工學碩士 學位論文

신경회로망을 이용한 지능형 가공 시스템 제어기 구현

An Implementation of the Controller for Intelligent Process System using Neural Network

指導敎授 李 尙 培

2001年 2月

韓國海洋大學敎 大學院

電子通信工學科

孫 彰 佑

목차

Abstract

An artificial neural network is an information-processing system that has certain performance characteristics in common with biological neural networks. Artificial neural networks have been developed as generalizations of mathematical models of human cognition or neural biology, based on the assumptions.

In this study, this system makes use of the analog infrared rays sensor and converts the feature of fish outline when sensor is operating with CPU(80C196KC). Then, after signal processing, this feature is classified a special feature and a outline of fish by using the neural network, one of the artificial intelligence scheme. This neural network classifies fish pattern of very simple and short calculation. This has linear activation function and the errror back propagation is used as a learning algorithm. And the neural network is learned in off-line process. Because an adaptation period of neural network is too long when random initial weights are used, off-line learning is induced to decrease the progress time

An "iron butcher" is a head-tail cutting machine that is commonly used in the fish processing industry.

Millions of dollars worth of "pollack" are wasted annually due to inaccurate head-tail cutting using these somewhat outdated machines. The main cause of wastage is the "over-feed problem". This occurs when a pollack is inaccurately positioned with point to

the cutter blade so that the cutting location is into the gill and tail of a pollack. An effort has been made to correct this situation by sensing the position of the gill using sensors accordingly.

We confirmed this method has better performance than somewhat outdated machines.

1. 서 론

오늘날 사회는 기계기술에서 시작되어 최근의 전자기술, 정보기술, 제어기술 등으로 발전하여 오늘날의 산업을 이룩하였다.

제어기술로는 요즘 인공 지능 기법이 많은 부각을 받고 있으며, 공학과 산업 응용에서 공통적으로 사용하고 있다. 그 중에서 신경회로망은 수학적인 공식이 요구되지 않으므로 작업과 동작 환경에 대한 수학적인 모델을 쓸 수 없는 시스템에 적용이 되므로 데이터의 패턴 인식이나 음성 인식, 연산 메모리등에 많이 쓰인다.

따라서 이런 알고리즘을 바탕으로 아날로그식으로 명암과 거리를 판별할 수 있는 광량 센서를 어레이식으로 나열하여 특징점과 윤곽을 받아, 현 산업 공정에서 대두되고 있는 인공 지능 제어기법을 기반으로 센서에서 나오는 신호의 특징점과 윤곽을 패턴 분류하였다.

인공지능 기법들은 여러 가지가 있으며, 그 대표적인 기법은 퍼지논리와 신경회로망이다. 퍼지논리는 인간의 추론 방법을 구현하기 때문에 인간의 지능을 표현하기가 매우 쉽고 복잡한 환경에서도 그 성능은 우수하다[1]. 그리고 신경회로망은 인간의 학습능력과 유사하기 때문에 패턴인식과 분류가 우수하다는 것을 여러 논문에서 입증되었다[2].

이런 기능을 바탕으로 어류가공 시스템에 마이크로 컨트롤러(80C196KC)를 이용해서 생선의 종류, 크기등의 가변적인 상황에서도 공정의 안정성과 비선형적인 상황(같은 크기의 생선에서도 아가미부분의 길이가 다를 수가 있는 경우)을 거리와 명암을 판별하는 아날로그식 광량 센서를 사용해서 센서에서 나오는 신호를 A/D 변환하고 신호처리하면서 인공지능 제어기법을 이용한 가공 기계를 연구하였다.

또한 어류의 아가미와 꼬리부분 절단기의 위치를 동시에 마이크로 컨트롤러로 위치제어하고, 컨베이어 모터제어와 어류의 고정과 절단 동작을 시퀀스적으로 구현하였다.

본 논문의 구성을 살펴보면 제 2장에서는 신경망의 개요와 학습 알고리즘과 패턴인식을 위한 신경회로망 모델을 논의하였고, 제 3장에서는 생산가공 시스템에서의 광량 센서에 대한 물체 검출, 신경회로망을 이용한 패턴 분류, 마이크로 컨트롤러 시스템 그리고 DC 서보 모터 제어에 대해 설명하였다. 그리고 제 4장에서는 제시된 시스템의 구조를 기반으로 생선의 아가미와 꼬리 부분을 절단하는 어류 가공 시스템에서 실험하고 그 결과를 고찰하였으며, 제 5장에서는 결론을 제시하였다.

제 2 장 신경회로망

신경회로망은 학습을 통해 지식과 경험을 축적하여 스스로 상황을 판단할 수 있는 인간과 유사한 것을 만들고자 생겨난 인공지능의 한 분야이다.

신경회로망의 발단은 뇌의 생물학적 신경세포와 그들의 연관관계를 단순화시키고 수학적으로 모델링하므로써 뇌가 나타내는 지능적 형태를 구현해 보자고 하는 것이었다. 신경회로망은 개념적으로 매우 단순하며 주어진 입력에 대해 자신의 내부구조를 스스로 조직화하여 학습해 나간다.

신경회로망에 대한 연구는 1943년 맥컬럭(McCulloch)과 피츠(Pitts)에 의해 처음으로 가능성이 제어되었다[2]. 이들은 인간의 두뇌를 수많은 신경세포들로 이루어진 계산기라 생각했다. 그리고 단순한 논리적 임무를 수행하는 모델을 보여주었으며, 패턴분류가 인간의 지능적인 행위를 규명하는데 매우 중요하다는 것을 인식시켰다.

헵(Hebb)은 두 뉴런사이의 웨이트(Weight)를 조정할 수 있는 최초의 학습규칙을 제안하였으며, 이 학습에 관한 연구는 적응 신경회로망의 연구에 많은 영향을 끼쳤다. 1957년 로젠블렛은 퍼셉트론(Perceptron)이라는 신경모델을 발표하므로써 실질적인 신경회로망에 관한 연구가 활성화 되었다.

그후 민스키(Minsky)와 파퍼트(Papert)등이 퍼셉트론 모델을 수학적으로 철저히 분석하여, XOR 함수와 같이 단순한 비선형 문제를 풀 수 없다는 것을 밝혀낸 후 신경회로망에 관한 연구는 20년간 침체기를 맞게 되었다.

그러나 1980년대에 들어서 홉필드(Hopfield), 코호넨(Kohonen), 코스코(Kosko), 파커(Parker)에 의해 신경회로망이 새롭게 발전하게 되었다[3].

오늘날 가장 일반적으로 사용하는 신경회로망의 학습알고리즘인 오류 역전파 알고리즘은 웨보스(Werbos)와 파커(Parker)에 의해 정립되었다.

이런 역사적인 배경으로 발전한 오늘날의 신경회로망은 패턴인식, 음성인식, 제어 시스템, 의료진단, 통신시스템 등 여러 분야에 널리 응용되고 있다.

본 장은 신경회로망들이 본 연구에서 어떤 형태로 이용되는지를 도움 주기 위해 먼저 신경회로망의 구조와 학습알고리즘, 그리고 패턴인식과 예측을 위한 신경회로망 모델을 논의한다.

2.1 신경회로망 모델

신경회로망에 관한 연구는 두뇌와 신경세포 모델에 대한 연구에서 시작되었다. 뇌의 무게는 약 3 파운드를 조금 넘고, 100 140억개의 뉴런이라고 불리는 신경세포로 구성되어 있다.

모든 인간의 행동은 최종적으로 작은 세포들의 활동에 기인하고 뉴런은 다른 뉴런들과 상호 연결되어 있어서 신경회로망이라고 하며, 뉴런들로 조밀하게 서로 상호 연결되어 있다. 이러한 광범위한 상호 연결은 대단히 큰 연산과 기억 능력을 제공해 준다[4][5].

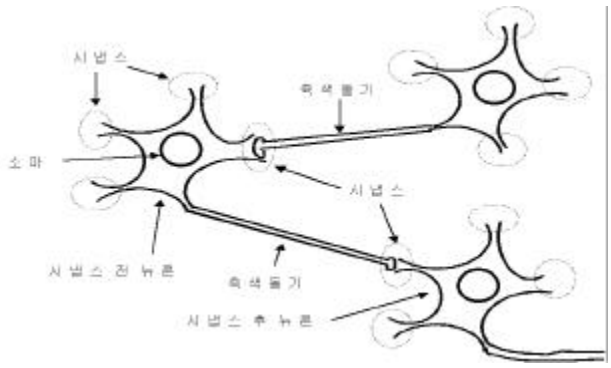

그림 1. 생물학적 뉴런의 구조

뉴런은 중추신경계의 기본 단위이고, 생물학적 뉴런의 개략적인 모습은 그림 1에 나타내었다.

여기서 정보처리의 관점에서 보면 개개의 뉴런은 다른 뉴런으로부터 정보를 받는 수상돌기(Dendrite), 다른 뉴런으로부터 수상돌기가 받는 정보를 수집 및 조합하는 세포체(Soma 또는 Cell Body), 세포체의 결과를 다른 뉴런으로 전달하는 축색돌기(Axon)로 구성되어 있다. 그리고 한 뉴런의 수상돌기와 다른 뉴런의 축색돌기의 연결 지점을 시냅스(Synapse)하며 시냅스는 과거의 축적된 경험이나 지식 등을 기억한다[2].

정보의 처리와 전송은 시냅스 전 뉴런의 활동전위 펄스가 시냅스 후 뉴런의 막전위를 변화시킴으로써 정보가 수상돌기를 통해 세포체로 전달된다. 이때 뉴런은 정보의 값이 뉴런 고유의 한계 값보다 커지면 뉴런은 발화(Fire)되어 다른 신경세포에 자신의 출력을 전달한다. 이러한 뉴런을 인공적인 뉴런으로 모델링(Modelling)하면 그림 2와 같이 된다[5][6].

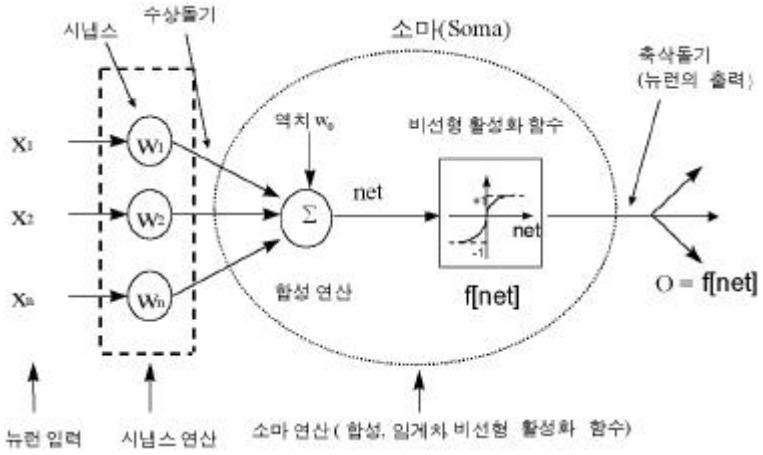

그림 2. 인공적인 뉴런의 구조

생물학적 뉴런의 성질이 복잡하고 다양하기 때문에 그 모델 특성을 요약하기가 어렵다. 뉴런은 다른 뉴런 또는 외부로부터 입력을 받으며 그 입력들의 가중된 합은 그림 2에서 나타낸 비선형 활성화 함수로 입력된다. 그리고 입력들의 가중된 합이 정해진 뉴런의 임계치를 넘었을 때 뉴런이 점화(Firing)되어 다른 뉴런으로 출력된다. 이 뉴런 함수를 수학적으로 표현하면 식(1)과 같다.

$$O = f\left[\sum_{i=1}^{n} w_i x_i - w_0\right] \tag{1}$$

여기서 $x_1, \ldots, x_n$는 뉴런의 입력, $w_1, \ldots, w_n$는 시냅스 가중치, O는 뉴런의 출력, w_0는 임계치(역치), f 는 비선형 활성화 함수이다.

신경회로망에서 많이 사용되는 활성화 함수의 종류로는 그림 3에 나타내었다.

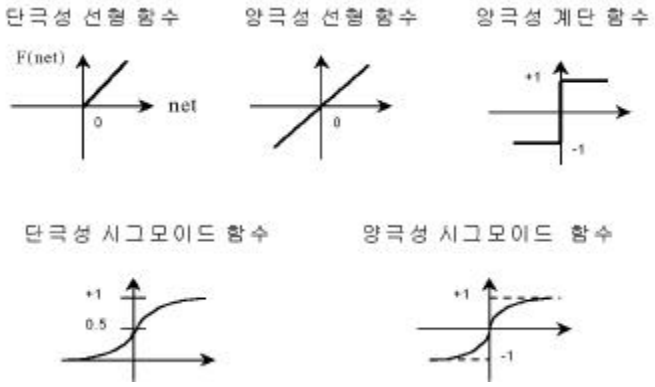

그림 3. 뉴런의 활성화 함수

대표적으로 단극성 선형함수(Unipolar linear function), **양극성 선형함수**(Bipolar linear function), **양극성 계단함수**(Bipolar step function), **단극성 시그모이드 함수**(Unipolar sigmoid function), **양극성 시그모이드 함수**(Bipolar sigmoid function) **등이 있다**[2].

2.2 다층 신경회로망의 구조와 학습

인간의 뇌는 수많은 뉴런으로 서로 연결되어 있다. 따라서 인간의 뇌와 유사한 인공적인 신경회로망은 다층 구조라 할 수 있고 , 서로 연결된 뉴런에 의해서 더욱 더 좋은 성능으로 수행할 수 있다. 일반적으로 더욱 큰 망은 큰 연산 용량을 제공한다. 뉴런을 층에 배열하는 것은 뇌의 일부분인 계층화된 구조를 흉내낸 것이다.

패턴 인식과 시스템 인식, 또는 제어와 같은 응용에서 가장 일반적으로 사용되는 신경회로망 구조는 오류 역전파(Error Back-Propagation) **알고리즘을 갖는 다층 신경회로망**(Multi layered

neural network)이다. 전형적인 다층 신경회로망은 그림 4에 나타내었다[7][8].

그림 4에서 각각의 원은 그림 2에서 보여준 뉴런이다. 이 신경회로망은 x라는 입력 벡터를 갖는 입력층과 y라는 출력 벡터를 갖는 출력층으로 이루어지며 입력층과 출력층 사이의 층을 우리는 보통 은닉층(Hidden layer)이라 한다.

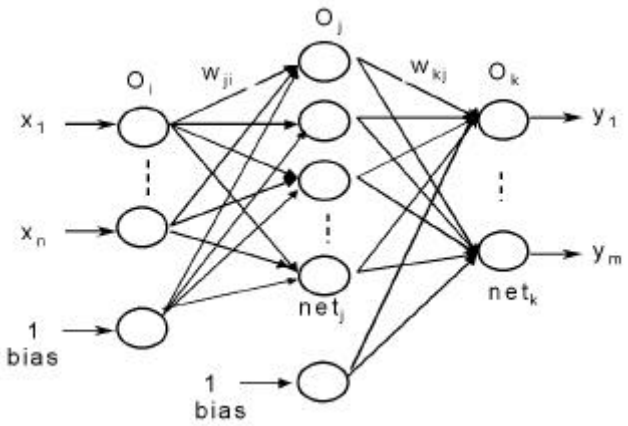

그림 4. 다층 신경회로망의 구조

그림 4에서 O_i, O_j, O_k는 입력층, 은닉층, 출력층들의 각 뉴런 출력이고, 입력층과 은닉층 사이의 웨이트를 W_{ji}, 은닉층과 출력층 사이의 웨이트를 W_{kj}로 표기한다. 모든 정보는 신경회로망의 웨이트에 저장되며, 학습과정 동안 웨이트 W_{ji}, W_{kj}의 성분은 계속적으로 새로운 정보로 바뀌어 진다. 일반적으로 새로운 정보를 변경하는 신경회로망의 대표적인 알고리즘은 오류 역전파 알고리즘이다.

오류 역전파 알고리즘은 신경회로망의 각 뉴런에 의해 계산된 최종 출력층 뉴런의 출력과 바라는 출력사이의 오차를 자승하여 최소화시키는 최소-평균 자승법(Least-mean square)이다[9].

오류 역전파 학습 알고리즘의 원리는 먼저 입력층에서는 신경회로망의 입력 x를 은닉층으로 보낸다. 두번째로 은닉층의 뉴런들은 각각의 입력층으로부터 입력된 값과 웨이트들의 곱을 합산함과 동시에 활성화 함수를 통해 연산된 결과를 출력층으로 보낸다.
출력층은 은닉층과 같은 뉴런 연산을 하여 출력한다. 이때 신경회로망의 출력값이 바라는 목표값과의 차이를 구하며, 이 차를 오차라고 말한다.

이 오차를 최소화 하기 위해 각 층에 있는 웨이트의 오차 벡터 항을 편미분하여 웨이트를 조정한다. 다시 말해 출력층의 출력과 바라는 목표치의 오차를 연산한 후 출력층에서 은닉층으로, 은닉층에서 입력층으로 역전파하여 오차에 따른 웨이트 변화량에 의해 웨이트들을 조정하며 이것을 오류 역전파라고 말한다[7].

오류 역전파 학습 알고리즘을 수식적으로 나타내면 다음과 같다.
먼저 입력층, 은닉층, 출력충의 뉴런 출력은 식(3), 식(5), 식(7)과 같다.

$$net_i = x_i \quad (i = 1, 2, 3, \ldots, n) \tag{2}$$

$$O_i = \lambda f \ [net_i] \tag{3}$$

$$net_j = \sum_j W_{ji} O_i \tag{4}$$

$$O_j = \lambda f \ [net_j] \tag{5}$$

$$net_k = \sum_k W_{kj} O_j \tag{6}$$

$$O_k = \lambda f \ [net_k] \tag{7}$$

여기서 사용한 f 는 활성화 함수이며, net_i, net_j, net_k는 이전의 뉴런 출력과 현재 층에 있는 웨이트들과의 곱을 합산한 값이고 λ는

활성화 함수의 기울기이다. 신경회로망을 학습시키기 위해 신경회로망의 출력값이 바라는 목표값과의 차인 오차를 구해야 하며 이 오차를 구하는 수식은 식(8)에 나타내었다.

$$E = \frac{1}{2}\sum_{k}(D_k - O_k)^2 \tag{8}$$

학습의 목적은 웨이트를 조정하여 오차 E를 최소화하는 것이므로 웨이트의 조정에 대하여 살펴보면 오차를 최소화하기 위해 웨이트를 음의 경사방향(Negative gradient direction)으로 변화시켜 한다. 따라서 웨이트 변화를 음의 경사 방향으로 오차에 대한 웨이트의 방향 벡터를 편미분함으로써 웨이트 변화량을 구할 수 있다. 각 층에 있는 웨이트 변화량을 구하면 다음과 같다.

$$\Delta W_{kj} = -\eta\frac{\partial E}{\partial W_{kj}}, \qquad \eta > 0 \tag{9}$$

여기서 η는 학습 속도를 나타내는 상수이며 이것을 학습률이라 한다. 그리고 식(9)을 연쇄 규칙(Chain rule)을 사용하여 아래와 같이 간단하게 쓸 수 있다.

$$\frac{\partial E}{\partial W_{kj}} = \frac{\partial E}{\partial O_k}\frac{\partial O_k}{\partial net_k}\frac{\partial net_k}{\partial W_{kj}}$$

$$= \frac{\partial \frac{1}{2}\sum_{k}(D_k - O_k)^2}{\partial O_k}\frac{\partial \lambda f[net_k]}{\partial net_k}\frac{\partial \sum_{k} W_{kj}O_j}{\partial W_{kj}} \tag{10}$$

여기서, 활성화 함수 f 가 선형함수라고 가정하면, 웨이트 변화량 ΔW_{kj}는 다음의 식과 같다.

$$\triangle W_{kj} = \eta (D_k - O_k) O_j \tag{11}$$

은닉층에 대한 웨이트의 변화량도 오차를 최소화하기 위해 웨이트를 음의 경사 방향(negative gradient direction)**으로 변화시켜 준다.**

$$\triangle W_{ji} = - \eta \frac{\partial E}{\partial W_{ji}}, \qquad \eta > 0 \tag{12}$$

식(12)**을 연쇄 규칙**(chain rule)**을 사용하여 아래와 같이 간단하게 쓸 수 있다.**

$$\frac{\partial E}{\partial W_{ji}} = \frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial net_k} \frac{\partial net_k}{\partial O_j} \frac{\partial O_j}{\partial W_{ji}}$$

$$= \frac{\partial \frac{1}{2} \sum_k (D_k - O_k)^2}{\partial O_k} \frac{\partial \lambda f [net_k]}{\partial net_k} \frac{\partial \sum_k W_{kj} O_j}{\partial O_j} \frac{\partial \lambda W_{ji} O_i}{\partial W_{ji}} \tag{13}$$

식(13)**에 의해 입력층과 은닉층사이에 있는 웨이트의 변화량은 다음의 식으로 나타내어진다.**

$$\triangle W_{ji} = \eta (D_k - O_k) W_{ki} O_i \tag{14}$$

따라서 웨이트의 변화는 다음과 같다.

$$W_{ji} = W_{ji} + \triangle W_{ji} \tag{15}$$

$$W_{kj} = W_{kj} + \triangle W_{kj} \tag{16}$$

지금까지 설명했듯이, 오류 역전파 알고리즘은 오차 신호를 계산하고 신경회로망의 웨이트들을 조정하기 위해서는 바라는 응답값이 필요하다. 이러한 초기의 학습 후에 신경회로망은 학습에 사용되지 않은 새로

운 데이터의 집합을 입력할 수 있다.

학습된 데이터의 집합이 아닌 데이터를 갖는 망의 정확성은 신경회로망에 일반화 능력을 부여한다. 그리고 이것은 곧 신경회로망의 신뢰도를 가리킨다. 학습과 검사단계 후에, 신경회로망은 패턴 분류기, 또는 잘 모르는 비선형 함수와 복잡한 처리를 모델화하는데 사용될 수 있다[10].

신경회로망을 학습시킬 때 초기 웨이트는 작은 무작위 값으로 설정하고 이런 초기화는 최종 출력에 영향을 미치므로 보통 일반적으로 초기 웨이트는 -0.5에서 0.5사이의 값을 주로 사용한다. 그리고 오류 역전파 알고리즘의 수렴 정도는 학습률에 의해서도 달라질 수 있다. 학습률은 신경회로망의 구조와 응용 목적에 따라 각각 달리 선택되고 일정한 기준이 없으며 보통 0에서 1사이의 값을 사용한다. 만약 큰 학습률을 사용하면 오버슈트가 일어날 수 있고 작은 학습률을 사용하면 학습속도가 느려질 수 있으므로 위에서 제시한 범위 내에서 적절히 선택해야한다.

2.3 모멘텀 항 연산

모멘텀 방법은 오류 역전파 알고리즘에서 수렴 속도의 향상과 지역 최소점으로 빠지는 걸 막기 위한 목적으로 사용한다.
여기서 식(12)에서 가장 최근의 웨이트 변화량을 추가시킨 것이 모멘텀 방법이고, 추가시킨 항을 모멘텀 항이라 하고, 아래와 같이 표현되어진다.

$$\Delta w(t) = -\eta \Delta E(t) + \alpha \Delta w(t-1) \quad (17)$$

또, 상수 α를 모멘텀 상수라고 한다. 보통 모멘텀 상수는 0.1에서 0.8의 값으로 사용한다. 모멘텀 방법을 사용한 N 스텝 전체의 웨이트 변화량은 아래 식과 같다.

$$\Delta w(t) = -\eta \sum_{n=0}^{N} \alpha^n \Delta E(t-n) \quad (18)$$

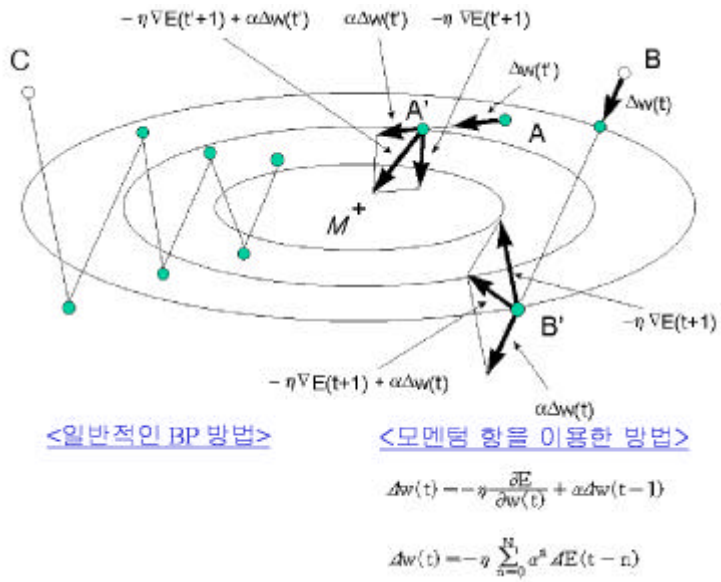

그림 5. 오류역전파 방법과 모멘텀 항 추가한 방법

그림 5의 A 에서 경사 하강법이 시작된다고 할 때, A 에서는 (-) 방향으로 웨이트가 변화하지만 A' 에서는 반대 방향인 (+) 방향으로 향한다. 이것은 이전의 A 의 (-) 웨이트 변화량을 모멘텀 항으로 추가하면 이러한 오버슈트를 줄이게 되어 학습의 신뢰도를 향상시킨다[11].

반면, 왼쪽 그림의 C 파형은 일반적인 오류역전파 방법으로 최소지점 M을 지나치는 오버슈트가 발생하게 된다.

3. 자동화 가공 시스템

메카트로닉스 시대의 기술 중에서 가장 두드러진 특징이라면 자동화 시스템을 들지 않을 수 없듯이 이는 어떤 형태든 계측을 전제로 하지 않으면 안 된다.

생산 공정에 있어서 자동화(FA)는 그 과정에서의 물리적 또는 화학적인 계량이 요구에 맞게 계측되어지고, 이것을 제어 기능과 연결시키면서 동시에 액추에이터 기능과 연결시킴으로써 가능하게 된다[12].

따라서 본 장에선 생산 가공 시스템에서의 센서 기술과 인공 지능형 제어 기술, DC 서보 모터제어 기술, 프로세서 기술에 대해 논의 한다.

3.1 광량 센서에 의한 물체 검출과 신경망을 이용한 패턴 분류

센서는 오래전부터 제어 기기의 검출부로서 이용되어 왔지만 최근엔 소형으로서 고성능인 센서가 다종 개발되어 각종 산업이나 민생 응용에서 부터 마이컴에 이르기까지 광범위하게 이용되고 있다.

본 연구에서는 아날로그식 적외선 센서를 사용함으로써 물체의 윤곽과 특징점을 추출하여 신호 처리한 후에, 인간의 학습 능력과 유사한 신경회로망 제어 기법으로 패턴 분류하고자 한다[13].

적외선 센서에는 수광부에서 나오는 신호가 아날로그식과 디지털식이 있는데, 그림 6은 ON/OFF 디지털 방식과 아날로그 광량 방식의 구성을 비교 설명하였다.

(a) ON/OFF 디지털 방식 (b) 아날로그 광량 방식

그림 6. 센서의 디지털 방식과 아날로그 방식

신호 검출은 물체에서 반사되는 빛의 양(아날로그)을 측정하여 물체의 윤곽과 특징점을 측정하는 방법으로, 마이크로 컨트롤러를 사용하여 아날로그의 신호를 A/D 변환한다.

이렇게 신호를 받은 여러 물체들의 윤곽이나 특징점들을 마이크로프로세서에서 판별하게 된다.

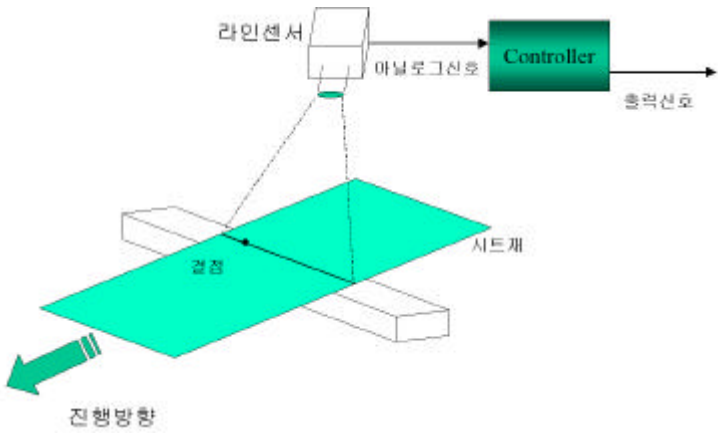

그림 7. 결점 검사 시스템

이러한 구조로 생산 가공 시스템에서 활용되고 있으며, 그림 7은 산업 공정에서 라인 센서를 이용한 결점 검사 시스템 구조이다[14].

3.2 마이크로 컨트롤러 시스템

제어 응용 시스템에 마이크로 컨트롤러를 사용하게 되면 다음과 같은 장점이 있다.

① 소형 경량화.

시스템의 컨트롤러 부분이 마이크로 컨트롤러 LSI(Large-Scale Integrated Circuit) 1개와 극히 소수의 외부 소자들로 간단히 구성됨으로 컴퓨터 사용에 비해 크기와 무게가 현저히 줄어들고 소비 전력도 적어진다.

② 낮은 가격.

컨트롤러 부분이 단순화됨에 따라 부품비, 제작비, 개발비가 감소되고 개발 시간도 단축된다.

③ 신뢰성의 향상.

컨트롤러가 단순화되어 부품수가 적어지고 신뢰도가 높은 소자를 사용하므로 고장률이 감소되며 Chip 교체 만으로 유지 보수가 용이해진다.

④ 융통성.

하드웨어에 의존하는 부분을 소프트웨어로 처리할 수 있게 됨으로 기능의 변경이나 확장에 보다 유연하게 대응 할 수 있다.

80C196KC를 사용하여 모터 2개의 위치 제어와 A/D 변환할 수 있는 제어 응용 시스템을 구현하고자 한다. 그림 8은 제어응용 시스템에서 마이크로 컨트롤러의 블록도이다.

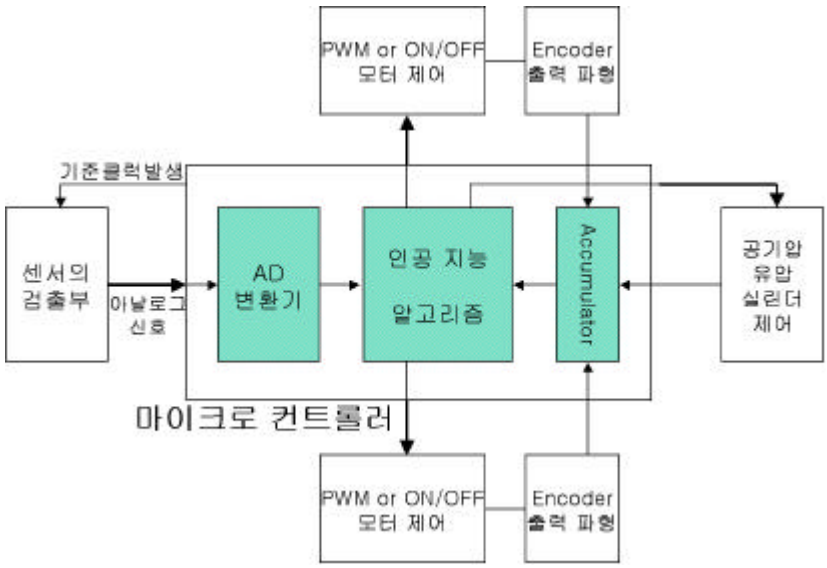

그림 8. 제어응용 시스템에서의 마이크로 컨트롤러 블록도

3.3 DC 서보 모터 제어

이동 로봇이나 매니퓰레이터(Manipulator)등의 산업용 가공 시스템에는 움직임을 발생시키는 액추에이터(Actuator)가 반드시 필요하다.

외부환경을 인식하는 부분이 센서라면 일을 하는 부분이 바로 액추에이터로써, 소형및 경량이고 토크등의 출력이 커야하고 에너지 효율도 좋고 제어하기 쉬워야 한다[15].

현재 가공 시스템에 사용되는 엑추에이터는 공기압이나 유압등을 이용한 실린더 방식이나 모터 등을 이용하는 방식이 대부분이다. 여기서는 DC 서보 모터제어 방법에 대해 설명한다[15][16].

DC 모터를 사용하려면 폐루프 제어(Closed loop control)를 해야 한

다.

페루프 제어란, 엔코터 등을 모터 회전축에 부착하여 속도와 위치 정보를 알아내서 속도나 위치 제어 알고리즘 등이 지령 값과 실제 값의 차이를 없애면서 모터를 움직이도록 제어하는데, 이러한 제어를 할 수 있는 모터를 서보 모터라 한다[17][18].

그림 9는 DC 모터 제어 시스템 구성도이다.

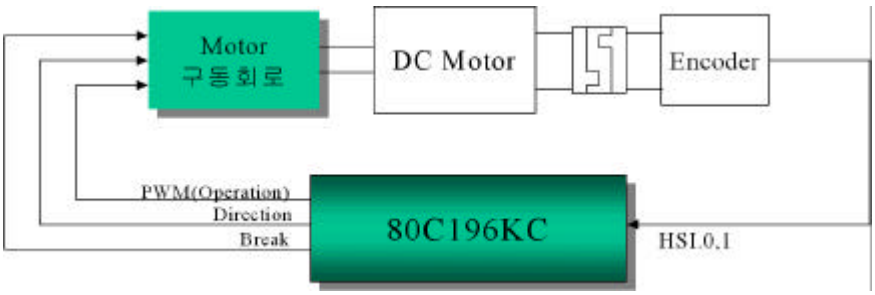

그림 9. DC 모터 제어 시스템 구성도

DC 모터를 사용하여 제어를 하는 경우, DC 모터의 등가회로를 고려해야 한다. 그 이유는 등가회로를 알면 모터의 특성을 알 수 있어 그 뒤의 회로설계가 용이하게 되기 때문이다. 그림 10(a)는 모터와 전원을 접속한 회로의 예이다. 이것을 등가회로로 치환하면 그림 10(b)와 같이 된다.

여기에서 그림 10(b)는 아래와 같은 관계식이 성립된다.

$$E_b = R_a \cdot I_a + V_B + E_c \qquad (19)$$

E_b ; 전원전압[V]

R_a ; 전기자 내부저항[Ω]

I_a ; 모터 전류[A]

V_B ; 브러시-커뮤테이터간의 접촉 전압[V]

E_c ; 모터의 유도전압[V]

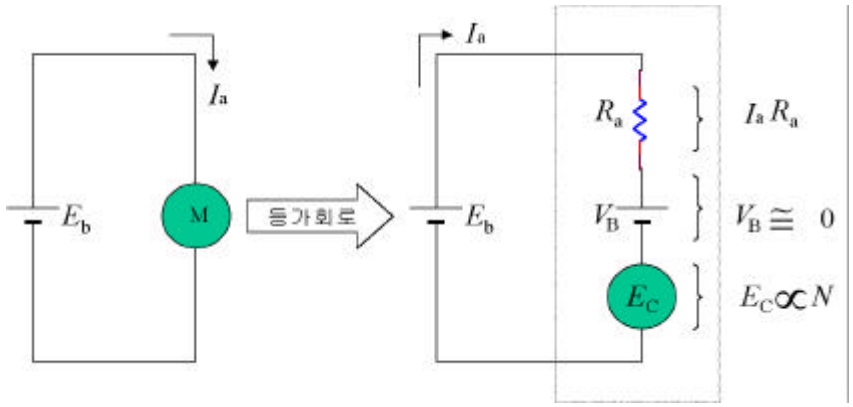

(a) 전원과 접속했을 경우 (b) 등가 회로

그림 10. DC 모터의 등가회로

또한 브러시-커뮤테이터간에 발생하는 접촉 전압 V_B는 $E_b \gg V_B$, $E_c \gg V_B$여서, 이것을 무시하면 식 (20)과 같이 된다.

$$E_b = R_a \cdot I_a + E_c \tag{20}$$

따라서 DC 모터는 일정한 회전수로 회전하고 있는 경우. 그림 11과 같은 등가회로로 표현할 수 있다. 이것들의 관계에서 그림 12와 같은 DC 모터의 특성이 얻어진다.

그림 12에서 $T-N$ 커브는 반비례 관계로 토크가 크면 클수록 회전수가 낮아지고, $T-I$ 커브는 토크가 클수록 모터 전류는 높아진다. 그래서 회전수를 빨리 하면서 토크를 높이려면 큰 회전수를 가진 모터

선정과 모터 축앞에 기어 박스를 달므로 인해 토크와 회전수의 반비례적인 관계를 극복해야 한다.

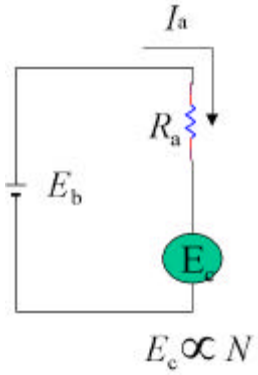

그림 11. 정상상태 등가회로

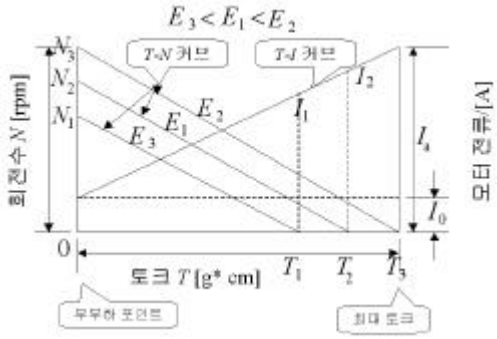

그림 12. DC 모터의 T-N / T-I 특성

본 연구에서도 DC 모터 3개를 사용하는데, 2개의 모터에는 1/2의 기어 박스를 달고, 큰 힘을 발휘해야 하는 컨베이어 모터에는 1/100의 기어 박스를 장착해서 시스템의 성능에 부합시켰다.

4. 실험 결과 및 분석

본 장에서는 3장에서 언급한 기능들을 어류가공시스템에 적용해 생선의 종류, 크기 등의 가변적인 상황을 수용하면서도 공정의 안정성과 유연성이 뛰어난 어류가공기계에 적용하여 실험하였다. 이를 위해 원양해협에서 잡히는 명태를 표본으로하여, 기계식 어류가공 시스템의 일률적인 동작과 노동 집약적인 수작업의 가공을 사용자와 관리자 측면에서 보다 편리하게 사용함에 목적을 두었으며, 정확하게 어류의 절단 위치를 검출해서 아가미와 꼬리 부분을 제거하는데 촛점을 두었다.

4.1 전체적인 시스템

시스템의 주 제어기인 내장형 제어기, 센서 회로, 절단 위치로 이동하는 모터, 컨베이어 모터를 제어하면서 고정과 절단 동작을 시퀀스적으로 동작을 수행하는 회로를 부록 그림 1, 2, 3, 4, 5에 나타내었다.

부록 그림 6은 가공 시스템의 정면도를 나타내고 있고, 부록 그림 7은 시스템의 검출부인 센서의 외형, 마이크로 컨트롤러(80C196KC), 주변 회로 및 아날로그 센서 회로의 실험 장치와 2개의 절단기 위치제어 모터이다. 왼쪽것은 꼬리부분을 절단하는 실린더를 이동시키는 모터이고, 오른쪽것은 아가미부분을 절단하는 실린더를 이동시킬 모터이다.

그림 13은 전체 하드웨어 구성도로써 내장형 제어기(80C196KC)를 기준으로 주변 장치들을 나타낸 것이다.

먼저, 광량센서에서 나오는 아날로그 신호를 CPU 자체내의 A/D 변

환기능으로 처리해서 이 데이터를 임시 저장 레지스터에 저장한다. 그래서 데이터를 신호처리 한 후에 신경망 학습에 의한 아가미의 절단 부분을 찾아서 위치 제어 모터를 움직이고, 컨베이어 모터를 정지시킨 후에 어류 고정, 절단 동작한 후 컨베이어 모터를 움직이면 1사이클의 동작이 끝나게 된다.

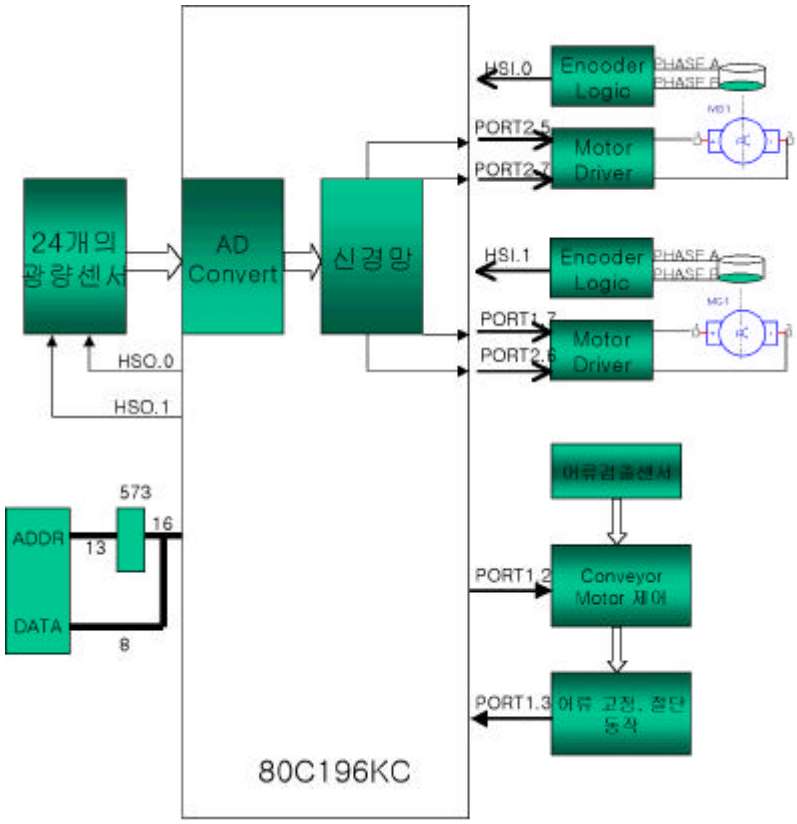

그림 13. 전체 하드웨어 구성도

그림 14는 절단기의 기본 구조를 그린 것으로 어류를 타겟 접시에 올려놓고, 컨베이어가 진행하면서 광량센서에 의해 아가미 부분의 윤곽

을 받아 절단위치로 칼날을 이동시킨다. 이 때 어류검출센서로 신호가 들어오면 컨베이어는 정지하고 V자형 칼날과, 一자형 칼날이 공기압에 의해 위에서 밑으로 내려 치는 동작을 한다.

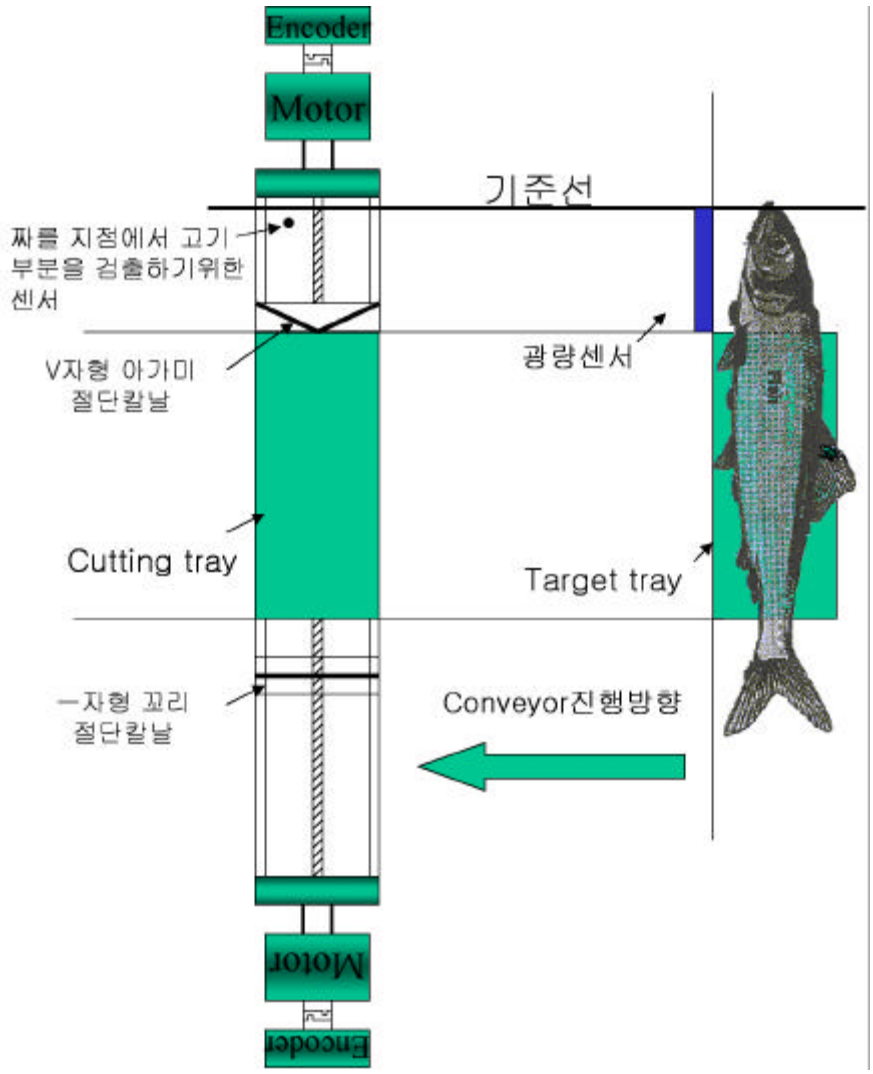

그림 14. 절단기 기본 구조도

시스템의 구성요소로는 센서요소, 입력요소, 출력요소, 동작요소가 있으며, 그림 15에 제시하였다.

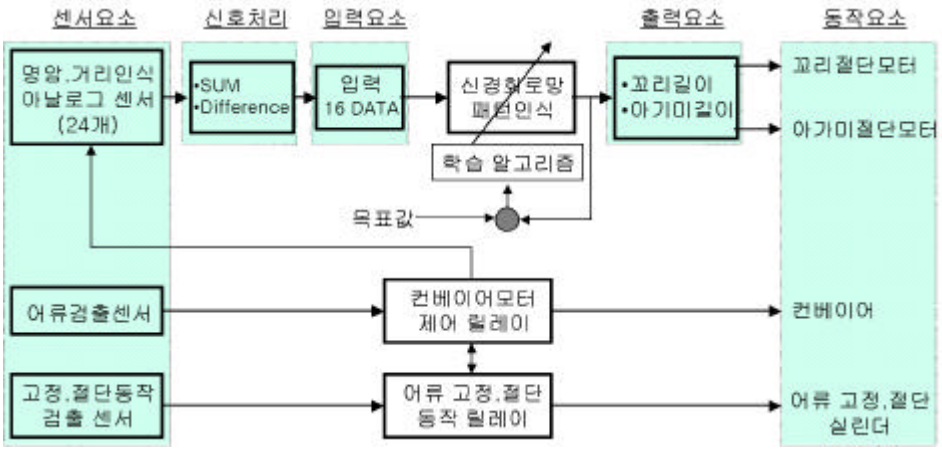

그림 15. 가공 시스템의 구성요소

4.2 센서 회로

일반적으로 빛과 물질사이에는 물리적 상호작용이 있다. 물질이 광자(광 에너지)를 흡수하고 전자를 방출하는 현상을 광전효과라 한다. 이 결과 반도체 접합부에 전압이 나타나는 현상을 광기전력효과라고 한다. 광 센서는 이러한 광기전력을 이용한 것으로 빛을 받아서 그것을 전기적 신호로 바꾸는 일종의 변환기이다.

점등 방식으론 스태틱 점등(Static drive)과 펄스 점등(Pulse drive)이 있는데, 스태틱 구동은 송신부쪽에서 일정한 전류(정격을 넘지 않는)를 계속 흘려 수신부에서 읽는 가장 간단한 방법이지만 송신부의 전류가 약해서 잘 쓰이지 않는다.

펄스 구동 방식은 일정한 펄스를 송신부에 입력시켜 송신부의 출력을 높게 해서 비교적 외란광의 영향을 줄이는 방법이다.

본 연구에서는 마이크로 프로세서에서 펄스를 구동시켜 센서와 동기화하여 데이터 값을 가져온다. 그림 16은 광량 센서 펄스 구동방식에 대해 묘사했다.

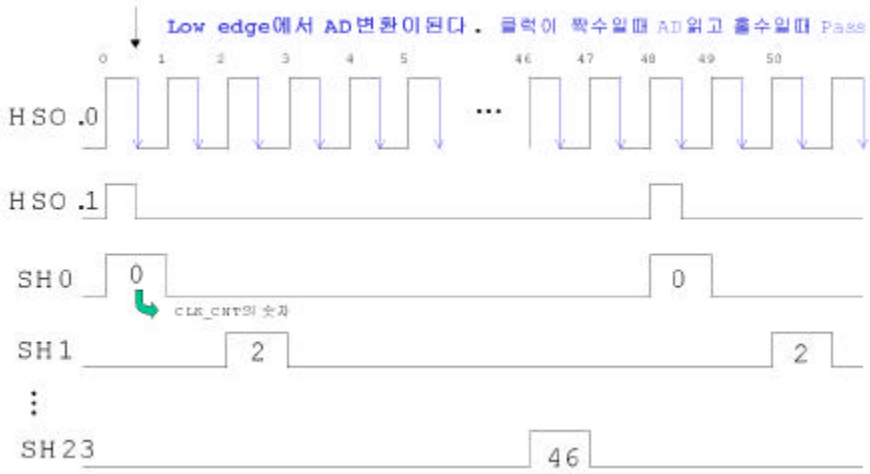

그림 16. 광량 센서 펄스 구동 방식

80C196KC는 HSO.0 핀으로 계속해서 shift register chip(74HC164)에 기준 펄스를 만들고 HSO.1 핀으론 HSO.0이 48번 클럭이 생성될때마다 한번씩 클럭을 생성한다. 그러면 shift register(74HC164)에선 SH0~SH23과 같은 파형이 생성되어 각각의 광량 센서에 흘러 센싱을 하게 된다.

80C196KC에서 A/D 변환하는 시기는 HSO.0의 클럭이 짝수 번째의 Low edge에서 A/D 변환한다.

각각의 수광부 센서에서 나오는 아날로그 신호를 A/D 변환해서 80C196KC의 임시 레지스터 D000H에서부터 차곡차곡 저장한다.

다음 그림들은 아날로그 광량센서를 구동시킬 펄스와 수광 센서에서 나오는 출력 펄스들이다. 그림 17은 센서 드라이브단의 실질적인 입력 펄스인 shift register의 기준 클럭(HSO.0)과 shift register로 들어가는 첫 번째 클럭(HSO.1)의 파형이고, 그림 18은 위에서부터 HSO.1과 수광 센서로 들어가는 펄스인 shift register 0(SH0), SH1, 마지막 클럭 SH23의 클럭이다. 그림 19와 그림 20은 물체가 있을 때와 없을 때의 수광센서에서 나오는 아날로그 파형과 발광센서로 들어가는 파형을 비교하였다. 물체가 없을 때의 수광 센서의 출력 전압은 0.5V의 offset 전압이 뜨고, 물체가 있을 때의 수광 센서의 출력 전압은 2.5V의 전압이 나타나 현격한 차이를 보였다.

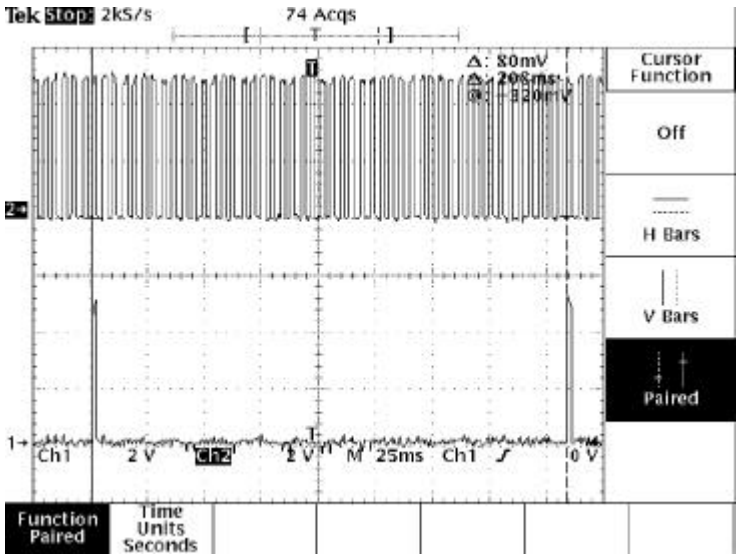

그림 17. Shift Register의 기준 클럭(HSO.0)과 HSO.1 신호

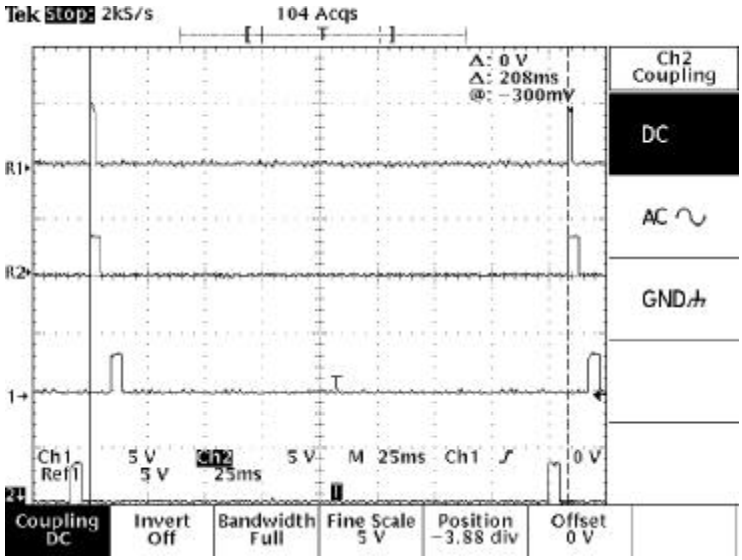

그림 18. HSO.1, SH0(shift register 0), SH1, SH23 **신호**

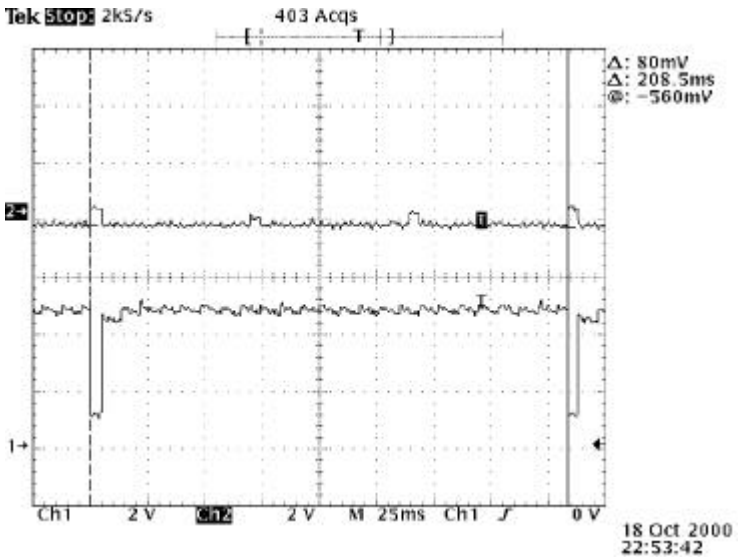

그림 19. **물체가 없을 때의 수광 신호와 발광 신호**

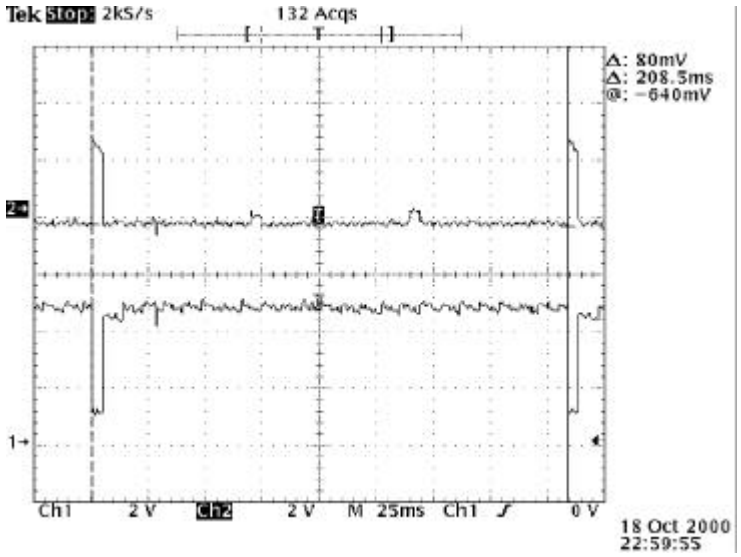

그림 20. 물체가 있을 때의 수광 신호와 발광 신호

그림 21은 80C196KC와 센서부의 인터페이스 구조에 대한 그림이다.

아날로그 광량센서는 아가미의 윤곽과 지느러미의 특징점을 추출하는 장치로서, 카메라로 받는 데이터 보다는 정확도가 떨어지지만, 24개의 센서값들을 컨베이어 모터가 움직이면서 32번 스캔하는 방식으로 어류의 아가미 부분을 검출한다.

그리고 센서의 감도가 달라질수 있으므로 가변 저항기(10kΩ)의 설치로 어느 정도 감도를 조절하였다.

이러한 방법으로 받은 센서의 데이터를 신호 처리해서 분석한 결과 일정한 파형을 얻을 수 있었다.

그림 22는 센서에서 받은 데이터와 신호 처리해서 분석한 그래프이다. 그림 22(a)는 실질적인 명태를 컨베이어에 올려 놓고 아날로그 광량 센서로 스캔한 데이터를 Matlab으로 구현했고, 그림 22(b)는 24개 각각의 센서에서 받은 데이터를 합해서 100으로 나눈 값을 (a)와 같이

Matlab으로 구현했고 식(21)과 같다. 그림 22(c)는 더해서 100을 나눈 값들을 각각 편차를 구해 그래프로 나타냈고 식(22)와 같다.

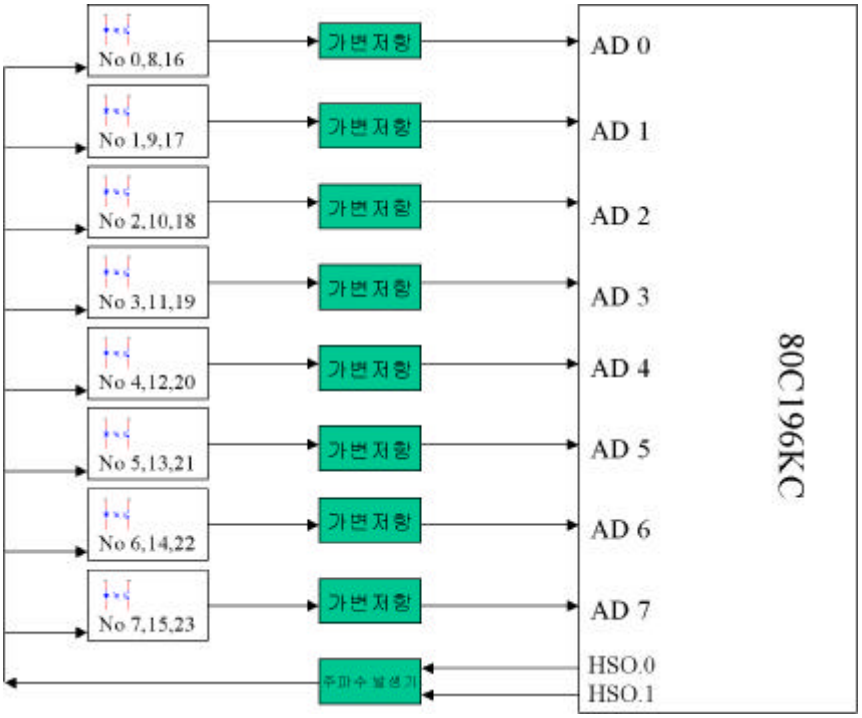

그림 21 마이크로 프로세서와 센서와의 인터페이스

$$S(j) = \frac{\sum_{i=1}^{32} R_j(i)}{100},\ j = 0,1,2,\cdots,23 \qquad (21)$$

$$D(j) = S(j+1) - S(j),\ j = 0,1,2,\cdots,22 \qquad (22)$$

$R_j(i)$; j번째 센서가 i번 스캔한 아날로그 데이터 값

$S(j)$; j번째 센서의 32번 스캔한 값을 더한 값

$D(j)$; $S(j)$ 값의 편차값

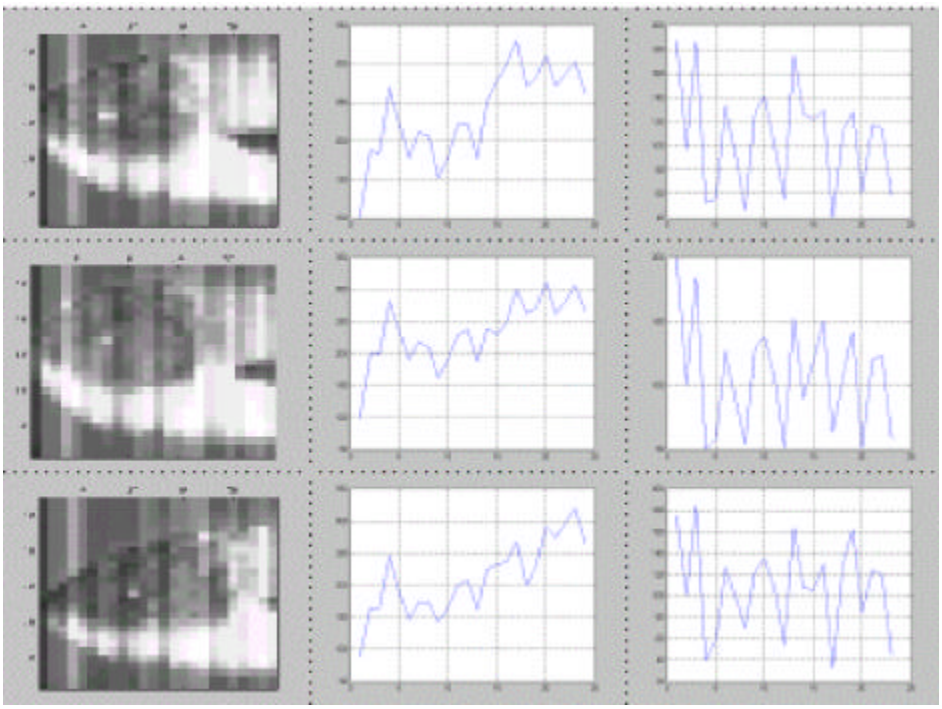

(a) 어류의 윤곽 (b) 각 센서를 더한 후 스케일 (c) 편차=U(k+1)-U(k)

그림 22 센서에서 받은 데이터

신호 처리한 23개의 값에서 16개의 데이터($D(7) \sim D(22)$)값을 신경회로망의 입력으로 설정하며, Off-line 상에서 8마리 각각의 명태를 입력 패턴으로 설정해서 학습시켜 최적의 웨이트 값을 얻었다.

은닉층은 10, 학습률은 0.6 이고, 활성화 함수는 기울기가 0.0006인 선형 함수를 사용하였으며, 학습은 에러율이 0.0001밑으로 내려 갈 때까지 계속하였다.

그림 23은 아가미의 패턴을 받아 마이크로 컨트롤러에서 학습시킨 신경망 구조이다.

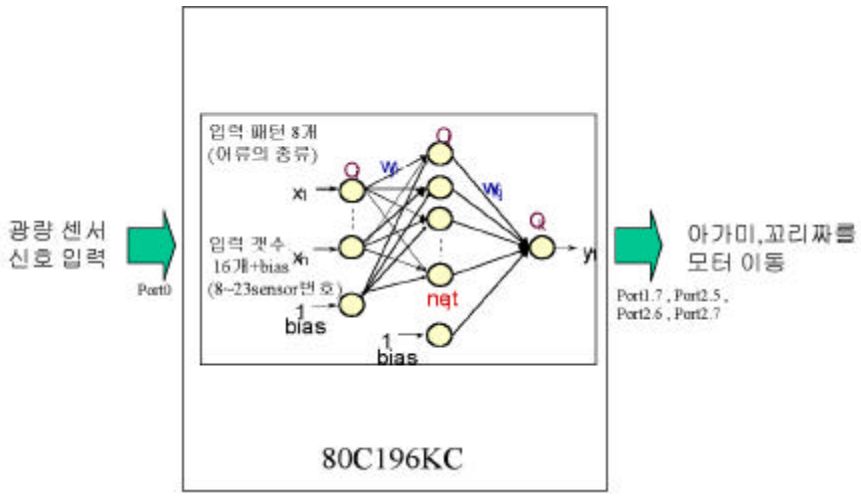

그림 23. 마이크로 컨트롤러에서 학습시킨 신경망 구조

그림 24는 일반적인 신경망으로 학습시켰을 때의 에러율을 그래프로 나타낸 그림이고, 그림 25는 모멘텀 항을 사용한 에러율의 그래프로써 수렴속도가 빠르게 도달되는 것을 볼수가 있다.

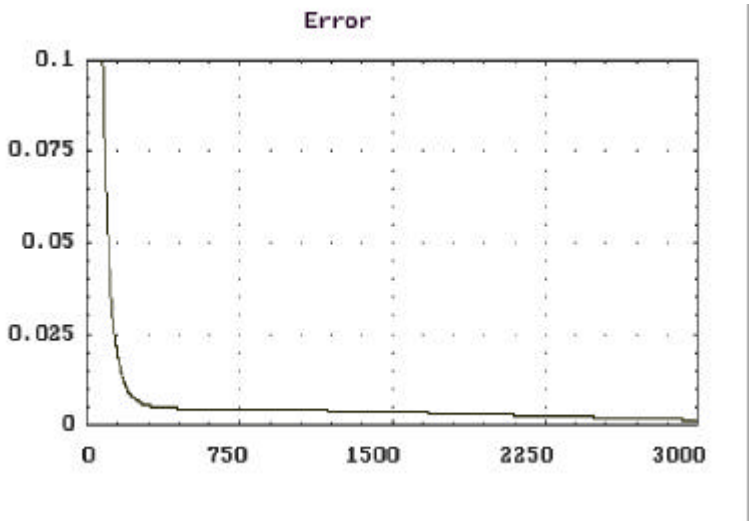

그림 24. Off-line 상에서의 일반적인 BP 학습 그래프

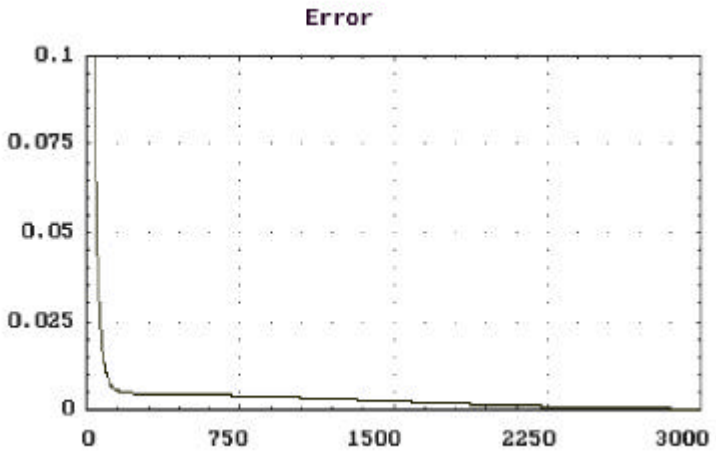

그림 25. 모멘텀 항을 사용한 BP 학습 그래프

이렇게 구한 최적의 웨이트값들을 마이크로 컨트롤러 변수에 대입시켜, 실질적인 물체(생선)의 특징점과 윤곽의 데이터들이 들어오면 절단될 아가미와 꼬리부분의 절단 모터에 신호를 전송한다.

4.3 마이크로 컨트롤러를 사용한 모터 위치 제어

센서에서 받은 데이터를 계측해서, 제어 기능과 연결시키면서 동시에 액추에이터 기능을 연결시키면 자동화 기능의 기본적인 구조라 할 수 있다. 이런 일들은 단순하면서 개발비가 저렴한 마이크로 컨트롤러와 폐루프 제어를 할 수 있는 DC 서보 모터의 이용으로 구현할 수 있다[14].

마이크로 컨트롤러는 INTEL社의 80C196KC를 사용했으며, 자동화 생산 가공 시스템의 기능에 대해 설명하면 다음과 같다.

① 샘플/홀드 기능을 포함한 8 또는 10비트의 A/D 변환기를 8채널

② 인터럽트와 연계된 고속 입출력(HSI,HSO) 기능

HSI 기능 ; 엔코더가 부착된 모터 2개의 펄스를 동시에 인터럽트 사용으로 카운팅

HSO 기능; 인터럽트 사용으로 아날로그 센서에 기준 클럭 발생

③ 외부 어드레스 버스가 16개로써 최대 64KB의 메모리 용량

④ 5개의 8비트 I/O 포트중에 2개(포트 1, 포트 2)는 2개의 위치제어 모터의 동작, 방향, 기준선의 판별 제어와 컨베이어 모터 제어 사용

이와 같은 기능을 어셈블리 언어로 구현했으며, A/D 변환 기능과 모터 2개의 엔코더에서 나오는 클럭을 카운팅하는 기능은 80C196KC의 인터럽터 기능인 A/D 변환 완료과 HSI 데이터 셋 인터럽터를 사용해서 구현하였다.

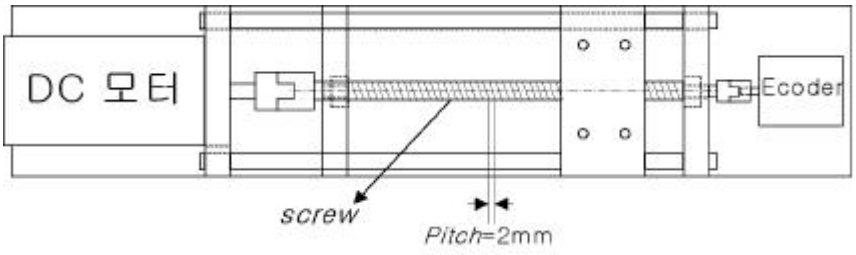

그림 26. 위치제어 모터의 평면도

그림 26은 위치제어 모터의 평면도로, 피치(screw가 한바퀴 돌았을 때의 거리 : pitch)가 2mm이므로 모터가 한바퀴 돌 때 2mm 움직이면서 엔코더에서 나오는 펄스의 수는 25펄스 나오게 된다. 만약 20mm 가고자 한다면 DC 모터에 전원을 인가한 후 엔코더에서 나오는 펄스의 수가 250펄스 카운팅이 되면 모터를 정지하는 식으로 위치를 제어하였다.

4.4 컨베이어 제어와 시퀀스 동작

그림 27은 컨베이어 모터의 제어와 고정과 절단 동작을 순서도로 나타내었다.

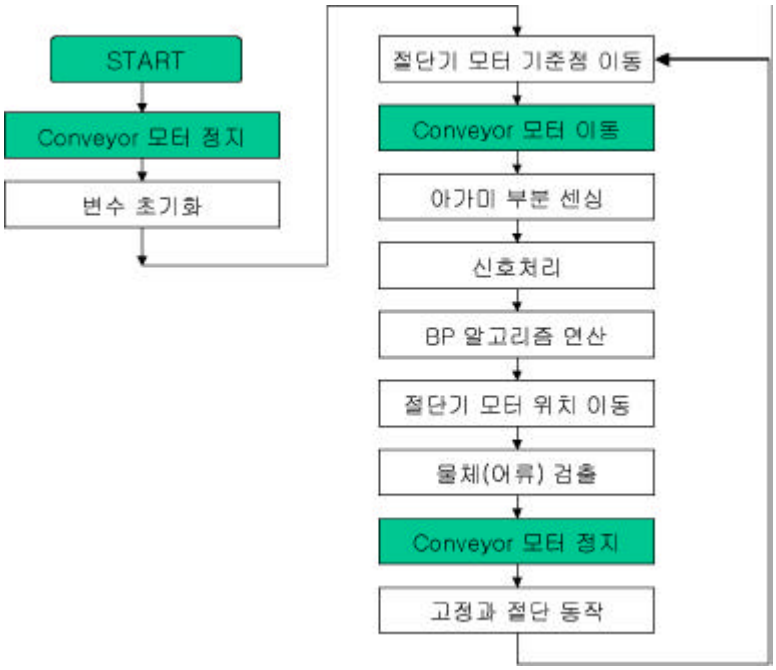

그림 27. 컨베이어 모터제어와 고정과 절단 순서도

고정과 절단 동작은 공기압으로 동작이 되었고 시퀀스적으로 구현했다.

시퀀스적인 타임 챠트는 그림 28에 나타내었다.

그림 28. 시퀀스 타임 챠트

컨베이어의 모양은 부록 6에 나타냈는데, 이 시스템에서 어류를 칸칸마다 올리지 않고 3 접시(tray) 건너 뛴 후에 어류를 올려 놓는다. 왜냐하면 기계의 동작에서 맨 처음 어류를 광량 센서로 스캔하는데 한 접시 길이 만큼이 소요되고, 이것을 신호처리하고 알고리즘 연산한 후에 모터 2개를 이동시키는데 3접시의 거리가 필요하기 때문이다.

이런 방법으로 30마리의 명태에 대해 적용한 결과 실질적인 아가미 길이에 대한 아가미 절단기 위치제어 모터의 위치는 그림 29와 같이 나타났고, 두 위치의 편차를 그림 30에 나타났다.

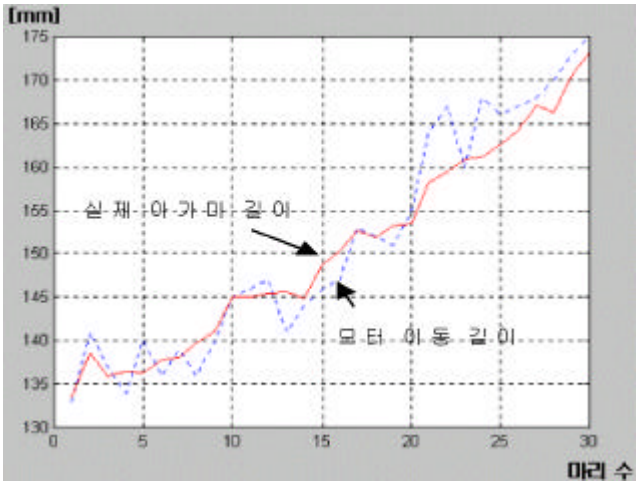

그림 29. 어류의 아가미와 모터이동길이의 출력 비교

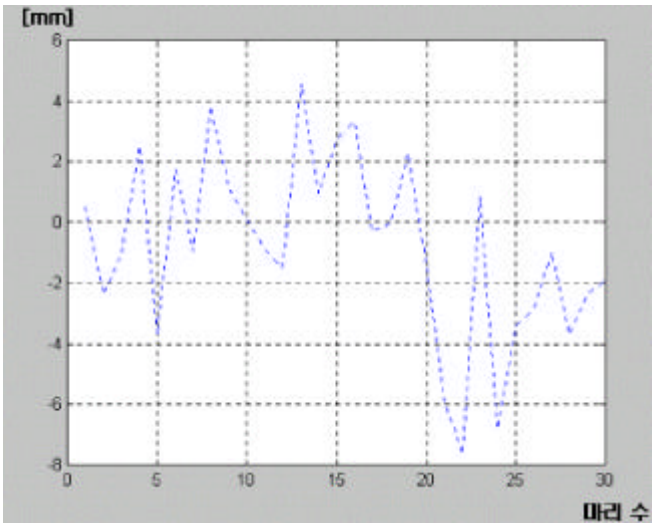

그림 30. 어류의 아가미와 모터이동거리의 오차분포

5. 결론

인공지능의 방법인 신경회로망은 매우 간단하며, 짧은 시간에 빠른 연산을 할 수 있어 빠른 수렴과 비 선형 시스템의 처리 능력에서 효과적인 성능을 얻을 수 있음을 실험 결과로 확인 할 수 있었다.

본 연구에서는 현재의 기계식 생선 가공 시스템의 일률적인 동작과 노동 집약적인 수작업의 가공을 사용자와 관리자 측면에서 보다 편리하게 사용하기 위하여 정확하게 생선의 절단 위치를 검출해서 아가미와 꼬리 부분을 제거할 수 있는 시스템을 구현하였다.

광량 센서에서 나오는 신호를 CPU상에서 A/D 변환과 신호 처리하면서 인공지능 제어기법을 이용하여 어류의 특징점과 윤곽을 분류하였고, 엔코더에서 나오는 펄스로 카운팅해서 위치를 찾아 어류의 아가미와 꼬리 부분을 절단하기 위하여 DC 서보 모터 2개를 제어하였다.

어류의 윤곽을 광량 센서로 받아들인 아가미 부분의 특징점 패턴 분류에서 off-lin 상의 오류 역전파 알고리즘으로 학습시킨 그래프와 모멘텀 항을 사용한 오류 역전파 알고리즘의 학습 그래프 비교에서 모멘텀 항을 사용한 연산의 수렴 속도가 빨리 감소하는 것을 알 수 있었고, 지역 최소점으로 빠질 확률도 적었다. 그리고 실질적인 아가미 길이와 신경회로망에서 출력된 아가미 길이의 오차 범위가 8mm 범위안에 존재하는 것을 알 수 있었다.

향후 연구 방향은 본 논문을 기초로 모든 어종에 연관시켜 정확한 데이터를 검출하여 절단기를 최적의 목적 위치로 이동시키고, 생선의 내장제거, 껍질제거를 할 수 있는 장치를 연구하여 모듈별 어류가공 기계를 계속 연구하고자 한다.

참 고 문 헌

[1] Lefteri H. Tsoukalas and Robert E. Uhrig. *Fuzzy and Neural Approaches in Engineering*, John Wiley & Sons Inc., 1992.

[2] Jacek M. Zurada, *Introduction to Artificial Neural System*, West Publishing Company, 1992.

[3] Chin-Teng Lin and C.S. George Lee, *Neural fuzzy systems*, Prentice Hall, 1996.

[4] **이재현, 강성인, 이상배**, "**신경회로망을 이용한 동적 시스템의 상태 공간 인식 모델에 관한 연구**", **한국 퍼지 및 지능 시스템 학회 논문집**, Vol 7, pp.115-120, 1997.

[5] Yan-Qing Yang and Abraham Kandel, "Compensatory Neuro-fussy Systems with Fast Learning Algorithm", IEEE Trans. on Neural Networks, Vol. 9, No. 1, pp. 83-105, 1998

[6] Y. Chen and F. Bastani, "ANN with Two Dendrite Neurons and Weight Initialization", Proc. IJCNN, Baltimore, Vol.III, pp. 139-146, 1992.

[7] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators", Dept. Economics, University of California, San Diego, CA, discussion pap., June 1988.

[8] K. S. Narendra and K. Parthasarathy, "A diagrammatic representation of back propagation", Center for Syst. Sci., Dept. of Electrical Eng., Yale University, New Haven, CT, tech.

rep. pp. 78-85, Aug. 1988.

[9] **김태영, 김관형, 김일, 이상배, "신경회로망의 패턴분류를 이용한 용접 갭 검출에 관한 연구", 한국 퍼지 및 지능 시스템 학회 논문집** Vol. 8, No. 2, pp. 527-531, 1998.

[10] P. G. Gallman and K. S. Narendra, "Identification of nonlinear systems using a Uryson model", Becton Center, Yale University, New Haven, CT, tech. rep., Apr. 1976.

[11] **이상배, 퍼지-뉴로 제어 시스템, (주)교학사**, pp. 151-152, 1999.

[12] R.J. Thien and S.D. Hill, "Sensor Fusion for Automated Assembly Using an Expert System Shell", Proc. 5th Int. Conf. Advanced Robotics, Pisa, Italy, Vol. 2, pp. 1270-1274, 1991.

[13] C.W. de Silva, *Motion Sensors for Industrial Robots*, Mech. Eng., pp. 40-51, 1985.

[14] C.W. de Silva, "Advanced Techniques for Robotic Manipulator Control", Proc. Int. Conf. Tech, pp. 148-153, 1986.

[15] G.F. franklin, and A.E. Naeini, *Feedback Control of Dynamic Systems*, Addison-Wesley, Reading, MA, 1986.

[16] D.H. Rao and M.M. Gupta. "A Multi-Functional Dynamic Neural Processor for Control Applictions", Proc. Am. Control Conf., San Francisco, pp. 2902-2906, 1993.

[17] J.H. Smith and C. Naina, "The Space Station Freedom Evolution Phase", Proc. IEEE Int. Conf. Robotics and Automation, Scottsdale, AZ, pp. 1472-1477, 1989.

[18] C.W. de Silva, *Control Sensors and Actuators*, Prentice-Hall, Englewood Cliffs, NJ, 1989

부 록

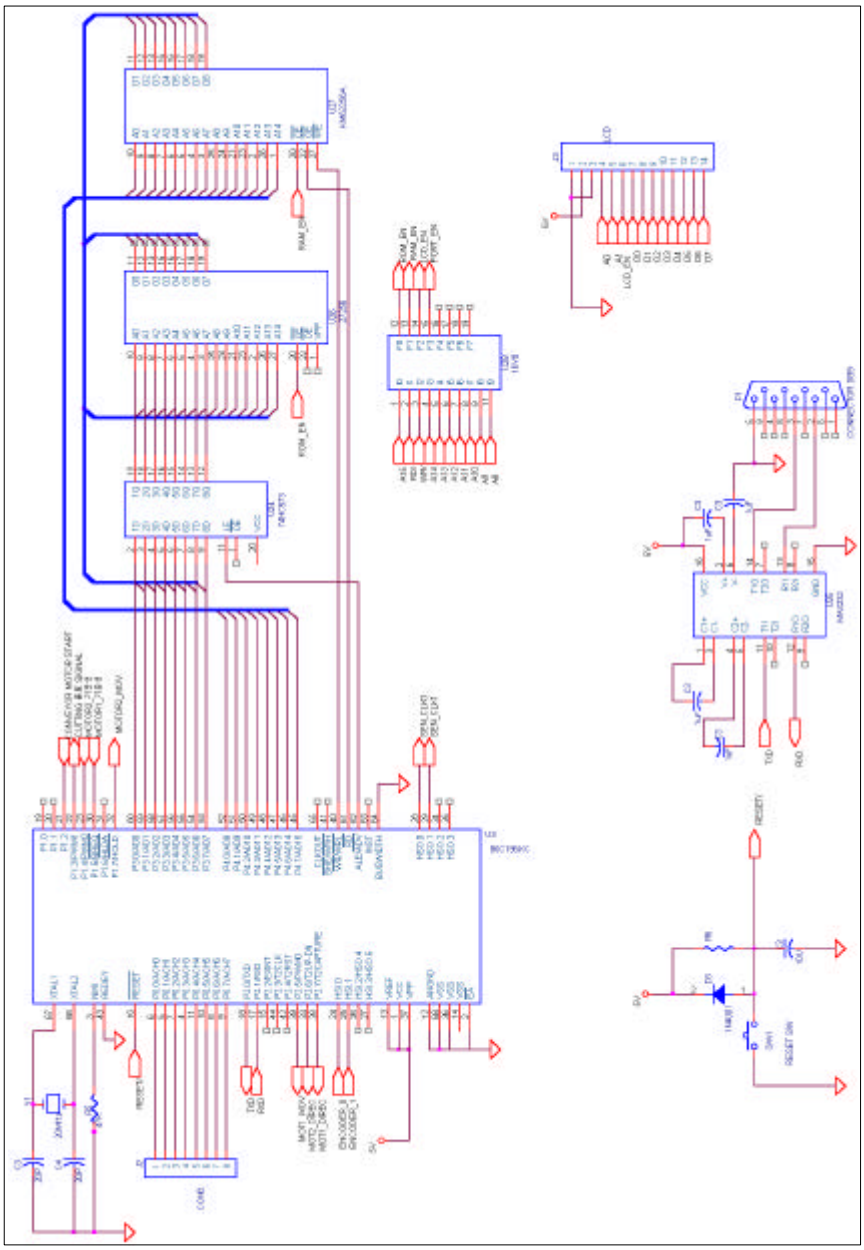

그림 1. 80C196KC Main System 회로도

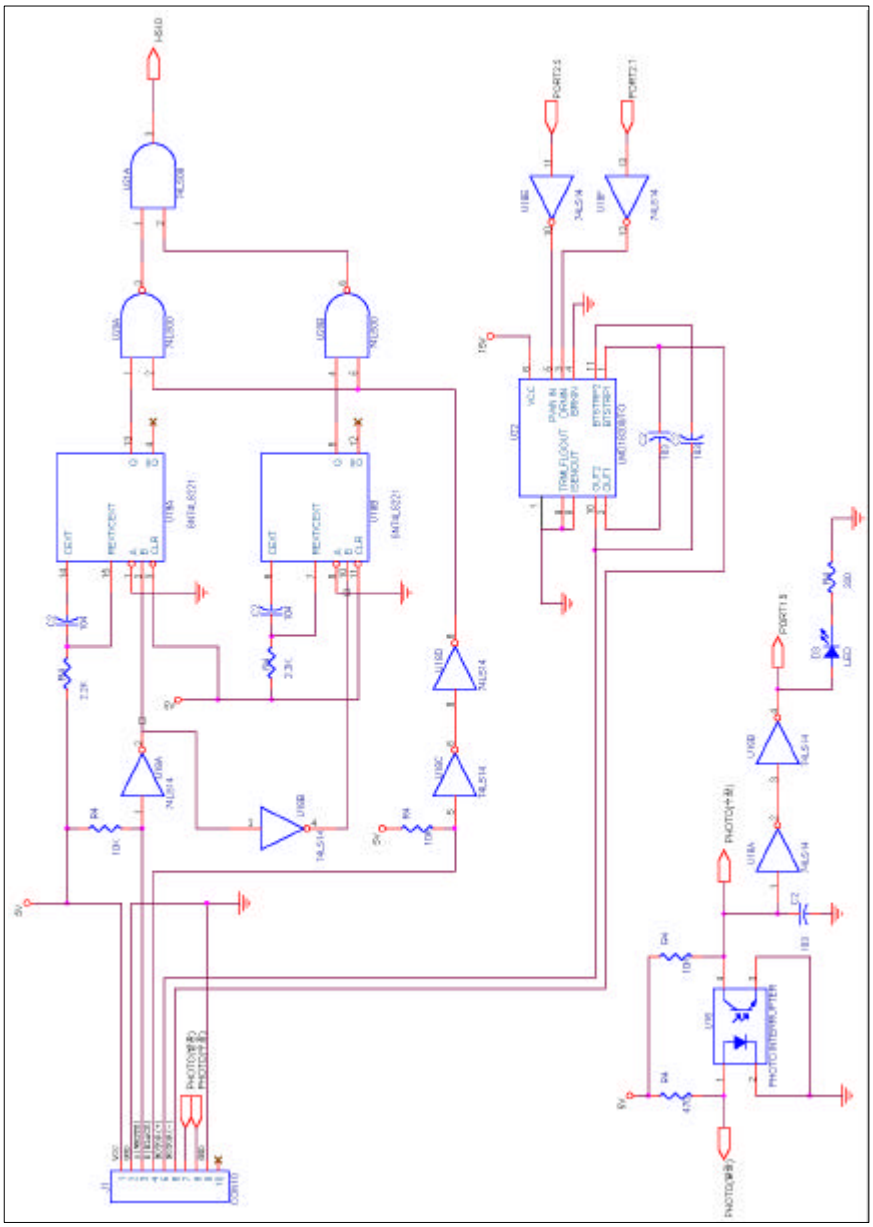

그림 2. 절단기 위치 제어 모터_1 회로도

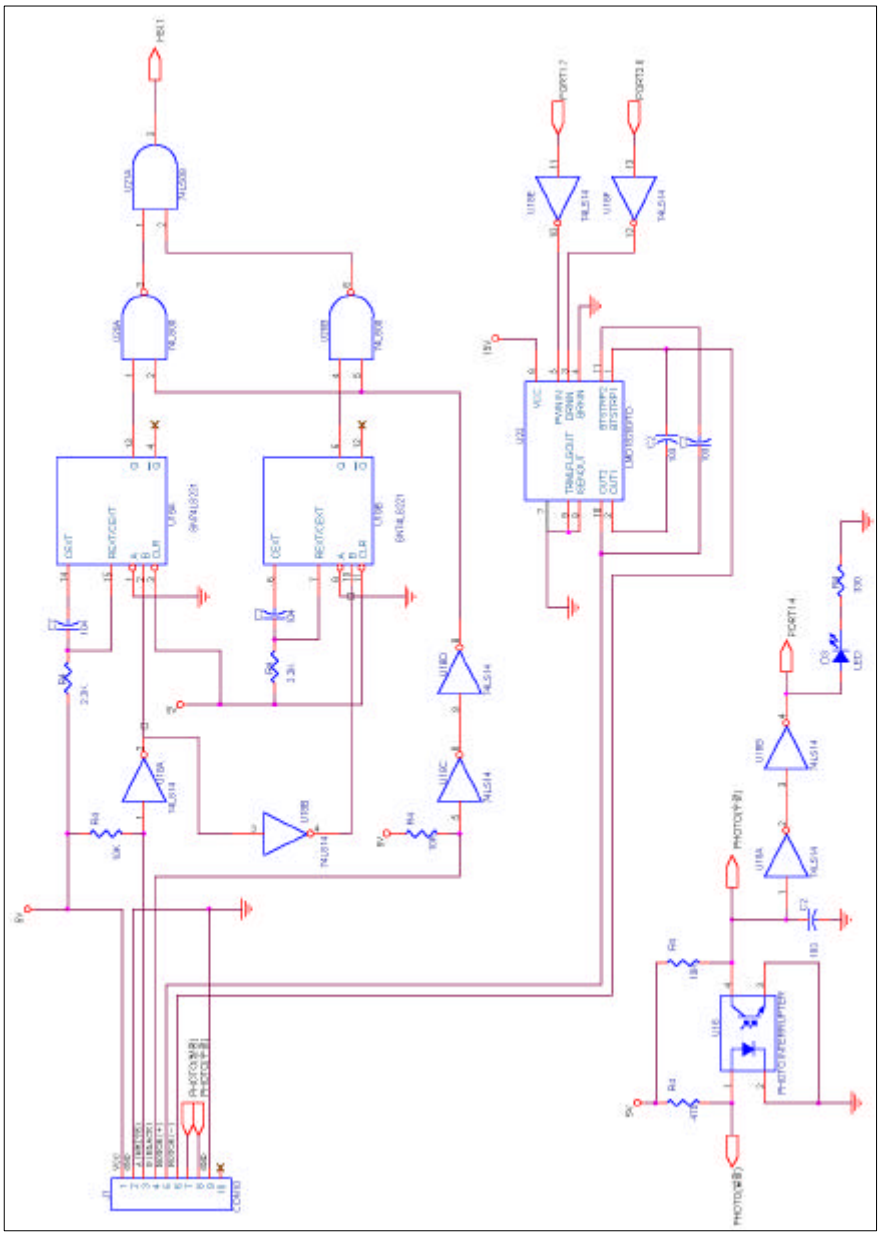

그림 3. 절단기 위치 제어 모터_2 회로도

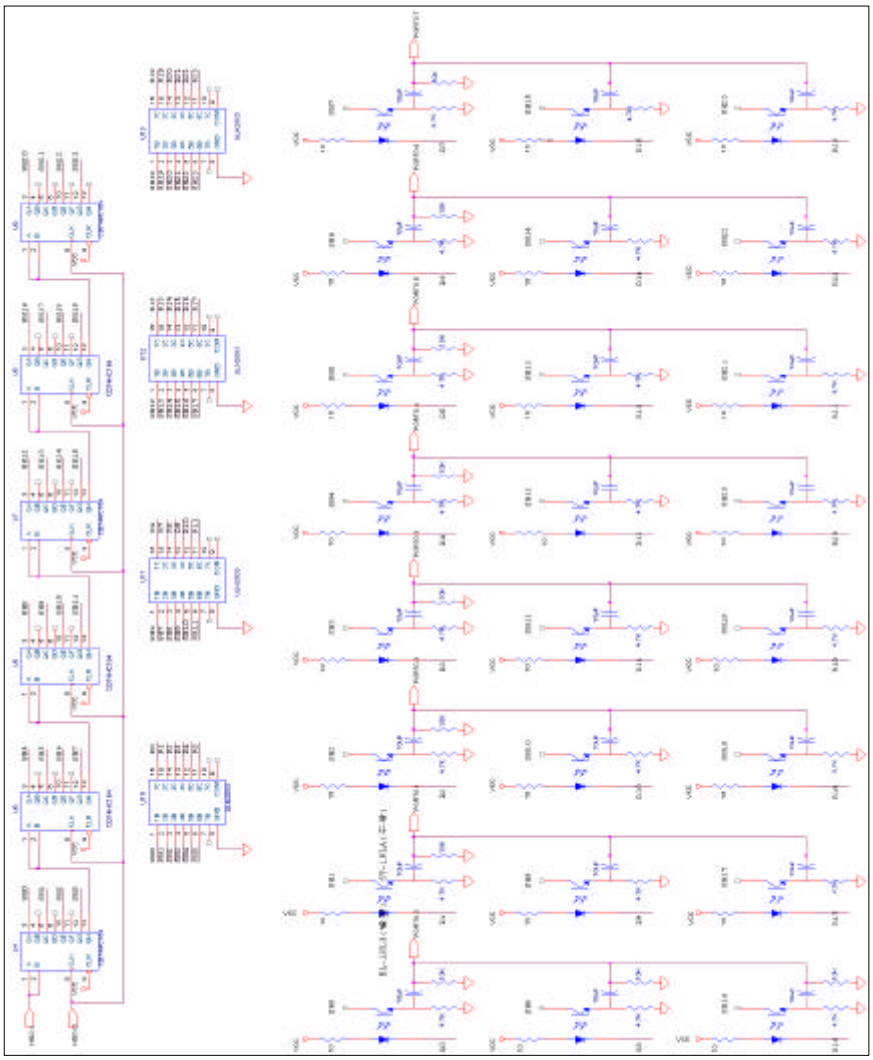

그림 4. 24개의 아날로그 광량 센서 회로도

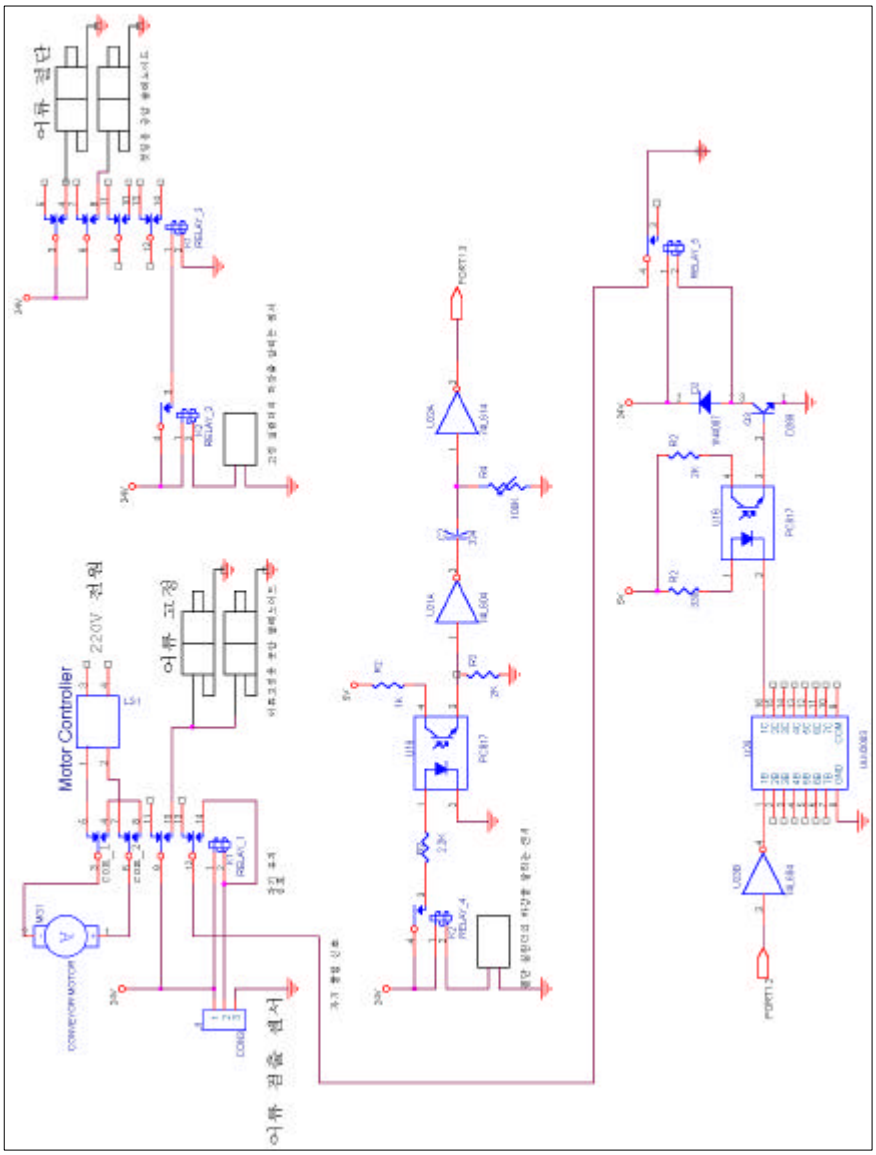

그림 5. Conveyor **모터와 어류 고정, 절단 회로도**

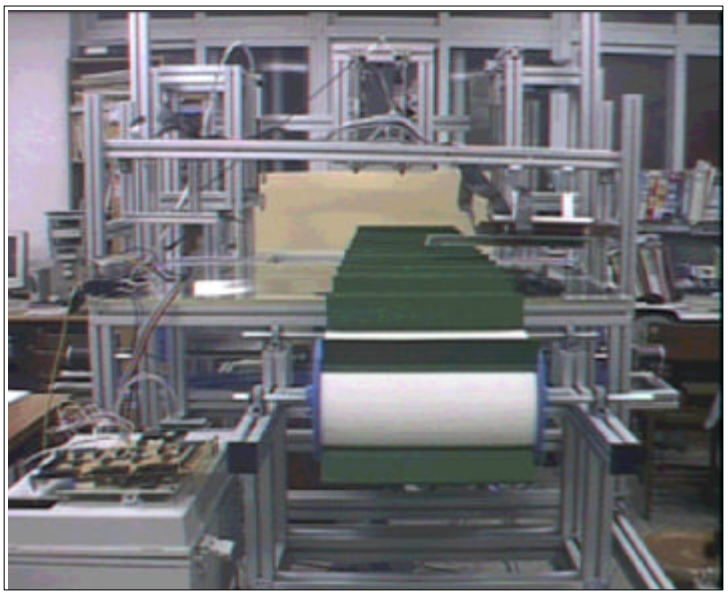

그림 6. 인공 지능형 어류가공 시스템

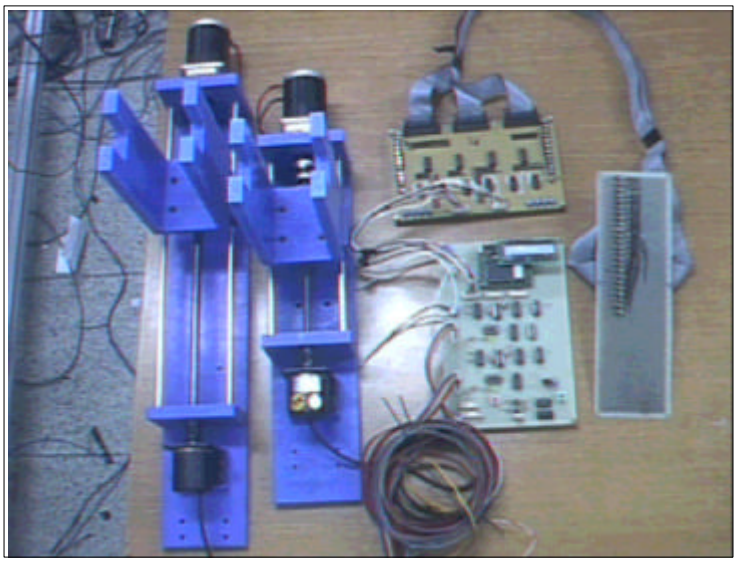

그림 7. 센서회로, 마이컴(80C196KC), 절단기 위치
제어 모터 실험 장치