

보울 피이더에서 신경 회로망을 이용한 부품 자세 인식에 관한 연구

임 태 군* ◦ 김 중 형* 조 형 석* 김 성 권**

* 한국 과학 기술원 생산 공학과

** (주) 삼성 전자 생산 기술 본부

A Neural Network Method for Recognition of Part Orientation in a Bowl Feeder

T.G. Lim* ◦ J.H. Kim* H.S. Cho* S.K. Kim**

* Department of Production Engineering
Korea Advanced Institute of Science
and Technology

** Robotics Reserch Center,
Production Tech. Div.
Samsung Electronics Co.

ABSTRACT

A neural network method is applied for recognizing the orientation of individual parts being fed from a bowl feeder. The system is designed in such a way that a part can be discriminated and sorting according to every possible stable orientation without implementing any mechanical tooling. The operation of the bowl feeder is based on a 2-D image obtained from an array of fiber optic sensor located on the feeder track. The acquired binary image of a moving and vibrating part is used as input to a neural network which, in turn, determines the orientation of the part. The main task of the neural network, here, is to synthesize the appropriate internal discriminant functions for the part orientation using the part features. A series of the experiments reveals several promising points on performance. Since the operation of the feeder is highly programmable, it is well suited for feeding and sorting small parts prior to small batch assembly work.

1. 서론

제조 공정에있어 자동화는 매우 중요한 과제이다. 특히 조립 작업은 노동 집약적이므로 조립 작업의 자동화는 생산성 향상 및 원가 절감에 직접 관련된다. 대량 생산 체제에 적용되는 자동 조립 시스템에서는 다목적용 조립 로봇의 응용에대한 관심이 고조되고 있다. 산업용 다목적용 로봇의 도입이 많이 사용되어 지고 있지만 많은 제한 요소를 가진다. 가장 주된 이유는 부품 공급의 어려움에 있다. 특히 조립 공정에 있어서는 한개의 제품에도 수십개에 이르는 부품이 조립되어 지므로 이들을 정렬시켜 자동으로 공급하는 작업은 매우 중요한 기술이다. 요구되는 방향 및 위치에 부품을 공급하기 위해서는 부품 전송 장치와 부품 정렬 장치가 사용되어 진다. 또한 이러한 장치들이 유연성(flexibility)를 가지기 위해서는 공급되는 다양한 부품에 따라 프로그래밍이 가능한 기능이 있어야 한다. 여러 부품이 섞여서 공급되거나 한 부품이 임의 자세로 공급되는 경우, 각 부품들의 기하학적 특징들을 이용하여 이들을 정렬하고 공급한다.

일반적으로 널리 사용되어지는 부품 공급 장치로는 진동식 보울 피이더가 있다. 여기에는 매우 정교히 제작된 부품 정렬 및 이송 장치가 있다. 부품 정렬 장치의 경우 방향이 틀린 부품이 이송되어 올 경우 기구적으로 설계된 트랙(track)위의 장애물을 이용하여 정렬이 잘못된 부품을 보울의 밑바닥으로 떨어뜨리거나 능동적으로 올바른 방향으로 부품을 바로 잡기도 한다. 이러한 장애물들은 주로 부품의 기하학적인 특징을 이용하는데 그 예로는 wiper blade, pressure break, slotted track, scallop, V cutout, narrow track 등이다. 센서를 이용하지 않고 기구적인 장애물만을 사용하는 경우 부품에 따라 설계 변수를 달리 지정해 주어 새로이 제작하는 등 유연성이 결여 된다. 또한 자세가 틀린 부품을 트랙에서 제거하여 버림으로 전체적인 부품 공급의 효율을 저하 시킨다.

프로그램이 가능한 보울 피이더에 대한 연구가 많이 진행되고 있다. 일련의 광전 소자를 트랙위에 심어서 부품이 소자위를 지나면 on-off의 신호 조합으로부터 부품의 특정 위치의 값을 비교함으로써 부품의 특징을 추출하는 연구가 제시 되었다.[1,2] 저출력의 He-Ne 레이저를 사용하여 부품의 자세를 판별하는 시스템도 개발되었다.[3] 이러한 경우 유연성은 다소 떨어지나 열거하고 처리 속도면에서 장점이 있다고 하겠다. 보울 피이더의 출구에 라인 스캔 카메라(line scan camera)를 장치하여 콘베이어상에서 일정한 속도로 공급되는 부품의 그림자 영상(silhouettes image)를 이용하여 부품의 자세를 판별하는 시스템이 개발되었다.[4,5] 또한 TV 카메라를 이용하여 보울 피이더상에 이송되는 부품의 2 차원 영상을 인식하여 부품의 자세를 판별하는 시스템도 개발되었다.[6] 영상을 이용한 연구의 경우 프로그래밍의 기능이 매우 뛰어나지만 처리 과정이 복잡하고 처리 속도가 떨어지므로 실제 생산 현장에서의 사용은 제약을 받게 된다. 광 파이버 센서를 이용한 프로그래밍 부품 정렬 시스템이 개발되었다.[7] 부품 자세의 인식은 보울 피이더의 트랙에 심어 있는 광 파이버 센서로부터 2 차원 영상을 받아 signature 처리 알고리즘을 수행함으로써 얻어 졌다. 이 알고리즘은 부품의 내부 특징(hole, bay)을 알아 내는데 효과적이기 때문에 기존의 보울 피이더로 공급 및 정렬 하기 어렵던 부품들도 처리하였다. 이방법은 2 차원의 영상으로부터 signature 정보 추출하는데 어려움이 있다. 특히 복잡한 부품의 경우 계산 시간의 소모 및 부품의 정렬에도 판별목(decision tree)이나 규칙(rule)을 만들어야하는 문제점이 있다.

방법으로 가중치를 재조정한다. 훈련 세트(training set)의 모든 입-출력 패턴쌍에 대한 평균 시스템 오차는

$$E = \frac{1}{2P} \sum_P \sum_N (t_{pk} - o_{pk})^2 \quad (5)$$

와 같다. 여기서 P는 학습에 사용된 입-출력 패턴쌍의 표본(sample) 수이다.

일반화된 델타룰(Generalized delta rule) 또는 역전달 학습룰(back-propagation learning rule)[8]은 위와 같은 학습과정에 사용되는데, E_p 가 가능한 한 빨리 줄어드는 방향으로 가중치들을 변화시켜 가중치의 적당한 set를 학습시킨다. 수렴을 보장하기 위해 가중치 변화량 $\Delta_p \omega_{kj}$ 를 $\partial E_p / \partial \omega_{kj}$ 와 비례하게 놓는다.

$$\Delta_p \omega_{kj} = -\eta \frac{\partial E_p}{\partial \omega_{kj}} \quad (6)$$

여기서 η 는 학습율이고 학습의 빠르기에 관계된다. 만약

$$\Delta_p \omega_{kj} = \eta \delta_{pk} o_{pj} \quad (7)$$

와 같이 놓으면, E_p 는 식 (1),(2),(4),(6)와 같이 표현되므로 chain rule을 이용하면 출력층의 노드에서는

$$\delta_{pk} = (t_{pk} - o_{pk}) f_k'(net_{pk}) \quad (8)$$

와 같이 계산되고, 중간 계층(hidden layers)에서는

$$\delta_{pj} = f_j'(net_{pj}) \sum_N \delta_{pk} \omega_{kj} \quad (9)$$

와 같이 계산된다. 활성도 함수로 Sigmoid 함수가 쓰이면, 식 (8)과 (9)는 각각

$$\delta_{pk} = (t_{pk} - o_{pk}) o_{pk} (1 - o_{pk}) \quad (10)$$

$$\delta_{pj} = o_{pj} (1 - o_{pj}) \sum_N \delta_{pk} \omega_{kj} \quad (11)$$

와 같이 구해진다.

가중치들을 학습해 갈 때, 미소 가중치 변화량 (incremental weight changes)은 각 패턴 쌍에 대한 가중치 변화량을 전부 합하여

$$\Delta \omega_{kj} = \sum_P \Delta_p \omega_{kj} \quad (12)$$

와 같이 계산한다. 이러한 학습과정은 반복적으로 이루어진다.

$$\Delta \omega_{kj}(n+1) = \eta \delta_{kj} o_j + \alpha \Delta \omega_{kj}(n) \quad (13)$$

여기서 n은 반복횟수를 나타내며, α 는 momentum rate이다. 이는 학습율(learning rate) η 가 클 때, oscillation이 발생하는 것을 방지하기 위한 것이다. 각 반복 학습 때마다 모든 입력/표적 패턴쌍이 한번씩 주어진다. 이러한 반복 학습이 계속 되다가 시스템 오차가 주어진 범위 내에 들어 오면 학습은 끝나게 된다. 학습이 끝나면 신경회로망 내부에는 입-출력 패턴쌍의 상관관계가 표현되게 된다. 산출 단계에서 새로운 입력이 주어지면 이러한 상관관계에 의해서 그에 적당한 출력을 내주게 된다.

4. 부품 자세의 인식

부품의 자세 인식 작업은 영상 시스템으로부터 얻어진 2차원의 2차 영상을 입력으로 한 뉴럴 네트워크 알고리즘에 의하여 수행된다. 그림 7(a)에서 보듯이 부품의 영상은 8개의 선분(line segment) 정보로 구분되며, 이들은 각각의 8개 광 파이버로부터 구해진다. 주어진 영상으로부터 2개의 기본적인 feature를 추출할 수 있다. 이들은 각 선분의 면적(A_j)과 선분의 중심($Xc.j$)으로 다음과 같이 표현된다.

$$A_j = \sum P(i,j), \quad Xc.j = \frac{\sum P(i,j) \times i}{A_j} \quad (14)$$

여기서 $P(i,j)$ 는 2차 영상의 (i,j) 화소(pixel) 값이다. 선분의 면적과 그의 중심은 대략적인 부품의 형상 정보를 포함하고 있을 뿐 아니라 상위 feature를 쉽게 만들 수 있다.

feature의 선택은 부품의 인식 및 분류에 있어 매우 중요하다. 일반적으로는 부품과 관련되는 여러 feature를 대상으로 신뢰성과 정확성, 처리 속도면등을 비교 검토하는 작업을 통하여 가장 적절한 feature를 선택하게 된다. 실제로 부품 분류의 성능은 적절한 feature 선택에 의해 좌우된다.

본 시스템은 광 파이버 센서를 사용함으로써 feature 선택에 있어 제약 조건을 가진다. 광 파이버 센서는 그의 직경보다 작은 부품의 형상은 표현될 수 없으므로 분해능은 파이버의 직경보다 작을 수 없다. 따라서 형상적인 차이가 작은 부품을 구분하기 위한 feature의 선택은 어렵다. 또한 광 파이버 센서 위를 통과하는 부품은 공급 속도 변화 및 불규칙한 진동으로 인하여 화상에 노이즈가 많을 뿐 아니라 부품의 영상이 실제와 왜곡되어 나타나므로 신뢰성이 높은 feature의 선택이 어렵다. 그림 7(b)는 실제 부품의 형상과 그의 대표적 2차화 영상을 보여준다. 이와 같은 센서의 특징 때문에 부품의 이송시에 동일한 광 파이버에 대하여도 매우 불규칙한 신호가 나타나므로 영상에서 추출된 기본적 feature는 Gaussian 확률 분포를 갖는다고 할 수 있다. 그림 8은 부품 3의 80개에 대한 기본 feature들의 Gaussian 확률 분포를 나타내었다. 면적 feature의 경우 편차가 매우 커서 부품의 각 자세를 구별하기 힘들다. 단지 선분(line segment) 면적 중심 값중 몇개의 선분에서 부품 자세에 따른 확률 분포가 쉽게 구분이 가능하고 나머지는 편차가 크게 나타난다. 따라서 이런 영상에서 추출된, 전체 형상을 표현하는 global feature는 편차의 값이 커서 부품을 구별하는 데는 신뢰성이 없고 정밀도가 떨어진다. 비록 가능하더라도 계산 시간이 많이 소요된다. 따라서 부품의 자세에 따른 특징이 잘 나타나있는 몇 개의 기본적인 feature만을 이용하면 영상이 전체적으로 일관성이 없더라도 자세를 잘 구분할 수 있다.

뉴럴 네트워크는 병렬 구조를 가지고 본산적으로 작동되므로 전체의 영상 정보보다는 분산된 선분 feature의 정보가 부품의 자세를 인식하는데 보다 적합하다. 따라서 간단한 feature를 이용한 뉴럴 네트워크 알고리즘을 적용함으로써 낮은 분해능의 영상 시스템의 성능을 향상시켰다.

뉴럴 네트워크의 입력으로는 선분 면적 및 중심의 feature와 이에서 파생된 moment의 정보를 추가의 feature로 다음과 같이 선정하여 사용하였다.

- i) 선분의 면적 (A_j)
- ii) 선분 면적의 중심 ($Xc.j$)
- iii) 선분 면적의 1차 moment ($Mx.j$)

본 연구에서는 뉴럴 네트워크(neural network)를 이용하여 프로그래머블 보울 피이더에서 공급되는 부품의 자세를 정렬하였다. 뉴럴 네트워크의 입력으로는 트랙상에 심어져있는 광 파이버에서 나온 2차원 영상에서 추출된 feature를 사용하였다. 광 파이버에서의 추출된 영상은 다른 카메라에서 추출된 영상에 비해 분해능이 떨어지지만 어느 정도 제한된 종류의 부품이 사용되어지는 로봇 조립 환경하에서는 사용가능하다. 일반적으로 feature의 종류는 매우 다양하며 부품이나 그의 자세에 따라 선택하여 사용하고 있다. 하지만 좋은 feature의 선택은 시스템의 성능에 많은 영향을 준다. 특히 처리 속도면과 인식 능력면에서 큰 영향을 주므로 feature의 선정은 매우 중요하다. 본 연구에서는 가장 기본되는 feature와 그의 파생되는 feature만을 뉴럴 네트워크의 입력으로 사용하여 여러 종류의 부품에 대해 적용하였다. 뉴럴 네트워크의 훈련 과정(training mode)에서는 구별 함수(discriminant functions)를 자동적으로 생성하여 사용하였다. 뉴럴 네트워크의 작동은 분산적으로(distributed manner) 되므로 노이즈에 강하고 인식 능력도 신뢰성을 가진다. 여러 부품에 대한 실험 결과를 통하여 본 시스템의 성능을 평가하였다.

2. 장치 구성

전체 시스템은 그림 1에 보인바와 같이 보울 피이더와 광 센서 그리고 이로 부터 얻어진 2 차원 영상을 처리하는 IBM-PC부분과 정렬된 부품을 자세에 따라 공급하는 분류 공급 장치로 구성되어 있다. 보울 피이더는 350mm 직경의 보울과 폭 20mm의 폴리우레탄으로 코팅된 트랙으로 구성되어 있다. 그리고 35mm의 간 블록이 트랙속에 장착되어 있다. 이 블록속에는 부품의 영상을 추출하는 광 파이버 센서가 포함되어 있다. 트랙에 평행한 단면은 부품들을 빨리 이송시키기에 적합하게 설계되었다. 영상 시스템은 그림 2에 나타나있다. 영상시스템의 작동 원리는 다음과 같다. 외부 조명의 영향을 없애기 위하여 자연 조명보다 180 Lx 이상의 백열 등 조명을 광 파이버 위를 비추주고 있으며, 광 파이버 센서는 각각 8개가 한 조가 되어 부품이 진행하는 방향과 작각으로 보울 피더 트랙상에 1열로 설치되어있다. 부품들이 파이버를 지나면서 생기는 그림자는 광 트랜지스터(photo TR)에 의하여 전기적인 신호로 바뀌어 진다. 광 트랜지스터에서의 출력은 문턱값(threshold)에 의해 '0'과 '1'의 값을 갖는 2차 영상(binary image)이 된다.

2차 영상으로부터 실제 부품을 인식 및 구분하는 작업은 뉴럴 네트워크 알고리즘을 이용하여 실행 하였다. 2차 영상에서 물체에 따른 feature를 추출하여 뉴럴 네트워크의 입력으로 사용하였으며, 뉴럴 네트워크는 이들을 이용하여 분산적 방법으로 처리하여 부품의 자세를 인식하였다. 알고리즘의 수행은 IBM-PC를 통하여 구현하였다. 실험에 사용한 부품은 기하학적으로 다른 형상을 가진 것들로서 각기 4가지의 안정된 자세를 가지고 있다. 특히 부품 3은 피아노에 사용되는 부품(flange)으로 형상의 복잡도가 높다. 또한 모든 부품이 기존의 기구적 정렬 장치로는 자세를 정렬, 구분하기 힘든 것이다.

보울 피이더의 끝 부분에는 분류된 부품을 공급하는 탈출 장치(escape device)가 그림 4와 같이 장치되어 있다. 탈출 장치는 공기압 밸브로 작동되며 4개의 출구가 있어 부품의 자세에 따라 각기 공급한다.

3. 역 전달 신경회로망(Back-propagation neural network)

신경회로망은 인간의 뇌기능 모델에 기초한 인지적 정보처리 구조이다. 기존의 계산기가 복잡하고 다양한 계산을 할 수 있는 연산자에 의존하는 반면, 신경회로망은 간단한 계산만이 가능한 연산자들이 다수로 연

결되어 있다. 이러한 연산자들사이의 연결의 강도를 조절하면서 입-출력 간의 관계를 표현하게 된다. 연결의 수가 많으므로 복잡한 표현도 가능하고 정보를 분산적으로 표현할 수 있다. 따라서 연상작용이 가능하게 되어 학습되지 않은 입력이나 변형된 입력에 대해서도 적합한 출력을 내줄 수 있다. 신경회로망은 두 가지 모드로 작동되는데, 학습 단계와 산출 단계가 있다. 먼저, 학습 단계에서는 다수의 입-출력쌍이 주어지고 이 입-출력쌍의 관계를 잘 표현해 주도록 연결의 세기를 조정하게 된다. 먼저, 하나의 입력 패턴에 대해 출력을 계산한다. 오차가 없으면 학습이 이루어지지 않지만, 오차가 있으면 이 오차가 줄어들도록 연결의 강도를 조절한다. 이러한 조절과정이 끝나면, 새로운 입-출력쌍이 주어지고 같은 과정으로 학습이 이루어진다. 다음에 연상과정에서, 새로운 입력들이 주어지면, 학습과정에서 신경회로망 내부에 형성된 입-출력쌍의 연관관계에 의해 적합한 출력들이 계산되게 된다.

여기서는 역전달 신경회로망이 사용되었는데 입-출력 상호간의 상관관계를 잘 묘사해 준다.

<산출 단계(Production phase for estimation)>

입력층(layer i)에 입력 패턴들이 주어지면 계층 j(layer j)에 있는 노드로 들어 가는 순(net) 입력은 다음과 같이 계산된다.

$$net_{pj} = \sum \omega_{ji} \alpha_{pi} \quad (1)$$

여기서 ω_{ji} 는 계층 j와 계층 i를 연결하는 링크의 가중치들로 학습과정에서 적절하게 결정되게 된다. 또한 α_{pi} 는 계층 i에 있는 노드에서 나오는 출력을 나타낸다. 이 순입력은 활성화(activation)함수를 거쳐 다음과 같이 계산된다.

$$\alpha_{pj} = f(net_{pj}) \quad (2)$$

보통 활성화 함수로는 sigmoid 함수가 사용되는데 이는 다음 식과 같이 표현된다.

$$\alpha_{pj} = \frac{1}{1 + \exp\{-(net_{pj} + \theta_j)\}} \quad (3)$$

여기서 θ_j 는 계층 j에 있는 노드의 문턱값(threshold value)이다. 식 (1), (2), (3)과 같은 과정을 거쳐서 α_{pj} 로부터 α_{pk} 가 계산된다. 따라서 임의의 입력 패턴은 입력층부터 최종 출력층까지 전달되어, 출력 패턴이 계산된다.

<학습 단계(Learning phase for training)>

입력 패턴(input pattern)과 표적 패턴(target pattern)이 주어지면, 신경회로망은 역전달 학습이론(back-propagation learning algorithm)을 이용하여 squared output error

$$E_p = \frac{1}{2} \sum_N (t_{pk} - \alpha_{pk})^2 \quad (4)$$

가 최소가 되도록 모든 링크의 가중치와 문턱치들을 조정한다. 이와 같은 가중치 조정 과정이 끝나면, 또 다른 입-출력 패턴쌍이 주어지고, 같은

- iv) 선분 면적의 2차 moment (M_{xx}, j)
- v) 두 선분 면적의 차이

$$\Delta A_j = A_{j+1} - A_j$$
- vi) 두 선분 면적 중심의 차이

$$\Delta X_{c,j} = X_{c,j+1} - X_{c,j}$$

실험을 통하여 각 feature들의 부품 자세 인식 능력을 평가하여 가장 적절한 feature를 선택하였다.

5. 결과 및 토론

뉴럴 네트워크 알고리즘의 성능을 평가하기 위하여 그림 3에서와 같이 3가지의 서로다른 형상의 부품을 대상으로 각각의 자세를 인식하는 실험을 행하였다. 뉴럴 네트워크의 학습 단계에서는 한개 부품, 한개의 자세에 대해 10개의 정보를 사용하였다. 이 단계에서는 2개의 layer가 사용되었으며 첫째 layer는 10개의 node 둘째 layer는 4개의 node로 구성되어 있다. 학습 단계를 마치면 뉴럴 네트워크는 일반적인 mapping 특성을 기억하게 된다. 인식 실험은 한개 부품, 한개의 자세에 대하여 40개씩 총 160(=4x40)개의 데이터에 대해 부품의 자세의 인식 성공률을 측정했다. 표 1은 여러 feature에 대한 인식 실험 결과를 보여 주고 있다. 부품 1의 4가지 자세는 1차 moment만으로도 성공적으로 구분하였다. 부품 2, 3의 경우는 한개의 feature만으로는 모든 자세의 구분이 힘들음을 알 수 있지만, 한개 이상의 feature를 사용하면 잘 구분 할 수 있다. 따라서 일반적인 부품의 경우 여러 feature를 사용하여 거의 100%의 자세 인식 성공률을 얻는다. 4가지의 자세는 출력 layer node의 패턴을 2치(binary)화하여 결정한다. 그림 9는 부품 3에 대한 2000회의 반복 학습된 후, 160개 데이터에 대해 부품의 자세를 인식했을 때 출력 layer node의 두개의 출력 패턴(O_1, O_2)의 값을 각 feature에 따라 보여준다. 선분의 변적 feature의 경우 4가지의 모든 자세가 동일한 값을 갖으므로 자세의 구분이 불가능하다. 1차 2차 moment에서는 3, 4번째의 자세는 쉽게 구분이 가지지만 1, 2번째의 자세는 비슷한 값을 갖는다. 그러나 그림9(b), (f)에서 선분 면적의 중심과 차이값에 대한 결과는 모든 4가지의 자세를 쉽게 구분지을 수 있음을 알 수 있으므로 이들이 부품 3에 대해서는 좋은 feature라는 결론이 된다.

6. 결론

본 연구에서는 보울 피이더에 공급되는 부품의 자세 인식을 위하여 뉴럴 네트워크 알고리즘을 적용하였다. 부품 자세에 따른 기하학적 형상 정보는 광 파이버 센서에서 얻어진 2차원의 2치 영상으로 표현했다. 값은 싸지만, 일반 카메라에 비해 분해능이 낮은 센서의 사용과 공급 속도의 변화 및 진동으로 인하여 실제로 얻어진 부품의 영상은 크기 및 형상이 매우 불규칙하여 부품 자세를 구분 지을 수 있는 feature의 선택이 어려웠다. 본 연구에서는 기본적인 feature를 뉴럴 네트워크의 입력으로 사용하여 여러 부품에 대해 각 부품의 자세를 성공적으로 구분하였으므로 다음과 같은 장점을 갖는다. 첫째로 선택된 feature가 간단하고, 뉴럴 네트워크 알고리즘이 병렬 구조를 갖으므로 처리 시간면에서 매우 유리하다. 둘째, 부품이 바뀌어도 뉴럴네트워크의 학습단계에서 분류 함수(discriminant function)을 자동적으로 만들어 줌으로 부품 변화에 대한 유연성이 좋다. 셋째, 실험 결과에서 보는 바와같이 신뢰성이 보장된다. 따라서 본 시스템은 값이 싸고 신뢰성이 있고 유연성이 요구되는 자동 조립 작업에 적합하다는 결론을 얻을 수 있다.

후후의 연구 과제로는 보울 피이더의 트랙 벽면에 추가의 광 파이버 센서를 설치하여 부품의 3차원 영상을 받도록하여 부품의 3차원

특징까지 이용함으로써 보다 다양한 부품 및 자세에 대한 확장성에 대한 연구와 뉴럴 네트워크의 layer 및 node 수를 변화시켜 보다 신뢰성이 있는 방법에 대한 연구를 들 수 있다.

참고 문헌

- [1] Monthly Journal of Automation System, pp.20-23, August 1977
- [2] John Hartley, "Picking Parts from a Bowl Feeder with Image Sensor", Sensor Review, Vol.1, No.1, pp.30-31, Jan. 1981.
- [3] Swift, K.G., Dewhurst, R.J., "A Felexible System Handles Engineering Components", Assembly Automation, May 1983
- [4] Pugh, A., Heginbotham, W.B. and Waddon, "Versatile Parts Feeding Package Incorporating Sensory Feedback", Proc. of 8th Int. Symposium on Industrial Robots, Stuttgart, 1978
- [5] Cronshaw, A.J., Heginbotham, W.B. and Pugh, A., "A Practical Vision System for Use with Bowl Feeder", Proc. of the 1st Int. Conf. on Assembly Automation, pp.265-274, March 1980
- [6] Hill, J.W., "Programming Bowl Feeder Design based on Computer Vision", Assembly Automation, Vol.1, pp.21-25, Nov. 1980
- [7] Park, I.O., Cho, H.S. and Gwen, D.G., "Development of a Programmable Bowl Feeder Using a Fiber Optic Sensor", Proc. of the 10th Int. Conf. on Assembly Automation pp.265-274, March 1989
- [8] Pao, Yoh-Han, Adaptive Pattern Recognition and Neural Networks, Addison-Wesely Publishing Company, Inc. 1989




Fig.1 Overview of the programmable bowl feeder




Fig.2 Schematic diagram of the image system




Fig.3 Various parts and their orientations

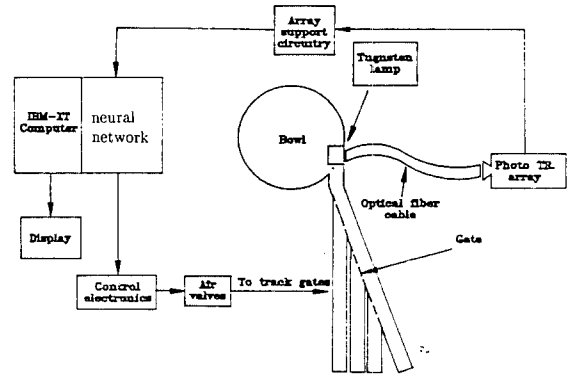


Fig.4 The feeding system block diagram

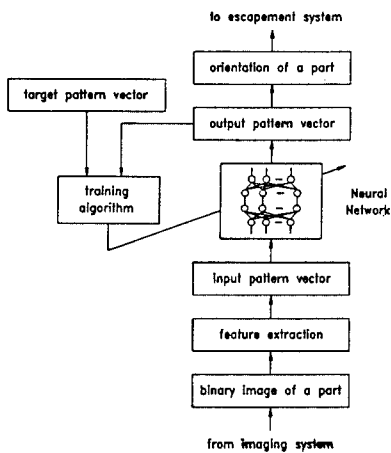


Fig.5 Block diagram of the recognition procedure for part orientation using neural network





Fig.6 Schematic diagram of a multilayer neural network



(a) Division of the field view into 8 segments (b) Binary images of each orientations superimposed on a part profile

Fig.7 Sample images for each orientation of part 3




Fig.9 Estimation results for part 3

Table 1 The success rate of recognition for part orientations

for various features

Feature	part 1	part 2	part 3
Area (A_i)	71	28	25
Center ($x_{c,i}$)	48	100	100
1st moment ($m_{x,i}$)	100	81	70
2nd moment ($m_{xx,i}$)	90	100	75
Change of area (ΔA_i)	63	64	40
Change of center ($\Delta x_{c,i}$)	63	100	100

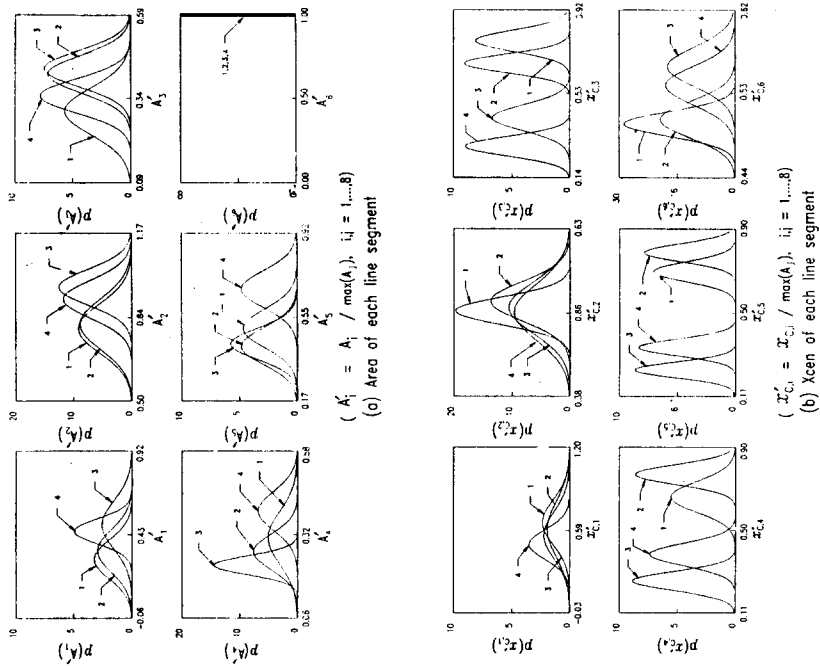


Fig.8 Probability distributions of primary features for part 3