

## RBFN을 이용한 음소인식에 관한 연구

안종영 김주성 김수훈 허강인

동아대학교 전자공학과

### A Study on the Phoneme Recognition using RBFN

J. Y. Ahn J. S. Kim S. H. Kim K. I. Hur

Dept. of Electronic Eng. Dong-A Univ.

#### 요약

계층형 신경망은 교차신호들의 학습으로 원하는 인출터간의 매핑을 할 수 있으므로 패턴분류를 위해 사용되어 왔다.

본 논문은 계층형 신경망의 일종인 RBFN중 GPFN과 PNN으로 한국어 음소인식을 수행하였다. RBFN의 구조는 계층형 신경망과 유사하나 차이점으로는 은닉층에서 시그모이드 함수, 참조벡터 및 학습알고리즘의 선택이 다르다. 특히 PNN의 시그모이드 함수는 시수를 포함한 함수들로 대체되며, 학습없이 패턴을 분류하므로 계산시간이 빠르게 수행된다.

본 실험에서는 한국어 단음절에서 모음과 자음을 추출하여 음소인식을 수행하였다. 실험 결과 학습과 평가데이터에 의한 인식률은 계층형 신경망과 비교하여 향상되었으며, Hybrid구성(VQ·LVQ)에 의한 실험에서도 향상된 인식률을 얻을 수 있었다.

VQ·LVQ 코드북과의 Hybrid 구성으로 계층형 신경망과 RBFN에 대한 음소 인식결과를 비교하였다. 그 결과 RBFN에 의한 인식률이 우수하게 나타났다.

#### II. RBFN(Radial Basis Function Network)

##### 2.1 GPFN(Gaussian Potential Function Network)

GPFN은 은닉층에 GPF(Gaussian Potential Function)라 부르는 unit로 되어져 있다.  $x$ 를 입력패턴으로 할 때 은닉층 unit  $\phi_j$ 의 정의는 다음과 같다.

$$\phi_j = \phi(x, p_j) = e^{-d(x, p_j)^2} \quad (1)$$

$$d(x, p_j) = d(x, m^j, K^j) = (x - m^j)'K^j(x - m^j) \quad (2)$$

여기서,  $m^j$ 와  $K^j$ 는 각각  $j$ 번째 GPF의 평균벡터와 공분산행렬의 역행렬이다.  $d(x, m^j, K^j)$ 를 다시 전개하면 식(3)과 같다.

$$d(x, m^j, K^j) = \sum_j \sum_k k_{jk}^j (x_j - m_j^j)(x_k - m_k^j) \quad (3)$$

여기서  $x_j$ : 입력벡터  $x$ 의  $j$ 번째의 요소,  $m_j^j$ 는 평균벡터  $m^j$ 의  $j$ 번째의 요소,  $k_{jk}^j$ 는 역공분산 행렬  $K^j$ 의  $(j, k)$ 번째의 요소를 각각 나타낸다.  $k_{jk}^j$ 는 주변(Marginal) 표준편차  $\sigma_j^j$ 와  $\sigma_k^j$ 와 상관계수  $h_{jk}^j$ 로 나타낼 수 있다.

$$k_{jk}^j = \frac{h_{jk}^j}{\sigma_j^j \sigma_k^j} \quad (4)$$

여기서  $\sigma_j^j$ : 양의 실수

$$\begin{cases} h_{jk}^j = 1 & , j=k \\ h_{jk}^j \leq 1 & , \text{그외} \end{cases}$$

그림1에 3층구조의 GPFN을 나타내었다. 입력층과 출력층은 신경 unit들로 구성되었으며, 은닉층은 GPF를 발생시키는 GPFU(Radial Basis Function Unit)로 구성되었다.

GPFU의 가중치 출력들은 원하는 potential fields를 합성하기 위해 은닉층과 출력층 사이에 연결되어 더해진다.

$j$ 번째 출력 unit의 출력치를  $\phi_j$ 로 하면

$$\phi_j = \sum_k w_{jk} \phi_k \quad (5)$$

로 된다.

#### I. 서론

컴퓨터 및 정보통신 기술의 급속한 발전과 보급이 한 발짝에 따라 전문가뿐만 아니라 각 분야의 많은 사람들이 이용하게 되었고, 인간-기계의 인터페이스를 용이하게 하려는 욕구가 증대되고 있다. 그 중에서 음성에 의한 인간과 기계사이의 인터페이스는 속도가 빠르고 특별한 훈련 없이 이루어질 수 있다는 장점 때문에 연구가 활발히 진행되어지고 있다.

음성 정보처리의 한 분야인 음성인식의 연구는 DTW, HMM, 신경망에 의해 계속되어 왔다. 또 수년간 신경망에 의한 음성처리의 연구가 진행되어 좋은 결과를 많이 주고 있다.

신경망의 연구는 1969년 Minsky-Papert들이 피셔트론의 한계에 대한 연구 후 침체 상태에 접어들었으며, 1986 Rumelhart들이 계층형 신경망에 대한 의신과 알고리즘을 정식화 하였다.<sup>[1]</sup>

계층형 신경망은 패턴인식, 모호부 제어 및 시계열 예측 등의 응용분야에 적용하고 있다. 계층형 신경망은 중간층의 units를 충분히 많게 하면 3층의 신경망으로서 임의의 함수를 근사화할 수 있으며 학습데이터에 대해서는 평균자승오차가 최소인 신경망의 구성이 가능하다고 발표되었다.<sup>[2]</sup>

또한 중래의 역전파 학습법의 걸림인 많은 학습시간과 Local Minima의 문제점을 개선한 신경망도 발표되어 있다.<sup>[3-5]</sup>

RBFN의 일종인 GPFN과 PNN은 계층형 신경망과 구조가 유사하나, 차이점으로는 은닉층에서 활성화 함수, 참조벡터 및 학습 알고리즘의 선택이 다르다. 특히 PNN은 시그모이드 활성화수가 지수를 포함한 함수들의 한 분류로 대체된다는 것이며 학습이 필요없으므로 전체 계산시간이 빠르게 수행된다.

본 연구에서는 사후화법을 이용하여 GPFN과 PNN으로 한국어 음소(모음, 12자음) 인식실험을 수행하였으며,

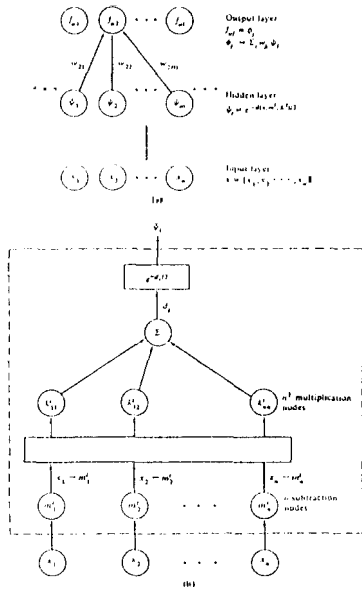


그림 1. GPFN의 구조

이 네트워크를 학습하기 위해서는 역전파 학습법과 동일하게 오차함수에 최급하강법을 적용하여 교사패턴을 참조하여 파라미터를 점차로 갱신하는 것이다.

$p$ 번째 교사패턴의 오차함수  $E_p$ 를 식(6)로 정의한다.

$$E_p = \frac{1}{2} \sum_{j=1}^M (t_{pj} - \phi_{pj}(n_j))^2 \quad (6)$$

여기서  $M$ 은 출력 unit의 수,  $t_{pj}$ 는 교사신호를 나타낸다.  $\phi_{pj}$ 는 실제 출력의  $j$ 번째 요소를 나타내고,  $n_j$ 는  $j$ 번째의 출력 unit의 전파파라미터에서 일백디로 된다.

$$n_j = [w_j^1, m_j^1, \sigma_j^1, h_j^1]^T \quad (7)$$

방향벡터  $\Delta n_j \equiv [\Delta w_j^1, \Delta m_j^1, \Delta \sigma_j^1, \Delta h_j^1]^T$ 는 최급하강법으로 구해진다.

파라미터의 갱신규칙은

$$n_j^{new} = n_j^{old} + \eta \Delta n_j \quad (8)$$

로 된다.  $\eta$ 은 학습률(learning rate)라 부르는 양의 정수이다.

•  $j$ 번째의 출력층과  $i$ 번째의 GPFU 사이의 가중치

$$\Delta w_{ji} = - \frac{\partial E_p}{\partial w_{ji}} = (t_j - \phi_j) \phi_i \quad (9)$$

• 평균값에  $m^1$ 의  $j$ 번째의 요소

$$\Delta m_j^1 = - \frac{\partial E_p}{\partial m_j^1} = \sum_i k_{ji}^1 (x_i - m_i^1) \phi_i \sum_k (t_k - \phi_k) w_{kj} \quad (10)$$

• 주변(marginal) 표준편차  $\sigma_j^1$

$$\Delta \sigma_j^1 = - \frac{\partial E_p}{\partial \sigma_j^1} = - \frac{1}{2} \frac{(x_j - m_j^1)(x_j - m_j^1)}{\sigma_j^1} \phi_j \sum_k (t_k - \phi_k) w_{kj} \quad (11)$$

•  $k_{ji}^1$ 에 대한 역공분산 계수  $k_{ji}^1$

$$\Delta k_{ji}^1 = - \frac{\partial E_p}{\partial k_{ji}^1} \quad (12)$$

$$= - \frac{1}{2} \frac{(x_j - m_j^1)(x_j - m_j^1)}{\sigma_j^1} \phi_j \sum_k (t_k - \phi_k) w_{kj}$$

## 2.2 PNN(Probabilistic Neural Network)

패턴을 분류하기 위해 사용되는 결정 규칙이나 정리들은 expected risk를 최소화하는 것이다.

Bayes의 정리는 여러 다른 카테고리들 갖는 문제들에 적용할 수 있다.

학습데이터가  $X_1, X_2, \dots, X_m$ 으로 주어질 때 Specht는 학습데이터의 확률밀도함수를 Gaussian Kernel로서 추정하였다.

$$P(X) = \frac{1}{(2\pi)^{m/2} \sigma^m} \quad (13)$$

$$\frac{1}{m} \sum_{i=1}^m \exp\left\{ - \frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right\}$$

여기서  $n$ 는 패턴수,  $m$ 은 학습패턴의 총수,  $X_i$ 는 카테고리에서  $i$ 번째 학습패턴,  $\sigma^2$ 는 스무딩 파라미터 및  $\beta$ 는 측정공간에서의 차원이다.

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




그림 2. 분류를 위한 PNN 회로망의 구조

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)

$$Z_i = X \cdot W_i \quad (14)$$

그리고 가산 unit에 그것들의 활성 level을 출력하기 전에  $Z_i$ 에 식(14)의 비선형 변환함수인 시그모이드 함수를 이용한다.

$$g(Z_i) = \exp\left[ \frac{Z_i}{1 + \sigma^2} \right] \quad (15)$$

$X$ 와  $W_i$ 를 단위길이로 정규화 하면 식(16)이 된다.

$$g(X) = \exp\left[ - (W_i - X)^T (W_i - X) / 2\sigma^2 \right] \quad (16)$$

이것은 식(13)의 지수함수항과 같은 형태이다. 그러므로 내부의 연결들에서 수행되는 내적은 뉴런 활성화 함수(지수적인 함수)에 따라서 가산 unit들은 선택된 학습 패턴에서 카테고리에 일치하는 패턴 unit에서 입력들을 간단히 더한다.




그림 3. 페던 unit

III. Learning Vector Quantization(LVQ)<sup>(18)</sup>

LVQ1은 생성되어지는 참조벡터의 차이에 대해서 그 거리 척도로서 학습되어지는 알고리즘의 하나이다. 이 LVQ 방법은 VQ를 개선한 것으로 참조벡터를 뉴런들 간의 시냅스 결합에 대응시켜 교차 학습으로 적절한 참조벡터를 구하는 방법이다.

$$c = \arg \min \{ \text{length} (x - m_i) \}$$

참조벡터  $m_i$ 에 가장 근접한 입력벡터  $x$ 를  $m_c$ 로 나타낸다.

가장 근접한 분류를 하기 위해서 오차를 최소화 하는  $m_i$ 의 값은 식(17),(18)의 학습과정으로 생성된다.

- $x$ 와  $m_c$ 가 동일 Class 일때 :  
 $m_c(t+1) = m_c(t) + \alpha(t) [ x(t) - m_c(t) ]$  (17)
- $x$ 와  $m_c$ 가 다른 Class 일때:  
 $m_c(t+1) = m_c(t) - \alpha(t) [ x(t) - m_c(t) ]$  (18)
- $i$ 와  $c$ 가 같지 않을 때:  
 $m_i(t+1) = m_i(t)$

여기서  $x(t)$ 는 입력벡터의  $i$ 번째 요소이고,  $m_i(t)$ 는 참조벡터  $m_i$ 의  $i$ 번째 요소를 나타낸다. 그리고  $\alpha(t)$ 는 학습율이요 시간에 따라 단조 감소하는 함수이다.

LVQ1은 학습페턴 중 특별한 형태의 패턴이 코드화 벡터와의 거리가 될 경우 오 분류가 발생한다는 특징이 있다. 이와같은 단점을 보완한 LVQ2 알고리즘은 두 개의 단점 카테고리중에서 한 카테고리는 정 분류이고, 다른 카테고리는 오 분류일 때를 고려하였다. 그러나 학습횟수가 많을 때 각 분류중 참조벡터가 집근적으로 갱신 될 경우 각각의 클래스가 안정성을 잃을 우려가 있다. LVQ3에서는 각 분류에 대해서 식(19)와 (20)에서와 같이  $\alpha$ 값에 또 다른 학습가중치  $\epsilon$  ( $0 < \epsilon < 1$ )을 곱해서 보정한다.

- $x$ 와  $m_k$ 가 동일 Class 일때 :  
 $m_k(t+1) = m_k(t) + \epsilon(t) \cdot \alpha(t) [ x(t) - m_k(t) ]$  (19)
- $x$ 와  $m_k$ 가 다른 Class 일때 :  
 $m_k(t+1) = m_k(t) - \epsilon(t) \cdot \alpha(t) [ x(t) - m_k(t) ]$  (20)

이 알고리즘은 자기안정화, 즉  $m_i$ 의 최적화는 계속적인 학습에서 변화하지 않음을 알 수 있다.

IV. 실험 결과 및 고찰

4.1 음성DB 및 분석조건

표1은 6명의 일본인화자가 발성한 음절 음성의 전 프레임에서 2/3번째인 1프레임을 취한 것이며 분석조건은 표2와 같다.

(예: /ba/ -> /a/)

표3의 자음은 한국어인 5명의 화자가 5회 발성한 것으로 그 중 3회 발성분은 학습데이터, 2회 발성분은 평가 데이터로 하였고 음성분석 조건은 표4와 같다.

표1. 모음의 음성DB

데이터	아	이	우	에	오	합계
학습	1380	1072	1740	846	1668	6706
평가	400	518	248	421	422	2009

표2. 음성의 분석조건

샘플링 주파수	12 KHz
정합수(해당량)	21.33 ms (256point)
프레임 주기	5 ms ( 60point)
분석	14차 LPC 분석
특성 파라메터	10차 LPC mel cepstrum계수

표3. 초성자음의 음성DB

음성	음성파일음					비 음					마찰음과 파일음					무성파일음							
	ㄱ	ㄷ	ㄴ	ㄹ	ㄺ	ㄻ	ㄼ	ㄽ	ㄾ	ㄿ	ㅀ	ㅁ	ㅂ	ㅃ	ㅄ	ㅅ	ㅆ	ㅇ	ㅈ	ㅊ	ㅋ	ㆁ	
학습	990	360	465	630	420	390	600	600	555	45	240	255											
합계	1815					1440					1755					540							
평가	660	240	310	420	280	260	400	400	370	30	160	170											
합계	1210					960					1170					360							

표4. 음성의 분석조건

샘플링 주파수	10 KHz
정합수(해당량)	20 ms (200point)
프레임 주기	5 ms ( 50point)
분석	14차 LPC 분석
특성 파라메터	10차 LPC mel cepstrum계수

4.2 인식결과 및 고찰

표5는 모음과 초성자음의 인식을 위한 3층 신경망의 구조를 나타낸다. 학습횟수는 시간을 제한하기 위하여 3000번 이내로 하였다. 각 신경망의 입력은 모음인 경우는 10입력 units(1프레임×10 mel cep. 계수), 자음인 경우는 20입력 units(2프레임×10 mel cep. 계수)로 하였고, 특히 PNN의 중간층은 각각 모음과 자음의 학습데이터 수 만큼의 units를 가진다.

VQ의 LVQ로 구성된 코드북 수는 64,128,256개로 하였다.

표5. 신경망의 구조

데이터	신경망	입력층	중간층	출력층
모음	MLP	10 units	15 units	5 units
	GFNN	10 units	16 units	5 units
	PNN	10 units	학습데이터수	1 unit
자음	MLP	20 units	30 units	3 units
	GFNN	20 units	32 units	3 units
	PNN	20 units	학습데이터수	1 unit

표6과 표7은 사후확률을 이용한 확률이 음소 5모음과 12자음의 인식결과를 각각 나타내었다.

표6에서 모음(아,이,우,에,오)의 인식률은 학습 평가데이터에서 코드북 256의 LVQ-PNN의 인식률이 다른 방법보다 우수하였다.

표6에서 자음의 경우, 유성파열음(ㄱ, ㅋ, ㆁ)의 인식율은 학습데이터에서는 GPFN, 평가데이터에서는 코드북 128의 LVQ-PNN의 인식결과가 우수하였다. 비음(ㄷ, ㅌ, ㄴ)의 인식율은 학습데이터에서는 PNN, 평가데이터에서는 코드북 64의 LVQ-PNN의 인식결과가 가장 우수하였다. 또한 마찰음과 파열음(ㅅ, ㅆ, ㅈ)의 인식율은 학습·평가데이터에서 PNN의 인식결과가 다른 방법보다 우수하였으며, 무성파열음(ㅊ, ㅊ, ㅍ)의 인식율은 학습데이터에서는 GPFN, 평가데이터에서는 PNN의 인식결과가 가장 우수하였다.

그리고 스무딩 파라미터  $\sigma$ 는 0.05~10까지 변화시킨 경우 PNN에서는 0.2~0.3, VQ·LVQ와 PNN의 하이브리드 구성인 경우 0.1~0.2가 가장 좋은 인식율이 나타났다. 또한 코드북 수가 많은 경우가 적은 경우 보다 인식율이 낮은 경우는 코드북의 인덱스와 평가데이터와의 유클리드 거리의 차이로 인해 카테고리들을 잘못 찾은 것으로 사료된다.

음소인식 실험에서 모음(아, 이, 우, 에, 오)의 경우는 학습·평가데이터에서 코드북 256의 하이브리드 LVQ-PNN의 인식결과가 우수하였다. 자음에서는 유성파열음(ㄱ, ㅋ, ㆁ)의 경우 학습데이터에서는 GPFN, 평가데이터에서는 코드북 128의 하이브리드 LVQ-PNN이 우수하였고, 비음(ㄷ, ㅌ, ㄴ)의 경우는 학습데이터에서는 PNN, 평가데이터에서는 코드북 64의 하이브리드 LVQ-PNN의 이, 마찰음과 파열음(ㅅ, ㅆ, ㅈ)의 경우는 학습·평가데이터에서 PNN이, 무성파열음(ㅊ, ㅊ, ㅍ)의 경우 학습데이터에서는 GPFN, 평가데이터에서는 PNN의 인식결과가 다른 방법들에 비해 가장 우수한 인식율을 얻을 수 있었다.

향후 HMM을 이용한 하이브리드 신경망을 구성하여 음성인식 실험을 수행할 예정이다.

참고문헌

- 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 - : 3層ニューラルネットワークによる恒等寫像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.
- 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, 数理科學, 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: 情報量基準による3層ニューラルネットワークの隠れ層のユニット数の決定法, 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, pp.789-794, Nov., 1991.
- 12) N.Morgan, et al., Continuous Speech recognition on the resource management database using connectionist 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関数の推定と母音認識, 日本音響學會議論集, 2-1-9, 1992.3.
- 14) K.L.Hur, S. Nakagawa, and Y.Ono, 'Estimation of Probability Density Function and Evaluation by Vowel Recognition', Proc. IJCNN, 1993.10, pp.2223-2226.
- 15) 허강인 외 2인, '사후확률·확률밀도함수의 추정과 Probabilistic Neural Network을 이용한 모음인식에 의한 평가', 한국음향학회지, 12권, 16호, pp.21-27, 1993.
- 16) 허강인 외 3인 '계층형 신경회로망을 이용한 음성인식에 관한 연구', 동아대학교 공과대학 부설 한국지원개발연구소 연구논문집, 제18권, 제1호, pp.156-164, 1994.
- 17) 김주성, 허강인 '사후확률을 이용한 RBF 신경망에 의한 음소인식' 1994 신호처리 합동학술대회 논문집 제7권 1호 pp.743-747, 1994.
- 18) 안종영, 허강인 'HMM segmentation 과 LVQ를 이용한 음절인식에 관한 연구' 제11회 음성통신 및 신호처리 워크샵 논문집 pp.378-382, 1994.

표6. 모음(아, 이, 우, 에, 오)의 인식결과 (%)

방법	코드북	학습데이터	평가데이터
MLP		91.35	79.54
GPFN		92.68	79.74
PNN		94.26	80.99
VQ-MLP	64	88.88	74.71
	128	89.52	76.26
	256	90.53	77.85
VQ-GPFN	64	87.67	75.06
	128	90.55	78.30
	256	91.26	79.19
VQ-PNN	64	89.05	81.78
	128	92.70	86.96
	256	94.38	88.15
LVQ-MLP	64	87.74	75.38
	128	88.76	77.81
	256	91.22	78.67
LVQ-GPFN	64	89.38	84.76
	128	90.11	84.90
	256	92.20	87.10
LVQ-PNN	64	93.65	87.03
	128	94.37	87.24
	256	94.89	87.60

표7. 자음의 인식결과 (%)

방법	코드북	아, 이, 우		에, 오		ㄱ, ㅋ, ㆁ		ㄷ, ㅌ, ㄴ	
		학습	평가	학습	평가	학습	평가	학습	평가
MLP		71.40	70.66	67.32	69.25	56.08	55.77	71.85	73.06
GPFN		89.48	76.20	82.20	71.13	81.49	73.26	91.11	73.06
PNN		85.62	76.28	90.74	70.19	90.43	78.86	90.74	78.89
VQ-MLP	64	51.46	50.91	61.58	61.19	48.27	49.07	63.89	65.28
	128	54.77	54.05	61.92	61.09	47.76	50.76	68.15	66.67
	256	61.49	60.74	63.74	63.81	50.08	52.29	65.00	65.56
VQ-PNN	64	69.59	71.07	65.99	67.47	58.35	59.51	75.00	70.83
	128	71.29	70.74	67.80	67.05	61.46	62.22	75.93	75.83
	256	73.61	72.23	68.08	68.51	64.69	63.67	80.19	77.50
LVQ-MLP	64	51.07	50.99	60.81	59.52	43.75	44.82	62.22	63.61
	128	55.21	55.21	61.58	58.79	47.48	48.05	69.63	69.72
	256	61.21	60.99	63.74	63.18	52.18	52.55	69.63	70.56
LVQ-PNN	64	79.94	76.86	82.30	71.86	68.19	65.53	85.00	76.67
	128	83.69	77.02	81.32	71.65	71.36	67.23	79.63	73.33
	256	79.17	73.64	83.21	71.03	73.23	68.76	79.44	76.11

V. 결론

본 연구는 사후확률을 이용하여 RBFN의 한 종류인 GPFN과 PNN으로 한국어 음소(5모음, 12자음)인식실험을 수행하였다. 그리고, VQ·LVQ 코드북과의 하이브리드 구성으로 MLP와 RBFN에 대한 음소인식 성능을 비교하였다.