

회귀신경망을 이용한 음성인식에 관한 연구

A Study on Speech Recognition using Recurrent Neural Networks

한 학 용*, 김 주 성*, 허 강 인*

(Hag Yong Han*, Joo Sung Kim*, Kang In Hur*)

요 약

본 논문은 회귀신경망을 이용한 음성인식에 관한 연구이다. 예측형 신경망으로 음절단위로 모델링한 후 미지의 입력음성에 대하여 예측오차가 최소가 되는 모델을 인식결과로 한다. 이를 위해서 예측형으로 구성된 신경망에 음성의 사변성을 신경망 내부에 흡수시키기 위해서 회귀구조의 동적인 신경망인 회귀예측신경망을 구성하고 Elman과 Jordan이 제안한 회귀구조에 따라 인식성능을 서로 비교하였다. 음성DB는 ETRI의 샘들이 음성 데이터를 사용하였다. 그리고, 신경망의 최적 모델을 구하기 위하여 예측차수와 은닉층 유니트 수의 변화에 따른 인식률의 변화와 문맥중에서 자기회귀계수를 두어 이전의 값들이 문맥중에서 누적되도록 하였을 경우에 대한 인식률의 변화를 비교하였다. 실험결과, 최적의 예측차수, 은닉층 유니트수, 자기회귀계수는 신경망의 구조에 따라 차이가 나타났으며, 전반적으로 Jordan망이 Elman망보다 인식률이 높았으며, 자기회귀계수에 대한 영향은 신경망의 구조와 계수값에 따라 불규칙하게 나타났다.

ABSTRACT

In this paper, we investigate a reliable model of the Predictive Recurrent Neural Network for the speech recognition. Predictive Neural Networks are modeled by syllable units. For the given input syllable, then a model which gives the minimum prediction error is taken as the recognition result. The Predictive Neural Network which has the structure of recurrent network was composed to give the dynamic feature of the speech pattern into the network. We have compared with the recognition ability of the Recurrent Neural Network proposed by Elman and Jordan. ETRI's SAMDORI has been used for the speech DB. In order to find a reliable model of neural networks, the changes of two recognition rates were compared one another in conditions of: (1) changing prediction order and the number of hidden units; and (2) accumulating previous values with self-loop coefficient in its context. The result shows that the optimum prediction order, the number of hidden units, and self-loop coefficient have differently responded according to the structure of neural network used. However, in general, the Jordan's recurrent network shows relatively higher recognition rate than Elman's. The effects of recognition rate on the self-loop coefficient were variable according to the structures of neural network and their values.

I. 서 론

최근 다양한 구조의 신경망으로 패턴인식, 시스템 모델링, 비선형 예측등과 같은 분야에 널리 사용되고 있다. 특히 MLP는 정적패턴의 인식에는 우수한 성능을 보이지만, 음성과 같이 시간에 따라 특성이 변화하고 동일화자라도 발생속도에 따라 시간축 길이가 다른 동적 패턴의 인식에는 적합하지 못하였다. 따라서 이러한 시계열 동적 패턴을 음성인식에 적용하기 위한 몇 가지 신경망이 제안되었다.

정적인 패턴분류를 위해서는 주로 정적구조의 MLP를 사용하여 구성하며, 메모리가 없는 처리요소를 사용한다.

MLP는 패턴을 분류하기 위한 임의의 식별곡선을 형성할 수 있을 뿐만 아니라, 오류역전파(Error Back-Propagation)라는 강력한 학습규칙이 존재하기 때문에 많은 분야에서 뛰어난 성능을 발휘하고 있다. 반면에 음성과 같은 시계열 동적 패턴인 경우에는 동적 신경망으로 망 내부에 어떠한 형태로든 메모리를 갖게 하여서 과거의 입력이 현재의 출력에 영향을 주게 하여 입력신호의 문맥을 학습할 수 있도록 하여야 한다. 이것은 다시 전향에 의한 것과 회귀에 의한 것으로 나뉘어지며, 널리 알려진 TDNN(Time-Delay Neural Network)의 경우는 전자에 해당한다. TDNN은 MLP로 구성된 전향 신경망에 시간지연 개념을 도입한 것으로서 음소인식 및 신호예측에 적용한 예가 보고되고 있다. 이와 유사한 것으로 최근에 보고된 ATNN(Adaptive Time-Delay Neural Network)은 TDNN이 고정된 지연을 갖고 있음에 착안하여 가변지연을 구현한

* 동아대학교 전자공학과
접수일자: 1998년 11월 17일

것으로서 신호예측에 적용하여 TDNN보다 향상된 결과를 얻고 있다.¹¹⁾

이와는 다르게 회귀신경망으로 동적 신경망을 구성할 경우에는 출력층과 은닉층의 활성화 값을 회귀시키는 구조를 취하여 메모리를 구성하고 있다. 회귀신경망은 Hopfield망¹²⁾을 효시로 하여 Jordan망¹³⁾과 Elman망¹⁴⁾이 대표적이며, 이를 일반화시킨 Williams-Zipser망¹⁵⁾을 비롯한 많은 종류가 있다.

본 논문에서는 다양한 길이를 가진 음성과 같은 동적 패턴의 인식을 위해서 예측신경망(Predictive Neural Network)과 회귀예측신경망(Predictive Recurrent Neural Network)을 구성하여 패턴예측기로 사용하고, 숫자음에 대한 인식 결과를 CHMM에 의한 인식결과와 비교하여 각 신경망 모델에 대한 인식성능을 서로 비교하였다.¹⁶⁾¹²⁾

II. 예측신경망¹⁶⁾¹⁷⁾

그림 1은 MLP에 의한 음성패턴의 예측기를 보여 주고 있다. 입력유니트에 음성특징벡터 $x_{t-\tau}, \dots, x_{t-1}$ 을 순차적으로 입력시킴으로서 예측된 특징벡터 \hat{x}_t 를 출력하도록 하는 것이다. τ 는 음성특징벡터의 프레임 번호를 나타내며, 다층 신경망의 입출력간의 관계는 식(1), (2)와 같다.

$$h_i = f \left(\sum_{j=1}^r w_j x_{t-j} \right) \quad (1)$$

$$\hat{x}_t = w_0 h_i \quad (2)$$

여기서, w_0, w_1, \dots, w_r 은 가중치 행렬을 나타내며, h_i 는 은닉층의 출력벡터, $f(x)$ 는 시그모이드함수로 벡터 x 의 각 요소에 대한 출력을 결정한다.

신경망의 학습규칙은 BP 알고리즘을 이용하였으며, 예측된 특징벡터인 \hat{x}_t 는 입력되는 음성특징벡터와 비교하여 이의 유클리디안 거리의 지승인 $\|x_t - \hat{x}_t\|^2$ 이 예측 오차값이 된다. 인식결과와는 이러한 예측오차값의 평균이 최소가 되는 모델로 한다.




그림 1. MLP 예측신경망
Fig. 1. MLP Predictive Neural Network.

III. 회귀예측신경망¹⁸⁾

회귀신경망은 회귀 구조에 따라 여러 가지 형태가 있으며, 학습 알고리즘도 시간에 따라 오차역전파 학습, RTRL(Real-Time Recurrent Learning)¹⁹⁾등이 있다. 또한 회귀형태에 따라 출력층의 활성화치를 회귀시키기 위해 문맥층을 마련한 Jordan망²³⁾과 은닉층의 활성화치를 회귀시키기 위해 문맥층을 마련한 Elman망¹⁴⁾등이 있다.

3.1 Elman형 회귀예측신경망

그림 2는 Elman형 회귀예측신경망의 구조를 나타내고 있다. 이 신경망은 입력층과 출력층 사이에 은닉층을 삽입하고, 은닉층의 모든 유니트는 문맥층으로 회귀연결되는 다층구조이다. 출력층에는 선형출력함수, 은닉층에는 비선형함수인 시그모이드 함수를 사용한다.




그림 2. Elman형 회귀예측신경망
Fig. 2. Elman Predictive Recurrent Neural Network.

$S^T = |s(1), \dots, s(T)|$ 를 음성의 발생시간 T 동안의 음성패턴이라 할 때 $s(t) = [s_1(t), \dots, s_M(t)]$ 는 시각 t 에서의 N 차원의 특징벡터이다. 시각 t 에서의 교사벡터를 $s(t)$ 라 할 때 예측차수가 r 인 경우, 입력벡터 $x(t) = [x_1(t), \dots, x_M(t)]$ 는 $s(t-1), \dots, s(t-r)$ 의 r 개의 벡터를 연결한 벡터이다. 은닉층의 전체입력값들로 이루어진 벡터를 $n(t) = [n_1(t), \dots, n_{H+N}(t)]$, 은닉층의 출력벡터를 $h(t) = [h_1(t), \dots, h_H(t)]$, 출력층의 출력벡터를 $o(t) = [o_1(t), \dots, o_N(t)]$ 라 하면, 교사벡터 $s(t)$ 에 대한 예측벡터 $\hat{s}(t)$ 는 출력벡터 $o(t)$ 와 같다. $n(t), h(t), o(t)$ 의 j 번째 성분 $n_j(t), h_j(t), o_k(t)$ 는 각각 다음과 같다.

$$\begin{cases} n_j(t) = \sum_{i=1}^{H+N} w_{ji} z_i(t) & j=1, \dots, H+N \\ h_j(t) = f(n_j(t)) & j=1, \dots, H \\ o_k(t) = \sum_{i=1}^N w_{ki} h_i(t) & k=1, \dots, N \end{cases} \quad (3)$$

여기서 w_{ji} 는 i 번째 입력층 유니트에서 j 번째 은닉층 유니트로의 연결 가중치이고, w_{ki} 는 i 번째 은닉층 유니트

와 k 번째 출력층 유니트로의 연결 가중치이다. $f(\cdot)$ 는 시그모이드 함수를 나타낸다.

그리고 $z_i(t)$ 는 시각 t 에서 입력벡터 $x(t)$ 와 시각 $t-1$ 에서의 은닉층의 출력벡터 $h(t-1)$ 를 연결한 $H+N$ 차원 벡터의 i 번째 성분이다.

$$\begin{aligned} z_i(t) &= [z_1(t), \dots, z_{H+N}(t)] \\ &= [h_1(t-1), \dots, h_H(t-1), x_1(t), \dots, x_N(t)] \\ &= [C_1(t), \dots, C_H(t), x_1(t), \dots, x_N(t)] \end{aligned} \quad (4)$$

여기서, $C_i(t)$ 는 문맥층의 벡터를 나타낸다.

시각 t 에서 교사벡터와 출력벡터 사이의 누적예측오차는 다음과 같다.

$$J(t) = \frac{1}{2} \sum_{k=1}^K [e_k(t)]^2 \quad (5)$$

여기서, $e_k(t) = s_k(t) - \hat{s}_k(t) = s_k(t) - o_k(t)$ 는 k 번째 유니트의 예측오차, 즉 교사값과 실제 출력값 사이의 오차를 나타낸다.

한편, 신경망 학습이 시작시각 t_0 에서 시작하여 최종 시각 T 에서 종료된다고 가정하면, 최종누적 예측오차 E 는 다음과 같다.

$$E = \sum_{t=t_0+1}^T J(t) \quad (6)$$

예측오차 제적을 최강강화법에 적용하면 가중치벡터, W 는 ∇E 의 음(negative)의 값으로 수정되어진다. 이 기울기는 각 단계마다 예측오차 제적을 따라 $\nabla J(t)$ 의 값을 누적함으로 계산되어진다. 신경망에서 어떤 특정 가중치 w_{ji} 와 w_k 에 대한 전체 가중치 변화는 다음과 같다.

$$\Delta w_{ji}(t) = -\alpha \frac{\partial J(t)}{\partial w_{ji}} = \alpha \sum_{k=1}^K e_k(t) \frac{\partial h_j(t)}{\partial w_{ji}} \quad (7)$$

$$\Delta w_k(t) = -\alpha \frac{\partial J(t)}{\partial w_k} = \alpha e_k(t) o_j(t) h_j(t) \quad (8)$$

여기서 α 는 학습률을 나타낸다.

신경망의 초기상태는 가중치에 대해서 함수적으로 독립이라고 가정하기 때문에 초기조건식은 다음과 같다.

$$\frac{\partial h_j(t_0)}{\partial w_{ji}} = 0 \quad (9)$$

그리고 회귀조건식은 다음과 같다.

$$\begin{aligned} \frac{\partial h_j(t+1)}{\partial w_{ji}} &= f'(n_j(t)) \left[\sum_{i=1}^H w_{ji} \frac{\partial h_i(t)}{\partial w_{ji}} + \delta_{ji} z_j(t) \right] \end{aligned} \quad (10)$$

그러므로, 각 시각 t 에 대해서 가중치 변화식은 아래와 같다.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t) \quad (11)$$

$$w_k(t+1) = w_k(t) + \Delta w_k(t) \quad (12)$$

3.2 Jordan형 회귀예측신경망

Jordan형 회귀예측신경망의 구조는 출력층의 모든 유니트가 문맥층으로 회귀연결되는 구조이다. 그리고 그림3 문맥층에 회귀계수를 적용한 Jordan형 회귀예측신경망의 구조를 나타내고 있다.




그림 3. Jordan형 회귀예측신경망
Fig. 3. Jordan Predictive Recurrent Neural Network.

문맥층에서 회귀계수를 적용하는 수식은 식(13)과 같다.

$$\begin{aligned} C_j(t+1) &= \mu C_j(t) + O_j(t) \\ &= \mu(\mu C_j(t-1) - O_j(t-1)) + O_j(t) \\ &= \sum_{\tau=0}^t \mu^{t-\tau} O_j(\tau) \quad (C_j(0) = 0) \end{aligned} \quad (13)$$

여기서, μ 는 자기회귀계수이며 0~1사이의 값을 설정한다.

IV. 인식실험 및 조건

4.1 음성 DB 및 분석조건

숫자음 데이터는 ETRI의 샘플이 데이터중에서 “영, 일, 이, 삼, 사, 오, 육, 칠, 팔, 구” 10개의 음성을 사용하였다. 이는 남성화자 20명이 10개 숫자음을 4회 발성한 총 800개의 데이터중에서 처음 3회분은 학습용(600개)으로 나머지 1회분은 평가용(200개)으로 사용하였으며 분석조건은 표1과 같다.

표 1. 음성데이터의 분석조건

Table 1. Analysis method of speech data.

Filtering	LPF, 7KHz
A/D 데이터	16KHz, 16bit, signed
프레임 간격	3.75 ms
분석창 길이	16 ms
특징 파라미터	10차 LPC Melcepstrum

4.2. 예측차수에 따른 패턴의 설정

그림 4는 예측차수에 따라 입력패턴과 교사패턴을 설정하는 방법을 나타낸다. 처음과 마지막 프레임이 교사패턴과 입력패턴으로 참여할 수 있게 하기 위해서 처음과 마지막 프레임을 복사하여 패턴을 설정한다. 이러한 전후 프레임에 대한 패턴설정 방법의 차이에 따라 서로 인식률에 큰 변화가 있음이 보고되어 있다.^[11]

이와 같이 설정되어진 패턴은 한 프레임씩 순차적으로 이동하면서 전음절구간에 대하여 신경망의 입력패턴과 교사패턴으로 사용된다.




그림 4. 예측차수에 따른 패턴 설정 방법
Fig. 4. Extension of pattern according to prediction order.

4.3 인식실험

신경망의 구조는 예측차수가 1차, 2차, 3차, 4차 일때 입력층은 각각 10, 20, 30, 40 유니트로 하고, 은닉층은 5,10,15,20 유니트로 변경하면서 실험하고 출력층은 10 유니트로 하여 한 프레임을 예측하도록 하였다. 그리고 회귀 연결한 Elman형과 Jordan형 모두 문맥층에서 회귀계수를 적용한 경우의 실험을 추가하였다.

표 3. MLP 예측신경망 인식결과[%]

Table 3. Recognition rate of CHMM for isolated digits.

예측차수	1				2				3				4			
	5	10	15	20	5	10	15	20	5	10	15	20	5	10	15	20
학습	89.6	97.0	98.0	97.5	89.2	97.2	98.8	99.3	89.5	98.5	98.7	99.5	90.3	97.8	99.3	97.8
평가	86.0	94.5	96.0	96.0	88.5	94.0	98.0	97.0	88.0	97.0	97.5	97.5	89.0	96.5	96.0	95.0

[방법 1] MLP 예측신경망

[방법 2] Jordan형 회귀예측신경망

[방법 3] Elman형 회귀예측신경망

[방법 4] Jordan형 회귀예측신경망
+ 문맥층에 회귀계수 적용

[방법 5] Elman형 회귀예측신경망
+ 문맥층에 회귀계수 적용

이들 신경망 모델은 각 입력에 대한 교사패턴을 그 다음의 프레임으로 설정하고 예측계적을 학습한다. 매 순간의 회귀입력은 음성의 시변성에 따라 결정되고, 예측오차는 매 순간마다 누적된다. 인식실험은 모든 네트워크들에 입력을 인가하여 평균예측오차가 가장 최소가 되는 모델을 인식결과로 하였다.

V. 실험결과 및 고찰

실험결과 평가용 데이터에서 CHMM은 5상태 4출력본포의 경우 99.0%(198/200)로 인식하였다. Jordan형 회귀예측신경망은 자기회귀계수를 설정하지 않은 경우 은닉층 유니트 20, 예측차수 4차에서 98.5%(197/200), 자기회귀계수를 설정하였을 경우에는 μ 가 0.4이고 은닉층 유니트수 20, 예측차수 3차에서 99.0%(198/200)으로 CHMM과 같은 인식결과를 나타내었다.

각 신경망 모델에 따른 인식성능은 예측차수와 은닉층 유니트의 개수에 따라 불규칙적인 변화를 보였다. 은닉층의 변화에 대해서 MLP 예측신경망과 Jordan형 회귀예측신경망은 은닉층의 유니트 수가 증가함에 따라 인식률이 향상되었다. 이것은 은닉층의 과도적인 정보가 문맥층으로 회귀되어 현재의 예측에 반영하는 Elman형 구조보다는 이전 출력층의 예측된 정보가 회귀되어 현재의 예측에 반영하는 Jordan형 구조가 신경망의 예측능력 향상에 유리하기 때문인 것으로 사료된다. 그러나 예측차수의 증가에 따라서는 두드러진 인식률의 향상을 보이지 않았다.

자기회귀계수의 변화에 따른 인식률은 신경망의 모델에 따라 불규칙하였다. 그러나 전반적으로 자기회귀 계수값이 0.4인 경우는 Elman망에서 우수하였으며, 자기회귀 계수값이 0.5인 경우는 Jordan망에서 우수한 인식률을 보였다.

표 2. CHMM에 의한 숫자음 인식률(%)

Table 2. Recognition rate of Predictive Neural Network.

상대수	학습	평가
4	98.7	98.5
5	100.0	99.0
6	99.3	98.0
7	99.8	98.0

표 4. 자기회귀계수를 적용하지 않은 회귀예측신경망 인식결과

Table 4. Recognition rate of Recurrent Predictive Neural Network.

예측차수		1				2				3				4			
은닉층수		5	10	15	20	5	10	15	20	5	10	15	20	5	10	15	20
학습	Jordan	88.5	98.5	98.0	98.5	88.3	97.2	98.7	99.2	90.2	98.3	98.5	99.2	90.0	97.2	99.5	99.7
	Elman	87.5	96.8	98.7	98.0	87.3	96.8	98.7	99.0	90.0	97.2	99.0	99.0	90.5	98.2	98.3	99.3
평가	Jordan	88.5	97.0	95.0	96.5	87.0	93.0	97.0	97.5	87.5	95.5	97.0	97.0	87.5	94.5	95.0	98.5
	Elman	87.0	91.5	94.5	93.0	87.0	94.0	95.5	95.0	89.0	95.5	95.5	94.0	88.5	97.5	95.5	95.0

표 5. 회귀예측신경망 인식결과[%] ($\mu=0.4$)

Table 5. Recognition rate of Recurrent Predictive Neural Network ($\mu=0.4$).

예측차수		1				2				3				4			
은닉층수		5	10	15	20	5	10	15	20	5	10	15	20	5	10	15	20
학습	Jordan	88.5	87.2	93.2	94.5	90.2	93.8	95.3	95.7	89.8	96.7	98.5	99.0	91.2	99.0	99.7	99.7
	Elman	86.5	96.0	98.3	97.8	89.3	98.2	98.8	98.8	89.5	97.3	97.7	98.7	91.0	98.0	99.5	99.2
평가	Jordan	87.0	87.0	91.5	97.5	87.5	95.0	94.0	97.0	88.5	95.0	97.0	99.0	88.0	97.5	95.5	97.0
	Elman	87.0	93.0	98.0	95.5	87.0	96.5	95.5	96.5	87.5	94.5	95.5	95.0	87.5	97.0	95.0	97.0

표 6. 회귀예측신경망 인식결과[%] ($\mu=0.5$)

Table 6. Recognition rate of Recurrent Predictive Neural Network ($\mu=0.5$).

예측차수		1				2				3				4			
은닉층수		5	10	15	20	5	10	15	20	5	10	15	20	5	10	15	20
학습	Jordan	88.3	96.7	96.8	97.7	90.8	97.2	97.7	99.0	90.2	96.2	99.2	99.5	90.2	98.5	99.5	99.5
	Elman	87.5	95.8	98.3	98.2	89.5	98.7	99.2	99.2	89.5	98.0	96.7	99.3	90.8	97.5	98.3	98.7
평가	Jordan	85.0	94.0	92.5	96.5	87.0	97.0	95.5	98.0	87.5	92.0	97.0	96.5	88.5	96.5	96.0	96.5
	Elman	85.5	92.0	96.0	93.0	88.0	96.0	97.0	96.5	87.5	94.0	94.5	96.5	87.5	94.5	94.0	94.5

표 7. 회귀예측신경망 인식결과[%] ($\mu=0.6$)

Table 7. Recognition rate of Recurrent Predictive Neural Network ($\mu=0.6$).

예측차수		1				2				3				4			
은닉층수		5	10	15	20	5	10	15	20	5	10	15	20	5	10	15	20
학습	Jordan	88.7	93.8	95.5	96.3	91.2	97.5	97.3	98.7	90.3	96.0	98.7	98.7	90.3	97.8	99.0	99.2
	Elman	87.3	96.0	97.7	97.5	89.0	98.2	98.7	96.2	89.3	97.2	98.2	98.5	90.7	96.7	98.3	99.0
평가	Jordan	84.0	90.5	94.0	95.5	87.5	96.5	95.5	98.0	88.5	93.0	96.0	95.5	88.5	96.0	96.5	96.0
	Elman	85.5	93.0	96.0	94.0	88.0	96.5	96.5	93.0	88.5	92.5	95.5	96.5	88.0	95.0	95.0	95.5

VI. 결 론

본 논문에서는 한국어 숫자음의 인식을 위하여 MLP 예측신경망, Jordan형과 Elman형 회귀예측신경망을 사용하여 예측차수와 은닉층의 유니트수의 변화와 자기회귀 계수에 따른 인식성능을 연속분포 HMM과 비교하였다.

실험결과 예측차수, 은닉층 유니트수, 자기회귀계수는 신경망의 구조에 따라 인식률은 서로 다르게 나타났으며, 전반적으로 Jordan망이 Elman망 보다 인식률이 양호하였다. 자기회귀계수의 변화에 따른 인식률은 신경망의 모델에 따라 불규칙적으로 변화하였다. 그러나 전반적으로 자기회귀 계수값이 0.4인 경우는 Elman망에서 우수하였으며, 자기회귀 계수값이 0.5인 경우는 Jordan망에서 우수한 인식률을 보였다.

회귀예측신경망으로 각 음절에 대하여 모델링 할 경우 HMM과 유사한 인식률을 얻을 수 있었다. 이는 추후 연속 음성에 대한 신뢰할 만한 음절단위의 분할이 이루어진다면 신경망을 이용한 연속음성인식에 적용 가능할 것이다.

참 고 문 헌

1. D. T. Lin, J.E. Dayhoff, and P.A. Ligomenides, "Adaptive time-delay neural network for temporal correlation and prediction," SPIE Intelligent Robots and Computer Vision XI: Bioloical, Neural Net, and 3-D Methods, vol. 1826, (Boston, November), pp.170-181, 1992.
2. J. J. Hopfield, "Neurons with Graded Response Have Collective Computational Properties Like Those of Two-State Neurons," Proceedings of the National Academy of Sciences USA, Vol. 81, pp.3088-3092, 1984.
3. M. I. Jordan, "Serial Order: A parallel distributed processing approach," Technical Report ICS-8604, Institute for Cognitive Science, University of California, Sab Diego, La Jolla, California, May 1986.
4. J. L. Elman, "Finding structure in time," Technical Report CRL-8801, Center for Reserch in Language, University of california, San Diego, La Jolla, california, April 1988.
5. R. J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks," Neural Computation, vol. 1, pp. 270-280, 1989.
6. Ken-ichi Iso and Takao Watanabe, " Speaker-Independent Word Recognition Using A Neural Prediction Model," Proc.ICASSP'90, pp.441-444, 1990.
7. K. Iso and T. Watanabe, "Large vocabulary speech recognition using neural prediction model," Proc. ICASSP'91, pp. 57-60, 1991.
8. 류재관, 라경민, 임재열, 성평모, 안수길, "회귀신경예측모델을 이용한 음성인식," 대한전자공학회 논문지, 제11권 B편, 제32권, 1995.
9. Joo-Sung Kim, Kwang-Suk Lee, Kang-In Hur, "The Recognition of Korean Syllables using Recurrent Prediction Neural Networks," ICASP, vol.1 of 2, pp.395-399, 1997.
10. Soo Hoon Kim, Sang-Boum, Kang-In Hur, "The Recognition of Korean Syllables Using Neural Predictive HMM,"

ICASP, vol1 of 2, pp.427-431, 1997.

11. 한학용, 김주성, 허강인, "패턴구성에 따른 RPNN의 음성인식 성능비교," 동아대학교 정보통신 연구소논문지, 제5권, 1호, pp.123-128, 1997.

▲ 한 학 용 (Hag Yong Han)

1968년 11월 1일생



1994년 2월 : 동아대학교 전자공학과(공학사)
 1994년 5월~1997년 3월 : 경남에너지(주) 근무
 1999년 2월 : 동아대학교 대학원 전자공학과(공학석사)
 1999년 3월 : 동아대학교 대학원 전자공학과 박사과정 재학중

*주관심분야: 패턴인식, 신호처리, 신경회로망

▲ 김 주 성 (Joo Sung Kim)

1967년 11월 23일생



1990년 2월 : 동의대학교 전자공학과(공학사)
 1993년 2월 : 동아대학교 대학원 전자공학과(공학석사)
 1997년 2월 : 동아대학교 대학원 박사과정 수료

*주관심분야: 패턴인식, 신호처리, 신경회로망

▲ 허 강 인 (Kang In Hur) : 12권 6호 참조