

인공신경회로망의 대표적 모델과 전력계통적용에 대한 조사연구

고 윤석, 김 호용
한국 전기 연구소

Typical Models of Artificial Neural Networks and Their Application Fields to the Power System

Yunseok Ko, Hoyong Kim
Korea Electrotechnology Research Institute

ABSTRACT

The human brain has the most powerful capabilities in thinking, interpreting, remembering, and problem-solving. Artificial neural network is appeared by scientists who have tried to simulate such a human brain. The artificial neural network has the capability of learning, massive parallelism capability and robustness for disturbance which are necessary for power system application. In this paper, we reviewed the typical topologies and learning algorithms of artificial neural networks which can be used for pattern classification. And we surveyed for the applications of artificial neural network to the power system.

1. 서론

"인간은 어떻게 사고하고 기억하며 문제를 해결하는 것일까?" 많은 과학자들이 이러한 인간의 행동심리 연구에 관심을 가졌으며, 그 결과 음성/영상 인식, 로버틱스, 전문가 시스템 등의 분야에서 인간의 행동심리를 묘사하는 초보적 연구가 이루어졌다. 인공 신경 회로망(Artificial Neural Networks)은 강력한 사고판단 능력을 갖는 인간의 뇌를 모델링하는 것이다. 이들 모델은 병렬로 처리되는 많은 비선형 계산요소들로 이루어지는데, 이들은 마치 생체 신경회로망을 연상케하는 구조로 배열된다. 인공신경회로망은 이러한 구조적 특성에 기인하여 연결주의 모델(Connectionist Model), 병렬 분산 처리 모델(Parallel Distributed Processing Model) 또는 Neuromorphic System 등으로 불리운다. 인공 신경회로망의 연구는 1943년 McCulloch와 Pitts[1]의 신경계 모델링 연구를 기점으로 하여, Hebb[2], Rosenblatt[3]의 초기적 연구를 거쳐, 1980년대 Hopfield[4], Rumelhart와 McClelland, Sejnowski, Feldman, Grossberg[5]의 연구로 급진적인 발전을 이루게 되었다. 특히, 80년대의 연구를 통하여 새로운 신경회로망 구조(Topology)와 알고리즘 그리고 아날로그 VLSI 구현기법[6]이 개발됨으로서, 새로운 적용, 개발 연구를 위한 가능성이 제시되었다. 인공 신경 회로망은 수많은 입력요소들의 대단위 병렬처리가 가능하다. 또한, 학습된 지식 범위 내에서 어느 정도의 에러에 대해 정확하게 해를 찾아낼 수 있는 Robustness를 갖는다. 그리고 새로운 입력 패턴에 대해서는 학습된 지식에 근거하여 출력은 입력 능력을 갖는다. 따라서 주로 대단위 병렬 처리를 필요로 하는 음성/영상 인식 분야에서 활발한 연구가 이루어졌다. 그러나 최근, 데이터의 실시간 고속 처리, 에러에 대한 Robustness 그리고 비선형 운전제어의 적응능력 강화를 위해 인공 신경 회로망의 전력계통에 대한 적용 연구[7-14]가 새로이 계획, 추진되고 있다. 본지에서는 이러한 추세에 따라, 먼저 대표적인 인공 신경회로망의 구조(Topologies)와 학습(Learning) 알고리즘을 검토한다. 그리고 선진 기술국의 전력계통에 대한 적용 연구와 가능영역을 분석한다. 끝으로, 이 검토를 통해, 국가산업의 집대적 에너지원인 전력을 수용가에게 운송하는 전력계통을, 언제나 안전하고 최적으로 운전, 제어 하는데 있어, 인공 신경회로망의 잠재적 가능성을 진단해 본다.

2. 신경(Neuron)의 구조

인간의 뇌는 밀접하게 상호연결된 약 10조개 이상 100조개 정도의 신경 단위세포들로 구성된다. 그리고 각 신경들은 약 1000개 정도의 수지상돌기(dendrite)를 가지며, 100,000조개 정도의 연결부(synapse)에 의해서 상호 연결된다. 그리고 이 신경계는 100 Hz로 동작하며 초당 10,000개 정도의 상호연결(interconnection)을 처리한다.




그림 1-a. 신경세포(Neuron)의 구조

신경세포는 그림 1.a 에 보이는 바와 같이 신경몸체(soma) 또는 cell body), 축삭돌기(axon), 수지상돌기(dendrite) 그리고 연결부로 구성된다. 신경몸체는 연결부를 통하여 많은 다른 신경들로부터 신호를 받아 조합하는 간단한 프로세싱 유니트이다. 축삭돌기는 신경으로부터 전송되는 펄스를 생산한다. 반면에 수지상돌기는 연결부를 통하여 다른 신경들로부터 입력을 받는다. 그리고 연결부는 서로 다른 두 신경체의 수지상 돌기를 서로 연결시켜주는 것으로 학습을 통하여 적절하게 조정되는 연결강도를 갖는 뇌의 기본메모리 유니트이다. 그림 1-b는 신경세포의 모델링을 보인다.




그림 1-b. 신경세포의 모델링

3. 신경회로망과 전문가시스템(기존 컴퓨팅)과의 비교[15]

가. 학습(Learning)

전문가 시스템은 지식이 명확히 규칙(rule)의 형태로 만들어지지만 신경회로망은 교육 예(training set)로부터 학습하여 스스로 규칙들을 발생시킨다.

나. 분산 배치된 연상(Associative) 메모리

신경회로망의 중요한 특징은 정보를 저장하는 방법에 있다. 첫째로 이들은 분산적이다. 즉, 단위지식을 회로망의 모든 기본기억장치(연결 가중치)에 분산 저장시킨다. 둘째로 신경회로망의 메모리는 연상적이다. 즉, 기교육원 신경회로 망에 부분적인 입력이 제공되면 신경 회로망은 기억중에서 그 입력에 가장 가까운것을 찾아냄으로서 완전한(전체) 입력에 대응하는 출력을 발생한다.

다. 고장에 대한 강건성(fault tolerance)

기존의 컴퓨팅 시스템이 메모리에 대한 약간의 피해에도 쓸모가 없게되는데 비하여, 대부분의 신경회로망은 몇개의 프로세싱 유니트들이 고장이 나거나 그들의 연결이 다소 변경되어도 네트워크의 출력은 전체적으로 큰 변화가 없다.

4. 신경회로망 모델의 분류[1-5,16,17]

인공 신경 회로망은 지금까지 주로 음성/영상 인식 분야에서 음성이나 영상의 인식 기(recognizer)로 연구되어 왔으며, 근래에 시스템 제어 분야에서 적용 제어기[18-19]로도 연구되고 있다. 그리고 최근들어 전력계통의 최적한 운전, 제어를 위해 다양한 용도로 연구가 시도되고 있다. 그림 2는 인공 신경회로망의 대표적 모델을 분류하여 표시한 것이다.

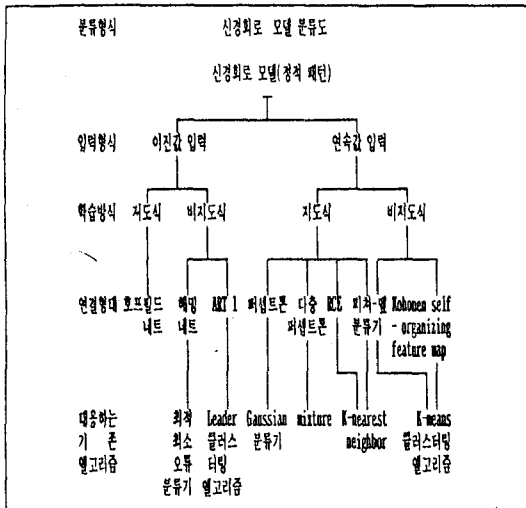


그림 2 인공 신경회로망 모델의 분류도

가. 호프필드 네트워크(Hopfield net)

호프필드 네트워크는 보통 이진입력값을 가지고 이용된다. 이 호프필드 네트워크를 연상메모리로 이용하는 경우, 수렴후의 네트워크를 완전한 직접 복구 메모리로 이용한다. 그리고 분류기도 이용하는 경우는 수렴후의 출력을 한 표준패턴(exemplar)과 정확히 일치하는지를 판별하기 위해서, M개의 표준 패턴들과 비교해야 한다. 이 네트워크의 단점은 연상메모리로 이용할때 저장해서 정확히 기억해 낼 수 있는 패턴들의 수가 극히 제한적이라는 점이다. 이러한 현상은 부류의 수를 입력요소들 수의 0.15배로 제한함으로써 줄일 수 있다. 그림 3은 호프필드 네트워크의 구조를 보인다.

OUTPUTS (Valid After Convergence)

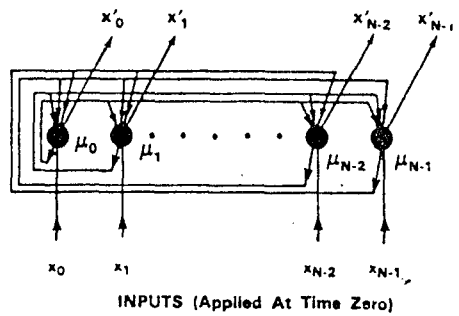


그림 3 호프필드 네트워크의 구조

나. 해밍 네트워크(Hamming Net)

해밍 네트워크는 최적 분류기(optimal minimum error classifier)를 인공 신경회로 망을 이용하여 구현한 것이다. 일반적으로, 2진고정길이 신호(binary fixed-length signal)가 메모리가 없는 대칭채널을 지나는 경우, 전송 비트들이 주어진 확률범위 내에서 불규칙적이고 독립적으로 변하는데, 이러한 통신 문제에 대해서, 해밍 네트워크는 최적분류기로 동작한다. 따라서 먼저 각 부류의 표준패턴들에 대한 해밍 거리를 계산하고 그 다음 최소해밍거리를 가지는 한 부류를 선택한다. 이때 해밍거리는 대응하는 표준 패턴의 비트와 일치하지 않는 입력 비트의 수를 말한다. 그림 4는 해밍 네트워크를 보이는데 상부네트워크와 하부 네트워크로 구성된다.

OUTPUT (Valid After MAXNET Converges)




그림 4 해밍 네트워크의 구조

다. 카펜터/그로스버그 네트워크(Carpenter/Grossberg Net)

이 네트워크는 간단한 순차 리더 클러스터링 알고리즘과 유사한 클러스터링 알고리즘을 구현한다. 리더 알고리즘은 맨 처음 입력을 첫번째 군(cluster)의 표준 패턴으로 선택한다. 그다음 두번째 입력이 첫번째 군의 표준패턴과 비교되며, 만약 첫번째 표준패턴까지의 거리가 임계치보다 작으면 같은 부류로 인식하여 첫번째 군으로 통합시키며, 그렇지 않은 경우 새로운 군의 표준패턴으로 추가한다. 이 처리과정은 모든 입력들에 대하여 반복된다. 따라서 이 네트워크의 군의 수는 시간과 함께 증가하며, 입력 들을 군의 표준패턴들과 비교하기 위하여 이용하는 임계치와 거리에 좌우된다. 이 네트워크는 최대값을 가지는 출력노드들 얻은다음 그 내용 하는 표준 패턴을 입력에 비교하여 임계치 시험을 행하는 매카니즘을 갖는다.

라. 단층 퍼셉트론(Single Layer Perceptron)

단층 퍼셉트론은 이진값 입력이나 연속치 입력을

가지고 이용할 수 있는 네트워크, 개발 초기에는 간단한 패턴들을 인식하기 위한 학습능력을 가정으로서 많은 관심을 받았다. 그림 8은 하나의 입력이 두 부류중 어느부류에 속하는지를 결정하는 퍼셉트론을 보인다. 단일 노드는 가중치가 곱해진 입력요소들의 합을 계산하고 임계치를 뺀다. 그 결과를 hard limiting 비선형 함수를 통하여 통과시켜 +1 또는 -1의 출력값 y를 얻게된다. 이때 결정규칙(decision rule)은 +1 이면 A부류에, -1이면 B부류에 속하는 것으로 한다.

마. 다중 퍼셉트론(Multi-Layer Perceptron)

다중 퍼셉트론은 입력과 출력 노드 사이에 하나 이상의 노드들의 층을 갖는다. 이들 층은 입력과 출력노드들에 직접 연결되지 않은 hidden(숨겨진) 유닛들을 갖는다. 다중 퍼셉트론은 단층 퍼셉트론의 많은 제한들을 극복할 수 있으나 과거 효과적인 학습 알고리즘이 개발되지 않아 이용되지 못했다. 그러나 최근 새로운 알고리즘의 개발로 급격한 연구의 활성화가 이루어지고 있다. 다중 퍼셉트론은 단층 퍼셉트론에 비해 강력한 인식능력을 갖는데 이것은 주로 노드내에 이용된 활성화 함수(activation function)로부터 얻어진다.

1) hard-limiting 활성화 함수

그림 5는 hard-limiting 활성화 함수 가지는 단층, 2층 그리고 3층 퍼셉트론에 대한 각각의 능력을 보인다. 단층 퍼셉트론은 half-plane 판별 영역(decision region)을 구성한다. 2층 퍼셉트론은 다중 퍼셉트론에서 첫번째 층의 노드들로부터 구성되는 half 판별 영역들의 교집합으로부터 거의 임의적인 볼록 판별 영역(convex decision region)을 구성한다. 이들 볼록 판별 영역은 첫번째 층의 노드 수만큼의 면들을 가진다. 3층 퍼셉트론은 망(meshed) 판별 영역과 같은 아주 복잡한 판별 영역을 임의적으로 판별할 수 있다.

STRUCTURE	TYPES OF DECISION REGIONS	EXCLUSIONS ON PROBLEM	CLASSES WITH MESHED REGIONS	MODE GENERAL REGION SHAPES
SINGLE LAYER	HALF PLANE BOUNDED BY HYPERPLANE			
TWO LAYER	CONVEX OPEN OR CLOSED REGIONS			
THREE LAYER	ARBITRARY (Complexity Limited By Number of Nodes)			

그림 5 단층 및 다중 퍼셉트론의 능력

2) sigmoid 활성화 함수

그림 6은 3층 퍼셉트론의 구조를 보인다. 노드내의 활성화 함수로서 sigmoid를 이용하는 3층 퍼셉트론은 지금까지 언급된 hard limiting 활성화 함수에 비해 판별영역이 직선 대신 완만한 곡선에 의해서 결정되기 때문에 훨씬 복잡하고 해석이 더 어려우나, 새로운 오차 역행 전달(error back propagation) 교육 알고리즘을 가지고 학습할 수 있다. 이 알고리즘은 전향연결(feed forward) 퍼셉트론의 실제 출력과 기대 출력 사이의 차이에러를 최소화하는 반복 gradient descent 이용한다. 역행 알고리즘은 일반적으로 좋은 성능을 보이지만, 요구된 global minimum 대신 LMS 비용함수의 local minimum을 가져올 수 있는 gradient 검색 기법을 사용한다. 따라서 이 local minimum의 해를 줄이기 위해서는 추가 히든 유닛들을 채용하거나 가중치를 적용시키기 위해 이용되는 이차항의 값을 낮춘다. 그리고 여러개의 랜덤 가중치들의 집합을 가지고 많은 교육을 시도해 봐야 한다.

마. 코호넨의 연결구조 조직화(Self Organizing) 및

뇌의 시각경로의 중요한 조직원리는 신경들의 배열이 자극되고 있는 자극(stimulus)의 어떠한 실제적 특성을

반영하도록 규칙적으로 배열된다는 점이다. 예를 들어 시각경로의 각 레벨에서 신경들은 각 신경에서 최대응답을 이끌어내는 주파수에 관련 하여 자동적으로 배열된다. 비록 낮은 레벨 조직에 있는 대부분은 미리 결정되어 있지만 보다 높은 레벨에 있는 일부조직은 연결구조조직화(self-organization)를 촉진하는 알고리즘에 의해서 학습을 통하여 만들어진다. 코호넨은 이러한 뇌에서 일어나는 것과 유사한 알고리즘을 제시하였는데, 이를 연결구조 조직화 및 배열이라 한다. 이 알고리즘은 필요한 클러스터의 수가 이용전에 미리 정해지고 교육자료(training data)가 클러스터의 수에 비해 탈때 사용할 수 있다.

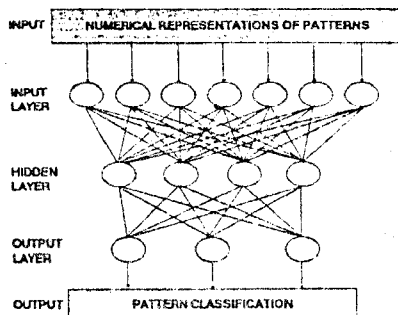


그림 6. 3층 퍼셉트론의 대표적 연결 구조

5. 전력계통 적용 현황 및 가능 분야

신경회로망은 전력계통과 같이 다이내믹하게 변화하는 시스템에서 학습된 지식에 근거하여, 모든 조건에 적용하여 적절한 해를 발생시키는 능력을 갖는다. 또한 수개의 독립 분산된 기억요소들에 의한 연상생성능력에 의해 부적절하고 불충분한 입력패턴에 대해 거의 완전한 해를 얻을 수 있으며 내인위 방법치리가 가능함으로써 대규모화된 전력계통의 실시간 고속 데이터 처리가 가능하다. 전력계통 및 배전계통에 대한 인공지능회로망의 대표적 적용예를 살펴보면 다음과 같다.

가. 동적안전도평가(Dynamic Security Assessment)[8]

의뢰 또는 고장중 전력계통의 안정도 분석은 비선형 미분방정식으로 표시되는 수학적 모델의 안정도 분석으로부터 해석될 수 있다. 고장제거후 시스템의 접근적 안정 영역은 Liapunov의 직접 기법을 이용하여 얻어질 수 있는데, 만약 시스템을 정상상태로 복구시키기 위한 스위칭시에 고장 제거후 시스템의 초기상태가 이영역내에 놓이게 되면 시스템은 안정하게 된다. 임계 고장제거 시간(critical clearing time:CCT)은 시스템의 조건이 이 접근적으로 안정한 영역의 경계에 놓이게 되는 극한 시간치를 말하는 것으로 고장제거후 계통의 동적특성을 해석하는데 있어서 중요한 변수중의 하나이다. CCT는 고장전 시스템 조건(유전 조건, 구성, 시스템 파라미터), 고장종류(타일과 위치) 그리고 고장 제거후 계통 조건의 복잡한 함수로서 해석적 방법을 도입하여 구하는 것이 극히 비합리하거나 많은 변수때문에 매우 복잡하다. CCT는 2가지 방법으로 얻을 수 있다. 첫번째는 의뢰의 영향을 고려한 시스템 방정식을 수치 적분 이용하여 시행착오적으로 구하는 것이며, 두번째는 그 것이 미리 규정된 임계레벨에 이를 때까지 Liapunov 함수값을 체크하여 얻는 것이다. 그러나 두 방법에서 포함되는 적분절차는 on-line 구현관점에서 중요한 문제가 된다. 이러한 문제를 해결하기 위해서, Belhomme[8]는 Liapunov의 에너지 함수로부터 얻어지는 2개 변수이동에 근거할 뿐, CCT 해석을 위한 실제적 PR(Pattern Recognition) 기법을 제안하였다. 그러나 결과의 정확성이 시스템 구조(topology)나 검색전략의 변화에 민감하다. 따라서 새로운 운용조건은 물론 새로운 구조에 적용하여 적절한 해를 얻을 수 있는 해석 기법이 필요하다.

나. 배전계통 커패시터의 실시간 최적 제어[9]

배전계통에 대한 대부분의 무효전력 보상법은 개별부하들이 전체 시스템 부하와 같은 비율로 변화한다고 보는 부하 예측에 근거를 둔다. 커패시터의 최적 제어 문제는 이러한 관점에서 실제로 편리하게 도입되어 완전하게 해결될 수 없다. 그러나 실제적으로 몇개의 부하 그룹들은 시스템의 다른 부하들과 같은 방법으로 일별 부하 곡선에 따라 변화하지 않으며, 따라서 중요한 부하 프로파일이 쉽게 예측될 수 있다. 이러한 문제는 최적 커패시터 설계 알고리즘을 고정하여 실시간적으로 적용함으로써 해결될 수 있다. 그러나 이 접근법은 많은 데이터를 연속적으로 감시해야 하는 어려움과 지나치게 긴 계산시간이 요구되는 문제점을 갖는다. 즉 많은 시간이 요구되는 최적화 절차가 각 부하 프로파일에 대해서 수행되어야 함은 물론 비슷한 부하 프로파일에 대해서도 독립적인 최적화 절차가 요구된다. 따라서 제한된 수의 on-line 측정 데이터만을 가지고 계산상으로도 효율적인 면에서 최적 커패시터 제어 문제를 해결할 수 있는 제어 전략을 개발할 필요가 있다.

다. 신경 회로망 적용 가능 분야

표 1은 전력계통에 대한 기존의 전문가 시스템의 적용분야와 인공신경 회로망의 새로운 적용 가능분야(16-18)를 보이는 것으로, 여러문제 특성에서 성능향상이 기대된다. 앞으로 인공 신경 회로망(ANN)의 적용 연구를 위해서는 문제의 특성을 ANN의 관점에서 보다 정확히 파악해야 할 것으로 본다.

표 1. 인공 신경 회로망의 적용 가능 분야[7-14, 21-23]

문제특성	계통특성	Expert	신경	적용가능분야
계 획	송전/배전	0	0	부하 예측 계획(Planning) 배전 설계(Distribution Design) 보호협조(Protection Coordination)
	송전/배전	0	0	
	배 전	0	0	
	전력/배전	0	0	
감시제어	전력/배전	0	0	Network Reconfiguration 전압/무효전력 제어 전압 제어(VTC-SVC 연계 제어) 최적 커패시터 제어 부하 제어(Load Shedding) Power Plant Control 변전소 제어
	전력 계통	0	0	
	배 전	0	0	
	배 전	0	0	
	전력/배전	0	0	
	전력 계통	0	0	
	전력 계통	0	0	
	전력 계통	0	0	
해 석	송전/배전	0	0	Event Analysis(사고 파행 이용) Contingency Analysis Dynamic Security Assessment 고조파 해석(Harmonic Analysis) Topological Observability Intelligent Alarm Processing State Estimation
	전력 계통	0	0	
	전력 계통	0	0	
	배전 계통	0	0	
	전력 계통	0	0	
	전력 계통	0	0	
	전력 계통	0	0	
진 단	전력/배전	0	0	고장 진단(Fault Diagnosis) 전력 설비 진단
	전력/배전	0	0	

6. 인공 신경회로망의 전망

인공 신경회로망의 성능은 가능한 교육용(Training Set)과 학습시간(Learning Time), 그리고 교육된 많은 지식내에서 실시간으로 주어지는 입력데이터의 정확한 의미할 확인하는 인식능력에 좌우된다. 이러한 관점에서 미국, 일본등 기술 선진국 그리고 국내일부에서 인공 신경 회로망의 구조(Topology)와 학습 알고리즘이 연구되고 있으며, 그 결과가 인공 신경회로망으로 구현되고 있다. 최근, 발표된 Hecht-Neilsen 뉴러커피터[24]는 인공신경회로망 자체의 능력은 물론 이것으로부터 전문가 시스템을 자동생산하는 능력을 갖는다. 그리고 Nester[24]사는 그들이 가장 신뢰적인 신경 회로망이라고 주장하는 NNC를 발표하였는데, 그들은 이 뉴럴 네트워크의 특성을 다음과 같이 주장한다.

먼저, 기존의 뉴럴 네트워크에 비해 가장 빠른 학습과 프로세싱 능력을 갖는다. 예로서, 35개의 features와 106개의 교육 패턴들을 이용한 4개의 인이 부류 학습문제에서 오차 역행 전달(Error Back Propagation) 알고리즘의 29250 sec.의 학습시간에 비해 훨씬 빠른 150 sec.의 학습시간이 요구되 있음을 주장한다. 둘째로, 시스템을 재 설계하지 않고 새로운 features와 클래스를 추가할 수 있는 능력, 그리고 문제의 복잡성을 보다 완화시켜주는 dynamic configuration 능력, 끝으로 보다 효율적인 VLSI 구현을 위한 최소화된 연결성(Minimized Connectivity)을 주장한다. 이 두 예의 특징에서 보이는바와 같이 이들은 보다 실용화에 가까운 진보된 뉴럴 네트워크이다. 인공신경회로망에 대한 전망은 밝다. 무엇보다도 수많은 세월을 거치면서 외부에서 유발되는 자극에 따라 그 특성을 최대로 반영하도록 변화된 인간의 뇌 구조와 특성 이해하고 모델링하고자 하는 많은 관심과 VLSI의 설계기술의 급진전은 머지않은 장래에 보다 완벽하고 실용적인 뉴럴 네트워크의 개발을 가져올 것이며, 그 강력한 능력때문에 다양한 분야에서 적용될 것으로 본다.

참고문헌

- 1) W.S. McCulloch and W.Pitts, "A Logical Calculus of the Ideas Imminent in Nervous Activity", in NeuroComputing(NC).
- 2) D.O. Hebb, "The Organization of Behavior, The First Stage of Perception: Growth of the Assembly", pp 60-78, John Wiley & Sons, New York, 1949.
- 3) R. Rosenblatt, "The perceptron: A Probabilistic Model for Information Storage and Organization in the Brain", Psychological Review 65, pp 386-408, 1958.
- 4) J.J. Hopfield, "Neural Networks and Physical Systems with Emergent Collective Computational Abilities.", Proc. Natl. Acad. Sci. USA, Vol. 79, pp 2554-2558, April, 1982.
- 5) R.P. Lipmann, "An Introduction to Computing with Neural Nets", in V. Vemuri(Ed.), Artificial Neural Networks: Theoretical Concepts, IEEE CSP, pp 36-54, 1988.
- 6) C.A. Mead, Analog VLSI and Neural Systems, Course Notes, Computer Science Dept., California Institute of Technology, 1986.
- 7) M. Aggoune, M.A. El-Sharkawi, et.al, "Preliminary Results in Using Artificial for Security Assessment of Power System", PICA '89, pp 282-288, 1989.
- 8) D.J. Sobajic, Y.H. Pao, "Artificial Neural Net Based Dynamic Security Assessment for electric Power Systems", IEEE Trans. on PS, Vol.1.4, No.1, pp 220-228, Feb. 1989.
- 9) N. Iwan Santoso, Owen T. Tan, "Neural-Net Based Real-Time Control of Capacitors Installed on Distribution Systems", IEEE Trans. on PD, Vol.5, pp 266-272, Jan. 1990.
- 10) M.A. El Shawkawi, R.J. Marks, et.al, "Dynamic Security Assessment of Power Systems Using Back Error Propagation Artificial Neural Networks", Second Symposium on Expert Systems Application to Power Systems.
- 11) H. Mori, H. Umetsu, et.al, "Identification of Harmonic Loads in Power Systems Using an ANN", in Ref. [10].
- 12) H. Tanaka, S. Matsuda, et.al, "Design and Evaluation of Neural Network for Fault Diagnosis", in Ref. [10].
- 13) H. Mori, S. Tsuzuki, "Power System Topological Observation", in Ref. [10].
- 14) Edward H.P. Chan, "Using Neural Network to Interpret Multiple Alarms", IEEE Computer Applications in Power.
- 15) Neural Wareing, Neural Works I, II
- 16) AFCEA Inter. Press, DARPA Neural Network Study, 1988.
- 17) Dennis Feucht, "Pattern Recognition: Basic Concepts and Implementations", Comput Design, pp 57-68, 1977.
- 18) H. Miyamoto, M. Kawato, "Feedback Error Learning Neural Network for Trajectory Control of a Robotic Manipulator", Neural Network, Vol.1, pp 261-265, 1988.
- 19) Dr. L. Gordon Kratt and D.P. Con pagna, "A Comparison of CMC Neural Network and Traditional Adaptive Control Systems", WP 12-2-00, pp 880-889.
- 20) Anderson and Rosenfeld, Neurocomputing: Foundations of Research, MIT Press.
- 21) 23) etc.
- 24) IEEE Expert Vol.5, Num. 1, February 1990.