

# AI기법을 응용한 생산공정 자동화 연구사례

조 형 석

## Case Studies on the Automation of Manufacturing Processes Using Artificial Intelligence

Hyung Suck Cho

- 조형석 (한국과학기술원 정밀공학과)
- 1944년생
- 제어 및 자동화를 전공하였으며, 인공지능을 이용한 제조공정(용접, 조립, 레이저가공, 검사)의 계획 및 제어, 이동로봇과 원격제어 로봇의 제어 분야에 관심을 가지고 있다.

### I. 머리말

최근 들어 인공지능 기법의 급속한 발전에 힘입어 이를 생산현장 공정에 응용하려는 연구가 활발히 진행되고 있다. 이 인공지능 기법은 인간이 지닌 추론능력과 학습능력 그리고 인식능력 등을 구현하는 것이 목적이며, 이의 대표적인 것으로는 신경회로망과 퍼지논리를 들 수 있다. 생산현장의 공정에서 흔히 관찰되어지거나, 혹은 제어를 하고자 하는 대부분의 동력학계들은 비선형성과 불확실성을 내포하고 있다. 종래의 제어방법에서는 이 시스템 특성을 수학적으로 단순화 시킨 모델을 사용하고 있으나, 여기서 여러 가지의 정보가 손실됨으로써 제어기의 성능에 좋지 않은 영향을 끼치게 된다. 인공지능 기법을 이와 같은 생산공정의 자동화에 적용하면, 종래의 여러가지 이론으로 해결하기 어려운 문제들을 극복할 수 있는 잇점이 있다. 퍼지이론은 1965년 Lefti Zadeh 교수에 의해

해 처음으로 제창되었으며 여러 분야에서 응용이 확대되어 많은 좋은 성과를 얻고 있다.<sup>(1,2)</sup> 그러나 전문가 시스템의 일종인 퍼지 논리를 이용한 제어는 제어를 하고자 하는 시스템의 정성적인 특성에 대한 법칙의 추출이 어려운 문제로 남아 있다. 반면에 신경회로망을 이용한 제어는 스스로 지식을 축적할 수 있는 장점을 갖고 있으므로 최근에 많은 연구가 진행중에 있다.<sup>(3,4)</sup> 특히 제어분야에서는 용접공정이나 조립공정 등의 공정제어와 로봇제어의 분야에 이르기까지 응용분야가 확대되고 있다.

이 글에서는 이러한 인공지능 기법을 생산공정의 자동화에 적용한 사례 연구를 통해 이 기법의 유용함을 살펴보기로 한다.

### 2. 퍼지논리 응용

#### 2.1 조립공정

조립 자동화는 조립될 부품에 대한 매우 정교한 위치 정밀도와 주변환경에 대한 정확

한 정보를 필요로 한다. 그러나 실제 조립작업은 위치오차, 마찰 등과 같은 불확실성과 비선형을 내포하고 있으며 위치오차와 힘정보간의 관계는 매우 애매하고 부정확하다. 이러한 어려움을 극복하기 위해 퍼지 알고리즘을 이용한 자기 학습규칙 조립방법이 제안되었다. 이것은 강화학습 방법을 이용하여 조립작업이 효과적으로 잘 수행될 때까지 퍼지 룰베이스를 개선시켜 나가는 방법이다.

그림 1은 이 제안된 조립 알고리즘의 블록선도를 보여준다. 이 조립 알고리즘은 크게 두 개의 부분으로 구성된다. 하나는 퍼지 제어기로서 작업시 발생하는 힘, 모멘트를 입력으로 받아 이에 대응하는 보정운동을 출력으로 생성해준다. 이러한 입출력 관계를 결정해주는 것이 퍼지를 베이스이다. 또 하나는 룰 학습메카니즘으로, 이것은 두 개의 뉴런과 유사한 원소로 구성이 되며, 학습기능을 통하여 작업의 수행에 적합한 룰베이스를 스스로 구축해준다. 따라서 조립작업시 원통과 구멍의 접촉에 의해 힘이 발생하면 학습이 완료된 퍼지 제어기는 이 힘에 대응하여 보정운동을 생성한다. 그러면, 로봇은 새로운 기준입력에 따라 움직이게 되어 조립작업은 원활히 수행될 수 있다. 그 구체적인 방법은 Park and Cho<sup>(5)</sup>에 나타나 있다.

그림 2는 제시된 알고리즘의 실험결과를 보여 준다. 이 그림에서 알 수 있듯이 학습이 진행됨에 따라 (즉, 작업의 시도횟수가 커짐에 따라) 작업이 수행되는데 필요한 스텝수는 감소함을 알 수 있다. 이는 점진적으로 퍼지를 조립공정에 알맞는 값으로 학습됨을 보여준다. 한편, 학습의 효율은 학습계수  $\alpha$ 에 크게 좌우되는데, 결과를 보면  $\alpha$ 가 클수록 학습속도는 빨라지나 너무 큰 값일 때는 불안정해짐을 알 수 있다.

위의 결과로부터 퍼지를 조립에서 발생되는 불확실성을 극복할 수 있고, 또한 룰 학습메카니즘은 학습기능을 통하여 작업의 수행에 적합한 규칙을 스스로 구축할 수 있

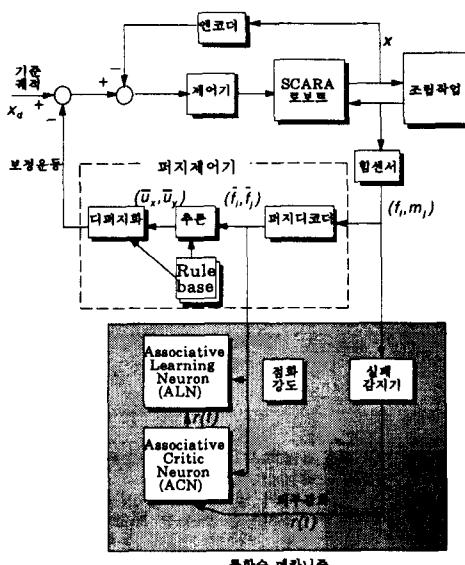


그림 1 자기 학습 규칙 알고리즘의 블록 선도

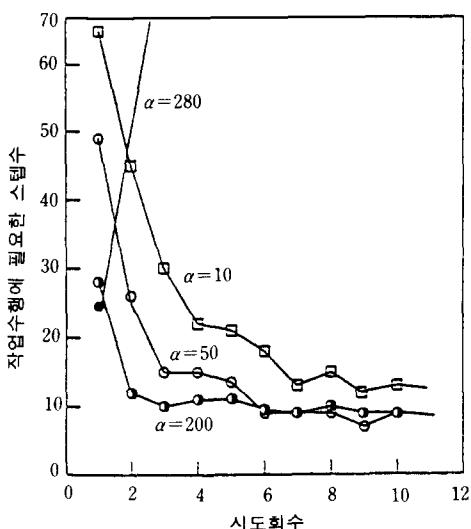


그림 2 여러가지  $\alpha$ 값에 대한 조립 실험결과  
( $\beta=0.8$ ,  $\gamma=0.8$ ,  $\delta=0.9$ ,  $\lambda=0.7$ ,  $x=2500$ )

음을 알 수 있다.

## 2.2 GMA 용접에서 아크 안정성 제어

아크 용접에서는 용접파워, 용접전압, 용

접 전류, 용접속도, 보호가스의 종류와 유량 등 많은 용접 변수가 있으며 이들에 따라 용접부의 품질과 기계적 성질이 결정된다. GMA용접에서는 이러한 용접 변수의 조합에 따라 아크의 불안정함이 발생할 수 있는데, 용접부의 품질 유지를 위해 안정된 아크 상태의 유지는 매우 중요하다.<sup>(6)</sup> 아크 안정성에 가장 중요한 인자는 전압·전류의 조합이며 이것은 전극의 직경, 보호가스의 양, 전극의 이송속도 용접기의 특성에 따라 변한다. 아크 안정성을 판별하기 위한 기준으로서 Mita는 단락 아크 용접에서 전압과 전류의 과정에 영향을 주는 여러 인자를 관찰하고, 이들에 대한 통계적인 분석과 처리를 통해 효율적인 아크 안정성 지수를 제안하였다.<sup>(7)</sup> 이 지수의 주요 구성요소는 단락 아크 시간, 아크시간, 평균 단락전류, 평균 아크 전류의 4가지 인자의 표준편차이다. 이 지수는 값이 낮을수록 아크가 안정함을 나타내는데, Mita는 주어진 전류값에서 안정된 아크를 얻기 위한 어떠한 전압 영역이 존재함을 보여주었다. 안정한 아크상태로 용접이 되기 위해서는 용접 조건으로부터 계속적으로 아크 안정성 지수를 구하여 최소의 지수 값이 되는 전압·전류 조합이 찾아야 하지만, 실제 용접공정은 매우 복잡하고 또한 지수 곡선의 비선형 특성과 외란 등으로 인해 기준의 모델링기법으로는 어려움이 따른다. 이를 극복하기 위해 본 연구에서는 퍼지 알고리즘을 사용하였으며 그림 3에 이 알고리즘에 대한 흐름도가 나타나 있다. 여기서,  $w$ 는 아크안정도,  $\Delta v$ 는 전압변화량, 그리고  $\partial w / \partial v$ 는 전압에 대한 아크안정도의 변화율을 나타낸다.

이 알고리즘의 성능을 평가하기 위한 실험으로서 열입력을 4 kW로 하여 작업하다가 16번째 학습실험에서 갑자기 5 kW로 변화시켜 아크안정성을 조사하여 보았으며, 30번의 학습실험을 총 3회씩 수행하였다. 그림 4에 나타난 실험결과를 보면 아크 안정성지수가

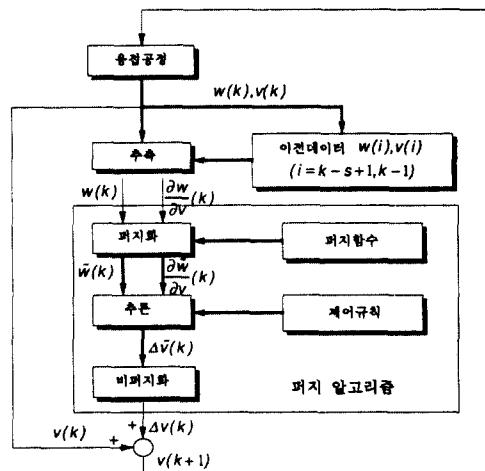
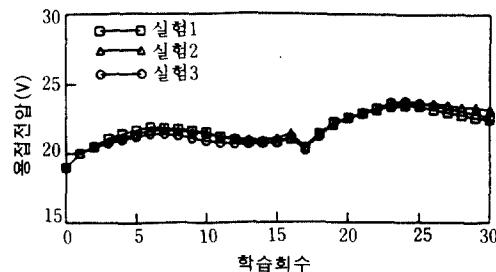
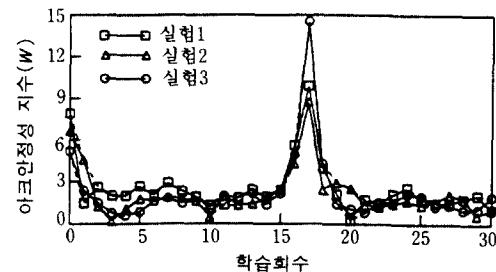


그림 3 퍼지규칙 알고리즘 흐름도



(a) 전압변화



(b) 아크안정성 지수의 변화

그림 4 열 입력변화에 대한 아크 안정조건 템색 결과

16번째 학습 실험에서 크게 변화한 후 2~3회의 학습 실험내에 안정된 아크상태로 수렴함을 알 수 있다.

본 연구는 안정된 아크상태를 보장하는 전

압·전류 조합을 얻기 위한 퍼지률을 제시하였으며, 실험결과로부터 이 방법은 GMA공정에서 아크 안정성에 많은 변수가 영향을 줌에도 불구하고 효과적으로 아크 안정성을 제어할 수 있음을 알 수 있다.

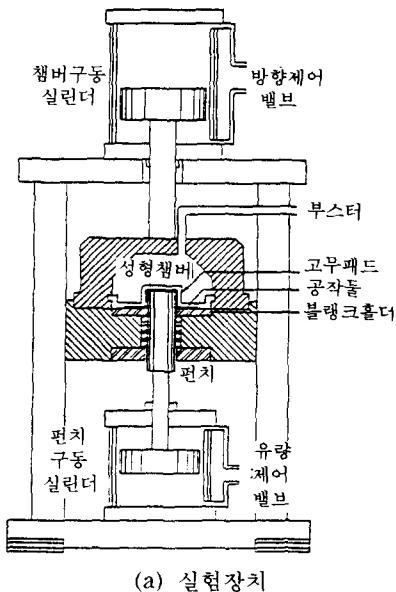
### 3. 신경회로망 응용

#### 3.1 성형공정

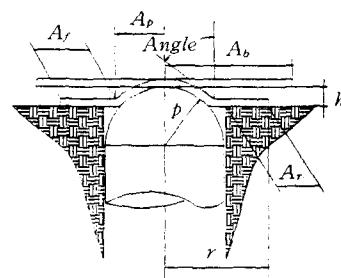
하이드로 포밍 공정은 연질 다이의 역할을 하는 가압된 유체속으로 펀치를 밀어올려, 펀치와 유체 사이에 있는 박판 블랭크를 펀치 모양으로 소성가공하는 성형기술이다. 이 공정에서 성형압력이 충분하지 못할 경우에는 제품의 표면에 주름이 잡힌 요철이 발생하며(wrinkling), 반대로 성형압력의 크기가 너무 클 때는 크랙과 같은 초기 파열(tearing)이 발생한다.<sup>(8)</sup> 따라서 두께가 균일한 양질의 제품을 얻기 위하여 중간 영역의 적절한 성형압력이 필요하다. 본 연구에서는 이러한 성형압력을 성형공정 전에 미리 추정, 계획하기 위하여 지도학습능력을 갖는 다층신경회로망 기법을 이용한다.<sup>(3)</sup>

주어진 두께를 갖는 블랭크에 대하여 에너지의 변환이 발생하는 부위의 기하학적 파라메터(즉, 그림 5의 블랭크 면적  $A_b$ , 플랜지 면적  $A_f$ , 다이와 펀치의 접촉각  $Angle$ , 다이와 블랭크의 접촉면적  $A_r$ , 펀치의 투영면적  $A_p$ )가 주어지면, 각 에너지간 변환비율이 균형을 이룰 수 있는 챔버 내의 성형압력을 추정할 수 있다. 다층신경회로망의 입력은 앞에서 기술한 5가지의 기하학적 상태변수이고 출력은 챔버내의 성형압력이다.

실험은 먼저 펀치의 형상 및 크기, 드로잉비와 같은 공정조건이 주어지면 이미 학습된 신경회로망을 이용하여 온라인으로 펀치 스트록 대 성형압력을 구한다. 얻어진 펀치 스트록 대 성형압력은 귀환제어를 갖는 비례압력제어기에 의하여 추종된다. 성형제품의 양부는 성형이 완료된 후 제품의 두께 변화를



(a) 실험장치



(b) 기하학적 상태변수

그림 5 하이드로 포밍공정에서의 기하학적 상태변수

측정하여 판정한다.

학습을 위하여 취한 350개의 샘플 데이터 중 일부를 학습에 사용하지 않고 제외시켜, 학습된 신경회로망의 압력추정 성능을 검증하기 위한 기준 데이터로 사용하였다. 그림 6은 펀치지름이 40이고 드로잉비가 17인 특정 공정조건에서 추정한 성형압력곡선과 실험에 의하여 얻은 목적 압력곡선을 보여준다. 이 그림은 샘플 데이터중 드로잉비가 1.9인 110개의 샘플을 제외시키고 학습된 신경회로망에 의해 성형압력을 추정한 결과를

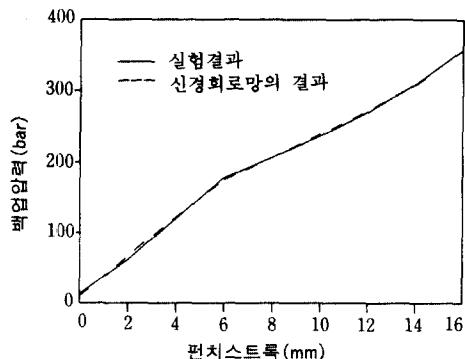


그림 6 편치행정에 대한 성형압력곡선

보여준다.

실험결과를 보면 본 방법에 의하여 학습된 신경회로망은 편치의 형상 및 드로잉비 등의 다양한 공정조건의 변화에도 자율적으로 대응하여 성형압력을 매우 근사하게 추정할 수 있음을 보여준다.

### 3.2 고주파 전기 저항 용접 공정

강판을 생산하는데 사용되는 고주파 전기 저항 용접은 재료의 두께 및 재질, 용접속도, 성형조건 등에 따라 입열양을 적절히 변화시켜야 우수한 품질을 얻을 수 있다. 그러므로 입열을 자동으로 조절하는 제어장치의 개발과 아울러 공정의 상태를 알 수 있는 측정 시스템의 개발이 필요하다. 이를 위해 비드 형상을 온라인으로 계측하고 입열량을 추론하는 시스템에 대하여 소개하고자 한다.

비드의 형상은 입열량뿐 아니라 다른 여러 변수들에 의해서도 영향을 받는다.<sup>(9,10)</sup> 동일한 입열량이라 할지라도, 입열량을 제외한 다른 변수들, 예를 들면 용접속도, 대강의 두께, 가압률 압력, 용접 재료 재질 등이 제각기 산포도를 가지며 변화하므로 비드형상을 대변할 수 있는 특정치 추출에 어려움이 따른다. 이 문제점을 극복하기 위해 본 연구에서는 코호넨 네트(Kohonen net)를 이용하여 다양한 비드의 형상을 대변할 수 있는 대표 형상 추출법을 제안한다.

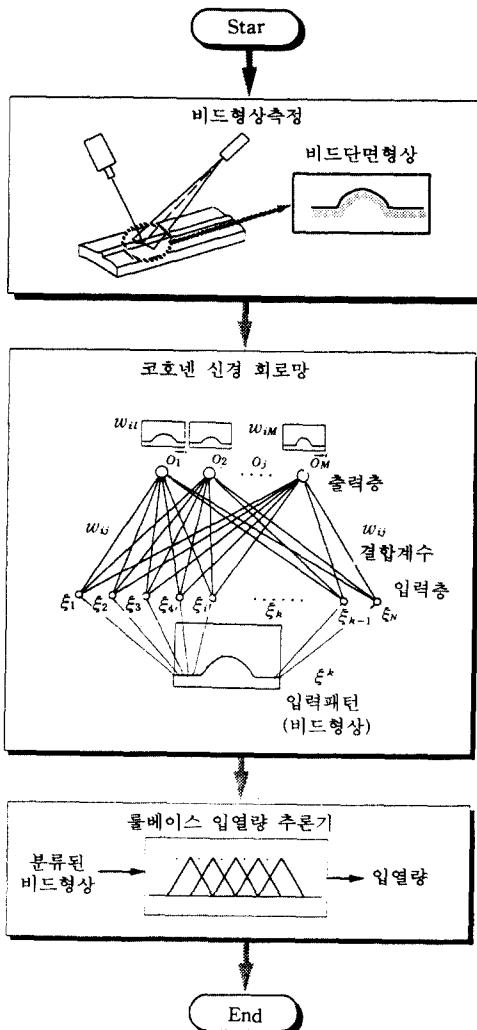


그림 7 입열량 추론기의 전체 개요도

분류된 비드의 형상과 입열량과의 관계는 동일한 입열량에 대하여도 추출되는 비드의 형상은 일정하지 않으므로 한 개의 대표적인 비드 형상만을 가지고 입열량을 추론하는 것은 부정확하다. 본 연구에서는 정해진 범위 내에서 계속 측정된 비드 형상의 통계적인 자료를 근거로 현재의 입열량을 추론하는 방법을 제안하고, 이에 대한 전체 개요도는 그림 7에 나타나 있다.

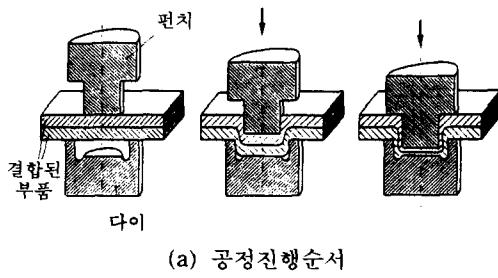
코호넨 네트의 구성은 입력으로는 영상상의 주어진 폭(180 pixel) 내의 스트라이프(stripe) 패턴의 상대 좌표 값을 사용하였다. 각 노드(node)의 연결강도는 비드의 스트라이프 패턴 800개를 사용하여 학습시켰다.

본 연구는 추출된 비드의 형상을 자기조직 신경회로망을 이용하여 각 클래스의 대표적인 비드 형상을 만들고, 입력 패턴과 비교함으로써 다소 노이즈가 섞인 입력 패턴이라 할지라도 훌륭한 분류 결과를 보여 주었다. 여기서 추론된 비드 형상의 분류 결과들을 사용하여 이들의 빈도수를 근거로 입열량의 정도를 파악할 수 있다.

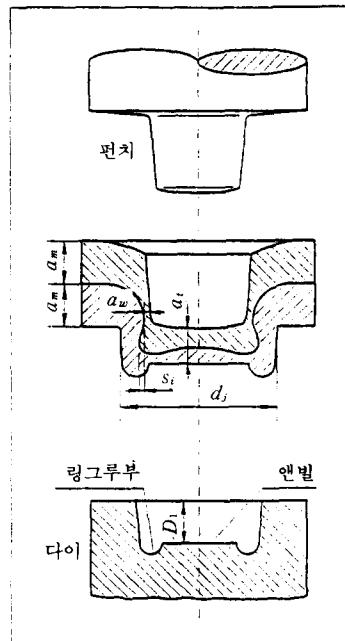
### 3.3 톡스(Tox) 접합부품의 인장강도 추정<sup>(4)</sup>

톡스 접합은 유압, 혹은 공압에 의하여 구동되는 한 개의 편치와 한 개의 다이 사이의 상호 작용에 의하여 이루어진다. 편치가 상부에 있는 박판의 표면을 누르고 접합될 하부의 박판으로 내려감에 따라 국부적으로 전단 삽입(shear insertion)이 발생되고, 접합재료는 다이 안으로 흘러들어가 채워지면서 업셋팅(upsetting)이 일어나 접합이 이루어지게 된다. 일반적으로 톡스접합의 접합강도는 접합방식, 편치와 다이의 기하학적인 형상, 접합재료의 성질 및 두께, 기계의 운전조건 등과 같은 공정 변수들에 의하여 영향을 받는다.

접합강도에 직접적인 영향을 주는 관련 인자는 다이와 편치의 형상관련 인자 중에서는 다이의 직경( $d_i$ ), 다이의 상부에지와 침골부 간의 거리인 편치의 삽입길이( $D_i$ ), 편치와 다이에 의하여 형성되는 하부두께( $a_s$ ) 등으로 알려져 있다.<sup>(11)</sup> 또한 접합재료 관련 인자 중에서는 접합전의 박판두께( $a_m$ )가 접합강도에 가장 크게 영향을 주는 변수임을 실험적으로 알 수 있었다. 본 연구는 그림 8에 나타나 있는 이 4개의 공정변수와 접합강도, 즉 인장강도, 간의 사상관계를 찾아내는데



(a) 공정진행순서



(b) 접합요소와 공구에서의 공정변수

그림 8 접합요소와 공구에서의 공정변수

목적이 있다. 이를 위해 본 연구에서는 다층 신경회로망을 사용하였다. 입력으로 앞에서 정의한 4개의 공정변수가 사용되었고, 출력은 추정하고자 하는 접합부의 인장강도이다.

그림 9(a)와 (b)는 각기 다이렉트 인장 테스트와 전단 인장 테스트에 대하여 학습된 네트워크가 추정한 인장강도의 결과와 실험적으로 얻은 인장강도를 비교하여 보여준다. 이 그림에서 볼 수 있듯이 추정된 인장강도가 실험치와 매우 근사함을 알 수 있다. 추

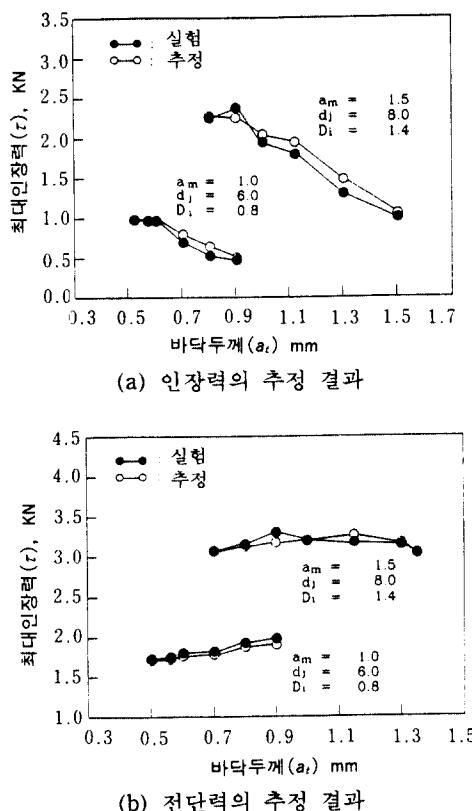


그림 9 인장강도의 추정치와 실험치와 비교  
(재료 두께  $a_m=1.0$  mm, 1.5 mm)

정 오차는 전단 인장 테스트에 대해서  $0.07\sim0.2$  kN이고 다이렉트 인장 테스트에 대하여  $0.1\sim0.4$  kN 사이에 분포함을 알 수 있다.

본 실험결과를 보면, 본 방법은 기존의 인장응력 측정 방법인 인장 응력 테스트기를 이용한 파괴 측정 방법을 대체하여 월등히 적은 노력과 시간 및 비용으로 알맞은 공정 조건을 찾을 수 있음을 보여준다.

#### 4. 맺음말

생산공정 자동화를 위해 퍼지논리와 신경회로망을 이용한 계측 및 제어에 대한 사례 연구를 제시하였고 이들 결과들을 요약하면

다음과 같다.

- (1) 조립작업에 자기학습 알고리즘을 적용한 결과, 주위환경의 불확실성을 극복하면서 정밀도가 높은 부품의 조립에 효율적으로 사용될 수 있음을 보였다.
- (2) GMA 용접에서 안정한 아크 상태를 얻기 위하여 퍼지규칙을 적용하여, 여러가지 용접조건에서도 안정된 아크 상태를 얻을 수 있었다.
- (3) 성형공정의 압력을 추정하기 위하여 신경회로망을 학습시킨 결과, 다양한 공정조건의 변화에 자율적으로 대응하여 성형압력을 잘 추정하였다.
- (4) 고주파·전기 저항 용접 공정에서 비드 형상의 분류를 위해 신경회로망을 적용한 결과, 외부 노이즈를 극복할 수 있었다.
- (5) Tox접합품의 인장강도를 추정하기 위하여 신경회로망을 이용한 결과, 비파괴적인 방법에 의해 인장강도를 잘 추정할 수 있었다.

#### 참고문헌

- (1) Mamdani, E. H., 1974, "Application of Fuzzy Algorithms for Control of Simple Dynamic Plant," *IEEE Proc. Control & Science*, Vol. 121, No. 12, pp. 1585~1588.
- (2) Sugeno, M., Nishida, T., 1985, "Fuzzy Control of Model Car," *Fuzzy Sets and System*, Vol. 16, pp. 103~113.
- (3) 현봉섭, 김재선, 조형석, 1992, "다중신경회로망 기법을 이용한 하이드로포밍 공정의 성형압력곡선 추정," 한국자동제어학술회의, pp. 607~612.
- (4) Kim, J. S., Cho, H. S., Lappe, W., Gao, S. and Bnclde, L., 1993, "A Quality Estimation Method for Clinching Processes Via Neural Network," '93 Winter Annual Meeting, Joint Symposium on Me-

- chatronics for Manufacturing, U.S.A.
- (5) Park, Y. S. and Cho, H. S., "A Self-Learning Rule-Based Control Algorithm for Chamferless Parts Mating," *Control Engineering Practice* (*to appear*).
- (6) Won, W. J. and Cho, H. S., 1992, "A Fuzzy Rule-Based Method for Seeking Stable Arc Condition under Short-Circuiting Mode of GMA Welding Process," *Part I-Journal of Systems and Control Engineering, PIME*, Vol. 206, pp. 117~125.
- (7) Mita, T., Sakabe, A. and Yokoo, T., 1988, "Quantitative Estimates of Arc Stability for CO<sub>2</sub> Gas Arc Welding," *Weld. Instrl.*, pp. 152~159.
- (8) Tirosh, J., Yossifon, S., Esbel, R. and Betzer, A., 1977, "Hydroforming Process for Uniform Wall Thickness Products," *ASME, J. Eng. Ind.*, 99, pp. 685~691.
- (9) Yutuka MIHARA, "A New Automatic Heat Input Control for Production of Electric Resistance Welded Pipe," *Transaction ISII* Vol. 25.
- (10) Haga, H., Aoki, K. and Sato, T., 1986, "Welding Phenomena and Welding Mechanisms in High Frequency Electric Resistance Welding-1st Report," Nippon Steel Technical Report.
- (11) Budde, L. and Lappe, W., 1990, "Stanznieten ist zukunftsträchtig in der Blechverarbeitung," *Bander Bleche Rohre* 5, pp. 94~100. ■