

I. 서 론

CMAC 신경회로망 기반 로보트 제어기술

신경회로망은 학습 능력과 실시간 계산능력 및 보간능력 등 장점이 많으므로 여러 분야에서의 응용 잠재력이 큰 것으로 알려져있다. 그러나 로보트 제어에 응용처럼 입력이 다차원인 문제에 대해서 일반적인 신경회로망(다중신경망)을 사용할 경우, 학습의 어려움 때문에 실용적 응용에 성공 사례가 많지 않다. CMAC(Cerebellar Model Articulation Controller) 신경회로망은 사람의 소뇌를 모방한 신경회로망으로서 CMOS 칩에 의한 구현이 가능하고 학습이 타 신경회로망에 비해 월등히 용이하기 때문에 로보트 제어에 성공적으로 적용한 사례들이 많다. 이 기고에서는 CMAC 신경회로망의 소개와 이를 이용한 주요 로보트 제어 기술들에 관하여 기술한다.

1970년대 Albus^[1-4]에 의해 개발된 CMAC 신경회로망은 빠른 학습 속도와 하드웨어 구현의 용이성 등의 특성 때문에 학자들의 관심이 점차 높아지고 있는 신경회로망이다. Albus 이후에도 많은 학자들이 CMAC을 연구하여 이론을 발전시켰다. Wong과 Sideris^[8]는 CMAC 학습이 훈련 데이터 집합에 대하여 임의의 정확도 이내로 항상 수렴함을 증명하였고, Cotter와 Guillerm^[9]은 CMAC이 구조적으로 Kolmogorov 이론으로부터 유도된 신경회로망과 유사함을 보였다. 한편, Moody^[12]는 CMAC의 단점인 block화 현상을 해결하기 위해 다중 해상도 계층을 갖는 CMAC의 학습 메카니즘을 연구하였고 Lane 등^[13]은 유연한 감응영역(receptive field)을 갖는 CMAC을 연구한 바 있다. 또한 CMAC의 block화 현상을 완화시키기 위해서 퍼지논리 개념을 도입하는 연구들도 수행되었다 Ozawa 등^[14]은 인간의 의도를 나타내는 퍼지 추론 규칙을 구성하기 위해서 CMAC-fuzzy 시스템을 제안하였다. Jou^[15]는 적용 퍼지 제어기의 개념적 연구를 제안하였고, Nie와 Linkens^[16]는 실시간으로 교사신호가 필요한 자기 학습 특징을 갖고 다변수 적응제어기로 작용하는 퍼지화된 CMAC(FCMAC)을 제안하였다.

金 炯 烨, 崔 鍾 淳*
全北大學校 制御計測工學科
*浦港產業科學研究員

CMAC 신경회로망의 응용 연구 사례들도 많이 발표되었는데 Lin과 Kim^[6]은 CMAC 기반 적응 비판학습(adaptive critic learning)을 제안하여 장시간에 걸친 제어 행위에 대한 종합 평가 값만을 이용하여 이전의 부적절한 제어를 교정 학습케하였다. Kraft 등^[17]은 CMAC을 이용한 신경회로망 제어기를 기준 적응 제어기인 STR(self-tuning regulator) 및 MRAC(model reference adaptive control) 와의 비교연구를 수행하였다. CMAC 응용분야 있어서 두드러지게 기여한 사람은 Miller 였다. 그는 CMAC의 로보트 제어에의 성공적 응용에 대한 많은 사례를 발표하였을 뿐 아니고^[18-20] 패턴인식 및 신호처리에 대한 응용가능성을 보였으며^[7], 전용의 CMOS logic을 이용하여 CMAC을 설계하고 구현하였다^[10].

이 기고에서는 CMAC 신경회로망에 대한 기본적인 내용과 CMAC을 이용한 로보트 제어기술 중 대표적인 기술들을 소개하고자 한다.

II. CMAC 신경회로망

CMAC은 인간의 소뇌를 단순 모델링한 신경회로망으로서 그림 1은 Albus가 제안한 모델이다. 상위레벨 명령센터 또는 센서로부터의 정보는 양자화되고 개념적 메모리(conceptual memory)에 대한 주소로 사용된다.

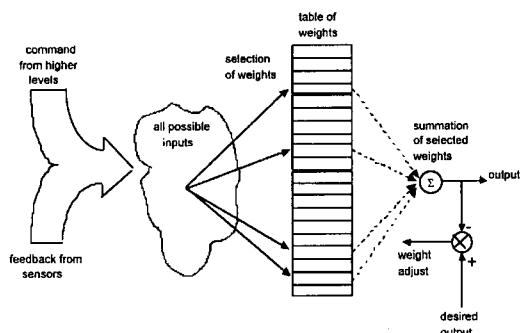


그림 1) Albus의 CMAC 모델^[1]

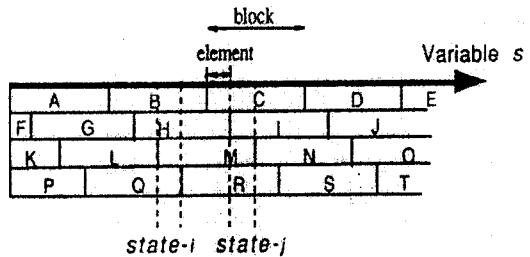


그림 2) 단일 입력변수에 대한 CMAC의 block 분할

CMAC에서 상태에 대한 정보는 메모리에 분산되어 저장되고 주소의 key로써 상태변수를 이용하여 검색하게 된다. 데이터 검색을 위해 상태변수들은 중간변수들로 사상(mapping)된 다음 출력 값을 검색하기 위해 물리적 메모리 주소로 사상된다.

그림 2에 보인 것처럼 상태변수 s 는 block이라는 여러 개의 영역으로 분할되고 각 block은 element라 하는 부 영역으로 분할된다. Block들은 시작하는 위치에 따라 그 경계 위치가 달라지는데 이렇게 block 시작 위치의 다양성에 따라 여러 층으로 나눈다. 각 층에서의 각 block은 인식명(identification name)을 할당받는다. 그러므로 양자화된 하나의 상태는 여러개의 층에 속하는 block명의 집합으로 특징 지울 수 있다. 예를 들면, 그림 2에서 상태 i 와 j 는 각각 {B, H, M, Q}와 {C, I, M, R}에 의해서 특징 지워진다. 이 block 명들에는 램덤하게 선택된 메모리를 하나씩 할당하여 정보를 저장한다. 그런데 각 상태는 여러 개의 block들을 포함하고 있으므로 정보는 그 상태를 구성하고 있는 block들의 메모리에 분산 저장한다.

$f(i)$ 를 상태 i 에 대한 CMAC의 출력이라 하고 I 를 상태 i 를 위한 block 명, $m(I)$ 를 block I 에 해당하는 메모리의 값이라고 하면, 상태 i 에 대한 값 $f(i)$ 는

$$f(i) = \sum_I m(I_i) \quad (1)$$

로 계산된다. 한편 상태 i 에 학습시켜야 할 목표 값을 g_0 라고 하면 g_0 와 $f(i)$ 의 차이 값에 비례하는 갱신량 δ 가 다음과 같이 계산된다.

$$\delta = \eta(g_0 - f(i)) \quad (2)$$

여기서 η 는 [0 1]의 값을 갖는 학습 계수이다. 그런데 상태 i 에는 다수의 메모리가 관여되어 있으므로 이 메모리의 수를 N_e 라고 하면 상태 i 를 구성하고 있는 개개의 메모리는 다음 식과 같이 δ 값을 N_e 로 나눈 값 δ' 에 의해 갱신된다.

$$\delta = \eta \frac{(g_o - f(i))}{N_e} \quad (3)$$

III. CMAC의 로보트 제어에 응용

1. CMAC의 영상 기반 로봇제어에 응용

Miller는 CMAC 학습을 이용한 영상기반 로봇제어 방법을 발표하였다^[18]. CMAC 모듈을 기반으로 한 학습제어 시스템은 다중 감각입력과 다중 명령 변수를 갖는 복잡한 시스템 제어에 적응 가능하도록 제안되었다. 그림 3와 같이 카메라가 장치된 로보트 팔로서 컨베이어 상을 이동하는 물체를 집어내고 추적하는 것이 목표이다. 이를 위한 페루우프 제어 장치의 블럭도는 그림 4와 같다. 이 제어장치에서 trajectory planner는 각 제어주기의 시작 시점에서 원하는 작업에 요구되는 센서의 출력을 결정해 준다. 이것을 센서 출력의 목표 값이라고 한다. CMAC은 센서의 출력이 이 목표 값과 일치할 수 있도록 학습된다. 이를 위해서 목표 벡터 s_d 는 로봇의 상태 센서와 현재의 제어상태 측정 센서의 출력이 결합되어 구성된다. 목표 벡터

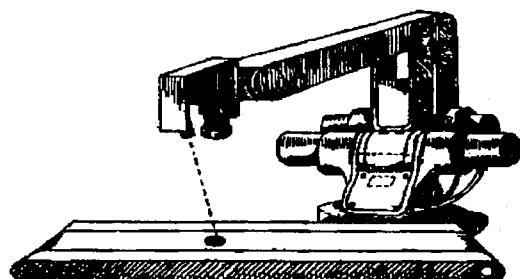
s_d 는 CMAC에 인가되어 출력 $f(s_d)$ 가 계산되고 이 값은 로보트를 명령하는데 이용된다. $f(s_d)$ 에 의해서 로보트를 동작시킨 후, 측정된 센서의 출력 벡터와 작업의 상태 벡터를 결합시켜 만든 벡터를 s_o 라고 하면, 이 로보트는 $f(s_d)$ 를 인가할 때, 출력이 s_o 가 되는 시스템임을 의미한다. CMAC은 이 시스템의 역 동력을 학습한다. 즉 CMAC은 로보트의 상태 s_o 를 입력으로 인가할 때 출력으로 $f(s_d)$ 를 제시할 수 있도록 학습된다. 그런데 학습이 충분히 이뤄지지 않은 상태에서의 CMAC은 s_o 가 인가될 때 목표값 $f(s_d)$ 와는 다른 $f(s_d)$ 를 출력한다. CMAC은 $f(s_d)$ 와 $f(s_d)$ 가 동일하게 될 때까지 이

들의 차를 학습한다. 여기서 목표 값 $f(s_d)$ 를 g_o 라고 하면 CMAC의 학습 갱신량 δ 은 다음과 같다.

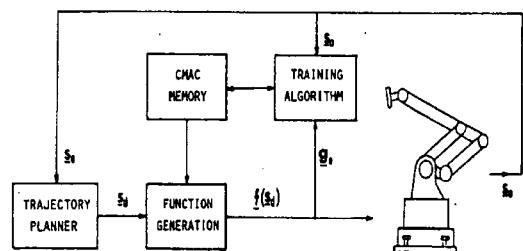
$$\delta = \beta \frac{g_o - f(s_o)}{c} \quad (4)$$

만일 CMAC 메모리가 바람직한 값(모든 상태에 대하여 0)으로 초기화되지 않는다면 로보트가 부적절한 동작을 하게 되고 이 동작은 다시 관측되고 학습되기 때문에 양호한 제어 시스템 성능을 얻을 수가 없다. 그러므로 대부분의 학습 시스템에서와 같이 제어기가 시스템을 학습하고 성능을 개선시킬 수 있도록 하는 초기성능을 제공하기 위해서 로보트에 랜덤한 입력을 가하거나 CMAC 제어기와 별별로 위치한 고정이득 선형 궤환 제어기를 이용한다.

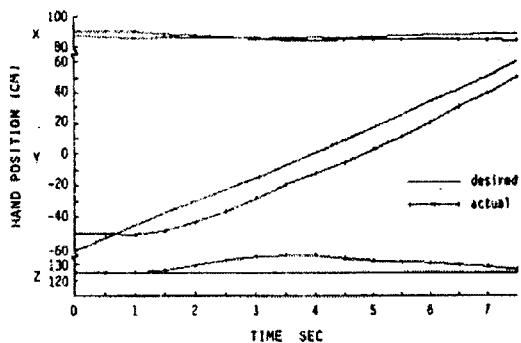
Miller는 컨베이어 벨트 위를 움직이는 물체를 인식하고 이를 로보트 팔이 추적케 하는 실험을 수행하였다. 그림 5는 물체가 컨베이어 벨트 상을 움직이는 실험 결과로서 물체와 로봇 팔 위치 궤적을 보여준다. 그림 5(a)는 첫 번째 시도할 때의 궤적이고 5(b)는 10 번의 학습 실험 후의 궤적이며 10 번의 학습 실험 후에는 큰 오차 없이 로보



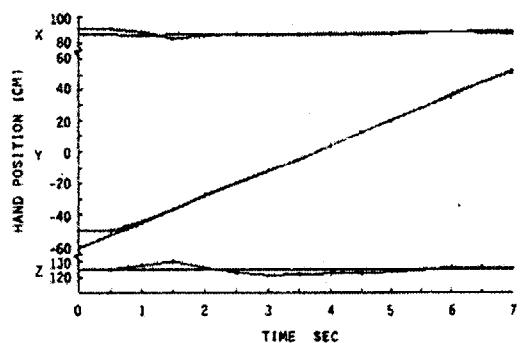
〈그림 3〉 영상 기반제어에 사용된 로보트 시스템



〈그림 4〉 CMAC 기반 학습제어 시스템의 블록도.



(a) 첫번째 실험 결과



(b) 10번 실험 후의 결과

(그림 5) 로보트 팔의 목표 위치와 실제 위치
(컨베이어 벨트 상의 물체 추적 실험)

트 팔이 물체를 잘 추적함을 알 수 있다.

2. 역 동력학 학습에 의한 로보트 제어

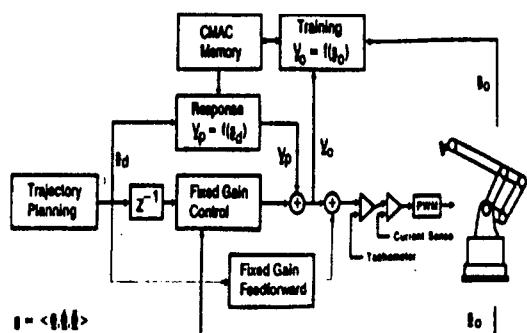
로보트의 구동 회로를 포함한 다축 매니퓰레이터가 다음의 일반적인 방정식으로 표현되는 전자기계시스템이라 하자.

$$V = m(\theta, \dot{\theta}, \ddot{\theta}) \quad (5)$$

여기에서 V 는 액츄에이터 구동 벡터이고, $\theta, \dot{\theta}, \ddot{\theta}$ 는 각각 조인트 위치, 속도 및 가속도 벡터이며, m 은 로보트 역 동력학과 액츄에이터 구동 특성을 기술하는 비선형 함수를 나타낸다. 만일 함수 m 을 알고 있다면 식 (5)는 원하는 궤적을 따라가는데 필요한 조인트 구동 값을 계산하는데 이용할 수 있고, 추정된 구동 값을 케이블 제어기와 병렬로 전향 항으로 사용될 수 있다. 그러나, 보통의 로보트

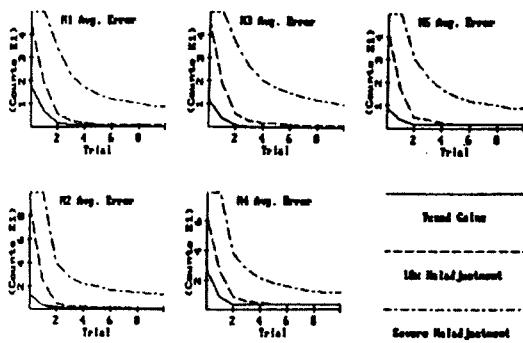
에 대한 역동력학 함수 m 은 정확하게 결정하기가 어렵고 실시간 제어기의 일부분으로 구현하기는 더욱 어려운 복잡한 연산을 포함하고 있다. 그러나 신경회로망을 이용하면 m 이 학습에 의해 쉽게 구해질 수 있게 된다. 그림 6은 이를 위한 제어기 구조를 보여준다. 이 제어기의 특징은 역동력학 학습용 CMAC 신경회로망과 고정이득 제어기가 병렬로 연결되어 상호 보완 제어할 수 있는 구조이다.

궤적 planner는 각 제어주기 초기에 이상적인 궤적을 작성하여 다음 제어주기에서 원하는 시스템 상태 s_d 를 결정해야 한다. 원하는 다음 상태 s_d 는 $f(s)$ 를 만들어내는 CMAC 신경회로망으로 보내진다. 결과 벡터 값은 로보트가 상태 s_d 가 되도록 하기 위해 필요한 액츄에이터 구동 추정 값이며 이 벡터는 고정 이득오차 케이블 제어기의 출력과 합해져서 로보트 액츄에이터 구동기에 보내진다. CMAC의 학습은 CMAC의 출력과 고정이득 제어기의 합성 벡터 Y_o 를 목표값으로하고 이 값이 로보트에 인가된 후 관측된 센서의 출력 s_o 를 입력으로 하여 로보트의 제어가 진행되는 동안 on-line으로 학습된다. 여기서 CMAC 입력 벡터 s_o 는 벡터 $\theta, \dot{\theta}$ 및 $\ddot{\theta}$ 로부터 형성되고, CMAC 함수 $f(s)$ 는 매니퓰레이터 함수 $m(\theta, \dot{\theta}, \ddot{\theta})$ 에 해당된다. 시스템이 초기화되었을 때, 연결강도는 $f(s_d)$ 가 원하는 상태에 대하여 null 벡터이고 로보트에 대한 명령 벡터 집합이 고정이득 제어기의 출력과 같도록 모두 zero가 된다. CMAC 신경회로망이 연속적인 제어 주기를 따라 계속 훈련됨에 따라 CMAC 함수 $f(s)$ 는 상태공간의 특정 영역에서의 시스템 역 동력학 전달함수 $m(\theta, \dot{\theta}, \ddot{\theta})$ 의 근사화를 실현할 수 있다. 실제의 로보트 작업시 로보트의 원하는 상태가 이전에 관측된 상태와 유사한 상태공간 영역에 있다면, CMAC 신경회로망의 출력은 요구되는 실제 액츄에이터 구동값과 유사하게 될 것이다. 결과적으로 상태오차는 작아질 것이고 CMAC 신경회로망은 고정이득 제어기로부터 로보트 제어 역할을 인계 받게된다. 제어기가 얻는 경험이 많을수록 CMAC의 출력 $f(s)$ 는 상태공간의 일정한 영역 내에서 시스템의 전달함수를 더욱 잘 근사화하게 된다.



〈그림 6〉 역동력 학습 제어기의 블럭도

그림 7은 GE사의 P-5 로보트를 이용하여 원을 추적하는 실험 결과로서 로보트의 각 조인트의 에러를 나타내고 있다. 각 그림에서의 3 개의 그래프는 3 종류의 고정 이득 제어기를 사용할 경우의 학습 성능이다. 여기서 실선은 최적의 전향 이득 제어기를 사용할 경우이고 점선은 최적 제어기의 10 % 이득만을 사용한 경우이며, 1 점 쇄선은 전향 이득 제어기를 사용하지 않은 경우이다. 어느 경우나 학습이 진행됨에 따라 오차가 줄어들게 됨을 보여 주며 또한 전향 이득제어기를 사용할 경우가 사용하지 않은 경우에 비해 나은 학습 성능을 보여준다.



〈그림 7〉 4 조인트에 대한 위치 에러

제시된 결과는 충분한 메모리를 가질 경우에 적은 횟수의 학습으로 작은 오차로 수렴함을 보여준다. 일반적으로 고정이득 제어기를 잘 조정하게되면 양호한 성능을 얻을 수 있는 반면, 학습이 없는 제어 시스템 성능은 제어기 부조정(malad-

justment)에 상대적으로 매우 민감함을 알 수 있다. 반면에, 학습을 갖는 제어 시스템은 심각한 파라미터 부조정이 있더라도 튜닝된 고정이득 제어기에 비해 제어오차가 적게됨을 알 수 있다.

이 연구에서 제시된 학습 제어기는 산업용 로보트 매니퓰레이터 제어에 실제 응용할 수 있다.

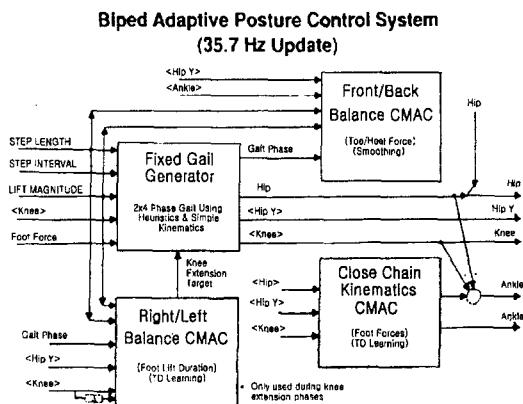
3. CMAC의 2 족 보행 로보트에 이용

CMAC 신경회로망은 동적 균형을 갖는 2족 보행문제(biped walking problem)에 적용할 수 있다. 이를 위해서 간단한 gait oscillator, PID 제어기 및 신경회로망 학습의 hierarchy를 기반으로 제어기를 구현할 수 있다. 이 제어기를 이용한 학습제어가 진행됨에 따라 제어 성능은 점차 발전하게 되므로 다른 제어기에서 요구되는 kinematic 모델이나 동적 모델이 필요 없게된다.

실험 대상이 되는 2 족 보행로보트는 그림 8과 같이 leg당 각 hip에 두 개, 각 knee에 하나, 그리고 각 ankle에 두 개 등 다섯 개의 회전 조인트를 갖고 있다(전체 10개의 액츄에이터). 궤환은 10개의 조인트 위치 센서와 각 발의 바닥에 4개의 힘 센서에 의해서 얻어진다(전체 18개의 센서). 제어기의 목표는 서있는 자세에서 걷는 동작으로 변화하는 동안 넘어짐 없이 short steps을 연결하여



〈그림 8〉 2 족 보행 로보트



〈그림 9〉 2 쪽 보행로보트 제어 시스템의 블록도

Welking 할 수 있는 on-line 학습 제어기술을 학습하는 것이다.

이를 위한 제어기는 그림 9에 보인바와 같이 3 개의 CMAC 신경회로망과 간단한 gait oscillator 및 액츄에이터 레벨 PD 제어기로 구성된다.

제어기에서 Fixed Gait Generator 모듈은 상위의 감독제어 레벨로부터 전체 스텝 길이, 전체 스텝 간격 및 최대 foot lift 크기에 대한 상수 값을 받은 후, 반복적으로 8 gait phase 동안 각 제어주기에 대하여 hip과 knee의 위치 기준명령을 발생시킨다. Right/left Balance CMAC(CMACrl) 신경회로망은 해당하는 발을 올리기 위하여 측방향의 momentum을 충분히 얻을 수 있도록 knee의 확장 값을 예측하는데 이용된다. 이 CMACrl은 그 스텝에 대하여 원하는 foot lift 지속기간과 관측된 foot lift 지속기간 사이의 차이를 기반으로 각 스텝 후에 훈련된다. 이를 위해서 CMACrl은 각 개별 제어주기 후에 temporal difference 학습 방법^[21]을 이용하여 훈련된다.

또한 로봇의 기구학을 학습하기 위해 이용되는 Closed-Chain Kinematics CMAC(CMACK) 신경회로망은 각 발의 바닥이 균형된 힘을 갖도록 하며 발 바닥이 지면과 항상 평행을 유지 할 수 있도록 하기 위해서 frontal 및 lateral ankle 회전에 적합한 위치를 예측하여 제시한다. 이 신경회로망의 훈련 규칙은 다음과 같다. 만일 두 발바닥에 인가되는 힘의 중심이 서로 반대쪽(왼쪽 발바닥의 원편

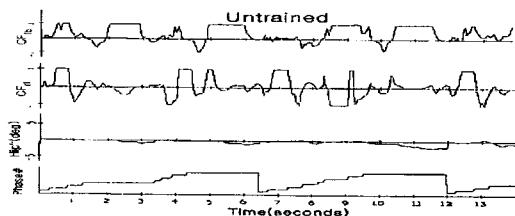
과 오른쪽 발바닥의 오른편)에 치우쳐 있다면 CMACK는 발바닥을 더욱 평행하게 만드는 두 Ankle-Y 축이 반대로 회전하도록 훈련된다. 만일 두 발바닥의 힘 중심이 모두 오른쪽에 치우치거나 왼쪽에 치우쳐 있다면 로봇을 기울이는 효과가 있도록 두 Ankle-Y 축이 같은 방향으로 회전하여 바로잡을 수 있도록 훈련된다. 만일 두 발의 힘 중심이 발의 반대편 front/back 가장자리에 근접하다면 CMACK는 발이 평행이 될 수 있도록 ankle 축이 반대쪽으로 회전하도록 훈련된다. 걷는 동안, CMACK는 양발이 바닥에 접촉할 때마다 발의 힘 중심과 발바닥의 중심과의 오차 신호를 기반으로 훈련된다. 한쪽 발만 바닥에 접촉할 때, CMACK는 temporal difference 학습을 이용하여 훈련된다. 또한 CMACK는 들어올린 발이 바닥에 직각으로 내려오도록 정확한 ankle 방향을 예측하는데 이용한다.

Front/back Balance CMAC (CMACfb) 신경회로망은 standing, swaying 및 walking 하는 동안 front/back 균형을 제공하기 위해 이용된다.

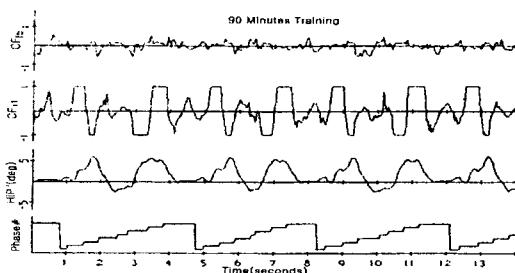
이 제어기를 이용한 2 쪽 로보트의 제어실험 결과는 그림 10과 같다. 그림 10(a)와 10(b)는 학습되지 않은 경우와 90 분간의 학습후의 제어 결과를 보여주는 그림으로서 2 쪽 로보트로부터 검출된 전후방향을 위한 힘(CF_{fb}), 좌우 방향을 위한 힘(CF_{ri}), 과전후 방향의 균형유지를 위한 CMAC_{fb}의 출력을 보여주며 hip 각도 Hip"와 8 보 진행 주기동안의 Phase #를 나누고 있다. 그림 10 (a)에서 CF_{fb} 가 자주 +1 혹은 -1에 이르는 것은 모든 힘이 발바닥의 앞에 위치한 힘 센서에 가해지거나(+1의 경우) 뒤에 위치한 센서에 가해지는 경우(-1)로서 학습 초기에는 앞뒤 방향의 균형을 자주 잃게됨을 의미한다. 그림 10(b)에서의 CF_{fb} 값이 +1, 혹은 -1에 가까운 값을 갖지 않음은 학습 후, 전후 방향의 균형이 유지되고 있음을 나타내고 있다. 좌우 방향을 위한 힘(CF_{ri})을 측정하는 힘 센서의 출력이 +1 혹은 -1에 이르는 것은 두 발 중 한 발에만 모든 무게가 실리게 됨을 의미하는 것으로서 2 쪽 보행시 필수적인 과정이다. 이 그래프에서 그림 10 (a)와 (b)를 비교할 때, 학습

초기에 불규칙적으로 좌우 발에 힘이 인가되었으나 학습 후에는 규칙적으로 좌우의 발에 로보트의 무게가 실리고 있음을 알려준다. 이와 같은 학습과 정을 거쳐서 2 쪽 보행로보트는 약 한시간 동안의 학습으로 분당 30보의 속도를 유지하면서 1 보 당 1~4 cm의 간격으로 3.5 m의 거리를 안정되게 걸어갈 수 있는 성과를 거둘 수 있다.

범용의 보행 기술은 아직 성취하지 못했지만 실험용 2 쪽 로보트는 foot contact를 유지하는 동안 무게 중심을 이동시키는데 필요한 closed chain kinematics를 학습할 수 있고, 다른 속도에서 무게 중심을 이동시키는 동안 앞 또는 뒤로 넘어지는 것을 피하기 위해 필요한 quasistatic balance를 학습할 수 있다. 또한, 2 쪽 로보트 제어기는 신경회로망 학습에 의해서 제어 기술을 향상 발전시킬 수 있기 때문에 제어기에 kinematic 또는 dynamic 모델이 요구되지 않는다는 장점이 있다.



(a) 학습시키지 않은 상태에서의 보행실험



(b) 90 분간의 학습 후 보행 실험

〈그림 10〉 2 쪽 보행로보트 보행 실험 중의 센서 출력

IV. 맷는 말

이 기고에서는 CMAC 신경회로망을 이용한 로보트 제어에 대하여 기술하였다. 신경회로망 기반 제어는 제어 대상의 기구학이나 동력학에 대한 정확한 지식이 없이도 학습에 의해 제어기를 구성할 수 있으며 특히 on-line 학습구조를 갖는 경우에는 제어가 진행되는 동안 점차 제어 기술을 향상 발전시킬 수 있다는 장점이 있다. 그러나 일반적으로 많이 사용되는 다층 신경회로망을 이용하게 되면 학습이 어렵기 때문에 로보트처럼 많은 입력 변수가 있는 시스템의 제어에는 실용적 이용 사례가 많지 않다.

CMAC 신경회로망은 타 신경회로망에 비해 탁월한 학습 속도를 갖는다는 특징이 있으므로 on-line 학습이 가능하고, CMOS 칩등을 이용하여 쉽게 구현할 수 있기 때문에 실용적 이용이 용이한 신경회로망이다. CMAC 신경회로망에도 hashing 잡음이 있다는 단점은 있으나 충분한 메모리를 사용하면 완화되는 문제로서, 최근 발달된 메모리 기술로 해결이 가능하다.

이 글에서는 현재까지 발표된 CMAC 기반 로보트 기법 중의 대표적인 기법들인 CMAC을 이용한 영상기반 로보트 제어기법과 역동력학 학습에 의한 로보트 팔 제어 기법 및 2 쪽 보행 로보트에 성공적으로 응용하는 예를 소개하였다. 가속되는 시장 개방에 대비한 국제 경쟁력을 갖추기 위해서는 지능 및 자동화된 생산설비가 필요할 것이며, 이를 위해서 CMAC과 같이 실용적 이용이 용이한 신경회로망의 산업적 활용에 관심을 가질 필요가 있을 것이다.

참 고 문 헌

- [1] J. S. Albus, *Theoretical and experimental aspects of a cerebellar model*, Ph. D. Thesis, U. of Maryland, 1972.

- [2] J. S. Albus, "A new approach to manipulator control : The Cerebellar Model Articulation Controller (CMAC)," *Journal of Dynamic Systems, Measurement, and Control, Transactions of the ASME*, pp. 220-227, September, 1975.
- [3] J. S. Albus, "Data storage in the Cerebellar Model Articulation Controller (CMAC)," *Journal of Dynamic Systems, Measurement, and Control, Transactions of the ASME*, pp. 228-233, September, 1975.
- [4] J. S. Albus, "Mechanisms of planning and problem solving in the brain," *Mathematical Biosciences* 45, pp. 175-185, 1977.
- [5] A. G.. Barto, R. S. Sutton, and C. W. Anderson, "Neuronlike adaptive elements that can solve difficult learning control problems," *IEEE Transactions on Systems, Man and Cybernetics*, vol. SMC-13, no. 5, pp.834-846, September/October 1983.
- [6] C.-S. Lin and H. Kim, "CMAC-based adaptive critic self-learning control," *IEEE Transactions on Neural Networks*, vol. 2, no. 5, pp. 530-533, September 1991.
- [7] W. T. Miller, III, F. H. Glanz, and L. G. Kraft, "CMAC: An associative neural network alternative to backpropagation," Proc. *IEEE*, vol. 78, pp. 1561-1567, October 1992.
- [8] Y. Wong and A. Sideris, "Learning convergence in the Cerebellar Model Articulation Controller," *IEEE Transactions on Neural Networks*, vol. 3, no. 1, pp. 151-121, January 1992.
- [9] N. E. Cotter and T. J. Guillerm, "The CMAC and theorem of Kolmogorov," *Neural Networks*, vol. 5, pp. 221-228, 1992.
- [10] W. T. Miller, III, B. A. Box, E. C. Whitney, J. M. Glynn, "Design and implementation of a high speed CMAC neural network using CMOS logic cell arrays," *Advanced in Neural Information Processing System 3*, R. P. Lippman, J. E. Moody, and D. S. Touretzky, Ed., pp. 1022-1027, 1991.
- [11] D. Knuth, *Sorting and searching, The art of computer programming*, vol. 3, Addison Wesley, Monlo Park, CA, pp. 506-542, 1973.
- [12] J. Moody, "Fast learning in multi-resolution hierarchies," *Advanced in Neural Information Processing Systems*, vol. 1, D. S. Touretzky Ed. Margan Kaufmann Publishing, pp. 29-39, 1989.
- [13] S. H. Lane, D. A. Handelman, and J. J. Gelfand, "Theory and development of higher -order CMAC neural networks," *IEEE Control System Magazine*, pp. 23-30, April 1992.
- [14] J. Ozawa, I. Hayashi, and N. Wakami, "A Fuzzy Cerebellar Model Articulation Controller," *IEEE International Conference on Fuzzy Systems*, vol. 2, pp. 1171-1178, San Diego, March 1992.
- [15] C.-C. Jou, "A fuzzy cerebellar model articulation controller," *IEEE International Conference on Fuzzy Systems*, vol. 2, pp. 1179-1186, San Diego, March 1992.
- [16] J. Nie and D. A. Linkens, *Fuzzy-Neural Control : principles, algorithms and applications*, pp.203-220, Prentice Hall, 1995.
- [17] A. G. Kraft and D. P. Campagna, "A comparison between CMAC neural network control and two traditional adaptive control systems," *IEEE Control*

- Systems Magazine*, pp. 36-43, April 1990.
- [18] W. T. Miller, III, "Real-time application of neural networks for sensor-based control of robots via vision," *IEEE Transactions on Systems, Man and Cybernetics*, vol. SMC-19, no. 4, July/August 1989.
- [19] W. T. Miller, III, R. P. Hewes, F. H. Glanz, and L. G. Kraft, "Real-time dynamic control of an industrial manipulator using a neural-network-based learning controller," *IEEE Transactions on Robotics and Automation*, vol. 6, pp. 1-9, February 1990.
- [20] W. T. Miller, III, "Real-time neural control of a biped walking robot," *IEEE Control Systems Magazine*, pp. 41-48, February 1994.
- [21] R. S. Sutton, "Learning to predict by the methods of temporal differences," *Machine Learning*, vol. 3, pp. 9-44, 1988.

저자 소개



金 倸 爰

1956年 1月 21日生

1980年 2月 한양대학교 전자공학과(학사)

1982年 8月 전북대학교 전기공학과(석사)

1992年 5月 Univ. of Missouri-Columbia 전기공학과(박사)

1982年 1月~1993年 8月 국방과학연구소 선임연구원

1993年 8月~현재 전북대학교 제어계측공학과 조교수

주관심 분야: 신경회로망 제어, 로봇 비전, Tele-robot, GIS



崔 鍾 淚

1969年 1月 18日生

1990年 2月 전북대학교 전기공학과 졸업(학사)

1992年 2月 전북대학교 대학원 전기공학과 졸업(석사)

1996年 8月 전북대학교 대학원 전기공학과 졸업(박사)

1994年 3月~1996年 7月 포스콘 기술연구소 선임연구원

1996年 7月~현재 포항산업과학연구원 주임연구원

주관심 분야: 신경회로망 이론 및 응용, 뉴로-퍼지 시스템, 지능 제어