

인간형 로봇의 동작궤적 학습 및 생성

Learning and Generation of Motion Trajectory in a Humanoid Robot

진영규, 사공준, 최진영

서울대학교 전기·컴퓨터공학부 지능 연산 제어 연구실, 자동화 시스템 연구소

y.g.jin j.sakong and j.y.choi

school of electrical engineering & Computer Scienc, ASRI Seoul National University

E-mail: jychoi@neuro.snu.ac.kr

본 논문에서는 작업 변수 또는 동작의 의도에 따라 다양한 형태의 궤적을 생성할 수 있는 동작 궤적 메모리(MTM)와 로봇 관절의 속도 및 가속도 제약조건을 만족하는 동작 시간을 계산하는 방법인 제약 조건을 고려한 표본화 간격 계산법(STICCON)이라는 두 가지 방법을 제시한다. 그리고 그 방법은 인간형 로봇의 동작 궤적 생성을 위한 구조적인 틀을 제안한다. 제안된 방법은 인간형 로봇의 궤적 생성 방법이 가져야 하는 두 가지 특성, 즉 복잡하고 다양한 동작의 궤적 표현 능력과 제약 조건에 따른 동작 궤적의 변형 과정을 모두 가지고 있다.

Keywords : 궤적 생성, 인간형 로봇, 동작 프로그램, 신경회로망, 일반화

I 서론

산업용 로봇이 정확성과 견실성을 보장하기 위해 단순한 형태의 궤적을 사용하는 것과는 달리, 인간형 로봇은 인간과 유사한 동작을 하는 것을 목표로 하기 때문에, 복잡하고 다양한 동작을 나타낼 수 있는 궤적 생성 방법이 필요하다.

인간형 로봇에 사용하는 대표적인 궤적 생성 방법은 궤적 생성과 동작 시행이 분리된 계층화 모델[12]에 기반을 둔 것들[2,6,7,8,10,13,14]이다. 즉, 계획 단계에서 기준 궤적이 만들어지고, 제어기는 기준 궤적을 추종(tracking)한다.

이에 반해, Kawato[9]는 궤적 생성과 제어가 통합된 형태로서 최소 토크 변화 기준을 이용한 중속형 인공신경망을 제안하였다.

로봇의 궤적을 생성할 때 고려해야 할 사항은 로봇의 관절에 속도 및 가속도 등의 제약 조건이 주어진다는 것이다. 따라서, 인간형 로봇의

궤적 생성 방법은 복잡하고 다양한 동작을 표현 할 수 있어야 할 뿐만 아니라, 관절에 주어진 제약 조건을 만족시키도록 궤적을 적절하게 변형할 수 있는 과정도 포함해야 한다.

본 논문에서는 작업 변수 또는 동작의 의도에 따라 다양한 형태의 궤적을 생성할 수 있는 동작 궤적 메모리(Motion Trajectory Memory, MTM)와, 로봇 관절의 속도 및 가속도 제약 조건을 만족하는 동작 시간을 계산하는 방법인 제약 조건을 고려한 표본화 간격 계산법(Sampling TIIme Calculation under the CONstraints, STIC CON)이라는 두 가지 방법을 결합하여 인간형 로봇의 동작 궤적 생성을 위한 구조적인 틀을 마련하고자 한다.

MTM은 인간의 기억 구조가 장기 기억과 단기 기억으로 이루어진다는 연구 결과[1,15]에 따라 LT-MTM(Long-Term MTM)과 ST-MTM(Short-Term MTM)으로 구성된다. MTM의 주요 기능은 학습과 일반화인데, 이는 신경회로망이 가진 기본적인 특징이므로 MTM을 구현할 때에 신경회로망을 이용한다. STICCON은 동작

1) 이 연구는 두뇌한국21 사업과 뇌과학연구 사업의 지원에 의해 이루어 졌습니다.

시간을 계산하여 MTM으로부터 만들어진 궤적
이 제약 조건을 만족하도록 한다.

II MTM과 STICCON을 이용한 궤적 생성

1 입력 변수가 하나인 연속 함수를 근 사화 하는 신경회로망의 학습

신경 회로망의 전형적인 학습 알고리즘이라고
할 수 있는 오차 역전파 알고리즘(error back-propagation algorithm)은 상당한 학습 시간을 필요로 한다. 그런데, 입력 변수가 하나인 경우에
는 다음의 공식으로부터 별도의 학습이 없이도
연결 가중치를 쉽고 빠르게 계산할 수 있다.[4]

하나의 은닉층을 가진 다중 인식자로 입력변
수가 하나인 연속함수 을 근하는 경우를 생각해
보자. 연속함수 $f: R \rightarrow R$ 는 닫힌 구간 $[a, b]$ 에서
부분적으로 미분 가능하므로, 도함수 f' 를 여러
개의 계단 함수로 근사할 수 있다. 따라서 임의의
구간구획 $P: a = x_0 < x_1 < \dots < x_n = b$ 에 대하여
추정 도함수 \hat{f}' 를 다음과 같이 나타낼 수 있다.

$$\hat{f}' = \sum_{i=1}^n f'(x_i^-) [u(x - x_{i-1}) - u(x - x_i)], x \in [a, b] \quad (1)$$

여기서 $u(\cdot)$ 는 단위 계단 함수이고, $f'(x_i^-)$ 는
점 x_i 에서의 좌극한 값이다. 그러면 근사 함수 \hat{f}
는 다음과 같이 신경회로망의 기본형태로 나타
낼 수 있다.

$$\begin{aligned} \hat{f} &= \int_a^b \sum_{i=1}^n f'(x_i^-) [u(x - x_{i-1}) - u(x - x_i)] d\tau + f(a) \\ &= \sum_{i=1}^n v_i \phi(\omega_i x + \beta_i) + \alpha \end{aligned} \quad (2)$$

$$v_i = f'(x_i^-) \cdot (x_i - x_{i-1}) \approx f(x_i) - f(x_{i-1})$$

$$\omega_i = \frac{1}{x_i - x_{i-1}}$$

$$\phi(z) \approx \frac{1}{1 + e^{-\mu z}}$$

$$\alpha = f(x_0), \beta_i = \frac{- (x_i + x_{i-1})}{2(x_i - x_{i-1})} \quad (3)$$

μ - 과도 영역의 기울기

v_i - 출력 뉴런과 i 번째 뉴런사이의 가중치

ω_i - i 번째 은닉층 뉴런과 입력 뉴런사이의 가중치

α - 출력 뉴런의 바이어스

β_i - i 번째 은닉층 뉴런의 바이어스

이와 같이, 입력 변수가 하나인 연속 함수의 표
본 자료 집합이 주어지면, 식 (2), (3)으로부터
별도의 학습 과정 없이 인공 신경망의 가중치와
바이어스를 계산할 수 있다.

2 신경회로망을 이용한 동작 궤적 메 모리(MTM)

MTM은 다음과 같이 관절의 각도 벡터 $\theta(t)$
를 출력으로 하는 함수의 형태로 수식화 할 수
있다.

$$\theta(t) = f(t, \text{parameter}) \quad (4)$$

식 (4)에서 볼 수 있듯이, 원하는 동작의 궤적을
생성하는 것은 개념적으로 매우 간단하다. 그러나
동작 궤적 생성을 위한 MTM을 구성하는 데
는 두 가지 문제가 있다. 하나는 적당한 파라미
터들을 설정하는 문제이고, 다른 하나는 설정한
파라미터들과 관절 벡터를 연결시키는 관계식
 f 를 구하는 문제이다. 파라미터 설정 문제는 다
음과 같이 3개의 파라미터를 가지는 것으로 해
결한다.

$$\theta(t) = f(t, x_{\text{type}}, x_{\text{task}}, x_{\text{pace}}) \quad (5)$$

x_{type} - 동작의 유형에 관한 파라미터

x_{task} - 동작의 목표 또는 과제에 대한 파라미터

x_{pace} - 동작의 속도에 대한 파라미터

그러나 f 를 다항 함수 같은 명시적인 형태로
나타내는 것은 불가능하다. 이렇게 형태를 정확
하게 알 수 없는 함수를 근사할 때 유용하게 사용
할 수 있는 도구가 바로 신경회로망이다. 신경
회로망은 임의의 함수를 표현할 수 있다는 것이
증명되어 있기 때문에[5], 궤적이 아무리 복잡하
더라도 f 를 충분히 표현할 수 있다. 뿐만 아니라
신경회로망의 일반화 특성을 이용하여 인간의
동작 제어 시스템이 가진 다음과 같은 특성을
MTM에서 구현할 수 있다.

1. 파라미터 공간에서의 일반화

신경회로망은 주어진 자료를 학습하고 일반화
하므로, 몇 가지 파라미터 값에 대한 자료만으로
전체 파라미터 공간에 해당하는 MTM을 구성할
수 있다.

2. 동작 수정 과정에서의 일반화

신경회로망은 이미 학습한 내용을 초기값으로
새로운 자료를 학습하기 때문에, 수정된 결과는
저장되어 있던 내용과 크게 달라지지 않는다. 이
와 같은 신경회로망의 특징은 특정 점에 대한
정보 수정만으로 동작을 학습하는 인간의 동작
수정 과정을 모방할 수 있게 한다.

2-1 MTM의 구조와 형성 방법

MTM은 LT-MTM과 ST-MTM으로 이루어
지는데, 두 가지 MTM 모두 신경회로망을 이용
하여 구현하지만 구조와 기능 등은 서로 다르다.

a) LT-MTM

LT-MTM에서는 파라미터 x_{last} 에 대해서만 일반화가 이루어진다. LT-MTM의 출력인 관절의 궤적은 제어기의 기준 궤적으로 직접 사용되지 않고, 일단 ST-MTM에 저장된다. 그러면 ST-MTM은 적절한 수정 과정을 거쳐 제어기의 기준 궤적을 만들어 낸다. LT-MTM은 저장해야 할 자료가 많기 때문에 온너층 뉴런의 개수를 가능하면 많이 사용한다. 그러나 너무 많을 경우 학습에 너무 오랜 시간이 필요하기 때문에 실제 응용에서는 어느 정도 제한을 두어야 한다. LT-MTM에 사용할 수 있는 신경회로망의 종류와 학습 방법은 여러 가지가 있지만, 본 논문에서는 다층 인식자(multi-layer perceptron)와 오차 역전파 알고리즘을 이용하여 LT-MTM을 구현하였다.

b) ST-MTM

ST-MTM은 LT-MTM에서 생성한 동작 궤적을 저장한다. LT-MTM이 충분한 자료를 학습하여 파라미터의 일반화가 완벽하게 된 경우에는, 옮겨진 궤적이 상당히 정확하기 때문에 그대로 사용하면 된다. 그러나, 일반화가 완벽하지 않으면, 현재 수행하고자 하는 동작의 상황에 맞는 약간의 수정이 필요하다. 이와 같이 동작 수정 과정에서의 일반화는 ST-MTM이 수행하는 주요 기능이 된다. ST-MTM은 동작 파라미터를 처리하지 않기 때문에 단지 시간 벡터만을 입력으로 사용한다. ST-MTM은 기준에 저장되어 있던 내용은 지우고 새로운 내용을 저장하는 과정을 반복해야 하므로 학습이 빠르게 이루어져야 한다. 여기서 주목할 점은 ST-MTM의 입력이 하나뿐이라는 사실이다. 따라서 2.1 절에서 설명했던 방법을 사용하여 학습 없이 신경회로망의 가중치와 바이어스를 계산할 수 있고, ST-MTM의 요구 조건을 만족시킬 수 있다. 본 논문에서는 입력이 하나인 다층 인식자와 식(2), (3)의 계산 방법을 이용하여 ST-MTM을 구현하였다.

c) MTM의 형성 과정

MTM은 네 가지 단계, 즉 시범단계(demonstration phase), 상기 단계(recall phase), 수정단계(correction phase), 장기 기억 단계 (permanent storage phase)를 거쳐 만들어진다.

i) 시범 단계(demonstration phase)

특정한 동작 파라미터에 대한 동작 궤적으로 LT-MTM을 학습시킨다. 이 과정은 동작에 대

한 원형(prototype)을 학습하는 것으로 생각할 수 있다.

ii) 상기 단계(recall phase)

현재 수행해야 하는 동작의 파라미터를 LT-MTM에 입력으로 주어 궤적을 생성한다. 그리고 나서, 생성된 궤적을 ST-MTM에 저장한다.

iii) 수정 단계(correction phase)

상기 단계에서 ST-MTM에 저장된 궤적이 현재의 동작을 수행하는데 적당하지 않으면, 올바른 정보를 얻어 ST-MTM에 저장된 궤적을 수정한다. 수정된 궤적은 제어기의 기준 궤적으로 사용된다.

iv) 장기 기억 단계 (permanent storage phase)

수정 단계에서 개선된 사항을 반영하기 위해, 동작이 끝난 후에 해당하는 동작 파라미터와 수정 정보를 LT-MTM에 저장한다.

3 제약 조건을 만족하는 동작 시간 계산 알고리즘(STICCON)

STICCON 알고리즘을 적용하기 전에 역기구 학과 궤적 생성방법을 통하여 제약조건을 고려하지 않은 관절 궤적 $\theta^i(t)$ 를 생성한다. 그리고 나서, STICCON 알고리즘으로 동작 시간 t_f 를 계산한다. 구체적인 방법은 다음과 같다.

먼저 표본점의 개수 N_s 를 결정하고, $\theta^i(t)$ 를 표본화하여 이산형 궤적 $\theta^i_k, k=1, \dots, N_s$ 로 나타낸다. 이산형 궤적과 수치미분공식으로 부터 관절의 속도와 가속도를 계산한다.

$$v_k^i = \frac{\theta_{k+1}^i - \theta_k^i}{\Delta t} \quad (6)$$

$$a_k^i = \frac{\theta_{k+1}^i + \theta_{k-1}^i - 2\theta_k^i}{\Delta t^2} \quad (7)$$

여기서, v_k^i, a_k^i 는 각각 k 번째 시간 지점에서 i 번째 관절의 속도와 가속도를 나타내고, Δt 는 표본화 간격을 나타낸다. Δt 는 $k=1, 2, \dots, N_s - 1$ 에 대하여 속도 제약조건

$$V_{\min}^i \leq \frac{\theta_{k+1}^i - \theta_k^i}{\Delta t} \leq V_{\max}^i \quad (8)$$

을 만족하고, $k=2, 3, \dots, N_s - 1$ 에 대하여 가속도의 제약조건

$$A_{\min}^i \leq \frac{\theta_{k+1}^i + \theta_{k-1}^i - 2\theta_k^i}{\Delta t^2} \leq A_{\max}^i \quad (9)$$

을 만족해야 한다. 여기서 V_{\max}^i 와 V_{\min}^i 은 각각 i 번째 관절 속도의 상한과 하한이고, A_{\max}^i 와 A_{\min}^i 는 i 번째 관절 가속도의 상한과 하한이다. 로봇 관절의 속도와 가속도의 상한과 하한은 각각 양수와 음수이어야 한다. 그리고, 어떤 Δt




그림 1 수정단계 이전의 궤적




그림 2 MTM으로 학습 완료 후의 궤적




그림 3 MTM과 STICCON을 사용하여 나타낸 궤적

IV 참고 문헌

- [1] J.R.Andersson. *Aggressive trajectory generator for a robot ping-pong player*. Int'l Conference on Robotics and Automation, pp 188-193, 1988
- [2] D.Bullock, and S. Grossberg. *Neural dynamics of planned arm movements: emergent invariants and speed-accuracy properties during trajectory formation* Psychological Review, 95, pp45-90, 1988.
- [3] S.Chiaverini and G.Fusco. *A new inverse kinematics algorithm with path tracking capability under velocity and acceleration constraints*. Proc.38th IEEE Conf. Decision and Control, vol 3, pp. 2064-2069, 1999
- [4] C.-H.Chi and J.Y.Chi. *Construction of neural networks to approximate arbitrary continuous functions of one variable*. IEE Electronics Letters, vol. 28, pp.151-153, 1992
- [5] G.Cybenko. *Approximation by superpositions of a sigmoidal function*. Mathematics of control, Signals, and Systems, vol. 2 pp. 303-314 1989.
- [6] G.Z.Grudic and P.D Lawrence. *Human-to-robot skill transfer using the SPORE approximation*. Int'l Conference on Robotics and Automation, pp. 2962-2967, 1996
- [7] G.Hayes and J.A Demiris. *A robot cart roller using learning by imitation*. Proceedings of the 2nd International Symposium on Intelligent Robotic Systems, pp 198-204, 1994
- [8] J.C Houk, S.P.Singh, C.Fisher, and A.G Barto. *An adaptive sensorimotor network inspired by the anatomy and physiology of the cerebellum*. Neural Networks for Control, MIT Press, pp.301-348. 1990
- [9] M.Kawato Y.Maeda, Y.Uno, and R.Suzuki. *Trajectory formation of arm movement by cascade neural network model based on minimum torque-change criterion*. Biological Cybernetics, vo. 62 pp. 275-288 , 1990
- [10] H.Miyamoto, S.Schall, andolfo, Y, Koite, R.Osu, E.Nakano, Y.Wada, and M.Kawato. *A Kendama learning robot based on bidirectional theory*. Neural Networks, vol. 9, pp. 1281-1302, 1998
- [11] P.Morasso and V.Sanguineti. *Neural models of distributed motor control. Tutorials in Motor Behavior II*, Elsevier Science Publishers, pp. 3-30, 1992.
- [12] S.Schaal. *Learning from demonstration*. Advances in Neural Information Proceeding Systems, MIT Press, vol. 9, pp.605-611, 1997
- [13] S.Schaal and D.Sternad. *Programmable pattern generators*. Int'l Conference on Computational Intelligence in Neuroscience (ICCIIN'98), pp.48-51, 1998
- [14] R.A.Schmidt and T.D.Lee. *Motor Control and Learning: A Behavioral Emphasis*, 3rd ed., Human Kinetics, 1998