

CBAM 모델에 관한 연구

(A Study on CBAM Model)

任 庸 淳*, 李 根 泳*

(Yong Soon Im and Keun Young Lee)

要 約

본 논문에서는 CBAM(Combination Bidirectional Associative Memory) 모델의 알고리즘을 제안하고, 패턴의 연상 및 인식에 대하여 시뮬레이션함으로써 CBAM 모델의 성능을 분석하고 평가했다. 학습 과정에서는 주어진 학습패턴으로 각각의 상관관계 행렬을 얻고, 각각의 행렬 원소를 결합하여 하나의 행렬(Combination Correlation Matrix, CCM)로 구성된다. 연상과정에서는 CCM의 원소를 역으로 분해하여 모든 상관관계 행렬을 산출한다. 임의의 입력패턴과 모든 상관관계 행렬의 계산에서 가장 작은 에너지값을 가진 패턴을 선택한다. CBAM 모델을 이용함으로써 얻은 장점은 다음과 같다. 첫째, 20%미만의 잡음이 첨가된 모든 패턴을 연상할 수 있다. 둘째, 기억용량(memory capacity)을 더욱 증가시킬 수 있다. 셋째, CCM의 수행으로 학습시간을 감소시킬 수 있다.

Abstract

In this paper, an algorithm of CBAM(Combination Bidirectional Associative Memory) model proposes, analyzes and tests CBAM model's performances by simulating with recalls and recognitions of patterns. In learning-procedure each correlation matrix of training patterns is obtained. As each correlation matrix's some elements correspond to juxtaposition, all correlation matrices are merged into one matrix (Combination Correlation Matrix, CCM). In recall-procedure, CCM is decomposed into a number of correlation matrices by splitting its elements into the number of elements corresponding to all training patterns. Recalled patterns are obtained by multiplying input pattern with all correlation matrices and selecting a pattern which has the smallest value of energy function. By using a CBAM model, we have some advantages. First, all pattern having less than 20% of noise can be recalled. Second, memory capacity of CBAM model, can be further increased to include English alphabets or patterns. Third, learning time of CBAM model can be reduced greatly because of operation to make CCM.

1. 서론

* 正會員, 成均館大學校 電子工學科
(Dept. of Elec. Eng., Sungkyunkwan Univ.)
接受日字: 1993年 8月 2日

기존의 Von Neumann형 컴퓨터에 인간과 같은 기능을 부여하려는 노력과 한계에 도달함으로써 이에

대한 해결 방안으로 인간의 두뇌를 근거로 신경회로망에 대한 관심이 높아지고 있다. 신경회로망은 기존의 Von Neumann형 컴퓨터에 비해 패턴인식(pattern recognition), 음성인식(speech recognition), 제어(control)등의 여러 분야에서 좋은 성능을 보여주었다. 신경회로망의 기초는 1943년 McCulloch과 Pitts의 논문으로 그 당시 많은 영향을 미치고, 그후 보다 직접적인 연구는 1949년 Donald O. Hebb의 'Hebb의 가설' 혹은 'Hebb의 학습법칙'을 들 수 있다.^[8] 이 법칙은 1972년 Kohonen^[10,11], 1982년 Hopfield 모델^[5,7,8,9], 그리고 이와 비슷한 특징을 가진 1985년 양방향 연상 기억(Bidirectional Associative Memory, BAM) 모델의 기초가 되었다.^[1,2,3,4,5,6,7,12,13]

연상기억 모델의 형태는 크게 자기연상 기억(Autoassociative memory) 모델인 Hopfield 모델과 이상연상 기억(Heteroassociative memory) 모델인 BAM 모델이 있다. 자기연상 기억 모델은 불완전한 입력 패턴벡터를 받아들여 기억 내용에 저장되어 있는 정확한 패턴벡터를 출력으로 낼 수 있으나 연관되어 있는 정확한 다른 기억내용의 패턴벡터를 출력할 수 없다. 반면에 이상연상 기억모델은 입력 패턴벡터를 받아 들여 연관된 다른 패턴을 출력한다. BAM 모델은 다른 모델에 비해 구현이 쉽고, 양방향성을 갖고 있으나 모델 자체가 단층 구조이므로 성능(performance)의 한계가 있었다. 또한 기억된 패턴의 수가 증가하면 할 수록 상대적으로 기억용량(memory capacity)과 오차보정 능력이 감소하게 되며, 난수 잡음(random noise)이 포함된 입력 패턴에 대해서는 적은 수의 패턴인 경우라도 잘못 인식하게 되었다.

본 논문에서는 신경회로망의 기억용량과 오차보정 능력을 향상시키기 위해 개선된 학습및 연상방법을 제안하게 되었고, 개선된 BAM(Combination BAM, CBAM) 모델을 이용함으로써 문제점을 개선할 수 있었다. 본 논문의 구성은 II장에서 기본 개념, III장에서는 제한한 CBAM 모델의 알고리즘, IV장에서는 시뮬레이션및 결과, 마지막으로 V장에서는 결론을 맺는다.

II. 본 론

1. BAM 모델의 기본 개념^[1,2,3,4,5,6,7]

1985년 Kosko에 의해 처음 제안된 양방향 연상기억(BAM) 모델의 기본 구조는 다음 그림 1과 같다. 주어진 벡터 A와 B의 외적을 구하고, n x p인 각각

의 상관관계 행렬(correlation matrix)을 합하여 학습시킨 후 기억한다




그림 1. BAM 모델의 구조
Fig. 1. The structure of BAM model.

기본 식은 다음과 같이 각각의 n과 p개의 원소(element)로 구성된 벡터 A와 B는 N개의 학습벡터로 구성되어 있다.

$$\{(A_1, B_1), (A_2, B_2), \dots, (A_i, B_i), \dots, (A_N, B_N)\}$$

$$A_i = (a_{i1}, a_{i2}, \dots, a_{ij}, \dots, a_{ip})$$

$$B_i = (b_{i1}, b_{i2}, \dots, b_{ij}, \dots, b_{ip})$$

그리고, a_{ij}, b_{ij} 는 각각 0, 1인 이진형태(binary type)이다. 입출력 벡터 A와 B의 외적으로 상호간의 연결강도의 세기를 결정하는데 이용하는 상관관계 행렬(correlation matrix)은 다음 식 (1)과 같다.

$$M = \sum_{i=1}^N X_i Y_i \tag{1}$$

여기서, X_i, Y_i 는 이진형태인 A_i, B_i 를 쌍극형태(bipolar type)로 변환한 것이다.

다음과 같이 임의의 벡터 (α, β) 가 입력되면 순방향에서는 기억된 행렬 M을, 역방향에서는 전치(transpose)행렬 M^T 를 각각 식 (2)와 (3)에 적용함으로써 연상된 결과벡터 (α', β') 를 얻게된다.

$$\beta' = \Phi(\alpha M) \tag{2}$$

$$\alpha' = \Phi(\beta' M^T) \tag{3}$$

$$\Phi(F) = G = (g_1, g_2, \dots, g_i, \dots, g_n) \tag{4}$$

$$F = (f_1, f_2, \dots, f_i, \dots, f_n) \tag{5}$$

$$\begin{aligned}
 g_i &= 1 && : f_i > 0 \\
 g_i &= \begin{cases} 0 \text{ (이진)} \\ -1 \text{ (쌍극)} \end{cases} && : f_i < 0 \\
 g_i &= \text{먼저 값 } (g_i) && : f_i = 0
 \end{aligned} \tag{6}$$

여기서, 'T'는 역방향 과정의 행렬의 전치(transpose)이며, 식 (4), (5), (6)은 i번째 원소의 임계조건(threshold condition)이다. 임의의 벡터 (α, β)를 연상시키기 위해 최적의 안정상태를 표현하는 Lyapunov 혹은 에너지함수(energy function) E는 다음 식 (7)과 같다.

$$E = -a M \beta^T \tag{7}$$

에너지함수가 국부극소점(local minimum)에 위치할 때 안정된 상태이므로 원하는 패턴을 연상시킬 수 있게 되고, 연상된 패턴벡터의 에너지함수는 근접한 어떤 점 보다 작게 된다.

2. MTBAM (Multiple Training BAM) 모델 ^[12,13]

연상하고자 하는 패턴벡터 (A_i, B_i)를 다수학습(multiple training)에 의해 각각의 패턴벡터를 연상시킬 수 있다. 또한 패턴벡터 (A_i, B_i)를 연상되도록 다음과 같이 정의할 수 있다.

$$P = (q-1)X_i^T Y_i \tag{8}$$

$$E'(A, B) = -A_i M B_i^T - (q-1)A_i X_i^T Y_i B_i^T \tag{9}$$

식 (8)은 주어진 벡터(A_i, B_i)의 행렬에 임의의 정수인 학습계수 (q-1)을 곱하므로 전체 에너지함수는 더욱 안정하게 된다. 그리고 다수학습으로 적당한 학습계수 q의 값을 선정함으로써 에너지함수 E'는 더욱 작은 값으로 감소될 수 있다. 다수학습(multiple training)은 각각의 패턴벡터는 연상되지만, 모든 패턴벡터가 연상된다고 알려지지는 않았고, 한정된 n, N에서 기억용량(memory capacity)과 오차보정률은 낮은 상태였었다.

III. 제안한 CBAM 모델

기존의 방법은 상관관계 행렬의 원소를 부분적으로 변경하여 여러 패턴에 적합하도록 반복학습에 의해 결정 되었으나, 임의의 패턴이 주어졌을 때 부분변경된 행렬은 그 고유한 연상기억 능력을 상실하는 경우

가 있었다. 그래서, 각각의 상관관계 행렬(correlation matrix)의 결합방법으로 기억하고 연상하고자 할 때는 역으로 분해방법에 의해 과정을 수행한다. 이 방법은 불완전한 패턴벡터나 잡음이 첨부된 패턴벡터가 입력되더라도 원래 기억된 패턴벡터에서 최적의 안정 상태를 찾아갈 수 있는, 향상된 연상 및 오차보정 능력을 지니고 있다. 이 개선된 BAM(Combination-BAM, CBAM) 모델은 본래의 BAM 모델과 같이 Hebb의 법칙을 사용했다. Hebb의 법칙은 벡터 A에 대해 벡터 B를 갖는 연상기억 모델은 양방향 연상 기억 능력이 있으며, 내적구현 특성을 가지고 학습능력을 증대시키는 장점을 가지고 있다. 제안한 CBAM 모델의 구조는 그림 2와 같고, M_i'는 각각의 행렬을 결합한 하나의 행렬이다.




그림 2. CBAM 모델의 구조
Fig. 2. The structure of CBAM model.

1. 학습과정(결합과정)

벡터 A와 B를 쌍극형태(bipolar type)로 변환하고, 각각의 외적으로 얻은 N개의 상관관계 행렬(correlation matrix) M₁, ..., M_i, ..., M_N은 다음과 같이 표현된다.

$$M_i = X_i^T Y_i \tag{10}$$

구성된 상관관계 행렬 M_i의 쌍극형(bipolar type)인 원소를 역으로 이진수(binary)로 변환한다. 그리고 변환된 상관관계 행렬 M_i'는 다음 식과 같다.

$$M_i' = (M_i + 1) / 2 \tag{11}$$

이진화된 행렬 M_i'의 원소들을 결합(combination)방법에 의해 하나의 행렬(combination correlation matrix, CCM)으로 변환되고 표현은 다음

과 같다.

$$M^c = \text{Combination}(M'_i) \quad (12)$$

$$= M'_1 | \dots | M'_N \quad (13)$$

$$= \begin{bmatrix} m'_{1(1,1)} & \dots & m'_{1(1,p)} \\ \vdots & \ddots & \vdots \\ m'_{1(n,1)} & \dots & m'_{1(n,p)} \end{bmatrix} | \dots | \begin{bmatrix} m'_{N(1,1)} & \dots & m'_{N(1,p)} \\ \vdots & \ddots & \vdots \\ m'_{N(n,1)} & \dots & m'_{N(n,p)} \end{bmatrix}$$

여기서, $m'_{a(b,c)}$: a = 행렬의 수
 : b, c = 원소의 행렬

위의 식에서 '|'은 M'_1 의 원소 $m'_{1(1,1)}$ 뒤에 M'_N 의 원소 $m'_{N(1,1)}$ 를 덧붙여줌을 의미한다. 그리고 표현은 다음과 같다

$$= \begin{bmatrix} m'_{1(1,1)} | \dots | m'_{N(1,1)} & \dots & m'_{1(1,p)} | \dots | m'_{N(1,p)} \\ \vdots & \ddots & \vdots \\ m'_{1(n,1)} | \dots | m'_{N(n,1)} & \dots & m'_{1(n,p)} | \dots | m'_{N(n,p)} \end{bmatrix} \quad (14)$$

행렬의 원소들이 결합되어 밀줄친 하나의 원소 $m'_{1(1,1)} | \dots | m'_{N(1,1)}$ 로 되고, 결합된 원소를 밑의 비트(bit)부터 나누어 10진수로 변환을 하면 다음 식 (15)와 같은 하나의 상관관계 행렬 M^c 로 표현하게 된다.

$$M^c = \begin{bmatrix} m_{(1,1)} & \dots & m_{(1,p)} \\ \vdots & \ddots & \vdots \\ m_{(n,1)} & \dots & m_{(n,p)} \end{bmatrix} \quad (15)$$

변환방법으로 얻은 $m(\dots)$ 의 원소에 의해 하나의 새로운 상관관계 행렬 M^c 을 구성한다. 식 (15)에서는 원래 기억된 패턴벡터의 특징을 그대로 기억하는 기능을 가지고 있음을 의미하고, 기억된 상관관계 행렬은 패턴의 특징에 의해 연관된 패턴을 연상 및 인식 할 수 있다.

2. 연상과정(분해과정)

식 (15)로 구성된 상관관계 행렬 M^c 는 각각의 고유 특징을 기억하고, 임의의 패턴이 주어지면 기억한 행렬에 의해 원하는 패턴을 연상시킬 수 있다. 따라서 M^c 의 원소를 이진화하고, 여러개의 이진수로 결합되어 있는 원소를 단일(bit) 원소로 분해하여 N 개의 행렬 M'_i 를 산출하게 되며, 표현은 다음과 같다.

$$M'_i = \text{Decomposition}(M^c) \quad (16)$$

$$= \begin{bmatrix} m'_{1(1,1)} & \dots & m'_{1(1,p)} \\ \vdots & \ddots & \vdots \\ m'_{1(n,1)} & \dots & m'_{1(n,p)} \end{bmatrix}, \dots, \begin{bmatrix} m'_{N(1,1)} & \dots & m'_{N(1,p)} \\ \vdots & \ddots & \vdots \\ m'_{N(n,1)} & \dots & m'_{N(n,p)} \end{bmatrix}$$

위 식은 원래 기억된 행렬 M_i 만으로 원하는 패턴을 연상시킬 수 없었고, 이에 대한 해결 방안으로 N 개의 행렬 M'_i 와 다음의 계수 q_{ij} 로 부터 행렬 M_j^* 를 얻게 되었다. 여기서, '*'가 표시된 행렬 M_j^* 는 M_i 와 구분되어 진다.

$$M_j^* = \sum_{i=1}^N q_{ij} (2 * M'_i - 1) ; j = 1, \dots, N \quad (17)$$

임의의 패턴 (α, β)가 주어지면 같거나 가장 근사한 패턴 (A_i, B_i)를 연상시키기 위해, 얻은 N 개의 행렬 M_j^* 를 다음 식에 적용할 수 있다.

$$\beta'_j = \Phi(\alpha M'_j) \quad (18)$$

$$\alpha'_j = \Phi(\beta'_j M_j^{*T}) \quad (19)$$

여기서, Φ 는 식 (4), (5), (6)의 임계조건(threshold condition)을 사용하였다.

계수 q 의 구성은 다음과 같이

$$q = \begin{bmatrix} q_{1,1} & q_{1,2} & \dots & q_{1,N-1} & q_{1,N} \\ q_{2,1} & q_{2,2} & \dots & q_{2,N-1} & q_{2,N} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \dots & q_{ij} & \dots \\ \vdots & \vdots & \dots & \vdots & \vdots \\ q_{N-1,1} & q_{N-1,2} & \dots & q_{N-1,N-1} & q_{N-1,N} \\ q_{N,1} & q_{N,2} & \dots & q_{N,N-1} & q_{N,N} \end{bmatrix} \quad (20)$$

여기서, $q_{ij} \neq 0 ; i, j = 1, \dots, N$

$$q_{ij} \geq \frac{N}{2} ; i = j$$

$$q_{ij} \ll \frac{N}{2} ; i \neq j$$

에너지함수는 식 (21)과 같이 표현된다.

$$E'(A, B_i) = -A M'_j B_i^T \quad (21)$$

주어진 임의의 벡터(α, β)로 얻은 N 개의 결과벡터 (α', β')의 에너지함수를 얻을 수 있고, 위의 식을 이용함으로써 N 개의 에너지함수 E' 를 계산하여 가장 음수로 국부극소점(local minimum)에 접하는 패턴

백터를 결정하게 된다.

IV. 시뮬레이션 및 결과

본 장에서는 개선된 BAM(Combination-BAM, CBAM) 모델의 시뮬레이션을 통하여 특성과 성능을 평가하고자 하였다. 사용된 패턴은 숫자패턴과 영문자패턴 모두 n 과 p 가 서로 같은 35bit 원소로 시뮬레이션을 하였다. 그리고 패턴 모두 +1과 0의 값인 이진형태를 +1과 -1의 쌍극형태로 변환하여 사용하였다. 본 모델은 입력층과 출력층으로 구성되었고, 적용된 비선형함수로는 일반적인 계단함수(unit function)를 사용하였다. 시뮬레이션을 통하여 학습과정에서는 각각의 행렬을 기억함으로 반복이 없다는 특성을 알게 되었고, 연상과정에서는 얻은 학습계수 q 에 의해 입력력 패턴의 오차를 보정할 수 있었고, 반복없이 안정된 상태에 도달하였다. 그림 3의 숫자패턴과 그림 4의 영문자패턴을 사용하였고, 잡음이 첨부된 영문자패턴은 그림 5와 같다.




그림 3. 시뮬레이션에 이용된 숫자 패턴
Fig. 3. Numerical patterns used in simulation.




그림 4. 시뮬레이션에 이용된 영문자 패턴
Fig. 4. English character patterns used in simulation.

1. 에너지함수(energy function)의 최적화
연상과정시 에너지함수에 의해 최적의 q 값을 선택하는 여러 단계를 보여 주고있다. 그림 6의 (a)는 q 값이 모두 같은 1인 경우이고(직선), 앞의 조건으로




그림 5. 잡음이 첨부된 영문자 패턴
Fig. 5. English Character patterns having noise

q 값의 변경에 의해 (b)는 곡선 중 가장 낮은 값을 얻음으로써 주어진 패턴을 완전하게 연상할 수 있었다. 여기서 사용한 패턴은 잡음이 첨부되지 않은 영문자 패턴 'O'이다.




그림 6. 에너지함수의 최적화
Fig. 6. Optimization of Energy functions.

2. Hamming distance에 의한 오차보정능력 평가
그림 3과 4의 기억된 패턴을 이용하여 오차보정(Error-Correction)능력을 [표 1] 과 그림 7 (a), (b)로 보여준다. 그림 7의 오차보정률(Error-Correction Rate)의 표현식은 다음과 같다.

$$Error-Correction Rate [\%] = \frac{(\text{전체 패턴수} - \text{실패한 패턴수})}{\text{전체 패턴수}} * 100 [\%]$$

여기서, 숫자 패턴과 영문자 패턴을 각각 3,600개, 9,360개 난수발생하고, 이에 대한 시뮬레이션 결과로써 제안한 알고리즘의 성능을 보여주고 있다. 그리고 잡음이 첨부되지 않은 Hamming Distance(HD)가 0인 경우, 모든 패턴을(100%) 연상할 수 있음을 보여준다.(표 1, 그림 7)

그림 8은 잡음이 첨부된 영문자 'G' 패턴 (sample)을 이용한 최적의 에너지함수와 시뮬레이션 결과(result B, A)를 보여준다.

표 1. HD에 대한 시뮬레이션 결과
Table 1. Simulation results for HD.

[HD : BIT, %]

패턴 \ HD(bit)	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14
숫자	100	97	97	97	95	93	91	87	71	76	71	58	48	20	13
영어	100	99	98	97	96	93	90	87	82	70	58	40	16	9	1




그림 7. 오차 보정 능력 평가
(a) 숫자 패턴을 사용
(b) 영문자 패턴을 사용
Fig. 7. Estimation of Error-correction capability.
(a) Using Numerical patterns.
(b) Using English character patterns.




그림 8. CBAM 모델의 시뮬레이션 결과
Fig. 8. Simulation result of CBAM model.

V. 결론

본 논문에서는 개선된 BAM(Combination-BAM, CBAM) 모델의 알고리즘을 제안하고, 그에 대한 분석과 시뮬레이션을 통하여 성능을 평가하였

다. 제안한 CBAM 모델의 시뮬레이션을 통하여 얻은 장점은 다음과 같다. 첫째, 20%미만의 잡음이 첨부된 모든 패턴을 연상할 수 있었다. 둘째, 기억용량 (memory capacity)을 더욱 증가시킬 수 있었다. 셋째, CCM의 수행으로 학습시간을 감소시킬 수 있었다. 제안한 CBAM 모델의 알고리즘을 이용함으로써 연상기억, 부분적으로 주어진 패턴만으로도 재생, 분류, 오차보정 능력면에서 좋은 성능을 보여 주었다.

參考文獻

- [1] B. Kosko, "Bidirectional Associative Memory," *IEEE Trans. Syst., Man, Cybern.*, vol.18, no.1, pp.49-60, Jan./Feb. 1988.
- [2] B. Kosko, "Competitive Adaptive Bidirectional Associative Memory," in *Proc. IEEE 1st ICNN*, vol.II, pp.759-766, 1987.
- [3] B. Kosko, "Adaptive Bidirectional Associative Memory," *Appl. Opt.*, vol. 26, no.23, pp.4947-4960, Dec. 1987. vol. II, pp. 759-766, 1987.
- [4] B. Kosko, *Neural Networks And Fuzzy Systems - A Dynamical Systems Approach To Machine Intelligence*, Prentice-Hall, Inc., 1992.
- [5] James A. Freeman and David M. Skapura, *Neural Networks Algorithms, Applications, and Programming Techniques*, Addison-Wesley Publishing Company, Inc., 1991.
- [6] K. Haines and R. Hecht-Nielsen, "A Bidirectional Associative Memory with Increased Information Storage Capacity," in *Proc. IJCNN 88*, vol.1, pp.181-190, 1988.
- [7] Philip D. Wasserman, *Neural Computing - Theory and Practice*, Van Nostrand Reinhold, 1989.
- [8] Richard P. Lippmann, "An Introduction to Computing with Neural Nets," *EEE ASSP Magazine*, pp.4-22, Apr. 1987.
- [9] R.J. McEliece, E.C. Posner, E.R.

- Rodemich, and S.S. Venkatesh, "The Capacity of the Hopfield Associative Memory," *IEEE Trans. on Information Theory*, 33(4), pp.461-482, July 1987.
- [10] T. Kohonen, *Self-Organization and Associative Memory*, Springer-Verlin Heidelberg, Third Edition, 1989.
- [11] T. Kohonen, "Correlation Matrix Memories," *IEEE Trans. Comput.*, vol. C-21, pp. 353-359, Apr. 1972.
- [12] Y.F. Wang, J.B. Cruz, Jr., and J.H. Mulligan, Jr., "Guaranteed Recall of All Training Pairs for Bidirectional Associative Memory," *IEEE Trans. Neural Networks*, vol.2, no.6, pp.559-567, Nov. 1991.
- [13] Y.F. Wang, J.B. Cruz, Jr., and J.H. Mulligan, Jr., "Two Coding Strategies for Bidirectional Associative Memory," *IEEE Trans. Neural Networks*, vol.1, no.1, pp. 81-92, Mar. 1990.

 著 者 紹 介



任庸淳(正會員)

1964年 10月 22日生. 1988年 성균관대학교 전자공학과(공학사). 1988년 ~ 1990년 금성사 평택연구소 근무. 1993년 성균관대학교 산업대학원 전자공학과(공학석사). 1994년 3월 ~ 현재 성균관대학교 대학원 전자공학과 박사과정 중. 주관심 분야는 신경회로망, 컴퓨터비전, 디지털신호처리 등임.



李根泳(正會員)

1947年 12月 30日生. 1973년 전남대학교 전기공학과(공학사). 1975년 한양대학교 대학원 전자공학과(공학석사). 1978년 한양대학교 대학원 전자공학과(공학박사). 1979년 3월 ~ 1980년 2월 Denmark 공과대학(객원교수). 1977년 3월 ~ 1981년 8월 광운공대 조교수. 1987년 9월 ~ 1988년 8월 영국 Loughborough 대학(객원교수). 1981년 9월 ~ 현재 성균관대학교 전자공학과 교수. 주관심 분야는 디지털 공학, 신경회로망, 컴퓨터비전, 디지털신호처리 등임.