

초음파 센서와 신경회로망을 이용한 물체 인식과 복원

*추 승원, 이 기성
홍익대학교 전기제어공학과

Object Recognition and Restoration Using Ultrasound Sensors and Neural Networks

*Seungwon Choo, Keeseong Lee
Department of Electrical & Control Engineering
Hong-Ik University

Abstract - An object recognition and restoration using ultrasound sensors and neural networks are presented. The planar arrangement of the sensor is used to reduce the interference effects between sensors. The SOFM (Self-Organizing Feature Map) Neural Network and SCL (Simple Competitive Learning) method are learned with the acquired data. Lab experiments were performed that the object can be recognized and the resolutions of the object can be enhanced by using the small number of the ultrasound array and neural networks.

1. 서론

공장 자동화를 위해서 물체의 인식이나 분류를 하는 경우 송신과 수신 시간차(음파 비행 시간)를 이용하여 측정하는 초음파 센서를 이용하는 경우 경제적이고 장치의 구성이 Tactile 센서나 Camera를 이용한 Vision 시스템에 비해 간단하다. 또한 빠른 처리시간으로 인해 실시간 물체 인식이 가능하며, 음파의 송·수신으로 물체를 인식하므로 밝고 어두움에 관계없이 3차원 물체 형상들을 바로 획득할 수 있다. 그리고 유체속에서도 사용이 가능하다는 장점을 가지고 있다. 기존의 초음파센서 응용에 관한 연구 방향은 주로 물체의 유무 감지나 2차원적인 물체 윤곽 추출과 인식 분야로 진행되어 왔다. 자율 주행 이동로봇에 초음파 센서를 사용한 경우, 단순히 물체의 유무나 방해물의 거리를 측정하는 것에 한정되어 있다[1,2]. 따라서 초음파가 반사되어 오는 지점의 정보만 알 수 있지 물체의 전체 윤곽은 정확히 알 수가 없었다. 또한 Watanabe와 Yoneyama의 연구 [4]에서는 3차원으로 물체를 인식하는데 있어서 물체 윤곽을 추출하고 위치를 결정하여 해상도를 높혀 물체의 윤곽을 복원하는데 있어서 BPNN(Back Propagation Neural Network)을 적용하였는데, 적은 수의 초음파 센서를 사용하여 해상도를 높이는 문제에 있어서는 좋은 결과를 얻었지만 모든 출력노드에 있어서 목표치를 정해 주어 야만 하고 학습하는데 많은 시간이 소요되는 단점이 있다. 또한 많은 병렬 신경회로망을 사용하여 복잡한 Data 처리과정을 거쳐야하는 문제로 인해 학습시간에 있어서도 비효율적이다. 3차원 물체 인식을 위해 초음파의 평면 배열 방법을 이용하여 간섭없이 물체들에 대한 정보를 획득할 수 있다. 이렇게 초음파 센서로부터 얻은 정보를 통해 물체 크기 인식이 이루어진다. 본 실험에서는 물체에 대한 거리와 위치 정보를 획득하여 필터를 통과시켜 신경회로망의 입력으로 사용하여 크기를 결정할 수 있도록 학습을 시켜 물체 인식과 원래의 물체 형태로 복원하는 학습시간이 빠른 방법을 제안한다.

2. 시스템 구성

시스템 구성은 초음파센서의 거리·위치 정보를 획득하기 위한 하드웨어부와 획득된 정보를 처리하는 분류·복원부로 되어 있다[9]. 하드웨어부는 초음파 센서의 다중반사와 간섭을 줄이면서 구동시키고 주위 환경의 변화(온도 변화나 측정물체에 대한 기준 평면 변화등의 외란)에 대해 보정하면서 거리·위치 Data를 획득한다. 신경회로망은 먼저 입력된 센서 정보로 패턴을 분류하는 분류부와 획득한 저해상도 물체 윤곽을 향상시키는 복원부의 두 부분으로 구성되어 있다. 전체 시스템 블록도는 그림 1과 같다. 8개의 초음파센서로 배열을 구성하고 스캐핑 모터로 1 Step(2.5cm)씩 이동한다.

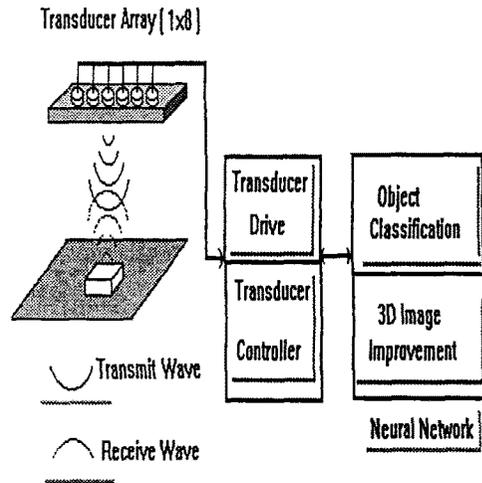


그림 1. 시스템 블록도

2-1. 초음파 센서를 이용한 3차원 정보 획득

거리 측정을 위한 초음파센서 구동 하드웨어는 초음파센서 구동부와 제어부의 두 부분으로 구성되어 있다. 초음파 센서 구동부는 초음파의 송수신을 담당하며 반사되어 오는 초음파를 수신한다. 감지된 신호를 디지털 신호로 변환하여 출력한다. 이 디지털 수신 신호를 센서 제어기에 전송하게 된다. 초음파센서는 송신시 센서의 인가 전압과 송신시간에 비례하여 측정거리가 증가하므로 구동하고자 하는 환경에 맞게 선택을 하여야한다. 제작된 센서 제어기는 Micro-Controller로 구성

되어 각각의 초음파 센서들에 대해 송신시간을 제어하여 측정 범위를 벗어난 거리에 대해 제한한다. 또한 간섭의 영향을 억제시키며 독립적으로 구동시키고 스캐핑 모터를 제어하여 연속적으로 거리를 측정한다. 이 측정된 거리와 위치정보를 저장하여 PC가 요구할 때 정보를 전송한다. 이 제어기는 0.185mm의 거리 해상도를 가지며 온도에 따라 변화하는 초음파 속도에 대한 거리정보 오차를 보정한다. 여기서 사용된 초음파센서는 POLAROID사에서 나온 Electrostatic Transducer [7] 를 사용하고 있다.

2-2 분류·복원부 구성

신경회로망을 이용하여 물체 인식 및 윤곽 검출을 한다. 먼저 초음파와 센서 제어기에서 들어온 3차원 정보들을 Filter를 통과시켜 측정할 때 발생하는 측정 기준 평면의 굴곡이나, 외부 환경등의 외란에 둔감하도록 일정한 Pixel 크기로 3차원 정보를 재구성한 다음, 분류하는 신경회로망에 입력시켜 학습시킨다. 이렇게 학습된 각각의 물체들은 특징에 따라서 분류된다. 다음으로 분류된 물체들에서 샘플들을 정하여 물체 윤곽들을 복원한다. 추출된 저해상도의 3차원 물체 윤곽 정보를 사용하여 고해상도의 3차원 물체 윤곽으로 향상시키는 신경회로망에 입력시켜서 해상도가 향상된 정밀한 3차원 물체의 윤곽을 복원한다.

가. 신경회로망 (Neural Networks)

센서 제어기에서 전송된 입력 Data를 처리하기 위해 신경회로망(Neural Network)을 이용하였다. 실험에 이용한 SOFM (Self-Organizing Feature Map) Algorithm[5]은 목표값을 지정해줄 필요가 없는 Unsupervised Learning 계열이다. SCL(Simple Competitive Learning)의 경우도 적은 수의 Teaching Data로 학습시켜 물체의 3차원 해상도를 향상시킨다. 제어기에서 입력된 정보는 매우 정밀하게 거리를 측정하므로 바닥면의 굴곡이나 센서 배열장치의 틈경도와 측정 물체의 표면 변화에 따라 거리, 위치정보가 매우 민감하게 변화한다. 따라서 이러한 측정 물체와 환경의 변화에 둔감하도록 Filter를 거쳐 일정 단계의 레베로 재 구성하여 신경회로망의 입력으로 사용하였다. 제어기에서 보내온 3차원 정보를 이 부분에서 일정 크기의 Pixel로 재구성하여 대략적으로 물체의 윤곽을 결정한다.

나. 분류 (Classification)

Filter를 거친 8x16 배열의 거리, 위치정보들을 분류하는 신경회로망에 입력하여 학습시킨다. 이 신경회로망은 각각의 측정 물체들에 대한 3차원 윤곽 특징을 추출하여 입력 정보들의 종류 갯수만큼 분류를 한다. 입력 Data의 분류에는 SOFM 알고리즘을 사용하였다. SOFM 알고리즘에서 출력 노드 Neuron Space A는 10x10의 정방형으로 구성되고 입력 Vector space V는 128 차원(16x8)으로 구성된다. 사용된 입력 Pattern은 4가지(크기가 각각 5.5cm x 5.5cm, 6.9cm x 6.9cm, 7.8cm x 7.8cm 와 8.9cm x 8.9cm)로 각각 Pattern들에 대한 정보들을 신경회로망에 입력시켜 분류한다. 아래 그림 2와 같이 구성된 신경회로망으로 분류 학습을 시킨다. SOFM의 알고리즘 다음과 같다.

$$w_r(t+1) = w_r(t) + \epsilon(t)h_{rn}(t)(V_{\phi_r(\omega)}(t) - w_r(t)) \quad (1)$$

$w_r(t)$: 시간 t에서 A상 r번째 Weight Vector

$\epsilon(t)$: $t \rightarrow \infty$ 에서 $\epsilon(t) \rightarrow 0$ 인 적응이득

$h_{rn}(t)$: $t \rightarrow \infty$ 에서 범위가 줄어드는 Neighborhood Function

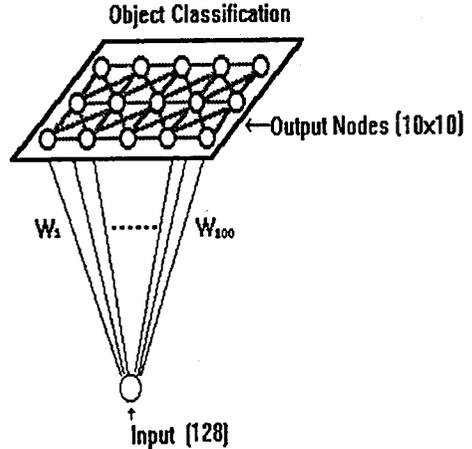
$\phi_r(\omega)$: A 상 r번째 Weight Vector에 대하여 입력 Pattern의 Index를 Return 시키는 함수

$$\phi_r(\omega) = \{ i \in B \mid \|V_{\phi_r(\omega)}(t) - \omega_r(t)\| = \min_{i \in B} \|V_i(t) - \omega_r(t)\| \} \quad (2)$$

식(2)에서

B는 입력 Pattern의 Index 집합

$V_i(t)$ 는 시간 t에서의 Index i를 지니는 입력 Vector 로써 총 10,240개로 반복적으로 학습.



* Neural Networks for Object Classification *

그림 2. SOFM 신경회로망

다. Teaching Data 추출

분류된 Data 들에 대한 Teaching Data는 LVQ(Learning Vector Quantization)를 사용하여 학습시킨다. LVQ 알고리즘은 다음과 같다.

$$w_i(t+1) = w_i(t) + \epsilon(t)(V_j(t) - w_i(t)) (2\delta(i-j) - 1) \quad (3)$$

$$\delta[x] = \begin{cases} x = 0 & \text{이면 } 1 \\ x \neq 0 & \text{이면 } 0 \end{cases}$$

i : Weight Vector $w(t)$ 의 소속 Class.

j : Input Vector $V(t)$ 의 소속 Class.

여기서 Class는 Filtering 기준을 Class로 삼았다. 예를들어 0 ~ 2.5는 Filter Value 0의 Class가 된다. 학습후 추출된 Teaching Data는 4종류이다.

라. 3차원 해상도 향상과 복원

Teaching Data에서 추출된 물체 윤곽 정보들을 가지고 신경회로망에 해상도를 향상시키도록 학습을 시킨다. 이 학습을 통해서 16x8의 저해상도 3차원 Image를 32x32의 고해상도 3차원 Image로 해상도를 향상시킨다. R.D.(Resolution Development)는 다음의 Two-phase SCL의 수정형으로 구성한다.

Phase - One

해상도를 향상시키기 위해 출력 뉴런 공간 A를 16x8을 기준

으로 32x32로 구성한다. R.D 란 이렇게 확장된 Weight Vector 에 적절한 값을 지정하여 16x8 data 정보를 확대 시키는 것을 의미한다. 만일 단순한 Interpolation 을 사용한다면, 육면체의 경우 사각꼴이나 원뿔 형태로 나타나게 될 것이다. 여기서 응용한 Interpolation 은 모양 그 자체에 어떠한 변형도 가하지 않고 바로 확대 시키는 것이다. 먼저 16x8의 Data를 가지고 32x32의 해상도로 향상 시키기 위해서는 16x8의 Teaching Data에 해당되지 않는 Weight Vector 를 16x8 의 기준 Weight Vector 주변으로 보내야 한다. 따라서 다음과 같이 구성한다.

$$\omega(t+1) = \omega(t) + \epsilon(t) \exp\left(-\frac{\|L(\omega'(t)) - L(\omega(t))\|^2}{\sigma^2(t)}\right) (\omega'(t) - \omega(t)) \quad (4)$$

$\omega'(t)$: 기준 Weight Vector.

$\omega(t)$: Update 할 Weight Vector.

$L(\omega(t))$: $\omega(t)$ 의 2차원 Index에 의해 구해지는 Input 공간의 위치
 $\sigma(t)$: 임의의 값에서 0으로 줄어드는 가변 분산.

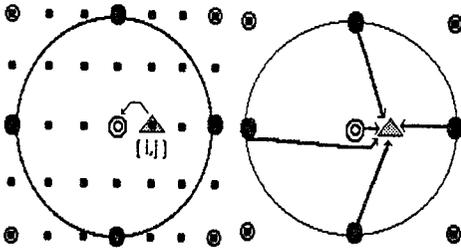


그림 3. 1차 Update 방법

그림 4. Update 강도.

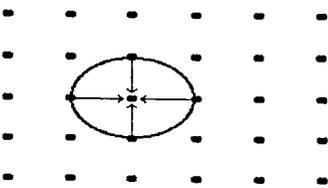
위의 그림 3 에서 (i, j)번째 Weight Vector 중 가장 가까운 16x8 Weight Vector를 중심으로 한 총 5개의 Weight Vector로 (i, j)번째 Weight Vector를 1차로 Update 시킨다. Weight Vector의 강도는 그림 4 처럼 가장 인접한 것에 영향을 많이 받아 Update 된다.

Phase - Two

Phase - One을 통해 일정한 값을 가진 Weight Vector 전체를 Phase - Two에서는 선명한 고해상도 3차원 Image를 복원하기 위해 다시 학습시킨다. Update Rule은 다음과 같다.

$$\omega(t+1) = \omega(t) + \epsilon(t) \exp\left(-\frac{\|L(\omega'(t)) - L(\omega(t))\|^2}{\sigma^2(t)}\right) (\omega'(t) - \omega(t)) \quad (5)$$

여기서 $\omega'(t)$ 는 $\omega(t)$ 주변으로 (x, y)방향으로 하나씩 증감된 Weight Vector 이다. 그림 5 처럼 Phase - One의 학습으로 32x32의 해상도로 향상된 결과에 대해서 인접한 5개의 Data를 다시 학습시킨다.



* Two-Phase R. D. [32x32] *
 [Smooth Update]

그림 5. 2차 Update 방법

이를 통해서 각 Weight Vector는 3차원 Image 윤곽을 전체적으로 Smooth 하게 만든다.

3. 실험

초음파 센서를 이용하여 물체 인식을 하거나 윤곽을 검출할 때 다음의 가정을 한다. X, Y 좌표값의 선택은 초음파 센서 배열 상의 고정된 좌표값을 기준으로 한다고 가정한다. 즉, 센서 배열을 구성하면서 X, Y 좌표값은 미리 결정되어 있는 것이다. 실험에서는 빠르고 정확한 One Pulse Echo Mode를 사용하고 측정거리를 벗어난 범위에 있는 물체에서 돌아오는 반사파는 무시한다. 3.85cm 크기의 초음파 센서를 센서 중심을 기준으로 5cm 간격으로 8개가 배열된 1x8의 배열을 2.5cm 간격으로 16 스텝을 이동 시키면서 물체를 인식하여 16x8 배열의 3차원 물체 정보를 획득하였다. 한 스텝당 이동 거리는 2.5cm 이다. 또한 물체측정 범위는 가로(X축), 세로(Y축)로 42.33cm, 44.83cm이고 높이(Z축)는 32cm ~ 56cm 이다. 그리고 0.185mm의 해상도로 측정된 거리 정보를 32cm ~ 56cm까지 0.6cm 단위로 40단계의 높이를 결정하였다. 따라서 측정된 물체에 대한 1 Pixel 크기는 X축으로 5cm, Y축으로 2.5cm, Z축으로 0.6cm 이다.

- 3차원 Image 분류 및 해상도 향상을 위한 실험.

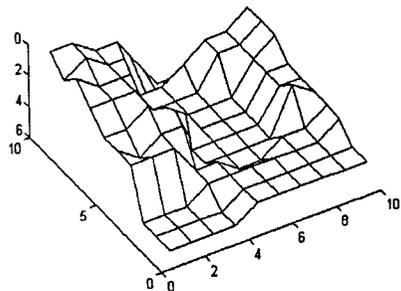
실험에서 사용한 물체는 다음과 같다.

가로: 5.5cm, 세로: 5.5cm 높이: 2cm 인 정사각형 물체.
가로: 6.9cm, 세로: 6.9cm 높이: 2cm 인 정사각형 물체.
가로: 7.8cm, 세로: 7.8cm 높이: 2cm 인 정사각형 물체.
가로: 8.9cm, 세로: 8.9cm 높이: 2cm 인 정사각형 물체.

모든 초음파 센서 구동시 서로간의 간섭을 방지하는 송수신 제어와 거리, 위치정보 관리는 제어기에서 담당하고 PC 요구시에 제어기에서 Data를 전송한다. 실험에서는 4종류의 단면적이 다른 정사각형 물체에 대해 Filter 를 통과시킨 각각 20개씩 80개의 Data를 추출하였다. 추출된 정보를 분류하는 신경회로망에 입력시켜 15번의 Epoch로 학습시켰다. 다음으로 분류된 Data들에 대한 Teaching Data를 추출하기 위해 LVQ 에 입력시켜 각각의 물체에 대한 Teaching Data를 결정하였다. 이 Teaching Data를 이용하여 학습시켜 해상도를 향상시킨다.

4. 결과 및 검토

학습 후 분류 결과는 Training Data 의 경우 100%이다. Test Data의 경우도 100%였다. 학습 후 구성된 SOFM 의 MAP 구성은 다음과 같다.



실험은 크기가 다르고 모양이 같은 물체에 대한 해상도 향상 실험이다. 크기가 작을수록 해상도를 향상시키는 학습과정에서 3차원 윤곽이 많이 손상 되었다. 해상도를 향상시킨 결과 를 보면 물체의 크기가 뚜렷이 구별됨을 알 수 있다.

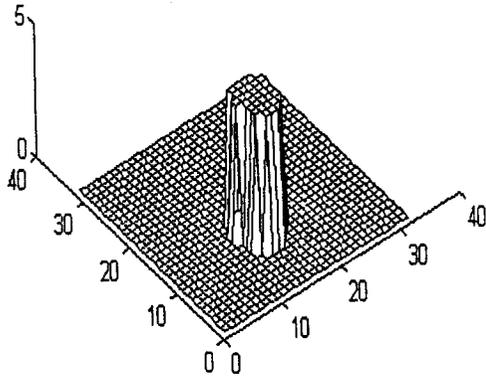


그림 I. 가로, 세로: 5.5cm, 높이:2.0cm 인 정사각형 물체.

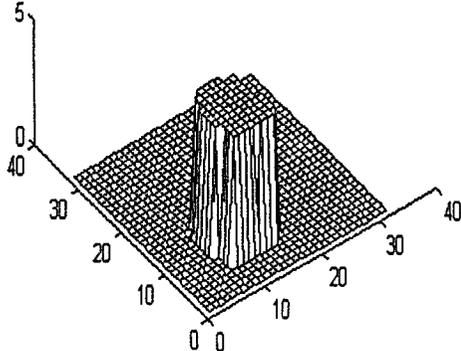


그림 II. 가로, 세로: 6.9cm, 높이:2.0cm인 정사각형 물체

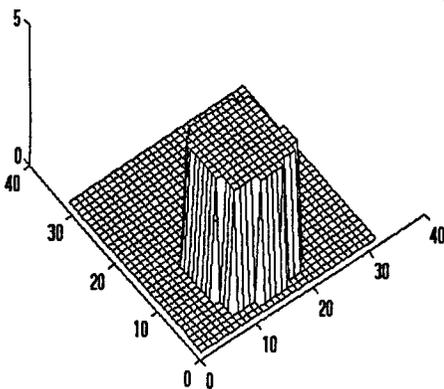


그림 III. 가로, 세로: 7.8cm, 높이:2.0cm 인 정사각형 물체

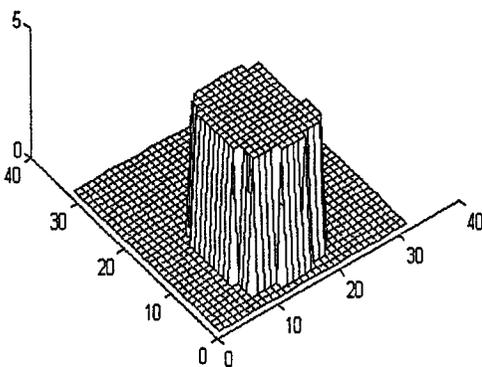


그림 IV. 가로, 세로: 8.9cm, 높이:2.0cm 인 정사각형 물체

초음파 센서에서 획득한 같은 모양에 크기가 다른 물체의 정보들을 학습시켜 100% 분류 할 수 있었다. 그리고 0.5cm 이상의 크기 차이가 나는 동일한 형태의 물체에 대해서도 분류가 가능하였다. BPN 보다 학습반복 횟수와 처리하는 Data량이 적어지므로 학습시간과 실험 면에서 능률적이다. 또한 3-D Image에 대한 해상도 향상에 있어서도 윤곽을 뚜렷이 구별함을 실험으로 알 수 있었다. 따라서 여기서 사용한 SOFM과 SCL 알고리즘이 초음파센서를 이용한 3차원 물체인식에서 보다 능률적임을 알 수 있었다.

5. 결 론

Camera를 이용한 Vision System을 사용하여 3차원 Image를 검출하는 경우 복잡한 수학적 해석을 필요로 한다. 그러나 초음파 센서는 직접 3차원 정보를 획득할 수 있으므로 빠르고 쉽게 0.5cm 이상의 크기가 차이 나는 동일한 형태의 물체를 인식할 수 있는 장점을 가지고 있다. 비접촉성 물질, 빛을 발하는 물체 또는 화재발생시 인명구조, 안개나 어두운 곳 또는 유체속에서 로봇이 작업을 할 경우, 초음파 센서를 이용한 3차원 물체 인식은 매우 유리하다. 본 연구를 통해 초음파 센서로도 3차원 물체 인식과 복원이 가능함을 알 수 있었다.

참 고 문 헌

- [1] 임종환, 조동우, "다중반사경로 효과를 고려한 자율이동로봇의 초음파 지도 형성," '93 한국 자동제어 학술회의 논문집, pp. 106-111, 1993.
- [2] 고중엽, 김완주, 정명진, "초음파 센서를 이용한 이동로봇의 실내 평면 구조 인식," '93 한국 자동제어 학술회의 논문집, pp. 125-132, 1993.
- [3] S.Y. Harmon, "Sonar-Based Real-World and Navigation," *IEEE Journal of Robotics and Automation*, Vol. RA-3, No. 3, June 1987.
- [4] Sumio Watanabe, Masahide Yoneyama, "An Ultrasonic Visual Sensor for Three-Dimensional Object Recognition Using Neural Network," *IEEE Transaction on Robotics and Automation*, Vol. 8, No. 2, April 1992.
- [5] Heige Ritter, Thomas Martinetz, Klaus Schulten, *Neural Computation and Self-Organizing Maps*, Addison Wesley, 1992.
- [6] Alois C. Knoll, "Ultrasonic Holography Techniques for Localizing and Imaging Solid Objects," *IEEE Transaction on Robotics and Automation*, Vol. 7, No. 4, August 1991.
- [7] *Ultrasonic Ranging System Handbook*, Polaroid Corporation.
- [8] Athanasios Papoulis, *Probability, Random Variables, and Stochastic Processes*, McGraw-Hill, 1991.
- [9] 추승원, 이기성, "초음파 센서 배열을 이용한 물체 인식," '94 한국 자동제어 학술회의, 대전, 1994년 10월.