

신경회로망을 이용한 전력계통 안전성 평가 연구

이광호 황석영
단국대학교 전기공학과

Power System Security Assessment Using The Neural Networks

Kwang-Ho Lee Seuk-Young Hwang
Dankook Univ.

(Abstract)

This paper proposed an application of artificial neural networks to security assessment(SA) in power system. The SA is a important factor in power system operation, but conventional techniques have not achieved the desired speed and accuracy. Since the SA problem involves classification, pattern recognition, prediction, and fast solution, it is well suited for Kohonen neural network application. Self organizing feature map(SOFM) algorithm in this paper provides two dimensional multi maps. The evaluation of this map reveals the significant security features in power system. Multi maps of multi prototype states are proposed for enhancing the versatility of SOFM neural network to various operating state.

1. 서 론

전력계통의 운용에서 예기치 못하지만 발생 가능한 사고에 대해 정전상태, 선로의 과부하, 모선의 이상전압 등을 파악하는 분야를 안전성 평가라고 한다. 계통운용에서의 안전성은 실시간 운용이 가능한 정도의 신속한 계산이 요구되며 미래의 발생 가능한 사고관련 경우의 수가 많을뿐만 아니라 계통의 상태가 시시각각 변하고 안전성 평가는 매 순간 이루어져야 하므로 안전성 평가에서 요구되는 계산량은 헤아릴 수 없을 정도로 많다.

이러한 계산시간의 부담 때문에 시간 단축을 위한 여러 가지 기법들이 사용되고 있다. 전력조류계산을 신속히 수행하는 근사적 기법[1]과 상정사고(Contingency)의 평가지수를 도입하여 계산의 대상을 감소시키는 기법[2]이 연구되어 왔으나 실제 적용에는 미흡한 실정이다.

안전성 평가란 사고 상황의 예측, 각 상태에 대한 패턴의 인식, 패턴 구분을 위한 신속한 계산 등이 밀접하게 관련된 복잡한 작업이다. 따라서 이러한 문제에 적합한 인공신경 회로망 분야와의 접목이 궁정적으로 평가되고 있으며 여러 방면으로 연구가 시도되고 있다[3].

안전성 해석은 계통의 상태 및 사고상황과 계통의 피해 정도와의 상관관계를 파악하는 문제이므로 수식적 정식화가 어렵다. 따라서 본 연구에서는 경쟁학습을 기초로 자기조직화(Self-Organizing) 기능으로 형상지도(Feature Map)를 구성하는 코호넨 신경망을 이용하였다. 이와 관련된 연구[5]가 발표된 바 있으나 이는 초기 계통에 대한 형상지도만을 발생시키기 때문에 부하 분포상황 등이 변했을 때는 안전성 판정에 오차가 많이 생기는 문제를 갖는다.

본 연구에서는 여러 계통에서의 형상지도를 이용하여 변화된 계통에 대해서도 안전성 해석 결과의 패턴을 얻는 다중 SOFM 신경회로망 기법을 시도하였다. 시뮬레이션 결과 임의의 시험 계통상태에 대해서도 형상지도만으로 유효한 결과를 얻을 수 있었다.

2. 자기조직화 형상지도 회로망

2.1 코호넨 회로망

(1) 경쟁학습

자기조직화 형상지도(SOFM)는 패턴 인식에 많이 사용되는 알고리즘으로서 주요 구성은 코호넨 회로망에 의해 이루어지며 코호넨 회로망의 핵심 기능은 경쟁학습이다. 경쟁학습의 개념은 1960년대에 많은 사람들에 의해 시작되고 발전이 이루어졌으나 코호넨에 의해서 체계적으로 정립되었다. 코호넨 회로망은 입력층과 코호넨 층이라고 하는 출력층으로 이루어 지는데 코호넨 층을 상세히 표현하면 다음 그림 2.1과 같이 두 개의 층으로 이루어지며 상위의 것은 경쟁 기능을 수행하는 MAXNET 회로이다.

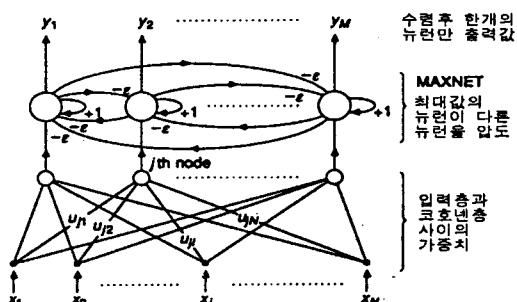


그림 2.1. 코호넨 경쟁 회로망

(2) 학습 알고리즘

임의의 입력에 대해 하나의 뉴런만이 선택되므로 가중치 학습도 선택된 뉴런에 대해서만 이루어진다. 코호넨 층의 뉴런 j 와 입력층 뉴런 i 와 연결되는 가중치를 w_{ij} 라고 하면 뉴런 j 로 입력되는 신호는 다음과 같은 선형결합으로 표시된다.

$$NET_j = \sum_i x_i w_{ij} = X \cdot W_j \quad (2.1)$$

이것은 입력 벡터와 각 가중치 벡터들과의 유사한 정도를 나타낸다. 입력과 가장 유사한 뉴런의 가중치가 더욱 입력 벡터와 가까워지도록 조정함으로서 학습이 이루어진다.

$$w_{new} = w_{old} + \alpha \cdot (x - w_{old}) \quad (2.2)$$

2.2. 형상지도(Feature Map) 알고리즘

코호넨 층의 모든 뉴런들 간에 상호 인접 정도의 개념을 부여하기 위해 2차원에 배열시킨 후 경쟁을 통해 선택된 뉴런과 그 주변에 위치하는 뉴런들을 동시에 학습시킨다. 이러한 학습이 완료되면 2차원의 코호넨 뉴런은 입력벡터들의 특

성구분은 물론 각 그룹들 간의 유사성도 2차원의 형상지도에 포함이 된다. 형상지도가 알고리즘이 적용되기 위해서는 선택된 뉴런뿐만 아니라 주변의 뉴런들도 함께 학습되어야 한다. 이와 같은 과정은 다음의 단계를 거쳐 이루어진다.

- 단계1: 가중치 w_{ij} 를 작은값으로 초기화
- 단계2: 학습 데이터 중에서 임의의 입력을 선택
- 단계3: 경쟁에서 선택된 뉴런 결정 (이때의 가중치 w_c)
- 단계4: 가중치 w_c 와 주변 뉴런의 가중치 w_i 를갱신
 $w_i(t+1) = w_i(t) + \alpha(t, i, c)[x - w_i(t)], i=c \text{ 혹은 } i \in NBH, (2.3)$
 $= w_i(t), \text{ 아닌 경우}$
- 단계5: 학습 횟수를 의미하는 변수 증가($t=t+1$)
- 단계6: 만약 $\alpha(t, i, c) < \epsilon$ 이면 종료, 아니면 단계2로 이동

여기서 학습계수 α 는 주로 횟수의 변수(t)에 대해 지수 감소 함수가 사용되고 NBH 는 선택 뉴런(c)의 주변 뉴런들의 집합을 의미한다. 주변 뉴런들은 인접도(neighborhood order)로 정의되는데 1차 인접도 뉴런이란 일반적으로 선택 뉴런과 인접한 8개를 뜻하고 2차 인접도는 1차 인접도 뉴런을 둘러싸는 16개의 뉴런을 의미하며 그 이상의 인접도 뉴런도 같은 방식으로 정의된다. 이러한 인접도 뉴런의 정의는 유클리디안 거리를 사용할 수도 있으며 여러 가지 정의가 가능하다. 학습 대상이 되는 주변 뉴런의 범위를 학습 진행에 따라 좁히기 위해 NBH 는 학습횟수에 따른 지수 감소 함수가 사용된다.

3. 전력계통 안전성 해석 적용

3.1. 상정사고 해석

전력계통 안전성 해석의 관건은 얼마나 많은 상정사고 해석을 수행하는가에 달려있다. 따라서 선형계산과 병렬처리의 장점을 갖는 인공 신경회로망의 도입이 필요하게 된 것이고, 계통상태의 변동에 따른 안전성 해석 결과가 공통된 특징을 갖는 몇 개의 그룹으로 구분될 수 있으므로 패턴 인식의 기능이 우수한 코호넨의 SOFM 신경망을 사용하였다.

적용 대상으로 하는 사례 계통은 다음 그림 (3.1)과 같은 간단한 5모선 계통이다. 상정사고 해석은 각 선로에 대한 단일 사고 7개, 이중 선로사고 21개, 발전기 사고 2개, 발전기와 선로사고 조합 14개를 합한 44개의 사고 계통에 대해 이루어지고 사고전 정상상태를 포함한 45개의 계통에 대한 계통상태가 신경망의 학습 데이터로 사용된다. 또한 선로조류와 모선전압의 계통상태 중에서 조류에 대한 패턴의 추출만을 목적으로 한다.

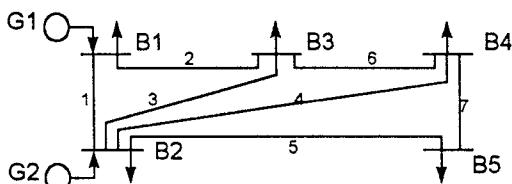


그림 3.1. 5모선 사례 계통

3.2. 형상지도 학습과정

형상지도 회로망은 코호넨 층의 뉴런을 2차원 배열시켜 상정사고 해석 결과들 간의 공통된 패턴 그룹을 2차원 형상지도에 나타내는 것이다. 본 연구에서는 7×7 의 배열 49개의 뉴런을 사용하고 있다. 따라서 형상지도의 학습은 14개 입력 뉴런과 49개 코호넨 층 뉴런들 간의 14×49 차원의 가중치 행렬을 결정하는 것이다.

정상상태에서의 45개 상정사고에서의 14개 선로조류 값이 입력벡터로 작용한다. 학습의 횟수는 10,000 번을 시도하였으며 수렴시간은 Pentium PC 133MHz 기준으로 12초 정도 소요된다. 가중치의 초기값도 난수로 발생시키고 학습시 입력

벡터도 난수적으로 선택한다. 그 중 한 경우에 대해 형상지도의 해석 사례를 살펴본다. 학습 결과 다음 그림 3.2와 같이 각각의 상정사고와 코호넨층 뉴런과의 매핑관계가 구해지며 이것이 계통 안전성 형상지도이다.

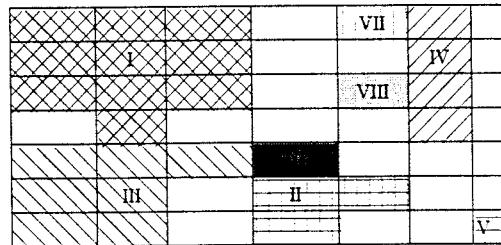


그림 3.2. 안전성 형상지도 사례

형상지도는 특정의 상태를 기준으로 추출된 것이기 때문에 계통상태가 변하면 기준상태가 달라진다. 부하 수준이 $\pm 10\%$ 변동할 때 약 9%의 형상지도 오차를 보인다는 연구 결과도 있다.[5] 그러나 이러한 변화는 부하의 분포가 일정한 채 균등한 비율로 부하가 증감한 경우에 해당한다. 실제의 부하 변화는 부하 수준뿐 아니라 분포까지도 변동하므로 실제의 형상지도의 변화는 이보다 크게 나타나게 된다.

따라서 형상지도의 활용도를 높이기 위해서는 이러한 부하분포의 변화에도 적용될 수 있는 형상지도 알고리즘이 필요하다. 본 연구에서는 이러한 약점을 개선하기 위해 다중 형상지도 알고리즘을 제안한다. 하나의 형상지도가 특정 부하 분포에서 추출된 계통 특성이라면 다중의 형상지도 방식은 변동하는 부하 분포에 대해 각각의 특성을 형상화한 것이다.

4. 다중 형상지도에 의한 안전성 해석

4.1 다중 형상지도(Multi-SOFM)

하나의 형상지도가 적용될 수 있는 범위는 제한적이기 때문에 여러 운전점에서 형상지도를 만들고, 임의의 계통에 대해서도 이를 충족할 것을 선택하여 안전성 해석을 신속히 대체할 수가 있다. 적용 계통에서는 다음과 같은 34개 경우의 부하 변동을 표준 부하상태로하여 SOFM을 형성하였다. 기준률의 부여와 상이한 패턴의 모서리 배치를 위해 본 연구에서는 35개 표준 계통상태를 해석하고 공통점을 분석하여 3개의 특수 상정사고를 선택하였다. 이들의 경우는 사고번호 3, 38, 39로서 계통상태가 각각 선로1의 과부하, 안전상태, 선로2의 과부하 상태로 구분되는 대표적인 경우로서 상호간 관련성이 매우 많다. 이러한 현상은 부하상태가 서로 다른 35개 계통에서 공통적으로 나타나고 있다. 이를 세 경우를 그림 3.3과 같이 형상지도에서 각각 좌상, 좌하, 우하에 대응되도록 배치하여 학습하였다. 10,000번의 학습과정 중 보통의 입력벡터는 난수적으로 선택되고 코호넨 층에서의 경쟁을 통해 하나의 뉴런이 자연적으로 결정되어 학습이 수행된다.

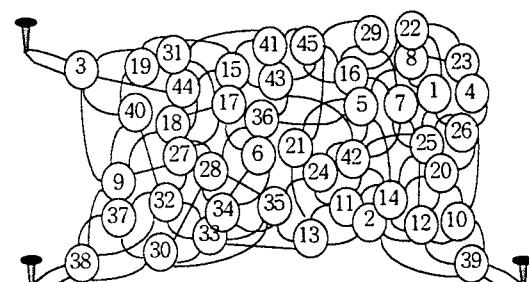


그림 3.3. 뉴런 배치 개념도

4.2 다중 형상지도 적용 알고리즘

형상지도를 대표적인 부하 상태 각각에 대해 만든 것은 임의의 부하에 대해서 가장 적절한 형상지도를 대응시켜 안전성 해석 결과를 이용하고자 하는 것이다. 따라서 임의 계통에 대한 안전성 해석이 즉각적으로 이루어지게 되어 단일 형상지도를 이용하는 것보다 훨씬 넓은 영역에서 온라인 안전성 해석이 가능하게 된다. 다음과 같은 단계의 형상지도 선정 알고리즘을 수립하였다.

- 단계1: 임의 계통에 대한 선로조류를 입력벡터에 인가
- 단계2: 입력신호는 다중 형상지도 각각의 경쟁층에 도달
- 단계3: 각 형상지도에서 활성화 뉴런 선정
- 단계4: 활성화된 뉴런들의 출력값이 상위의 경쟁층에 도달
- 단계5: 상위 경쟁층에서 활성화 뉴런 선정
- 단계6: 선정된 형상지도가 입력계통의 안전성 해석 결과 이와 같이 형상지도 선정 알고리즘을 구현하기 위한 신경망의 구조는 다음과 같다.

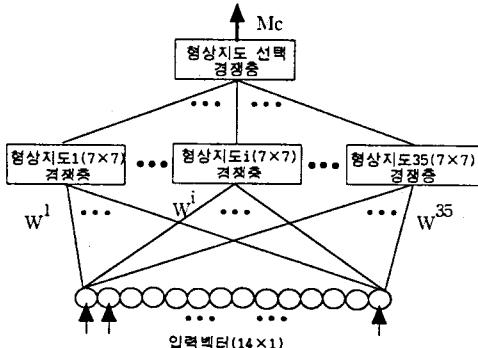


그림 4.1. 형상지도 선택 회로망

다음 그림 4.2와 같이 안전성 해석의 검증을 위해 50개의 임의 계통을 난수 발생시켜 각각에 대한 선택 형상지도(A)와 실제의 상정사고 해석(B)을 비교하였다. 시험 계통 50개에 대해서 성공과 실패의 비율을 조사함으로서 전체적인 타당성을 검증할 수 있다.

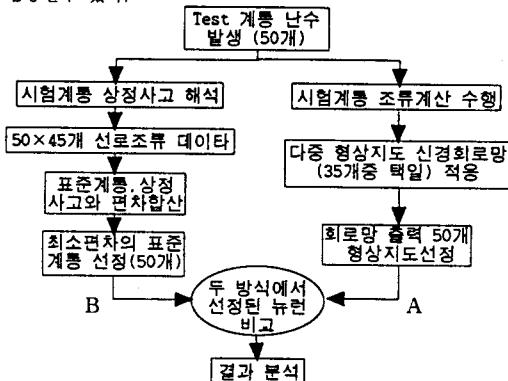


그림 4.2. 타당성 검증 순서도

5. 사례연구

다중 형상지도 추출을 위해 초기 계통의 부하수준을 10% ~ 30% 사이의 모선별 부하 변화를 반영하여 전체 35개 표준 계통을 설정하여 35개의 형상지도가 구해진다.

시험 계통에 대한 형상지도 대응 관계의 타당성 검증을 위해 실제의 선로조류와 비교하는 과정을 수행하였다. 결과는 다음 표 5.1과 같다. 표에서 A열은 다중 형상지도를 통하여 활성화된 뉴런들이고 B열은 상정사고의 선로조류를 비교하여 가장 가까운 표준계통을 선택한 것이다. 50개 중에서 11번과

41번의 경우를 제외하고는 다중 형상지도에서의 결과와 일치하여 96%의 성공률을 보였다. 이러한 시뮬레이션을 수차례 수행한 결과 86%~96%의 성공률을 나타내었다.

표 5.1. 다중 형상지도 신경망의 검증 결과

| | A | B | A | B | A | B | A | B | A | B |
|----|----|----|----|----|----|----|----|----|----|----|
| 1 | 4 | 4 | 11 | 26 | 6 | 21 | 0 | 0 | 31 | 33 |
| 2 | 9 | 9 | 12 | 9 | 9 | 22 | 3 | 3 | 32 | 7 |
| 3 | 0 | 0 | 13 | 29 | 29 | 23 | 3 | 3 | 33 | 26 |
| 4 | 14 | 14 | 14 | 7 | 7 | 24 | 0 | 0 | 34 | 18 |
| 5 | 29 | 29 | 15 | 30 | 30 | 25 | 34 | 34 | 35 | 4 |
| 6 | 5 | 5 | 16 | 30 | 30 | 26 | 7 | 7 | 36 | 2 |
| 7 | 5 | 5 | 17 | 5 | 5 | 27 | 18 | 18 | 37 | 7 |
| 8 | 34 | 34 | 18 | 5 | 5 | 28 | 7 | 7 | 38 | 3 |
| 9 | 4 | 4 | 19 | 5 | 5 | 29 | 6 | 6 | 39 | 28 |
| 10 | 10 | 10 | 20 | 1 | 1 | 30 | 9 | 9 | 40 | 7 |
| | | | | | | | | | 50 | 0 |

대응상태를 분석한 결과를 정리하면 다중 형상지도 신경망은 입력되는 임의 계통의 부하 패턴과 유사한 표준 계통을 출력한다. 정확히는 외형적인 부하 패턴 보다는 상정사고의 해석 결과가 가까운 표준 계통이 선택된다. 두 개의 표준 계통이 입력된 계통과 상정사고 측면에서 비슷한 유사성을 보이는 경우에는 판별이 어려우며 이러한 문제는 표준 계통을 적절히 선정함으로서 극복할 수 있다. 또한 임의 입력을 형상지도에서의 기준 뉴런에만 작용시킨 결과값을 비교함으로서 다중 형상지도 알고리즘의 성공률을 향상시킬 수가 있다.

6. 결론

본 연구는 안전성 해석의 패턴을 추출하여 2차원의 형상지도에 나타내는 코호넨 신경회로망 기법을 제안한다. 형상지도에는 각각의 상정사고 패턴은 물론 패턴의 상관관계 정보까지 포함되므로 계통의 기준 상태로부터 부하 변화에 따른 상정사고의 결과를 온라인으로 예측할 수가 있다.

기준의 단일 형상지도로는 일반적인 부하 패턴의 계통에 대한 안전성 해석을 수행하기 어렵기 때문에 여러 개의 표준 계통 각각에 대한 형상지도를 활용하는 새로운 개념을 적용하였다. 다중의 형상지도를 사용하여 임의 계통에서의 안전성을 해석하기 위한 형상지도의 선택 알고리즘도 제안하였으며 사례연구를 통해 실제의 상정사고 해석과 유사함을 검증하였다. 본 연구에서는 선로조류만이 상정사고 해석 대상이었지만 모든 전압의 이상 상태까지 반영하기 위해서는 적절한 입력 데이터의 선정에 관한 연구가 지속되어야 한다. 이와 함께 패턴의 선별성을 높이기 위한 효과적인 기준률의 선택, 임의의 계통 변화를 대표할 수 있는 표준 계통의 적절한 선택 알고리즘이 보완되어야 한다.

(참 고 문 헌)

- [1] Debs, Modern Power System Control And Operation, 1988, Kluwer Academic Publisher
- [2] B.F. Wollenberg, "Automatic Contingency Selection," IEEE Trans. on PAS, Vol.98, No.1, Jan./Feb. 1979
- [3] M.A. El-Sharkawi, "Application of Artificial Neural Networks to Power Systems", IEEE, 1996
- [4] H.H. Yan, "Hybrid Expert System/Neural Network Hierarchical Architecture for Classifying Power System Contingency," IEEE ISAP 91
- [5] D.N. Nicbur, A.J. Germond, "Power System Static Security Assessment Using The Kohonen Neural Network Classifier," IEEE Trans. on PS, Vol.7, No.2, May 1992