(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(51) 。Int. Cl. [7]
H02H 3/00

(45) 공고일자 2003년01월09일
(11) 등록번호 10-0367155
(24) 등록일자 2002년12월23일

(21) 출원번호 10-2001-0008512
(22) 출원일자 2001년02월20일

(65) 공개번호 특2002-0068216
(43) 공개일자 2002년08월27일

(73) 특허권자 학교법인 성균관대학
서울 종로구 명륜동3가 53

(72) 발명자 김철환
경기도성남시분당구정자동112한솔마을506호1024호
조성빈
제주도제주시용담1동2826-4번지

(74) 대리인 윤여표
이희명
이상찬
박기환
신양환

심사관 : 이승한

(54) 신경회로망을 이용한 송전선로의 재폐로방법

요약

전력시스템의 안정도를 향상시키기 위해 임의의 비선형적인 입력데이터에 대응한 신경회로망의 패턴인식을 통해 고장종류의 정확한 판단과 재폐로 수행여부를 결정하는 신경회로망을 이용한 송전선로의 재폐로방법에 대해 개시한다.

본 발명의 신경회로망을 이용한 송전선로의 재폐로방법은, 일시고장 또는 영구고장의 특징을 갖는 사고를 발생시키는 제1 단계; 상기 신호에서 제n 고조파 이상의 성분을 제거시키기 위해 저역통과필터를 이용하여 필터링하는 제2 단계; 상기 필터링된 아날로그 신호를 디지털신호로 변환시키는 제3 단계; 주파수 분석을 수행하되 일시고장과 영구고장을 구분지을 수 있는 특징을 고조파분석을 통해 추출하는 제4 단계; 상기 추출되어진 데이터를 입력층과 출력층을 포함하는 다층으로 형성되어 고장종류에 대한 패턴인식을 학습하는 신경회로망에 적용하는 제5 단계; 및 상기 신경회로망의 출력결과를 분석하고, 단상 자동재폐로의 수행여부를 결정하는 제6 단계;를 포함하여 이루어진 것을 특징으로 한다.

본 발명에 따르면, 일시적으로 발생하는 아크현상을 신호처리기법을 이용하여 일시고장과 영구고장을 우선적으로 검출한 후, 일시고장에 대해서는 2차 아크의 소멸시간과 그 이후의 주파수 특성을 이용함으로써 무전압시간이 끝나는 시점과 재폐로를 수행하는 시점을 쉽게 알 수 있다. 또한, 이러한 방법으로 검출되어진 특징을 신경회로망을 이용하여 2비트(bit)의 디지털신호로 출력해 줌으로써 실제 적용시에 자동적으로 재폐로가 수행될 수 있다. 고장의 특징추출에 있어서도 시간과 주파수 그리고 크기의 3차원 영역을 통해서 분석되는 웨이브렛변환과 STFT 분석을 이용함으로써 신속하고 정확한 고장검출과 일시고장이 끝나는 정확한 시점을 알 수 있다. 특히, 765kV가 건설되고 국토가 좁은 우리나라의 실정에서 앞으로 전력공급량이 크게 증가함을 예측할 때 대용량전력을 2회선으로 공급하는 추세에 맞춰 3상 재폐로와 다상 재폐로 방식이 적용되어져야 하며, 이로부터 3상 재폐로와 다상 재폐로 방식연구에 크게 기여할 것이라 여겨진다.

대표도

도 18

색인어

신경회로망, 송전선로, 재폐로

명세서

도면의 간단한 설명

도 1은 본 발명에서 이용하는 신경회로망의 동작과정을 나타낸 개념도,

도 2는 오차 역전파 알고리즘의 모델을 나타낸 도면,

도 3a 및 도 3b은 1차아크와 2차아크의 전압-전류 특성을 나타낸 그래프,

도 4는 본 발명의 일실시예에 의한 신경회로망을 이용한 단상 자동재폐로 과정을 나타낸 흐름도,

도 5는 일시고장일 경우의 전압파형을 나타낸 그래프,

도 6은 영구고장일 경우의 전압파형을 나타낸 그래프,

도 7 및 도 8은 일시고장 및 영구고장 각각에 대해 저역통과필터를 통과한 전압파형을 나타낸 도면,

도 9는 웨이브렛 분석의 개념을 개략적으로 나타낸 도면,

도 10은 웨이브렛 필터뱅크에 대한 구성도를 나타낸 도면,

도 11 및 도 12는 일시고장 및 영구고장시 웨이브렛 분석을 통해 얻어진 그래프들,

도 13은 STFT 분석의 개념을 개략적으로 나타낸 도면,

도 14 및 도 15는 일시고장시 STFT 분석결과를 나타낸 그래프,

도 16 및 도 17은 영구고장시 STFT 분석결과를 나타낸 그래프,

도 18은 본 발명의 일실시예에 의한 고장판별을 위해 구성한 신경회로망을 개략적으로 나타낸 도면,

도 19는 20㎞지점에서 a상 일시고장시 신경회로망의 출력을 나타낸 3차원 그래프,

도 20은 20㎞지점에서 a상 1선지락 고장시 신경회로망의 출력을 나타낸 3차원 그래프,

도 21은 60㎞지점에서 b상 일시고장시 신경회로망의 출력을 나타낸 3차원 그래프,

도 22는 60㎞지점에서 ab상 2선지락 고장시 신경회로망의 출력을 나타낸 3차원 그래프이다.

발명의 상세한 설명

발명의 목적

발명이 속하는 기술 및 그 분야의 종래기술

본 발명은 송전선로의 재폐로방법에 관한 것으로, 특히 전력시스템의 안정도를 향상시키기 위해 임의의 비선형적인 입력데이터에 대응한 신경회로망의 패턴인식을 통해 고장종류의 정확한 판단과 재폐로 수행여부를 결정하는 신경회로망을 이용한 송전선로의 재폐로방법에 관한 것이다.

국·내외의 학술지 및 문헌에 의하면, 송전선로의 뇌서지에 의한 1회선 아크접지사고(일시적 1회선 아크사고)의 비율이 대기 중에서 발생하는 송전선로의 고장의 85%를 넘고, 이 중 일시적 1선지락 아크사고의 비율은 70%를 넘는 것으로 집계되고 있다. 이러한 일시적 1선지락 아크사고가 발생한 경우에 대책으로 단상 자동재폐로 방식을 이용하고 있다. 현재 사용되고 있는 단상 자동재폐로 방식은 사고가 발생하면 차단기로 사고를 차단하고 고장시간(Dead Time)이 지나면 자동적으로 재폐로를 수행하고 있다.

전력계통에서 상기한 고장시간(Dead Time)에 의존하는 기존의 단상 자동재폐로 방식은 일시고장시에 고장이 완전히 제거되지 않은 상태에서 재폐로를 수행하거나 영구고장임에도 불구하고 재폐로를 수행함으로써 전력시스템의 안정도와 전력설비에 막대한 손실을 줄 수 있는 가능성을 내포하고 있다.

이와 같이, 기존의 단상 자동재폐로 방식은 일시고장시에 고장이 완전히 제거되지 않은 상태에서 재폐로를 하거나 영구고장임에도 불구하고 재폐로를 수행함으로써 전력시스템의 안정도와 전력설비에 막대한 손실을 줄 수 있는 가능성을 내포하고 있었다. 따라서, 단상 자동재폐로를 효율적으로 수행할 수 있는 방법이 절실히 요구되는 과제를 안고 있었다.

발명이 이루고자 하는 기술적 과제

따라서, 본 발명의 목적은 전력시스템의 안정도를 향상시키기 위해 임의의 비선형적인 입력데이터에 대응한 신경회로망의 패턴인식을 통해 고장종류의 정확한 판단과 재폐로 수행여부를 결정하는 신경회로망을 이용한 송전선로의 재폐로방법을 제공하는데 있다.

여러 가지 학습패턴의 특성을 신경이라는 뉴런소자의 기억을 통해서 저장하며, 신경망이라는 구성을 통하여 패턴의 분류 및 데이터의 저장, 병렬처리에 의한 기억의 백업능력으로 인하여 한 번 학습이 되고 나면, 그와 비슷한 데이터를 같은 패턴으로 인식하는 능력이 있으며, 병렬적 학습원리에 의해서 기존의 수치 해석적인 인공지능의 직렬적 연산 시스템이 가지는 계산의 순차성을 극복하여 지식시스템의 구축으로 인한 패턴의 연관기억능력과 고도의 학습능력을 가지고 있으며, 불완전하고 예측 불가능한 비선형적인 입력데이터에 대해서도 우수한 작용을 할 뿐 아니라, 넓은 범위에서 패턴분류기로서 작용을 할 수 있는 신경회로망의 특징을 이용하여 효율적인 단상 자동재폐로 방법을 제공하는데 있다.

또한, 기존의 고장시간(dead time) 방식에 의해 전력계통에 야기되는 설비위험 및 안정도 위협을 동시에 방지할 수 있도록 무전압시간을 자동적으로 탐지하고 기존의 아날로그식 방식에서 벗어나 디지털 신호의 동작에 의해 자동적으로 재폐로를 수행할 수 있는 단상 자동재폐로 방법을 제시하고자 한다.

발명의 구성 및 작용

상기한 본 발명의 목적을 달성하기 위한 본 발명의 신경회로망을 이용한 송전선로의 재폐로방법은, 일시고장 또는 영구고장의 특징을 갖는 사고를 발생시키는 제1 단계; 상기 신호에서 제n 고조파 이상의 성분을 제거시키기 위해 저역통과필터를 이용하여 필터링하는 제2 단계; 상기 필터링된 아날로그 신호를 디지털신호로 변환시키는 제3 단계; 주파수 분석을 수행하되 일시고장과 영구고장을 구분지을 수 있는 특징을 기수 및 우수 고조파분석을 통해 추출하는 제4 단계; 상기 추출되어진 데이터를 입력층과 출력층을 포함하는 다층으로 형성되어 고장종류에 대한 패턴인식을 학습하는 신경회로망에 적용하는 제5 단계; 및 상기 신경회로망의 출력결과를 분석하고, 단상 자동재폐로의 수행여부를 결정하는 제6 단계;를 포함하여 이루어진 것을 특징으로 한다.

이 때, 상기 제n 고조파는 10조파인 것이 바람직하다. 또한, 상기 주파수 분석방법으로 웨이브렛변환 및 단시간 퓨리에 변환에서 선택된 어느 하나의 방법을 이용하는 것이 더욱 바람직하다. 이 때, 상기 웨이브렛변환을 이용할 경우에, 저역(approximation) 필터를 통해서 얻어지는 신호는 또 다른 두 개의 저역 필터(cA1)와 고역 필터(cD1)로 분해되고, 상기 저역 필터(cA1)를 통과한 신호는 또 다시 두 개의 저역 필터(cA2)와 고역 필터(cD2)로 분해되는 연속적인 과정에 의해 고역 필터(cDn)와 저역 필터(cAn)에 입력될 데이터를 매 2번째 샘플점마다 통과시키는 다운 샘플링기법을 이용하는 것이 좋다.

한편, 상기 제5 단계는, a. 신경망의 연결 가중치를 적당한 값으로 초기화하는 단계; b. 학습시킬 입력 패턴을 선정하는 단계; c. 신경망의 입력층 인공 신경세포에 입력 패턴을 제시하는 단계; d. 신경망의 인공 신경세포들을 층별로 동작시켜 출력 패턴을 출력시키는 단계; e. 신경망의 출력층 인공 신경세포에 목적 패턴을 선택적으로 제시하는 단계; f. 선택된 학습 규칙에 따라 연결 가중치를 조절하는 단계; g. 모든 입력 패턴에 대해 b f 과정을 반복하는 단계; 및 h. g 단계를 신경망이 완전히 학습될 때까지 반복하는 단계;를 포함하여 이루어진다.

그리고, 상기 신경회로망의 학습시에, 모멘텀, 바이어스, 델타-바-델타, 및 전역적인 학습방법에서 선택된 어느 하나의 방법을 이용하여 학습속도를 증대시킨다.

또한, 상기 신경회로망의 오차를 최소화하기 위해, 출력층의 에러가 연결층으로 역전파되어 각각의 신경망에 연결된 가중치값을 갱신하는 오차 역전파(Error Backpropagation)방법을 이용하는 것이 바람직하다.

여기서, 상기 신경회로망은 적어도 3개층으로 이루어지며, 입력층, 히든층, 출력층을 포함하는 이루어진다. 이 때, 상기 히든층은 6 내지 10개 범위의 뉴런으로 이루어진 것이 바람직하다.

이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시예에 대해 설명한다.

먼저, 본 발명에서 이용될 신경회로망에 대해 살펴보자.

도 1은 본 발명에서 이용하는 신경회로망의 동작과정을 나타낸 개념도이다. 도 1을 참조하면, 신경회로망을 구성하는 인공신경세포의 정보처리는 신경세포의 전기적 펄스나 화학물질을 모두 수치로 바꾼 것이다. 먼저, 신경망의 학습을 위해 입력패턴(x(n))과 그 입력패턴(x(n))에 대한 신경망의 출력 형태를 지시하는 목적패턴(t(m))의 쌍을 사용한다. 감독 학습방법을 사용하는 경우 신경망의 동작결과 출력패턴(y(m))이 얻어지면, 이것을 신경망에 주어진 입력패턴(x(n))과 쌍을 이루는 목적패턴(t(m))과 비교하여 출력패턴(y(m))이 목적패턴(t(m))과 같아지도록 연결 가중치를 수정한다.

이와 같은 과정이 반복되면 입력패턴(x(n))에 의한 신경망의 출력패턴(y(m))은 그 입력패턴(x(n))과 쌍을 이루는 목적패턴(t(m))과 같아지게 된다. 결국, 학습된 신경망은 주어진 입력패턴(x(n))과 쌍을 이루는 목적패턴(t(m))을 출력하도록 학습하는 것이며, 이것은 신경망이 입력패턴(x(n))과 목적패턴(t(m))을 서로 연관시켜 주는 패턴 연관기(Pattern Associator)의 기능을 수행하게 됨을 의미한다. 인공신경세포의 동작 과정은 다음과 같이 요약할 수 있다.

① 신경망의 연결 가중치를 적당한 값으로 초기화한다.

② 학습시킬 입력 패턴을 선정한다.

③ 신경망의 입력층 인공 신경세포에 입력 패턴을 제시한다.

④ 신경망의 인공 신경세포들을 층별로 동작시켜 출력 패턴을 출력시킨다.

⑤ 신경망의 출력층 인공 신경세포에 목적 패턴을 제시한다. (감독 학습의 경우)

⑥ 선택된 학습 규칙에 따라 연결 가중치를 조절한다.

⑦ 모든 입력 패턴에 대해 ② ⑥과정을 반복한다.

⑧ ⑦과정을 신경망이 완전히 학습될 때까지 반복한다.

한편, 신경회로망의 오차를 최소화하기 위해 이미 학습규칙으로 잘 알려진 오차 역전파 알고리즘(Error Backpropagation Algorithm)을 이용한다.

도 2는 오차 역전파 알고리즘의 모델을 나타낸 도면이다. 도 2에 도시된 바와 같이, 이 오차 역전파 알고리즘은 다층 전방향 퍼셉트론으로 구성되어 원하는 출력과 실제출력 사이의 최소자승 오차를 최적화하는 반복 알고리즘이다.

임의의 신경세포의 활성이 다른 신경세포의 잘못된 출력에 공헌을 하게 되면, 두 신경세포간의 연결 가중치를 그것에 비례하여 조절해 주어야 한다. 그리고 그러한 과정은 그 아래에 있는 신경세포들까지 계속된다. 이렇게 일반화된 델타 규칙을 상기한 오차 역전파 알고리즘(Error Backpropagation Algorithm)이라고 부른다. 이 오차 역전파 알고리즘은 도 2와 같이 학습시 신호의 흐름과는 역방향으로 재귀적인 계산을 실행하므로 역전파 기법이라고도 한다.

일반화된 델타규칙 알고리즘이 기존의 델타규칙 알고리즘과 다른 점은 출력층의 에러가 아래층으로 전파되어 각각 연결된 가중치값을 갱신한다는 것이다.

출력층에서 목적패턴과 출력 신경세포의 활성값을 뺀 값을 출력 신경세포의 오차라 할 때 일반화된 델타규칙에서는 이 오차를 한번 더 가공하여 각각의 출력층 신경세포에 대해 델타라는 것을 구하는 것이다.

신경세포의 오차로부터 델타를 구하는 식은 다음과 같다.

$$\delta_j = f'(net_j)e_j = a_j(1-a_j)e_j \qquad (1)$$

$$e_j = t_j - a_j \leftarrow \text{- 출력층 신경세포의 경우}$$

$$f'(net_j) = \frac{\partial f(net_j)}{\partial net_j} = a_j(1-a_j) \qquad (2)$$

여기서,

δ_j : 출력층 신경세포 j의 델타,

$f'(net_j)$: 출력층 신경세포 j의 활성 함수의 미분값,

e_j: 출력층 신경세포 j의 오차,

t_j: 출력층 신경세포 j에 대응하는 목적 패턴의 성분,

a_j: 출력층 신경세포 j의 활성값

을 각각 나타낸다.

상기 델타가 구해지면, 이 델타는 위에서 아래로 이것과 연결된 연결 가중치가 곱해져 아래층 신경세포로 전달되고 그렇게 전달된 델타들은 아래층 신경세포에서 합쳐지게 된다. 이렇게 합쳐진 값이 바로 히든층 해당 신경세포의 오차가 된다. 은닉층 신경세포들의 오차가 구해지면, 다시 히든층 신경세포의 델타를 식(3)과 같이 구할 수 있다.

$$\delta_j = f'(net_j)e_j = a_j(1-a_j)e \qquad (3)$$

$$e_i = \sum_j w_{ij}\delta_j \leftarrow \text{은닉층 신경세포의 경우}$$

$$f'(net_j) = \frac{\partial f(net_j)}{\partial net_j} = a_j(1-a_j) \qquad (4)$$

여기서,

δ_j : 출력층 신경세포 j의 델타,

$f'(net_j)$: 출력층 신경세포 j의 활성 함수의 미분값,

e_i: 출력층 신경세포 j의 오차,

t_j: 출력층 신경세포 j에 대응하는 목적 패턴의 성분,

a_i: 출력층 신경세포 j의 활성값

을 각각 나타낸다.

이와 같은 형태로 역전파되어 나가는데, 이 작업은 입력층 바로 위층의 델타가 구해질 때까지 계속된다. 구해진 일반화된 델타규칙에 의해서 아래의 식(5)와 같은 형태로 연결 가중치를 구한다.

$$w(new)_{ij}=w(old)_{ij}+\alpha\delta_j a_i$$
$$\delta_j=a_j(1-a_j)e_j$$
$$e_j=\left(t_j-a_j \quad \leftarrow \text{출력층 신경세포의 경우}\right)$$
$$e_j=\left(\sum w_{jk}\delta_k \quad \leftarrow \text{은닉층 신경세포의 경우}\right) \qquad (5)$$

결국, 일반화된 델타규칙은 다음 식(6)과 같다.

$$w(new)_{ij}=w(old)_{ij}-\alpha\frac{\partial E_p}{\partial w_{ij}} \qquad (6)$$

이 때, 다층 신경망으로 구성된 학습 네트워크는 목표로 하는 값에 수렴하기 위해서 많은 반복횟수동안 학습을 반복하여야 한다. 그러나 구분하기 어려운 패턴을 갖는 신경망의 학습에서는 오차값이 지역 극소에 빠지거나 진동하는 상태가 될 때가 많기 때문에 여러 가지 방법으로 학습이 낮은 수렴값을 갖도록 할 수 있다. 이 경우에, 학습을 빨리 하면서 낮은 수렴값에 접근하는데 가장 큰 영향을 주는 것은 네트워크에 주어지는 초기 가중치 값이다. 그런데, 입력에 따라 일정한 값으로 조정되는 가중치들에 대한 초기값 설정을 사용자가 임의로 조정한다는 것은 불가능하므로, 학습이 진행되는 동안 안정된 가중치를 갖도록 학습하는 것이 바람직하다.

즉, 학습속도를 향상시키기 위해 제안된 여러 가지 방법중에 하나가 모멘텀이다. 이 모멘텀은 신경망의 연결가중치 조절식에 관성을 줌으로써 학습시간을 단축하고 학습성능의 향상을 위해 고안된 것이다. 모멘텀은 아래의 식(7)과 같이 계산된다.

$$\Delta w_{ij}(old)=w_{ij}(old)-w_{ij}(older) \qquad (7)$$

이 모멘텀을 추가하여서 일반화된 델타규칙에 의한 연결 가중치 조절식은 다음 식(8)과 같이 된다.

$$w(new)_{ij}=w(old)_{ij}+\alpha\delta_j a_j+\beta\Delta w_{ij}(old) \qquad (8)$$

여기서, β 는 모멘텀의 크기를 제어하기 위한 상수이며, 일반적으로 0.9에서 0.7정도의 값이 사용된다.

한편, 학습속도 향상을 위해 다른 방법의 하나인 바이어스(bias)는 입력층 신경세포를 제외한 모든 신경세포가 가지는 특성으로 이것은 신경망의 활성함수를 이동시키는 역할을 한다. 바이어스는 마치 언제나 출력이 1인 가상적인 신경세포를 달고 있는 연결 가중치처럼 취급된다. 때문에 상기 바이어스는 신경세포의 활성에 참여할 뿐만 아니라 다른 연결 가중치들과 마찬가지로 학습에 의해 조절된다.

$$bias(new)_j = bias(old)_j + \alpha\delta_j \cdot 1 + \beta \triangle bias_j(old) \quad (9)$$

바이어스도 자체에 달려 있는 가상적인 신경세포의 출력이 언제나 1이라는 점을 제외하고는 다른 연결 가중치와 동일하게 취급된다.

여기에, 학습속도 향상을 위해 또 다른 방법의 하나인 델타-바-델타(Delta-bar-delta) 알고리즘은 각각의 가중치가 자기 자신의 학습률을 갖도록 한 것이다. 그리고 학습률은 학습과정에 따른 시간에 따라 변화된다. 만일 가중치의 변화가 여러 시간 스텝에서 같은 방향으로 증가하거나 감소하면 가중치에 대한 학습률을 증가하거나 감소시킨다. 가중치의 변화는 가중치에 대한 오차의 부분적인 도함수가 여러 시간 스텝에서 같은 부호를 가지면 학습률을 증가시키고 가중치에 대한 오차의 부분적인 도함수가 여러 시간 스텝에서 다른 부호라면 학습률은 감소시킨다.

델타-바-델타(Delta-bar-delta) 규칙을 적용한 새로운 학습률은 다음 식(10)과 같다.

$$\alpha_{ji}(t+1) = \begin{cases} \alpha_{ji}(t) + k & \text{if } \bar{\delta}_{ji}(t-1)\,\delta_{ji}(t) > 0 \\ (1-\gamma)\alpha_{ji}(t) & \text{if } \bar{\delta}_{ji}(t-1)\,\delta_{ji}(t) < 0 \\ \alpha_{ji}(t) & \text{otherwise} \end{cases} \quad (10)$$

파라미터 k 와 γ 는 사용자에 의해서 정의된다.

마지막으로, 전역적인 학습방법은 가장 간단한 학습속도 향상을 꾀하는 법칙이다. 델타-바-델타(Delta bar delta) 규칙이 각각의 가중치에 대해 가중치를 조절하는 향상 방안이라면 전역적인 학습방법은 전체 오차를 판단하여 이전 오차와 현재의 오차값을 비교하여 학습률을 결정한다. 즉, 전체 오차가 감소한다면 학습률을 증가시키고, 현재 오차가 이전 오차보다 일정한 배수 이상이면 감소시킨다. 그리고 만약 오차가 줄어들지 않았다면 학습률을 그대로 유지시켜 주는 방법이다. 아래의 식(11)과 같은 수식으로 학습률이 결정된다.

$$\alpha = \begin{cases} a \cdot \alpha(old) & \text{if } E(new) < E(old) \\ b \cdot \alpha(old) & \text{if } E(new) \geq kE(old) \\ \alpha(old) & \text{otherwise} \end{cases} \quad (11)$$

여기서, a=1.05, b=0.7, k=1.04이다.

상기한 바와 같이 다양한 학습방법을 이용하여 본 발명에 적용시키며, 이하 고장의 종류를 검출하기 위한 과정에 대해 설명한다.

송전선로의 고장은 크게 일시고장과 영구고장으로 나눌 수 있다. 영구고장은 전선이 땅에 떨어져 발생하는 지락사고와, 전선 상호간의 단락에 의해서 발생하는 단락사고 등이 있다. 반면에, 일시고장은 주로 자연환경에 의해 발생하는 번개, 기후변화, 바람 등의 파라미터들에 의해서 송전선로가 일시적으로 절연이 파괴되어 아크를 동반한 고장전류가 접지선을 따라 흐르게 되는 사고 등이 있다. 이 때, 발생하는 아크가 재폐로 여부에 중요한 요소가 되는데 이는 도 3을 통해 설명한다.

도 3a 및 도 3b은 1차아크와 2차아크의 전압-전류 특성을 나타낸 그래프이다. 도 3a 및 도 3b를 참조하면, 2차아크는 1차아크와 마찬가지로 히스테리시스 특성을 보이지만 1차아크 전류에 비해서 2차아크 전류가 훨씬 작기 때문에 도 3b에서 보는 바와 같이 파형의 범위가 다르다. 재폐로 시간은 아크 소멸시간에 따라 정해지는데 이 아크 소멸시간은 1차아크전류와 그 계속시간, 2차 아크전류 및 아크 소멸 후의 회복전압 등에 따라 달라진다. 단상 재폐로시의 이온소멸시간은 선로길이와 회로구성에 따라 다르지만 60사이클(cycle) 이상이 된다.

한편, 재폐로 방식에는 단상 재폐로 방식, 3상 재폐로 방식, 다상 재폐로 방식 등이 있다. 상기 단상 재폐로 방식은 1선지락 아크사고시에 사고상만을 차단하고 나머지 2상으로 전력을 송전하면서 동기를 유지하고 있다가 사고점의 절연회복을 기다려 차단했던 1상을 재폐로하는 방식이다. 또한, 3상 재폐로 방식은 사고상이나 사고상 수에 관계없이 회선단위로 3상 동시차단하고, 그후에 3상을 동시에 재폐로 하는 방식이다. 그리고, 다상 재폐로 방식은 우리나라와 같이 국토가 좁은 경우에는 토지이용을 높이기 위하여 송전선은 모두가 동일철탑의 병행 2회선이기 때문에, 뇌격시에 철탑 전위상승이 생기면 2회선에 걸친 다중사고가 발생하는 확률이 높다. 따라서, 3상재폐로 방식을 적용하면 2회선차단이 되며 루트분단사고로 될 가능성이 많다.

도 4는 본 발명의 일실시예에 의한 신경회로망을 이용한 단상 자동재폐로 과정을 나타낸 흐름도이다. 도 4에 도시된 바와 같이, 전처리 과정으로 전력계통 과도해석 프로그램인 EMTP(Electro Magnetic Transients Program)에 의해 발생된 고장전압에 대해(S100) 저주파 통과 필터를 이용하여 디지털 보호계전기의 입력으로 적당한 10조파 미만의 전압을 얻은 후(S200) 디지털 신호처리를 위해 A/D변환을 수행하며(S300), 디지털 신호처리의 기법으로 웨이브렛(Wavelet) 분석과 단시간 퓨리에(STFT) 분석을 통해서 우수한 검출 결과를 얻을 수 있는 디지털 신호처리를 수행하고(S400), 본 발명의 알고리즘 수행을 위한 특징을 추출하여(S500) 신경회로망에 입력하여 패턴인식 과정을 진행하며(S600), 신경회로망의 출력결과에 따른 판별결과를 출력시킨다(S700). 본 발명의 연구수행 과정을 요약하면 다음과 같다.

① EMTP를 이용하여 일시고장 및 영구고장을 모의한다.

② 안티-앨리어싱 필터(Anti-aliasing filter)를 이용하여 10조파 이상의 성분을 제거한다.

③ 아날로그/디지털(A/D) 변환을 통해 아날로그 신호를 디지털 신호로 변환한다.

④ 주파수 분석 방법을 이용하여 일시고장과 영구고장을 검출할 수 있는 특징을 추출한다.

⑤ 추출되어진 데이터를 신경회로망에 적용한다.

⑥ 신경회로망의 출력결과를 분석하고, 단상 자동재폐로의 수행을 위한 알고리즘을 구현한다.

본 발명에서 사용하고자 하는 모델의 선로정수는 765kV 전력계통 모델의 선로정수이며, 이를 EMTP로 모델링하여 일시고장과 영구고장을 모의한다. 모델계통에서 모의하고자 하는 고장은 송전선로의 대기 중에서 가장 빈번하게 발생하는 1선지락 아크 고장을 비롯하여 1선지락 고장, 2선지락 고장, 선간단락 고장, 3상지락 고장 등이며, 기본 주파수는 60Hz, 64샘플링으로 전체 데이터 카드를 구성하기로 한다.

또한, 일시고장은 존스와 아가왈(Johns and Aggarwal)의 아크 모델을 근간으로 EMTP 모델들(MODELS)을 이용하여 1차 아크와 2차 아크의 모델링을 프로그래밍을 이용하여 모의되어지며, 영구고장은 EMTP를 이용하여 모의되어진다. 고장의 모의는 20㎞ 단위로 모의되어지며, 0.1[s]에 사고가 발생하며 0.3[s]에 차단기를 동작시킨다.

도 5는 일시고장일 경우의 전압파형을 나타낸 그래프이다. 도 5에 도시된 바와 같이, 상기한 조건에 의해 모의가 이루어질 경우, 일시고장인 경우에는 2차 아크의 소멸시간이 대체적으로 계전점에서 멀어질수록 약간 길어지며, 1차 아크전압의 크기는 고장거리가 길어짐에 따라 증가함을 알 수 있다. 또한, 2차 아크의 전압의 크기는 소멸시간에 비례하여 커짐을 알 수 있다. 그리고, 차단기가 동작한 이후 2차 아크가 발생하며 선로의 절연회복이 되는 시점에서 2차 아크는 소멸되며 디시오프셋(DC-offset)을 지닌 정현파 형태의 파형이 지속됨을 알 수 있다.

도 6은 영구고장일 경우의 전압파형을 나타낸 그래프이다. 도 6에 도시된 바와 같이, 영구고장시에는 차단기가 투입된 후 정현파 형태의 파형이 지속되며 일시고장와 대비적으로 2차 아크가 발생하지 않는다. 차단기의 스위칭 작용에 의한 고조파가 발생하며 디스오프(DC-OFF) 성분은 일시고장에 비해 매우 작음을 알 수 있다.

한편, 선로에 차단기가 투입될 때 스위칭 작용으로 인해 고조파 성분들이 발생하는데, 이 고조파 성분들은 일시고장과 영구고장의 검출에 장애 요소가 되며, 실제 디지털 보호계전기의 동작에도 에러를 발생시킬 수 있으므로 LPF(Low Pass Filter)를 이용하여 10조파 미만의 전압성분을 걸러낸다.

도 7 및 도 8은 일시고장 및 영구고장 각각에 대해 저역통과필터를 통과한 전압파형을 나타낸 도면이다. 도 7과 도 8에 도시된 바와 같이, 저역통과필터(LPF)는 1차에서 10차까지의 차수 중 필터링 능력과 속도면에서 가장 우수하다고 판정되는 2차를 선정하였으며, 스위칭시에 발생되는 고조파 성분을 제거함으로써 고장검출을 용이하게 만들었으며 신호처리를 위한 전처리 과정으로써 안티-앨리어싱(anti-aliasing) 필터로서 동작하고 있음을 알 수 있다.

이후, 이 신호에 대해 웨이브렛(Wavelet) 분석이 이루어지게 되는데, 이 웨이브렛 분석은 영역의 크기가 가변되는 윈도우 방법을 나타낸다. 웨이브렛 분석은 저주파수 정보를 더욱 정확하게 원하는 곳에서는 긴 시구간을 사용하고, 고주파수 정보를 원하는 곳에서는 짧은 시구간을 사용한다. 또한, 웨이브렛 분석은 시간-주파수 영역을 사용하지 않고 시간-스케일(scale) 영역을 사용한다. 따라서 시간과 윈도우의 크기를 적당히 선정하게 되면, 그 윈도우의 크기는 모든 주파수 영역에서 같아지는 단시간 퓨리에 변환(STFT)의 단점을 극복할 수 있다. 도 9는 상기한 웨이브렛 분석의 개념을 개략적으로 나타낸 도면이다.

또한, 오늘날의 디지털 시스템은 2의 멱승 형태에 기초한 시스템들이므로, 이러한 시스템에 적합한 분석을 하기 위해선 연속 웨이브렛 변환보다는 이산웨이브렛 변환이 더 효율적이고 실제 응용 면에서도 뛰어나다. 임의의 신호에 대해 정확한 웨이브렛 분석을 수행하려면 모든 스케일(scale)에서 웨이브렛 계수를 계산하는 것이 바람직하다. 그러나, 여러 단계의 웨이브렛 변환을 수행하게 되면 엄청나게 많은 양의 데이터가 산출되고 분석시간도 길어지는 문제점이 발생한다. 따라서, 2의 멱승 형태에 기초한 스케일(scale)과 쉬프트(shift)를 선택한다면 분석은 더욱 효율적으로 수행될 것이다. 이러한 분석은 이산 웨이브렛 변환을 통해서 구현된다.

이산 웨이브렛변환 $D_{a,b}$는 다음 수학식 (1)로 나타낼 수 있다.

$$D_{a,b}=\frac{1}{\sqrt{a_0^m}}\sum_k S[n]\cdot\Psi[\frac{k-na_0^m}{a_0^m}] \quad (1)$$

여기서, 스케일을 나타내는 변수는 a_0^m 이고, 쉬프트를 나타내는 변수는 na_0^m 이다.

일반적으로 신호에 대한 저주파 성분은 신호의 고유한 특성을 나타내고, 고주파 성분은 미세한 특성을 나타낸다. 웨이브렛변환에서는 이와 같은 특성을 어프록시메이션(approximation, 이하 approximation이라 함)과 디테일(detail, 이하 detail이라 함)로 각각 칭한다. approximation은 고차 스케일(a< < 1)을 통해서 얻어지며 신호의 저주파 성분을 나타내고, detail은 저차 스케일(a1)을 통해서 얻어지며 고주파 성분을 나타낸다. 따라서, 이산 웨이브렛의 수행과정은 고역 필터(D)와 저역 필터(A), 2가지 필터링의 개념으로 확장될 수 있다.

웨이브렛의 다분해능은 신호를 여러 형태의 고역 필터 성분들로 나누기 위해서 웨이브렛 필터 뱅크를 사용하는데, 이러한 웨이브렛 필터뱅크에 대한 구성도가 도 10에 잘 나타나 있다.

도 10을 참조하면, 웨이브렛 필터 뱅크는 다수의 고차 필터(D1, D2, D3,…,Dn)와 저차필터(A1, A2, A3,…,An)로 구성된 필터뱅크의 형태로 웨이브렛 변환을 반복하게 된다. 이 때, 각 필터링을 통해서 얻어지는 데이터의 양을 감소시켜 신속한 계산을 수행하기 위하여 다운-샘플링(Down-sampling)을 수행하며, 이에 따라 연산량이 적어지게 된다.

도 11 및 도 12는 일시고장 및 영구고장시 웨이브렛 분석을 통해 얻어진 그래프들이다.

한편, 고장신호 분석시에 가장 널리 알려진 퓨리에 분석을 이용할 수 있는데, 이 방법은 신호를 다양한 주파수의 정현파로 분해한다. 즉, 퓨리에 변환은 시간에 기초한 관점으로부터 주파수에 기초한 관점으로 신호를 변환시키는 방법이다. 많은 신호들에 대해서 신호의 주파수 성분은 중요하기 때문에 퓨리에 변환은 매우 유용하다. 하지만, 퓨리에 변환에는 퓨리에 분석이 주파수 영역으로 변환될 때, 시간 영역에 대한 정보가 손실된다는 중요한 단점이 있다. 신호의 퓨리에 변환시 특정한 사고가 언제 발생했는지 알 수 없다. 만약, 신호가 긴 시간 동안에 대해 크게 변화하지 않는다면 이러한 단점은 중요하지 않다. 그러나, 대개의 경우, 관심의 대상이 되는 신호는 변화가 크거나 일시적인 특성을 많이 포함하고 있다. 이러한 특성들은 신호의 중요한 부분이 될 수 있지만 퓨리에 분석은 그것들을 검출하는데 적합하지 못하다. 이러한 퓨리에 변환의 단점을 보완하기 위해서, 퓨리에 변환을 개선하게 되는데, 이 방법은 임의의 시점에서 신호의 작은 부분만을 분석하는 것으로 윈도윙(windowing) 개념을 사용한다. 단시간 퓨리에변환(이하, STFT라 함)라 불리우는 이 방법은 신호를 시간과 주파수의 2차원 함수로 분석한다. 도 13은 STFT 분석의 개념을 개략적으로 나타낸 도면이다. STFT는 신호를 시간과 주파수에 기초한 관점으로 절충한 표현이다. STFT는 임의의 시점에서 그리고 임의의 주파수에서 사고가 발생했는지에 대한 정보를 제공한다. 시간과 윈도우의 크기를 적당히 선정하게 되면, 그 윈도우의 크기는 모든 주파수 영역에서 같아진다는 단점이 있지만 시간이 변화됨에 따라 특정 주파수 성분들의 크기의 변화를 알고자 할 때 유용하다.

도 14 및 도 15는 일시고장시 STFT 분석결과를 나타낸 그래프이다. 도 14는 기수 고조파 성분을 나타내고 있으며, 도 15는 우수 고조파 성분을 나타내고 있다. 도 14 및 도 15를 참조하면, DC 성분인 경우에 2차 아크가 소멸된 시점에서 DC성분이 크게 나타남을 알 수 있다. 이는 아크가 소멸되기 전까지 선로의 커패시터 성분에 축적되었던 전압이 2차 아크의 자동 소호에 따라 전원으로 동작되어 축적된 전압 크기만큼 디시오프(DC-OFF)가 발생되었기 때문이다.

도 16 및 도 17은 영구고장시 STFT 분석결과를 나타낸 그래프이다. 도 16은 기수 고조파 성분을 나타내고 있으며, 도 17은 우수 고조파 성분을 나타내고 있다.

도 18은 본 발명의 일실시예에 의한 고장판별을 위해 구성한 신경회로망을 개략적으로 나타낸 도면이다. 도 18에 도시된 바와 같이, 본 발명의 일실시예에 의한 신경회로망에서는 일시고장과 영구고장을 판별하기 위한 신경회로망의 입력패턴으로 STFT 분석결과에서 보여지는 전압의 DC 성분, 1차 고조파 성분, 3차 고조파 성분, 5차 고조파 성분, 및 7차 고조파 성분으로 구성되는 5개의 데이터를 입력패턴으로 선정하여 모의를 진행한다.

또한, 본 발명의 일실시예에 따라 사용된 신경회로망은 3층 구조를 지니고 있으며 입력층 5개, 히든층 7개, 출력층 2개의 뉴런을 가진 구조로 구성한다. 히든층의 7개로 한 이유는 6 10개의 뉴런갯수를 바꿔서 실험한 결과, 시간과 학습결과의 최적화에 가장 적절한 것으로 판단되었기 때문이다.

단상 재폐로의 연구를 위해 3상중 대표적으로 a상 고장에 대해 고찰해 보면, 신경회로망의 입력패턴으로 일시고장시 a상의 STFT결과를 채택하였고, 영구고장인 경우에 a상 1선지락, ab상, ac상 선간단락, ab상, ac상 2선지락, abc 3선지락의 a상에 대한 STFT결과를 하나의 파일로 만든 후, 최대값으로 전체를 나누어줌으로써 데이터의 영역이 0 1사이가 되도록 정규화하였다. 이는 [표 1]에 잘 나타나 있다.

[표 1]

[표 1]

	학습조건	테스트 조건
고장형태	1선 아크고장 : a상 1선 지락 : a상 2선 지락 : ab, ca상 선간단락 : ab, ca상 3선지락 : abc상	1선 아크고장 : a상 1선 지락 : a상 2선 지락 : ab, ca상 선간단락 : ab, ca상 3선지락 : abc상
고장거리	80[km]	20, 40, 60, 100, 120, 140 [km]

본 실험에서는 765kV 송전선로 중에서 일부구간을 20㎞마다 나누어서 시뮬레이션을 수행하고, 신경회로망의 학습을 중간지점인 80㎞에서 학습하고 나머지 모든 거리에 대해 신경회로망의 테스트를 실시한다. 즉, 80㎞에서의 학습된 결과를 가지고 나머지 모든 거리에 대해 고장판별을 시도한다. 고장각에 따른 고장파형의 차이는 없음을 알 수 있고, 따라서 고장각은 본 실험에서 고려하지 않는다.

신경회로망의 출력은 2개의 뉴런(neuron 1, neuron 2)을 통해서 출력되며 첫 번째 뉴런을 2차 아크의 존재 유무를 판별하며, 두 번째 뉴런은 DC성분의 유무를 판별한다. 출력이 00인 경우에는 2차아크와 DC성분이 없음을 나타내며 이는 영구고장을 의미하고 선로의 트립 및 차단신호를 의미하는 디지털신호가 된다. 이는 [표 2]에 잘 나타나 있다.

[표 2]

[표 2]

	neuron 1	neuron 2
영구고장	0	0
2차 아크검출	1	0
2차 아크의 소멸순간	1	1
재폐로 투입	0	1

출력이 '10'인 경우에는 현재 2차 아크가 발생함을 탐지한 상태로 일시고장이 발생했음을 알 수 있으며, 출력이 '11'인 경우에는 2차 아크가 소멸되는 시점은 나타내며, 이는 일시고장이 소호되는 시점에서 2차 아크와 DC성분이 공존하는 구간임을 나타낸다. 출력이 '01'인 경우는 2차 아크성분이 완전히 소호된 상태로 오직 DC성분만이 검출됨을 나타내며, 이는 일시고장이 종료된 상태를 의미하여 재폐로를 투입하는 투입지령 신호가 됨을 나타낸다.

도 19는 20㎞지점에서 a상 일시고장시 신경회로망의 출력을 나타낸 3차원 그래프이다. 도 19를 참조하면, a상 일시고장인 경우에는 2차 아크소호시간이 0.971[s]임을 알 수 있는데 뉴런2의 출력 및 데이터를 통해 거의 시간이 일치함을 알 수 있으며, 뉴런 1이 경우에 실제 데이터를 정규화 시켰을 때 크기가 0.8이상이 되는 경우에 1이 출력되도록 학습시

키고 있으며, 0.8이 선택되어진 이유는 영구고장인 경우에도 0.4 0.5정도의 크기의 정규화가 되는 경우가 발생하며, 대부분의 아크특징의 크기는 전체데이터의 가장 큰 값 중 대다수가 0.8 0.9정도를 형성함을 알 수 있다. 출력이 [1, 1]인 경우는 한 번 있으며, 이는 2차아크와 고장이 끝난 후 DC성분과의 중첩이 작음을 나타내며, 따라서 좀 더 정확하고 빠른 재폐로 수행이 가능해진다.

도 20은 20㎞지점에서 a상 1선지락 고장시 신경회로망의 출력을 나타낸 3차원 그래프이다. 도 20을 참조하면, 20[km]에서 a상 1선지락사고가 발생한 경우에, 영구고장인 경우를 나타내고 있으며 신경회로망의 출력은 [0, 0]임을 알 수 있다.

[표 3]은 20[km]에서 a상 1선 일시사고가 발생할 경우에, 신경회로망의 출력을 보여주고 있다. 2차 아크가 발생한 부분에 대해 신경회로망의 출력은 뉴런 1은 1값을, 뉴런 2는 0값에 근사한 값을 출력함을 볼 수 있고, 샘플번호가 451번인 경우 시간적으로 0.976[s]에 해당되며 신경회로망의 출력은 둘 다 1에 근접한 값을 출력함으로써 2차 아크가 소멸되는 시점임을 보여주고 있다. 그러나 이러한 값들이 많으면 그만큼 신경회로망의 판별능력이 떨어짐을 나타냄으로써 자동재폐로의 적용에 시간지연이 됨으로 최소화시켜야 한다. 이후의 값은 뉴런 1은 0값을, 뉴런 2는 1값에 수렴하는 값을 출력함으로써 재폐로를 투입하라는 지령신호가 됨을 알 수 있다.

[표 3]

[표 3]

샘플번호	neuron 1	neuron 2
442	0.9855	0.0030
443	0.9904	0.0027
444	0.9996	0.0014
445	0.9999	0.0016
446	0.9998	0.0052
447	0.9987	0.0284
448	0.9983	0.0579
449	0.9974	0.1096
450	0.9898	0.2996
451	0.8027	0.8227
452	0.0178	0.9924
453	0.0014	0.9972
454	0.0008	0.9975
455	0.0010	0.9974
456	0.0012	0.9973
457	0.0013	0.9972
458	0.0013	0.9972
459	0.0013	0.9972

도 21은 60㎞지점에서 b상 일시고장시 신경회로망의 출력을 나타낸 3차원 그래프이다. 도 22는 60㎞지점에서 ab상 2선지락 고장시 신경회로망의 출력을 나타낸 3차원 그래프이다. 도 21 및 도 22에 도시된 바와 같이, 상기한 도 19 및 도 20과 동일한 판별결과가 이루어지며, 고장형태와 거리에 상관없이 일시고장과 영구고장을 정확하게 판별함을 알 수 있다. 즉, 신경회로망을 이용하여 일시고장과 영구고장의 판별을 수행한 결과, 고장에 대한 우수한 판별능력이 있음을 확인할 수 있다. 일시고장인 경우에 2차 아크의 검출은 학습이 된 결과대로 오차가 거의 없었음을 알 수 있고, 단지 2차 아크의 소멸순간에서의 neuron 1과 neuron 2가 동시에 1이 출력된 경우가 있는데, 신경회로망의 학습에 있어 [1, 1]이라는 목적패턴은 없었기 때문에 이는 신경회로망의 출력오차에 해당된다. 이 신경회로망의 출력오차는 [표 4]에 잘

나타나 있다.

[표 4]

[표 4]

	a상	b상	c상
20km	1	1	0
40km	1	0	1
60km	1	1	1
100km	1	1	0
120km	0	2	1
140km	1	1	1

발명의 효과

상술한 바와 같이, 본 발명에 따른 신경회로망을 이용한 송전선로의 재폐로방법은, 일시적으로 발생하는 아크현상을 신호처리기법을 이용하여 일시고장과 영구고장을 우선적으로 검출한 후, 일시고장에 대해서는 2차 아크의 소멸시간과 그 이후의 주파수 특성을 이용함으로써 무전압시간이 끝나는 시점과 재폐로를 수행하는 시점을 쉽게 알 수 있다. 또한, 이러한 방법으로 검출되어진 특징을 신경회로망을 이용하여 2bit의 디지털신호로 출력해 줌으로써 실제 적용시에 자동적으로 재폐로가 수행될 수 있다.

고장의 특징추출에 있어서도 시간과 주파수 그리고 크기의 3차원 영역을 통해서 분석되는 웨이브렛변환과 STFT 분석을 이용함으로써 신속하고 정확한 고장검출과 일시고장이 끝나는 정확한 시점을 알 수 있다.

특히, 765kV가 건설되고 국토가 좁은 우리나라의 실정에서 앞으로 전력공급량이 크게 증가함을 예측할 때 대용량전력을 2회선으로 공급하는 추세에 맞춰 3상 재폐로와 다상 재폐로 방식이 적용되어져야 하며, 본 발명은 이러한 3상 재폐로와 다상 재폐로 방식연구에 크게 기여할 것이라 여겨진다.

본 발명은 상술한 실시예에 한정되지 않으며, 본 발명의 기술적 사상 내에서 당분야의 통상의 지식을 가진 자에 의하여 많은 변형이 가능함은 명백할 것이다.

(57) 청구의 범위

청구항 1.

일시고장 또는 영구고장의 특징을 갖는 사고를 발생시키는 제1 단계;

상기 신호에서 제n 고조파 이상의 성분을 제거시키기 위해 저역통과필터를 이용하여 필터링하는 제2 단계;

상기 필터링된 아날로그 신호를 디지털신호로 변환시키는 제3 단계;

주파수 분석을 수행하되 일시고장과 영구고장을 구분지을 수 있는 특징을 기수 및 우수 고조파분석을 통해 추출하는 제4 단계

상기 추출되어진 데이터를 입력층과 출력층을 포함하는 다층으로 형성되어 고장종류에 대한 패턴인식을 학습하는 신경회로망에 적용하는 제5 단계; 및

상기 신경회로망의 출력결과를 분석하고, 단상 자동재폐로의 수행여부를 결정하는 제6 단계;

를 포함하여 이루어진 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 2.

제 1 항에 있어서, 상기 제n 고조파는 10조파인 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 3.

제 1 항에 있어서, 상기 주파수 분석방법으로 웨이브렛변환 및 단시간 퓨리에변환에서 선택된 어느 하나의 방법을 이용하는 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 4.

제 3 항에 있어서, 상기 웨이브렛변환을 이용할 경우에,

저역(approximation) 필터를 통해서 얻어지는 신호는 또 다른 두 개의 저역 필터(cA1)와 고역 필터(cD1)로 분해되고, 상기 저역 필터(cA1)를 통과한 신호는 또 다시 두 개의 저역 필터(cA2)와 고역 필터(cD2)로 분해되는 연속적인 과정에 의해 고역 필터(cDn)와 저역 필터(cAn)에 입력될 데이터를 매 2번째 샘플점마다 통과시키는 다운 샘플링기법을 이용하는 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 5.

제 1 항에 있어서, 상기 제5 단계는,

a. 신경망의 연결 가중치를 적당한 값으로 초기화하는 단계;

b. 학습시킬 입력 패턴을 선정하는 단계;

c. 신경망의 입력층 인공 신경세포에 입력 패턴을 제시하는 단계;

d. 신경망의 인공 신경세포들을 층별로 동작시켜 출력 패턴을 출력시키는 단계;

e. 신경망의 출력층 인공 신경세포에 목적 패턴을 선택적으로 제시하는 단계;

f. 선택된 학습 규칙에 따라 연결 가중치를 조절하는 단계;

g. 모든 입력 패턴에 대해 b f 과정을 반복하는 단계; 및

h. g 단계를 신경망이 완전히 학습될 때까지 반복하는 단계;

를 포함하여 이루어진 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 6.

제 1 항에 있어서, 상기 신경회로망의 학습시에,

모멘텀, 바이어스, 델타-바-델타, 및 전역적인 학습방법에서 선택된 어느 하나의 방법을 이용하여 학습속도를 증대시키는 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 7.

제 1 항에 있어서, 상기 신경회로망의 오차를 최소화하기 위해, 출력층의 에러가 연결층으로 역전파되어 각각의 신경망에 연결된 가중치값을 갱신하는 오차 역전파(Error Backpropagation)방법을 이용하는 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 8.

제 1 항에 있어서, 상기 신경회로망은 적어도 3개층으로 이루어지며, 입력층, 히든층, 출력층을 포함하는 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

청구항 9.

제 8 항에 있어서, 상기 히든층은 6 내지 10개 범위의 뉴런으로 이루어진 것을 특징으로 하는 신경회로망을 이용한 송전선로의 재폐로방법.

도면

도면 1

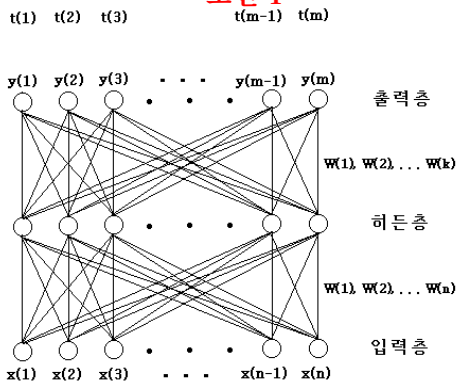

도면 2

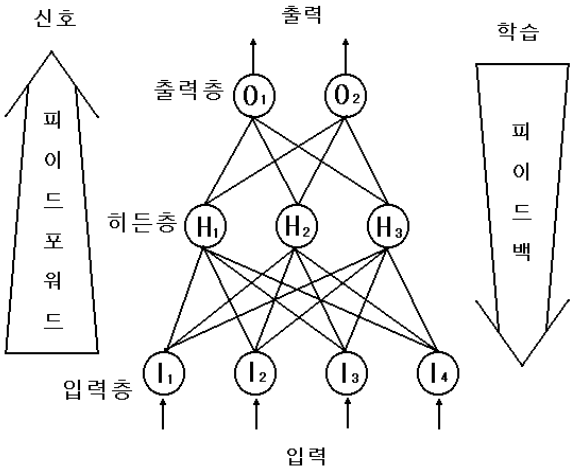

도면 3a

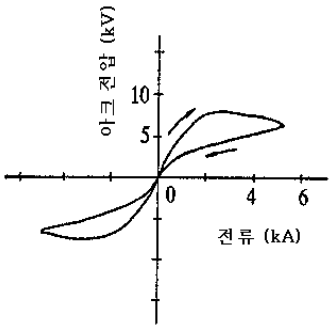

도면 3b

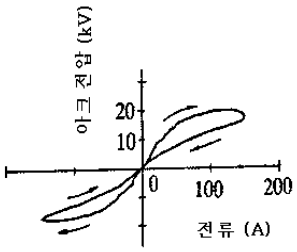

도면 4

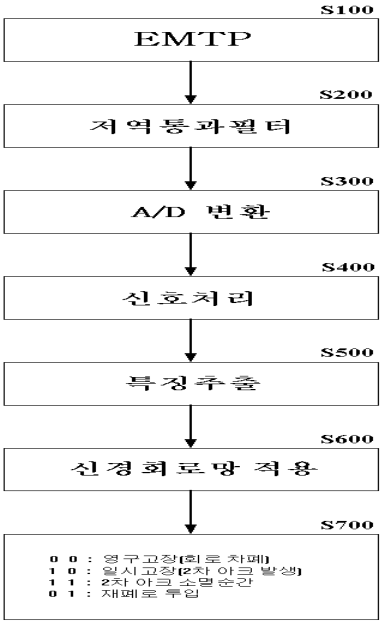
S100
EMTP
S200
저역통과필터
S300
A/D 변환
S400
신호처리
S500
특징추출
S600
신경회로망 적용
S700
0 0 : 영구고장(회로 차폐)
1 0 : 일시고장(2차 아크 발생)
1 1 : 2차 아크 소멸순간
0 1 : 재폐로 투입

도면 5

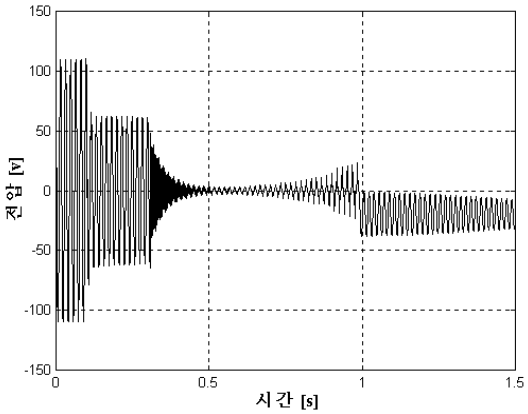
150
100
50
0
-50
-100
-150
전압 [v]
0
0.5
1
1.5
시간 [s]

도면 6

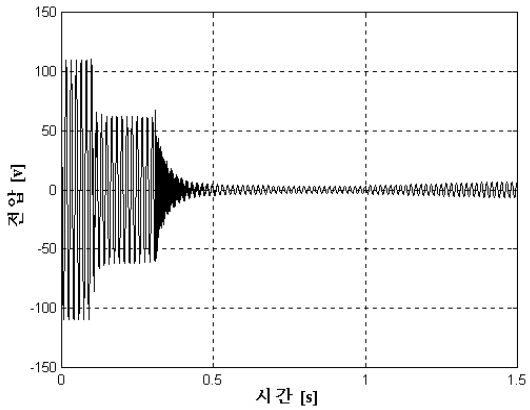
150
100
50
0
-50
-100
-150
0
0.5
1
1.5
전압 [v]
시간 [s]

도면 7

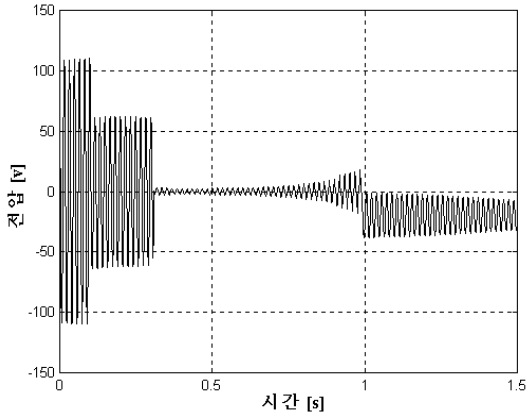
150
100
50
0
-50
-100
-150
0
0.5
1
1.5
전압 [v]
시간 [s]

도면 8

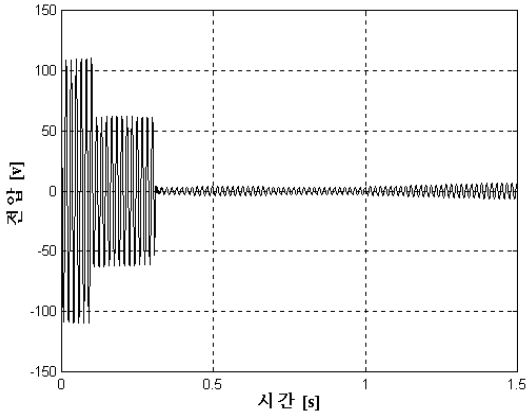
150
100
50
0
-50
-100
-150
0
0.5
1
1.5
전압 [v]
시간 [s]

도면 9

도면 10

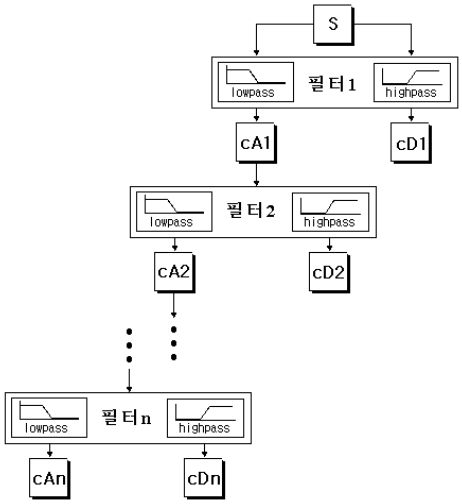

도면 11

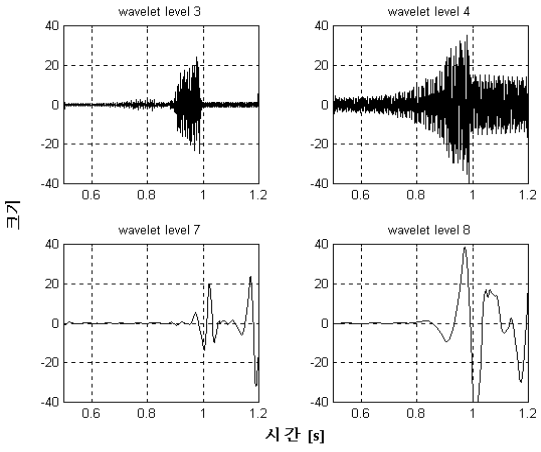

도면 12

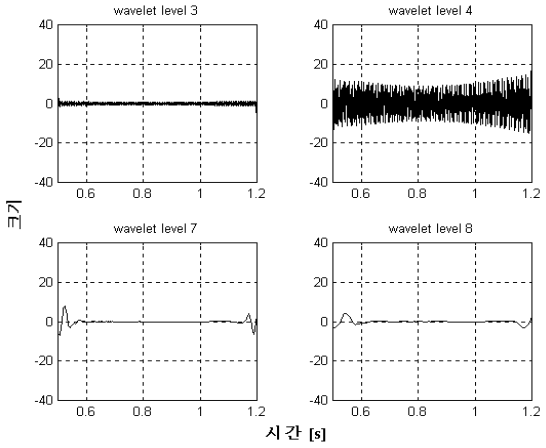

도면 13

도면 14

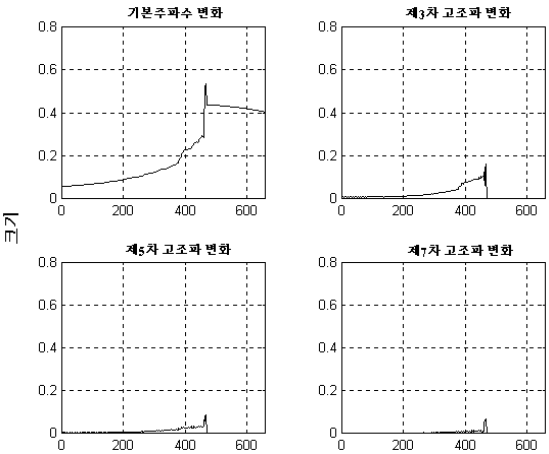

도면 15

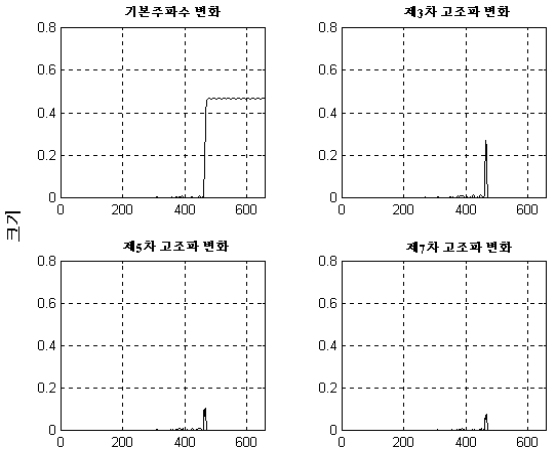
기본주파수 변화
제3차 고조파 변화
제5차 고조파 변화
제7차 고조파 변화
크기
0.8
0.6
0.4
0.2
0
0
200
400
600

도면 16

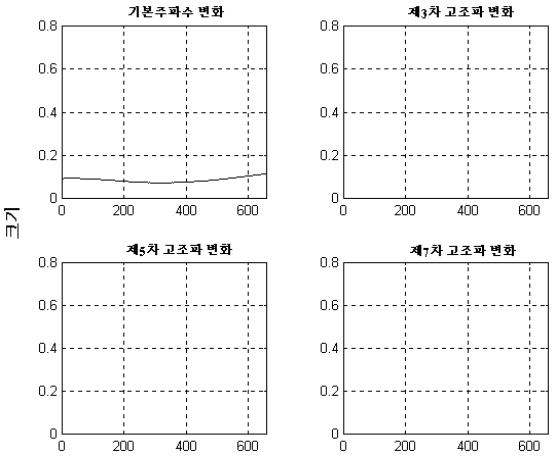
기본주파수 변화
제3차 고조파 변화
제5차 고조파 변화
제7차 고조파 변화
크기
0.8
0.6
0.4
0.2
0
0
200
400
600

도면 17

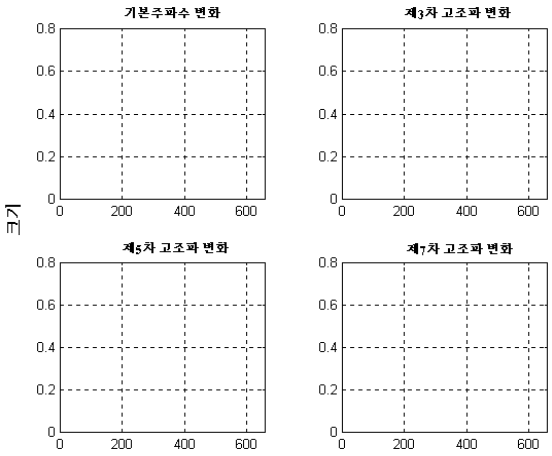
기본주파수 변화
제3차 고조파 변화
제5차 고조파 변화
제7차 고조파 변화
크기
0.8
0.6
0.4
0.2
0
0
200
400
600

도면 18

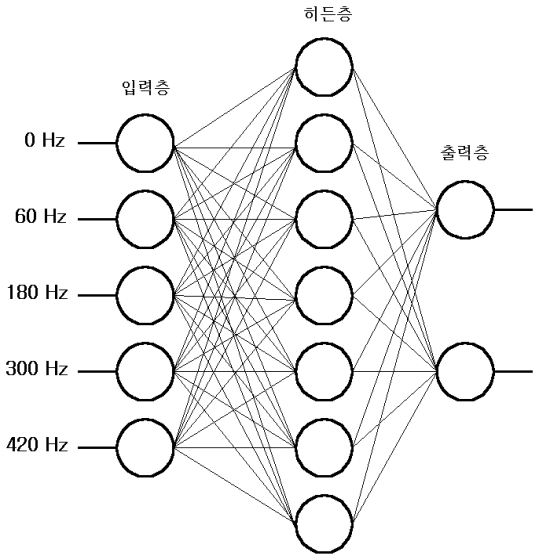
히든층
입력층
출력층
0 Hz
60 Hz
180 Hz
300 Hz
420 Hz

도면 19

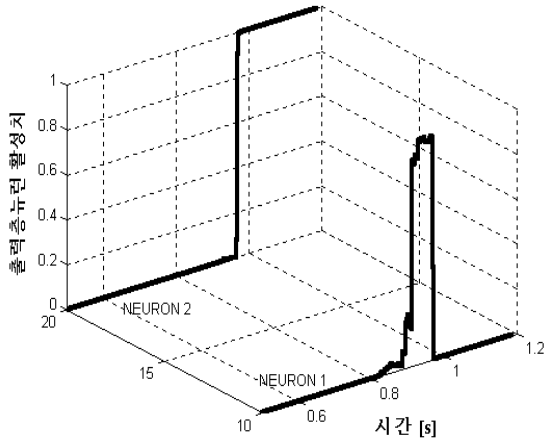
출력층뉴런 활성치
1
0.8
0.6
0.4
0.2
0
20
15
10
NEURON 2
NEURON 1
0.6
0.8
1
1.2
시간 [s]

도면 20

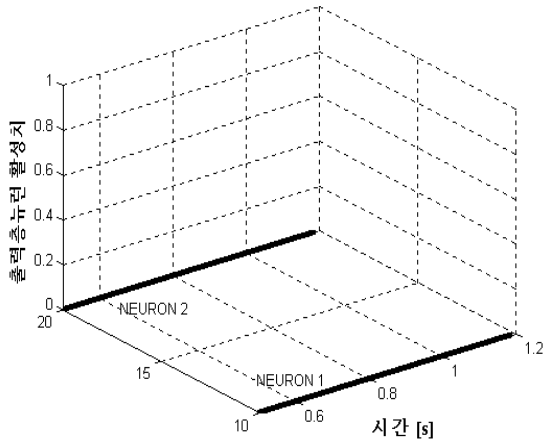
출력층뉴런 활성치
1
0.8
0.6
0.4
0.2
0
20
15
10
NEURON 2
NEURON 1
0.6
0.8
1
1.2
시간 [s]

도면 21

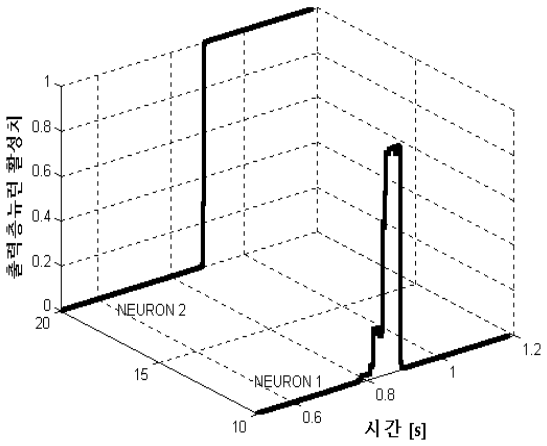
출력층뉴런 활성치
1
0.8
0.6
0.4
0.2
0
20
15
10
NEURON 2
NEURON 1
0.6
0.8
1
1.2
시간 [s]

도면 22

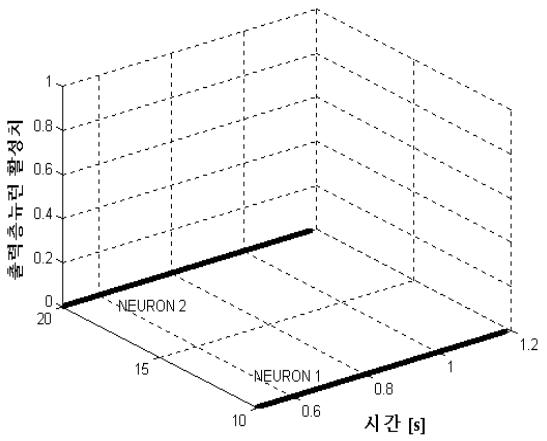
출력층뉴런 활성치
1
0.8
0.6
0.4
0.2
0
20
15
10
NEURON 2
NEURON 1
0.6
0.8
1
1.2
시간 [s]