션 회로망(counter-propagation network : CPN)모델을 이용하여 고저항 고장검출용 신경회로망을 구성하였다.

신경회로망 방법의 유통성을 보기 위해 한국전력공사의 신축데이터[4]를 이용하여 시뮬레이션 해본 결과, 종래의 방법보다 나은 결과를 나타내어 신경회로망을 이용한 고저항 고장 검출이 가능함을 알 수 있었다.

2. 신경회로망 모델

2.1 역전파 회로망[11]

BPN의 학습 알고리즘은 출력층에서 실제로 계산된 출력값과 학습쌍에 의해 제시된 목표 출력값의 차이를 줄이는 방향으로 가중치를 조절하는 것으로 Rumelhart 및 PDP그룹에 의해 제시된 "generalized delta rule"을 이용하였다.

2.2 카운터 프로파게이션 회로망[12]

CPN은 입력 유형 즉, $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ 이 주어지면 X와 Y간의 관계인 맵핑(mapping)을 나타내는 함수를 찾도록 학습된다.

입력층은 입력이 선형으로 인가되는 버퍼(buffer)의 역할을 한다. 그런데 입력벡터 X는 입력층으로 인가되기 전에 정규화되어야 하며 그 식은 다음과 같다.

$$\|X\| = 1 \quad (1)$$

여기서, $X = (x_1, x_2, \dots, x_n)$ n : 입력 뉴런의 수
즉,

$$x_1^2 + x_2^2 + \dots + x_n^2 = 1 \quad (2)$$

또한 출력층에서 경쟁층으로의 가중치벡터 W_j 도 정규화되어야 하며 그 식은 다음과 같다.

$$\|W_j\| = 1 \quad (3)$$

여기서, $W_j = (w_{j1}, w_{j2}, \dots, w_{jn})$ n : 입력뉴런의 수

: 입력층에서 경쟁층의 j번째 뉴런으로의 가중치

경쟁층에서는 일단 가중합을 계산하고 가중합이 가장 큰 PC 만 출력을 1로 내고 나머지는 0이다. 즉, 경쟁층의 i번째 뉴런의 출력값인 z_i 는 다음과 같다.

$$z_i = \begin{cases} 1 & \|net_i\| > \|net_j\| \text{ for all } j \neq i \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

그리고 경쟁후에는 출력층에서의 가중합을 계산하여 그 값을 출력으로 내게 된다.

$$y_j' = \sum_i z_i v_{ji} \quad (5)$$

여기서, y_j' : 출력층의 j번째 뉴런의 실제치

v_{ji} : 경쟁층의 i번째 뉴런에서 출력층의 j번째 뉴런으로의 가중치

CPN의 학습법은 다음과 같다. 먼저 입력에서 경쟁층으로의 가중치는 경쟁층의 승자(win)뉴런에서 연결된 가중치만 다음 식으로 조정한다.

$$w_{ji}(t+1) = w_{ji}(t) + \alpha(x_i - w_{ji}(t)) \quad (6)$$

여기서, w_{ji} : 입력층의 i번째 뉴런에서 경쟁층의 j번째 뉴런으로 가중치

α : 학습률

식 (6)으로 조정 후 가중치벡터 W_j 는 다시 정규화시켜야 한다. 또한, 승자 뉴런에서 출력층으로의 가중치만 Widrow-Hoff 학습법인 다음 식과 같이 조정한다.

$$v_{ji}(t+1) = v_{ji}(t) + \beta(y_j - y_j') \quad (7)$$

여기서, y_j : 출력층의 j번째 뉴런의 목표치, β : 학습률

3. 고지항 고장 및 신경회로망 적용법

3. 1 고지항 고장

고지항 고장은 지락과 함께 아크를 동반하여 고장전류에는 아크 발생시의 스파크와 비대칭 저속전류가 흐른다. 또한, 다중점지 배전선로에서의 부하 불평형 때문에 야기되는 증성선 전류와 고장전류의 구분이 곤란한 정도로 고장전류의 크기가 매우 작다. 그래서 기존의 상계전기(phase relay) 및 과전류지락계전기(over current ground relay)로는 고지항 고장을 검출할 수 없다.

고지항 고장의 유형을 보면 고지항 대지(아스팔트, 콘크리트, 모래, 자갈, 보도블럭 등)에 전선이 단선 또는 접촉 지락된 경우, 단선된 후 전선이 대지에 접촉되는 않고 근접되어 치쳐 있는 상태, 선로 주변의 수목등과 접촉되는 경우, 전선과 전주, 완금동과의 고지항 접촉의 경우, 그리고 절연전선의 불완전 지락등을 들 수 있다.

3. 2 신경회로망의 고지항 고장검출에의 적용

고지항 고장발생시 전압, 전류는 미세하지만 변화한다는 것을 알 수 있으며 이 전압, 전류치를 계측하여 신경회로망의 입력으로 이용할 수 있다. 또한, 신경회로망은 종래의 여러 검출방법에서 사용한 고지항 고장 검출에 유용한 데이터를 입력으로 결합하여 이용할 수 있는 장점을 가지고 있다.

신경회로망의 출력은 정상운전시는 0, 고장발생시는 1로 정하여 신경회로망을 학습시켰다.

본 논문에서는 신경회로망의 입력으로 전류의 순시치를 이용하는 방법, FFT(fast fourier transformation)분석을 행하여 구한 주파수 스펙트럼을 이용하는 방법, 그리고 이 두 데이터를 결합하여 사용하는 방법을 제시하였고, 앞에서 제시한 두가지 신경회로망 모델을 이용한 시뮬레이션을 통하여 신경회로망 방법이 고지항 고장 검출에 유용한지를 검토하였다.

4. 사례 연구

4. 1 실험 자료

본 연구에서 사용한 데이터는 1986년 12월 3일 정주 변전소 관할 정유 D.L에서 인위적으로 C상의 고지항 지락 고장을 발생시켜 측정한 3상의 전류데이터[4]를 이용하였다.

고지항 지락고장 발생시의 접지 표면의 종류로는 아스팔트, 보도블럭, 보통 땅, 나무접지, 자갈, 모래등이 있다. 실험 자료의 목록을 표 1에 나타내었다.

표 1 실험자료 목록

접지 표면의 종류	실험 횟수
아스 팔트	2
보도블럭	6
보통 땅	4
나무접지	3
자갈, 모래	5
모래	5

표 1의 데이터 중에서 보도블럭에 대한 2번째 실험 데이터 및 4번째 실험 데이터의 c상의 전류파형을 그림 1 및 2에 나타내었다.

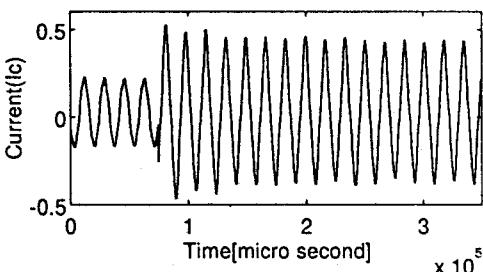


그림 1 보드블럭 2번째 데이터의 c상의 전류파형

그림 1, 2에서 5번까지가 정상상태 파형을 나타내고 그 이후는 고장 발생 후의 파형을 나타낸다. 그림 1, 2에서 보는 것처럼 똑같은 보도블럭에 대한 데이터지만 육안으로 쉽게 정상상태와 고장후의 경계가 구별이 가능한 것도 있고 거의 구별할 수 없는 데이터도 있다. 또한 전압 데이터는 거의 구별할 수 없다는 것을 알 수 있었다. 그래서 각 데이터에 대해 64-point FFT분석을 행하여 구한 주파수 스펙트럼을 구하였다.

그림 3에 보드블럭 2번째 데이터의 주파수 스펙트럼을 나타내었다.

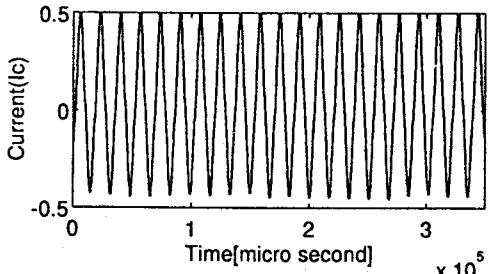
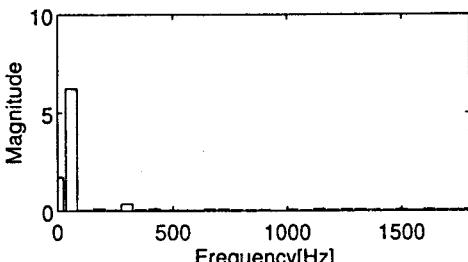
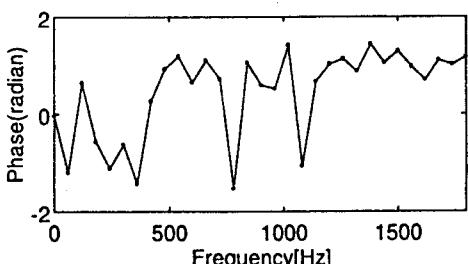


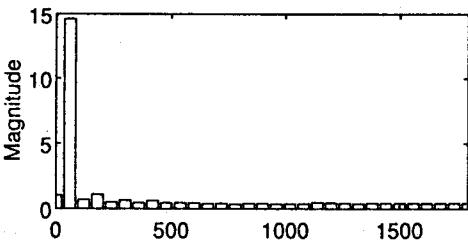
그림 2 보드블럭 4번째 데이터의 c상의 전류파형



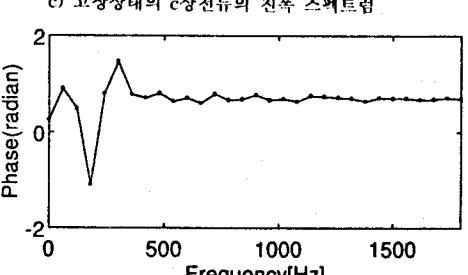
a) 정상상태의 c상전류의 진폭 스펙트럼



b) 정상상태의 c상전류의 위상 스펙트럼



c) 고장상태의 c상전류의 진폭 스펙트럼



d) 고장상태의 c상전류의 위상 스펙트럼

그림 3 보드블럭 2번째 데이터의 주파수 스펙트럼

그림 3에서 보는 것처럼 정상상태와 고장 발생후의 주파수 스펙트럼이 차이를 보인다는 것을 알 수 있으며 이 데이터를 신경회로망의 입력으로 이용할 수 있다. 또한 전류의 순시치를 신경회로망의 입력으로도 이용하였다.

4. 2 순시치 데이터를 신경회로망의 입력으로 이용한 경우
신경회로망의 입력으로 a상, b상, c상, n상 순시치 전류를 이용하였다. 학습데이터의 구성은 그림 4에 나타내었다.

a상	b상	c상	n상	0/1
순시치전류 64개	순시치전류 64개	순시치전류 64개	순시치전류 64개	출력

그림 4 순시치 데이터를 이용한 경우의 신경회로망 입, 출력
학습 데이터의 수는 표 1의 각 실험횟수에 대하여 정상상태 1주기, 고장상태 3주기를 취하여 총 100가지 경우로 학습하였으며 출력은 정상일 때는 0, 고장일 때는 1로 정하였다.

BPN을 이용한 경우의 신경회로망 구조는 입력 뉴런은 256, 은닉층의 뉴런은 40, 출력층의 뉴런은 1개로 구성하였고, CPN의 경우에는 입력 뉴런의 256, Kohonen층의 뉴런은 100, 출력층의 뉴런은 1개로 구성하였다.

표 2에 학습 이후의 정상 및 고장상태의 데이터를 각각 1cycle, 5cycle을 취하여 학습시와 동일한 방법으로 구성한 후 검출 성능을 평가하였다. 표 2에서 보는 것처럼 고장 발생후 신경회로망이 계속 고장상태를 나타내는지를 검토하기 위하여 연속해서 3cycle 이상을 고정으로 판단한 경우를 검토하였다. 또한 CPN을 이용하는 방법이 BPN보다 더 나은 결과를 보임을 알 수 있었다.

표 2 순시치 데이터를 이용한 경우의 검출 성능

방법	실현데이터			A	B	C
	D	검출율	D	검출율	D	검출율
CPN	18/25	72.0%	99/125	79.2%	15/25	60%
BPN	16/25	64.0%	86/125	68.8%	14/25	56%

A : 연속해서 3cycle 이상을 고장으로 판단한 경우

B : 고장으로 정판정한 경우, C : 정상으로 정판정한 경우

D : 검출데이터수/실험데이터수

4. 3 주파수 스펙트럼을 신경회로망의 입력으로 이용한 경우

신경회로망의 입력으로 a상, b상, c상, n상의 전류를 각각 FFT분석을 한 후 각자의 최대값으로 나누어 신경회로망의 입력으로 이용하였다. 입력 데이터의 구성은 그림 5에서 보는 것처럼 3가지 방법을 이용한 경우를 시뮬레이션하였다.

a상	b상	c상	n상	0/1
크기5개	크기5개	크기5개	크기5개	출력

a) 4고조파까지의 진폭 및 위상 스펙트럼 데이터를 이용한 경우

a상	b상	c상	n상	0/1
위상5개	위상5개	위상5개	위상5개	출력

b) 4고조파까지의 진폭 스펙트럼 데이터를 이용한 경우

a상	b상	c상	n상	0/1
위상5개	위상5개	위상5개	위상5개	출력

c) 4고조파까지의 위상 스펙트럼 데이터를 이용한 경우

그림 5 주파수 스펙트럼을 이용한 경우의 신경회로망 입, 출력
학습 데이터의 수는 순시치 데이터를 이용한 경우에서 사용한 데이터를 FFT분석하여 구성하였으므로 총 100가지의 경우이다.

BPN과 CPN을 이용한 경우의 각 회로망의 구조 및 학습성능 평가 결과를 표 3에 나타내었고 A, B, C, D는 표2와 같다.

표 3 주파수 스펙트럼 데이터를 이용한 경우의 검출 성능

방법	실현 데이터			A	B	C	
	구조	D	검출율	D	검출율	D	검출율
CPN	a) 40-100-1	18/25	72%	101/125	80.8%	18/25	72%
	b) 20-100-1	19/25	76%	107/125	85.6%	23/25	92%
	c) 20-100-1	14/25	56%	91/125	72.8%	17/25	68%
BPN	a) 40-30-1	18/25	72%	70/125	56%	13/25	52%
	b) 20-20-1	18/25	72%	86/125	68.8%	15/25	60%
	c) 20-20-1	18/25	72%	93/125	74.4%	13/25	52%

표 3에서 보는 것처럼 주파수 스펙트럼을 이용한 경우 중 진폭 스펙트럼을 이용한 경우가 가장 좋은 검출 성능을 나타내었다.

4. 4 순시치와 주파수 스펙트럼 데이터를 결합하여 신경회로망의 입력으로 이용한 경우

고장High 고장 검출에 유용한 정보인 순시치와 주파수 스펙트럼 데이터를 결합하여 입력으로 구성한 신경회로망 구조를 제안하였다.

입력데이터 구성 방법은 그림 6에 나타내었고 검출 성능은 표 4에 나타내었다.

a상	b상	c상	n상	0/1
크기5개, 위상5개,	크기5개, 위상5개,	크기5개, 위상5개,	크기5개, 위상5개,	출력

순시치64개 순시치64개 순시치64개 순시치64개

a)

a상	b상	c상	n상	0/1
크기5개	크기 5개	크기 5개	크기 5개	출력

순시치64개 순시치64개 순시치64개 순시치64개

b)

a상	b상	c상	n상	0/1
위상 5개	위상 5개	위상 5개	위상 5개	출력

순시치64개 순시치64개 순시치64개 순시치64개

c)

그림 6 순시치 및 주파수 스펙트럼을 이용한 경우의 신경회

로망 입, 출력

표 4 순시치 및 주파수 스펙트럼 데이터를 이용한 경우의
검출성능

실험 데이터	A		B		C		
	D	검출율	D	검출율	D	검출율	
CPN	296-100-1	18/25	72%	100/125	80%	18/25	72%
	276-100-1	19/25	76%	98/125	78.4%	17/25	68%
	276-100-1	17/25	68%	98/125	78.4%	18/25	72%

또한, 검출 신뢰도를 높이기 위하여 순시치 및 전폭스펙트럼을 각각 이용한 신경회로망을 AND로 결합하여 검출 성능을 평가해본 결과 연속해서 3 cycle 이상을 동시에 고장으로 판단한 경우가 16 / 25 (64%)이었으며, 동시에 고장으로 고장으로 판단한 경우는 88 / 125 (70.4%)이었다.

5. 결론

본 연구에서는 종래의 방법으로는 쉽게 검출하기 어려운 문제인 고장High 고장 검출에 학습능력을 가진 신경회로망을 고장High 고장 검출법으로써 사용하였다.

이때 사용한 두 가지 신경회로망 모델중 CPN이 수렴속도면에서나 신뢰도 면에서 다소 나은 면을 보여주었다. 그리고 4고조파까지의 전폭스펙트럼을 이용한 경우가 검출 성능이 가장 우수하다는 것을 알 수 있었다.

앞으로는 좀 더 다양한 데이터를 이용하여 시뮬레이션 해볼 필요가 있으며 신경회로망에 의한 고장High 고장 검출 방법은 많은 장점을 가질 것으로 기대된다.

6. 참고 문헌

- [1] Sonja Ebron, David L. Lubkeman, and Mark White, "A Neural Network Approach to the Detection of Incipient Faults on Power Distribution Feeders", IEEE Trans. on Power Delivery, Vol. 5, No. 2, pp. 905 - 914, April, 1990
- [2] A. F. Sultan, G. W. Swift, and D.J.Fedirchuk, "Detection of High Impedance Arcing Faults Using A Multi-layer Perceptron", IEEE Trans. on Power Delivery, Vol. 7, No. 4 pp. 1871 - 1877, Oct., 1992
- [3] Wook Hyun Kwon, Gi Won Lee, Young Mun Park, Man Chul Yoon, and Myeong Ho Yoo, "High Impedance Fault Detection Utilizing Incremental Variance of Normalized Even Order Harmonic Power", IEEE Trans. on Power Delivery, Vol. 6, No. 2, pp. 557 - 564, April, 1991
- [4] "다중진자 배전선로 보호계전방식 개선에 관한 연구", 한국전력공사 기술연구원, 1987
- [5] "Detection of High Impedance Faults", EPRI Report EL-2413, prepared by Power Technologies, Inc., June, 1982
- [6] "High Impedance Fault Detection Using Third Harmonic Current", EPRI Report EL-2430, prepared by Huges Aircraft Co., June, 1982
- [7] J. Carr, "Detection of High Impedance Faults on Multi-Grounded Primary Distribution System", IEEE Trans. on Power Apparatus and Systems, Vol. 100, No. 4, pp. 2008 - 2016, April, 1981
- [8] B. M Aucoin and B.D. Russell, "Detection of Distribution High Impedance Faults Using Burst Noise Signals Near 60Hz", IEEE Trans. on Power Delivery, Vol. 2, No. 2, pp 342 - 348, April, 1987
- [9] B. M Aucoin and B.D. Russell, "Distribution High Impedance Fault Detection Utilizing High Frequency Current Components", IEEE Trans. on Power Apparatus and Systems, Vol. 101, No. 6, pp. 1596 - 1606, June, 1982
- [10] "Detection of Downed Conductors on Utility Distribution Systems", IEEE Tutorial course.
- [11] J. L. McClelland, D. E. Rumelhart and the PDP Research group, "Parallel Distributed Processing : Explorations in the Microstructure of Cognition", Vol. 1, Bradford book, The MIT Press, 1986
- [12] James A. Freeman and David M. Skapura, "Neural Networks : Algorithms, Applications, and Programming Techniques", Addison - Wesley Publishing Company Inc., 1991