

새로운 지도 경쟁 학습 알고리즘의 개발과 전력계통 과도안정도 해석에의 적용

박 영 문 조 흥 식[°] 김 광 원
서울대학교 전기공학과

A New Supervised Competitive Learning Algorithm and Its Application to Power System Transient Stability Analysis

Young-Moon Park Hong-Shik Cho[°] Gwang-Won Kim
Department of Electrical Engineering, Seoul National University

ABSTRACT - Artificial neural network based pattern recognition method is one of the most probable candidate for on-line power system transient stability analysis. Especially, Kohonen layer is an adequate neural network for the purpose. Each node of Kohonen layer competes on the basis of which of them has its clustering center closest to an input vector. This paper discusses Kohonen's LVQ(Learning Vector Quantization) and points out a deficiency of the algorithm when applied to the transient stability analysis. Only the clustering centers located near the decision boundary of the stability region is needed for the stability criterion and the centers far from the decision boundary are redundant. This paper presents a new algorithm called boundary searching algorithm II which assigns only the points that are near the boundary in an input space to nodes of Kohonen layer as their clustering centers. This algorithm is demonstrated with satisfaction using 4-generator 6-bus sample power system.

1. 서론

전력계통의 과도안정도 해석은 전력계통공학에서 가장 중요한 연구 분야 중의 하나로서 상정하고 후에 전력계통이 평형상태를 유지한 채 운용될 수 있는지를 판정할 수 있게 해 준다. 안정한 계통이 동기기들의 상태변수값이 새로운 동작점으로 수렴하지만 불안정한 계통이면 동기기 중에 일부가 탈조이며 그 과정 효과가 확대되어 계통 전체가 붕괴될 수도 있다.

전력계통의 규모가 커지고 복잡해짐에 따라 안정도 해석에 걸리는 시간이 기하급수적으로 증가하게 되므로 정확하면서도 빠른 과도안정도 해석 기법의 필요성이 대두되고 있다. 수정오일러법, 사다리꼴법, 분기-쿠타법 등의 수치적분법으로 상태변수의 시간에 대한 궤적을 디지털 컴퓨터 상에서 직접 구하여 과도안정도를 해석하는 방법이 있지만 [1], [2] 각 구간마다 시간이 많이 걸리는 조류 계산을 해야 하기 때문에 실시간 이용은 어렵다. Lyapunov의 직접법은 수치적분법보다 시간적 이득은 있으나 안정도 해석의 충분조건 밖에는 제시하지 못하므로 임계치 부근에서는 그 판정이 틀릴 수 있다 [3], [4]. 경험된 정보로부터 오프라인으로 안정한 영역과 불안정한 영역을 구분짓는 선별기(Classifier)를 만들어 놓음으로써 안정도를 해석하는 패턴인식법은 오프라인으로 처리해야 할 양이 많은 반면 일단 선별기가 완성되면 선별 시간이 극히 짧다는 장점이 있다 [5-7].

신경회로망은 병렬처리에 의하여 빠른 속도로 계산할 수 있다는 큰 장점을 갖고 있기 때문에 전력계통 안정도 해석의 실시간 처리에 높은 가능성을 제시한다. 전력계통의 안정도 해석에 사용될 수 있는 신경회로망으로는 역전파학습법(Back-Propagation Learning Algorithm)을 이용한 다층 퍼셉트론과 [8], [9] 코호넨의 경쟁학습법(Kohonen's Competitive Learning)을 이용한 코호넨층이 있다 [10], [11]. 코호넨의 경쟁 학습법은 코호넨층에서의 대표점들이 선별 공간에 적절히 분포되어 있어서 입력에 대한 가장 가까운 대표점을 선택하여 그 정보를 출력하는 방법이다 [12]. 역전파학습법에 의한 접근은 문제를 함수의 내삽(Interpolation)으로 생각하는 방식이기 때문에 학습에 시간이 많이 걸리고 많은 양의 학습데이터가 필요하게 된다.

코호넨의 경쟁학습법은 비지도 학습법(Unsupervised Learning Algorithm)으로 클래스를 고려하지 않는 데이터의 clustering에 그 목적이 있기 때문에 선별(Classification)문제에 적용하기 위해서

는 어떠한 지도 학습(Supervised Learning)이 참가되어야 한다. 학습데이터에 대한 클래스 선별이 정확한지의 여부에 따라 대표값의 학습 방법에 차이를 두는 코호넨의 LVQ(Learning Vector Quantization) 방법은 여러가지 선별 문제에서 좋은 결과를 보였다 [12-14]. 그러나 전력계통의 과도안정도 해석 문제와 같은 클래스의 구분이 경계면으로 분명하게 구분 지어지는 문제에 있어서 clustering에 기반을 둔 LVQ방법은 보통 clustering문제에 적용될 때 보다 훨씬 많은 수의 노드가 필요하게 된다. 이 때 경계면과 같은 정확한 선별이 요구되는 저점에만 노드의 대표값을 배치시킨다면 선별기의 성능이 향상된다.

본 논문에서는 경계면탐색법 II라는 새로운 지도 경쟁 학습 알고리즘을 제시한다. 제안된 방법은 학습데이터로부터 선별의 필요성이 있는 곳에 노드의 대표값을 구한다. 참고문헌[15]의 경계면탐색법 I이 노드의 수를 고정시키고 경계면을 찾는 과정인데 반하여 경계면탐색법 II는 학습 중에 선별이 필요한 데이터가 들어 왔을 때 노드의 수를 하나씩 증가시키므로 노드를 더 효율적으로 운용할 수 있다. 또한 노드의 수가 고정값 이상이 되면 노드의 추가가 불필요한 노드의 삭제 과정을 병행함으로써 정확한 선별기를 구현할 수 있다.

2. 코호넨의 경쟁학습

2.1 코호넨층 (Kohonen Layer)

코호넨층은 그림 1과 같이 입력데이터와 노드의 대표값과의 거리에 반비례하는 스칼라값을 계산하는 부분과 계산된 결과로부터 가장 큰 값을 선택하는 MAXNET의 두 부분으로 구성된다.

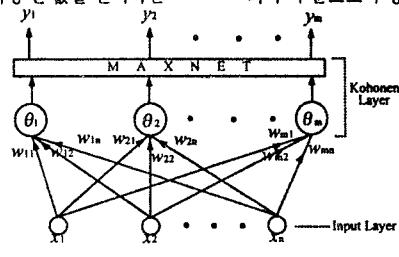


그림 1 코호넨층의 구조

그림 1에서 코호넨층(Kohonen Layer)의 각 노드는 입력벡터와 가중치 벡터 W_i 의 내적과 문턱값(threshold) θ_i 의 차이로써 입력벡터와 각 노드의 대표값과의 거리를 구하므로 가중치 벡터 W_i 와 문턱값 θ_i 가 i번째 노드의 대표값 m_i 를 결정한다고 볼 수 있다. MAXNET에서는 m개의 양수 입력중에서 가장 큰 입력에 대한 출력만을 '1'로 하고 나머지 노드의 출력은 '0'으로 한다. 즉, 대표값이 입력벡터에 가장 가까운 노드의 출력만 '1'이 되고 나머지 노드의 출력은 '0'이 된다.

2.2 코호넨의 LVQ (Learning Vector Quantization)

코호넨의 LVQ는 지도경쟁학습(supervised competitive learning)을 이용한 clustering에 바탕을 둔 선별 이론이다. 각 노드는 대표값과 소속 클래스를 가지고 있고 그 수는 미리 결정된다. c번

노드의 대표값이 식(1)과 같이 입력 x 에 가장 가까울 때, x 의 선별은 0번재 노드의 소속 클래스에 의하여 결정된다.

$$\|x - m_i\| = \min_j (\|x - m_j\|) \quad (1)$$

학습 과정 동안 노드의 대표값은 식(2)와 같이 개선된다

$$\begin{aligned} m_c(k+1) &= m_c(k) + \alpha(k)(x(k) - m_c(k)) \\ x \text{와 } c \text{ 번째 노드가 같은 클래스에 속할 때} \\ m_c(k+1) &= m_c(k) - \alpha(k)(x(k) - m_c(k)) \\ x \text{와 } c \text{ 번째 노드가 다른 클래스에 속할 때} \\ m_i(k+1) &= m_i(k) \end{aligned}$$

i와 c가 다를 때 $\alpha(k)$: 학습률. 0에서 1사이로 시간에 따라 단조 감소

LVQ는 노드의 대표값을 학습 데이터의 확률적 분포에 따라 배치하는 clustering에 바탕을 둔 선별 이론이므로 그림 2(a)와 같이 대표값의 분포가 학습데이터의 확률적 분포를 반영한다. 그러나, 선별 경계면에서 멀리 위치한 대표값은 선별에 기여도가 낮기 때문에 LVQ는 다소 비효율적이라고 할 수 있다. 따라서, 일정한 수의 대표값으로 보다 정확한 선별을 하기 위해서는 그림 2(b)와 같이 노드의 대표값을 경계면 부근에 배치하는 것이 효과적이다.

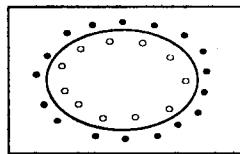
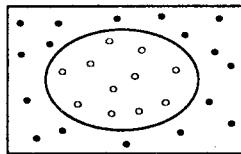


그림 2 (a) clustering을 기반으로 한 classification의 대표값의 분포

그림 2 (b) 경계면을 기반으로 한 classification의 대표값의 분포

그림 3은 2개의 클래스로 구분되는 2차원 입력 문제에 대하여 노드수 200개인 신경 회로망을 LVQ를 써서 학습했을 때의 노드의 대표값의 분포이다.

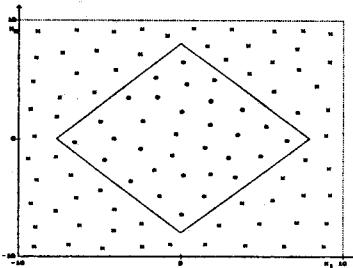


그림 3 LVQ로 학습한 경우 (노드수 200)

3. 경계면 탐색법 II

전력 계통 과도 안정도 해석에서의 안정과 불안정은 제 변수들이 이루는 상태 공간에서의 임계면을 기준으로 결정된다. 선별 문제에서, 코호넨층은 입력데이터와 노드의 대표값과의 거리가 선별의 기준이 되므로 대표값이 경계면으로부터 먼 곳에 위치한 노드를 제외하더라도 선별기의 성능에는 영향을 미치지 않는다. 본문에서 제시한 경계면 탐색법 II는 앞서 언급한 불필요한 노드의 대표값을 경계면 근처의 값으로 대치함으로써 노드의 대표값을 모두 경계면 근처에 분포시킬 수 있게끔 하였다. 따라서 코호넨의 LVQ에 비해서 선별기의 노드를 효율적으로 활용할 수 있다 는 점에서 더 좋은 성능을 기대할 수 있다.

경계면 탐색법 II는 학습시에 대표값 집합(codebook vector set)을 사용하는데, 이는 임시적인 대표값의 저장장소로서 학습이 끝난 후에 코호넨층의 가중치와 문턱값을 결정하는데 사용된다. 학습 시작시에 대표값 집합은 공집합이며 학습이 진행됨에 따라 원소가 추가된다.

경계면 탐색법 II는 세 개의 학습과정으로 구성되며 각 학습과정이 순차적으로 수행된다. 과정1에서는 대표값의 수가 최대 한 개인 N에 이를 때까지 적절한 학습데이터를 대표값 집합에 새로운 원소로서 추가하며, 과정2는 과정1의 결과를 초기 값으로 하여 필요한 대표값의 추가와 다소 불필요한 대표값의 삭제를 병행함으로써 대표값의 수를 N으로 유지한다. 과정3은 상태공간에서 대표값의 분포를 경계면 근처에 고루 분포하게끔 하여 과정2의 결과를 개선한다.

과정1

- 1: 첫번째 학습데이터를 대표값 집합에 포함시킨다.
- 2: 학습데이터 집합에서 다음의 학습데이터를 받아들인다.
- 3: 현재의 학습데이터를 대표값 집합의 대표값을 기준으로 분류하고 아울러 선택된 대표값(winner)과의 거리를 구한다(d_i).
- 단, i 는 선택된 대표값의 번호.
- 4: 현재의 학습데이터가 잘못 분류되었거나 $d_i \geq \sigma$ 면 단계 6으로 진행.
- 5: 학습 데이터 집합에 새로운 데이터가 없으면 경계면 탐색법 II를 끝내고 아니면 단계2로 진행.
- 6: 현재의 학습 데이터를 대표값 집합에 포함시킨다.
- 7: 대표값 집합의 원소의 수가 최대 한계에 이르렀으면 과정2로 진행하고 아니면 단계 2로 진행.

과정1에서, 학습데이터가 현재까지의 대표값으로 잘못 분류되었거나 가장 가까운 대표값과의 거리가 σ 이상일 때 그 학습데이터가 새로운 대표값으로 추가된다. 이는 과정1의 시작점에 미리 결정하는 파라메터이다. 언급한 바와 같이 대표값 집합의 원소의 수가 최대 한계와 같아지면 과정1에서 과정2로 진행한다.

과정2

- 1: 학습데이터 집합에서 다음의 학습데이터를 받아들인다.
- 2: 현재의 학습데이터를 대표값 집합의 대표값을 기준으로 분류한다.
- 3: 현재의 학습데이터가 잘못 분류되었으면 단계 5로 진행.
- 4: 학습데이터 집합에 새로운 데이터가 없으면 과정3으로 진행하고 아니면 단계1로 진행.
- 5: 모든 대표값에 대해 DD_i 를 식(3)을 이용하여 구한다.

$$DD_i = \min_j (\|m_i - m_j\|) \quad (3)$$

여기서, m_i : i번째 대표값

- 6: 현재 학습데이터와 같은 클래스에 속하는 모든 대표값에 대해 ND_i 를 구한다. 단, $ND_i = \|m_i - m_j\| > DD_i$ 를 만족하는 현재 학습데이터와 같은 클래스에 속하는 대표값 k 의 갯수.
- 7: 가장 큰 ND_i 에 해당하는 대표값을 대표값 집합에서 삭제한다.
- 8: 현재의 학습데이터를 대표값 집합에 포함시키고 단계1로 진행.

과정2에서, 경계면에서 먼 대표값을 삭제하고 선별하는데 필요한 곳에 새로운 대표값을 추가함으로써 모든 대표값을 경계면 부근에 배치할 수 있다. 그럼 4는 앞서 LVQ에서의 예에 과정1, 2 단계를 적용하여 대표값을 결정한 결과로서 모든 대표값들이 경계면 근처에 분포됨을 알 수 있다. 그러나, 대표값이 없는 경계면 부근의 입력에 대해서는 잘못 분류할 가능성이 높으므로 대표값을 경계면 근처에 고루 분포시키기 위한 과정3이 필요하게 된다.

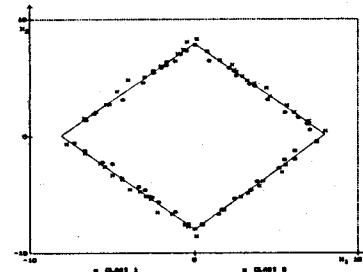


그림 4 과정 1, 2 만 적용한 경우 (노드수 200)

과정3

- 1: 첫번째 학습데이터를 받아들인다.
- 2: 현재의 학습데이터를 대표값 집합의 대표값을 기준으로 분류한다.
- 3: 현재의 학습데이터가 잘못 분류되었으면 단계 5로 진행.
- 4: 학습 데이터 집합에 새로운 데이터가 없으면 경계면 탐색법 II를 끝내고 아니면 다음 학습 데이터를 받아들이고 단계2로 진행.
- 5: 모든 대표값에 대해 DS_i 를 식(4)을 이용하여 구한다.

$$DS_i = \min_{j \neq i} (\|m_i - m_j\|) \quad (4)$$

여기서, m_i : i번째 노드의 대표값

- j : i번째 노드와 같은 클래스인 노드의 번호
- 6: 가장 작은 DS_i 에 해당하는 대표값을 대표값 집합에서 삭제한다.

7: 현재의 학습데이터를 대표값 집합에 포함시키고 다음 학습 데이터를 받아들이고 단계2로 진행.

과정3은 밀접하게 붙어 있는 대표값을 삭제하고 선별하는데 필요한 곳에 새로운 대표값을 추가함으로써 노드의 대표값들을 될 수 있으면 경계면 부근에 고르게 분포시키는 과정이다. 그림5는 앞서의 예에 경계면탐색법II의 전 과정을 적용한 결과이며 그림4와 비교하여 대표값들이 경계면 부근에 고르게 분포된 것을 알 수 있다.

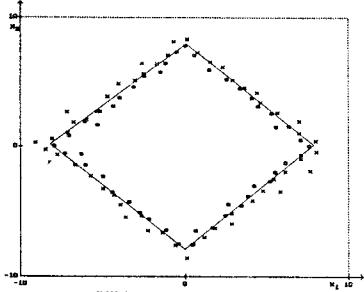


그림 5 과정 1, 2, 3을 적용한 경우 (노드수 200)

4. 사례 연구

4기 6모선 전력계통의 과도안정도 해석에 코호넨의 LVQ 와 본 논문에서 제시한 경계면 탐색법 II를 적용하여 그 성능을 비교하여 보았다. 상정사고는 3상단락을 가정하였으며 신경회로망의 입력변수는 각 발전기의 회전자와 회전자의 상태각과 고장의 지속시간으로 하여 $N+1$ 차 입력을 다음과 같이 구성하였다.

$$x_i = \delta_i(t) - \delta_0(t) \quad i=1, \dots, N_G \quad (5)$$

x_{N_G+1} = 고장 지속 시간

여기서,

$$\delta_0 = \frac{1}{M_0} \sum_{i=1}^{N_G} M_i \delta_i \quad (6)$$

$$M_0 = \sum_{i=1}^{N_G} M_i \quad (7)$$

M_i : i번째 발전기의 관성계수

δ_i : i번째 발전기의 회전자 각

N_G : 발전기 수

참고문헌 [3],[8]에서 제시된 그림 6과 같은 4기 6모선 모의 계통을 대상 전력계통으로 하였으며 선로 데이터, 발전기 데이터는 참고문헌 [3]에 부록 데이터는 표 1에 제시되어 있다.

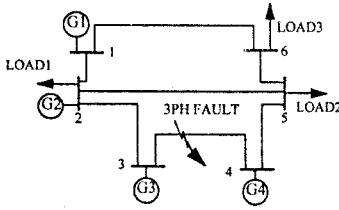


그림 6 4기 계통도

표 1 부하 데이터

| 모선 | 2 | 5 | 6 |
|----------|----|----|----|
| 부하 P(MW) | 20 | 40 | 30 |
| Q(MVAR) | 10 | 15 | 10 |

상정사고는 3, 4번 모선 사이의 선로에 3상단락을 가정하였고 고장제거는 고장선로 양단의 차단기가 동작한 상태로 정의하였습니다. 고장제거시간은 2초 이내에서 임의로 설정하고 각 부하 수준을 표 1의 값에서 0.7 ~ 2.0배로 변화시켜가며 수치적분법에 의하여 안정도 해석을 수행하여 2500개의 학습데이터와 540개의 검증데이터를 수집하였다. 5차의 입력이 사용되었으나 동작점 부근의 안정도 경계면만 관심이 있으므로 노드수는 20, 30, 40개로 비교적 적은 수를 채택하였다. 사례 연구의 결과는 표 2와 같다. 코호넨의 LVQ는 코호넨층의 초기 가중치를 난수로 결정하였기 때문에 10회 실험하여 평균치를 수록하였다.

표 2 안정도 해석 오진율(%)

| 방법 | LVQ | 경계면 탐색법II |
|-----|------|-----------|
| 노드수 | | |
| 20 | 1.67 | 0.93 |
| 30 | 1.46 | 0.56 |
| 40 | 1.33 | 0.37 |

5. 결론

전력계통의 과도안정도 해석 문제와 같이 클래스간의 경계가 분명한 선별 문제에서는 선별기로서 코호넨층의 성능은 노드의 대표값을 경계면에만 분포시킬 때 더욱 향상될 수 있다. 경계면 탐색법 II는 선별의 필요성이 큰 곳에만 노드의 대표값을 분포시키고 선별에 불필요한 노드를 배제시키기 때문에 같은 노드수를 갖고 있는 코호넨층에 있어서 LVQ보다 우수한 선별기를 구현할 수 있다. 제안된 알고리즘의 유용성을 입증하기 위하여 4기 6모선 모의 전력계통에 대해 적용하여 LVQ 방법과 비교해 보았으며 더 좋은 성능을 확인하였다. 사례연구에서는 전력계통의 구성과 고장의 종류를 한정하였으므로 실제용에 적용하기 위해서는 다양한 상정사고에 대하여도 안정도를 해석할 수 있도록 하기 위한 연구가 보완되어야 할 것이다.

REFERENCES

- [1] D.Xia and G.Heydt, "On Line Transient Stability Evaluation by System Decomposition-Aggregation and Higher Order Derivatives", IEEE Trans.on PAS, Vol.102, No.7, pp2038-2046, Jul. 1983.
- [2] Y.M.Park and G.W.Kim, "Power System Transient Stability Analysis Using Nonlinear Transition Matrices and Voltage Derivatives", MS thesis, Seoul Nat'l Univ., Seoul, 1991.
- [3] A.H.El-Abiad and K.Nagappan, "Transient Stability Regions of Multi-Machine Power Systems", IEEE Trans.on PAS, Vol.85, No.2, pp169-178, Feb. 1966.
- [4] F.S.Prabhakana and A.H.El-Abiad, "A Simplified Determination of Transient Stability Regions by Lyapunov Methods", IEEE Trans.on PAS, Vol.94, No.2, pp672-689, Mar/Apr. 1975.
- [5] C.K.Pang, F.S.Prabhakana, A.H.El-Abiad and A.J.Koivo, "Security Evaluation in Power System Using Pattern Recognition", IEEE Trans.on PAS, Vol.93, pp969-976, May/Jun. 1974.
- [6] S.Y.Oh, "A Pattern Recognition and Associative Memory Approach to Power System Security Assessment", IEEE Trans.on SMC, Vol.16, No.1, pp62-72, Jan/Feb. 1986.
- [7] H.Hakimimashadi and G.Heydt, "Fast Transient Security Assessment", IEEE Trans. on PAS, Vol.102, No.12, pp3816-3824, Dec. 1983.
- [8] D.J.Sobajic and Y.H.Pao, "Artificial Neural-Net Based Security Assessment for Electric Power System", IEEE Trans.on Power Sststem, Vol.4, No.1, pp220-228, Feb. 1989.
- [9] K.Ikenono and S.Iwamoto, "Generalization of Transient Stability Solution Using Neural Network Theory", T.IEE Japan, Vol.111-b, No.7, pp723-728, Jul. 1991.
- [10] D.Niebur and A.J.Germond, "Power System Static Security Assessment Using the Kohonen Neural Network Classifier", IEEE Trans.on Power System, Vol.7, No.2, pp865-872, May 1992.
- [11] H.Mori, Y.Tamura and S.Tsuzuki, "An Artificial Neural-Net Based Technique for Power System Dynamic Stability with the Kohonen Model", IEEE Trans.on Power System, Vol.7, No.2, pp856-864, May. 1992.
- [12] T.Kohonen, "Self-Organizing and Associative Memory", 2nd ed., Berlin : Springer-Verlag, 1988.
- [13] T.Kohonen, G.Barna and R.Chrisely, "Statistical Pattern Recognition with Neural Networks: Benchmarking Studies", in Proc.IEEE Int. Conf. Neural Networks, Vol.1 (San Diego, CA), July 24-27, 1988, pp.61 - 68.
- [14] J.A.Kangas, T.Kohonen and J.T.Laaksonen, "Variants of Self-Organizing Maps", IEEE Trans. on Neural Networks, Vol.1, No.1, pp93-99, March, 1990.
- [15] Y.M.Park and G.W.Kim, "Power System Transient Stability Analysis Using Boundary Searching Algorithm", Trans.of KIEE, Vol.44, No.5, 1995.