

# 신경회로망을 이용한 음성인식과 그 학습

正會員 李 權 鉉\*

## Speech Recognition and Its Learning by Neural Networks

Kwon Hyun LEE\* *Regular Member*

**要 約** 본 논문에서는 전화번호 서비스시 사용되고 있는 영(zero)에서 일까지 2종류의 숫자음(한글발음의 생수와 한자발음의 임음수) 22개에 대하여 신경회로망을 이용한 음성인식 실험의 결과와 학습과정에서 나타난 세 현상에 관해 논하였다.

신경회로망은 입력단과 출력단만을 갖는 2단구조와 한개의 은닉단을 갖는 3단구조의 회로망으로 은닉단의 뉴런(Neuron) 수를 11, 22 및 44개로 가변해 가면서 BP(Back-Propagation) 알고리즘에 의하여 학습하였고 학습과정에서는 학습팩터(Learning factor), 학습방법(예로써 Random or Cycle), 모멘텀(Momentum)등을 조정해 가면서 최적의 학습과정을 찾고자 하였다.

실험결과 2단구조에 의한 화자독립의 경우 최고 96%의 인식율을 나타냈고 학습과정이 너무 많은 경우 오히려 인식율이 낮아졌으며 이 현상은 3단구조의 회로망에서 더욱 두드러지게 나타났다.

**ABSTRACT** A speech recognition system based on a neural network, which can be used for telephone number services was tested.

Because in Korea two different cardinal number systems, a Koreanic one and a sinokoreanic one, are in use, it is necessary that the used system is able to recognize 22 discrete words.

The structure of the neural network used had two layers, also a structure with 3 layers, one hidden layer formed of each 11, 22 and 44 hidden units was tested. During the learning phase of the system the so called BP-algorithm (back-propagation) was applied. The process of learning can be influenced by using a different learning factor and also by the method of learning(for instance random or cycle).

The optimal rate of speaker independent recognition by using a 2 layer neural network was 96%. A drop of recognition was observed by overtraining. This phenomenon appeared more clearly if a 3 layer neural network was used. These phenomena are described in this paper in more detail.

Especially the influence of the construction of the neural network and the several states during the learning phase are examined.

### I. 서 론

말은 정보교환 수단중에서도 가장 자연스럽고 간단하면서도 신속하게 이루어질 수 있는 수단중의 하나다. 예로써 오늘날의 컴퓨터화 시대에서 키보드(keyboard)를 통한 자동명령을 직접 말로

써 그 대행이 가능하다면 즉, 인간과 기계와의 관계를 음성으로 해결할 수만 있다면 우리 생활 전반에 걸쳐서 가장 획기적인 기술혁명이 될 것이다. 이와 같이 기계와 인간과의 관계를 말음 통해서 연결시키고자 하는 소위 음성인식 기술에 대한 연구가 활발히 진행되고 있으며 특히 최근에는 병렬성을 이용한 대량정보의 신속한 처리와 비선형적 특징 및 학습의 기능등 장점을 지닌 신경회로망을 이용한 음성인식 기술의 개발에 지대한 관심을 갖게 되었다<sup>(1)(2)</sup>.

\*東新大學 電子工學科  
Dong-Shin University  
論文番號 : 91-34(接受1991. 2. 6)

일반적으로 음성신호에 대한 정확한 인식을 위해서는 입력된 음성신호의 주파수 분석을 기초로 단어의 시작과 끝점의 검출, 잡음 등 음성인식에 장애가 되는 요소를 최대한 줄이는 일련의 전처리과정을 통하여 음성신호의 특징 추출을 하게 되고 이 신호는 음성인식 장치에 저장시킴 놓는다. 이어서 테스트단어(test pattern)가 입력되면 테스트단어에 대한 특징과 기 저장된 참고 단어(reference word)의 특징을 비교해가며 인식을 결정하는 방법이 dynamic programming등을 이용한 기존의 인식방법에서 갖는 분류(classification) 과정 이라고 하겠다<sup>43)</sup>. 그러나 본 연구에서 이용한 신경회로망 인식시스템에서는 수학적 모델이나 알고리즘을 통해서 분류상의 문제점을 해결하였다. 즉, 신경회로망내에서 학습을 통해 분류과정을 갖게 되는데 이 때의 학습과정(learning process)에서는 reference word에 기초를 두지 않고 연결세기(weight factor)의 조절을 통해서 분류가 가능하도록 중요 정보를 저장해 놓는다. Test pattern이 신경회로망을 통과할 때 weight factor가 일어나고 이것을 통해서 학습시 확정지워진 특징에 덧붙여 가브로서 인식의 결정과 학습정도에 따라서는 최적 인식율에 도달하게 된다<sup>44)</sup>. 또한 신경회로망은 이미 학습을 통하여 weight factor가 설정된 음성데이터와 새로운 화자로부터 음성데이터를 추가한 후 계속해서 학습할 경우라도 먼저 설정된 weight factor의 손실없이 특징을 지워나가는 장점을

갖고 있다. 본 논문에서는 이와 같은 학습을 통해서 음성의 특정분류와 인식율의 향상을 기할 수 있는 장점을 이용하여 전화번호 서비스시 사용되는 숫자음의 인식시험을 시도하였다. 본 시험에 적용된 신경회로망의 구조는 2단구조 및 한개의 은닉단을 갖는 3단구조의 신경회로망으로서 3단구조를 이용한 시험에서는 은닉단의 뉴론수를 숫자음데이터의 절반에 해당되는 11개와 숫자음과 같은 23개 및 2개의 44개를 적용해가면서 최적의 학습방안을 찾고자 하였다.

그림 1은 본 연구의 음성인식 시스템에 대한 구성도이다.

## II. 학습알고리즘

신경회로망을 이용한 음성인식 시스템으로는 BP(back-propagation) 신경망, 자율조직(self-organization) 신경망, Hopfield neural network 및 Boltzmanmachine<sup>6)7)8)</sup>등을 들 수 있으며 학습 방법으로는 주어진 입력에 대해서 원하는 출력을 미리 정해주고 훈련시키는 지도학습(supervised learning)과 출력을 정해주지 않은 채 학습시키는 자율학습(unsupervised learning)의 두가지로 분류할 수 있다<sup>6)9)</sup>. 본 연구에서는 지도학습방법의 BP신경회로망을 적용하였으며 그림 2는 본 연구에 적용했던 회로망구조중의 하나인 3단구조의 신경회로망이다.

BP알고리즘은 Rumelhart와 Hinton<sup>6)</sup>에 의해

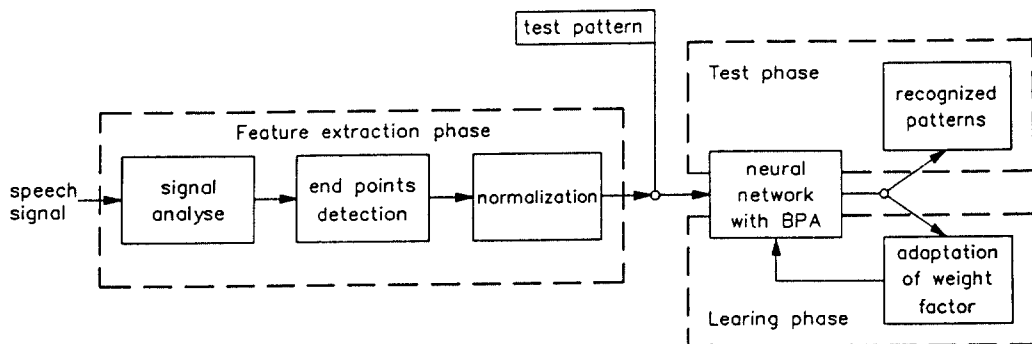


그림 1. 신경회로망을 이용한 음성인식 시스템의 구성도.  
Fig. 1 Structure of speech recognition system by neural network




그림 2. 지도 학습의 3단 신경회로망  
Fig. 2. Super vised learning 3 layer neural network

개발되었는데 그것은 어떤 Pattern이 입력단(input layer)으로 부터 출력단(Output layer)으로 진행함에 따라 각 단의 뉴론은 바로 전(앞)단 뉴론의 weight가 곱해져서 출력으로 보내어지고 여기서 만들어진 출력값은 다시 곱 weight가 곱해져 최종출력단에 도달하게 되는데 실제 출력된 값과 기대 출력값과의 차이에 대한 제곱값(오차값)을 최소화 하는데 있다. 이들 오차값은 회로를 역 방향으로 진행하면서 각종의 weights를 수정해 간다. 이 때 뉴론들의 활성화수(active function)로는 주로 sigmoid 함수  $f(x) = \frac{1}{1 + \exp^{-x}}$  을 적용하는데 이 함수는 비분위 가능하고 점진적인 증가치를 갖는다. 학습초기시 각 뉴론들이 갖는 극히 적은 값인 weight는 점차적인 학습횟수를 통해서 재 형성 되어진다. 본 연구에 적용했던 BP신경망의 알고리즘에 대한 단계별 설명은 다음과 같다.

단계 1 : 입력단 패턴( $X_i, i=1 \dots i$ )의 제공과 요구하는 출력단 패턴값을 제시한다. 본 연구에서는 활성화치(active output value)를 0.9 이상으로 나머지 뉴론들에 대한 active output value를 0.1 이하로 요구하여 학습했다. 어떤 뉴론의 출력값이 아주 높은 값( $>0.9$ )을 나타내고 기타 모든 다른 뉴론들의 출력값이  $<0.1$ 을 나타냈을

때 이 패턴의 특징분류(feature classification : F)는 완성되었으며 그것으로 부터 기대하는 출력값들( $e_n, n=1 \dots k$ )이 가능하다. 즉,  $n=F$ 이면  $e_n=1, n \neq F$ 이면  $e_n=0$ 이 된다.

단계 2 : 각 뉴론들의 실제적인 active value ( $Z_n, n=1 \dots k$ )의 계산.

$$Y_m = f\left(\sum_{i=1}^i X_i \cdot W_{X_i Y_m} - \theta\right) \quad (1)$$

여기서

$f$  : 뉴론 m의 active function

$X_i$  : 뉴론 m의 전(앞)단 뉴론 i에 대한 activity.

$W_{X_i Y_m}$  : 앞단의 i번째 뉴론과 m번째 뉴론 사이의 weight.

$\theta$  : m 뉴론의 threshold 값.

i : m 뉴론 앞단의 모든 뉴론들에 대한 index ( $i=1 \dots 22$ )

식(1)과 같이 주어진 입력패턴  $X_i$ 로 부터 은닉단 뉴론들의 active value  $Y_m$ 을 구하고 다시 계속하여 은닉단으로 부터 출력단 뉴론들에 대한 active value  $Z_n$ 을 계산한다.

$$Z_n = f\left(\sum_{m=1}^m Y_m \cdot W_{Y_m Z_n} - \theta\right) \quad (2)$$

단계 3 : weight 및 threshold 값의 수정.

출력단과 은닉단에 대한 weight 및 threshold 값의 수정은 식(3)의 보정 알고리즘에 의하여 교정되어진다.

$$\text{출력단 : } W_{Y_m Z_n}^{(t+1)} = \alpha \cdot W_{Y_m Z_n}^{(t)} + \eta \delta_{Z_n Y_m} \quad (3)$$

여기서  $\alpha$  = momentum

$\eta$  = learning factor ( $< 1$ )

$$\theta_n^{(t+1)} = \theta_n^{(t)} + \eta \cdot \delta_{Z_n} \quad (4)$$

은닉단 :

$$W_{X_i Y_m}^{(t+1)} = \alpha W_{X_i Y_m}^{(t)} + \eta \delta_{Y_m X_i} \quad (5)$$

$$\theta_m^{(t+1)} = \theta_m^{(t)} + \eta \cdot \delta_{Y_m} \quad (6)$$

식(3)의 교정팩터(corrector factor)  $\delta_{zn}$ ; 이는 기대했던 출력단의 출력값  $e_n$ 과 현실적으로 출력단에 출현된 값(actual output)  $Z_n$  사이의 오차를 이용한 것으로

$$\delta_{zn} = Z_n(1 - Z_n)(e_n - Z_n) \quad (7)$$

와 식(5)의 교정팩터  $\delta_{ym}$ :

$$\delta_{ym} = Y_m(1 - Y_m) \sum_{n=1}^{\infty} \delta_{zn} \times W_{ymzn} \quad (8)$$

으로써 이러한 과정이 기대하는 출력값에 도달할 때까지 반복된다. 또한 식(3)과 (5)에서 momentum  $\alpha$ 는 앞 단계의 계산에서 나타난 weight의 변화를 다음 단계에 반영시켜서 학습과정시 수렴의 속도를 촉진시켜주는 역할을 한다. 학습과정에서의 학습횟수는 오차의 조정(control)으로 결정짓게 되는데 이 오차의 크기는 e-function에 의해 점진적으로 적어지는 관례를 나타내며  $\delta_z=0$ 일 때 이는 더 이상의 교정이 필요치 않게 되고 학습과정은 종결짓게 된다.

### Ⅲ. 실험결과 및 분석

#### 1. 음성자료 및 실험방법

음성자료 :

이곳 독일에서 15년 이상 체류하고 있는 40대 교포 남녀 1명씩과 20대 유학생 남녀 2명씩 총 6명이 22개의 숫자음(「하나」에서 부터 「열」, 「일」에서 부터 「십」 그리고 「영」, 「공」)을 각각 1번, 2번, 4번 및 6번씩 발음한 총 132, 264, 528, 792개의 음성데이터를 학습용 데이터로 사용했고 또 다른 4명의 남성으로 부터 4번씩 발음한 총 352개의 음성데이터는 테스트용 데이터로 이용하였다.

실험방법 :

본 실험은 방음장치가 되었지 않고 컴퓨터용 프린터 및 기타 잡음이 있는 보통 사무실에서 마이크를 통하여 학습용과 테스트용 음성자료를

입력시켰으며 3.5KHz 저역통과 필터를 거쳐 8KHz로 정규화(normalized value)한 샘플링을 12Bit의 A/D로 변환시켜 ATARI-ST 컴퓨터의 신경회로망에 저장시켰고 시뮬레이션에 사용된 언어는 C언어이다.

#### 2. 결과 및 분석

시험패턴(test pattern)에 대한 인식율은 각 실험종류에 의해서 많은 차이를 나타냈다. 그림 3은 2단구조의 회로망에서 화자 6명이 6번씩 발음했던 학습용 패턴을 가지고 learning factor와 momentum의 숫치를 고정한 경우와 조정을 해가면서 훈련한 후의 인식 결과를 나타낸 것이다.




그림 3. 학습팩터 및 모멘텀 가변에 의한 인식율 비교  
Fig. 3. Comparison of recognition rates by learning factor  $n=0.9, \alpha=0.9$  and  $n=0.7, \alpha=0.8$

곡선A는 학습팩터  $\eta=0.9$ 와 momentum  $\alpha=0.9$ 로써 학습초기부터 종료까지 고정상태로 학습한 결과이고 곡선B는 학습초기에는 학습팩터  $\eta=0.9$ 와 모멘텀  $\alpha=0.9$ 로 실시하다가 학습횟수 3000번부터는  $\eta=0.7, \alpha=0.8$ 로 바꾸어서 훈련한 실험 결과이다. 곡선 A는 학습팩터와 모멘텀이 커서 학습속도가 증가한 현상을 나타냈으나 패턴에 대한 특징추출의 분류작업이 섬세하게 진행되지 못하므로서 최고의 인식율에 수렴하지 못하고 진동현상이 일어났으나 이와는 달리 B곡선에서

는 학습속도는 늦어졌으나 최고 인식율에서 약간의 좋은 결과(~1%)를 나타냈고 지속적으로 최고 인식율에 수렴하였으며 진동현상은 45000번의 학습횟수에서부터 나타나기 시작하였다. 따라서 본 실험에서 발표된 모든 인식결과는 학습패턴과 모멘텀을 조정해가면서 학습한 실험 결과이다.

다음 그림 4는 2단구조의 신경회로망에서 학습패턴을 각각 1번, 2번, 4번 및 6번씩 발음한 숫자음에 대한 학습횟수별 인식결과이다.




그림 4. 2단 신경망에 의한 음성인식률  
Fig. 4. Speaker-independent speech recognition rates by 2 layer neural network.

각 화자가 1번씩 발음한 학습패턴의 경우는 최고 인식율이 84%이나 6번씩 발음한 학습데이터의 인식율은 최고 96%로 이는 많은 학습용 데이터를 가지고 학습하므로 높은 인식율을 기대할 수 있음을 나타내고 있다. 그러나 4번씩 발음한 경우와 6번씩 발음한 학습데이터의 실험에서는 큰 차이가 없음을 발견할 수 있는데 이는 한 화자가 발음한 아무리 많은 횟수의 음성데이터를 학습용 패턴으로 적용한다 하더라도 인식율에 있어서는 크게 향상되지 못함을 알 수 있다. 즉 이는 특징분류상 큰 차이점이 없기 때문이다. 또한 그림에서 학습단어의 숫자가 적으면 적을수록 적은 학습횟수에서 최고의 인식율을 나타내며 그 이후 학습횟수의 증가에 따라 인식

율의 빠른 퇴조현상을 보인다. 이와는 반대로 학습단어가 많으면 많을수록 최고 인식율에 이르기까지 많은 학습횟수를 요하게 되는데 본 실험에서 6번씩 발음한 학습데이터의 경우 그림상에 나타나지 않았으나 약 45000번까지는 최고의 인식율에 머물다가 그 이후의 학습횟수에서는 진동현상이 일어났으며 75000번의 학습횟수에서는 87%의 낮은 인식율을 보였다. 이는 입력된 학습용 단어에 대하여 과다한 학습에서는 학습패턴에 대한 너무 정확한(또는 세밀한) 특징분류작업이 실시되 인식의 영역이 좁혀져 버리기 때문이다. 이와 같은 현상은 그림 5에서와 같이 은닉층(hidden layer)이 있는 경우에는 더욱 두드러지게 나타나고 있다.




그림 5. 3단 신경망에 의한 음성인식률  
Fig. 5. Speaker-independent speech recognition rates by 3 layer neural network.

그림 5는 각 화자가 6번씩 발음한 학습패턴을 hidden layre의 neuron수가 11, 22, 44개인 신경망에 훈련한 결과로써 2단구조와 비교하여 아주 빠른 학습속도를 보이고 있으나 최고인식율이 지속되지 못하고 감소현상을 보이는데 특히 44개의 뉴론수를 갖는 구조에서는 이 현상이 더욱 뚜렷하게 나타났다. 이는 2단구조에서 설명된 바와 같이 과다한 학습훈련의 경우 특징분류가 너무 세분화되어 시험패턴의 유사성에 대한 여유(tolerance)가 적어지기 때문이며 뉴론수가 많은 경우 이 경향은 적은 학습횟수에서도 나타난다. 그러나 대량단어의 훈련에서는 다층 신경회로망

의 적용으로 높은 인식율 및 훈련시간의 단축을 기대할 수 있다<sup>(9)(11)</sup>.

2단 회로망에서의 최적학습은 약 20,000~30,000회수에서 형성됐지만 3단회로망에 있어서는 분명한 학습회수를 제시하기는 어려우나 22개 및 44개의 뉴론을 갖는 구조에서는 3,000~5,000의 훈련회수에서 최고인식율에 도달할 수 있었다.

본 실험의 결과를 통해 각 회로망 구조에 따른 인식율은 물론 어떤 구조에서 인식의 확실성을 제공할 수 있는지의 판정방법을 찾아냈다. 이때 단어인식의 결정기준으로 threshold값의 결정법을 이용했다. 시험패턴이 출력단에 바르게 인식될 수 있는 확실성은 식(9)에 의해 산정했다.

$$Z_{diff} = \frac{Z_{out} - Z_{er}}{Z_{out}} \quad (9)$$

여기서,

$Z_{out}$  : 테스트패턴과 동일한 뉴론의 actual output 값.

$Z_{er}$  : 테스트패턴 이외의 뉴론들이 갖는 actual output 값.

그림 6은 학습과정이 이뤄진후 「열」의 테스트패턴을 입력시켰을 때 출력단 22개의 뉴론들에 나타난 각 뉴론들의 actual output값을 threshold값에 따라 모니터(Monitor)상에 막대그래프로 나타낸 것이다.

그림 6에서 「열」의 테스트패턴 출력세기는 0.7을, 그 다음으로 큰 값의 뉴론은 「영」으로




그림 6. 시험패턴의 threshold 값

Fig. 6. Threshold value of the test Pattern.

0.65값을 나타내고 있다. 이 때 이 테스트패턴이 항상 옳게 인식되어질 확신통은 식(9)에 의해  $Z_{diff}=0.7$ 이 된다.

만약 그림 6에서 「열」의 세기가 0.7대신 0.3의 값을 그리고 「영」의 출력값이 0.25를 나타내었다면 이 때의  $Z_{diff}=0.17$ 로써 후자의 경우에서 비록 인식출력값의 절대치는 작을지라도 상대적으로 확실한 인식을 기대할 수가 있다. 즉,  $Z_{diff}$  값이 Zero에 가까워지면 실수용 화자가 변경되거나 인식시험의 환경등, 테스트 조건이 조금만 달라질 경우우라도 그 테스트 패턴은 잘못 인식된 확률이 증가하게 된다.

그림 7은 화자 6명이 6번씩 발음한 음성에 대하여 2단 및 3단구조의 신경망에서 실험한 결과 최고의 인식율을 나타낸 weight 를 가지고 식(10)을 이용하여 계산된 인식의 확신통을 도시한 것이다.

$$Z_{m-diff}(i) = \frac{1}{n} \sum_{k=1}^n Z_{diff}(i) \cdot k \quad (10)$$

여기서,

$n$ : 한 패턴에 대한 총 테스트 횟수(여기에선  $n=16$ )

그림 7에서 가로축의 index  $i$ 는 출력단 22개의 뉴론수를 나타낸 것이며 테스트 음성에 대한 index는 0으로, 그리고 식(10)에 의해 가장 큰 값에서 부터 가장 적은 값까지 단계별 차이를 표시한 것이다. 그리고 index 0으로 부터 좌측의 “-” 부호 index는 테스트패턴에 대한 오인식된 경우로 그림의 우측 상단 하강곡선 부분이 이에 상응되는 부분이다.

그림 7에서 2단 구조의 신경회로망이 3단구조의 신경회로망에 비하여 확실하게 인식된 확률이 높음을 보여주고 있다. 또한 3단구조의 신경망에서 22개의 은인뉴론을 갖는 회로망이 44개의 은인뉴론을 갖는 회로망에 비하여 인식율에서는 약 1% 정도 낮은 결과를 보이지만 실험조건외 변동에도 최고 인식율의 유지가 가능하겠으나 이와 달리 44개의 뉴론을 적용한 회로망에선

최고 인식율로 기록된 96%에서 약간의 변동이 예측된다.

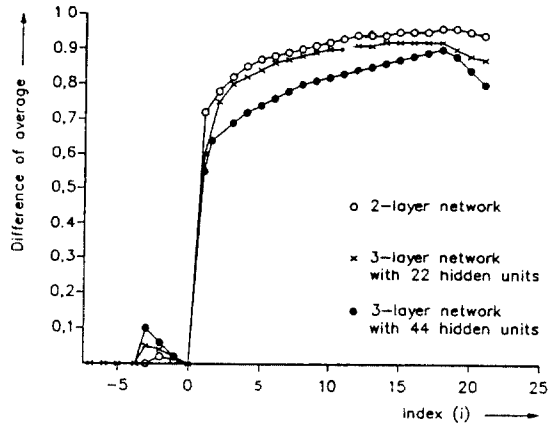


그림 7. 인식의 확신통.

Fig. 7. Certainty of recognition ratio.

#### IV. 결 론

본 연구에서 채택한 22개의 숫자음에 대한 화자독립-인식실험은 최고 96%의 높은 인식율을 보였다. 그러나 본 실험에서 채택한 숫자음의 대부분이 거의 유사한 음절 및 음소로 구성되어 있어 단어별 인식에서는 100%에서 최하 81%로 큰 차이를 나타내고 있는데 「열」과 「이」, 「다섯」과 「어섯」을 서로 바꿔서 인식되는 경우가 있었고 「셋」은 「넷」으로, 「넷」은 「영」으로, 「열」은 「영」으로, 「구」는 「오」등으로 잘못 인식되는 경우가 있었다.

그러므로 이들 숫자음에 대해서는 테스트 발음시 좀더 명확한 발음에 주의를 한다면 더욱 향상된 인식율을 보일 것으로 전망되며 화자선택성지능일이라는 지역적 특성때문에 각종의 화자들로부터 음성샘플을 취득하기가 어려웠고 테스트 화자들간의 발음상 많은 차이가 있어서 인식 결과에 제한이 따랐지 않나 생각된다.

본 연구의 3단구조 신경회로망에서 최고 인식 지점이 계속 지속되지 못하고 곧바로 감소현상을 나타낸 결과에 대해서는 다층 BP 알고리즘에서

볼 수 있는 현상으로 밝혀지고 있으나 보정 알고리즘의 적용과 좀더 다양한, 즉 성별, 연령별 및 지역별이 고려된 학습용 데이터를 이용한 실험이 이뤄진다면 최고 인식율의 향상과 최고 인식율의 지속을 연장할 수 있으리라 사료된다.

이 논문은 한국과학재단 연구비 지원으로 이루어 졌습니다.

### 參 考 文 獻

1. 은종관, 유성에 의한 Man Machine Communication 기술의 현황, 전자공학회지, 제15권 2호, pp. 210~222, 1988.
2. 이수영, 신경회로망의 통신분야 응용, 한국통신학회지, 제7권 3호, pp. 182~187, 1990.
3. K. Sickert, Automatische Spracheingabe und Sprachausgabe, Markt & Technik verlag, pp. 223~405, 1983.
4. B. Hosticka and P. Richert, Sprecherunabhängige Spracherkennung mit neuronalen Netzen, Pattern Recognition DAGM-Syposium proceedings, pp. 551~558, 1989.
5. R.P. Lippmann, An Introduction to Computing with Neural Nets, IEEE ASSP Magazine, Vol. 4, pp. 4~22, 1987
6. P. Richert, Entwicklung eines Sprecherunabhängigen Spracherkennungssystem mit neuronalen Netzen, VDI Verlag, pp. 78~82, 1990.
7. T. Kohonen, The Neural Phonetic Typewriter, IEEE Computer, pp. 11~22, March 1988.
8. D.E. Rumelhart, G.E. Hinton and R.J. Williams, "Learning internal Representations by Error Propagation" in Parallel Distributed Processing, Vol. 1, The MIT Press, pp. 318~362, 1986.
9. H. Reininger and D. Wolf, "Nonlinear Prediction of Stochastic Processes using Neural Networks" in Signal Processing, Elsevier Science Publishers B.V, pp. 1623~1624, 1990
10. J. Shynk and S. Roy, Analysis of a Perceptron Learning Algorithm with Momentum updating, IEEE Int. Conf. Acoust., Speech Signal Processing, pp. 1377~1380, April 1990.
11. Y. Chauvin, Generalization Performance of Overtrained Back-Propagation Networks, Neural Networks EURASIP workshop 1990, pp. 46~55, Feb. 1990.



李 權 鉉 (Kwon Hyun LEE) 正會員  
 1950年 4月 24日生  
 1972年 2月 : 朝鮮大學校 電氣工學科 (工學士)  
 1976年 9月 : 延世大學院 電氣·電子專攻 (工學碩士)  
 1985年 5月 : 西獨 Duisburg 大學院 器具設計學 (工學博士)  
 1985年 9月 : 現代重電機(株) 技術研究所 責任研究員

1986年 5月 : 三星電子部品(株) 技術研究所 責任研究員  
 1987年 3月~ : 東新大學 電子工學科 副教授  
 1990年 6月~1990年 8月 : 西獨 KAAD 裝學財團 招請 研修 (Duisburg 大學校 精密機械器具研究所)  
 1990年 9月~1991年 現在 : 韓國科學財團支援 Post-Doc 研修中 (西獨 Aachen 工科大學 情報通信機器研究所)