

로봇의 운동패턴학습

이호길

1. 서론

산업사회에서 정보화시대, 지능화시대로 사회적 패러다임이 변화하고 있다. 로봇분야도 제조업현장에서 활용되던 제조업용(산업용)로봇에서 가정, 복지 등 사회전반에 활용될 수 있는 서비스로봇으로 사회적 needs가 변화되기 시작했다. 이에 따라 로봇제어기술도 기존 playback방식에서 서비스에 적합한 새로운 방식으로의 전환이 요구된다. 서비스로봇은 환경적 변화로 특징지어질 수 있는 복잡한 생활공간에서 인간과 함께 동거하며, 심부름 등의 작업을 수행해야한다. 이때 요구되는 중요한 특징은 제조업용 로봇과 같은 단순반복기능이 아니라, 스스로 상황에 맞는 적절한 작업을 선택하여 수행할 수 있어야 한다는 점이다. 또한 서비스로봇은 전통적 로봇보다 인간과 유사한 시각, 음성인식, 이동, 물체조작 등 보다 복잡한 기능과 많은 자유도를 갖추어야한다.

이러한 복잡성을 고려할 때 작업기능도 다양한 패턴(pattern)으로 DB화하여, 대응하는 것이 바람직하다. 인간의 행동을 관측해보면, 익숙한 작업은 거의 무의식적으로 행동할 수 있도록 패턴화되어 있고, 또 그 패턴은 경험적 학습을 통해 얻어진다고 믿어진다. 서비스 로봇의 작업기능도 이러한 방식을 모방할 필요가 있다. 이러한 관점에서 본고에서는 로봇이 어떻게 운동패턴을 획득할 수 있을까, 또한 유사한 동작은 어떻게 상황에 맞추어 적응시킬 수 있을까하는 방법론에 대해 고찰해보고자 한다.

2. 운동의 패턴화

운동패턴이란 주목하는 대상물의 위치나 힘의 변화를 시간축에 나열한 유한시간의 구간 점열데이터라고 할 수 있다. 이러한 일련의 데이터를 $y(t)$, $t \in [0, T]$, 이때 시간은 t 로, 시각 0에서 T 까지라고 표시한다. 예를 들어, 손끝이 작업 대상물에 접근하는 위치의 점열데이터도 이렇게 표현할 수 있다. 물론 3차원공간에서의 위치와 자세를 나타낸다면 위치벡터 $\vec{y}(t)$ 로 표시된다.

이러한 운동패턴은 인간의 교시에 의해 얻어질 수 있다. 숙련 작업의 운동패턴을 얻을 수 있다면, 이를 기준으로 다음절에서 논의하는 방식으로 로봇이 학습함으로서, 로봇은 동작을 구현 할 수 있다. 또 대상물부근에서의 손가락 벌림, 물체를 파지하기 위한 동작, 물체를 들어 올리는 동작, 물체를 옮기고 내려놓 은 일련의 동작을 각각 패턴으로 구분하여 로봇동작으로 획득 하고, DB화하여, 이러한 패턴을 적절히 배열함으로서, 상황에 맞는 적절한 작업을 수행할 수 있다.

페턴화의 장점은 패턴의 시간축 상 배열 역시 패턴으로, 요소 패턴을 어떻게 구성하는가에 따라 다양한 작업패턴이 만들어질 수 있다는 점이다. 또한 이렇게 작업프로세스를 일련의 패턴으로 구분하고 DB화 할 때, 환경조건에 대응하는 보다 추상화된 지령이 쉽게 만들어질 수 있고 그 지령은 다시 DB 상의 패턴 조합으로 실현이 될 수 있다. 뿐만 아니라 이러한 패턴의 시간 구간을 짧게 잡는다면, 패턴을 수행할 때의 로봇동특성은 선형 시스템으로 간주할 수 있어, 로봇제어가 아주 편할 수 있다는 장점이 있다. 문제는 이러한 방식의 확장성에 있다고 보여진다. 실제 패턴동작이 로봇으로 어떻게 획득가능하고, 또 그와 유사한 동작은 어떻게 대응할 수 있는가하는 점일 것이다.

3. 운동폐턴 제어상의 문제점

제어공학에서는 잘 알려진 사실이지만 정밀한 동작제어시 출력신호의 피드백(feedback)은 필수적이다. 단 이때의 목표추종성은 시간에 대해 일정한 목표일 경우에 한정된다. 즉, step 목표에 대해서 추종성이 보증되지만, 패턴 $y(t)$, $t \in [0, T]$ 에 대해서는 엄밀한 추종을 보장하지 않는다. 한편, Arimoto S.는 미분가능한 목표패턴에 대해 오차를 이용한 학습법 betterment process를 제안하여, 로봇운동을 패턴에 일치시킬 수 있음을 증명하였다.

즉, 학습수렴조건을 만족하는 시스템은 시간적인 구간정보 입력에 대해, 각 시각에 대한 출력과의 오차에 학습gain을 곱하여 입력을 갱신하면 학습 횟수를 거듭할수록 출력이 목표에 수렴한다는 것이다. 이 방식은 인간의 스킬 훈련에 의한 학습과

정과 유사한 특징을 보이고 있고, 구현방법 또한 간단하나, 학습된 최종입력은 목표패턴이 바뀔 때마다 학습을 다시 해야 하는 문제가 있다.

다음절에서 이러한 학습상의 문제점을 보완하고, 실제, 로봇의 유연성을 부여하기 위해, 최근 주목받고 있는 신경분야의 연구 결과를 소개하고 패턴회득의 기본적 수학모델을 제시하고자 한다.

4. 신경세포의 역행성 전도현상과 수학모델화

4.1. 신경세포의 역행성전도

최근 노말스키 미분현미경과 적외선조명방법을 도입하여 생체 표본을 직접 관찰하는 방법이 개발되면서, 신경세포 활동전위의 역행전도현상이 발견되었다. 그림1 A와 같이 대뇌피질V층(대뇌피질을 표면부터 6층으로 나누었을 때의 제5층)의 추체 세포(錐體細胞) 수상돌기에 전기적 자극을 가하면, 세포에 활성 전위가 발생한다. 이때 세포체에 활성전위신호 s 는 수상돌기신호 d 보다 빠르며 진폭도 크다(그림1.B). 기록전극1에 전류를 주입하여 활성화시켜도 수상돌기에는 비슷한 활성전위가 유발된다.(그림1.C) 한편 세포밖에 복어 독(TTX)을 주입하여 이온이동을 차단하면, 그림1.D처럼 시간지연이 발생하지 않는다.

이것은 다음사항을 설명하고 있다. 신경전류는 세포체 즉 축색의 시작점에서 발화되며 이온이동에 의해 수상돌기로의 역행 전류가 흐른다. 즉 이온이동에 의한 수상돌기 스냅입력부위로의 피드백이 존재하며, 이 피드백은 발화를 촉진시킨다는 것을 알 수 있다(local positive feedback).

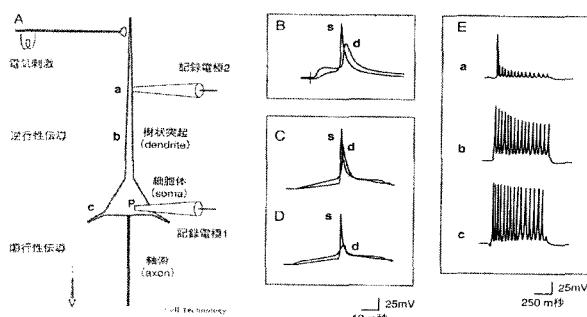


그림 1. 신경세포의 역행성 전도현상.

한편 그림1.E는 기록전극1에 고빈도의 교류자극을 가할 때 역행전류는 동일자극을 억제한다는 것을 나타내고 있다(a, b, c). 그림1.E에서 전기자극은 세포체 축색 기저부에 동일한 크기로 직접 인가되었지만 피드백에 의해 다시 기저부의 전류크기를 점차 감소시키고 있다(local negative feedback).

세포내에는 이러한 2종류의 국소피드백이 존재하고 있다는 것이 분명해졌다. 인공지능연구자들은 세포자신의 역할보다는 수상돌기 스냅결합(snap junction)의 가소성에 주목하여 이를 모방한 신경망(neural network)을 제안하고 있지만, 이러한 세포내의 피드백 활동에 대한 모델화는 간과하고 있는 면이 있다.

4.2. 수학적 모델링

세포내에서 이러한 2종류의 국소피드백이 어떠한 정보처리를 하는지는 알 수 없지만, 적어도 국소정보에 관여하여 독립적 정보처리를 하고 있다는 가정이 성립하며 수학적으로도 모델을 구축할 수 있다.

4.1절의 관찰결과를 토대로 이러한 작용을 할 수 있는 수학적모델을 아래 그림 2 와 같이 추정해 보았다.

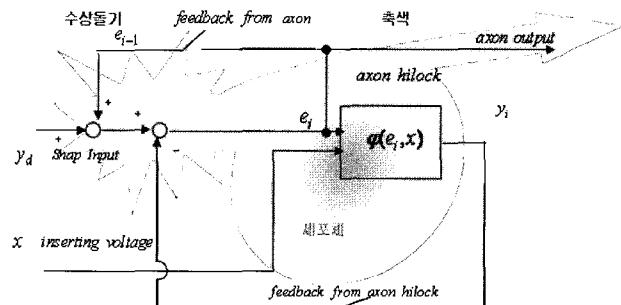


그림 2. 신경세포의 수학적 모델.

수상돌기의 스냅부분에서는 스냅입력과 시간적 지연을 갖는 positive feedback 축색 기저부에서의 negative feedback 이 합쳐져서, 다시 축색기저부로 전류가 흐르고, 한편 축색기저부에서는 무엇인가 알 수는 없지만 정보처리기구 ϕ 에 의해 발화여부가 결정되고, 축색으로 그 결과를 송출한다. 이 송출된 정보는 수상돌기 스냅부로 다시 전달되며 또 한편으로는 다음 신경세포에 전달된다. 그림 2 에서 세포체에 대한 외부전류 자극은 y_d 로 표현되고, 정보처리기구 ϕ 는 일종의 연산자라고 간주된다. 여기서 제시된 신경생리학적 지연을 토대로 한 이 수학모델은 다음절에서 설명하는 정보처리능력을 갖는다.

5. 운동패턴학습법

상기 수학모델을 통한 운동패턴학습방법과 그 수렴조건에 대해 검토하자. 학습목표패턴 $y_d(t)$, $t \in [0, T]$ 가 인간교시에 의해 주어지고, 신경모델의 ϕ 는 로봇의 동력학적 모델이라고 하자. 이때 로봇의 동력학적 모델을 전혀 모른다고 가정하고, 다음의 학습알고리즘을 통해 목표에 대한 수렴을 검토하자. 이때 모든

데이터는 패턴으로서, 오차 e_i 는 학습수행시 저장하였다가 다음 학습시의 입력구성에 이용한다. 아래첨자는 학습 횟수를 의미 한다.

5.1. 패턴학습법

미지의 비선형 연산자(operator) $\varphi: e \rightarrow y$, 즉 $y = \varphi(e)\circ$ 고, 학습횟수에 대해 미분가능하고 φ 의 역연산자 φ^{-1} 가 존재한다고 하자. 이러한 φ 에 대해서도 적절한 입력 e 를 구하면 출력 $y \rightarrow y_d$ 가 되는 학습이 가능하다. 함수 $y = \varphi(e)$ 에 대한 학습평가기준으로 다음과 같은 학습시행에 대한 각 시각별의 평가 Liapunov함수를

$$J(j) = \frac{1}{2} [y_d(j) - y(j)]^2 \quad (1)$$

로 정의하고 이를 최소로 하는 최적입력 e 를 구하는 문제이다. 이후 (j)의 표기는 생략하고 필요시에만 기술한다. 패턴내의 각 시각에 대한 평가함수 식(1)이 최소화된다면, 패턴에 대해 최소화된다는 것은 자명하다.

매회 학습마다의 평가함수의 변화량 ΔJ 가 $\Delta J \leq 0$ 이라면, 무한한 학습 횟수에 대해 $y \rightarrow y_d$ 이 될 것이다. ΔJ 를 미소변화에 대한 체인룰에 의해 전개하면

$$\Delta J = -(y_d - y) \frac{\partial y}{\partial e} \Delta e \quad (2)$$

한편, 학습입력을 수학모델의 입력구조를 고려하여, 오차와 오차에 대한 감도의 곱으로 놓아서

$$\Delta e = \frac{\partial y}{\partial e} (y_d - y) \quad (3)$$

와 같이 설정한다면

$$\Delta J = - \left[\frac{\partial y}{\partial e} \right]^2 (y_d - y)^2 \leq 0 \quad (4)$$

가 성립, 학습에 대한 수렴성이 보장된다. 또 $\Delta e = e_i - e_{i-1} \circ$ 므로 식(3)은 반복학습의 형태로

$$\Delta e = e_i - e_{i-1} = \frac{y_{i-1} - y_{i-2}}{e_{i-1} - e_{i-2}} (y_d - y_i) \quad (5)$$

가 된다. 단 i 는 학습의 시행횟수. 따라서 학습 i 번째의 입력은

$$e_i = e_{i-1} + \frac{y_{i-1} - y_{i-2}}{e_{i-1} - e_{i-2}} (y_d - y_i) \quad (6)$$

식(6)과 같이 구성하면 신경세포의 수학적 모델과 유사하며, 학습의 수렴성이 보장된다. 또한 위식은 최급강하법(search algorithm of steepest descent)과 유사하다.

또한 학습무한대에서

$$e_\infty = \varphi^{-1}(y_d) \quad (7)$$

가 성립하여, 목표값과 분리는 되어있지 않지만 역함수형태가 얻어진다.

5.2. 다입력1출력의 학습

뉴런에서와 같이 수상돌기의 다입력, 축색의 1출력과 같은 다입력 1출력의 경우, 학습은 다음과 같이 확장될 수 있다.

$$\begin{aligned} y &= \varphi(x, e), \\ J &= \frac{1}{2} (y_d - y)^2 \\ \Delta J &= -(y_d - y) \left\{ \frac{\partial y}{\partial x} \Delta x + \frac{\partial y}{\partial e} \Delta e \right\} \end{aligned} \quad (8)$$

식(4)와 같이 수렴성을 보장하기 위해

$$\Delta e = \frac{\partial y}{\partial e} (y_d - y), \quad \Delta x = \frac{\partial y}{\partial x} (y_d - y)$$

로 놓으면 유사한 결과가 얻어질 수 있다. 이때 학습입력은 아래와 같다.

$$e_i = e_{i-1} + \frac{y_{i-1} - y_{i-2}}{e_{i-1} - e_{i-2}} (y_d - y_i), \quad x_i = x_{i-1} + \frac{y_{i-1} - y_{i-2}}{x_{i-1} - x_{i-2}} (y_d - y_i) \quad (9)$$

5.3. 구속조건이 있는 학습

$y = \varphi(e)$ 일 때 e 에 대한 등식구속조건 $z = g(e)\circ$ 추가된 경우, 라그랑제 승수(Lagrange multiplier) λ 을 이용하여 다음 평가 함수

$$J = \frac{1}{2} (y_d - y)^2 + \lambda z \quad (10)$$

을 만족하는 학습입력 e 와 λ 를 구하자.

$$\Delta J = -(y_d - y) \frac{\partial y}{\partial e} \Delta e + \lambda \frac{\partial g}{\partial e} \Delta e + g(e) \Delta \lambda$$

여기서

$$\Delta e = \frac{\partial y}{\partial e} (y_d - y), \quad \Delta \lambda = -g^{-1}(e) [\lambda \frac{\partial g}{\partial e} \Delta e] \quad (11)$$

로 놓으면 $\Delta J \leq 0$ 즉 학습은 수렴한다. 단, $\Delta \lambda$ 를 얻기 위해 g^{-1} 가 이 학습이전에 구해져야 한다는 점을 주의해야한다. 따라서 이러한 구속문제는 먼저 g^{-1} 를 얻기 위한 학습이 이루어지고 나서, 다시 $y_d \leftarrow y$ 의 2차 학습을 하는 것이 좋다.

5.4. 다층세포에 의한 미지함수 학습

신경 각 세포의 흥분은 탈분극에서 재분극까지의 주기적인 과정으로서 각 주기 내에 신호가 유발된다. 따라서 비선형함수도 미소시간, 미소변화에서는 선형함수로 표현함이 신경세포내의 활동과 유사하게 된다고 생각된다.

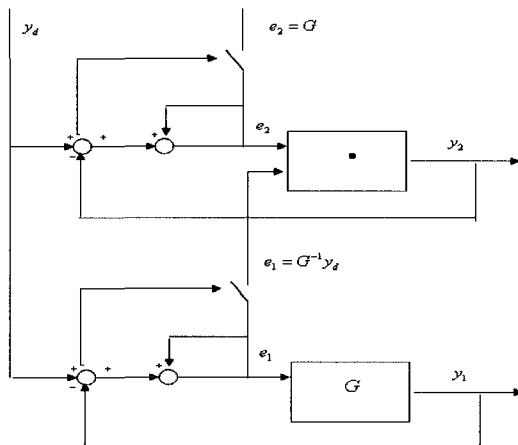


그림 3. 다층 패턴학습모델.

신경세포를 모방한 다층구조의 학습효과를 그림3을 통해 알아보자. 아래 부분은 미지의 환경과 접촉하고 있는 로봇시스템으로 설정하고, 한 개의 뉴런이 제어하고, 이 바로 위층은 아래에서 전달된 신호와 목표를 입력으로 하는 형태이다. (단, 로봇은 입력에 대한 출력구배, $\partial y / \partial e > 0$ 가 성립함으로서 식(6)의 우측 2항의 구배는 1로보고 그림과 같이 회로를 구성 하여도 수렴성이 보장됨). 우선 아래층은 상층으로부터의 신호가 영향을 주지 않기 때문에, 식(6)과 같은 학습입력에 대해, 궁극적으로 식(7)로부터 $e_1 = G^{-1} y_d$ 로 수렴할 것이다. 한편, 이때 상층부는 $y_2 = G^{-1} y_d + e_2$ 이며, 이것이 수렴한다면 입력 y_d 와 같아지게 된다. 즉 $y_2 = y_d = G^{-1} y_d + e_2$ 이므로, $e_2 = G$ 가 될 수밖에 없다. 즉 미지의 함수가 상층 출력으로 얻어지므로, 이를 타 세포에 기억시켜놓으면, 유사한 다른 목표패턴이 주어졌을 때 로봇의 적절한 제어입력을 생성시키거나 시스템 거동을 예측하는데 이용할 수가 있다.

6. 운동패턴학습의 시뮬레이션

5.1절에서 논의한 패턴 학습문제에 대해 검증하기위한 시뮬레이션 결과를 그림 4를 통해 보여주고 있다. 그림4의 대상 미지함수는 $\varphi = \sin e$ 로서 이때의 목표패턴 $y_d(t) = [0, 0.5]$ 의 step함수(우측 상부그래프)로 주어졌다. 그림의 좌상부는 학습회로로 그림2의 $x = 0$ 인 수학모델을 Matlab에서 구성한 것이다. 이때 학습제어법은 식(6)의 왼쪽 2번항의 구배를 1로 놓고 오차의 시간지연은 극히 미소하다고 설정하였다. 이 모델의 출력은 $y = 0.5$ 에 수렴하였으며(우측 2번째 그래프), e 또한 $e \Rightarrow \sin^{-1} y_d$ 에 해당하는 값에 수렴함을 확인할 수 있었다(우측 3번째 그래프).

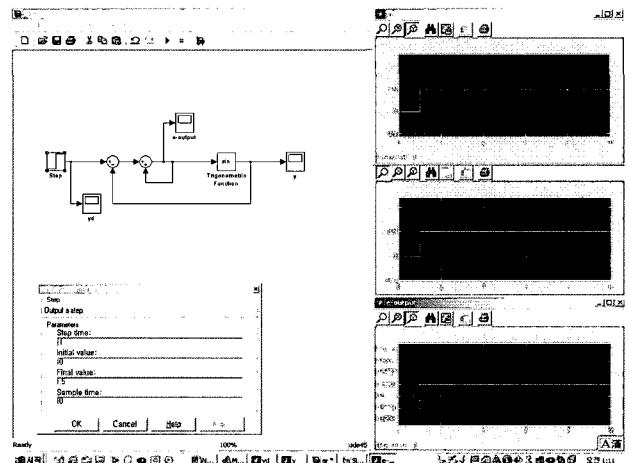


그림 4. 운동패턴학습제어의 수렴.

7. 결언

서비스로봇은 다양한 환경에서의 작업이 중요하다. 이에 대응하기 위해서는 로봇자신이 경험을 통해 행동패턴을 다수 획득하고, 구조화하는 능력이 필연적으로 요구되며, 이러한 패턴이 추상화됨으로서, 보다 유연한 작업성을 발휘할 수 있다고 판단된다. 신경계에서 말단신경세포는 신호전달과 압축을 담당하고, 반사는 등골중추에서, 그리고, 소뇌에서는 운동의 학습과 저장, 대뇌에서는 추상화된 지능정보처리가 이루어진다고 보여진다.

여기서 논의한 운동패턴학습은 이러한 신경계를 모방한 학습방법의 하나로, 이론적으로 결과를 설명할 수 있었다. 그러나지면관계로 다층모델에 대한 운동패턴학습의 수렴성과 시뮬레이션결과에 대해서 상세히 논의하지 못하였으나, 이러한 접근법의 가능성은 기대할만하다고 보여 진다.

다만, 다중구조의 학습법은 획적결합, 계층적 결합 등 구조적배치에 대한 많은 과제를 안고 있다. 또한, 학습에는 주어진 목표를 활용하였는데, 향후, 로봇이 스스로 목표를 설정하는 방법론개발도 중요하다고 여겨진다.

참고문헌

- [1] “지능형로봇산업비전과 발전전략”, 보고서, 산자부, 2005.
- [2] J. Y. Kim, H. R. Choi, and H. G. Lee, “experimental investigation on skilled human’s typing pattern for development of new input device”, *J. of Control, Automation and Systems Engineering*, vol. 9, no. 9, 720-726, 2003.
- [3] J. G. Nicoholls, et al, *From Neuron to Brain*, Sinauer Association, Inc, 4'th Edition, 2000.
- [4] G. J. Stuart, et al, *Nature*, 356, 69-72, 1994.
- [5] N. Spruston, et al, *Science* 268, 297-300, 1995.
- [6] A. Arimoto, “learning control theory for robot motion”,

J. of Adaptive Control and Signal Processing, vol. 4, no. 5, 1990.

- [7] 이호길, “intelligent machine system에 관한 연구”, 생기원, 1992.

저자약력



《이 호 길》

- 1980년 한양대학교 기계공학과 졸업.
- 1980년~1983년 현대정공 사원.
- 1984년~1989년 오오사카대학 대학원, 로보틱스 석사, 박사.
- 1989년~1991년 ASTEM 연구소 주임연구원.
- 1991년~현재 한국생산기술연구원, 성장동력 지능형로봇사업단 단장.
- 관심분야 : 로봇지능, 로봇제어.