

Raised Cosine RBF 신경망을 이용한 무제약 필기체 숫자 인식

Recognition of Unconstrained Handwritten Digits Using Raised Cosine RBF Neural Networks

박 준 근, 김 상 희, 박 원 우

Jun-Keun Park, Sang-Hee Kim, Won-Woo Park

요약

본 논문에서는 무제약 필기체 숫자 인식에 있어서 향상된 RBF(Radial Basis Function) 신경망을 이용한 새로운 접근 방법을 제시하였다. RBF 신경망은 인식률과 인식 속도를 향상시키기 위해 기저 함수로서 Raised Cosine RBF를 사용하였다. Raised Cosine RBF 신경망 분류기의 성능 평가를 위하여 캐나다 몬트리올 Concordia 대학의 무제약 필기체 숫자 데이터베이스를 사용하였고, 실험 결과 98.05%의 인식률을 보였다.

ABSTRACT

In this paper, we presented a new approach to the recognition of unconstrained handwritten numerals using an improved RBF(Radial Basis Function) Neural Networks. The RBF Neural Networks used Raised Cosine as a basis function to improve discrimination and reduce processing time. The performance of Raised Cosine RBF Neural Networks classifier was evaluated using totally unconstrained handwritten numeral database of Concordia University, Montreal, Canada, and the experimental results showed the recognition rate of 98.05%.

Key words: Handwritten digits recognition, RBF Neural Networks, Raised cosine RBF

I. 서론

오프라인 문자 인식에 해당되는 무제약 필기체 숫자 인식은 패턴 인식의 한 분야이며 그 용용 분야가 다양하고 여러 분야의 적용이 가능하지만 실용화 단계까지는 아직 해결해야 할 몇 가지 문제를 안고 있다. 그 대표적인 문제로 인식 성능을 향상시키는 것과 실용화를 고려하여 처리 속도를 빼니 하는 것이다. 인식 성능을 향상시키기 위하여 인식에 필요한 정보의 손실을 최소화하는 특징 추출기를 설계하고 그와 동시에 강력한 패턴 분류기를 설계하는 것으로 연구의 초점이 맞추어지고 있다. 패턴 분류기 설계에 있어서 필기체 숫자와 같은 복잡한 패턴 분류를 효과적으로 수행하기 위해 인공 신경망이 널리 사용되고 있다[1].

적용성, 비선형성 그리고 학습능력 등의 특성을 가지고 있는 인공 신경망을 이용한 패턴 인식 분야에서 많은 성공적인 적용 사례들이 나오고 있으며 높은 인식률을 보이고 있다. 그런데 패턴 인식 시스템은 현재의 출력이 현재 상태의 인식에만 영향을 줄 뿐 다음 상태의 출력에 영향을 미치지 않는 정적인 특성을 가지고 있기 때문에 기존의 RNN과 DNN(Diagonal Neural Networks) 등과 같은 동적인 특성이 강하게 나타나는 구조 즉, 현재의 출력이 다음의 출력에 영향을 주는 구조의 신경망을 현재의 패턴이 이전의 패턴에 영향을 받고 있지 않는 독립적인 정적 특성을 갖는 패턴 인식 분야에의 적용은 학습과 인식에 오히려 방해가 문제점을 가지고 있다[2]. 본 논문에서는 패턴 인식과 같은 정적 특성을 가지고 있는 시스템의 적용에 알맞다고 알려져 있는 전향구조의 신경망을 사용하여 효과적인

폐던 분류를 수행하여 인식률의 향상과 학습속도를 빠르게 개선하는 것에 연구의 초점을 두었다. 본 논문에서 전처리 단계에는 Kirsch 마스크를 이용하여 원 숫자 영상의 특징을 추출하였으며, 분류 및 인식 단계에서는 빠른 학습 속도를 가지며 필체의 변화에도 강한 특성을 나타내는 전향구조의 신경망인 Raised cosine RBF(Radial Basis Function) 신경망을 이용한 인식기를 구성하여 무제약 서체 숫자 인식 방법을 제안하였고, 이 방법의 인식 성능을 평가하였다. 실험 데이터로는 캐나다 몬트리올 Concordia 대학의 무제약 필기체 숫자 데이터베이스를 사용하였다.

II. 전처리

2.1 데이터베이스

실제로 사람이 쓴 필기 숫자를 인식하기 위해서는 다양한 폐디로 구성된 많은 수의 샘플을 포함하는 학습 데이터가 있어야 한다. 필체는 필기자의 국가, 지역, 교육의 정도, 직업, 개개인의 스트레스, 피로, 그리고 필기 속도등 여러 가지 조건에 따라서 큰 영향을 받는다. 또 필기시의 필기도구, 종이 및 잉크의 질 등도 영향을 미친다. 만약 학습 폐디가 이런 여러 가지 필기체 숫자의 특성을 포함하고 있다면 인식률은 높아질 것이다. 본 논문에서 사용된 필기체 숫자 데이터베이스는 이런 특성을 많이 내포하고 있으며 많은 필기자로부터 얻은 완전히 무제약적인 필기체 숫자의 샘플을 제공하고 있다.

그림 2.1에서 보듯이 숫자 데이터베이스 내의 각 숫자 데이터들은 전체적으로 크기, 형태의 제약이 없는 무제약 숫자 영상임을 알 수 있다.

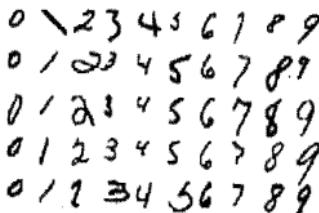


그림 2.1 숫자 데이터베이스의 예제 데이터들

이 데이터베이스는 미국 전역에 있는 우체국에서 발송되지 않는 우편물 가운데 6000여개의 우편 번호를 캐나다 Concordia 대학에서 데이터베이스화 시킨 것이다. 데이터베이스내의 숫자들은 대략 166PPI의 농담을 가지면서 0.153mm의 화소 크기를 갖고, 64×124의 영상 크기로 이치화 되어 있다.

데이터베이스내의 모든 숫자영상 데이터들은 Run

length coding으로 부호화되어 있다. 이를 원래 크기의 영상으로 복원한 뒤 16×16 화소 크기로 정규화 시킨 후 숫자 영상의 특징을 추출하였다. 이 과정에서 원래의 영상 정보를 최대한 보존하기 위해 모든 숫자 영상을 역치 처리(thresholding)하였다.

2.2 숫자 영상의 특징 추출

전처리 과정은 각종 폐디들의 물리적, 구조적, 수학적인 특징들로부터 구별 가능한 고유의 특징을 추출해 내는 과정이다. 신경망의 입력으로 숫자 영상을 그대로 쓰는 것보다는 원 숫자 영상에서 특징을 추출한 전처리된 데이터를 쓰면 인식 성능을 향상 시킬 수 있다.

본 논문에서는 특징 추출의 방법으로 Kirsch가 제안한 기법을 사용하였다. Kirsch는 식 2.1 ~ 2.3과 같은 비선형 에지 검출 알고리듬을 제안하였다[3].

$$G(i,j) = \max \{1, \max_{k=0}^7 [|5S_k - 3T_k|]\} \quad (\text{식 } 2.1)$$

$$S_k = A_k + A_{k+1} + A_{k+2} \quad (\text{식 } 2.2)$$

$$T_k = A_{k+3} + A_{k+4} + A_{k+5} + A_{k+6} + A_{k+7} \quad (\text{식 } 2.3)$$

$G(i,j)$: pixel (i,j) 의 기울기

A_k : pixel (i,j) 의 8개의 주변의 화소
($k = 0, 1, \dots, 7$)

A_0	A_1	A_2
A_7	(i,j)	A_3
A_6	A_5	A_4

그림 2.2 Pixel (i,j) 의 여덟 이웃 화소(A_k)

여기서 각 화소에 곱해지는 숫자는 방향성 기울기의 scale factor를 나타내며 이는 원 영상에서 추출하고자 하는 부분의 화소에는 5, 그렇지 않은 화소에는 -3의 값을 주어 각 숫자 영상의 방향 정보를 추출하였다. 4 가지의 방향성 영향 벡터 즉, 수평, 수직, 좌, 그리고 우방향에 대한 국부적인 특징 벡터 추출을 위해 식 2.4~식 2.7과 같이 방향 정보를 계산하였다.

$$G(i,j)_H = \max \{ |5S_0 - 3T_0|, |5S_4 - 3T_4| \} \quad (\text{식 } 2.4)$$

$$G(i,j)_V = \max \{ |5S_2 - 3T_2|, |5S_6 - 3T_6| \} \quad (\text{식 } 2.5)$$

$$G(i,j)_R = \max \{ |5S_1 - 3T_1|, |5S_5 - 3T_5| \} \quad (\text{식 } 2.6)$$

$$G(i,j)_L = \max(|5S_3 - 3T_3|, |5S_7 - 3T_7|) \quad (\text{식 } 2.7)$$

$$\begin{bmatrix} 5 & 5 & 5 \\ -3 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix}$$

(a) 수평 방향

$$\begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & -3 \\ 5 & 5 & 5 \end{bmatrix}$$

$$\begin{bmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & 5 \end{bmatrix}$$

$$\begin{bmatrix} 5 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & -3 & -3 \end{bmatrix}$$

(b) 수직 방향

$$\begin{bmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -3 \end{bmatrix}$$

(c) 우 대각 방향

$$\begin{bmatrix} -3 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & 5 & -3 \end{bmatrix}$$

$$\begin{bmatrix} 5 & 5 & -3 \\ 5 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix}$$

$$\begin{bmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{bmatrix}$$

(d) 좌 대각 방향

그림 2.3 각 방향 특성을 추출하기 위해 사용된 Kirsch 마스크

위와 같이 계산된 4가지 방향성 정보는 2×2 내의 4개 화소값을 모두 더하여 평균을 구한 후 한 개의 화소값에 할당하는 평균화 연산을 통하여 다시 4×4 의 국부적인 특징 벡터로 압축하였다. 국부적인 특징 벡터 이외의 전역적 특성을 고려하기 위해 정규화된 16×16 영상을 직접 평균화 연산을 통하여 8×8 영상으로 압축하여 이에 대한 전역적 특징 벡터를 추출하여 신경망의 입력으로 사용하였다. 그러므로 신경망의 입력 벡터는 총 128개이다.

그림 2.4는 숫자 '7'의 전역적인 특징 벡터와 국부적인 특징 벡터의 예를 보여 주고 있다.

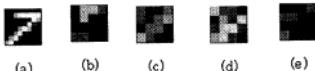


그림 2.4 숫자영상에서 특성이 추출된 영상

- (a) 전역적 특징, (b)-(e) 국부적 특징
- [(b) 수평, (c) 수직, (d) 좌대각, (e) 우대각 방향]

III. Raised Cosine RBF 신경망

3.1 Raised Cosine RBF 신경망

RBF 신경망은 Moody와 Darken이 제안한 신경망으로 함수적 근사화 이론에서 그 유래를 찾아 볼 수 있다[4]. 구조적인 특징은 그림 3.1에서와 같이 대부분 형태가 다른 2개의 종으로 이루어졌으며 입력층에서는 비선형 변환이 수행되며 입력층과 출력층 사이에는 선형 변환이 수행되는 전형 신경망이라는 점이다.

입력층의 활성화 함수로는 Gaussian 함수, Inverse Multiquadric 함수 등과 같은 RBF가 사용된다. 즉, 입력이 중심에 가까우면 출력이 최대가 되고 멀어지면 빠르게 0으로 줄어드는 함수들이다. 따라서 현재 입력 벡터에 가장 가까운 중심을 갖는 입력 뉴런의 출력값이 다른 입

력 뉴런들의 출력값보다 매우 크게 되므로 이 입력 뉴런의 활성값으로 RBF 신경망의 출력 값이 근사화될 수 있다. 이러한 점이 지역적 근사화를 가능하게 하고 학습 속도를 빠르게 할 수 있는 주요한 요인이 된다.

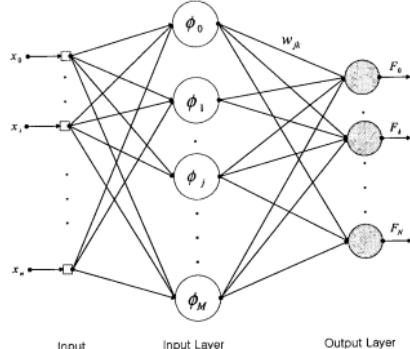


그림 3.1 Radial Basis Function Networks

Gaussian RBF는 그림 3.2에서 보듯이 입력 z 의 절대치가 커질수록 그 출력값이 점점 0으로 가까워지고 있음을 알 수 있다. 그러나 출력값은 0에 한없이 가까워 지기만 할 뿐 절대 0이 되지는 않는다. 따라서 z 를 신경망의 입력과 입력 뉴런의 중심값과의 차이라고 한다면 그 차이가 커지더라도, 다시 말해 z 의 절대치가 커지더라도 그 입력 뉴런의 출력은 0보다는 항상 큰 아주 작은 값을 가지고 있게 되는 것이다. 그렇기 때문에 Gaussian RBF의 RBF 신경망에의 적용은 이런 작은 값까지 계산에 포함해야 하기 때문에 학습 속도가 느려질 수 있다.

본 논문에서는 위와 같은 문제를 해결하고자 RBF 신경망의 RBF로 비선형 시스템의 근사화에 사용하였던 식 3.2와 같은 Raised Cosine RBF를 적용하였다[5]. 그림 3.2는 Rasised Cosine RBF를 Gaussian RBF와 비교하여 보여주고 있다.

$$\psi_g(z) = \exp(-z^2) \quad (\text{식 } 3.1)$$

$$\psi_c(z) \triangleq \frac{1 + \cos(\pi z)}{2}, \quad |z| \leq 1 \quad (\text{식 } 3.2)$$

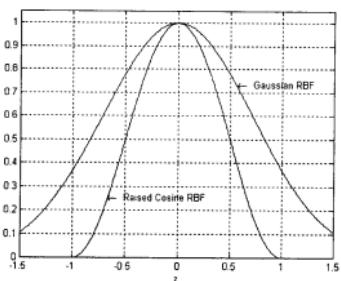


그림 3.2 Raised Cosine and Gaussian RBFs

Raised Cosine RBF는 Gaussian RBF와 달리 입력 z 의 절대치가 커져서 어느한계, 즉 반경을 넘으면 출력이 0이 되는 특징을 가지고 있다. 이러한 특징 때문에 입력 벡터와 어느 입력 뉴런의 중심값 벡터의 차이 z 가 그 입력 뉴런의 반경 이상으로 벗어지면 이 입력 뉴런의 출력이 0이 되므로 이 입력 뉴런의 출력값은 계산 할 필요가 없다. 따라서 학습속도를 더욱 빠르게 할 수 있는 것이다.

3.2 Raised Cosine RBF 신경망의 학습

RBF 신경망은 입력층 활성 함수의 중심값, 반경 그리고 입력층과 출력층사이의 웨이트를 학습시킬 수 있다. 본 논문에서는 목표값이 미리 주어지는 지도학습의 형태를 취하고 위 세 개의 파라미터들을 네트워크의 출력과 목표값의 차이가 최소화하는 방법에 의해 적응적으로 생성되도록 하였으며 이를 위해 LMS 알고리듬의 일반적인 표현방법인 Error Gradient Descent 알고리듬을 적용하여 학습시켰다[6].

먼저 하나의 입력 패턴에서 데이터 수가 n 인 신경망의 입력 벡터는 아래와 같이 표현할 수 있다.

$$\hat{x}_i \quad (i=0, 1, \dots, n)$$

i : 입력 패턴의 위치

입력 데이터의 수가 n 인 신경망에서 j 번째 은닉층의 출력은 식 3.3과 같이 표현되고, 뉴런의 출력값은 식 3.4와 같이 k 번째 출력 뉴런에서의 출력값을 나타낸다.

$$\phi_j(\hat{x}_i) \approx \prod_{i=1}^n \psi_c\left(\frac{\hat{x}_i - t_{ij}}{r_j}\right) \quad (식 3.3)$$

3.3)

$$F_k(\hat{x}_i) = \sum_{j=1}^M w_{jk} \phi_j(\hat{x}_i) \quad (식 3.4)$$

3.4)

j : 입력층의 뉴런 위치

k : 출력층의 뉴런 위치

M : 입력 뉴런 수

N : 출력 뉴런 수

r_j : Radius of Raised Cosine RBF ($r_j \neq 0$)

t_{ij} : Raised Cosine RBF의 중심값 벡터

w_{jk} : 입력층과 출력층사이의 웨이트 벡터

F_k : k 번째 출력 뉴런의 출력값

다음으로 네트워크의 출력값 F_k 와 목표치 d_k 와의 차이 e_k 를 식 3.5와 같이 구하여 에러함수 E_p 를 식 3.6과 같이 정의 하였다.

$$e_k = d_k - F_k(\hat{x}_i) \quad (식 3.5)$$

$$E_p = \frac{1}{2} \sum_{k=1}^N e_k^2 \quad (식 3.6)$$

d_k : 입력 패턴 한 개에 대한 k 번째 출력 뉴런에서의 목표값

e_k : k 번째 출력 뉴런에서의 목표값과 출력값의 차이

따라서 각 파라미터들의 변화에 대한 에러함수를 최소화하기 위하여 식 3.7 ~ 3.9를 사용하여 각 파라미터들을 생성하였다. 여기서 η_1, η_2, η_3 는 학습률, 그리고 t 는 시간을 나타낸다.

$$w_{jk}(t+1) = w_{jk}(t) - \eta_1 \cdot \frac{\partial E_p(t)}{\partial w_{jk}(t)} \quad (식 3.7)$$

$$t_{ij}(t+1) = t_{ij}(t) - \eta_2 \cdot \frac{\partial E_p(t)}{\partial t_{ij}(t)} \quad (식 3.8)$$

$$r_j(t+1) = r_j(t) - \eta_3 \cdot \frac{\partial E_p(t)}{\partial r_j(t)} \quad (식 3.9)$$

IV. 실험 및 결과

필기체 숫자 데이터베이스 안에는 총 6000개의 데이터가 있는데 이중에 4000개를 학습에 사용하였고 2000개를 인식 성능 평가에 사용하였다. 이들 학습 데이터와 시험 데이터는 서로 중첩되지 않는다. 실험에 사용된 Raised Cosine RBF 신경망의 구조는 입력이 128개이며 입력층의 뉴런이 256개이고 출력층의 뉴런은 1개이다. 각 파라미터들의 초기 값으로 웨이트는 0.01~2, 중심값은 0~1, 반경은 5~5.3 사이의 다양한 값을 주었다. 또한 업데이트를 위한 학습률 η_1, η_2, η_3 는 각각 0.012, 0.01, 0.01로 주었다. 이들 값은 최상의 인식률이 되도록 실험을 통하여 결정되었으며 실험에 쓰인 컴퓨터의 사양은 CPU는 Intel Pentium III 450MHz이고 RAM은 128MB이다.

신경망의 학습 회수는 더 이상 오차가 감소하지 않는

600회 정도에서 멈추었다. 그 후에 시험 데이터 2000개에 대해 숫자 인식 성능 테스트를 수행하였다. 표 4.1은 학습과 시험 데이터에 대한 학습 결과와 시험 결과를 보여주고 있다.

표 4.1 학습 및 시험 데이터에 대한 인식률

	인식률(인식한 데이터수/입력 데이터수)
학습	98.90% (3956 / 4000)
시험	98.05% (1961 / 2000)

표 4.1에서 보듯이 학습 데이터에 대한 인식률은 98.90%, 시험 데이터에 대한 인식률은 98.05%로 나타났다. 표 4.2는 시험 데이터에 대한 Confusion Matrix로서 각 숫자에 대한 신경망의 인식률을 보여주고 있다.

표 4.2 Raised Cosine RBF 신경망의 각 숫자별 인식률

(ID: 입력 데이터, RD: 인식한 데이터, U: Unknown)

ID	0	1	2	3	4	5	6	7	8	9	U	인식률 (%)	예외률 (%)
0	196		1						2	1	0	98.0	2.0
1		198							1	0	99.0	1.0	
2	1	1	197					1	1		0	98.5	1.5
3		1	194	2	1				2	0	97.0	3.0	
4			1	196		2			1	0	98.0	2.0	
5				2	196	1			1	0	98.0	2.0	
6					197				1	1	0	98.5	1.5
7	1		1				196	1	0	98.0	2.0		
8		1	1					196	1	0	98.0	2.0	
9	1		1					1	195	0	97.5	2.5	
평균치												98.05	1.95

표 4.3은 Concordia 대학의 같은 숫자 데이터베이스를 사용한 다른 인식률 연구논문과 인식률을 비교한 것이다. 본 논문에서 제안한 방법이 다른 인식률 연구논문에서 제안한 방법보다 상대적으로 높은 인식률을 보여주고 있음을 볼 수 있다.

표 4.4는 Gaussian RBF 신경망과 본 논문에서 제안한 Raised Cosine RBF 신경망의 학습 속도를 학습 데이터에 대하여 학습 횟수 1회, 10회, 100회에 걸쳐서 비교한 것이다. Gaussian RBF 신경망의 입력층과 출력층의 뉴런의 개수는 Raised Cosine RBF 신경망과 동일하다. 표 4.4에서 보듯이 일반적으로 학습 속도가 빠른 것으로 알려진 Gaussian RBF 신경망보다도 학습 속도가 좀 더 빠르게 나타났으며, 학습을 진행함에 따라 Gaussian RBF 신경망은 1회당 평균 학습 속도가 거의 변화가 없이 일정한 반면 Raised Cosine RBF 신경망

은 약간씩 속도가 줄어드는 경향을 보이고 있다. 이는 앞에서 예상했던 결과로 Raised Cosine RBF가 가지는 특성 때문이라 할 수 있다.

표 4.3 다른 논문과 인식률 비교

연구논문	인식률
최한고의[7]	98.0%
Lee[2]	97.30%
Lee[8]	96.5%
김영준의[9]	96.15%
Krzyzak[10]	94.85%
Legault[11]	93.90%
본논문	98.05%

표 4.4 Gaussian RBF 신경망과 Raised Cosine RBF

신경망의 학습속도 비교(단위 sec)

학습 횟수	Gaussian RBF 신경망	Raised Cosine RBF 신경망
1	241.2	235.3
10	2413.6	2334.9
100	24122.1	23345.7

V. 결론

본 논문에서는 Radial Basis Function으로 Raised Cosine RBF를 쓰는 RBF 신경망을 이용한 무제약 서체 숫자 인식률을 다루고 있다. 제안된 신경망은 전향적인 신경망으로서 정적인 구조를 가지고 있어 페턴 분류 같은 정적인 시스템에 적합하다. 또한 Raised Cosine RBF는 기존의 Gaussian RBF와는 다른 특성을 갖는다. 이러한 점이 좀 더 빠른 학습 속도를 나오게 하는 것을 확인하였으며, 인식률에 있어서도 만족할 만한 결과를 가져왔다.

앞으로 전처리 과정에서 좀 더 세밀한 특징 추출이 이루어진다면 인식률 향상을 가져올 것으로 예상되며 출력층의 뉴런을 현재의 1개에서 다단 출력으로 늘렸을 경우에도 인식률 향상이 기대된다.

접수일자 : 2001. 12. 20 수정완료 : 2002. 1. 23

본 연구는 한국과학재단 지정 금오공과대학교 전자부품고품질화 및 공정자동화 연구센터의 지원에 의한 것입니다.

참고문헌

- [1] B. Bavarian, "Introduction to Neural Networks for Intelligent Control", IEEE Control System Magazine, pp. 3-7, Apr. 1988.
- [2] Seong-whan Lee, Hee-heon Song, "A New Recurrent Neural Network Architecture for Visual Pattern Recognition", IEEE Trans. on Neural Networks, vol. 8, no. 2, Mar. 1997.
- [3] W. K. Pratt, "Digital Image Processing", New York, Wiley, 1988.
- [4] Simon Haykin, "Neural Networks", Prentice-Hall, 1999.
- [5] Robert J. Schilling, James J. Carroll, and Ahmad F. Al-Ajlouni, "Approximation of Nonlinear Systems with Radial Basis Function Neural Networks", IEEE Trans. on Neural Networks, vol. 12, no. 1, Jan. 2001.
- [6] N. B. Karayiannis, "Gradient Descent Learning of Radial Basis Neural Networks", Proc. IEEE International Conference on Neural Networks, vol. 3, Houston, Texas, pp. 1815-1820, 1977.
- [7] 최한고, 김상희, 이상재, "수정된 카오스 신경망을 이용한 무제약 서체 숫자 인식", 신호처리·시스템 학회 논문지, vol. 2, no. 1, pp. 44-52, 2001.
- [8] Sukhan Lee, Jack Chien Pan, "Unconstrained Handwritten Numerical Recognition Based on Radial Basis Competitive and Cooperative Networks with Spatio-Temporal Feature Representation", IEEE Trans. on Neural Networks, vol. 7, no. 2, Mar. 1996.
- [9] 김영준, 이성환, "유전자 알고리듬과 다중 러스터 신경망을 이용한 무제약 필기체 숫자의 오프라인 인식", 한국정보과학회 논문지, vol. 21, no. 8, 1994.
- [10] A. Krzyzak, W. Dai and C.Y.Suen, "Unconstrained Handwritten Character Classification Using Modified Backpropagation Model", Proc. 1st Int. Workshop on Frontiers in Handwriting Recognition, Montreal, Canada, pp. 155-166, 1990.
- [11] R. Legault and C. Y. Suen, "Contour Tracing and Parametric Approximations for Digitized Patterns".

Computer Vision and Shape Recognition, World Scientific Publishing, Singapore, pp. 225-240, 1989.

박준근(Jun-Keun Park)

準會員

2000년 금오공과대학교 전자공학과
(공학사)

2000년-현재 금오공과대학교
전자공학과 석사과정
관심분야 : 패턴 인식, 신경회로망,
컴퓨터 구조



김상희(Sang-Hee Kim)

正會員

1983년 홍익대학교 전기공학과
(공학사)
1985년 연세대학교 전기공학과
(공학석사)

1992년 TEXAS A&M
(공학박사)



1993 - 현재 금오공과대학교 전자공학부 부교수
관심분야 : 신경회로망, 계측 제어, 생체전자

박원우(Won-Woo Park)

正會員

1981년 서강대학교 전자공학과
(공학사)

1986년 The Univ. of Texas at Austin
(공학석사)
1991년 The Univ. of Texas at Austin
(공학박사)



1991년-1993년 삼성전자 컴퓨터부문 수석연구원

1993년 - 현재 금오공과대학교 전자공학과 부교수
관심분야 : 컴퓨터 구조, 컴퓨터 그래픽스, 인공지능
