

## 신경망을 적용한 지체장애인을 위한 근전도 기반의 자동차 인터페이스 개발\*

곽재경\*\* · 전태웅\*\* · 박흡용\*\*\* · 김성진\*\*\*\* · 안광덕\*\*\*\*\*

### Development of an EMG-Based Car Interface Using Artificial Neural Networks for the Physically Handicapped\*

Jaekyung Kwak\*\* · Taewoong Jeon\*\* · Humyong Park\*\*\*  
Sungjin Kim\*\*\*\* · Kwangdek An\*\*\*\*\*

#### ■ Abstract ■

As the computing landscape is shifting to ubiquitous computing environments, there is increasingly growing the demand for a variety of device controls that react to user's implicit activities without excessively drawing user attentions. We developed an EMG-based car interface that enables the physically handicapped to drive a car using their functioning peripheral nerves. Our method extracts electromyogram signals caused by wrist movements from four places in the user's forearm and then infers the user's intent from the signals using multi-layered neural nets. By doing so, it makes it possible for the user to control the operation of car equipments and thus to drive the car. It also allows the user to enter inputs into the embedded computer through a user interface like an instrument LCD panel. We validated the effectiveness of our method through experimental use in a car built with the EMG-based interface.

Keyword : Electromyogram (EMG), Human-computer Interface, Artificial Neural Network  
EMG, Pattern Recognition, Nonlinear Feature Projection, Wavelet Packet  
Transform, PCA, SOFM

논문투고일 : 2008년 04월 21일

논문수정완료일 : 2008년 06월 05일

논문게재확정일 : 2008년 06월 09일

\* 본 논문은 현대-기아 자동차 미래기술 공모전에 출품했던 작품으로서 차량과 개발비를 지원해준 현대-기아 자동차에 깊은 감사를 드린다.

\*\* 고려대학교 대학원 전산학과

\*\*\* 고려대학교 제어계측공학과

\*\*\*\* 한국과학기술 산업공학과

\*\*\*\*\* 충북대학교 전기공학과

## 1. 서론

2005년도 보건복지부 자료에 의하면 지체 장애인 발생률은 인구 천명당 22.23건으로서 모든 장애 유형 중 가장 큰 규모이며, 한국에서의 지체 장애인 수는 약 1,038,000명으로 추정되고 있다[2]. 이들은 타인의 도움없이 일상생활을 하는데 큰 어려움을 겪고 있다. 현재 이들을 위하여 디바이스를 사용할 수 있는 인터페이스 기술이 활발히 연구되고 있다. 이러한 목적을 위하여 생체신호를 사용할 경우 수족이 없는 장애인이라도 신체의 움직일 수 있는 부분이 있다면 생체신호의 전기적 성질을 획득하여 패턴인식을 적용함으로써 사용자의 의도를 반영할 수가 있게 된다[3]. 또한 노화나 근 골격계의 퇴화에 따른 운동기능 손실의 경우에도 생체신호를 기반으로 한 근전도를 적용할 수가 있다.

이러한 생체신호 기반의 신호를 이용한 시스템은 유비쿼터스 헬스케어에 관련된 주요 프로젝트를 중심으로 많은 연구들이 이루어지고 있다. 신호를 획득하는 방법으로는 뇌전도(electroencephalogram, EEG), 신경전도(electroneurogram, ENG), 심전도(electrocardiogram, ECG), 근전도(electromyogram, EMG)를 이용하는 방법들이 있다. 이 신호들을 사용자가 일상생활에서 편리하게 사용하려면 비 침습적인 방법으로 이루어져야 한다. 그런데 뇌전도의 경우에는 잡음으로 인해서 침습적인 획득 방법이 일반적이고 신경전도와 심전도 같은 경우는 전극의 움직임 등으로 제한을 받게 된다. 그러나 근전도 신호의 획득은 비 침습적인 방법으로도 신뢰성 있는 인식이 가능하기 때문에 유비쿼터스 환경에서의 디바이스 조작 대체 기술로서 가장 활발히 연구가 진행되고 있다[6].

근전도 신호는 분석이 까다롭다. 이들 정보는 병렬적(parallel)이며 연속적(continuous)인 특징을 가지고 있기 때문이다. 따라서 안전이 가장 중요한 자동차에서 이를 사용하기 위해서는 기존의 방법보다 인식률이 좋아야 한다. 과거에는 단순한 on/off 제어[7]만 하였지만, Englehart et al.은 wavelet 해석을

통해 패턴을 분석하였으며, “majority vote” 알고리즘을 사용하여 패턴인식의 안정성을 향상시켰다[9]. Jingdong et al.은 autoregressive(AR) model과 wavelet transform을 사용하여 패턴을 분석하였으며, variable learning rate(VLR) 기반의 신경회로망을 사용하여 학습 속도를 향상시켰고, 이를 이용하여 의수로봇을 제어하였다[5]. 그러나 이들은 대부분 의수 로봇 제어를 위한 연구이다. 이와 반면 지체장애인을 위한 근전도기반의 인터페이스 개발[5]에서는 유비쿼터스 컴퓨팅 환경에 맞는 사용자를 위한 디바이스 제어에 초점을 맞추고 있다.

본 논문에서는 지체장애인들이 자동차를 운전할 수 있도록 근전도 신호로부터 사용자의 의도를 추출하고, 이를 실제 자동차의 운전 조작에 적용하여 핸들과 가속페달을 사용하지 않고 근전도만으로 자동차를 사용할 수 있는 방법을 연구하였다. 신경망을 통해서 근전도 제어의 정확성을 높이는 연구를 진행하여 보다 넓은 범위에서 근전도가 사용될 수 있는 가능성을 보여 주었다.

## 2. 방법론

지체 장애인들(C<sub>7</sub>-C<sub>8</sub>)이 자동차를 원활하게 사용하기 위해 사용자 손목의 움직임을 이용하여 자동차 핸들을 좌/우 두 방향으로 제어하는 방법, 상/하 두 방향으로 가속과 정지를 할 수 있는 운전 방법, 공조 장치를 사용하기 위하여 주먹을 폈다/쥐었다 하는 두 개 동작까지 총 6가지의 행동을 택하였다. 이 방법은 손목의 움직임이 가리키는 방향과 핸들이 움직이는 방향이 정확히 일치하기 때문에 사용자가 핸들의 위치 제어를 직관적으로 할 수 있다는 장점이 있다. 자동차 사용을 원활히 하기 위해서는 핸들의 움직임을 제어하는 것뿐만 아니라 가속페달과 정지페달을 사용할 수 있는 인터페이스가 필요하다. 이를 위해 근전도의 데이터를 신경망을 이용하여 상, 하, 좌, 우, 정지, 출발 신호로 분석함으로써 인식 오류의 범위를 최소화하였다.

### 2.1 근전도 데이터 획득 신호부


[그림 1]은 근전도 신호만을 구분해 내는 회로이며 채널 1개의 회로를 보여준다. 총 4개의 채널을 구현하였으며 각 채널의 회로는 [그림 1]과 같은 회로로 구성되어 있다. 각 채널 당 전극은 두 개를 사용한다. 두 개를 사용하는 이유는 측정하고자 하는 근육의 범위를 정하기 위해서이며 한 개는 레퍼런스 신호, 다른 한 개는 액티브 신호로서 두 전극 사이의 근육 움직임 정보를 알 수 있게 된다.

전극으로부터 입력 받는 신호는 0~10mV의 진폭을 가지며 5~450Hz에 에너지가 집중되어 있고, 파워가 낮은 고주파 노이즈가 많이 섞여 있다. DSP의 샘플링 조건은 0~3V의 신호가 필요하다. [그림 1]의 각 번호에 해당하는 회로 설명은 다음과 같다.

- 1) 근전도 신호 취득에 사용되는 신호선을 연결하는 부분으로 총 4개(8개 전극)의 채널을 사용하였다.
- 2) 파워가 낮은 신호에서 고주파 차단을 위해 수동소자를 사용하여 500Hz 이하 주파수만

통과하게 하였다. 근전도 신호 취득 첫 단계 수동소자를 이용하여 LPF(Low Pass Filter)를 사용한 이유가 있다. 처음 설계 시 ②번 회로는 없었으며 ③번 회로의 차동증폭기로 근전도 신호가 들어가게 되었을 때 고주파 노이즈(1MHz이상)로 인해 OpAMP의 슬루레이트 현상이 발생하여 제대로 동작을 하지 않게 되었다. 그 현상을 제거 하기 위해 ②번 회로를 추가하게 되었다.

- 3) 두 전극 사이의 근육 정보를 얻는 방법으로 레퍼런스 신호와 액티브 신호의 전압차를 구하기 위해 차동회로를 사용하였다.
- 4) mV 단위의 근전도 신호를 샘플링하는 ADC의 전압 레벨로 맞추기 위해 전압 증폭을 1000 배로 설정하였다.
- 5) LPF(Low Pass Filter)의 Cutoff-Frequency를 450Hz에 맞추어 설계하였다. 그 이상의 신호는 여러 논문(의학, 전자기기)을 통해 확인해 본 바 근육 정보가 아닌 다른 생체 신호이기에 필요가 없어 제거하였다.
- 6) HPF(High Pass Filter)의 Cutoff-Frequency를 5Hz로 맞추어 ⑤번 회로와 구성된 BPF



[그림 1] 근전도 신호 취득 회로

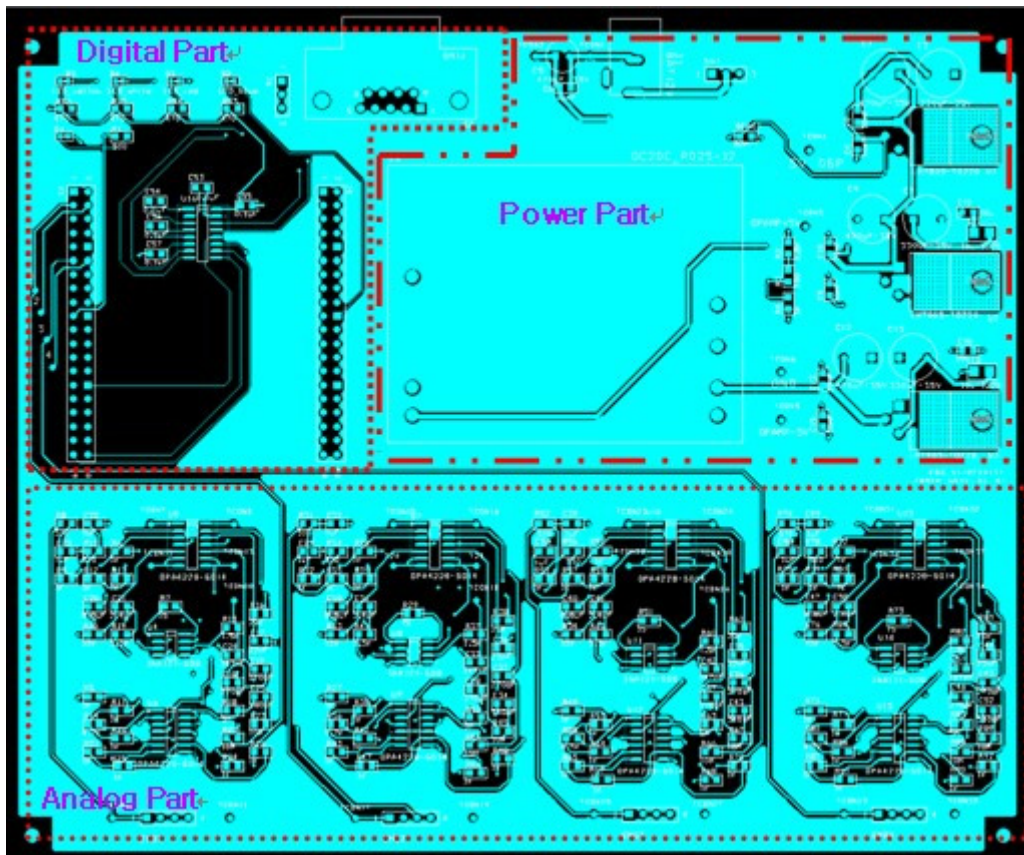
- (Band Pass Filter)를 구현하였고 그 주파수 대역은 5Hz~450Hz로 제한하였다.
- 7) 우리나라 220V전원 주파수 60Hz 영역을 BSF (Band Stop Filter)를 이용하여 제거하였다. 이 회로는 실험을 통해 추가하게 된 부분이다. 실험을 했을 때 생체 신호에서 아무런 정보를 주지 않았는데도 60Hz의 신호가 나와 이 회로를 설계하게 된 것이다.
  - 8) MCU의 ADC 샘플링 허용 전압 레벨에 맞추기 위해 실험 및 테스트를 하였으며 4.7배의 증폭이 필요하게 되어 전압 증폭회로를 구성하였다.
  - 9) ①~⑧까지 회로에서 나오는 파형은  $\pm 1.5V$ 의 레벨로 나온다. 우리가 선택한 MCU의 ADC

는 0V~3V의 레벨만을 인식할 수 있으므로 전압 기준을 올려야 했다. 가산기 회로를 구현하여 파형의 전압레벨을 0V~3V레벨로 상승시켰다.

- 10) ⑩번 회로의 가산기는 위상을 반전시켜서 나오게 한다. 이를 원래의 근육정보로 복원하기 위해 위상 반전회로를 추가 하였다.

본 연구팀은 근전도의 획득을 위하여 4개의 근전도 획득 채널을 지닌 H/W를 설계하고 구성하였으며 이는 크게 전원 부, 채널 필터 부, 신호처리 부로 나누어 구성하여 설계하였다.

전원 부는 차량에서 사용할 것을 고려하여 구성하였으며 2단계의 전원안정화 회로를 거치도록 되



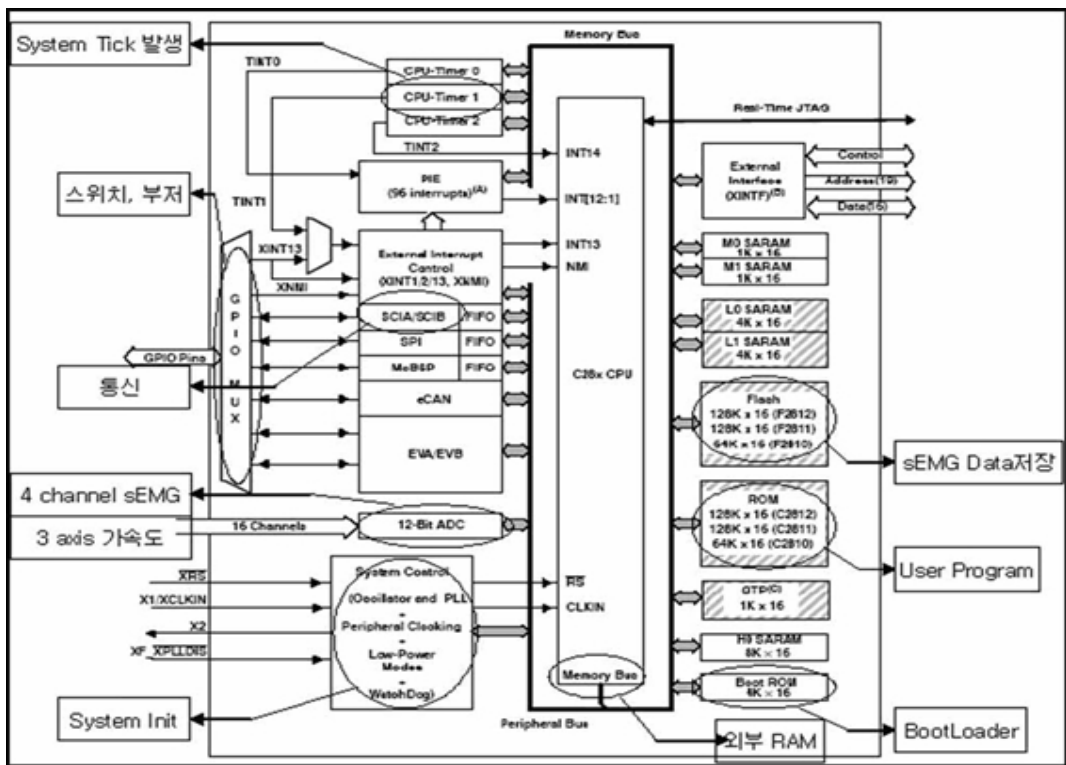
[그림 2] 4채널 근전도 PCB

어 있다. 차량의 outlet를 통하여 입력된 12V의 전원은 전원 부의 대용량 DC-DC Converter를 이용하여 1차적인 안정화를 거치게 된다. 그 후 차량의 점화 장치 및 전자기기의 작동으로 인한 power noise를 억제하기 위하여 채널 필터 부와 신호처리 부를 분리하여 독립된 전원을 구성하였다.

채널 필터 부는 표피로부터 얻어진 생체신호에서 근전도 신호의 영역만을 분리하는 역할을 하게 된다. 이 경우 기존의 근전도 획득의 방법을 사용할 수 있지만 차량을 이용하여 구현한다는 특이점이 있고 현재 대부분의 차량이 스마트 키, GPS, DMB 등 전자장치를 내장하고 있어 표면전극에 과도한 noise를 유입시킨다는 문제가 있다. 따라서 차량 내부에서 직접적인 측정을 통해 각종 전자장치 및 점화 노이즈를 상쇄시킬 수 있도록 필터를 구성하였다. [그림 2]는 4개의 채널 중 하나의 채널만을 보여주고 있으며 모든 채널은 [그림 2]의

구성과 동일하다. 500Hz이하의 신호만을 큰 마진을 가지고 받아들이기 위하여 passive device를 이용하여 LPF를 구성하였으며 이는 차동증폭기의 슬루레이트 현상을 방지하는 역할을 한다. 이 후 reference signal과의 차이를 기준으로 신호를 증폭하게 된다. 그 후 미약한 신호를 증폭시키기 위하여 1000배의 증폭을 거치고 5Hz에서 450Hz까지의 신호만을 획득하게 된다. 이 후 차량 내 가장 많이 나타나는 상용전력 주파수인 60Hz의 신호를 분리해 낸 후 신호 처리 부에서 원활하게 처리할 수 있도록 전압 레벨을 맞추게 된다.

신호 처리 부에서는 필터링 되어 나온 근전도 신호를 디지털 신호로 변환하게 된다. 이를 위해 TI사에서 발매되고 있는 TMS320F28X DSP의 ADC블록을 사용하였으며 샘플링 된 데이터를 무선통신을 이용하여 원격지의 정보처리 장치로 송신하도록 하였다. 부가적으로 회로 레벨에서만만



[그림 3] DSP TMS320F2812 사용한 블록도

아니라 PCB를 설계하면서 ground shielding과 signal shielding을 고려하여 채널 필터 부의 노이즈 유입을 최소화 하고자 하였으며 이를 위해 PCB는 4개 층(Analog Signal, GND, Power, Digital Signal)으로 구성하였다. [그림 2]는 설계된 PCB의 Layout을 보이고 있으며 Digital부와 Analog부 간의 GND는 분리되도록 설계하였다.

## 2.2 최종 표면 근전도 취득 모습

Dual Sequence Mode를 이용하여 한 번에 두 채널씩 연속하여 4번의 샘플링을 수행하게 된다. 이때 변환되는 채널들은 EMG의 각각 4채널이 된다. 1 msec 마다 근전도 신호의 AD변환을 완료하게 되면 4개의 채널에 대한 데이터가 생성된다.

처리는 화면에 출력하는 방법과, 화면에 출력 없이 바로 호스트에게 전송하는 방법이 있다. 화면에 출력하는 방법은 파형을 분석하기 위한 디버깅 과정이며, 호스트에게 전송하는 방법은 실제 차량에 적용하여 테스트를 하게 될 경우가 된다.

파형을 분석하기 위한 방법에서는 Matlab을 이용하게 되는데 화면에 나온 데이터를 파일 형식으로 저장하여 그래프를 그려봄으로써 실제 눈으로 확인하게 된다. 이는 데이터를 호스트에게 전송할

경우 Wavelet 변환 및 PCA, MLP까지 거치게 되므로 전송 전에 데이터를 미리 확인하기 위함이다.

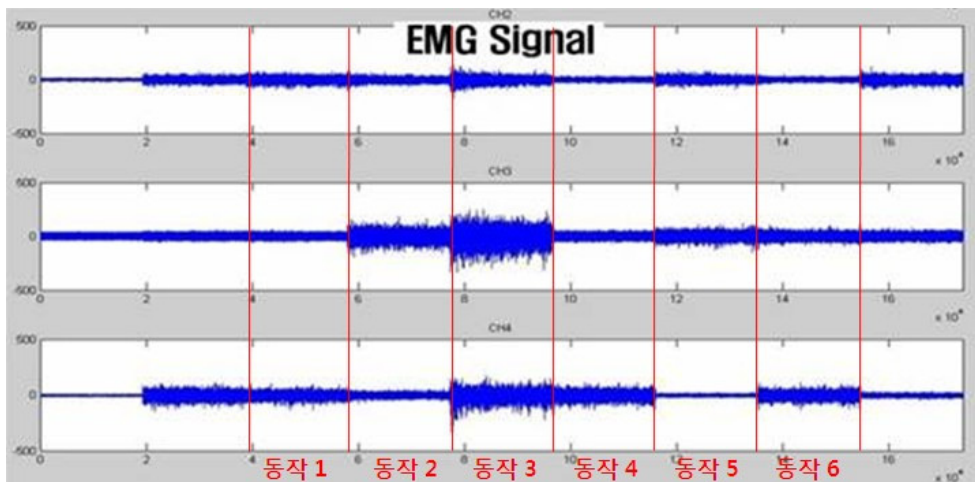
## 2.3 취득 데이터 파형 분석

[그림 4]는 동작 1~동작 6까지 6가지 근육 특징에 대한 샘플링 파형이다. Matlab을 이용하여 DSP 내 AD 변환을 통한 데이터의 파형을 그린 것이다. [그림 4]에서 동작 1은 상, 동작 2는 하, 동작 3은 좌, 동작 4는 우, 동작 5는 출발, 그리고 동작 6은 정지 신호로 자동차 주행 보드에 전달되어 핸들과 연동된다.


DSP 보드로부터 추출된 신호로부터 특징점을 찾아내는 단계가 필요하다. 이전에 연구가 되었던 Wavelet Transform (Coif-4)과 PCA는 특정 대상(피실험자)에 따라 주파수 특성 차이가 심하고, 노이즈에 매우 취약한 단점을 갖고 있었다. 본 연구에서는 채널별로 Normalize된 신호의 RMS Amplitude를 가장 큰 특징으로 선택하였다.

## 2.4 취득 데이터 학습 과정

각 동작 별로 4초간 정지 상태의 신호를 취득한다. 6가지 동작의 경우 신호의 샘플링 주파수가



[그림 4] 6가지 동작 샘플링 파형



[그림 5] 6가지 동작 샘플링 파형 파싱

1000Hz 이므로 각 채널 별로 24000개의 샘플이 취득된다. DSP의 A/D가 12bit의 분해능을 가지므로 하나의 샘플은 2byte의 크기를 갖는다.

[그림 5]에서 [동작 1]은 휴지 동작으로, 아무 동작도 취하지 않은 상태이다. 이 구간의 신호의 MAV(Mean Absolute Value)를 계산하여 Threshold 값으로 사용한다. 또한 각 구간의 MAV를 계산하여 특징으로 사용한다. 즉, 각 동작 별로 3개의 값이 나오게 된다(3 채널의 경우). EZ-X5 보드에서 이 연산을 수행하기 위하여, 기존의 알고리즘보다 연산량을 대폭 감소하게 되었다.

이렇게 구해진 특징값을 MLP에 1,000회 학습시켜, 신경망을 구성하게 된다.

\* MAV

$$\text{MAV\_VALUE} = \frac{\text{SUM}(\text{ABS}(X(i)))}{N},$$


$$i = 1 \sim N(\text{학습시}, N = 24000) \quad (1)$$

학습의 결과물은 각 채널 별 휴지 동작의 MAV


값과 MLP 신경망이다.

## 2.5 취득 데이터 인식 과정

인식 과정에서는 신호를 실시간으로 처리해야 하기 때문에, Sliding Window를 사용한다. 윈도우 크기는 300, 윈도우 스텝 수는 100으로 설정하였다. 즉, 각 채널로부터 100ms마다 300개의 샘플이 입력으로 들어오게 된다. 이 부분에서 시간 지연은 피할 수 없는 장애 요인이지만, 약 300ms 내에서는 사용자가 시간 지연을 인식하지 못한다[8]. 이 신호로부터 RMS(Root mean square)를 취하고(절대값으로 대체 가능) 각 채널의 최대 RMS Amplitude로부터 값을 Normalize한다. 즉, 채널 별로 상대적인 값의 차이만을 볼 수 있도록 하는 것이다. 이렇게 변환된 값으로부터 MAV를 계산하여 MLP의 입력 노드로 전달하면, 신경망 학습 결과로부터 결과 값이 인식된다. [그림 6]은 이러한 취



[그림 6] 취득 데이터 인식 과정



[그림 7] 인공 뉴런의 구조

득 데이터로부터 동작 인식 과정을 보여준다.

단, MAV값이 학습 과정에서 계산된 휴지 동작의 MAV의 1.2배가 넘는 경우에만 MLP의 입력 노드로 전달하고, 그렇지 않을 경우에는 휴지 동작으로 간주한다(대개 신호의 노이즈가 휴지 동작의 신호에서 1.2배까지 발생하기 때문이다).

### 3. 근전도 신호 신경망

#### 3.1 인식 데이터 신경망 학습

신경망이란 인간이나 동물의 뇌의 구조를 모방한 계산 모델이다[4]. 실제 생명체의 뇌는 단순한 일을 하는 개개의 뉴런들로 구성되는데, 이들은 천문학적인 수를 이루어 망을 형성하고 상호 작용하는 분산 병렬 방식의 처리과정을 통해 컴퓨터가 할 수 없는 고차원 적인 문제 해결을 가능케 한다.


신경망 모델은 각 뉴런의 기능, 망의 구조, 데이터에 따른 적용 알고리즘에 의해 그 유형이 구분된다. 모든 신경망은 기본적으로 [그림 7]과 같이 하나의 뉴런에서 시작하며 이를 변형하거나 응용하여 만들어진다.

[그림 7]에서  $x$ 값은 입력 신호들이며,  $x$ 값과 각각의 weight값인  $w$ 를 곱한 전체 합을 더하게 된다. 그리고 선택적으로 bias 값을 받아들이며, 활성화 함수(Activation Function)에서 처리를 통과하여 비로소 출력 값  $y$ 로 나가기 된다. 활성화 함수로는 threshold, piecewise-linear, sigmoid 등이 있다[10].

일반적으로 널리 사용되는 것으로는 다층 퍼셉트론(MLP : Multi Layer Perceptron)가 있다.

다층 퍼셉트론은 비선형 활성화함수를 가지고 있고, 은닉 층으로 불리는 중간층을 가지며, 각 층의 뉴런들은 인접한 층의 다른 모든 뉴런들과 상호 연결되어 있다는 특징을 지닌다.





[그림 8] 다층 퍼셉트론(MLP)

$$e_j(n) = d_j(n) - y_j(n) \quad (2)$$

$$E(n) = \frac{1}{2} \sum_{j=L} e_j^2(n), \quad E_{cn} = \frac{1}{N} \sum_{n=1} E(n) \quad (3)$$

학습은 출력 층의 에러 값이 최소가 되는 방향으로 이루어진다[10]. 식 (2)는 j번째 출력 뉴런에서의 에러 값 e를 구하는 것으로 출력 값 y와 학습 값 d사이의 오차 값을 사용한다. 그리고, 식 (3)은 출력 층의 모든 뉴런에 대한 에러 값을 더하여 2로 나눈 후, 전체 학습 데이터 패턴에 대한 평균 에러 값을 구하는 과정이다.

실제 학습은 다음의 과정을 거친다. 먼저 입력 층의 뉴런은 입력 신호 값에 가중치를 곱한 후 은닉 층으로 보낸다. 은닉 층의 뉴런은 입력 층의 뉴런들로부터 받은 값들을 모두 더한 후 비선형 활성화함수 처리를 하고 다시 가중치를 곱하여 출력 층으로 보낸다. 출력 층의 뉴런에서는 은닉 층의 뉴런들로부터 받은 값들을 모두 더하여 다시 활성화함수 처리를 하여 결과를 내보내게 된다. 이렇게 이전 층에서 나오는 결과 값들과 실제 값들을 비교하여 그 오차 값을 계산한 후, 신경망의 weight를 갱신해 주어야 하는데, 출력 층에서 입력 층까지 반대 방향으로 갱신 작업이 이루어진다고 하여 오류 역전파 방식(error-back propagation)이라 한다.

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (4)$$

$$\delta_j^{(l)}(n) = \begin{cases} e_j^{(L)}(n) \phi_j^1(v_j^{(L)}(n)) \\ \phi_j^1(v_j^{(L)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \end{cases} \quad (5)$$

$$\phi_j(v_j(n)) = \frac{1}{1 + \exp(-\alpha v_j(n))}, \quad \alpha > 0 \& -\infty < v_j(n) < \infty \quad (6)$$

$$\phi_j^1(v_j(n)) = \alpha y_j [1 - y_j(n)] \quad (7)$$

각 층의 오류 역 전파를 통한 가중치 갱신은 식 (4)과 같이 이전 층의 i번째 뉴런과 현재 층 l또는 L의 j번째 뉴런에 대한 계산으로 이루어지며, 이렇게 나온 값으로 식 (5)를 이용하여 에러 값  $\delta$ 를 계산하게 된다.  $\delta$  값을 구하기 위해서는 활성화함수가 미분 가능해야 하는데, Logistic function 또는 Hyperbolic tangent function 등이 사용된다. 식 (6)과 식 (7)은 전자에 해당하는 시그모이드 함수의 원형 식과 미분 식을 보여주고 있다.

실제 학습에 있어서 크게 순차적(sequential)인 방법과 일괄적(batch)인 방법이 있다. 순차적인 방법은 개개의 입력 값들에 대한 에러 값을 계산하여 바로 가중치를 갱신하는 방식으로 구현이 간편하다는 점과 방대하고 복잡한 패턴을 학습하는 데 상대적으로 신속한 장점이 있다. 반면 일괄적인 방법은 모든 입력 패턴의 값을 처리한 후 마지막에 한번 에러 값을 통한 갱신을 해주는 방식으로 비교적 적은 양의 데이터를 빠르게 처리할 수 있는 장점이 있다. 식 (3)은 순차 학습 방법의 에러 계산 식이다.

그 외, 패턴을 효율적으로 학습하기 위해서 입력 데이터를 정규화(Normalize)시키는 방법도 사용되며, 학습 시 에러의 수렴 속도를 빠르게 하기 위하여 모멘텀 항의 추가, 학습 계수 최적화, 선택적 재 학습 방법 등이 동원된다[1].

이번 연구에서 사용한 구체적인 신경망 알고리즘의 순서는 다음과 같다.

- 1) 네트워크의 상태를 결정하는 연결강도  $w$ 는  $\text{random}(-0.5, 0.5)$ ,  $\text{offset}$ 은  $\text{random}(-0.05, 0.05)$ 로 초기화.
- 2) 훈련 패턴 값을 정규화 하여 입력.
- 3) 훈련 패턴 값을 입력뉴런에 넣어서 출력되는 값  $o$ , 입력뉴런과 은닉뉴런 사이의 연결강도  $w$ 와 은닉뉴런의  $\text{offset}$ 을 이용하여 은닉뉴런의 입력  $\text{net}$ 을 구한다. 다음으로  $\text{net}$ 과 시그모이드 함수  $f$ 를 이용하여 은닉뉴런의 출력  $o$ 를 구한다.
- 4) 훈련 세트의 목표 출력  $t$ 와 실제 출력  $o$ 와의 차로부터 출력뉴런에 연결된 연결강도와 출력뉴런의  $\text{offset}$ 에 대한 오차  $d$ 를 구한다.
- 5) 오차  $d$ 와 함께 은닉뉴런과 출력뉴런 간의 연결강도  $w$ 와 은닉뉴런의 출력  $\text{net}$ 으로부터 은닉뉴런에 연결된 연결강도와 은닉뉴런의  $\text{offset}$ 에 대한 오차  $d$ 를 구한다.
- 6) 4단계에서 구한 출력뉴런에서의 오차  $d$ , 은닉뉴런의 출력  $o$ , 상수  $\alpha$ 와의 곱을 더하여 은닉뉴런과 출력뉴런에 연결된 연결강도  $w$ 를 수정한다. 또 오차  $d$ 와 정수  $\beta$ 와의 곱을 더하여 출력뉴런의  $\text{offset}$ 을 수정한다.
- 7) 은닉뉴런의 오차  $d$ , 입력뉴런의  $o$ , 상수  $\alpha$ 와의 곱을 더하여 입력뉴런과 은닉뉴런에 연결된 연결강도  $w$ 를 수정한다 또 오차  $d$ 와 상수  $\beta$ 의 곱을 더하여 은닉뉴런의  $\text{offset}$ 을 수정


한다.

- 8) 다음 훈련 패턴을 학습시킨다.
- 9) 모든 훈련 패턴에 대하여 전부 학습할 때까지 2단계로 되돌아 간다.
- 10) 학습의 반복 횟수를 100번 이상으로 한다.
- 11) 이렇게 학습된 뉴런을 기존 훈련 패턴에 대해 테스트 해본다.
- 12) 훈련 패턴대신 다른 집합인 검사 패턴에 대해 테스트 해본다.

### 3.2 신경망 학습 비교 실험 결과

보드에서 변환되어 넘어온 값으로부터 MAV를 계산하여 MLP의 입력 노드로 전달하면, 훈련 패턴 값이 6가지의 신호로 정규화하여 입력되어 있으므로 입력된 값과의 비교를 통하여 신경망 학습 결과로부터 최종 동작이 인식되어 보다 정확한 신호를 판별할 수 있다.

실험에서는 원하는 6개의 유형 패턴을 구분하여 75개의 훈련 패턴과 25개의 실험 패턴에 대한 인식률을 평가하였다. 훈련 및 실험 데이터의 임의의 구분이 인식률에 영향을 줄 것을 고려하여, 100개의 패턴을 순서대로 25개씩 실험 패턴으로 설정하여 실험 데이터를 생성하였다. 즉, 평균적인 성능 검사 결과를 알아보기 위해, 근전도 입력 뉴런 100개를 25개씩 네 집단으로 분리하여 해당 집단마다



[그림 9] 은닉 뉴런 수에 따른 분류 성능 결과


25개에 속하지 않는 나머지 75개를 학습용으로 사용하고 그 결과를 합한 후 평균하여 최종6개 유형 패턴 은닉뉴런과 비교를 통하여 훈련패턴 오류율을 추출하였다.

[그림 9]를 보면 은닉 뉴런 수가 증가함에 따라 훈련 받은 75개 패턴에 대한 분류 능력이 증가하는데 비해 25개의 검사 패턴에 대해서는 꾸준히 오류율이 감소하는 것을 보여주고 있다. 실제 디바이스 작동을 위한 근전도의 사용을 위해서는 높은 성능이 필요하단 점을 감안하면 상당히 낮은 오류율 수치임을 알 수가 있다.

### 3.3 6개 유형 패턴 추출을 위한 근전도 신호의 신경망 학습 적용 결과

근전도 기반의 컴퓨팅 인터페이스를 사용하여 디바이스를 동작시킬 장애인의 수족을 대신할 기능을 구현하기 위해서는 위의 신경망 학습 비교 실험 결과에 따른 오류율을 더 낮게 할 필요성이 있으므로 차량을 운전하는데 필요한 상, 하, 좌, 우, 정지, 출발의 6가지 패턴만을 더 정확히 검출

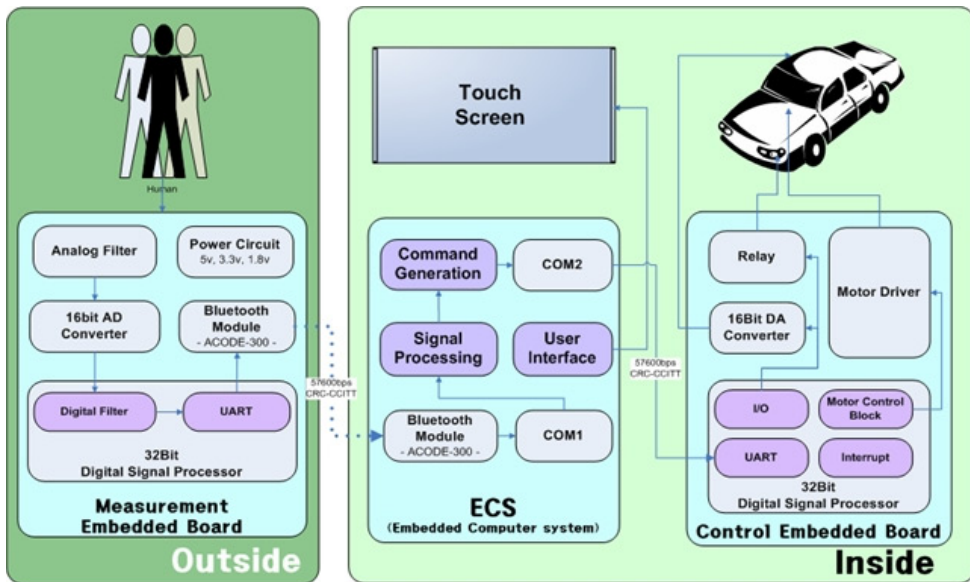
하기 위해 각 상황 별 활성도를 높여 신경망 회로에서 뉴런의 활성도에 따른 6가지 패턴인식에서 성공률을 비교하였다. 그 결과 [그림 10]에서 분류된 패턴이 얼마나 사용자의 의도를 잘 반영하고 있는지 나타내는 성공률을 확인하여 98.6%라는 높은 성공률을 인식함을 확인할 수 있다.



[그림 10] 신경망 학습 적용 결과의 인식률

## 4. 활용 실험 결과

신경망을 이용한 근전도 패턴 인식 방법의 활용 여부를 확인하기 위해 현대-기아 자동차에서 제공



[그림 11] 세부 블록

한 그랜저 차량에 차량 제어 보드를 만들고 이를 임베딩한 내장 컴퓨터를 통하여 사용자가 근전도를 통하여 차량을 제어할 수 있는 지를 실험하였다.

세부적으로 구현 내용을 보면 [그림 11]과 같이 Inside와 Outside로 구분되어 있다.

- Inside : ECS(내장형 컴퓨터)는 신호를 받아 처리하고 Touch Screen으로 표현한다. CEB(제어 보드)는 실제로 모터와 센서, 릴레이를 이용하여 자동차를 제어한다.
- Outside : 사용자에게서 데이터를 얻어 가공한 ECS로 전송한다.

### 4.1 차량 제어 부분

[그림 12]와 같이 모터로 핸들과 브레이크를 제어하고 DA Converter를 이용하여 엑셀을 제어한다. 그리고 릴레이를 이용해서 자동차에 필요한 여러 가지 신호를 만들어 입력하고 Isolated Opamp와 포토

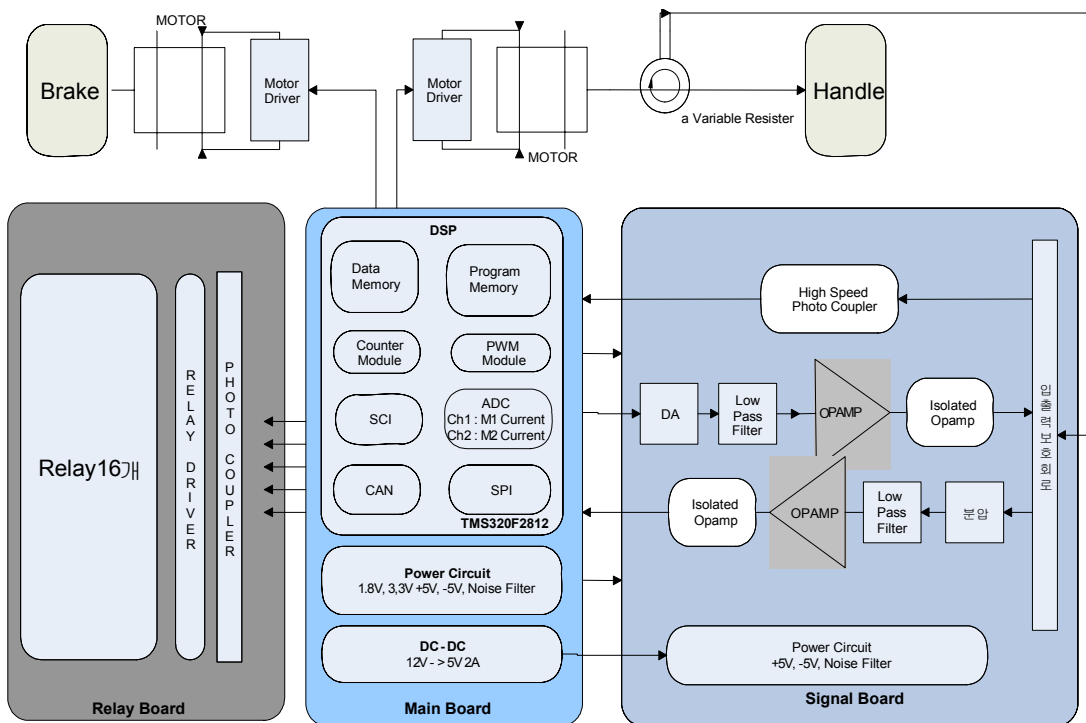
커플러를 통해 입력을 받아 제어를 한다.

### 4.2 사용자 적응형 계기판 디자인

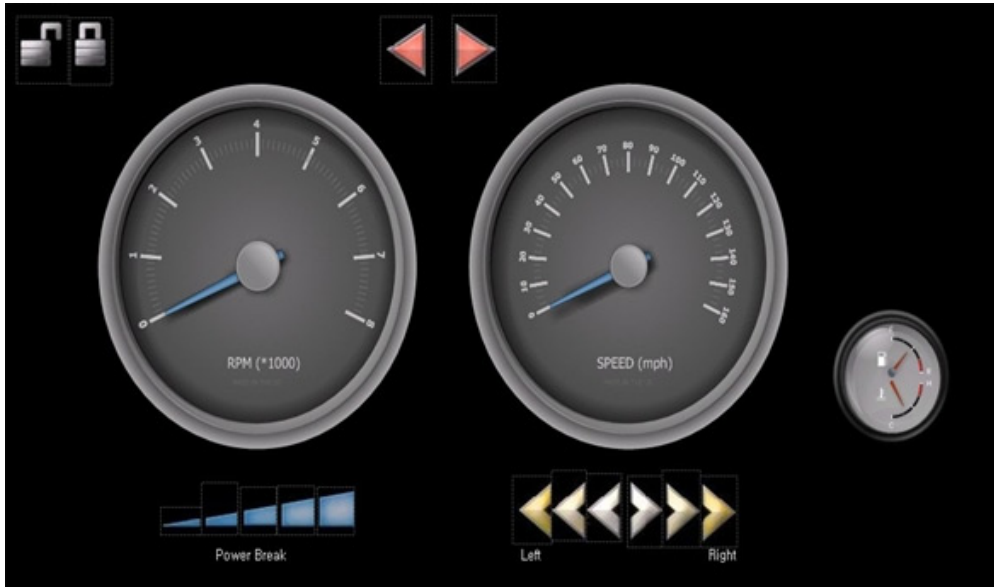
패턴 인식 학습에서 6가지의 정규화 입력으로 사용한 신호를 사용하여 좌/우/전진/후진/브레이크/잠금 을 실험할 수 있도록 [그림 13]과 같이 사용자 계기판을 구성하였다.

### 4.3 실물 개발

근전도 보드와 차량 제어 보드 그리고 사용자 적응형 계기판을 실제 차량에 부착하여 운전을 하면서 실제 상황에서의 변화를 확인할 수 있었으며, 이상과 같이 6가지 동작에 대한 근전도로부터 본 논문에서 제안한 패턴인식 방식에 의거하여 사용자의 의도를 98.6% 이상 인식하고, 인식한 정보를 이용하여 차량에서 사용자의 의도대로 정확하게



[그림 12] 차량 제어 부분



[그림 13] 사용자 적응형 계기판



[그림 14] 제어보드 차량 적용

장치를 동작시킴을 확인할 수 있었다.

## 5. 결 론

본 논문에서는 지체 장애인을 위해 손목의 움직임으로부터 발생하는 근전도 신호를 추출하여 신경망을 적용하여 근전도 신호의 신뢰성을 높여서 자동차를 제어하고 차량 정보를 사용자 친화적인 계기판을 이용하여 확인할 수 있는 컴퓨터 인터페이스를 개발하였다. 상기의 인터페이스를 이용하여 실험해 본 결과 차량을 제어하기 위한 6가지

패턴을 4가지의 근육을 사용하여 각각 98.6%이상의 높은 성공률로 분류하고 있음을 확인하였다.

전기 신호로 생성된 패턴을 컴퓨터로 다룰 수 있는 데이터로 변환시키기 위해 ADC 기법이 사용되었으며, 주파수 분석을 통하여 주파수 값으로부터 사용자의 의도를 6가지로 구하는 데에는 평균율의 지식이 필요하였고 이를 반복하여 완전한 패턴을 얻을 수 있었다.

실험을 통해 6가지의 정규화된 값에 따라 신호를 구분 할 수 있는 지를 알아 보았다. 실험 결과, 신호 인식률이 98.6%에 이른다는 것을 알 수 있었

다. 이는 신경망이 분류 작업을 효과적으로 하는데 효율적인 것으로 보이며, 또한 근전도를 이용한 실제 차량의 제어를 활용함으로써 기존의 척수 손상 장애우들에게 자동차 인터페이스로 대체 사용 가능성을 확인할 수 있었다.

## 참 고 문 헌

- [1] 김대수, 「신경망 이론과 응용」, 하이테크 정보, (1992), pp.110-117.
- [2] 변용찬, 김성희 등, “2005년 장애인 실태조사”, 「보건복지부, 한국보건사회연구원」, 2006.
- [3] 이정훈, 정경권, 이현관, 엄기환, “가상로봇 팔 제어를 위한 퍼지-SOFM 방식의 근전도 패턴 인식”, 「대한전자공학회논문지」, 제40권, CI편, 제2호, 2003.
- [4] 장병탁, “다층신경망 은닉뉴런수의 효율적인 최적화”, 「정보과학회논문지(B)」, 제25권, 제9호(1998), pp.1333-1341
- [5] 최창목, 한효녕, 하성도, 김정, “지체장애인을 위한 근전도 기반의 컴퓨터 인터페이스 개발”, 「HCI2007」, 2007.
- [6] Brown, P., S. Stephan, J. C. Rothwell, and R. Hari, “Cortical Correlate of the Piper Rhythm in Humans”, *The Journal of Neurophysiol-ogy*, Vol.80, No.6(1998), pp.2911-2917.
- [7] Childress, D. S., “An approach to powered grasp”, in *4th Int. Symp. External Control Human Extremities : Adv. External Control of Human Extremities*. Dubrovnik, Yugoslavia, 1972.
- [8] Englehart, K. and B. Hudgins, “A robust, real-time control scheme for multifunction myoelectric control”, *IEEE Transactions on Biomedical Engineering*, Vol.50(2003), pp. 848-854.
- [9] Englehart, K., B. Hudgins and P.A. Parker, “A wavelet-based continuous classification scheme for multifunction myoelectric control”, *IEEE Transactions on Biomedical Engineering*, Vol.48(2001), pp.302-311.
- [10] Haykin, S., *Neural Networks : a comprehensive foundation, 2/e*, Prentice Hall(1999), pp. 10-13, pp.156-173.
- [11] Jingdong, Z., X. Zongwu, J. Li, C. Hegao, L. Hong and G. Hirzinger, “A Five-fingered Underactuated Prosthetic Hand Control Scheme”, *The First IEEE/RAS-EMBS International Conference on Biomedical Robotics and Biomechanics*, 2006.

## ◆ 저 자 소 개 ◆

**곽재경 (jk\_kwak@korea.ac.kr)**

현재 고려대학교 전산학과 소프트웨어 엔지니어링 연구실에서 석사 과정 중이며, 세종대학교 컴퓨터 공학과를 졸업하였다. 주요 관심분야는 소프트웨어 아키텍처와 디자인패턴 분야이다.

**전태웅 (jeon@korea.ac.kr)**

현재 고려대학교 컴퓨터정보학과 교수로 재직 중이다. 서울대학교 계산통계학과에서 학사 및 석사 학위를 취득하였고 Illinois Institute of Technology에서 전산학 박사 학위를 취득하였다. 금성통신과 LG산전에서 연구소 책임연구원으로 재직하면서 산업용 자동화 시스템 소프트웨어들을 개발하였다. 주요 관심분야는 소프트웨어 아키텍처, CBD 방법론, 소프트웨어 테스트 등이다.

**박흥웅 (gmadyd@nate.com)**

고려대학교 제어계측공학과 학사, 고려대학교 제어계측공학과 메카트로닉스 전공 비선형 제어 연구실 석사과정에 재학 중이며 주요 관심분야는 비선형 제어이다.

**김성진 (novel@kaist.ac.kr)**

한국과학기술원 산업디자인학과 및 Business Economics 부전공 학사, 한국과학기술원 산업공학과 학·석사 연계 과정에 재학 중이다. 대한민국 최연소 신지식인 선정, 제 18회 한국정보올림피아드 대상(정보통신부장관상), 제 15회 정보문화상 최연소 국무 총리상, 제2회 전국 대학생 소프트웨어 경진대회 금상을 수상한 바 있으며 주요 관심분야는 e-비즈니스, ERP, 정보화 전략 등이다.

## ◆ 저 자 소 개 ◆



안 광 덕 (hinary29@lycos.co.kr)

원광대학교 자연과학대학 반도체학과 학사, 충북대학교 전기공학 석사과정에 재학 중이다. Soc Robot War 학생 자문단 회장을 역임하였고 현재 SoCium 참여연구원이다 주요 관심분야는 반도체 공정 모니터링이다.