

DNU에 의한 비선형 동적시스템의 적용제어

조현섭 김희숙**
*청운대학교 **원광대학교

Adaptive Control of Non-linearity Dynamic System using DNU

Hyeon Seob Cho, Hee Sook Kim**
*Chungwoon Univ., **Wonkwang Univ.

Abstract - The intent of this paper is to describe a neural network structure called dynamic neural processor(DNP), and examine how it can be used in developing a learning scheme for computing robot inverse kinematic transformations. The architecture and learning algorithm of the proposed dynamic neural network structure, the DNP, are described. Computer simulations are provided to demonstrate the effectiveness of the proposed learning using the DNP.

1. 서 론

미지의 변수를 가진 선형 시스템의 식별과 적용 제어에 관한 연구는 지난 30년간 꾸준히 연구되어 왔으며 괄목할 만하게 진보되었다. 하지만 기존의 적용제어 기법은 동적 시스템의 수학적 모형을 필요로 하지만 동적 시스템은 비선형성을 가지고 있으며, 비선형 특성이 심한 시스템의 제어는 아주 어렵다. 실제로 동적 시스템의 모형은 비선형성, 불확정성, 시간지연, 시변 시스템의 변수, 구조등에 의해 정확하게 기술한다는 것은 불가능하다. 특히 로봇 조작기의 정밀도는 주어진 특정 작업 공간에서 각 좌표의 목표 지점으로의 이동 능력에 좌우된다. 따라서, 목표하는 조작 단말의 위치에 대한 관절각들을 계산하기 위해 역기구학적인 문제를 실시간으로 풀어야 한다. 역기구학적인 문제는 대수적으로 또는 기하학적인 방법이나 반복법에 의해 풀 수 있다.[1]. 신경망 분야의 발전으로 인해 로봇 제어에 새로운 방향이 제시되고 있으며 신경망은 함수 사상과 동적 반복 능력이라는 장점에 의해 좌표 변환 학습에 사용될 수 있다[2-5]. 병렬 분산 처리에 기인하여 신경망은 예제 패턴들의 association에 대한 학습 능력을 갖는다. 예를 들어 이를 패턴은 작업 공간 좌표와 모형 다리의 대응하는 관절각을 나타낼 수 있다. 이를 두 패턴 집합의 association은 기본적으로 로봇 계열에서는 역기구학적으로 계산된다.

본 논문에서 논의된 신경망 구조는 임의 복잡도의 신경활동이 여기(excitatory, 양성)와 금지(inhibitory, 음성)의 신경 부차집단 사이의 상호 작용의 결과이고 신경 생리학적인 근거에 기초하여 개발된 dynamic neural processor(DNP)이다. 따라서 DNP의 구조에 대해 설명하고 신경망의 적용적인 가중치에 대한 학습 알고리즘을 제시한다. 그리고 학습 방법과 컴퓨터 모의실험에 의한 결과를 고찰 한다.

2. 신경 부차집단에 기초한 DNP

2.1 자극

지금까지의 인공 신경망의 구조는 주로 신경 정보 처리 동작을 나타내는 기본 계산 단위로서의 단일 뉴런의 거동만을 고려하였다. 신경망에서 각 계산 단위는 이상화된 뉴런의 개념에 기초하고 있다. 이상적인 뉴런은 인가된 입력에 효율적으로 대응한다고 가정된다. 신경 활동은 신경 집단(neural population) 또는 신경 덩어리(neural mass)라고도 하는 세포의 집단적인 조합으로 부터 야기된다. 신경 집단은 뉴런들로 구성되며, 그 성질은 개개의 뉴런의 성질에 대한 유전적인 유사성을 갖는다. 그러나 그것이 이상적인 것은 아니며 그 성질은 단일 뉴런의 성질로부터 예측할 수는 없다. 이것은 각 뉴런의 다양한 매개변수와 뉴런들의 상호 연결에 달려 있는 신경 집단의 성질에 기인한다[6]. 신경망 연구는 이상의 생물학적인 신경 구조의 두 가지 측면이 배제되는 단일 뉴런 해석에 기초한다.

신경 집단의 최소 위상을 여기(양성), 금지(음성), 여기-금지(여기에서 금지로의 시냅스 연결), 금지-여기(금

지에서 여기로의 시냅스 연결) 세 가지로 구분된다. 신경 집단의 가장 중요한 속성의 하나는 비선형 시스템 해석의 관점에서 기술할 수 있는 몇 가지 기본적인 속성이다. 이러한 전제를 바탕으로 로보틱스와 제어 문제에의 응용에 dynamic neural processor(DNP)를 제안하였다. 뉴런의 두 부차집단 간의 시냅스 연결 강도는 고정되어 임의적으로 선택되었다.

2.2 DNP의 구조와 수학적 모델

적용적인 시냅스 강도를 갖는 DNP의 기본적인 기능은 dynamic neural unit(DNU)에 기초한다[7-8].

(i) Dynamic Neural Unit(DNU)

DNU는 기억 요소(지연 연산자)와 그림 1과 같이 feedforward 및 feedback 시냅스 가중치로 구성된다. 이 통제 구조의 출력은 시변 비선형 활성화 함수에 대한 인자를 구성한다.

DNU는 크게 (i)synaptic operation과 (ii)somatic operation의 두 가지의 동작을 수행한다. 전자는 feedforward 및 feedback 시냅스 가중치의 적용(adaptation)에 대응되고 후자는 비선형 활성화 함수의 이득(형태)의 적용에 대응된다. DNU는 각각 비선형 활성화 함수에 이어지는 2차 구조를 나타내는 시냅스 가중치 a_{ff} 와 b_{ff} 에 의해 가중되는 feedforward 및 feedback 경로인 지연 요소로 구성된다.

$$v_1(k) = -b_1 v_1(k-1) - b_2 v_1(k-2) + a_{ff}s(k) + a_1 s(k-1) + a_2 s(k-2) \quad (1)$$

이 때 $s(k) \in R^n$ 은 신경 입력 벡터이고, $v_1(k) \in R^1$ 은 동적 구조의 출력이며, $s(k) \in R^n$ 은 신경 출력, k 는 이산 시간 지표, z_i 는 단위 지연 연산자, $a_{ff} = [a_0, a_1, a_2]$ 와 $b_{ff} = [b_1, b_2]$ 는 다음과 같이 정의 된다.

$$\Gamma^T(k, v_1, s) = v_1(k-1) \quad v_1(k-2) \\ s(k) \quad s(k-1) \quad s(k-2)] \quad (2)$$

$$\zeta^T(a_{ff}, b_{ff}) = [-b_1 \quad -b_2 \quad a_0 \quad a_1 \quad a_2] \quad (T: transpose) \quad (3)$$

(2)와 (3)에 의해 식 (1)은 다음과 같이 된다.

$$V_1(k) = \Gamma(k, v_1, s) \zeta^T(a_{ff}, b_{ff}) \quad (4)$$

$v_1(k)$ 에 대한 비선형 사상은 다음과 같은 출력을 낸다.

$$u(k) = \psi[g_s v_1(k) - \theta] \quad (5)$$

이 때 $\psi[\cdot]$ 는 비선형 활성화 함수로서 보통은 sigmoidal 함수이고 g_s 는 활성화 함수의 기울기를 제어하는 somatic gain이며, θ 는 뉴런을 점화시키기 위한 임계치(threshold)이다. 여기와 금지 입력 모두에 대한 수학적인 동작을 확장하기 위해 $[-1, 1]$ 에 대한 활성화 함수를 다음과 같이 정의한다.

$$\psi[v(k)] = \tanh[g_s v_1(k) - \theta] = \tanh[v(k)] \quad (6)$$

이 때 $v(k) = g(s)v_1(k)$ 이다.

(ii) Dynamic Neural Processor(DNP)

dynamic neural processor는 그림 2에서와 같이 여기와 금지 방식으로 결합된 두 개의 DNU로 구성된다. 이 구조에서, $s_{\lambda}(k)$ 와 $u_{\lambda}(k)$ 는 철자 λ 가 여기 E나 금지 I 상태를 가지길 때 신경 계산 단위의 자극(입력)과 상태 반응(출력)을 나타낸다. $s_{\lambda}(k)$ 는 신경 단위의 총 입력을 나타내고 $w_{\lambda\lambda}$ 는 자기 시냅스 연결 강도(그림 2의 W_{EE} , W_{II})를 나타내고, $w_{\lambda\lambda'}$ 는 한 뉴런에서 다른 뉴런으로의 상호 시냅스 연결 강도(그림 2의 W_{IE} , W_{EI})를 나타낸다. 신경 계산 단위의 DNU에 의해 여기 되는 기능적 동역학은 식(1)에 나타낸 바와 같이 2차 차분 정식으로 정의된다. 제안된 신경 프로세서의 여기 및 금지 신경 단위에 의해 시간 $(k+1)$ 에 발생되는 상태 수 $u_E(k+1)$ 과 $u_I(k+1)$ 은 다음과 같이 모델링된다.

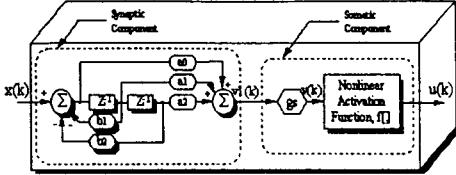


Fig. 1 The structure of dynamic neural unit (DNU)
그림 1 DNU의 구조

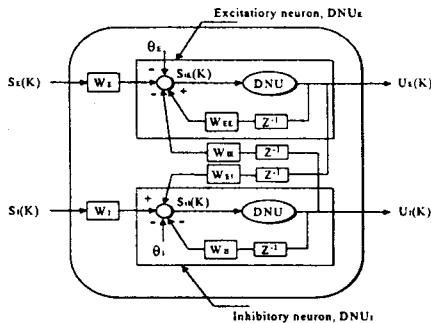


Fig. 2 The structure of dynamic neural Processor(DNP)
그림 2 DNP의 구조

$$u_E(k+1) = E[u_E(k), v_E(k)], \text{ and} \\ u_I(k+1) = I[u_I(k), v_I(k)] \quad (7)$$

이때 $v_E(k)$ 와 $v_I(k)$ 는 내부 임계치보다 더 큰 입력을 받아들이는 신경단위에서 뉴런의 비를 나타내고 E 와 I 는 뉴런의 여기와 금지 작용을 나타낸다. 임계치 보다 더 큰 입력을 받아들이는 뉴런은 비선형 합수 $v_i(k)$ 로 주어진다. 여기와 금지 신경 단위에 주어지는 총 입력은 각각 다음과 같다.

$$s_{EE}(k) = w_E s_E(k) + w_{EE} u_E(k-1) \\ - w_{EE} u_E(k-1) - \theta_E \quad (8)$$

$$s_{II}(k) = w_I s_I(k) - w_{II} u_I(k-1) + w_{EI} u_E(k-1) - \theta_I \quad (9)$$

이때 w_E 와 w_I 는 각각 여기와 금지 신경 단위의 비례상수(scaling factor)이고, w_{EE} 와 w_{II} 는 자기 시냅스 연결 강도를, w_{EI} 와 w_{IE} 는 상호 뉴런 시냅스 연결 강도. θ_E 와 θ_I 는 여기 및 금지 뉴런의 임계치를 각각 나타낸다. 뉴런의 여기와 금지 그룹의 일반적인 활동은 다음식에 의해 전개되어 이때 r_E 와 r_I 는 각각 여기와 금지 뉴런의 absolute refractory period(뉴런이 재 점화할 수 없는 기간)를 나타낸다.

$$u_E(k+1) = u_E(k) + (1 - r_E u_E(k)) \Psi_E[s_{EE}(k)]; \quad (10a)$$

여기 뉴런

$$u_I(k+1) = u_I(k) + (1 - r_I u_I(k)) \Psi_I[s_{II}(k)]; \quad (10b)$$

금지 뉴런

식 (8)과 (10)에 의해 등복자 곡선에 대한 방정식은 다음과 같이 쓸 수 있다.

$$u_I(k) = \frac{1}{w_{IE}} [(w_E s_E(k) - \theta_E +$$

$$\Psi_E^{-1} \left[\frac{u_E(k)}{(1 - r_E u_E(k))} \right] + w_{EE} u_E(k)] \text{ for } u_E(k+1) = 0$$

$$u_E(k) = \frac{1}{w_{EI}} [(-w_I s_I(k) - \theta_I +$$

$$\Psi_I^{-1} \left[\frac{u_I(k)}{(1 - r_I u_I(k))} \right] + w_{II} u_I(k)] \text{ for } u_I(k+1) = 0$$

sigmoid 함수의 수학적인 성질에 의하여, Ψ_E 와 Ψ_I 는 $(-\infty, \infty)$ 의 범위에서 단조 증가하는 유일한 역을 가진다. 그러므로 식 (11a)로 정의되는 v_i 는 언제나 u_E 의 단조 증가 함수이다. 반면에, 식 (11b)에서 Ψ_I^{-1} 의 (-) 부호에 의해 u_E 는 절차적으로 감소하는 v_i 의 함수가 될 것이다. 두 등복자 곡선 사이의 이러한 정성적인 차이는 여기와 금지 간의 반대청에 대한 적절적인 결과이다. 신경 단위의 기능적인 동작이 선형 시스템 이론에 의해 근사될 수 있다는 사실에 기인하여 DNP의 응답 $u(k)$ 는 신경 부차집단에서 여기와 금지의 개별적인

응답인 $u_A(k)$ 의 중첩이며 다음으로 주어진다.

$$u(k) = u_E(k) + u_I(k) \quad (12)$$

식 (12)의 의미는 신경 집단의 총체적인 활동이 여기와 금지 후 시냅스 응답의 합이다.

2.3 학습 알고리듬

학습 과정은 feedforward 및 feedback 가중치와 오차 합수를 최소화 하기 위한 somatic gain의 적용과정을 포함한다. 반복 학습 기법에서 제어의 순서는 각 반복 학습 단계에서 목표 상태 $u_d(k)$ 에 도달하기 위한 신경 출력 $u(k)$ 를 발생하기 위해 변형된다. 학습 후 학습 횟수가 증가함에 따라 오차 $e(k)$ 가 무한히 작은 값으로 줄어질 수 있다면 학습 방법은 수렴한다고 말한다. 즉, 초기 조건의 임의의 집합에 대해

$$u(k) \rightarrow u_d(k) \text{ as } k \rightarrow \infty \text{ or,} \\ \lim_{k \rightarrow \infty} [u_d(k) - u(k)] = e(k) = 0 \quad (13)$$

오차 $e(k)$ 와 매개변수 벡터 $\Omega_{(a_n, b_n, g_s, w_{\mu})}$ 의 성분은 각 학습 횟수 k 와 함께 변한다. $\Omega_{(a_n, b_n, g_s, w_{\mu})}(k+1)$ 을 구하기 위해서는 정보집합 $\{e(k-m), e(k), \Omega_{(a_n, b_n, g_s, w_{\mu})}(k)\}$ 만이 필요한데 이때 $m=1, 2, \dots$ 이며 창의 크기를 결정한다. 학습 횟수가 증가함에 따라 정보 집합은 다만 $\{\Omega_{(a_n, b_n, g_s, w_{\mu})}(k), e^*(k)\}$ 로 감소하며 이것은 DNU 매개변수와 오차가 최적치에 수렴하였음을 가리킨다. 이를 위해 각 매개변수 벡터에 대해 최적화되어야 하는 성능 지표는 다음과 같이 정의되며 이때 E 는 기대 연산자(expectation operator)이다.

$$J = E[F[e(k; \Omega_{(a_n, b_n, g_s, w_{\mu})})]] \quad (14)$$

식 (14)에서 $F[e(k; \Omega_{(a_n, b_n, g_s, w_{\mu})})]$ 의 일반적인 형태는 오차의 우함수이다. 즉,

$$J = \frac{1}{2} E\{e^2(k; \Omega_{(a_n, b_n, g_s, w_{\mu})})\} \quad (15)$$

이때 E 는 기대 연산자이고 $e(k)$ 는 목표 신호 $u_d(k)$ 와 실제 신호 $u(k)$ 의 차이로 정의되는 오차 신호이다. 벡터 $\Omega_{(a_n, b_n, g_s, w_{\mu})}$ 의 각 성분은 급경사 감소(steepest descent) 알고리듬에 의해 J 를 최소화 하는 방식으로 적용되었다. 이 적용 알고리듬은 다음과 같이 쓸 수 있는데 이때 $\Omega_{(a_n, b_n, g_s, w_{\mu})}(k+1)$ 은 새로운 매개변수 벡터이고, $\Omega_{(a_n, b_n, g_s, w_{\mu})}(k)$ 는 현재 매개변수 벡터이며

$\delta \Omega_{(a_n, b_n, g_s, w_{\mu})}(k)$ 은 매개변수 벡터의 적용 조절량이다. 급경사 감소법에서 매개변수 벡터의 조절은 성능지표 J 의 음의 기울기에 비례하도록 되어진다. 즉,

$$\delta \Omega_{(a_n, b_n, g_s, w_{\mu})}(k) \propto (-\nabla J) \text{ where,} \quad (16)$$

$$\nabla J = \frac{\delta J}{\delta \Omega_{(a_n, b_n, g_s, w_{\mu})}}$$

따라서, $\text{dia}[\mu]$ 가 독립적인 적용 이득 행렬일 때 다음과 같이 된다.

$$\delta \Omega_{(a_n, b_n, g_s, w_{\mu})} = -\text{dia}[\mu] \frac{\delta J}{\delta \Omega_{(a_n, b_n, g_s, w_{\mu})}} = \frac{\delta J}{-\text{dia}[\mu] \nabla J} \quad (17)$$

위의 식에서 $\text{dia}[\mu]$ 는

$$\text{dia}[\mu] = \begin{bmatrix} \mu_{a_1} & 0 & 0 & 0 \\ 0 & \mu_{b_1} & 0 & 0 \\ 0 & 0 & \mu_{g_s} & 0 \\ 0 & 0 & 0 & \mu_{\mu} \end{bmatrix} \quad (18)$$

이때 $\mu_{a_i}, i=0, 1, 2, \mu_{b_j}, j=1, 2, \mu_{g_s}$ 는 DNU의 적용 매개변수의 독립적인 학습 이득이고, μ_{μ} 는 자기 및 상호 뉴런 시냅스 연결의 학습 이득을 나타낸다. $\phi_{(a_n, b_n)}$ 로 DNU의 시냅스 가중치 벡터를 나타내면 $\phi_{(a_n, b_n)}$ 에 대한 성능 지표의 기울기는 다음과으로 구해진다.

$$\frac{\delta J}{\delta \phi_{(a_n, b_n)}} = \frac{1}{2} E \left[\frac{\delta [u_d(k) - u(k)]^2}{\delta \phi_{(a_n, b_n)}} \right] \\ = E \left[e(k) \left(-\frac{\delta \Psi(v)}{\delta \phi_{(a_n, b_n)}} \right) \right]$$

$$= E \left[-e(k) \left\{ \frac{\delta \Psi(v)}{\delta v} \frac{\delta v}{\delta \phi_{(a_n, b_n)}} \right\} \right] \quad (19)$$

$$= E \left[-e(k) \left\{ \sec^2[v(k)] P \phi_{(a_n, b_n)} \right\} \right]$$

이때 $P \phi_{(a_n, b_n)}(k) = \frac{\delta v(k)}{\delta \phi_{(a_n, b_n)}} = g_s \frac{\delta v_1(k)}{\delta \phi_{(a_n, b_n)}}$ 는 매개변수-상태(또는감도) 신호의 벡터를 나타낸다.

feedforward와 feedback 가중치에 대한 매개변수 상태 신호는 각각 다음 관계로 주어진다[9-10].

$$P \phi_{(a_n)}(k) = g_s [s(k-i)], i=0,1,2, P \phi_{b_n}(k) = -g_s [v_1(k-j)], j=1,2 \quad (20)$$

비슷한 방법으로, somatic gain g_s 에 대한 성능지표의 기울기는 다음과으로 주어진다.

$$\frac{\delta J}{\delta g_s} = \frac{1}{2} E \left[\frac{\delta [u_d(k) - u(k)]^2}{\delta g_s} \right] \quad (21)$$

$$= E \left[-e(k) \left\{ \sec^2[v(k)] v_1(k) \right\} \right]$$

자기 및 상호 뉴런 시냅스 연결에서의 적용은 다음과 같이 구할 수 있다.

$$\begin{aligned} \frac{\delta J}{\delta w_{\lambda'}} &= \frac{1}{2} E \left[\frac{\delta [u_d(k) - u(k)]^2}{\delta w_{\lambda'}} \right] \\ &= E \left[-e(k) \left\{ \frac{\delta \Psi(v)}{\delta v} \frac{\delta v}{\delta w_{\lambda'}} \right\} \right] \\ &= E \left[-e(k) \left\{ \operatorname{sech}^2[v(k)] g_s u_1(k-1) \right\} \right] \quad (22) \end{aligned}$$

위의 식들로부터 DNP 매개변수 생신 알고리듬은 다음과 같이 쓸 수 있다.

$$a_{ff_i}(k+1) = a_{ff_i}(k) + \mu_{ff_i} E[e(k) \sec^2[v(k)] P \phi_{a_n}(k)], i=0,1,2 \quad (23a)$$

$$b_{fb_i}(k+1) = b_{fb_i}(k) + \mu_{fb_i} E[e(k) \sec^2[v(k)] P \phi_{b_n}(k)], i=1,2 \quad (23b)$$

$$g_s(k+1) = g_s(k) + \mu_s E[e(k) \sec^2[v(k)] v_1(k)] \quad (23c)$$

$$w_{\lambda'}(k+1) = w_{\lambda'}(k) + \mu_{\lambda'} E[-e(k) \left\{ \operatorname{sech}^2[v(k)] g_s u_1(k-1) \right\}] \quad (23d)$$

식(23a)과 (23b)은 시냅스 가중치에서, (23c)는 DNU의 sigmoidal gain에서, 식 (23d)는 외부 시냅스 가중치에서 적용성을 갖는다.

3. 역구학적 변환의 온 라인 학습

3.1 학습 기법

그림 3에 있는 것처럼 제안된 학습 기법은 주어진 목표 직각좌표의 집합에 대한 관절각을 결정하기 위해 DNP를 사용한다. 전방 운동에 대한 입력으로 사용하는 이 추정된 관절각은 미리 정의된 로봇의 작업 공간에 반하여 점검된다. 이 부가적인 제어 수준은 로봇을 작업 공간 내에서 동작하도록 한다.

제 1수준이 신경망 구조의 구성을 바꾸는 로봇의 작업 공간을 설치하게 된다. 즉, 동적 신경망에서 병렬 충의 수를 결정한다. 만약 로봇의 작업 공간 사양(관절각, 링크의 길이)은 2 링크 로봇에 대한 것이며 신경망 프로세서는 한 충(여기와 금지 뉴런의 한 쌍)을 구성하게 된다. 신경 프로세서의 출력인 주정거 관절각은 항상 사양에 대해 점검되어 로봇의 운동을 미리 정의된 작업 공간으로 한정한다. DNP에 대한 입력은 목표 직각 좌표이고 출력은 적당한 비율로 추정된 관절각으로 로봇의 전방 운동에 대한 입력이 된다. 오차 신호는 목표 위치와 관측 위치의 차로 계산된다. 신경 가중치는 다음 절에서 개발되는 학습 알고리듬을 바탕으로 적용된다. 제안된 신경 프로세서와 학습 기법의 효과를 보이기 위해 본 논문에서는 인간 다리의 모델로서 2 링크 구조가 고려된다. 어떤 범위 내에서 일어나는 회전 운동에서의 관절은 인간 다리의 영역이 와 무릅 관절과 유사하다. 종점이라 고도 부르는 두 번째 링크의 자유로운 텁은 직각 좌표 시스템에 기초한 궤도를 나타낸다. 좌표계의 원점은 공간 상에 고정되어 있다고 가정하는 첫 번째 (엉덩이) 관절이고 반면 종점 좌표 (x, y) 는 두 수직축 X, Y 에 대해 위치된다. 둘째 관절은 청점으로 간주된다. 다리의 위치는 또한 그림과 같이 기준을 따라 두 관절이 형성하는 각에 의해 제한될 수 있다. 이를 두 각의 관계는 θ_1 과 θ_2 로 정의되며 종점 좌표 x, y 는 다음과 같은 2 링크 다리의 역학 방정식을 형성한다.

$$x = L_1 \cos(\theta_1) + L_2 \cos(\theta_1 + \theta_2) \quad (24a)$$

$$y = L_1 \sin(\theta_1) + L_2 \sin(\theta_1 + \theta_2) \quad (24b)$$

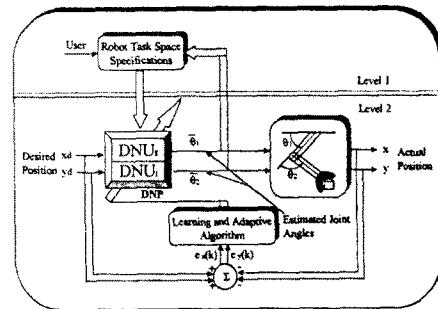


Fig.3 The Proposed learning scheme with inverse kinematic transformations of a two-linked robot.

그림 3 제안된 동적 신경망에의한 2관절 로봇의 학습 기법

역구학적인 문제의 한가지 해법은 다중 해의 발생을 피할 수 있는 어떤 편리한 각의 범위로 두 링크의 운동을 제한하는 것이다. 부수적으로 무릅 관절과 같이 경첩 구조를 가진 인간 다리의 구조는 정강이의 제한된 움직임을 허용한다. 위에서 언급한 제약들에 대해 생각해 보면 2 링크 다리 모델의 두 관절은 특별한 각 범위(-30° < θ1 < 180°, 0° < θ2 < 180°) 내에서 움직이도록 제한된다.

3.2 컴퓨터 모의 실험

예 1: 만약 요구되는 출력이 $y_1(k)$ 이고 제어중인 플랜트의 실제 출력이 $y(k)$ 일때 오차가 $e(k) = y_d(k) - y(k)$ 이면 제어의 목표는 다음과 같은 제한된 제어 입력 $u(k)$ 를 결정하는 것이다.

$$\lim_{k \rightarrow \infty} [y_d(k) - y(k)] = e(k) = 0 \quad (25)$$

제어되는 플랜트는 다음 차분 방정식으로 기술된다. $y(k) = f[y(k-1), y(k-2), u(k), u(k-1), u(k-2)] \quad (26)$

$$\begin{aligned} \text{식(23a)와 (23b)는 시냅스 가중치에서, (23c)는 DNU의 sigmoidal gain에서, 식 (23d)는 외부 시냅스 가중치에서 적용성을 갖는다.} \\ f[\cdot] &= [2 + \cos(7\pi(y^2(k-1) + y^2(k-2)))] + e^{-u(k)} / (1 + u^2(k-1) + u^2(k-2)) \quad (27) \end{aligned}$$

이고, 시스템 입력은 $x(k) = \sin(2\pi k/250)$ 이었다. 이때 얻어진 시뮬레이션 결과가 그림 1에 보여준다.

예 2: 이 예에서는 end-effector의 좌표 x 와 y 가 임의로 선택되어 DNP의 입력으로 인가되었다. 신경 가중치는 출력 오차가 미리 정의된 값 0.05로 감소될 때 까지 조절된다. 그림 2는 2 링크 로봇의 실제 및 학습된 좌표를 보이고 있다.

예 3: 지능 로봇의 성공적인 동작은 구조상에 동적 인변화를 초래할 수도 있는 섭동에 대한 대처 능력에 달려 있다. 이 예에서는 링크 L_2 가 개선된 효과를 보인다. 이러한 동적 섭동으로 인하여 관찰된 end-effector의 위치는 신경망 가중치의 개 조절을 요하는 목표 위치와 일치해야 한다. 따라서 그림 3의 결과로부터 DNP가 로봇의 역학적 변화에 적용할 수 있음을 보이며 따라서 학습 기법의 장인성을 보인다.

예 4: 이 예에서는 DNP 구조의 제안된 동적 신경망의 성능 비교에 관해 평가한다. 신경 프로세서는 여기와 금지 방식으로 된 두개의 상용 뉴런으로 구성된다. 상용 신경 구조에서 뉴런에 대한 입력은 합쳐지고 이 신호가 고정된 sigmoidal 함수를 통하여 지나간다. 동적 신경망과 간략화된 구조의 성능을 비교하기 위해 다른 end-effector의 위치가 양자에 제시된다. 얻어진 결과는 표 1에 정리되어 있다. 이 결과로부터 제안된 동적 신경망이 목표 패턴을 더 빠르게 학습할 수 있음을 알 수 있다. 그리고 표에서 '로 된 부분은 학습 할 수 없었으며 가중치 초기값과 알고리듬에서 학습 상수의 값을 불완전하게 선택한데서 연유한 것 같다. 결과적으로 동적 신경망이 정적 뉴런보다 빠르게 수렴하는 것을 알 수 있었다.

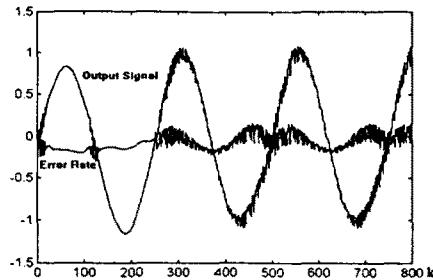


Fig.4 plant output and error response $e(k)$ of proposed DNP controller and BP controller in the 50th learning; Example 1.
그림 4. 예 1: 기존 제어기와 제안된 DNP제어기의 플랜트 출력과 오차응답 $e(k)$.

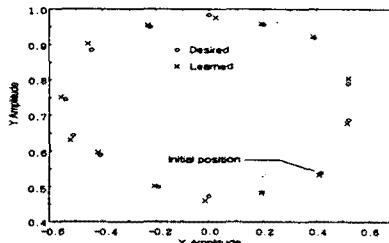


Fig.5 Illustration of the actual and the learned positions of different trajectories; Example 2.
그림 5. 예 2: 학습된 2링크 로봇의 궤적 좌표

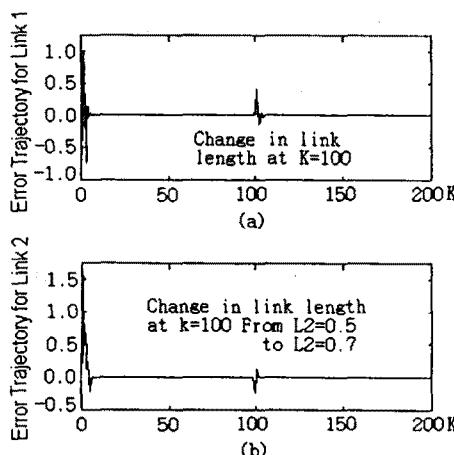


Fig.6 Error trajectories of robot links when the length of link L_2 was changed from 0.5 to 0.7 units at time instant $K=100$; Example 3.
그림 6 예 3: $K=100$ 에서 L_2 관절의 길이가 0.5-0.7으로 변화시 로봇 관절의 오차 궤적

3. 결 론
신경 구조의 통합된 동특성이 중시되는 DNP라는 신경망 구조가 제시되었다. 이 신경망 모델의 임시 거동이 간단히 논의되었으며, DNU 매개변수와 부자집단의 자기 및 상호 시냅스 가중치를 생성하기 위한 학습 알고리즘이 개발되었다. 그리고 두 계층 수준을 구성하는 온라인 학습 기법이 제안되었으며, 이 방법은 목표 직각좌표를 입력으로 받아들여서 로봇의 관절각을 결정할 수 있었다. 따라서 로봇이 미리 정의된 작업 영역 내에서 움직일 수 있었다. 학습 기법의 강인성을 통해 로봇에서 확인하였다. 또한 앞으로의 과제는 본 논문에서 개발한 유연한 구조와 복잡한 로봇 시스템에 대한 개념의 확장이 요구된다.

Table 1: Performance comparison; Example 4.
표 1. 예 4; 성능비교

Desired Coordinates		Dynamic Neural Processor		Simplified version of DNP			
x_d	y_d	x	y	Learning Iterations	x	y	Learning Iterations
-0.6	0.5	-0.602	0.51	422	-0.58	0.508	1512
-0.5	0.75	-0.504	0.753	104	-0.493	0.742	173
-0.38	0.58	-0.377	0.579	101	-0.39	0.588	201
-0.2	0.53	-0.209	0.533	80	-0.19	0.539	598
0.0	0.5	0.07	0.499	144	0.09	0.495	157
0.5	0.75	0.492	0.744	319	0.49	0.748	1033
0.3	0.85	0.302	0.86	199	0.29	0.85	3047
0.2	0.95	0.192	0.952	174	0.19	0.942	782
0.0	0.99	0.09	0.993	164	0.009	0.982	687
-0.25	0.9	-0.258	0.903	36	-0.26	0.894	104
-0.3	0.8	-0.309	0.793	31	-0.31	0.809	191
-0.6	0.6	-0.601	0.59	273	-0.592	0.592	667
-0.2	0.8	-0.207	0.812	36	-0.192	0.802	143
0.38	0.58	0.378	0.579	31	*	*	
-0.8	-0.2	-0.792	-0.195	69	*	*	
-0.3	-0.45	-0.312	-0.45	382	*	*	
0.5	0.4	0.492	0.404	53	*	*	
0.3	0.7	0.297	0.694	24	*	*	
0.0	0.96	0.08	0.961	60	*	*	

(참 고 문 헌)

- [1] K.s Narendra and K. Parthasarathy, "Indentification and Control of Dynamical System Using Neural Network," IEEE Trans. Neural Network, pp.1-14, 1990.
- [2] 조현섭, "A Simple and Efficient Technique for Rapid Convergence Speed of The LMS Algorithm." ITC-CSCC'97(Japan, Okinawa) (Vol 1), p31-34, 1997.
- [3] Madan M. Gupta, "Fuzzy Logic and Neural Networks." Proceeding of the Tenth International Conference(TAIPEI'92), Vol. 3, pp.281-294, July, 1992.
- [4] 조현섭, "The Neural Network Algorithm Using Control of Nonlinear Dynamic Systems." pp 167-173 EMB'95(Canada), 1995.
- [5] 조현섭, "퍼지 논리를 이용한 다층 신경망의 학습 속도 개선 및 비선형 동적 시스템 제어에 관한 연구". 한국통신학회 논문지. 제 20권 12호, pp 3552-3561, 1995.
- [6] 조현섭, "A Study on Neural-fuzzy Pattern Matching Word Recognition". NNASP'93 (Singapore) pp. 7-12 1993. 8. 17
- [7] 조현섭, "A Study on Korean Digit Recognition Using Semi-Dynamic Neural Network With Sequential Feedback Architecture". ICT'94(Shanghai) Volume 2, p 1442-1444, 1994. 6. 8
- [8] 조현섭, "신경 회로망을 이용한 비선형 동적 시스템의 적용 제어". 대한전기학회 논문집, pp 953-955, 1995.
- [9] 조현섭, "신경회로망 학습을 이용한 PID제어기의 자동통조에 관한 연구". 대한전기학회 논문집 Vol(G), p2394-2396, 1997. 7. 23
- [10] Robert Hecht-Nielsen, "Neuro Computing" HNC, Inc. and University of California, San Diego, 1991.