

사후 확률·확률 밀도 함수의 추정과 Probabilistic Neural Network을 이용한 모음 인식에 의한 평가

하 강 인*, 이 광 석**, 김 명 기*
(Kang In Hur, Kwang Seok Lee, Myung Ki Kim)

요 약

계층형 신경망은 패턴 분류를 위해 사용되어 왔다. 이것은 주어진 교사패턴들의 학습으로 원하는 입력-출력간의 매핑을 할 수 있기 때문이다.

신경망은 타겟 패턴이 입력 패턴의 카테고리에 일치할때 타겟트 패턴을 학습하므로써 사후확률을 근사화할 수 있다.

그리고 입력공간을 부분공간으로 나누어 학습 데이터들의 비율로서 만든 타겟트 벡터들로 학습한 신경망은 확률밀도함수를 나타낼 수 있다.

본 연구에서는 역전파 학습법을 이용한 계층형 NN과 코드북으로서 사후확률과 확률밀도함수의 추정방법을 제안하였다.

VQ로 추정한 사후확률과 확률밀도함수를 이용하여 학습이 필요없는 RBF network의 일종인 PNN으로 모음인식을 수행하였다.

인식 실험에서 PNN의 결과는 역전파 학습법을 이용한 3층 신경망과 VQ의 평균 인식율과 비교되었다. VQ-PNN의 인식율이 다른 것보다 우수하게 나타났다.

Abstract

A feed forward neural network has been used for the pattern classification. It has the capability of representing a desired input-output mapping through the training of a given set of teaching patterns. The neural network can approximate a posteriori probability through Baye's theorem, by training it with binary vectors as target patterns corresponding to the categories of input patterns.

And Also, the network, trained with target vectors made from ratios among numbers of training data in a partial input space, can represent the probability density function of input data.

In this study, An estimation method of a posteriori probability and probability density function is proposed by making use of a feed forward neural network utilized back propagation and that of codebook. And the vowel recognition was performed by PNN, which does not need training, using a posteriori probability and probability density function by VQ. In the vowel recognition, the average recognition rate of PNN compared with that of a 3 layer feed forward neural network using back propagation algorithm and that of vector quantization each other.

Finally, it was found that VQ-PNN was the highest recognition rate among them.

I. 서 론

*동아대학교 전자공학과

**창원전문대학 전자통신과

접수일자: 1993년 6월 30일

음성 정보처리의 한 분야인 음성인식의 연구는 1970년대부터 DTW(Dynamic Time Warping), HMM(Hidden Markov Model)에 의해 계속되어

왔다. 또 수년간 신경망에 의한 음성처리의 연구가 진행되어 좋은 결과를 보여 주고 있다.

신경망의 연구는 1943년 McCulloch-Pitts의 뉴런 모델의 연구를 시작으로 1957년 Rosenblatt에 의한 퍼셉트론(Perceptron) 연구로서 확장화 되었다.

1969년 Minsky-Papert 등이 퍼셉트론의 한계에 관한 연구 후 침체상태에 접어 들었으며 1986년 Rumelhart 등이 계층형 신경망에 대한 역전파학습법 알고리즘을 정식화하였다.⁽¹⁾

이러한 계층형 신경망은 패턴인식, 로봇제어 및 시계열 예측등의 응용분야에 적용되어 제품화가 본격화되었다. 계층형 신경망은 이론적으로 중간층의 unit 수를 충분히 많게 하면 3층의 신경망에서 임의의 함수를 근사화할 수 있으며 학습데이터에 대해서는 평균 자승오차가 최소인 신경망의 구성이 가능하다고 발표되었다.⁽²⁾

또 종래의 역전파학습법의 결점인 많은 학습시간과 Local Minima의 문제점을 개선한 신경망도 발표되어있다.^(3,4,5,6)

RBF(Radial Basis Function) 회로망의 일종인 PNN(Probabilistic Neural Network)은 신경망의 구조가 계층형 신경망과 유사하나 차이점은 시그모이드 활성화수가 지수를 포함한 함수들의 한 분류로 대체된다는 것이며 학습이 필요없으므로 전체 계산 시간이 수십만에 빠르게 수행된다는 것이다.⁽⁷⁾

본 연구에서는 계층형 신경망과 벡터 양자화로서 사후확률과 확률밀도함수를 추정하는 방법을 제안, 비교하였으며, 이것들을 이용하여 모음인식을 수행하였다.

인식 실험에서는 벡터 양자화에서 구한 사후확률과 확률밀도함수를 이용하여 학습이 필요없는 PNN으로 모음인식을 하였으며, 역전파학습법을 이용한 3층 신경망과 벡터 양자화에 의한 인식과 비교한 결과 VQ-PNN이 우수하였다.

II. 사후 확률과 확률 밀도 함수의 추정

2.1 신경망에 의한 사후 확률의 추정^(8,9,10,11)

계층형 신경망은 입력신호와 교사신호간의 집합인 학습패턴으로 학습을 행하여 출력신호와 교사신호간의 자승오차가 최소가 되는 신경망의 파라미터를 결정한다.

학습된 신경망은 구조의 제약하에서 시그모이드 함수를 이용한 비선형의 사상을 재현한다. 제약이 없

는 경우의 최적인 사상은 다음식으로 주어진다.

$$y(\bar{x}) = \int \bar{t} P(\bar{t} | \bar{x}) dt \quad (1)$$

여기서 \bar{x} 는 입력벡터, \bar{t} 는 교사벡터, $p(t|x)$ 는 입력벡터가 \bar{x} 일때의 교사벡터 \bar{t} 의 확률 밀도 함수이다.

패턴인식 문제에서 교사벡터의 요소 t_1, t_2, \dots, t_k 를 각 카테고리에 대응한 값으로 한 경우의 최적인 변환은 식(2)와 같다.

$$y(x) = \sum_{k=1}^K t_k P(t_k | x) \quad (2)$$

여기서, $P(t_k | x)$ 는 입력이 x 일 때의 카테고리 C_k 에 속하는 확률로서 Bayes의 정리에 의한 사후 확률에 해당한다. 교사벡터의 각 요소를 입력벡터가 속하는 카테고리에 해당하는 경우에는 1, 다른 카테고리의 경우는 0으로 하면 입력 벡터 x_i 에 대응하는 출력벡터의 k 번째의 요소 y_k 는 다음식이 된다.

$$y_k = \sum_{i=1}^K P(t_i | x_i) - P(t_{k-1} | x_i) \quad (3)$$

이것은 입력벡터 x_i 의 값으로서 교사벡터의 k 번째의 요소가 1이 되는 확률이다. 그러므로 어느 카테고리에서 발생하는지 알고 있는 입력샘플을 몇개 준비하고 입력샘플을 발생한 카테고리에 해당하는 출력 unit에는 교사신호 1을, 그 외의 카테고리에는 0을 부여하는 학습패턴을 만든다.

이 학습패턴을 신경망에 부여하여 역전파학습법으로 학습한다. 학습된 신경망에 평가샘플로서 입력 데이터를 부여하면 이 데이터가 각 카테고리에 어느 정도의 확률(사후 확률)에 속하는지를 출력한다.

2.2 벡터 양자화에 의한 사후 확률의 추정⁽¹¹⁾

입력 데이터의 공간을 부분공간으로 나누어 데이터의 발생 빈도를 조사하여 사후 확률을 추정할 수 있다.

벡터 양자화에 의한 사후 확률의 추정은 다음 순서로 구한다.

- 1) 벡터 양자화를 이용하여 학습데이터의 코드북으로 작성한다.
 - 2) 선학습 데이터를 코드워드에 따라 분류한다.
- 이것은 입력데이터의 공간을 부분공간으로 분류하는 것이다.

3) 각 코드북의 인덱스에 포함된 학습 데이터 수를 카테고리화 인덱스마다 구한다.

그리고 인덱스 i 에 포함된 카테고리 k 의 데이터 수를 N_{ki} 로 하면 인덱스 i 에 분류된 데이터 x 가 카테고리에 속하는 확률(사후확률)은 식(4)가 된다.

$$P(C_i|x) = \frac{N_{ci}}{\sum_{i=1}^k N_{ki}} \quad (4)$$

여기서 추정된 사후 확률은 이산확률 분포이다.

2.3 확률 밀도 함수의 추정^(11,12)

확률 밀도 함수의 추정은 입력 데이터의 공간을 부분공간으로 나누어 데이터의 발생 빈도를 조사하여 구해진다.

벡터 양자화에 의한 확률 밀도 함수의 추정은 다음과 같다.

- 1) 벡터 양자화를 이용하여 학습데이터의 코드북을 작성한다.
- 2) 전학습 데이터를 코드북 수에 해당하는 부분공간으로 분류한다.
- 3) 각 카테고리마다 부분공간에 포함된 데이터 수를 전데이터 수로 나누어 확률 밀도 함수를 구한다.

i 를 포함한 부분공간에 포함된 카테고리 C 의 전학습데이터 수를 N_{ci} 라 하면 카테고리 C 의 i 번째 부분공간에 분류된 데이터 x 의 이산 확률 분포 $P(\hat{x}|c)$ 는 식 (5)와 같다.

$$P(\hat{x}|c) = \frac{N_{ci}}{\sum_{i=1}^J N_{ci}} \quad (5)$$

식(5)에서 구한 값은 이산확률 분포의 확률밀도 함수이지만 이것을 신경망의 교사신호로서 학습시키면 신경망의 스무딩 능력으로 입력데이터를 발생한 원래의 확률 밀도 함수로 근사화 할 수 있다.

이것은 이산 확률 분포에서 연속 확률 밀도 함수를 추정할 수 있기 때문이다.

그러므로 학습데이터의 입력데이터를 코드북에 따라 분류하고 분류된 부분공간의 확률 밀도 함수를 교사신호로서 사용하여 학습 패턴을 만들어 신경망으로 학습시킨다.


2.4 사후 확률과 확률 밀도 함수의 추정실험 및 검토

추정된 사후 확률과 확률 밀도 함수의 예(모음/a/)를 그림1(a), (b)에 각각 보인다. 벡터 양자화를 이용하여 얻은 확률들은 코드북의 크기가 256이며 그림1의 횡축은 VQ의 코드북의 인덱스를 나타내며 각 인덱스의 centroid벡터를 신경망에 부여한 경우의 확률을 나타내고 있다. 이 인덱스는 VQ에 의해 얻어진 값을 큰 순서로 sort하여 나타내었다.

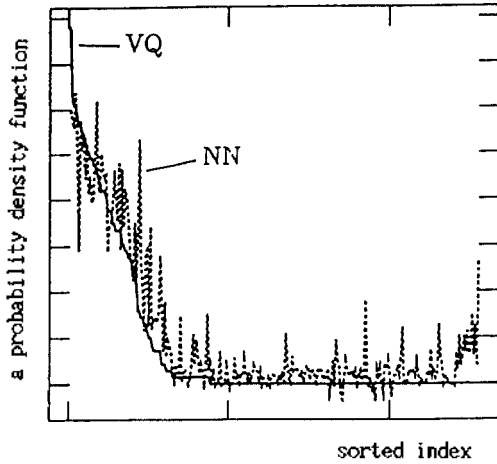
그림1(a)에서 신경망과 VQ에 의한 추정치는 다소 차이가 있지만 거의 근사화 되어 있음을 알 수 있으며 차이는 이산적인 분포와 연속적인 분포의 차이로 생각 되어진다.

그림1(b)에서 신경망과 VQ에 의한 추정치의 차이는 3층의 신경망이 임의의 분포를 재현할 수 있다는 이론에 약간의 모순을 보여주고 있다.

사용 가능한 중간 unit의 수가 계산기의 계산속도 및 메모리 양 등의 이유로 제한된 현재의 실험에서 임의의 정도로 완전히 확률 밀도를 학습하는 것이 어렵다는 것을 알 수 있다. 그러나 완전히 학습할 수 없다는 것은 역으로 스무딩 능력을 갖고 있다고 할 수 있다. 중간 unit수를 식세하면 부드러운(smooth) 분포가 되고, 중간 unit수를 크게하면 교사신호를 정확히 재현할 수가 있으나 학습이 어렵게 되는 문제가 발생하였다.



(a) 모음 /a/의 사후확률



(b) 모음 /a/의 확률 밀도 함수
그림 1.




그림 2. 분류를 위한 PNN 회로망의 구조

III. PNN^(7,13,14)

패턴을 분류하기 위해 사용되는 결성 규칙이나 정리들이 형태는 expected risk를 최소화하는 것이다.

Bayes의 정리는 여러 다른 카테고리들 갖는 문제들에 적용할 수 있다.

학습패턴이 X_1, X_2, \dots, X_m 으로 주어질때

Specht는 확률 밀도 함수를 다음 식과 같은 Gaussian Kernel로서 추정하였다.

$$P(X) = \frac{1}{(2\pi)^{p/2} \sigma^p} \cdot \frac{1}{m} \sum_{i=1}^m \exp \left[-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right] \quad (6)$$

여기서 i 는 패턴수, m 은 학습패턴의 총수, X_i 는 카테고리에서 i 번째 학습패턴, σ 는 스무딩 파라미터 및 p 는 측정공간에서의 차원이다.

그림2는 두 카테고리로 입력패턴들 X 의 분류를 하는 신경망 구조를 보인다.

그림2에서 입력 unit들은 단지 모든 패턴 unit에 동일한 입력값들을 공급하기 위한 distribution unit들이다. 각 패턴 unit들은 입력패턴 X 와 가중치 벡터 W_i 의 내적으로 이루어진다.(그림3)

$$Z_i = X \cdot W_i \quad (7)$$

그리고 가산 unit에 그것들의 활성 level을 출력하기 전에 Z_i 에 식(8)의 미선형 변환함수를 사용한다.




그림 3. 패턴 Unit

$$g(z_i) = \exp \left[-(Z_i - 1)^2 / \sigma^2 \right] \quad (8)$$

X 와 W_i 를 단위값이로 정규화 하면 식(9)가 된다.

$$g(x) = \exp \left[-W_i - X)^2 / (W_i - X)^2 / 2\sigma^2 \right] \quad (9)$$

이것은 식(6)의 지수함수항과 같은 형태이다. 그러므로 내부의 연결들에서 수행되는 내적은 뉴런 활성화 함수(지수적인 함수)에 따르며 가산 unit들은 선택된 학습패턴에서 카테고리에 일치하는 패턴 unit들에서 입력들을 간단히 더한다. 식(6)의 스무딩 파라메타 σ 는 상수이므로 임의의 스무딩 밀도 함수로 근사화할 수 있으나 σ 의 적당한 범위를 찾기위해 많은 시간이 소요되는 단점이 있다. 그러므로 VQ를 사용하여 학습샘플들을 임의의 부분공간(S_1, S_2, \dots, S_k)으로 분류하여 각 부분공간에 포함된 학습샘플들의 스무딩 파라메타(variable)로서 확률 밀도 함수를 구할 수 있다.

$$P(X) = \frac{1}{(2\pi)^{P/2}} \sum_{k=1}^K \frac{1}{\sigma_k^P} \frac{N_k}{m} \exp \left[-\frac{(X - \bar{X}_k)^T (X - \bar{X}_k)}{2\sigma_k^2} \right] \quad (10)$$

여기서 N_k 와 \bar{X}_k 는 각각 부분공간 S_k 에 포함된 학습 샘플의 수와 학습샘플벡터들의 평균 벡터이다. 그리고 $\sigma_k = \alpha \sigma_{sk}$, σ_{sk} 는 S_k 에서 샘플들의 분산값이며 α 는 임의의 상수이다. (실험값 $\alpha = 1/3$)
 본 연구에서 식(6)의 방법은 전 카테고리에 동일한 분산값을 할당하여 수행한 경우이므로 VQ-PNN($\sigma = \text{constant}$), 그리고 식(10)의 방법은 각 카테고리에 해당하는 분산값을 할당하여 수행하였으므로 VQ-PNN($\sigma = \text{variable}$)이라 부른다.

IV. 실험결과 및 검토

4.1 음성자료 및 분석조건

표1의 음성자료는 6명의 화자가 발생한 음절 음성에서 모음만 취한것이다.
 (예 : /ba/ → /a/)
 음성분석 조건은 표2와 같으며 특징 파라메터는 10차 mel cepstrum 계수를 이용하였다.

표 1. 음성 데이터 수

| | /a/ | /i/ | /u/ | /e/ | /o/ | 합계 |
|--------|------|------|------|-----|------|------|
| 학습 데이터 | 1380 | 1072 | 1740 | 846 | 1668 | 6706 |
| 평가 데이터 | 400 | 518 | 248 | 421 | 422 | 2009 |

표 2. 음성의 분석조건

| | |
|----------|------------------------|
| 샘플링 주파수 | 12KHz |
| 창함수(해밍창) | 21.33ms(256 points) |
| 프레임 주기 | 5ms(60 points) |
| 분석 | 14차 LPC 분석 |
| 특징 파라메타 | 10차 LPC mel cepstrum계수 |

4.2 인식결과 및 고찰

표3과 4는 각각 사후 확률과 확률 밀도 함수를 이용한 경우의 모음인식 결과들을 보인다. 표3, 4의 코드북 수에서 *5는 5개의 모음에 대해 각각의 코드북을 작성한 것이다. 예로서 $16 \cdot 5 = 80$ 즉 코드북 수는 80개를 나타낸다.

표3, 4에서 NN은 10 입력 units(10 mel cepstrum계수), 15 중간 units, 5 출력 units(5 모음)의 3층 신경망으로 역전파학습법을 이용한 것이다.

그리고 VQ-PNN에서 PNN은 10 입력 units(10 mel cepstrum계수), 6706 중간 units(학습 데이터 수), 1 출력 unit의 신경망을 이용하였다.

표3, 4에서 VQ-PNN으로 인식한 결과는 평가데이터에서 다른방법들보다 우수하게 나타났으며, 각 카테고리에 해당하는 분산값으로 수행한 VQ-PNN($\sigma = \text{variable}$)의 경우가 전 카테고리에 동일한 분산값

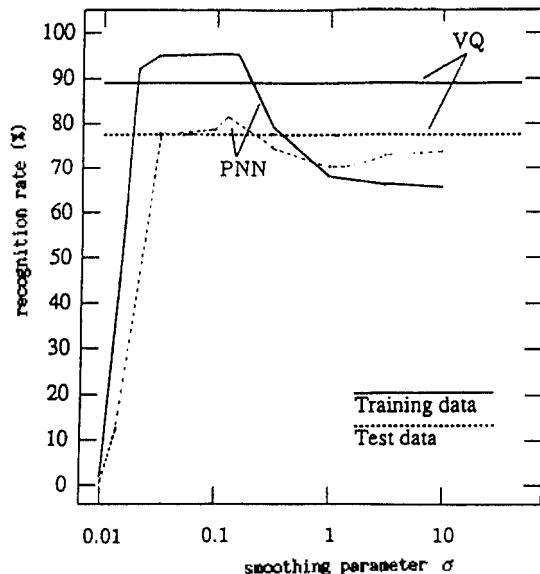


그림 4. VQ와 PNN에 의한 모음인식율

을 함당하여 수행한 VQ-PNN($\sigma = \text{constant}$)의 경우보다 약간 인식율이 좋게 나타났다.

그리고 코드북 256*5의 경우가 128*5의 경우보다 인식율이 낮은 이유는 코드북의 인덱스와 평가데이터와의 유클리드거리의 차이로 인해 카테고리를 잘못 찾은 것으로 사료된다.

표 3, 4에서 사후 확률의 경우가 확률밀도 함수보다 약간 우수하게 인식되었다. 그림 4는 코드북 수가 256일때 확률밀도 함수를 이용한 VQ와 PNN($\sigma = \text{constant}$)의 모음 인식율을 보였다. PNN($\sigma = \text{constant}$)은 σ 를 0.01에서 10까지 변화시킨 경우이며 인식율이 가장 좋은 경우의 스무딩 파라미터값은 $\sigma = 0.2$ 로 나타났다.

표 3. 사후 확률을 이용한 모음인식 결과 (%)

Vowel recognition result using posterior probability

| 방 법 | 코드북 수 | 학습 데이터 | 평가 데이터 |
|--|-------|--------|--------|
| VQ | 16 | 80.35 | 60.98 |
| | 32 | 83.84 | 67.40 |
| | 64 | 86.25 | 69.74 |
| | 128 | 88.68 | 76.31 |
| | 256 | 89.22 | 76.51 |
| NN | | 91.28 | 78.99 |
| VQ | 16*5 | 88.46 | 77.75 |
| | 32*5 | 90.86 | 79.99 |
| | 64*5 | 92.13 | 78.00 |
| | 128*5 | 93.60 | 79.54 |
| | 256*5 | 95.39 | 77.50 |
| VQ-PNN ($\sigma = \text{constant}$) | 16*5 | 89.32 | 79.19 |
| | 32*5 | 90.93 | 81.73 |
| | 64*5 | 91.89 | 81.53 |
| | 128*5 | 93.05 | 82.23 |
| | 256*5 | 93.86 | 81.43 |
| VQ-PNN ($\sigma = \text{variable}$) | 16*5 | 88.68 | 79.89 |
| | 32*5 | 89.93 | 81.83 |
| | 64*5 | 90.80 | 81.78 |
| | 128*5 | 91.44 | 82.38 |
| | 256*5 | 92.26 | 81.38 |

표 4. 확률 밀도 함수를 이용한 모음인식 결과 (%)

Vowel recognition results using probability density function

| 방 법 | 코드북 수 | 학습 데이터 | 평가 데이터 |
|--|-------|--------|--------|
| VQ | 16 | 79.83 | 68.09 |
| | 32 | 83.49 | 75.31 |
| | 64 | 85.55 | 71.08 |
| | 128 | 88.65 | 77.25 |
| | 256 | 89.02 | 77.60 |
| NN | | 89.10 | 76.41 |
| VQ | 16*5 | 88.40 | 77.60 |
| | 32*5 | 90.89 | 80.19 |
| | 64*5 | 91.96 | 78.50 |
| | 128*5 | 93.56 | 79.59 |
| | 256*5 | 95.30 | 77.70 |
| VQ PNN ($\sigma = \text{constant}$) | 16*5 | 88.85 | 78.65 |
| | 32*5 | 91.04 | 80.70 |
| | 64*5 | 91.84 | 80.84 |
| | 128*5 | 92.41 | 80.49 |
| | 256*5 | 93.07 | 79.89 |
| VQ-PNN ($\sigma = \text{variable}$) | 16*5 | 89.34 | 79.49 |
| | 32*5 | 90.58 | 81.48 |
| | 64*5 | 91.07 | 81.58 |
| | 128*5 | 91.63 | 81.09 |
| | 256*5 | 92.25 | 80.79 |

V. 결 론

본 연구에서는 역전파학습법을 이용한 3층 신경망과 양자화의 코드북을 이용한 사후 확률과 확률밀도 함수의 추정능력을 검토하였으며 벡터 양자화에 의해 추정된 사후 확률과 확률밀도 함수를 PNN에 적용하여 모음 인식실험을 수행하였다.

3층 신경망에 의한 사후 확률의 추정 능력은 벡터 양자화에 의한 것보다 거의 근사하였으나 확률 밀도 함수의 경우는 3층의 신경망이 이산적인 분포에서 연속적인 분포를 재현할 수 있다는 이론에 약간의 모순이 나타났다. 그리고 인식 실험에서 평가 데이터에 대한 인식율은 사후 확률을 이용한 VQ-PNN($\sigma = \text{variable}$)의 인식율이 역전파학습법을 이용한 3층 신경망과 벡터 양자화의 인식결과보다 우수하게 나타났다.

향후 LVQ(learning vector quantization)의 코드북을 이용하여 여러가지 신경망에 대한 인식실험을 수행할 예정이다.

본 논문은 한국과학재단 1992년 후반기 Post-doc 연수 지원비에 의하여 연구되었음.

참 고 문 헌

1. D.Rumelhart, G. Hinton and R. Williams : Learning internal representations by error backpropagation. In D. Rumelhart and J.McClelland(Eds), Parallel Distributed Processing, MIT Press(1986).
2. 船橋賢一 : 3層ニューラルネットワークによる恒等寫の近似的實現についての理論的考察, 信學論, J73-A, 1, pp.139-145, 1992(1990).
3. R.Hecht-Nielsen : Theory of the backpropagation neural network, IEEE International Joint Conference on Neural Networks, Vol. 1, pp.593-605(1989).
4. R.Beale and T Jackson : Neural Computing : An Introduction, Adam Hilger Bristol, Philadelphia and New York, 1991.
5. 松葉育雄 : バックプロパゲーションによる特徴抽出, 數理科學, NO.338., AUGUST(1991).
6. B.Kosko, editor, Neural networks for Signal Processing, pp. 199-223, Prentice-Hall International, Inc.
7. D.Specht, Probabilistic Neural Networks, Neural Networks, Vol. 3, pp.109-118(1990).
8. D. W. Ruck, et al. : The multilayer perceptron as an approximation to a Bayes Optimal discriminant function, IEEE Trans. Neural Networks, Vol. 1, No. 4, pp.296-298(1990).
9. E. A. Wan : Neural network classification : a Bayesian interpretation, IEEE Trans. Neural Networks, Vol. 1, NO. 4, pp.303-305(1990).
10. 栗田多喜夫 : 情報展基準による3層ニューラルネットワークの隠れ層のユニット 數の決定法, 信學論, Vol.J73-D-II, No.11, pp.1872-1878(1990).
11. Y.Ono, S.Nakagawa : Estimation of a posteriori probability using neural network, Proc. IJCNN, 789-794(1991.Nov).
12. N. Morgan, et al, Continuous Speech recognition on the resource management database using connectionis probability estimation, Proc.IC-SLP, pp.1337-1340(1990).
13. 小野義之, 中川聖一 : ニューラルネットワークによる事後確率と確率密度函數の推定と母音認識, 日本音響學會講論集, 2-1 9(1992.3).
14. S. Nakagawa, Y. Ono and K.I.Hur 'Estimation of Probability Density Function and Evaluation by Vowel Recognition,' Proc. IJCNN, '93, pp.2223-2226.

▲許 康 仁(Kang In Hur) 1955년 2월 20일생



1980년 2월 : 동아대학교 전자공학과(공학사)

1982년 2월 : 동아대학교 대학원 전자공학과(공학석사)

1990년 8월 : 경희대학교 대학원 전자공학과(공학박사)

1984년 9월 ~ 현재 : 동아대학교 공과대학 전자공학과 부교수

1988년 9월 ~ 1989년 8월 : 일본 筑波大學 객원연구원

1992년 9월 ~ 1993년 8월 : 일본 豊橋大學 객원연구원

※ 주관심분야 : 디지털신호처리, 음성인식·합성, 신경회로망

▲金 明 起(Myong Ki Kim) 1930년 2월 19일생



1951년 8월 : 해군사관학교(이학사)

1958년 6월 : 미국해군공과대학 전자공학과(공학사)

1966년 2월 : 서울대학교 대학원 전자공학과(공학석사)

1976년 2월 : 동아대학교 대학원 (공학박사)

1977년 3월 ~ 현재 : 동아대학교 공과대학 전자공학과 교수