

자기학습 규칙베이스 조립알고리즘

•박 용 길

조 형 석

한국과학기술원 정밀공학과

A Self-learning Rule-based Assembly Algorithm

Yong K.Park Hyung S. Cho

Department of Precision Eng.

KAIST

ABSTRACT

In this paper a new active assembly algorithm for chamferless precision parts mating, is considered. The successful assembly task requires an extremely high position accuracy and a good knowledge of mating parts. However, conventional assembly method alone makes it difficult to achieve satisfactory assembly performance because of the complexity and the uncertainties of the process and its environments such as imperfect knowledge of the parts being assembled as well as the limitation of the devices performing the assembly. To cope with these problems, a self-learning rule-based assembly algorithm is proposed by integrating fuzzy set theory and neural network. In this algorithm, fuzzy set theory copes with the complexity and the uncertainties of the assembly process, while neural network enhances the assembly scheme so as to learn fuzzy rules from experience and adapt to changes in environment of uncertainty and imprecision. The performance of the proposed assembly algorithm algorithm is evaluated through a series of experiments. The results show that the self-learning fuzzy assembly scheme can be effectively applied to chamferless precision parts mating.

1. 서 론

조립자동화에 대한 요구는 점점 증대되고 있다. 왜냐하면, 조립공정은 생산공정에서 매우 많은 부분을 차지하기 때문이다. 그런데 조립자동화는 조립될 부품에 대한 매우 정교한 위치정밀도와 많은 지식을 요구한다. 그러나 실제 조립작업에 있어서 조립자동화에 요구되는 정보는 로봇, 손목기구, 조립부품의 가공오차등의 오차 요인에 의하여 쉽게 만족될 수 없다. 이런 문제점을 극복하기 위하여 조립작업과 관련하여 많은 연구가 이루어졌으며, 그들의 연구는 크게 3가지로 나눌 수 있다[1]. 즉, RCC와 같은 유연 손목기구를 이용하여 조립작업을 성공적으로 수행하는 수동조립법, 두번째는 힘센서, 시각센서, 근접센서등의 센서로부터 얻어진 정보를 이용하는 능동적 방법, 그리고 이런 수동적 방법과 능동적 방법을 결합한 수동-능동법이 있다.

이세 방법이 각각 장점과 단점을 가지고 있으나, 능동조립법과 관련한 많은 연구가 발표되었다. 이것은 능동조립법이 다음과 같은 특징을 가지고 있기 때문이다[2]. 즉, (1)큰 초기오차를 보상할 수 있고, (2) 조립환경의 변화에 적응할 수 있으며, (3)설입력을 제어함으로써 반력을 최소화할 수 있기 때문이다.

때문이다. 특히 힘센서를 이용한 조립 기술은 다음과 같은 특징을 가지고 있기 때문에 활발한 연구가 진행되고 있다. 즉, (1) 힘센서는 작업공정 가까이에 위치하며, (2)각 공정마다 데이터를 이용할 수 있고, (3) 데이터가 compact하고, (4)위치데이터는 부품의 큰 강성에 의하여 배가되는 등의 장점을 가진다. 그러나, 실제조립작업에서 이런 기술은 다음과 같은 비선형성과 불확실성의 문제를 가진다. 즉, (1)힘 신호와 부품의 위치오차, (2)결합부품과 주변환경과의 기구적 구속에 인한 불완전한 지식, (3) 조립작업을 수행하는 기구의 한계성, (4)미찰 조건등에 기인한다. 이런 불확실성과 비선형성은 (1) 위치오차를 인식하기 위한 정확한 모델링의 어려움, (2)힘신호와 위치오차간의 관계는 예매하고 부정확하다.

이런 복잡한 문제에 관계없이, 성공적인 조립작업은 대략적으로 측정된 힘정보를 이용하여 추론과 작업을 행하는 인간에 의하여 효율적으로 이루어진다. 이런 인간의 경험과 heuristics을 제어에 활용하기 위하여 퍼지이론을 이용한 제어알고리즘을 제시하였다[3-8]. 앞의 연구에서[9,10]에서 면허가 없는 부품의 정밀조립작업을 하기 위하여 규칙베이스 조립알고리즘을 제시하였으며, 그성능을 실험을 통하여 검증하였다. 그러나, 퍼지규칙베이스의 성능은 퍼지추론과 특히 구축되는 규칙에 의하여 좌우된다. 많은 경우에 미리규칙을 구축하는 것은 미리 많은 실험을 요구하고, 부품이나 모델이 변경될 경우 이 작업은 방대하고 또한 발생되는 수치값으로부터 대응하는 오차영역이나 오차량을 대응(mapping)시키기는 매우 힘들고 지루한 작업이다.

이런 규칙 베이스와 관련된 문제점을 극복하기 위하여 자기학습 규칙베이스 조립알고리즘을 제시한다. 이것은 조립작업이 효율적으로 수행될 때까지 연속적으로 규칙을 개선시키는 방법이다. 제시된 조립알고리즘의 구조는 크게 두개의 계층구조를 가진다. 하부구조는 Park등[9,10]에서 제시하는 퍼지규칙베이스 위치제어기이며, 상부구조는 규칙을 적용시키는 메카니즘(mechanism)이다. 규칙적용메카니즘은 두개의 신경으로 구성되어 있으며[11-14], 이것은 조립작업이 규칙에서 더 이상의 변화를 주지 않아도 효율적으로 조립작업을 수행할 수 있을 때까지 계속된다.

제시된 조립알고리즘의 성능은 일련의 실험을 통하여 검증된다. 실험적 결과는 제시된 자기학습규칙 베이스 조립알고리즘이 효율적으로 조립작업을 수행할 수 있음을 보여준다. 본 논문의 구성은 다음과 같이 이루어진다. 제 2절에서는 실제 조립작업의 문제점을, 제 3절에서는 자기학습 규칙베이스 조립알고리즘을 보여준다. 실험적 결과는 제 4 절에서, 그리고 실험결과에 근거한 몇가지의 결론을 제 5 절에서 묘사한다.

2. 문제의 정의

본 절에서는 실제 조립작업에서 종래의 조립알고리즘이 적용될 때의 문제점을 제시하고자 한다. 면취가 없는 부품의 경우 조립작업은 탐색공정에 의하여 크게 좌우되므로 본 연구는 탐색공정에 대하여 중점적으로 살펴본다. 힘센서를 이용한 조립작업에 있어서, 접촉상태에 관계없이 다음과 같은 순서로 조립작업이 진행된다. 먼저, 펙(peg)이 매니퓰레이터의 coarse동작으로 인하여 홀(hole)의 면과 접촉하게 되면 조립반력이 발생하게 되고, 힘센서는 이 값을 측정하여 신호처리를 한 후 조립알고리즘에 보낸다. 이 신호를 이용하여 조립알고리즘은 오차보상을 위한 보상량을 발생시킨 후 매니퓰레이터를 통하여 보상한다. 이와 같은 방법으로 오차의 보상은 조립작업이 성공할 때까지 연속적으로 이루어진다.

결합부품간의 접촉특성은 조립전략을 수립하는 데 매우 중요하다. 그러나 실제 조작업의 특성은 다음과 같은 요인에 의하여 복잡성과 비선형성을 가진다. 즉,

- (1)오차량과 힘신호와의 비선형적 특성.
- (2)결합될 부품과 환경과의 구속에의한 불완전한 지식.
- (3)조립작업을 수행하는 기구의 한계성.
- (4)콜롱(Coulomb), 정지, viscous 마찰 조건 등이 있다.

위에서 언급한 비선형성과 복잡성 때문에 오차보상을 위한 수학적 모델을 구성하는 것은 매우 어렵다. 비록 수학적 모델이 구성된다 하더라도, 모델의 변수와 관련된 모델링 오차는 어느정도 항상 존재한다.

3. 자기학습규칙베이스 조립알고리즘

제시된 조립알고리즘의 블록선도는 그림1에서 보여주듯이 두부분의 계층구조로 되어있다. 하부구조는 퍼지화, 규칙베이스, 퍼지추론, 비퍼지화등으로 이루어진 규칙베이스 퍼지제어기이다. 상부구조는 두개의 신경요소로 구성되는 규칙학습기이다. 이것은 퍼지규칙에 있어서 더 이상의 변화가 없더라도 성공적인 조립작업이 이루어질 때까지 규칙의 교정을 계속한다.

3.1. 퍼지화

퍼지화는 관측된 입력 공간으로부터 어떤 일정대역의 퍼지집합으로 대응시키는 것을 의미하며, 퍼지화를 수행하기 위하여 조립작업과 관련된 입력/출력 변수를 먼저 설정해야한다. 우선 입력변수로서 다음과 같이 4개의 힘/모멘트 정보를 선택한다. 즉, f_x , f_y , m_x , m_y 으로 그림2에서 보여주는 좌표계에 의하여 이들의 방향은 결정된다. 또한 출력변수로서 부품간의 x, y 방향의 위치오차를 각각 u_x , u_y 로 선택한다. 퍼지분활을 위한 기본적 퍼지집합으로서 힘, 모멘트정보는 각각 3, 5개씩을 선택하였으며, 그대역은 그림3에서 보여주듯이 균등분할 하였다.

3.2. 규칙베이스

퍼지알고리즘의 핵심부분으로서, 입력과 출력간의 다중결합(multiple mapping)을 표현하는 규칙의 구축은 그 성능을 좌우한다. 이 규칙을 구축하는 일반적인 방법은 제시되지 않았으나 다음과 같은 4가지 방법이 있다. (1)전문가의 경험이나 공학적 지식, (2)오퍼레이터의 제어특성, (3)공정의 퍼지

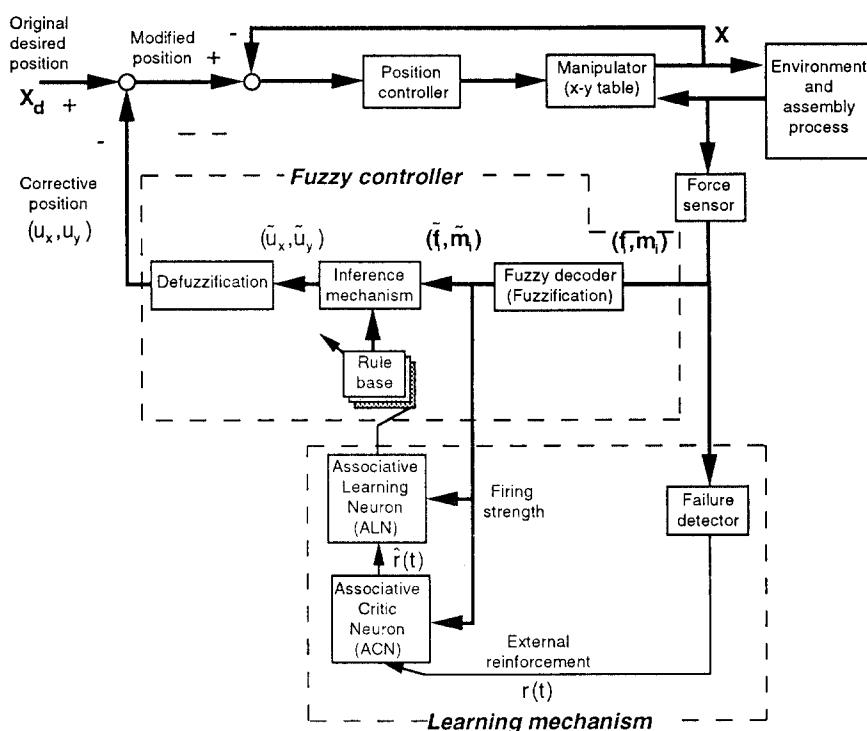


그림 1. 제시된 조립알고리즘의 블록선도.

모델, (4)자기개선 등이 있다. 본 논문에서는 자기개선에 의하여 규칙을 구축하며 구체적인 방법은 3.5절에서 언급하였다. 퍼지규칙의 형태는 다음과 같다.

R_k :

IF f_x is F_x^k , f_y is F_y^k , m_x is M_x^k , and m_y is M_y^k .
THEN u_x is U_x^k and u_y is U_y^k

(1)

3.3. 퍼지 추론

퍼지추론은 앞절에서 구축한 퍼지규칙에 의하여 제어값을 발생하는데 중요한 역할을 한다. 방정식(1)의 형태로 표현되는 제어규칙은 퍼지관계(fuzzy implication)에 의하여 x축과

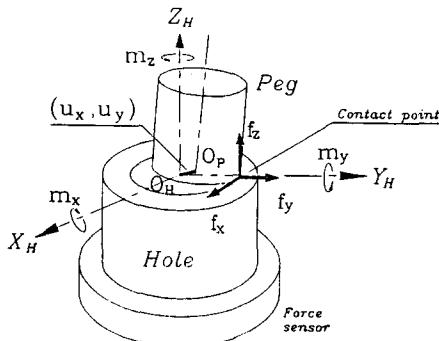


그림 2. 힘과 모멘트의 좌표계.

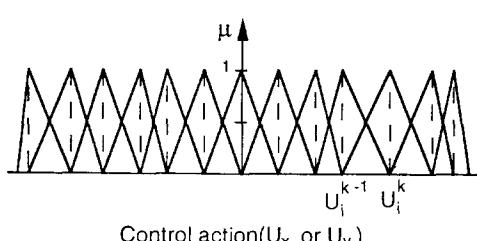
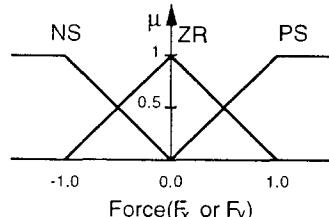
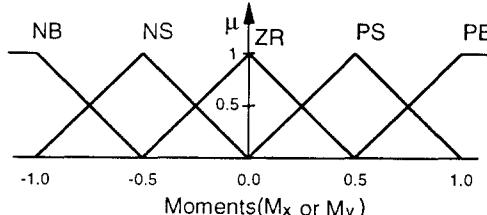


그림 3. 퍼지멤버십 함수.

y축이 독립적으로 발생되며 이때의 퍼지 추론은 만다니(Mamdani)의 최소.최대(MIN, MAX)합성에 의하여 이루어진다. n 개의 규칙에 의하여 얻어지는 최종적 멤버십 정도값(membership graded function)은 최대 합성에 의하여 다음과 같이 주어진다.

$$\mu(u_x) = \text{MAX}[\mu_1(u_x), \mu_2(u_x), \dots, \mu_n(u_x)] \quad (2)$$

$$\mu(u_y) = \text{MAX}[\mu_1(u_y), \mu_2(u_y), \dots, \mu_n(u_y)] \quad (3)$$

3.4. 비퍼지화

비퍼지화는 출력공간에 대하여 정의된 퍼지추론값으로부터 실제 출력공간상으로 크리스프한 값을 구하는 과정이다. 이 연구에서는 면적 중심법(center of area method)을 이용하여 비퍼지화하였다.

3.5. 규칙학습 기구

본 절에서는 방정식(1)에서 보여주는 후건부의 값 U_i^k ($i=x, y$, and $k=1, \dots, n$)을 몇 번의 실험을 통하여 학습시키기 위한 학습기구를 설명한다. 학습기구는 두개의 신경요소(Neuron-like elements)로 이루어져 있는데, associative critic neuron(ACN), associative learning neuron(ALN)이다. 각각의 구조에 대하여 살펴본다.

(1) Associative Critic Neuron(ACN) : ACN은 힘신호를 이용하여 학습의 방향이 제대로 되는가를 평가하는 실패검출기(failure detector)를 통하여 얻어진 신호, $r(t)$ 와 힘신호를 각 퍼지규칙에 대응시켰을 경우 해당하는 강도(firing strength), $s_k(t)$, ALN에 가하기 위한 ACN의 출력값, $\hat{r}(t)$, 앞의 값들은 다음과 같은 방정식에 의하여 구성된다. 전체적인 강화(reinforcement), $p(t)$ 는

$$p(t) = G \left(\sum_{k=1}^n \nu_k(t) s_k(t) \right) \quad (4)$$

으로 표현된다. 여기서, G 는 시그모이드 함수. 등가합수등이 될 수 있으며, 본 연구에서는 실험에서 주어지는 시그모이드 함수를 사용한다. k번째규칙의 관련학습 규칙은 부분적 메모리 트레이서, $s_k(t)$ 와 내부 강화에 의하여 부분적으로 특성지어 진다. 즉 k번째 규칙의 예상 강화는

$$\hat{\nu}_k(t+1) = \nu_k(t) + \beta \hat{r}(t) \mu_k(t) \quad (5)$$

여기서, β 는 양의 학습률 매개변수이다. 부분메모리 트레이서는 식 (6)과 같다. 즉,

$$\bar{s}_k(t+1) = \lambda \bar{s}_k(t) + (1-\lambda) |s_k(t)| \nu_k(t) \quad (6)$$

여기서, $0 \leq \lambda < 1$ 범위의 값을 가지며, 트레이서지연 매개변수이다. 트레이서는 자연합수의 특성을 가진다. 또, ALN에 가해지는 내부 강화는

$$\hat{r}(t) = r(t) + \gamma p(t) - p(t-1) \quad (7)$$

여기서, $0 \leq \gamma < 1$ 은 discount rate parameter이다.

(2) Associative Learning Neuron(ALN) : 그림1에서 보여주듯

이, ALN은 ACN요소로부터 받는 내부 강강화 입력, $r(t)$ 과 퍼지규칙에 해당되는 강도, $s_k(t)$, $k=1, 2, \dots, n$ 및 실제 제어입력으로 학습에 이용된다. 방정식(4)의 각 중심에 해당되는 값들은

$$w_i^k(t) = H(w_i^k(t)), i = x, y \quad (8)$$

$$k = 1, 2, 3, \dots, n$$

여기서, H 는 출력의 범위를 $[-1, 1]$ 사이에 위치하도록 동적 정규화를 수행한후 출력을 발생시킨다. 방정식 (8)에서 주어진 $w_i^k(t)$ 의 학습은

$$w_i^k(t+1) = w_i^k(t) + \bar{a}(t)r(t)e_i^k(t) \quad (9)$$

$$\bar{a} = \frac{at}{x + t}$$

여기서 $\bar{a}(t)$ 는 초기값 a 를 가진 동적양의 학습률 매개변수이고, x 는 각종 freeze 매개변수이다. 각종 freeze 매개변수는 다음방정식으로 주어지는 관련 트레이서에 의하여 표현된다.

$$e_i^k(t+1) = \delta e_i^k(t) + (1-\delta)u_i^k(t)s_k(t) \quad (10)$$

여기서, $0 \leq \delta < 1$ 은 다른 트레이서감쇄 매개변수이다.

4. 실험

제시된 조립알고리즘의 성능을 평가하기 위하여 일련의 실험을 하였다. 먼저, 제시된 방법의 학습 성능을 조사하였다. 둘째, 학습 매개변수의 효과를 조사하였고, 마지막으로 몇가지 초기오차에 대한 반복 실험의 결과를 조사하였다.

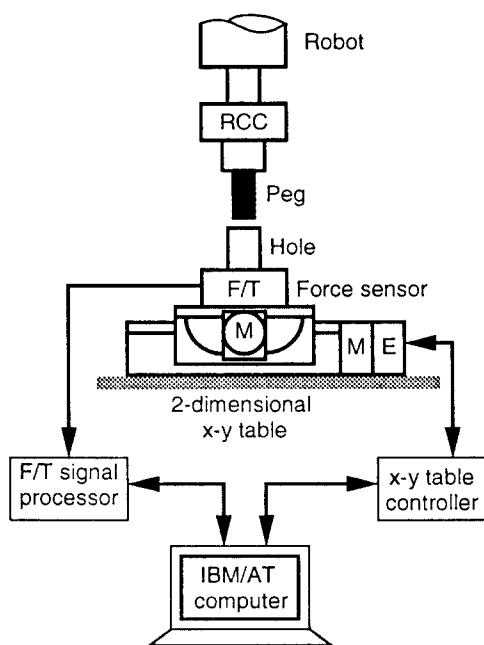


그림 4. 실험 장치.

4.1. 조립시스템

제시된 조립알고리즘을 실현하기 위하여, 실험장치를 그림4과 같이 구성하였다. 다시말하면, 시스템은 6축힘센서 (Barry Wright, FS6-120A-200), x-y미세운동 테이블, SCARA 로봇, z축 컴플라이언스를 가진 RCC와 IBM/AT 컴퓨터로 구성되어 있다. x-y미세조정 테이블은 두개의 D.C모터로 구동되고 이것은 INTEL8032 마이크로컴퓨터에 의하여 제어된다. 도축 제어기는 8255A 병렬 포트를 통하여 통신을 수행한다. IBM/AT 컴퓨터는 RS-232C 시리얼 포트를 통하여 힘센서와의 통신을 교환한다. 이때, 전송속도는 19200bps이다.

4.2. 실험 순서

그림5는 제시된 조립알고리즘의 흐름도를 보여준다. 펙을 z축 방향으로 정해진 조립반력을 나타내도록 일정한 위치로 홀로 접근시킨다. 이때, 조립반력의 크기가 $f_{1z} \leq f_z \leq f_{2z}$ 이 되면, 탐색작업은 시작된다. 그러면, 펙이 홀의 중심과 일치하기 위한 크기와 방향이 초기 퍼지규칙에 의하여 추론된다. 이 값은 펙과 홀간의 오차를 보상하는 x-y테이블에 보내져 보상운동이 이루어진다. 그리고 탐색작업의 성공여부는 z축 방향의 급작스런 힘의 변화에 의존한다. 만약 탐색이 완전히 이루어지지 않으면 퍼지규칙은 앞에서 언급한 학습기구에 의하여 계속 고정된다. 결국 이같은 과정이 탐색 작업이 완전히 이루어질 때까지 계속된다.

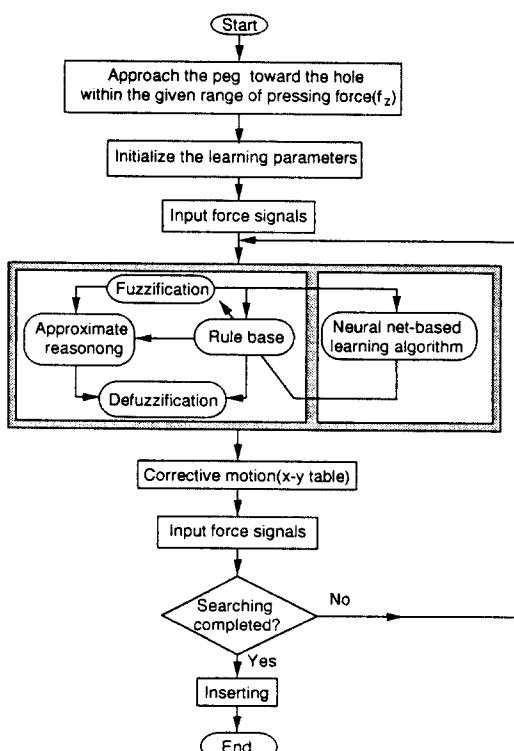


그림 5. 실험 순서.

4.3. 실험결과 및 토의

그림6는 제시된 조립알고리즘의 성능을 보여준다. 이 때 사용된 학습 매개변수들은 다음과 같은 값을 사용하였다. 즉. $\alpha=50$, $\beta=0.8$, $\gamma=0.8$, $\delta=0.9$, $\lambda=0.7$, $\kappa=2500$ 을 사용하였다. 그림에서 보여주듯이 첫번째 시도에서 퍼지규칙은 작업에 대한 예비정보가 없으므로 탐색에 요하는 스텝수는 48로서 매우 크다. 그리고 시도횟수가 점점 많아짐에 따라 스텝수는 현저히 줄어들음을 알 수 있는데, 이것은 점진적으로 퍼지규칙이 조립 공정에 '알맞는' 값을 학습함을 알 수 있다.

한편, 학습매개 변수의 영향을 살펴보기 위하여 일련의 실험을 수행하였다. 그림7은 다른 값은 그림6의 경우와 같이 고정시키고 α 의 값만을 변화시킨 경우의 학습 특성을 보여준다. 그림에서 알 수 있듯이 α 의 값이 커질수록 학습률은 빨라지나, 반면 그 값이 너무크지면($\alpha>280$) 외부신호에 너무 민감하게 반응하게 되어 불완전하게 된다. 다른 변수들의 영향은 학습 성능에 큰 영향을 주지 않기 때문에 여기서는 생략하였다.

그림8은 초기의 오차 방향에 관계없이 각각 30번의 반복 실험을 하였을 경우의 성공적인 탐색 스텝수를 나타내었다. 당연한 결과지만 초기오차가 커질수록 탐색스텝수는 많아지며, 오차가 클수록 평균스텝수에 대한 분산의 값 역시 커지는 데 이것은 오차가 클수록 불확실한 요인이 누적되기 때문이다.

5. 결론

본 논문에서는 조립작업에 있어서 퍼지규칙베이스를 자동적으로 구축하는 자기학습 알고리즘을 제시하였으며, 그 성능을 실험을 통하여 제시하였다. 퍼지규칙은 조립에서 발생하는 불확실성을 극복할 수 있고, 신경회로망은 학습기능으로 규칙을 실험을 반복함으로써 스스로 구축하였다. 결과로부터 제시된 알고리즘은 면취가 없는 부품의 정밀 조립에 효율적으로 사용될 수 있음을 보여준다.

6. 참고 문헌

- H.S. Cho, H.J. Warnecke, and D.G. Gweon, "Robotic assembly: a synthesizing overview," *Robotica*, Vol.5, pp.153-165, 1987.
- N.A. Aspragathos, "Assembly strategies for parts with a plane of symmetry," *Robotica*, Vol.9, pp.189-195, 1991.
- C.C.Lee, "Fuzzy logic in control systems : fuzzy logic controller-part I and part II," *IEEE trans. Syst., Man, and Cyb.*, SMC20, pp.404-435, 1990.
- E.H. Mamdani, "Application of fuzzy logic algorithms for simple dynamic plant," *Proc. IEE*, Vol.121, pp.1585-1588, 1974.
- E.H. Mamdani, "An experimental in linguistic synthesis with a fuzzy controller," *Int. J. Man mach. Studies*, Vol.7, pp.1-13, 1975.
- L.A. Zadeh, "A rational for fuzzy control," *Trans. ASME J. Dynam. Syst. Meas. and Control*, Vol.94, pp.3-4, 1972.
- L.A. Zadeh, "Outline of a new approach to the analysis complex systems and decision processes," *IEEE Trans. Syst, Man, and Cybernetics*, SMC3, pp.28-44, 1973.
- H.J.Park and H.S.Cho, "A fuzzy rule-based learning control method with application to hydroforming processes," *Mechatronics*, (to appear), 1992.
- Y.K.Park and H.S. Cho, "A fuzzy rule-based assembly algorithm for precision parts maing," *Mechatronics*, (to appear), 1992.
- Y.K. Park, H.S. Cho, and J.O. Park, "A fast searching method for precision parts mating," *Proc. IEEE Int. conf. on Int. Robots*, pp.1319-1323, 1992.
- A.G. Barto, R.S. Sutton, and C.W. Anderson, "Neuronlike adaptive elements that can solve difficult learning control problems," *IEEE Trans. on syst., Man, and Cybernetics*, SMC-13, pp.834-846, 1983.
- C.C. Lee, "Intelligent control based on fuzzy logic and neural net theory," *Proc. of Int. Conf. on Fuzzy Logic*, pp.759-764, 1990.
- C.C. Lee, "Modelling behavioral substracts of associative learning and memory: adaptive neuril models," *IEEE Trans. on Syst., Man, and Cybernetics*, pp.510-520, 1991.
- C.C. Lee, "A self-learning rule-based controller with approximate reasoning and neural nets," *Proc. of IFAC world congress*, Vol.7, pp.59-64, 1990.

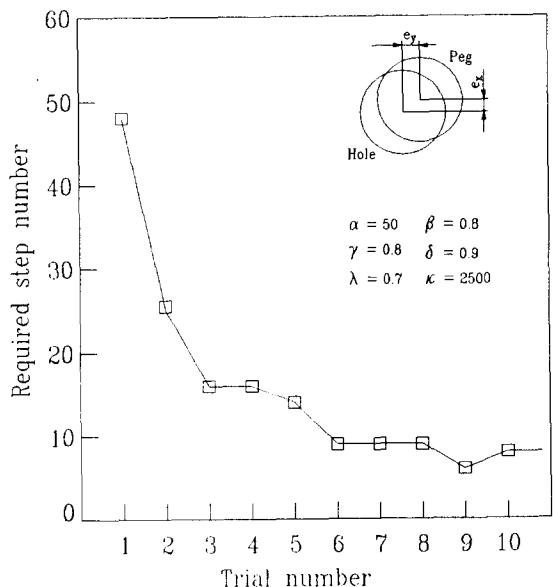


그림 6. 조립알고리즘의 학습성능.
 $(e_x, e_y) = (1.5, 1.5)$

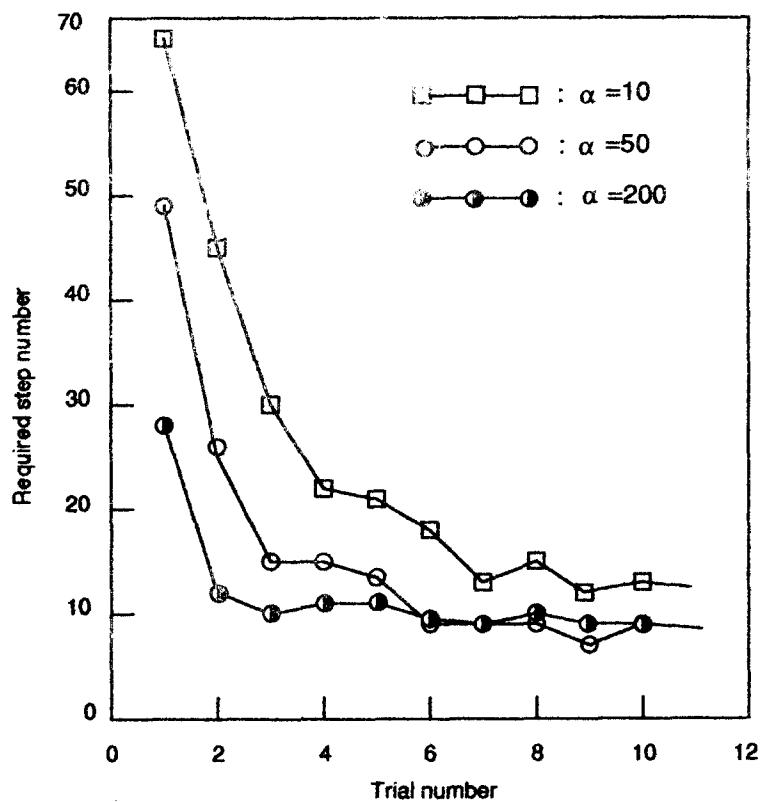


그림 7. 학습 매개변수의 영향.

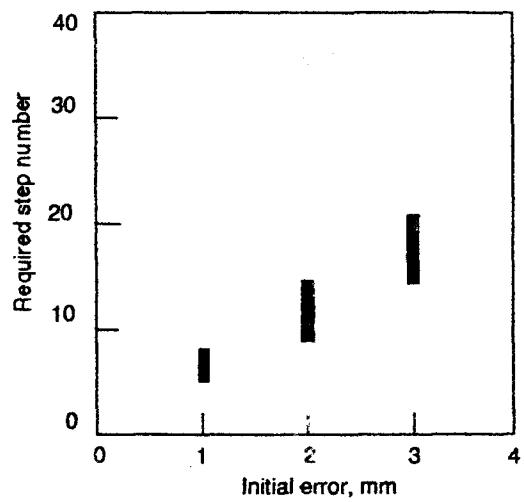


그림 8. 반복실험 결과.