

신경 회로망의 제어 분야 응용

오 세영

(포항공대 전자전기공학과 부교수)

1. 서 론

향후 20년간 신경 회로망(줄여 신경회로)은 인공지능 방법에 도전하여 자연지능을 가까이 모방하는 형태로 패턴 인식, 사무 및 공장 자동화, 그리고 상업 등 실로 광범위하게 응용될 것이다. 40여년간의 컴퓨터 역사에서 가장 중요하고 실제적인 응용들이 신경컴퓨터(Neurocomputer)로 인해 드디어 서막을 열었다. 신경회로는 massively parallel distributed processing 원리에 의해 임의의 입력과 임의의 출력에 대한 mapping을 수행 하므로 실상은 모든 계산을 대치할 수 있어 그 응용 범위는 실로 무한하다 볼 수 있다.

신경 회로의 제어 분야 응용의 이론적 기초는 이미 60년대에 비록 sequential computer를 사용했으나 적응 학습(Adaptive Learning) 능력을 가진 패턴인식 제어방식¹⁾에서 찾을 수 있다. 또한 자연의 신경 회로들의 주된 기능 중 하나가 생물체의 운동을 제어하는 것이기도 하다. 종래의 제어는 플랜트(Plant) 모델에 의거하여 수학적으로 제어 알고리듬을 설계하여 단계적 계산을 거쳐 제어하는데 반해 신경 회로는 센서를 통해 들어오는 플랜트 상태나 환경에서 오는 Feedback을 본 후 과거의 경험에 비추어 제어 신호를 내보내는 지능제어(Intelligent Control)를 한다. 즉, 종래의 제어가 단계적 프로그램 계산에 의거한다면 신경 회로방식은 훈련(training)을 거친 직관, 즉 패턴 인식에 의거하며 이는 생물계에서 대자연이 택한 방식이기도 하다.

다시 말해 신경 회로는 패턴 인식이 주요기능이고 신

경회로 제어는 이를 제어에 응용한 것이라 염밀하게 말하면 패턴인식제어(Pattern Recognizing Control)라 할 수 있다.

그러나 종래의 제어방식중에도 학습이 가미된 것으로 적응제어(Adaptive Control)가 있으며 Model Reference Adaptive Control (MRAC), Self Tuning Regulator(STR), Gain Scheduling 등이 있으나 이들은 공식유도가 복잡하고, 미지의 파라미터수의 증가에 따라 복잡도가 기하학적으로 증가하며, 광범위한 uncertainty에 대하여 robust 하지 않고, 조건적으로 안정하며 실시간(real-time) 제어에 부적합하다. 인공지능 전문가 시스템 역시 rule이 복잡하고 시간이 오래 걸리는 단점이 있다.

신경 회로의 지금까지의 주요 응용분야는 다량의 계산이 요구되는 문제들, 즉 음성 인식, 영상 인식 등의 패턴 인식이지만 앞으로는 제어분야에서 가장 활발하게 연구되리라 본다. 그 이유는 약 50년에 걸쳐 연구된 수학적 제어이론에 비해 여러가지 중요한 실용적 장점들이 있기 때문이다. 뿐만 아니라 종래의 제어이론으로 제어가 불가능한 시스템을 제어할 수 있거나 또는 더 효과적인 제어를 가능하게 해 주기도 한다. 신경회로 제어의 장점들은 다음과 같다.

- 1) 제어될 플랜트나 그 환경 모델의 불필요 — 복잡한 시스템에 효과적임
- 2) Uncertainty나 플랜트 — 환경의 변화에 적응 가능 — Robustness
- 3) 제어성능의 자체학습에 의한 항구적 개선
- 4) 신경회로의 병렬계산에 의한 고속 실시제어

- 5) 신경회로의 뉴론(Neuron) 수에 무관한 steady-state
로의 수렴속도 때문에 많은 수의 파라미터에 빨리
적용
- 6) 예시에 의해 매우므로 명확한 제어 공식이 불필요
— heuristic rule 사용 가능
- 7) 신경 회로내 정보의 분산 표현으로 인한 fault tolerance
— 일부 회로 소자가 고장나거나 불완전한 또는
잡음섞인 sensor data에 대해서도 graceful degradation
가능
- 8) Sensor Data Fusion이 자연스럽게 처리됨
본 해설에서는 신경회로의 응용분야 중 그리 결과가
많지 않은 제어분야를 소개함으로써 독자들에게 연구
자료들을 제공하고 또한 훌륭히 있는 신경 회로의 제어
응용 논문들을 분류 통일함으로써 이 분야를 조감할 수
있게 한다. 우선 신경 제어방식을 분류한 후 각각에 대
해 설명하기로 한다.

2 신경 제어방식의 분류

신경 회로를 훈련시키는데는 크게 Supervised Learning과 Unsupervised Learning 방법이 있다. 입력과 이에 대해 원하는 출력값 샘플들을 주어 훈련시키는 경우가 Supervised Learning이고, 원하는 출력값을 모를 경우 단지 어떤 보상함수(Payoff Function)를 극대화하는 방향으로 신경 회로의 접속치(Interconnection Weight)를 변화시키는 경우가 Unsupervised Learning이다. 후자의 고전적인 예가 그림1의 소위 Cart-Pole 문제(혹은 Inverted Pendulum, Pole Balancing, Broomstick Balancing 문제라고도 함)이다. 이 문제의 제어 목표는 Cart의 횡

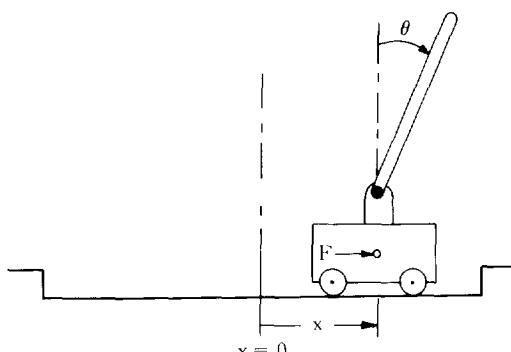


그림1. Cart-Pole System

자표(x)와 Pole의 수직 각도(θ)를 모두 원점으로 유지하는 것이다. 이 문제는 coupled, nonlinear, open loop unstable 시스템의 제어이므로 Michie², Widrow³, Barto⁴ 등 여러 사람들이 Learning Control을 사용하여 풀었다. 신경 회로의 제어구조는 크게 다음과 같이 네개의 유형이 있다.

2.1 Supervised Learning

다음의 세 방식은 Psaltis⁵에 의한 분류이다.

2.1.1 간접 학습방법

그림 2와 같이 원하는 출력을 바꿔가며 플랜트를 움직이는 동안 신경 회로를 역 플랜트의 전달함수로서 훈련시킨다. 이와 같이 훈련되는 신경 회로와 동일한 구조의 신경 회로를 플랜트 앞에 간접 제어기(controller)로 사용한다. 원하는 동작 범위에서 훈련시킬 수 있는 장점이 있는 대신 $\|u-t\|$ 를 극소화한다고 해서 $\|d-y\|$ 가 극소가 되는 것이 아닌 단점이 있다.

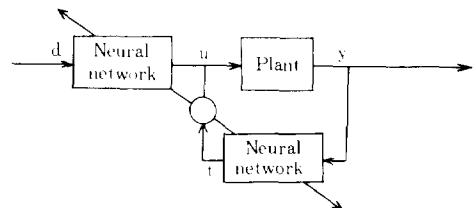


그림2. 간접 학습 구조

2.1.2 일반 학습방법

그림3에서는 플랜트의 제어 입력을 광범위하게 바꿔가며 그 출력으로 신경 회로를 훈련시킨 후 이 신경 회

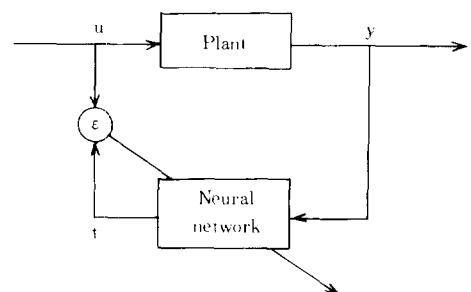


그림3. 일반 학습 구조

로를 제어기로 사용한다. 단점은 원하는 동작 범위에서만 한정된 훈련을 시킬 수 없고 또한 on-line 훈련을 시킬 수 없다는 것이다.

2.1.3 특정 학습방법

그림4와 같이 원하는 입력을 바꿔가며 신경 회로 제어기와 플랜트를 거친 후 나오는 출력을 원하는 입력에 근접하도록 신경 회로 제어기를 훈련시킨다. 원하는 동작 범위에서 훈련이 가능하고 on-line 훈련도 가능하다. 실제로는 전항의 일반 학습방법으로 광범위한 지역에서 훈련시킨 후 특정 학습방법으로 fine-tuning하는 방법을 사용하는 것이 좋다.

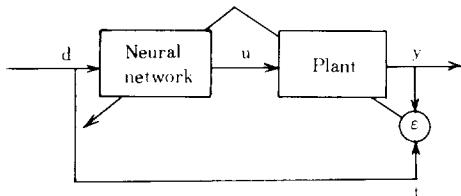


그림4. 특정 학습 구조

2.2 Unsupervised Learning

그림5처럼 신경 회로가 플랜트를 제어하면서 동시에 그때 그때 제어성능을 보상 함수로 받아서 이를 극대화하는 방향으로 자신을 훈련시킨다. 이 방식은 Cart-Pole 시스템처럼 원하는 출력값을 모를 때 매우 유용하다. Barto⁹, Kawato⁶, Sanner⁷ 등의 방법이 이에 해당한다.

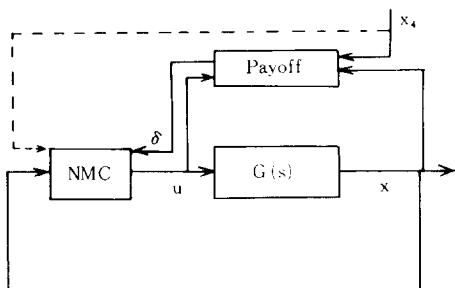


그림5. 보상함수를 극소화하는 Unsupervised Learning 신경회로 제어방식

2.3 Feedback-Feedforward 제어방식

그림6과 같이 신경 회로가 종래의 제어 또는 사람이 직접 제어⁸하는 것을 보며 이를 학습한 후 이를 Feed-forward 제어기로 사용한다. 훈련 후에도 Feedback Loop는 계속 작용한다. Miller⁹와 Kawato⁶의 방법이 이에 해당된다. Josin¹⁰의 방법과 같이 반대로 Feedback Loop에 신경 회로를 쓴 것도 있다.

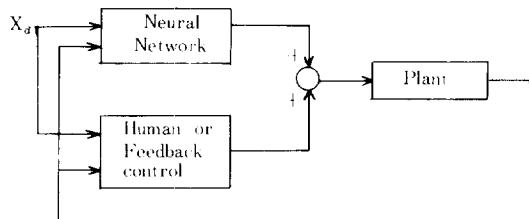


그림6. Feedforward-Feedback 제어방식

2.4 종래 제어방식의 파라미터만 신경 회로로 훈련시키는 방식

Guez¹¹는 그림7과 같이 종래의 PD(Proportional Derivative) 제어의 Gain을 Grossberg 신경 회로를 써서 동적으로 조정하는 방법을 소개했다. 이 방법은 1축 Manipulator의 제어에 응용되었으나 선형 제어의 틀을 벗어나지 못하는 단점이 있다.

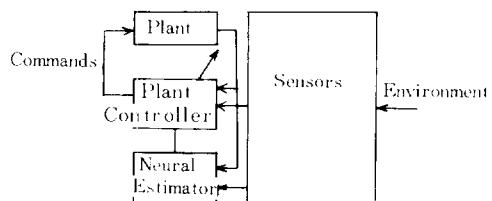


그림7. Guez의 Gain 조정 신경회로 제어기

3 신경 회로의 응용의 세부 해설

필자가 신경 회로의 제어 응용에 관련하여 조사한 논문들은 거의 모두가 simulation이 용이한 간단한 선형 및 비선형 시스템과 Cart-Pole 문제, 로보트의 Kinematic

control, Dynamic control, 시각 제어, Obstacle Avoidance 등에의 응용이었다. 그러나 Barto¹²⁾의 경우는 Landmark Learning 이라하여 간단한 생물체가 동서남북 지표에서 오는 신호와 먹이에서 오는 냄새를 이용하여 먹이를 찾아가는 제어 알고리듬을 신경 회로로써 구현하였다. 사용한 신경회로는 거의 대부분이 Back Propagation feed-forward 회로지만 Ritter는 Kohonen의 Topology-Conserving Map을, Tsutsumi가 Hopfield 회로, Guez가 Grossberg 회로, Miller가 Albus의 CMAC을, Barto가 Associative Search Network을 사용하였다.

3.1 Supervised 제어 모드

3.1.1 Miller의 CMAC 제어 방식

CMAC(Cerebellar Model Articulation Controller)은 Albus¹³⁾가 1975년에 발표한 뇌의 모델로서 다른 신경 회로구조와 판이한 구조를 가지고 있다. 그림8에서 보듯이 CMAC은 $S \rightarrow A' \rightarrow A \rightarrow f$ 의 mapping chain으로 되어 있다. 우선 입력 S 가 A' 테이블의 몇 개의 주소를 선택한 후, 테이블 크기를 줄이기 위해 Random Hash Coding에 의해, 축소된 테이블 A 의 몇 개의 weight를 선택한 후 이를 합산하여 출력을 낸다. CMAC의 혼련은 로보트를 움직이며 그때 그때 가해준 Torque와 출력 Response의 관계를 보면 A 테이블의 weight를 조정함으로써 이루어진다. 이 방식은 실제로 Camera 데이터를 받아 General Electric의 P-5로보트로 컨베이어상의 물체를 추적하는데¹⁴⁾ 응용되었다. 이는 신경 회로로 처음으로 현실적 문제에 적용한 좋은 예이다. 또한 2축 로보트의 dynamic control simulation에도 사용되었다.

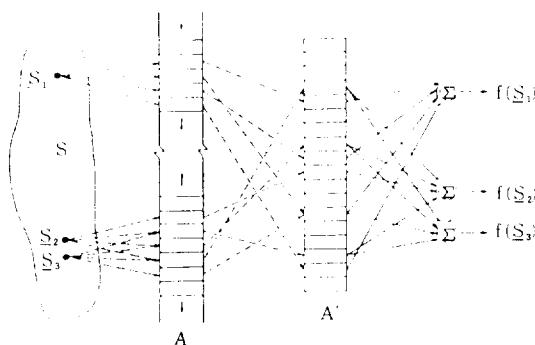


그림8. 기본적 CMAC 구조

3.1.2 Psaltis의 일반 학습, 특수 학습 제어방식

이미 2절에서 설명한 대표적 구조 유형으로서 2차원 극좌표에서 직교좌표로 변환시키는 mapping에 Back Propagation 회로를 사용하였다. 기타의 많은 방법들도 이 유형에 해당된다.

3.1.3 Widrow의 ADALINE 제어방식

Widrow는 60년에 발표한 ADALINE(Adaptive Linear Element)과 그 학습법칙인 Widrow-Hoff 법칙으로 유명하다. 63년에는 ADALINE으로 Inverted Pendulum을 제어했으며 87년에는 pendulum의 상태를 sensor 대신 시각 입력으로 대체하여 같은 문제를 풀었다¹⁵⁾. 이와 비슷한 것으로 88년도 Boston에서 열린 INNS(International Neural Network Society) 학회에서 HNC 회사가 ANZA-Plus와 자사의 독특한 알고리듬으로 Pole-Balancing 문제를 푸는 실험을 보였다.

3.1.4 Guez, Pao, Josin의 Back propagation Feed-forward Layer 제어방식

이들은 모두 Inverse Kinematic 함수의 샘플로써 Back propagation 회로를 훈련시켜 이를 테스트 입력에 대하여 일반화하는 것을 보였다. Guez¹⁶⁾와 Josin¹⁰⁾은 2축 로보트 simulation으로, Sobajic¹⁷⁾은 실제로 INTELLEDEX 로보트의 3,4축을 제어하였다.

3.1.5 Guez의 Human Teacher를 직접 모방하는 제어방식

신경 회로를 훈련시키는 방법으로 종래의 제어방식을 이용하는 것이 있고, 또 사람이 눈으로 보며 직관적으로 제어시키는 방법을 Guez가 설명하였다¹⁸⁾. Cart-Pole 문제를 사람이 직접 푸는 것을 신경회로가 옆에서 보고 배운 후에는 신경회로가 자발적으로 제어하는 방식을 보였다. 이는 산업 현장에서 사람이 하는 일을 신경회로로 대체하는데도 쓰일 수 있으리라 본다.

3.1.6 Ritter의 Topology-Conserving Map을 사용한 로보트의 Kinematic과 Dynamic 제어

Ritter¹⁹⁾는 로보트의 state space를 작은 구역들로 나눈 후 각 구역을 2차원의 뉴론 배치로 mapping한 후 이를 뉴론들이 로보트를 제어하는 알고리듬을 소개했다. 각 뉴론은 담당 구역내의 함수의 Taylor 전개계수를 계산한다. 이 방법이 카메라를 이용한 Inverse Kinematic 제어와 Dynamic 제어에 응용되었다.

3.2 Unsupervised Learning 제어

3.2.1 Barto의 Reinforcement 제어

Barto는 Cart-Pole 시스템의 보상 함수가 Pole이 쓰리지거나 Cart가 벽에 닿을 때만 negative reinforcement가 작용하기 때문에 그전의 순간 순간의 reinforcement를 예측하는 Adaptive Critic Element와 Associative Search Element 신경 회로를 동시에 썼다. 이 두 종류의 뉴론들은 Barto가 고안한 독특한 학습법칙을 가지고 있다.

3.2.2 Kawato의 Feedback Error Learning 제어

이 방법은 세 가지 면에서 다른 방법과 구별된다. 우선 기존의 PD 제어와 신경 회로가 병렬로 연결되어 제어를 한다. 제어의 주체는 처음에는 PD제어이고 그 후 신경 회로가 충분히 학습을 하면서 점차 신경 회로쪽으로 넘어간다. 둘째로 dynamics의 비선형 항들이 미리 계산된 후 뉴론에 의해 결합된다는 것이다. 이로써 뉴론은 선형 계산만 하게 되므로 부담이 줄어든다. 세째로 feedback torque가 오차 신호로 작용하여 back propagation 회로를 훈련시킨다. Kawato는 3축 로보트에 대해 simulation 하였고, Miyamoto는 실제 PUMA 260 로보트에 적용하였다.

3.2.3 Sanner의 Back Propagation 회로를 이용한 최적제어

Sanner는 플랜트 앞의 신경회로 제어장치(Neuromorphic Controller)를 입력 에너지와 위치 오차를 동시에 극소화하도록 훈련시키는 방법을 제안했다. 즉, 신경 회로를 써서 최적화 제어문제를 풀고자 한 것이다. 3층 회로구조를 몇개의 간단한 선형 시스템들과 2축 로보트의 Dynamic 제어에 사용했다.

3.2.4 Elsley의 Inverse Jacobian 제어 방식

Inverse Jacobian 제어는 Cartesian 위치 오차에 Inverse Jacobian을 곱하여 제어명령을 내린다. Elsley는 실제로 로보트를 움직이면서 Back propagation 회로를 훈련시켜 이 Inverse Jacobain mapping을 수행하도록 하였다¹⁹⁾. 이는 2축 로보트의 시각 제어 simulation에 이용되었다.

3.2.5 Tsutsumi의 Hopfield 회로를 이용한 Obstacle Avoidance 제어

Hopfield 회로는 constrained optimization 문제에 많이 이용되고 있다. Tsutsumi는 이를 8축 평면 로보트가

장애물을 피해서 목표에 도달하도록 제어하는데 이용하였다²⁰⁾. 각 link 위치의 함수로써 에너지를 정의하고 이 에너지를 극소화함으로써 여러 constraint를 만족하면서 목표위치에 도달하게 한다.

4 결 론

신경회로의 제어 응용이 세계적인 큰 관심을 가지고 연구된 것은 약 2년으로 그나마 제어 분야의 응용은 패턴 인식의 응용보다 보고된 결과가 적은 편이다. 또한 이 결과들마저 간단한 시스템에 대해 주로 simulation을 통한 실험이 대부분이다. 따라서 이 정도의 미미한 결과를 가지고 신경 회로가 미래의 제어 문제를 다 해결하리라는 기대는 성급하다고 볼 수도 있다. 그러나 현재까지 얻은 결과들은 한결같이 서론에서 나열한 바와 같이 종래의 제어 방식에서 볼 수 없는 너무도 중요한 장점들을 가지고 있다. 종래의 방식으로 풀 수 있는 문제들은 더 효과적이며 효율적으로, 종래의 방식으로 풀 수 없는 문제들은 그 해를 가능하게 할지도 모른다.

신경 회로의 실로 광범위한 응용중에 시스템 제어가 차지하는 중요도는 산업 공정제어 시스템이라는 막대한 시장으로 보아 가장 크다고 본다. 그러나 이와 같은 신경 회로제어가 실제로 보편화되기 위해서는 다음과 같은 연구가 선행되어야 한다.

- 1) 신경 회로의 경제적 구현 방식 — Analog, Digital, Optical 회로
- 2) 빠르고 효율적인 학습 알고리듬
- 3) 사용하기 쉬운 software 개발
- 4) 신경 회로의 응용분야 개발

신경 회로는 이런 시스템을 가장 효과적으로 제어하는 방식일 것이다. 이로 볼 때 앞으로 20년간 혁신하는 산업 제어 시스템은 차차 신경 회로제어로 부분적 또는 전체적으로 대체되어야 한다. 물론 그에 앞서 기존의 시스템과 신경 회로방식을 어떻게 효율적, 경제적으로 결합하느냐하는 system engineering 연구가 선행되어야 함은 물론이다.

참 고 문 헌

- 1) J.M.Mendel and K.S.Fu, *Adaptive Learning and Pattern Recognition Systems*, Academic Press, 1970.

-
- 2) D.Michie and R.A.Chambers, "BOXES : An Experiment in Adaptive Control," Machine Intelligence 2, Edinburgh : Oliver and Boyd, pp.137-152, 1968.
 - 3) B.Widrow, "The Original Adaptive Neural Net Broom-Balancer," the IEEE International Symposium on Circuits and Systems, pp.351-357, IEEE, May 1987.
 - 4) A.G.Barto, R.S.Sutton, and C.W.Anderson, "Neuron-like Adaptive Elements That Can Solve Difficult Learning Control Problems," IEEE Trans. Systems, Man, and Cybernetics, Vol.SMC-13, No.5, September 1983.
 - 5) D.Psaltis, A. Sideris, and A.A.Yamamura, "A Multilayered Neural Network Controller," IEEE Control Systems Magazine, pp.17-21, April 1988.
 - 6) M.Kawato, Y.Uno, M.Isobe, and R.Suzuki, "Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics," IEEE Control Systems Magazine, pp.8-16, April 1988.
 - 7) R.M.Sanner and D.L.Akin, "Neuromorphic Regulation of Dynamic Systems Using Back Propagation Networks, Poster Session, First Annual INNS Meeting, Boston, 1988.
 - 8) A.Guez and J.Selinsky, "A Neuromorphic Controller with a Human Teacher," Proc. of the IEEE International Conference on Neural Networks, pp.595-602, July 1988.
 - 9) W.T.Miller, F.Glanz, and L.G.Kraft, "Application of General Learning Algorithm to the Control of Robotic Manipulators," The International Journal of Robotics Research, pp.84-98, Summer 1987.
 - 10) G.Josin, D.Charney, and D.White, "Robot Control Using Neural Networks," Proc. of the IEEE International Conference on Neural Networks, pp.625-631, July 1988.
 - 11) A.Guez, J.L.Eilbert, and M.Kam, "Neural Network Architecture for Control," IEEE Control Systems Magazine, pp.22-24, April 1988.
 - 12) A.G.Barto and R.S.Sutton, "Landmark Learning : An Illustration of Associative Search," Biological Cybernetics, 42, pp. 1-8, 1981.
 - 13) J.S.Albus, "Mechanisms of Planning and Problem Solving in the Brain," Mathematical Biosciences, 45, pp.247-293, 1979.
 - 14) W.T.Miller, "Sensor-Based Control of Robotic Manipulators Using a General Learning Algorithm," IEEE Journal of Robotics and Automation, pp.157-165, Vol.RA-3, No.2, 1987.
 - 15) V.V.Tolat and B.Widrow, "An Adaptive Broom Balancer" with Visual Inputs," Proc. of the IEEE Conference on Neural Networks, pp.641-674, 1988.
 - 16) A.Guez and Z.Ahmad, "Solution to the Inverse Kinematic Problem in Robotics by Neural networks," Proc. of the IEEE Conference on Neural networks, pp.617-624, 1988.
 - 17) D.S.Sobajic, J.J.Lu, and Y.H.Pao, "Intelligent Control of the INTELLEDEX 605T Robot Manipulator," Proc. of the IEEE Conference on Neural Networks, pp.633-640, 1988.
 - 18) H.J.Ritter, T.M.Martinez, and K.J.Schulten, "Topology-Conserving Maps for Learning Visuomotor Coordination," The First INNS Meeting, Boston, 1988.
 - 19) R.K.Elsley, "A Learning Architecture for Control Based on Back-Propagation Neural Networks," Proc. of the IEEE Conference on Neural Networks, pp.587-594, 1988.
 - 20) K.Tsutsumi and H.Matsumoto, "Neural Computation and Learning Strategy for Manipulator Position Control," Proc. of the IEEE International Conference on Neural Networks, pp.525-534, 1987.