

일정한 가반 하중이 작용하는 스카라 로봇에 대한 신경망을 이용한 기계적 처짐 오차 보상 제어

Compensation Control of Mechanical Deflection Error on SCARA Robot with Constant Pay Load Using Neural Network

이 종 신*
(Jong-Shin Lee)

Abstract: This paper presents the compensation of mechanical deflection error in SCARA robot. End of robot gripper is deflected by weight of arm and pay-load. If end of robot gripper is deflected constantly regardless of robot configuration, it is not necessary to consider above mechanical deflection error. However, deflection in end of gripper varies because that moment of each axis varies when robot moves, it affects the relative accuracy. I propose the compensation method of deflection error using neural network. FEM analysis to obtain the deflection of gripper end was carried out on various joint angle, the results is used in neural network learning. The result by simulation showed that maximum relative accuracy reduced maximum 9.48% on a given working area.

Keywords: SCARA robot, mechanical deflection error, relative accuracy, neural network learning

I. 서론

갈수록 부품이 소형화 되고 높은 정밀도가 요구되기 때문에 산업용 로봇도 작업 정밀도의 향상이 필요하다. 이를 위해 다양한 제어 알고리즘이 개발되고 있으나 기계적 오차를 보상하는 방법에 대한 연구는 상대적으로 매우 미미한 것으로 보인다. 로봇의 경우 구동 모터의 부하를 경감시키기 위해 몸체 재료로 대부분 알루미늄을 사용하고 있으며, 이 때 로봇 몸체의 자중 및 가반 하중에 의해 그립퍼 끝단에서 처짐이 발생한다. 이와 같은 처짐으로 인한 오차는 절대 정밀도 및 상대 정밀도에 영향을 미친다. 만일 로봇의 자세에 따라 처짐량이 균일하다면 문제가 되지 않을 수도 있다. 로봇 정밀도에서 중요한 것은 반복정밀도이기 때문에 상대 오차가 중요한 인자가 된다. 그러나, 실제적으로 로봇은 자세에 따라 처짐량이 다르게 나타난다. 이는 로봇 암 자체의 무게와 가반 하중에 의해 각 축에 미치는 모멘트가 로봇의 자세에 따라 변하기 때문이다. 이와 같은 문제는 로봇 끝단의 상대 정밀도에 영향을 미칠 뿐만 아니라, 특히 경로를 따라 작업을 수행하는 경우 기계적인 오차가 경로정밀도에 그대로 반영된다고 할 수 있다. 따라서, 기계적 오차를 로봇 제어에 반영시킬 수 있다면 로봇 정밀도를 높이기 위한 좋은 방법이 될 수 있다.

본 연구에서는 이와 같은 기계적 처짐에 의한 오차를 보상하는 방법을 제안하였다. 본 연구에서는 S사에서 개발한 모델을 대상으로 사용하였다. 이를 위해 먼저 가반하중을 변화시켜가며 로봇 그립퍼 끝단에서 처짐량을 실제 측정된 값과 해석한 값을 비교하여 해석 데이터의 활용가능성에 대한 기초 자료로 활용하였다[1]. 이는 로봇의 다양한 자세 및 가반 하중 변화에 대해 로봇 공구단의 처짐량을 실제 측정하여 오차 보상제어에 사용하는 것은 데이터의 양이 방대하여 현실적으로 어려운 일이므로, 해석 데이터의 신뢰성을 확인 한

후 해석 데이터를 이용하기 위한 것이다. 본 연구에서는 117 개의 방법으로 로봇 자세를 변화시켜가며 로봇 공구단의 처짐량을 해석적으로 구한 후, 이를 신경망 학습 데이터로 활용하여 로봇 자세의 변화에 따른 처짐량을 예측하고, 이를 기계적 오차 보상에 이용할 수 있도록 하였다. 본 연구에서는 가반 하중 1Kg이 일정하게 작용하는 경우로 한정하여 처짐량을 보상하는 것으로 하였다.

II. 모델링 및 해석

1. 모델링 및 기하학적 치수

그림 1은 본 연구에 사용된 스카라 로봇으로 형상 및 치수 기호를 나타내고 있다. 그림 1에서 베이스에 내장된 암 1 구동용 모터의 중심과 암 1의 무게 중심 사이의 수직거리를 h_1 , 수평거리를 x_{c1} 으로 표시한다. 또, 암 1의 무게중심에서 암 2의 무게중심까지의 수직거리를 h_2 , 2축 중심에서 암 2 무게중심까지의 수평 거리를 x_{c2} , 암 2의 무게중심과 핸드의 무게중심까지의 수직거리를 h_3 로 표시하고, 1축과 2축의 수평거리를 l_1 , 2축과 핸드의 중심까지의 수평거리를 l_2 로 나타낸다. 또한, 베이스에 장착된 기준 프레임의 X 축과 1축과 2축을 연결하는 직선이 이루는 각도를 θ_1 , 1축과 2축을 연결하는 직선과 2축과 핸드의 중심선이 이루는 각도를 θ_2 로 나타내고, 암 1의 질량을 m_1 , 암 2의 질량을 m_2 , 쥘부의 질량(축 3과 축 4의 질량)을 m_3 , 가반하중을 W_L 로 표시한다. 그리고 X 축 방향 처짐량을 δ_x , Y 축 방향 처짐량을

표 1. 로봇 부품의 축 별 전체 질량, 질량중심 및 암 치수.
Table 1. Total mass, mass center of each axis and arm size.

	질량 (Kg)	질량중심(m)	암 치수
1축	78.984	0.0136	$l_1=0.35m$ $l_2=0.25m$
2축	9.101	0.0402	
쥘부	2.110	-	

* 책임저자(Corresponding Author)

논문접수: 2009. 4. 1., 채택확정: 2009. 5. 4.

이종신: 주성대학 컴퓨터응용기계과(leejs@jsc.ac.kr)




그림 1. 스카라 로봇의 좌표계 및 파라미터.
Fig. 1. Coordinate frame and parameters of SCARA robot.

δ_y , Z 축 방향 처짐량을 δ_z 로 한다. 본 연구에서는 스카라 로봇의 평면 구동 특성을 고려하여 평면 상의 처짐량인 δ_x 와 δ_y 만을 고려하는 것으로 하였다. 표 1은 본 연구에 사용된 스카라 로봇의 제원을 나타낸다.

2. 처짐에 의한 기구적 오차

암 1과 암 2의 자중 및 가반하중에 의해 로봇 그림퍼 끝에 처짐이 발생하며, 이 때 암 1과 암 2의 자세에 따라 1축




그림 2. Z 방향 처짐량의 실험 결과 및 해석결과.
Fig. 2. Test results and FEM analysis results in Z-direction.

표 2. Z-방향 처짐량.

Table 2. Deflection in Z-direction.


가반 하중	1Kg	2Kg	3Kg	4Kg	5Kg
측정결과(μm)	10	19	28	37	46
해석결과(μm)	9	17.5	26.4	35	43.7

및 2축에 에 걸리는 모멘트의 변화로 처짐량이 각각 다르게 나타난다. 이와 같은 기구적 오차에 의해 목표 위치로 로봇을 제어하더라도 실제 위치와는 다른 위치로 이동하게 된다.


따라서 로봇이 작업하고자 하는 경로에 따라 그 오차는 수시로 변하게 된다.

3. 해석 결과 검증


그림 1에서 θ_1 과 θ_2 가 각각 0° 일 때 그림퍼 끝에 다이얼 게이지를 이용하여 가반 하중을 1Kg ~ 5Kg까지 1Kg씩 증가시키며 Z 방향의 처짐량을 측정하였다[1]. Z 방향의 처짐량을 비교하고자 하는 것은 처짐을 측정하기 용이할 뿐만 아니라 데이터 비교가 가능하기 때문이다. 또한, 스카라 로봇을 3차원 모델링하여 해석에 사용하였다. 해석은 ANSYS를 이용하였으며 측정방법과 같이 정적인 상태에서 Z 방향의 처짐 결과와 비교할 수 있도록 하였다. 그림 2와 표 2는 측정결과와 해석결과를 보여준다. 해석결과가 비교적 측정결과



(a) In case of $\theta_1 = 0^\circ$ and $\theta_2 = 0^\circ$



(b) In case of $\theta_1 = 0^\circ$ and $\theta_2 = 30^\circ$



(c) In case of $\theta_1 = 0^\circ$ and $\theta_2 = 60^\circ$

그림 3. 처짐량 해석결과.

Fig. 3. Deflection analysis results.

와 큰 오차가 없는 것으로 나타났으며, 근사적으로 비례하는 것을 알 수 있었다.

그림 2에서 보는 바와 같이 측정결과와 해석결과의 오차는 실제 주물에서의 주물 두께 오차와 베어링 지지부의 모델링 오차에 기인한 것으로 판단된다. 그러나, 측정 결과와 해석결과가 근사적으로 오차를 보이고 있고, 상대 오차가 중요한 인자이므로 모델링 결과를 이용한 해석 데이터가 유용하게 사용될 수 있음을 알 수 있었다.

4. 해석 데이터 확보

본 연구에서는 로봇의 자세에 따라 그림퍼 끝단의 처짐량이 변하게 되므로, 이를 반영하기 위해 로봇의 자세를 변화시켜 가며 해석을 실시하였다.

처짐량의 변화는 θ_1 을 $\pm 60^\circ$ 범위에서 15° 간격으로, θ_2 는 $\pm 90^\circ$ 범위에서 15° 간격으로, 가반하중은 1Kg으로 하여 그림퍼의 각 방향 처짐량을 구하였다. 이를 조합하면 암의 자세변화에 따라 각각 117개의 처짐량 δ_x, δ_y 를 구하게 된다. 이는 다양한 자세에서의 처짐량을 구하고, 이 데이터를 신경망 학습에 이용하였다. 그림 3은 신경망 학습에 사용된 117개의 처짐량 데이터 중 3 가지 경우의 암 자세에 대한 해석결과를 예로 보여준다. 그림 3에 표기된 처짐량은 그림퍼 끝단에서의 처짐량을 나타낸다.

III. 신경망 학습

1. 신경망 구성

신경망의 입력 데이터로 주어지는 값들은 암 1의 회전각 θ_1 , 암2의 회전각 θ_2 가 된다. 본 연구에서는 가반하중이 1Kg인 경우로 한정하였다. 또한, 출력 데이터는 X 축 방향 처짐량 δ_x , Y 축 방향 처짐량 δ_y 가 된다.

신경망 학습에는 오류역전파 학습을 이용하였다. 본 연구에 사용된 오류역전파 알고리즘은 일종의 지도학습방법으로 실제의 출력값과 출력되기를 원하는 값 사이의 오차가 줄어들도록 가중치를 역방향으로 조정하여 오차의 평균제곱합이 최소가 되도록 하는 반복 알고리즘이다. 오류역전파 규칙은 일반화된 델타 규칙이라고도 불리우며 롬멜하트에 의해 만들어진 학습규칙으로 오늘날 가장 유명해진 학습 규칙 중의




그림 4. 신경망 구조.
Fig. 4. Structure of the neural network.

하나이다. 오류역전파는 작은 학습율이 사용되는 경우 아주 안정적인 방법이지만 수렴이 늦은 단점이 있다.

학습의 성능을 높이기 위한 방법으로 모멘트 항의 추가, 가변적인 학습율의 적용 등이 고려될 수 있다. 가중치 및 임계값들의 해를 얻기 위한 다른 방법들은 아주 복잡한 알고리즘을 포함하고 있다. 이들 기법의 대부분은 뉴턴 방법을 근거로 하고 있다[2]. 본 연구에서는 입력층은 2개의 신경세포로, 두 개의 은닉층은 10개의 신경세포로, 출력층은 2개의 신경세포로 구성하였다. 그림 4는 본 연구에 사용된 신경망 구조를 나타낸다.

그림 4에 보여준 신경망의 학습은 다음과 같이 수행된다. 층 2에서 j 번째 노드에 대한 입력은 다음과 같이 정의된다.

$$net_j = \sum_i W_{ji} O_i$$

여기서 W_{ji} 는 층 2에서 j 번째 노드와 층 1에서 i 번째 노드 사이의 가중치를 나타낸다. 또한, O_i 는 층 1에서 i 번째 노드의 출력값을 나타낸다.

j 번째 노드의 출력값은 다음과 같이 주어진다.

$$O_j = f_j(net_j)$$

여기서, $f_j(\cdot)$ 은 활성화 함수이다. 본 연구에서는 다음과 같이 표현되는 시그모이드 함수를 활성화 함수로 사용하였다.

$$f_j(net_j) = \frac{1}{1 + e^{-(net_j + \theta_j)}}$$

여기서, 인자 θ_j 는 바이어스로 사용된다. 층 3에서의 출력값은 비슷한 방법으로 구할 수 있다. m 번째 노드에 대해 입력과 출력은 다음과 같다.

$$net_m = \sum_k W_{mk} O_k$$

$$O_m = f_m(net_m)$$

먼저 각 샘플시 출력 오차는 다음과 같이 취한다.

$$E = \frac{1}{2}(\tau_p - O_p)$$

여기서, τ_p 는 목표 출력값을 나타내고, O_p 는 신경망에 의해 생성된 출력값을 나타낸다. 여기서, p 는 p 번째 학습 샘플을 나타낸다.

비용 함수를 최소화하기 위한 방법으로 다음과 같이 최소제곱(method of least-squares)을 이용한다.

$$E = \frac{1}{2P} \sum_p (\tau_p - O_p)^2$$

여기서, P 는 학습 샘플의 총수를 말한다. 가중치 수정식은 다음과 같다.

$$\Delta W_{ji}(n) = \eta \delta_j O_j + \alpha W_{ji}(n-1)$$

여기서, η 는 학습율, α 는 모멘텀 상수, n 은 반복 회수

를 나타낸다. 출력층에서의 노드에 대해, δ_m 는 다음과 같이 주어진다.

$$\delta_m = (\tau_m - O_m) f'_m(net_m)$$

여기서, τ_m 는 목표 출력값을 나타내고 $f'_m(net_m)$ 는 net_m 에 대한 $f_m(net_m)$ 의 편미분을 나타낸다. 층 3에서 k 번째 노드에 대해서 δ_k 는 다음과 같이 주어진다.

$$\delta_k = f'_k(net_k) \delta_m W_{mk}$$

여기서, δ_m 은 위의 식으로부터 구할 수 있다. 다른 층에 대해서도 유사한 방법으로 수정된다.

2. 신경망 학습

신경망을 학습시키기 위한 학습 패턴은 θ_1 과 θ_2 를 각각 9개와 13개 수준으로 하여 2개의 처짐량 δ_x, δ_y 에 대해 총

117개의 학습 데이터를 만들었다. 최종적으로 신경망 학습을 활용하고자 하는 것은 암1과 암2의 자세가 변할 경우 처짐량을 찾아내기 위한 것으로, 입력 데이터는 암1과 암2의 각도인 θ_1 과 θ_2 가 되고, 출력 데이터는 처짐량 δ_x, δ_y 가 된다.

신경망 학습은 모멘텀 상수, 학습율, 은닉층 열의 개수, 가중치를 변화시켜 가며 학습오차를 테스트하였다. 모멘텀 상수, 학습율, 은닉층의 개수, 은닉층 뉴런의 개수는 학습시간 및 학습오차를 줄일 수 있도록 시도하여 최종적으로 결정하였다. 그림 5는 학습결과 7361회째 수렴하는 것을 보여준다.

그림 6은 목표값과 학습 결과값을 그래프로 나타내었다. 시각적인 비교가 용이하도록 목표값과 학습 결과값은 학습 데이터 중 일부를 선정하여 그래프에 표기하는 것으로 하였다. 그림 6의 그래프에 나타난 것과 같이 신경망학습 결과, 만족할 만한 학습 데이터를 얻을 수 있었다.

IV. 컴퓨터를 이용한 모의실험

1. 모의 실험 방법

먼저 암 1과 암 2의 자세를 변화시켜가며 처짐량을 모의실험하였다. 먼저, 암 1의 각도를 $0^\circ \sim 60^\circ$ 까지, 암 2의 각도를

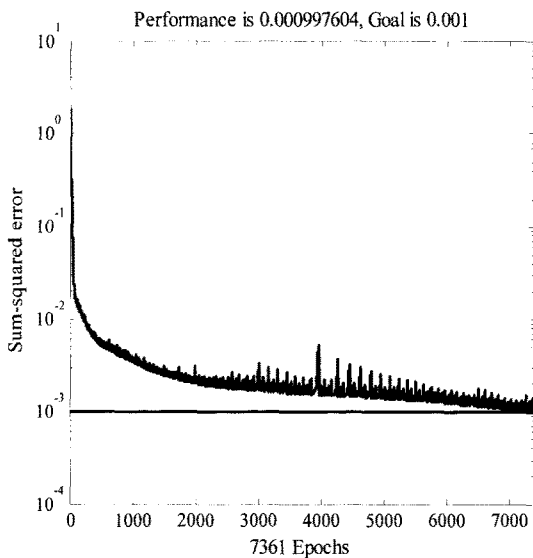


그림 5. 오류역전파를 이용한 신경망 학습결과.

Fig. 5. Backpropagation training results.




그림 7. 임의의 작업영역에서 X 방향 처짐량.

Fig. 7. X-direction deflection on a given working area.

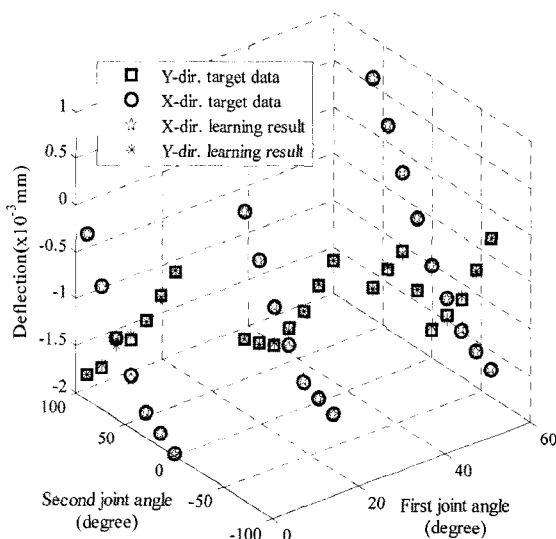


그림 6. X, Y 방향 처짐량의 목표값과 학습결과값.

Fig. 6. Target data and learning data in X,Y-direction.

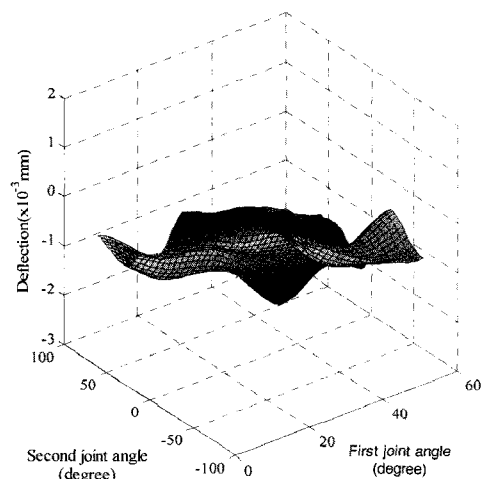


그림 8. 임의의 작업영역에서 Y 방향 처짐량.

Fig. 8. Y-direction deflection on a given working area.




그림 9. X 방향 경로 테스트($\delta_x \times 10^{-3}, \delta_y \times 10^{-3}$).

Fig. 9. X-direction path test($\delta_x \times 10^{-3}, \delta_y \times 10^{-3}$).

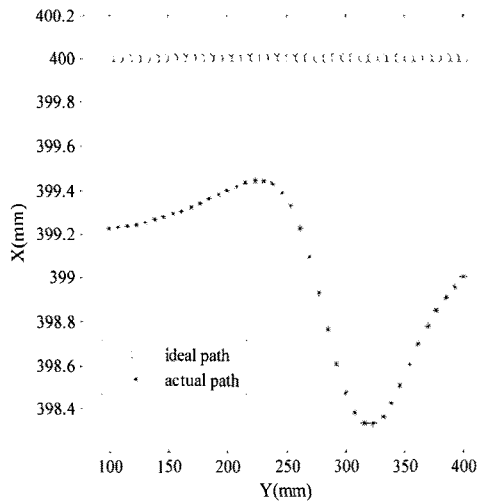


그림 10. Y 방향 경로 테스트($\delta_x \times 10^{-3}, \delta_y \times 10^{-3}$).

Fig. 10. Y-direction path test($\delta_x \times 10^{-3}, \delta_y \times 10^{-3}$).

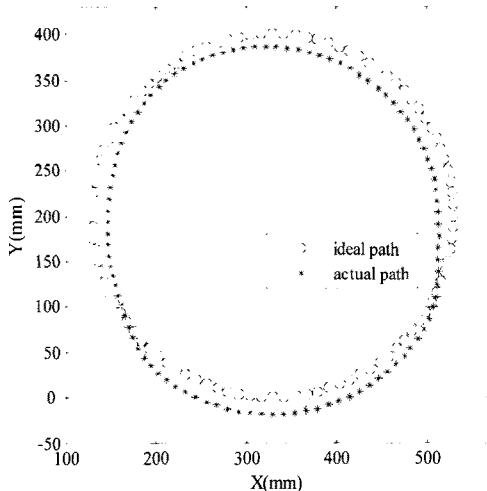


그림 11. 원호 경로 테스트($\delta_x \times 10^{-3}, \delta_y \times 10^{-3}$).

Fig. 11. Circle path test($\delta_x \times 10^{-3}, \delta_y \times 10^{-3}$).




그림 12. 신경망을 이용한 기계적 오차 보상.

Fig. 12. Mechanical error compensation using neural network.

-60° ~ 60° 까지 변화시켜 가며 X 및 Y 방향에 대한 치짐량에 대해 모의 실험을 실시하였으며 그 결과는 그림 7과 그림 8에 나타내었다. 또한 직선 방향과 원호에 대한 경로를 임의로 선정하여 모의실험을 실시하였다. X 방향 경로는 (200,200, 700)에서 (460, 200, 700)으로, Y 방향 경로는 (400, 100, 700)에서 (400, 400, 700)으로 직선 운동을 하는 것으로 하여 테스트 하였다. 그리고 원호에 대한 경로 테스트는 원의 중심 (330, 200,700)에서 반지름 200mm인 원호를 그리는 것으로 하여 테스트를 실시하였다. 그림 9, 그림 10 및 그림 11은 각각의 모의실험 결과를 보여준다.

2. 모의 실험 결과 및 분석

로봇의 암 자세에 따라 데이터는 X 축 방향 치짐량 δ_x , Y 축 방향 치짐량 δ_y , Z 축 방향 치짐량 δ_z 가 각각 다르게 나타난다. 이는 암의 자세에 따라 축에 걸리는 모멘트 값이 다르며 치짐량과 치짐 방향이 다르게 나타나기 때문이다. 따라서 예상대로 시뮬레이션 결과 암의 자세에 따라 다른 결과로 나타난 것을 알 수 있었다. 그림 7과 그림 8에서 보여주는 평면상 축, 암 1의 각도를 0° ~ 60° 까지, 암 2의 각도를 -60° ~ 60° 까지 변화시켜 가며 움직일 경우 상대 치짐량의 최대 오차는 X 및 Y 방향에 대해 각각 3.7920 μm , 2.3218 μm 으로 나타났다. 그리고, X 방향 경로에서는 최대 상대 오차가 0.9020 μm , Y 방향 경로에서는 최대 상대오차가 1.2059 μm 으로 나타났으며, 그림 9와 그림 10에 그 결과를 나타낸다. 그림 11에서 보여주는 바와 같이 원호를 그리는 경우 최대 2.591 μm 의 상대 오차를 나타냈다. 여기서 최대 상대오차는 치짐량의 최소값과 최대값과의 차이를 의미한다. 모의실험을 통해 알 수 있듯이 로봇의 자세에 따라 치짐량이 변화하게 되어 경로에 따라 상대 오차의 크기가 다르게 나타나는 것을 알 수 있었다. 모의 실험 결과 신경망학습을 통해 축의 치짐량을 보상하여 제어 한다면 원호 경로의 경우 최대 2.591 μm 의 상대 오차를 줄일 수 있음을 알 수 있었다. 로봇 제어에 적용하는 예로, 그림 12와 같이 신경망을 이용해 로봇 자세에 따른 기계적 오차를 보상하면 상대 오차를 줄일 수 있게 된다[3]. 그림 12에서 P 는 위치벡터, τ 는 구동토크를 나타낸다.

V. 결론


로봇에서 정밀도 구현은 매우 중요한 과제이다. 대부분 모터 및 제어 알고리즘 개발을 통해 로봇의 정밀도 향상을 위해 노력하고 있다. 본 연구에서는 암의 치짐에 의한 기계적 오차를 감소시키기 위한 수단으로 신경망을 이용해 암

의 자세에 따라 처짐량을 예측하여 제어에 보상할 수 있는 방법에 대해 제안하였다. 본 연구를 통해 다음과 같은 결론을 얻었다.

1. 스카라 로봇의 자중, 가반하중으로 인한 처짐이 암의 자세에 따라 실제 처짐량이 다르게 나타나며, 이로 인해 경로의 정밀도에 영향을 미친다는 것을 알 수 있었다.
2. 처짐량의 해석 결과값과 실험값의 오차가 크지 않고 근사적을 비례하는 것으로 나타났으며, 이는 해석 결과값이 처짐량을 보정하기 위한 데이터로 활용할 수 있음을 확인 할 수 있었다.
3. 암의 자세 변화에 따른 처짐량을 신경망을 통해 보정함으로써 임의 영역에서 최대 X 방향 $3.7920 \mu\text{m}$, Y 방향 $2.3218 \mu\text{m}$ 의 오차를 줄일 수 있음이 시뮬레이션을 통해 확인되었다. 이 오차는 $\pm 20 \mu\text{m}$ 의 성능을 구현하는 로봇의 경우 9.48%의 성능 향상을 가져올 수 있음을 의미한다.

참고문헌

- [1] 송기무, 이종신 외, “직접구동방식의 스카라 로봇 개발,” 삼성종합기술원, pp. 611-612, 1989.
- [2] 이현엽, 문경일, MATLAB을 이용한 퍼지-뉴로, 도서출판 아진, pp. 209-370, 1999.
- [3] J. J. Craig, *Introduction to Robotics*, Addison-Wesley Publishing Company, pp. 247, 1986.



이 종 신

1981년 부산대학교 기계공학과(공학사). 1985년 연세대학교 기계공학과(공학석사). 2000년 고려대학교 기계공학과(공학박사). 1986년~1995년 삼성종합기술원, 삼성중공업 중앙연구소. 1995년~현재 주성대학 컴퓨터응용기계과 교수. 관심 분야는 로봇, 자동화 장비 설계 및 제어.