

자율 학습 신경회로망을 이용한 고장상 선택 알고리즘

이재욱, 최창열, 장병태, 이명희*, 노장현*
 한전 전력연구원, 한국 전력 공사*

The Discrimination of Fault Type by Unsupervised Neural Network

Jae-Wook Lee, Chang-Yeol Choi, Byung-Tae Jang, Myung-Hee Lee*, Jang-Hyun No*
 KEPRI, KEPCO*

Abstract - The direction and the type of a fault on a transmission line need to be identified rapidly and correctly. The work described in this paper addresses the problem encountered by a conventional algorithm in a fault type classification in double circuit line ; this arises due to a mutual coupling and CT saturation under the fault condition .

We present an approach to identify fault type with novel neural network on double circuit transmission line. The neural network based on combined unsupervised training method provides the ability classify the fault type by different patterns of the associated voltages and currents.

건전상 전류가 정상상태보다 증가하게 되는 현상이 발생하며 과전류 계전 요소와 같은 알고리즘에서는 이러한 현상으로 인해 부정확한 계전기 동작이 발생할 소지가 있다.[2]




그림 1 건전상 및 고장상 전류

1. 서 론

계통의 안정도를 유지시키기 위해 무엇보다 중요시 되는 것은 고장 구간을 건전 구간으로부터 가능한 한 빨리 분리시키는 것이다. 고장 구간을 건전 구간으로부터 분리시키기 위한 보호시스템에서 계통상의 큰 전류는 변류기(Current Transformer)를 통해 보호 계전기가 사용할 수 있는 작은 전류로 변환되며 이 변환된 값이 입력값으로 사용되게 된다. 그러나 이러한 변류기는 철심으로 된 자기회로의 여자 특성이 비선형이기 때문에 과도한 고장 전류가 입력으로 가해지거나, 직류분 전류가 포함된 경우 및 철심 내부에 잔류 자속이 있을 경우 입력 전류가 변류비에 맞게 변환되어 2차 전류로 출력되지 못하고 왜곡된 전류 파형을 출력하므로 이를 입력으로 사용하는 보호계전기에서 오차를 발생시키고 심한 경우 오동작의 원인이 된다. 이러한 포화 현상을 해결하기 위해 정격전류의 수십 배에 달하는 고장전류에도 포화되지 않을 정도의 단면적이 큰 변류기를 사용하는 것이 현실이나 그리하여도 과도 직류분 전류나 잔류자속이 큰 경우에는 해결되지 않는다.[1]

본 논문에서는 전압과 전류의 순시치 샘플 데이터를 사용하고 자율 학습을 이용하는 신경회로망을 구성하여 계통내의 다양한 고장에서 빠르고 정확하게 고장상을 판별하는 알고리즘을 제안하였다. 그리고 CT 포화로 인해 왜곡된 계전기 입력 값을 받는 경우 또한 고려하여 알고리즘을 구성하였으며 이를 여러 가지 고장 패턴을 모의하여 그 효용성을 검증하였다.

2. SOM을 이용한 고장상 선택 알고리즘

2.1 고장 발생시의 계통 변화

계통에 고장이 발생하면 각 상의 전압과 전류는 고장의 종류에 따라 특징적으로 변화하며 이러한 특징에 따라 보호 계전요소는 동작하게 된다. 그러나 대용량 송전을 위해 병렬 송전 선로를 사용하는 현재의 계통에서는 두 선로간의 영상 상호 임피던스로 인해 그림 1과 같이

또한 보호 계전 요소의 입력부인 변류기의 규격은 1차 전류가 대칭분 전류, 즉 정상 상태에서의 특성을 규정한 것으로 실제계통에서는 고장이 발생 하였을 경우 나타나는 직류분에 의해 비대칭 전류가 흐르는 경우가 많으며 이때 변류기 2차측은 이 비대칭 전류에 의해 그림 2와 같이 과도 특성을 갖게 되어 계전기의 정상적인 동작 특성을 저하시키는 요소로 작용하게 된다.[3]

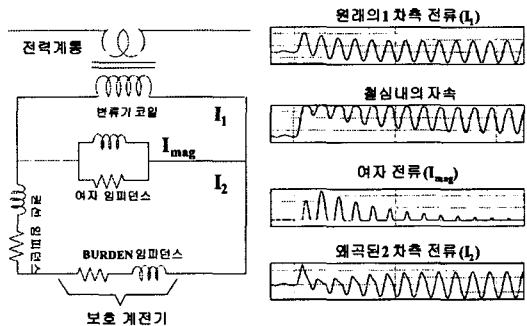


그림 2 변류기 포화 시 1차측/2차측 전류

2.2 SOM을 이용한 고장상 선택 알고리즘

SOM 신경회로망은 대표적인 자율학습 신경회로망으로 그림 3과 같이 입력 층과 코호넨 층의 이 단계 구조로 구성되어 있다. BP 알고리즘과 같은 지도 학습법을 사용하는 신경회로망과는 달리 SOM 알고리즘은 feed back 형태의 학습 과정이 없고 입력 뉴런들과 가장 가까운 코호넨층 뉴런이 활성화 되어 입력 뉴런들을 코호넨층에 그 유사성에 따라 분류 하는 구조를 갖게 된다. 일반적으로 격자형 구조를 갖는 코호넨층은 알고리즘의 목적에 따라 그 벡터 범위를 조정할 수 있고 이때 학습 시 활성화 되는 뉴런을 승자 뉴런이라 하며 알고리즘 상

에서 그 웨이트 값이 조정된다. 또한 승자 뉴런뿐만 아니라 preprocessor parameter로 설정해 주는 이웃 뉴런의 범위에 따라 승자 뉴런 주변의 뉴런들의 웨이트도 함께 변화되며 이러한 뉴런들을 이웃 뉴런이라 한다.

SOM 알고리즘에서 알고리즘의 반복에 따른 이웃 뉴런의 범위는 Mexican Hat의 형태를 갖고 학습 초기에 광범위 하게 적용되지만 학습이 진행 되면서 점차로 감소하게 되고 학습을 반복함으로써 주어진 입력 패턴들을 유사한 상관관계를 갖는 집단으로 분류한다[4][5].




그림 3 SOM 신경회로망

2.2.1 알고리즘의 구성

추출된 패턴 데이터로 SOM 회로망을 구성하게 되면 지락 고장과 단락 고장, 그리고 어떤 상에 고장이 발생하였는지는 각 상의 전압과 전류, 그리고 영상 전류의 패턴 특성이 확연히 구분될 수 있으므로 한 주기 안의 주어진 입력 패턴에 의해 정확한 고장상이 판별될 수 있다. 그러나 변류기가 포화되는 경우 고장 발생 전,후의 전류 값과 고장 발생 후 한주기 이후의 전류 값에 변화가 생기므로 단순히 고장이 발생하였는지만을 구분하는 것이 아니라 변류기 포화로 인해 왜곡된 입력이 주어진 것인지의 여부도 판별하는 알고리즘으로 구성해야만 한다.

제안한 알고리즘에서 변류기의 포화 여부는 전류 패턴에 의해 먼저 판별되고 이후 각 상의 고장 여부는 각각의 전압, 전류 값의 패턴에 의해 판별되며 지락 고장은 영상 전류의 패턴에 의해 판별되어 최종 출력 값을 생성시킨다.

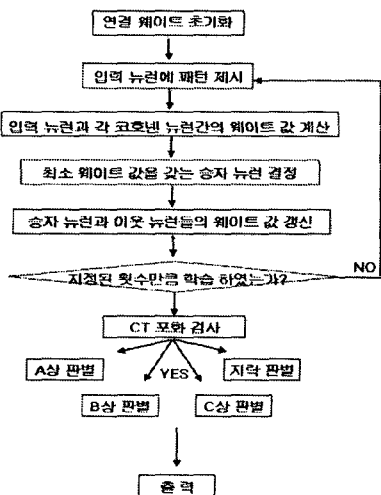


그림 4 Block Diagram

2.2.2 학습 데이터

본 논문에서는 각 고장에서 전류 및 전압의 순시치를 사용하였고 한 주기 당 24개의 샘플을 추출하고 24샘플

의 데이터를 입력으로 사용하여 Sliding Window를 구성하였다.

한 주기당 24개의 샘플로 구성된 Sliding Window는 학습의 진행 과정에서 순차적으로 첫 번째 값을 버리고 다음 샘플 값을 받아 학습에 사용한다. 그 결과로 고장이 발생하여 24개의 입력 값 중 정상 상태에 비해 바뀌어지는 몇몇 데이터들에 의해 정상 상태와 차별화 하여 코호넨층 상에 분리되는 형태를 갖게 된다.

SOM 알고리즘은 목표 값을 지정하여 출력 값을 그 목표 값에 근접시키기 위한 알고리즘이 아니라 주어진 입력 값들을 유사성에 따라 분류하는 구성으로 고장상 판별에 있어 입력데이터는 각 고장에서의 특징들을 명확히 나타내야 한다. 또한 일반적으로 변류기 포화가 고장 후 한주기 이후에 나타나기 때문에 변류기 포화 상태의 데이터를 학습시키기 위해서는 이를 고려한 학습 데이터를 추출해야만 한다.

본 논문에서 Sliding Window는 고장 전 두 주기와 고장 후 네 주기간의 데이터를 학습에 사용할 수 있도록 구성 되었고 따라서 고장 발생 전의 데이터, CT포화가 발생하기전의 고장 데이터, CT포화가 발생한 이후의 고장 데이터가 학습에 포함되었다.

표 1 SOM 학습 데이터

| 패턴 데이터 | 전류-4, 전압 3 (각 상 전압, 전류 및 영상전류) |
|-----------|-----------------------------------|
| 샘플링 주파수 | 24샘플/한 주기 (1440 Hz) |
| 입력 데이터 크기 | 24 샘플 |
| 추출 데이터 크기 | 고장 전 두 주기/ 고장 후 네 주기 |

2.2.3 신경 회로망의 전처리 파라미터

신경 회로망의 학습을 통해 구해진 웨이트 값은 실제 통에서 고장상을 판별하는데 직접 이용되는 값으로 무엇보다 중요하다. 따라서 다양한 고장 상황에서의 패턴 데이터를 이용한 학습이 필요하며 이때 결정된 웨이트 값은 신뢰성을 갖고 있어야만 한다.

본 논문에서 제안한 코호넨 층은 각 상이 정상상태, 불포화의 고장상태, 포화된 고장상태의 세 경우에 대해 입력 패턴을 분리 할 수 있도록 (0,0), (1,1)로 벡터 범위를 나누어 시험 하였으며, 이웃 뉴런의 범위는 2에서 12까지 변화시키며 테스트를 하였다. 또한 초기 학습률과 최종 학습률의 경우 각 입력 데이터가 코호넨 층에 분류되는 변별력을 결정하는 가장 중요한 인자임을 고려하여 초기 학습률의 경우 1.0에서 0.2까지, 최종 학습률의 경우 0.7에서 0.001까지로 변화시키며 학습의 반복을 수행하였다. 그리고 학습 반복 횟수는 3000회에서 12000회까지 변화시키며 학습하였다.

3. 시뮬레이션 및 고찰




그림 5 양단 2회선 모델 계통

본 논문에서 다양한 고장에서의 전압과 전류의 패턴 데이터를 구하기 위해 PSCAD/RTDS를 사용하여 그림 5와 같은 4모선, 60[Hz], 154[kV]급 양단 전원 병행 2회선 회로를 구성하였고 선로의 정상분 임피던스와 자기 임피던스, 그리고 상호 임피던스는 가공선로 ACSR 410mm²을 기준으로 하여 고장을 모의 하였다. 또한 CT는 B-4, C400 변압기용 고압부심 변류기를 대상으로 하여 계통을 구성하였다.




그림 6 RTDS 구성 계통

표 2 선로 데이터

| | 정상 | 영상 | |
|-----------|----------------|----------------|----------------|
| | | Self | Mutual |
| 전원 GA | 0.5389+j4.1562 | 1.8711+j10.096 | |
| 전원 GB | 0.5929+j4.9798 | 2.3597+j1.044 | |
| 선로 [Ω/km] | 0.0436+j0.3445 | 0.2384+j1.044 | 0.1948+j0.5633 |

표 3 모의 변류기 주요 변수 값

| 파라미터 | 크기 | 단위 |
|---------------------------|--------|-----------------|
| Cross Section Area | 5000 | mm ² |
| Path Length | 0.887 | mm |
| Primary Side Resistance | 0 | Ω |
| Secondary Side Resistance | 0.534 | Ω |
| Secondary Side Inductance | 0 | mH |
| Burden Series Resistance | 2.5 | Ω |
| Burden Series Inductance | 11.485 | mH |
| Turn Ratio | 1200/5 | |

학습에 사용하기 위한 고장 데이터는 선로 길이가 25[km]인 송전선에서 10가지 고장 유형의 고장 위치와 고장 저항을 변화 시키며 한 주기 당 24샘플로 각 상의 전압과 전류를 추출하였고 상호 임피던스 성분에 영향을 받는 건전 구간의 전압과 전류 값 역시 고려하여 입력 데이터를 구성하였다. RTDS 상에서 계통을 구성하여 고장을 모의한 결과 변류기 포화 현상은 고장 저항이 작거나 고장 지점이 계전기로부터 가까울수록 크게 발생하였고 반대의 경우 변류기는 포화되지 않고 변류비에 따라 이차측 전류를 출력하였다.

표 4 최종 학습 파라미터

| 호출번호 | (0.0) ~ (1.0) |
|----------|---------------|
| 이웃 뉴턴 범위 | 8 |
| 초기 학습률 | 0.65 |
| 최종 학습률 | 0.01 |
| 총 학습 데이터 | 103680 |

본 논문에서 제안한 고장상 선택 알고리즘의 타당성과 정확도를 검증하기 위해 10가지 종류의 고장에 대해 고장 위치와 고장 저항을 변화시켜 고장을 모의하였으며 고장 구간과 건전구간의 전압과 전류 값의 데이터를 추출한 후 제안한 알고리즘을 이용하여 정상 상태와 고장 종류, 그리고 변류기 포화 여부에 따라 패턴을 분리시켰다.

표 4는 제안한 알고리즘을 사용하여 여러번의 테스트를 거친 후 최종적으로 얻어진 학습 파라미터를 나타낸

다.

그림 7과 표 5는 학습 파라미터의 조정을 통해 학습된 SOM 알고리즘이 시험을 위해 주어진 입력 데이터를 코호넨 층에 다음과 같이 분류함을 보여준다.

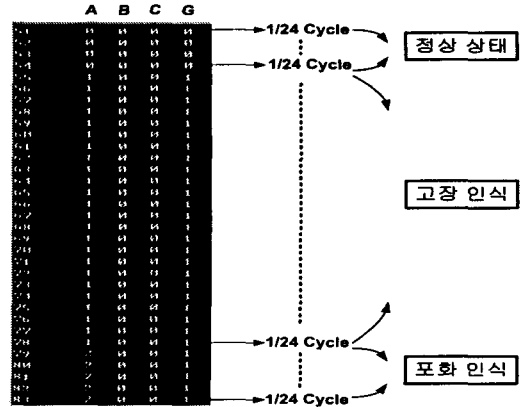


그림 7 A상 지락 고장 시 제안한 알고리즘 동작 결과

표 5 고장에 따른 SOM 신경회로망의 출력 값

| CT 상태 | A상 | B상 | C상 | 지락 | 고장유형 |
|-------|----|----|----|----|------|
| 정상 상태 | 1 | 0 | 0 | 1 | AG |
| | 0 | 1 | 1 | 0 | BC |
| | 1 | 1 | 0 | 1 | ABG |
| | 1 | 1 | 1 | 0 | ABC |
| | 0 | 0 | 0 | 0 | 정상상태 |
| 포화 상태 | 0 | 2 | 0 | 1 | BG |
| | 2 | 0 | 2 | 0 | CA |
| | 0 | 2 | 2 | 1 | BCG |
| | 2 | 2 | 2 | 0 | ABC |

계전기 동작의 신뢰성을 위해 고장상 선택 알고리즘은 고장 발생 후 한 주기 안에 고장을 인식할 수 있어야만 한다. 반면에 변류기 포화의 경우 고장 발생 후 한 주기 이후에 나타나므로 테스트 데이터는 고장 발생 전 두 주기 간의 데이터와 고장 발생 후 네 주기 간의 데이터를 추출하여 실험하였고 그 결과 각 고장유형(AG, BC, ABG)에 대해 모두 한 주기 안에 고장을 판별 하였으며 변류기 포화 여부 역시 정확하게 판별해 내었다.

그림 8은 제안한 알고리즘의 동작 속도를 나타낸 것으로 기존의 알고리즘과 제안한 알고리즘은 모두 고장상을 정확히 판별할 수 있었다. 고장 거리 150%의 A상 지락 고장과 AB상 단락 고장의 경우 기존의 알고리즘은 고장 발생 시점에서 0.69ms(1/24 Cycle) 후에 고장상을 판별 하였고 제안한 알고리즘의 경우 3.47ms(5/24 Cycle)에 고장상을 판별하였다. 또한 계전기 설치점에서 먼 곳의 고장의 경우 동작하는 시간을 측정하기 위해 250% AB상 지락 고장을 모의한 경우 기존의 알고리즘이 18.06ms (26/24 Cycle)에서 동작한데 반하여 제안한 알고리즘은 4.86ms(7/24 Cycle)에서 동작하였다.

그림 9는 고장 발생 후 한주기 이후에 CT 포화가 발생한 경우 제안한 알고리즘이 동작하는 시간을 나타낸 것으로 고장 거리 40%의 A상 지락 고장이 발생하게 되면 고장 발생 시점에서 3.47ms(5/24 Cycle) 후에 고장상을 판별하고 포화가 나타 난 후 11.1ms(16/24 Cycle) 후에 CT 포화 상태를 판별해 낼 수 있다.

제안한 알고리즘의 동작 속도는 몇 가지 조건에서 기존의 알고리즘에 비해 늦지만 Full Cycle Recursive DFT Filter를 사용하는 거리 계전 요소와 과전류 계전 요소등과 같은 알고리즘은 정확한 고장 신호를 얻기 위하여 한 주기 동안의 샘플 데이터를 필요로 하므로 그

이전의 신호는 신뢰성이 떨어진다고 할 수 있다. 따라서 이들 계전 요소들의 동작 속도는 보통 고장 발생 후 16.67ms(1Cycle) 이후이며 이점을 감안한다면 제안한 알고리즘이 이들 계전 요소와 보호 협조하여 동작하는 데는 문제가 없다.

for Double-circuit lines Based on a Combined Unsupervised/Supervised Neural Network”, IEEE Transaction on Power Delivery, Vol.14, 1250-1256, 1999
 [5] Kohonen Teuvo, "Self-organizing maps", Springer, 1997

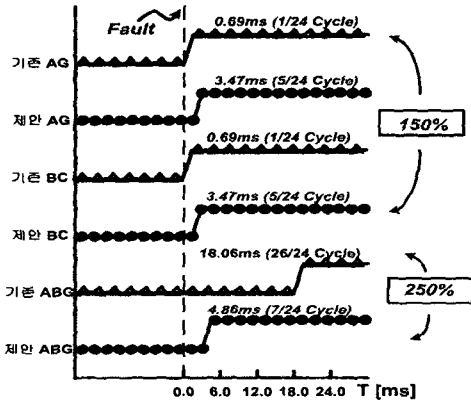


그림 8 기존 알고리즘과 제안한 알고리즘의 동작 속도




그림 9 CT 포화시 제안한 알고리즘의 동작 속도

4. 결 론

본 논문에서는 고장 발생시 나타나는 전압과 전류의 특징적 변화에 의해 정확하게 고장상을 판별하고 계전기 동작에 악영향을 미치는 CT 포화 상태에서 계전기 오부 동작을 감소시키기 위해 신경 회로망을 이용한 고장 상 선택 알고리즘을 제안하였다.

제안된 알고리즘은 전압과 전류의 순시치를 이용함으로써 디지털 필터링에 필요한 시간을 단축 하였으며 SOM 신경회로망의 구조적 특성을 활용하여 전압과 전류의 순시 패턴에 의해 고장상을 판별함으로써 계전기 입력값이 왜곡되는 경우에 대해서도 학습을 통한 패턴 분석으로 정확한 동작이 가능하였다.

그러나 일반적인 고장상 판별의 경우와 달리 고장 전후의 수 주기 동안의 학습 데이터가 필요하여 방대한 데이터를 필요로 하고 그에 따른 학습 시간 지연이 불가피하다는 단점을 갖고 있다.

향후 신경회로망을 이용한 알고리즘이 실제통에 적용되기 위해서는 계전기 동작에 악영향을 미치는 여러 요소들을 고려한 보다 폭넓은 학습 데이터를 이용한 연구가 필요하며 학습 속도를 향상시키기 위한 연구가 필요하다고 사료된다.

[참 고 문 헌]

- [1] Y.C. Kang, J.K. Park, S.H. Kang, A.T. Johns, and R.K. Aggarwal, "An Algorithm for Compensating the Secondary Current of Current Transformers", IEEE Trans. Power Delivery, Vol.12, 116-124, Jan. 1997
- [2] V.S. Vankayala and N.D. Rao, "Artificial NNS and Their Application to Power Systems a bibliographical survey", International Journal of Electrical Power System Research, Vol.28, 67-79, 1993
- [3] 장병태 외. "지능형 보호계전기 연구개발(I)", 1998
- [4] R.K. Aggarwal, Q.Y.Xuan, R.W.Dunn, A.T.Johns, A.Bennett, "A Novel Fault Classification Technique