

뉴럴 네트워크를 이용한 로봇 매니퓰레이터의 역보정

Inverse Calibration of a Robot Manipulator Using Neural Network

정동연*, 김종수*, 한성현**

* 경남대학교 대학원(Tel : 0551-249-2590; Fax : 0551-249-2617)

** 경남대학교 기계자동화공학부(Tel: +82-551-249-2624; Fax: +82-551-243-8133)

Abstract

The robot inverse calibration method using a neural networks is proposed in this paper. A high-order networks has been used in this study. The Pi-Sigma networks uses linear summing units in the hidden layer and product unit in output layer. The inverse calibration model which compensates the difference of joint variables only between measuring value and analytic value about the desired pose(position, orientation) of a robot is proposed. The compensated values are determined by using the weights obtained from the learning process of the neural networks previously. To prove the reasonableness, the selected compliance automatic robot arm type direct drive robot and anthropomorphic robot are simulated. It shows that the proposed calibration method can reduce the errors of the joint variables from $\pm 0.15^\circ$ to $\pm 0.12^\circ$.

1. 서론

로봇의 위치 정밀도는 반복 위치 정밀도와 절대 위치 정밀도로 구분될 수 있다. 이중 전자는 주로 제어기 분해능에 의해 좌우되는데, 현재 사용되고 있는 로봇의 대부분은 만족할 만한 수준을 보이고 있다. 반면 절대 위치 정밀도는 로봇의 구조, 재질 등에 따라 다양하게 제작, 사용되고 있기 때문에 결국 사용자에게 의한 보정 작업이 이루어져야 한다. 절대 위치 정밀도에 영향을 미치는 요소로는 각 조인트간의 관계를 정의하는 로봇 인자들의 기하학적인 오차와 로봇의 특성에 의해 생기는 비기하학적인 오차로 분류될 수 있으며, 이들은 모델링, 측정, 동정 및 보상의 절차

를 통해 이루어진다[1].

기하학적 오차 보정에 대해서는 Denavit-Hartenberg[2]가 4개의 인자에 의한 기구학적 모델 표현 방법을 제시한 이후 Veitschegger[3], Hayati[4], Stone[5]등에 의해 다양한 보정 모델이 제시되었다.

비기하학적인 오차에 대한 보정으로 Whitney 등[1]은 조인트 컴플라이언스, 백래쉬 등에 대한 보정을 실시한 바 있고, Judd 등[6]은 온도 구배, 서보 오차, 구조 변형, 기어의 오차 및 마모 등에 대한 오차 보상 모델을 제시한 바 있다.

그러나, 이러한 기하학적 및 비기하학적 오차 모델들은 실제 사용자 측면에서 볼 때 보정 방법이 복잡할 뿐만 아니라 보상할 인자의 수도 많아 비효율적이어서, Shama 등[7]은 조인트 변수와 로봇 말단부의 자세와의 관계를 블랙 박스로 나타내어 비교적 간단히 보정할 수 있는 방법을 제시하였다. 이후 Menq 등[8]은 가관측성측정을 통한 보정 방법을, Mirman 등[9]은 반복 보상 알고리즘을 사용하여 조인트 변수만으로 비교적 간단하며 직접적으로 보정할 수 있는 방법을 제시하였다.

이러한 단순한 보정 기법은 90년대를 전후로 하여 로봇의 보정에 신경 회로망이 사용되면서, 로봇의 각 조인트 변수만으로 보정하기 위한 연구가 많이 진행되었다. Ahmad 등[10]은 로봇의 역 기구학을 구하기 위하여 역 오류 전과 알고리즘에 의한 신경 회로망과 수치해석적 방법이 병행된 하이브리드 방법을 각각 사용한바 있으며, Kieffer 등은 SOM 알고리즘을 사용하여 로봇 팔의 역 기구학을 구한 바 있고, Watanabe 등은 백프로퍼게이션 학습 과정의 속도 향상을 위해 2단 학습 신경 회로망을 사용하였다. 그러나 이러한 백프로퍼게이

선 알고리즘은 로봇과 같이 비선형성이 강한 경우에는 은닉층 및 유닛의 수에 따라 학습 시간이 많이 소요 되고 지역 최소값에 빠지기 쉽다는 단점이 있어, Ghosh등은 1992년에 고차 다항식과 유사한 형태로 구성된 Pi-Sigma 신경 회로망을 제시하여 기존의 백프로퍼게이션 방법에 비해 좋은 결과를 얻은 바 있다.

따라서, 본 논문에서는 Ghosh등이 제시한 파이-시그마 신경 회로망을 사용하여 비교적 단순하면서도 정확하게 보정할 수 있는 보정 방법을 제시하고자 한다.

보정은 기존의 모델링-보상의 4단계를 본 연구에서는 측정 및 보상의 2단계로 실시하고, 보상할 인자로는 역 보정으로 기하학 및 비기하학적 오차 요인이 모두 포함되어 보상될 수 있도록 파이-시그마 신경 회로망을 사용하여 조인트 변수만으로 보상이 가능토록 한다. 제시된 방법의 타당성 검증을 위하여 4자유도 및 6자유도 로봇에 대한 모의 실험을 실시한다.

2. 본론

2.1 뉴럴네트워크

본 논문에서 사용된 파이-시그마 신경 회로망의 구조는 그림 1과 같다.




그림 1. 파이-시그마 신경 회로망의 구조.

이 구조는 1개의 은닉층이 사용되어 각 유닛에서는 더해지고, 출력층에서는 각 유닛이 곱해지는 형태로 고차의 비선형 방정식을 가지는 경우에 비교적 적합한 것으로 이미 증명된 바 있다. 이때 가중치는 은닉층에서만 갱신되고, 출력층에서는 고정된 값을 가지며, 출력층 유닛의 각각에 대하여 개별적인 학습이 이루어지는 특징이 있다.

학습은 다음과 같이 이루어진다. 우선 μ 번째

의 입력 데이터에 대하여 j 번째 은닉층 유닛 및 k 번째 출력층 유닛에서의 출력을 각각 h_j^μ , h_k^μ 라고 하면, h_j^μ 및 h_k^μ 는 은닉층 유닛의 수, m 개에 대하여 식(1) 및 (2)와 같이 나타낼 수 있다.

$$h_j^\mu = \sum_i w_{ji} x_i^\mu \quad (1)$$

$$h_k^\mu = \prod_j W_{kj} h_j^\mu = \prod_j W_{kj} \left(\sum_i w_{ji} x_i^\mu \right) \quad (2)$$

그리고, μ 번째 입력 데이터에 대한 k 번째 출력층에서의 목표치(desired value)를 y_k^μ 라고 했을 때, 에너지 함수(energy function), E 를 식(3)과 같이 정의하면,

$$E = \frac{1}{2} \sum_{\mu} (y_k^\mu - h_k^\mu)^2 = \frac{1}{2} \sum_{\mu} (y_k^\mu - \prod_j W_{kj} h_j^\mu)^2 \quad (3)$$

식(3)으로부터 갱신되는 가중치, ΔW_{ji} 는 최급 하강 규칙을 사용하여 식(4)와 같이 나타낼 수 있다. 이때 은닉층과 출력층간의 가중치, W_{kj} 는 일정하므로 ΔW_{kj} 는 고려할 필요가 없다.

$$\Delta W_{ji} = -\eta \frac{\partial E}{\partial W_{ji}} = -\eta \frac{\partial E}{\partial h_j^\mu} \frac{\partial h_j^\mu}{\partial W_{ji}} \quad (4)$$

여기서

$$\frac{\partial E}{\partial h_j^\mu} = -\sum_{\mu} (y_k^\mu - \prod_j W_{kj} h_j^\mu) \cdot \prod_{l \neq j} W_{kl} h_l^\mu \cdot W_{kj}$$

$$\frac{\partial h_j^\mu}{\partial W_{ji}} = X_i^\mu$$

이고, η 는 학습율이다.

2.2 역 보정 모델

로봇의 보정을 위해서는 우선 로봇의 정확한 자세 측정이 중요하다. 현재 주로 사용되고 있는 로봇의 자세 측정 장치로는 좌표 측정기, 레이저 트래킹 시스템, 레이저 경위의 및 비전 시스템등을 들 수 있으며, 이러한 측정 장치는 현재 $\pm 0.01mm \sim \pm 0.1\mu m$ 까지 측정이 가능하다. 이러한 위치 정밀도는 산업용 로봇의 사양, 즉 산업용 로봇의 위치 정밀도($\pm 0.05 \sim 0.1mm$)를 고

려할 때 만족할 만한 수준으로 사용자의 선택에 의하여 정확한 자세 측정이 가능하다. 따라서 본 논문에서는 측정 장치로부터 얻은 데이터는 오차가 없는 정확한 값으로 가정하였으며, 측정방법 및 그에 따른 각종 오차는 본 논문의 범주에서 벗어나므로 고려하지 않았다.

측정된 데이터, 즉 로봇의 정확한 자세로부터 로봇의 인자를 보상하는 로봇의 역보정은 Denavit-Hartenberg 인자를 근거로 한 오차 모델의 모든 인자들을 보상하는 방법과, 각 조인트의 변수만을 보상하는 방법으로 구분될 수 있다. 본 연구에서는 비교적 간단한 후자의 방법을 사용하여 주어진 로봇의 자세에 대한 역 기구학과 측정을 통하여 얻은 데이터와의 차이를 보상토록 하였다.

실제 로봇에 있어서 요망하는 자세(위치, 방위)에 대한 로봇의 각 조인트 변수의 값은 로봇의 역 기구학에서 해석적으로 얻은 값(θ_a)과 실제 측정을 통해 얻은 값(θ_m)과는 식(5)와 같은 조인트 변수의 오차($\Delta\theta$)를 가지게 된다.

$$\Delta\theta = \theta_m - \theta_a \quad (5)$$

따라서 이러한 조인트 변수의 오차를 어떻게 보상해 주느냐에 따라 보정 방법이 결정되는데, 본 논문에서는 그림 2와 같은 역 보정 모델을 사용하였다.

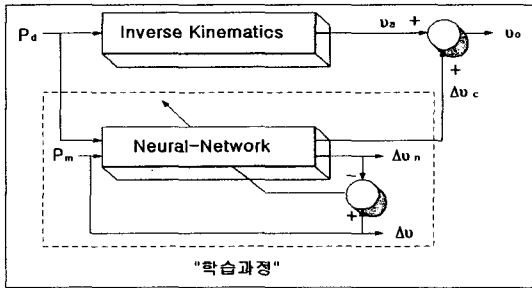


그림 2. 역보정 모델.

그림 2에서 P_d 는 요망하는 자세, θ_a 는 P_d 에 대한 역 기구학의 해이며 $\Delta\theta_c$ 는 조인트 변수의 보상 값이다. 그리고 Learning process에서 P_m 은 학습을 위해 측정된 로봇의 자세이고, $\Delta\theta$ 는 식(5)에서 구한 값이며, $\Delta\theta_n$ 은 신경 회로망(NN)의 학습 단

계에서 계산된 값이다.

학습은 그림 2의 학습과정에서 측정치(P_m)와 식(5)에서 얻은 조인트 변수의 오차($\Delta\theta$)를 각각 입력, 출력으로 하여 앞의 2장에서 설명된 Pi-Sigma 신경 회로망(NN)에 대하여 이루어진다. 이때 학습은 역 오류 전파 알고리즘에 의해 각 층간의 가중치 W_{kj} , W_{ji} 를 결정한다.

따라서 이렇게 결정된 가중치를 이용하면 요망하는 로봇의 자세에 대하여 조인트 변수의 오차($\Delta\theta_c$)를 직접적으로 보상이 가능하게 된다.

3. 실험 및 결과

모의 실험은 현재 본 연구실에서 보유한 수평 다관절 로봇인 SM5와 수직 다관절형 로봇인 AM1에 대하여 실시하였다.

사용된 SM5 로봇은 4자유도를 가지는 SCARA형 직접 구동 방식 로봇으로 그 형상은 그림 3과 같다.




그림 3. SM5 로봇의 좌표계.

SM5 로봇의 역 기구학에서 살펴보면, 로봇의 Z방향 변위, P_z 및 Z축에 대한 회전각, ϕ 는 각각 조인트 변수중 d_3 와 θ_4 에 대하여 1:1 매핑이 가능함을 알 수 있으므로, 여기서는 파이-시그마 신경 회로망의 타당성 검증을 위해 x, y좌표 값(P_x, P_y)에 대한 조인트 변수의 오차 $\Delta\theta_1, \Delta\theta_2$ 를 보정하는 경우만을 제시한다.

SM5로봇에서 2차원 평면상의 reachable workspace는 극좌표계(r, θ)에서 $125mm \leq r \leq 640mm, 0^\circ \leq \theta \leq 360^\circ$ 의 범위를 가지므로, 본

논문에서는 로봇의 오차를 대표적으로 나타내 줄 수 있다고 생각되는 1사분면에 대해서만 고려하였다.

데이터는 그림 4에서 보는바와 같이 등 간격 ($r=40mm$, $\theta=8.18^\circ$)으로 100개의 학습 데이터를 얻었으며, 조인트 변수의 오차 $\Delta\theta_1, \Delta\theta_2$ 는 $\pm 5^\circ$ 이내의 값을 사용하였다. 이때 로봇의 요망하는 자세에 대하여 1축과 2축의 조인트 변수가 상호 상쇄 혹은 보완되는 경우를 고려하여, $\Delta\theta_1$ 는 +, - 양방향의 오차를, $\Delta\theta_2$ 는 + 방향의 오차만 가지도록 하였다.




그림 4. 데이터 획득.

100개의 패턴에 대한 학습을 통하여 가장 적절한 은닉층의 유니트 수로 3개를 사용하였으며, θ_1 및 θ_2 의 학습율은 각각 0.05, 0.5였다.

그림 5는 에포크수에 따른 에너지 함수의 수렴정도를 보여주는 것으로 대체로 빨리 수렴함을 알 수 있다. 그러나 조인트 변수의 오차 범위, 즉 +, - 양방향으로 준 경우와 그렇지 않은 경우를 비교해 볼 때, 한 방향으로 오차를 준 경우가 빨리 수렴하면서 에너지 함수도 적음을 알 수 있었다.

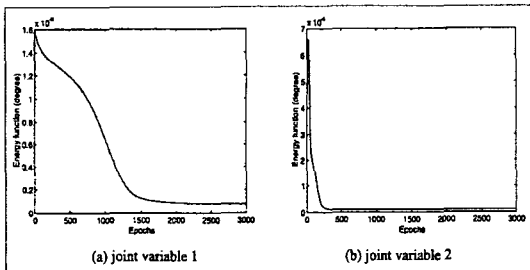


그림 5. SM5 로봇 학습의 결과

표 1은 3000 에포크로 학습된 결과를 이용하여 역 보정 모델에 의해 보상된 결과를 보여 주고 있다.

표 1. SM5 로봇의 역보정 결과.

unit : degree

Joint variable	Before calibration			After calibration		
	Average	Deviation	Max.	Average	Deviation	Max.
θ_1	0.480	0.320	1.276	0.097	0.075	0.192
θ_2	2.600	0.685	3.591	0.037	0.028	0.075

표 1에서 보면, 보정 전에 각 조인트의 절대 오차 평균이 0.475° , 2.6125° 이던 것이 보정 후에는 0.0971° 및 0.0372° 로 감소됨을 알 수 있었다. 이는 SM5 로봇 조인트의 레졸버 분해능 2048 pulse/rev. (0.1756°)을 고려하면 만족할 만한 값으로, 보상 가능한 최소 단위까지 보정될 수 있음을 알 수 있다.

AMI로봇의 형상은 그림. 6과 같으며, 6개의 조인트 변수에 대해 보정을 실시하였다.




그림 6. AMI 로봇의 좌표계.

6자유도인 AMI 로봇의 학습 데이터 획득은 측정 방법을 만족하도록 하기 위하여 로봇의 작업 영역 내에서 한 번이 $500mm$ 인 정 6면체(cube)를 선택하였다. 사용된 데이터는 총 120개로 x, y

및 z축을 각각 5등분하여 취하였으며, 사용된 각 축(axis)의 구간은 다음과 같다.

$$600(mm) \leq x \leq 1000(mm), \quad 0 \leq y \leq 500(mm), \\ 500(mm) \leq z \leq 900(mm)$$

이때 로봇 말단부의 Roll, Pitch 및 Yaw 각 (ϕ, θ, ϕ) 은 $\pm 45^\circ$ 범위 내에서 무작위로 선택하였다.

조인트 변수의 오차는 위치에 영향을 미치는 1, 2 및 3축에 대해서는 $\pm 2^\circ$ 이내로, 그리고 로봇 말단부의 방위에 영향을 미치는 4, 5 및 6축에 대해서는 $\pm 4^\circ$ 이내의 오차를 주었다. 이때 오차의 부호는 SM5 로봇의 경우와 유사하게 2축과 3축에 대해서만 +, - 양방향의 오차를 주고 나머지 축에 대해서는 한 방향으로 오차를 주었다.

AM1과 같은 6자유도의 로봇인 경우 로봇 말단부의 위치는 손목 부분의 조인트 변수와는 무관하다. 이는 역 보정 학습모델에서, 손목 부분을 제외한 조인트 변수는 입력 유니트로 로봇의 위치만 사용될 수 있음을 의미하는 것으로, 학습 속도의 향상을 위하여 위치에 영향을 미치는 조인트 변수와 그렇지 않은 조인트 변수로 구분하여 학습을 실시하였다.

$\theta_1 \sim \theta_3$ 는 x, y 및 z좌표 값을 유니트로 사용하여, 120개의 패턴에 대한 반복 학습을 통하여 가장 적절한 값으로 3개의 은닉층 유니트의 수를 결정하였으며, 학습율은 모두 0.5로 하였다.

$\theta_4 \sim \theta_6$ 는 입력 유니트로 x, y, z좌표 값 및 Roll, Pitch, Yaw각을 사용하여, 125개의 패턴에 대한 반복 학습을 실시한 결과, 가장 적절한 값으로 3개의 은닉층 유니트 수와 0.07, 0.5 및 0.3의 학습율을 각각 결정하였다.

그림 8은 각 조인트 변수의 학습 결과를 보여주는 것으로, 각 조인트는 1500 epochs 이내에 모두 만족할 만한 수렴 정도를 나타내고 있다. 특히 앞 절의 SM5 로봇과는 달리 오차의 방향(+, -)과는 무관하게 2축과 3축에서도 좋은 결과를 보여주고 있는데, 이는 AM1 로봇의 각 조인트 변수가 상호 커플링되어 있기 때문으로 생각된다. 이러한 결과는 결국 본 논문에서 사용한 파이-시그마 신경 회로망의 장점을 보여주는 것으로, 로봇과 같이 고차 다항식을 가지는 경우에 적합함을 알 수 있다.

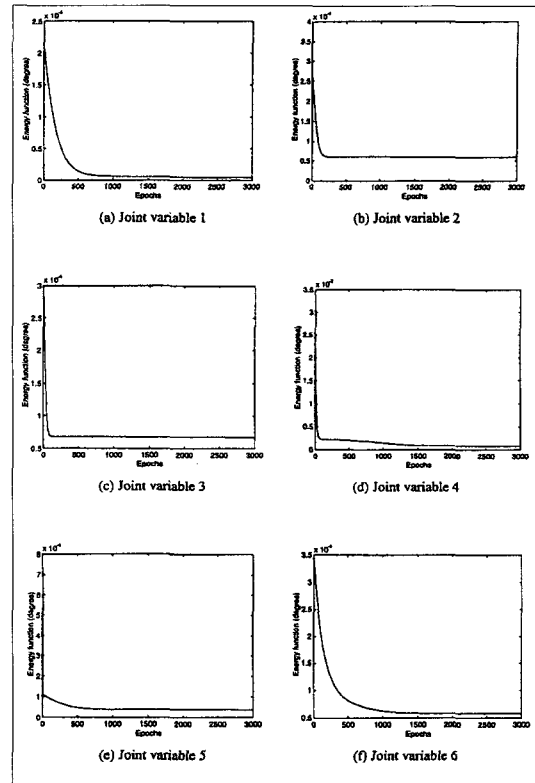


그림 7. AM1 로봇의 관절 변수 결과.

3000 에포크의 학습 결과를 토대로 역 보정된 결과는 표 2와 같다.

표 2. AM1 로봇의 보정 전·후의 결과 비교.

unit : degree

Joint variable	Before calibration			After calibration		
	Average	Deviation	Max.	Average	Deviation	Max.
θ_1	1.188	0.851	2.810	0.019	0.016	0.068
θ_2	0.941	0.552	1.957	0.081	0.056	0.229
θ_3	1.110	0.779	3.000	0.084	0.061	0.282
θ_4	4.834	0.686	6.064	0.090	0.070	0.413
θ_5	5.247	0.830	6.895	0.055	0.047	0.255
θ_6	2.433	1.062	4.611	0.075	0.059	0.381

표 2의 결과에서 보면, 보정 후의 각 조인트 변수의 오차는 AM1 로봇 조인트의 엔코더 분해능 2500pulse/rev. (0.1440°)을 고려할 때 대체로 만족할 만한 수준까지 보상 가능함을 알 수 있다.

4. 맺음말

본 연구에서는 신경 회로망을 이용한 역 보정 기법을 제시하였다. 그 결과를 요약하면 다음과 같다.

신경 회로망은 파이-시그마 구조를 사용하였으며, 학습은 요망하는 로봇의 자세(위치, 방위)에 대하여, 로봇의 역 기구학에서 얻은 해석 치와 실제 측정치와의 오차를 학습시켜, 이를 보상하는 역 보정 모델을 제시하였다.

제시된 모델의 타당성 검증을 위해 4관절형 수평 다관절 로봇 및 수직 다관절형 로봇의 2가지 경우에 대한 역 보정을 실시하여, 보정전 $\pm 0.35^\circ$ 내외의 조인트 변수 오차를 0.4° 이하로 줄일 수 있었다. 그리고, 파이-시그마 신경 회로망은 비교적 빨리 수렴하면서 정확도 면에 있어서 대체로 만족할 만한 수준을 가져 로봇과 같이 복잡한 기구학을 가지는 경우에 있어서 효과적으로 사용될 수 있음을 검증하였다. 또한, 제안된 로봇의 역 보정 모델을 이용하여 4관절 수평 다관절형 로봇에 대해서 보정 전 $0.48^\circ \sim 2.6^\circ$ 정도인 조인트 변수의 절대오차를 0.3° 이하로 줄일 수 있었으며, 6자유도의 수직 다관절형 로봇에 대해서도 보정 전 약 $0.94^\circ \sim 5.2^\circ$ 를 0.3° 이하로 줄일 수 있었다.

참고문헌

- [1] H. W. Stone and A. C. Sanderson, "A Prototype Arm Signature Identification System," *IEEE Conf. of Robotics & Automation*, pp. 175-182, 1987.
- [2] C. H. Menq, J. H. Borm and J. Z. Lai, "Identification and Observability Measure of a Basis Set of Error Parameters in Robot Calibration," *ASME j. of Mechanisms, Transmissions, and Automation in Design*, Vol. 111, pp. 513-518, 1989.
- [3] R. P. Judd and A. B. Knasinsk, "A Technique to Calibrate Industrial Robots with Experimental Verification," *IEEE Trans. on Robotics and Automation*, Vol. 6, No. 1, pp. 20-30, 1990.
- [4] Z. Ahmad and A. Guez, "On the Solution to the Inverse Kinematic Problem," *IEEE conf. on Robotics & Automation*, pp. 1692-1697, 1990.
- [5] S. Kieffer, V. Morellas and M. Donath, "Neural Network Learnig of the Inverse Kinematic Relationship for a Robot Arm." *IEEE int. Conf. on Robotics & Automation*, California. pp. 2418-2425, 1991.
- [6] C. R. Mirman and K. C. Gupta, "Compensation of Robot Joint Variables Using Special Jacobian Marices," *J. of Robotics Systems*, Vol. 9, No. 1, pp. 113-137, 1992.
- [7] J. S. Shamma and D. E. Whitney, "A Method for Inverse Robot Calibration," *ASME j. of Dynamic Systems, Measurement, and Control*, Vol. 108, pp. 36-43, 1987.
- [8] W. K. Veitschegger and C. H. Wu, "Robot Accuracy Analysis Based on Kinematics," *IEEE J. of Robotics & Automation*, Vol. RA-2, No. 2, pp. 171-179, 1986.
- [9] S. Hayati and M. Mirmirami, "Improving the Absolute Positioning Accuracy of Robot Manipulators," *J. of Robotic System*, Vol. 2, No. 4, pp. 397-413, 1985.
- [10] J. Denavit and R. S. Hartenberg, "A Kinematic national for lower-pair mechanisms based on matrices," *ASME J. of Applied Mechanics*. pp. 215-3221, 1955.