

새로운 순환신경망을 사용한 문자인식성능의 향상 방안

정 낙 우*, 김 병 기**

The Improving Method of Characters Recognition Using New Recurrent Neural Network

Nak Woo Chung*, Byung Gi Kim**

요 약

산업발전과 기술의 대형화, 고도화 등으로 인하여 매년 방대한 양의 정보가 처리되고 있다. 정보화를 이루기 위해서는 대부분 종이로 기록되어 내려오던 정보를 컴퓨터에 저장하여 적기적소에 사용할 수 있어야 한다. 문자인식을 위한 신경망의 학습에 있어서 출력값을 재사용하는 신경망모델로는 순환신경망이 있다. 그러나 이러한 방법들의 대부분은 오프라인 필기체문자와 같은 정적인 패턴의 분류에 있어서는 효과적으로 적용되지 않는다.

이에 본 연구에서는 오프라인 필기체문자와 같은 정적인 패턴을 효과적으로 분류하기 위한 새로운 형태의 순환신경망을 제안한다. 본 논문은 Jordan과 Elman Model을 확장 결합한 새로운 J-E(Jordan-Elman) 신경망 모델을 사용하여 숫자 및 필기체 문자와 같은 정적인 패턴의 인식에서 기존의 신경망보다 성능이 향상되었음을 보여준다.

ABSTRACT

In the result of industrial development, largeness and highness of techniques, a large amount of information is being treated every year. Archive informationization, we must store in computer, all informations written on paper for a long time and be able to utilize them in right time and place. There is recurrent neural network as a model reusing the output value in learning neural network for characters recognition. But most of these methods are not so effectively applied to it.

This study suggests a new type of recurrent neural network to classify effectively the static patterns such as off-line handwritten characters. This study shows that this new type is better than those of before in recognizing the patterns, such as figures and handwritten characters, by using the new J-E(Jordan-Elman) neural network model in which enlarges and combines Jordan and Elman Model.

* 서강전문대학 전자계산과 부교수

** 전남대학교 전산학과 교수

I. 서론

인간의 5감각기관중에서 가장 두드러진 역할을 하는 시각체계에 관한 연구는 지난 수십 년에 걸쳐서 이루어져 왔다. 특히 지난 수년간에 걸쳐 패턴분류를 위한 수 많은 신경망 모델들이 제안되어 왔으며^[1] 그 중에서도 특히 다층전향 신경망 모델들은 다양한 형태와 크기를 갖는 패턴의 분류에 효과적으로 적용되어 왔다^[2]. 그러나 이러한 방법들만으로는 유사한 형태의 패턴인식에 효율적인 학습이 되지 않고 실제 많은 패턴들의 인식에서 만족할 만한 성능을 보여주지 못하고 있다. 따라서 이러한 문제점을 해결하기 위해서 다층전향신경망의 출력값을 분석하고, 입력패턴의 학습에 이러한 정보를 이용하는 것이 필요하다.

일반적으로 다층전향신경망의 은닉유니트들은, 분류에 유용한 정보를 극대화하도록 학습되며, 출력유니트들은 은닉유니트들로부터 주어진 정보를 구별하도록 학습된다^[3]. 신경망의 학습에 있어서 출력값을 재사용하는 신경망 모델로는 순환신경망(Recurrent Neural Network)을 들 수 있다. 최근에는 이러한 순환신경망을 오프라인 필기체 문자와 같은 정적인 패턴 인식에 적용하려는 연구가 많이 진행되고 있다^[4]. 그러나 이러한 방법들의 대부분은 음성과 같은 동적인 패턴 분류를 위하여 설계된 Jordan과 Elman 순환신경망에 기반을 두고 있으므로 오프라인 필기체문자와 같은 정적인 패턴의 분류에 있어서는 아직도 효과적으로 적용하기 어렵다^[17]. 그러므로 본 연구에서는 오프라인 필기체문자와 같은 정적인 패턴을 효과적으로 분류하기 위한 새로운 형태의 J-E 순환신경망을 제안한다. J-E 순환신경망은 3개의 층으로 구성되며 출력층과 은닉층에 각각 1개씩의 context unit를 포함한다.

출력유니트와 은닉유니트는 자기 자신을 포함하여 은닉유니트들과 다른 모든 출력 유니트들에 완전 연결되어 있다.

본 논문의 구성은 다음과 같다.

2절의 관련 연구에서는 context unit이론 및 기존의 Jordan순환신경망과 Elman순환신경망 모델들을 소개하며, 3절에서 Jordan 및 Elman 모델을 확장 결합한 새로운 J-E 모델을 제안한다. 또 4절에서는 J-E 모델을 이용한 simulation 결과를 분석하고, 5절에서는 결론 및 앞으로의 연구 방향에 대하여 논한다.

II. 관련 연구

2.1 단순 순환망


문자열의 학습에 쓰이는 단순순환망은 전방향 연결구조를 갖는 "부분 순환망"이라고 한다^[5]. 또한 역방향 구조를 갖는 특별한 unit층이 있는데 이것을 context층이라고 한다^[6]. 역방향으로 연결되는 context층의 가중값은 고정되어 있으며 정보는 순차적으로 처리되고 기본적인 학습 과정은 표준 back propagation과 비슷하다.

2.2 구조

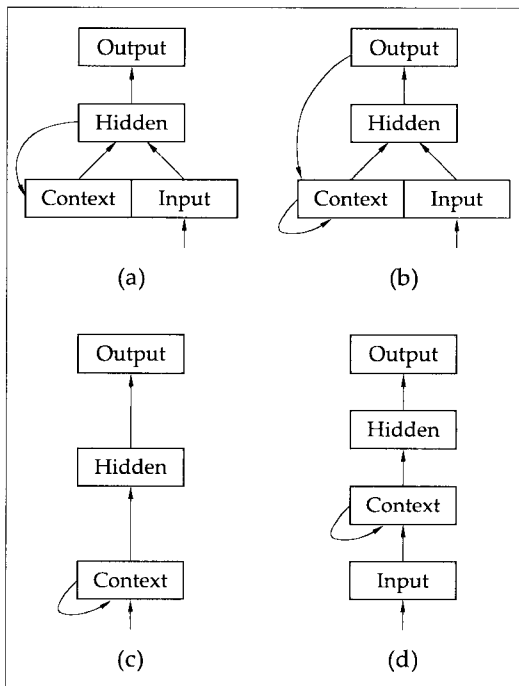
단순순환망의 구조는 (그림 1)과 같다.

문자열의 인식에 알맞은 단순 순환망은 주로전방향(feed forward) 연결구조이지만, 제한적으로 역방향(feed back)연결 구조를 가질 수 있다.

(그림 2)는 현재 사용되는 순환신경망의 여러 가지 구조를 보여준다.



(그림 1) 단순 순환망의 구조
(Fig. 1) Architecture of Simple Recurrent Neural Network



(그림 2) Context층을 갖는 순환망의 구조
(Fig. 2) Architecture of Recurrent Network with Context Unit

안했다^[5]. 입력층은 순수 입력층과 context층인 2부분으로 나누어진다.

context층은 이전단계에서 나온 은닉층의 활성화값(activation)을 단순히 복사하면 된다. 학습은 모두 전방향 구조이고 역전파방법으로 훈련되며 입력열의 경우 각 단계별로 수행된다. 역전파에서 context층은 흡사 입력층과 같이 다루어지며 열인식 및 문자열을 재현할 수 있다. 또 은닉 유닛의 초기 상태가 변하면 자동적으로 그 상태를 복사하여 학습할 수 있다^[6]. (그림 2(b))는 Jordan이 제안한 구조이다^{[10],[11]}. (그림 2(a))와 달리 출력층에서 나온 context층을 가졌다. 역전파가 은닉층과 출력층 어느 쪽에서 일어나느냐에 따라 그 결과도 차이가 생기고, context층은 단층 혹은 다층으로 구성하여 사용할 수 있다^[7]. context층은 전부 혹은 부분적으로 역전파 신호를 받으며 관성작용과 기억작용을 갖는다. context층의 활성화값은 전단계에서의 은닉unit의 출력값과 같다.

다음은 context 인식 훈련 알고리즘이다.

1단계. context층의 활성화 값을 0.5로 정한다.
2단계. 열이 끝날 때까지 3~7 단계를 행한다.

3단계. 입력기호가 나타난다.

4단계. 기대값에 대응되는 후속값이 출력 unit에 나타난다.

5단계. 예정된 후속값을 계산한다.

6단계. 에러를 정의하고 역전파한다. 가중치를 교정한다.

7단계. 종료 조건을 test한다. 만약 기대값과 종료조건이 같으면 학습을 마치고 그렇지 않으면 은닉층의 활성화값을 context층에 복사한 후 3~7 단계를 계속한다.

Elman은 (그림 2(a))에 보이는 구조를 제

학습에 관한 식은 다음과 같다.

$$C_i'(t+1) = \alpha C_i(t) + O_i(t) \quad (1)$$

여기서 O_i 는 출력 유니트이고 α 는 학습강도이다. 만약 출력 unit O_i 가 정해지고 C_i 가 $O_i/(1 - \alpha)$ 가 되는 쪽으로 급격하게 감소하면 이전 값을 점차 잊어버리게 되며 이러한 unit들을 수용성 unit라고 부른다.

또 식 (1)을 반복하면

$$\begin{aligned} C_i(t+1) &= O_i(t) + \alpha O_i(t-1) \\ &\quad + \alpha^2 O_i(t-2) + \dots \\ &= \sum_{t'=0}^t \alpha^{t-t'} O_i(t') \end{aligned} \quad (2)$$

를 얻을 수 있고 극한(limit) 상태에서는

$$C_i(t) = \int_0^t e^{-\gamma(t-t')} O_i(t') dt' \quad (3)$$

을 얻을 수 있는데 여기서 $\gamma = -\log \alpha$ 이다.

context층은 가중값의 이동평균값을 계산하거나, O_i 의 경우처럼, 이전의 과거값을 모두 축적하기도 한다.

α 가 1쪽으로 가까워짐으로서, 과거의 기억력은 더욱 확장되지만 민감한 부분은 완전 회복이 안되는 수도 있다. 일반적으로 α 값의 감소율은 입력열의 문자수의 크기에 비례하여 선택된다^[8]. 문자열의 크기가 크게 되면 각 출력층에 대해서 서로 다른 감소율값을 가진 여러개의 context 층을 갖도록 하는 것이 유용하다^[9].

context층은 식 (3)의 결과를 이용하여 이동 평균을 구하는 도구로도 쓸 수 있다.

입력이 제한된 (그림 2(b))의 네트워크에서, 입력열은 다른 출력열에 연쇄반응을 하는 훈련을 한다^{[10][11]}. 영어음절의 등급을 분류하는데도 이 훈련방법을 사용한다^[9].

(그림 2(c))는 Stornetta등이 제안한 구조로

서 인식작업을 연속적으로 수행한다^[8]. 역전파의 방향은 현재의 context층에서 그들 자신 쪽으로 향하며 식 (1)에서와 같은 고유성은 감소된다. 또한 입력값은 현재의 네트워크의 입력값 자신이며 context층을 경유하여 네트워크의 다른 부분에 도달한다. 효과적인 입력신호는, context층을 통해 이전의 이동평균값을 가중화하여 전처리한 것이다. 즉, 변환함수 $1/(1 - \alpha z^{-1})$ 을 가진 digital filter와 관련된 infinite impulse에 의해서 처리되는 식이다. 이러한 전처리과정을 거쳐 입력 값의 과거 모습이 현재의 context값이 되도록 도와주며 열인식과 열구분을 수행한다.

(그림 2(d))는 Mozer가 제안한 구조이다.

이것은 (그림 2(c))와 유사하지만 2가지 점이 서로 다르다.

첫째는, 1 대 1 연결자가 아니고, 입력과 context층 사이에서 학습강도가 높은 W_j 로 전체를 연결(full connectivity)한다는 것이다.

두번째는 context층의 자체교정력은 고정적이지 아니며 다른 연결자들처럼 훈련된다는 것이다.

context층은 입력 시간을 구하는 훈련중에 감소율이 구해진다. 순환 back propagation은 입력값과 학습인자가 상수로 계산된다. Mozer는 비용함수와 기울기감소(gradient descent)를 사용하여 그 결과가 차이가 나는데서 새로운 학습규칙을 이끌어 냈다^[12].

Mozer는 context층의 값(여기서 ζ 은 입력패턴)을 구하려고 식 (4)를 사용하였으며

$$C_i(t+1) = \alpha_i C_i(t) + g\left(\sum_j w_{ij} \zeta_j\right) \quad (4)$$

Williams와 Zipser는 전체적으로 연결된 순환망에

$$C_i(t+1) = g(\alpha_i C_i(t) + \sum_j w_{ij} \zeta_j) \quad (5)$$

를 적용하였다.

(그림 2(c))와 (그림 2(d))의 구조는 열인식 학습에 효과적이다.

Mozer는 (그림 2(a))나 (그림 2(b)) 경우에 출력층을 echo시키는 입력층에 대해 context층을 추가했다. 또 Shimohara은 이 밖의 다른 구조들에 대해서도 여러가지 실험 결과를 발표했다^[13].

Ⅲ. 새로운 순환신경망 J-E 모델

3.1 구조


본 연구에서 제안한 순환신경망은 입력층과 은닉층에서 context층을 갖도록 하였다.

이는 기존의 Jordan과 Elman이 제안한 구조를 확장 결합한 구조이다.

Jordan과 Elman 모델에서는 은닉층 및 출력층에서 나온 인식률의 오차를 극복하기 위해서 하위층에 각각 하나씩만 두었던 context층을 본 연구에서는 입력층과 출력층 모두에서 작용하도록 다층으로 구성하였다. 이는 정적 패턴의 분류에 있어서 분류성능과 일반화 성능을 향상시키기 위함이며 출력층의 출력 유닛과 은닉층의 은닉유닛은 하위층의 context층과 완전 연결되어 있다.

학습시간을 단축시키거나 또는 인식율을 향상시키는데 있어서 최적화된 구조나 또는 가중치의 최적화등 여러형태의 제안된 방법중에서 단지 어느 하나만을 사용할 경우 만족할 만한 결과를 얻기가 매우 어려우며 따라서 이러한 결합된 구조를 사용하여 인식을 수행하는 것이 타당하다고 본다.

그 구조는 (그림 3)과 같다.



(그림 3) J-E 순환신경망의 구조
(Fig.3) Architecture of J-E Recurrent Neural Network

3.2 학습 알고리즘

전체적인 학습 알고리즘은 다음과 같다.

- 단계 1. 훈련반복계수를 초기화한다.
- 단계 2. 훈련종료 조건이 아니면 2-9 단계를 행한다.
- 단계 3. 될수록 임의값을 적게 정하도록 가중값을 초기화한 후 3-8 단계를 행한다.
- 단계 4. 입력 unit($X_i, i = 1, \dots, n$)는 입력 신호 X 를 받고 상위층(은닉층)의 모든 unit에 이 신호를 전파한다.
- 단계 5. 은닉층($Z_j, j = 1, \dots, p$)에서 입력 신호의 가중값들을 합한다.

$$z_in_j = v_j + \sum_i x_i v_{ij} \tag{6}$$

여기서 z_in_j 는 은닉 유닛 j 에 있는 bias를 말하며 $x_i v_{ij}$ 는 훈련용 입력 벡터이다.

또한 출력신호를 계산하여 활성화 함수를 구하는데 활성화 함수 f 는 시그모이드 함수이다.

$$z_j = f(z_in_j) \tag{7}$$

이 신호를 출력층의 모든 unit와 입력층의 context로 역전파한다.

- 단계 6. 입력신호 X 와 context층으로 들어온 Z_j 를 합하여 은닉층의 모든 unit에 이 신호를 전파한다.

$$\begin{aligned} (z_in_j)_{new} &= Z_j + Z_in_j \\ &= Z_j + v_{oj} + \sum_j x_j v_{ij} \end{aligned} \quad (8)$$

다음 활성화함수를 구하여 출력층으로 보낸다.

$$(Z_j)_{new} = (f(z_in_j))_{new} \quad (9)$$

단계 7. 각 출력 unit($Y_k, k = 1, \dots, m$)는 은닉층에서 올라온 입력신호의 가중값을 합하고

$$Y_in_k = w_{ok} + \sum_j z_j w_{jk} + (z_in_j)_{new} \quad (10)$$

출력신호를 계산하여 활성화함수를 구한 후 은닉층의 context로 역전파한다. 여기서 w_{jk} 는 출력 유닛 k 의 bias를 말한다.

$$Y_k = f(Y_in_k) \quad (11)$$

단계 8. 출력층에서 역전파된 Y_k 와 은닉층의 합을 출력층에 보내 이들을 합한다.

$$(Y_in_k)_{new} = w_{ok} + \sum_j z_j w_{jk} + Y_k \quad (12)$$

단계 9. 각 출력 unit($Y_k, k = 1, \dots, m$)의 값과, 가중치($j = 1, \dots, m$)의 값 및 가중치($j = 1, \dots, p$)와의 차이를 교정한다.

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk} \quad (13)$$

또 각 은닉 unit($Z_j, j = 1, \dots, p$)와의 차이를 계산한다.

$$v_{ij}(new) = v_{ij}(old) + \Delta v_{ij} \quad (14)$$

단계 10. 훈련종료 조건을 test한다.

IV. 실험 및 결과 분석

4.1 실험 방법

J-E 순환신경망의 인식실험은 Eclipse

Series상의 MV-15000 시스템에서 C언어를 사용 구현하였다.


본 연구에서 사용된 신경망 구조는 Le Cun 등^[14]의 구조에 기반을 두었으며, 다층전향네트 워크구조로서 구조자체의 복잡성에 의한 학습 시간을 단축시키기 위하여 독립매개변수의 수를 대폭 줄였다.

각 신경망 분류기의 입력값은 오픈원도우 비트맵을 이용하여 20×20 그리드영역에 입력받은 방향정보값을 이용하였다. 방향성분 벡터는 위치변형을 수용할 수 있도록 2차신경망의 특징을 이용하여 각각의 방향성분 벡터와 그들간의 2차 상관관계를 추출하였다. 입력층은 20×20 의 유닛으로 구성되는데, 5×5 가중치 벡터를 적용시키기 위하여 정규화된 16×16 영상을 20×20 으로 확장시킨 것이다. 은닉층은 4개의 16×16 유닛 배열로 구성된다. 입력층과 은닉층사이의 가중치 벡터는 학습에 의하여 갱신되는 것이 아니고 적절한 특징을 추출하도록 고정된 값을 갖는다. 가중치 벡터는 은닉층에 있는 16×16 유닛에 대하여 256개가 아닌 16개의 독립된 가중치를 갖게 한다. 이 가중치는 바이어스(bias) 값과 함께 학습 단계동안 갱신된다. 출력층은 모두 10개의 유닛으로 구성되며 은닉층과 출력층사이는 완전 연결되어 있다. 출력층에 있는 10개의 유닛은 입력 부류에 해당하는 유닛만이 1값을 갖고 그 외의 유닛은 0값을 갖도록 하였으며 전향신경망, Jordan 순환신경망 그리고 Elman 순환신경망과 성능을 비교하였다.

전향신경망의 학습은 오류역전파알고리즘을 이용하였으며 Jordan과 Elman 순환신경망의 학습은 Willams-Zipser 학습알고리즘을 이용하였다.^{[15][16]}

4.2 실험 결과

(그림 4)는 학습 데이터의 크기가 증가함에 따른 오인식률을 보여준다.



(그림 4) 학습 데이터의 크기에 대한 오인식률
(Fig. 4) Malrecognition Rate on the Sign of Learning Data

(그림 4)에서 제안된 J-E 순환 신경망이 다른 신경망에 비하여 훌륭한 일반화 성능을 가짐을 알 수 있다.

<표 1>과 <표 2>는 학습데이터와 테스트데이터에 대한 인식결과이다.

<표 2>에 보여진 바와 같이 제안된 순환신경망이 다른 신경망 분류기에 비하여 높은 분류 성능을 나타냄을 알 수 있다.

<표 1> 학습데이터에 대한 오인식률
(Table 1) Malrecognition Rate on the Learning Data

신경망 분류기	전향 신경망	Jordan 순환신경망	Elman 순환신경망	J-E 순환신경망
오인식률	0.870%	0.670%	0.605%	0.423%

<표 2> 테스트 데이터에 대한 오인식률
(Table 2) Malrecognition Rate on the Test Data

신경망 분류기	전향 신경망	Jordan 순환신경망	Elman 순환신경망	J-E 순환신경망
오인식률	8.3%	6.2%	4.7%	2.7%

<표 3>은 각 순환신경망을 이용할 경우 단순한 다층 전향신경망에 비하여 감소된 오인식률의 비율을 보여준다.

<표 3> 단순한 다층전향신경망에 대한 순환신경망의 오인식감소비율
(Table 3) Reducing Rate of Malrecognition of Recurrent Neural Network to Simple Mulyi-layer forward Neural Network

신경망 분류기	Jordan 순환신경망	Elman 순환신경망	J-E 순환신경망
오인식감소비율	25.3%	42.2%	66.3%

위의 <표 3>에서 보여진 것과 같이 제안된 순환신경망을 무제한 필기체숫자인식에 이용할 경우 약 66.3%의 오인식률의 감소를 얻을 수 있었다. 또 Jordan과 Elman 순환신경망을 이용할 경우에는 각각 45.5%와 55.8%의 감소 비율을 얻을 수 있었다.

V. 결 론

본 연구에서는 오프라인 필기체문자와 같은 정적인 패턴을 효과적으로 분류하기 위하여 새로운 형태의 순환신경망을 제안하였다. 제안된 순환신경망은 3개의 층으로 구성되어 있으며 입력층과 은닉층에 각각 context층을 포함하고 있다. 출력층의 출력유니트들은 자기 자신을 포함하여 은닉유니트들과 다른 모든 출력유니트들에 완전 연결되어 있다.

일반적으로 다층전향신경망을 이용한 패턴 분류에 있어서 은닉유니트들은 입력패턴으로부터 은닉유니트들로부터 주어진 정보를 극대화하도록 학습되며 출력유니트들은 은닉유니트들로부터 주어진 정보를 구별하도록 학습된다. 따라서 출력 유니트에 보다 많은 정보를 입력하는 것은 구별성능과 일반화성능을 향상시킨다는 측면에서 중요한 의미를 지닌다. 본 시스템은 하나의 신경망에 의해 문자전체를 인식하므로 유형분류에 의한 영역별 인식 때문에 발생하는 오인식을 피할 수 있다. 또 필기체문자와 같은 정적인 패턴의 분류에 이용할 경우 분류성능과 일반화 성능을 크게 향상시킬 수 있음을 알 수 있었다.

하지만 다층으로 구성된 context로 인한 연결선의 수가 너무 많아 학습과 인식시에 많은 계산량이 요구되는 단점이 있다. 앞으로의 연구 방향은 제안된 순환신경망을 이용하여 연속필기된 숫자열을 효과적으로 인식하는 시스템을 구현하는 것이다. 아울러 알고리즘의 분석 및 개발, 프로그램의 효율화로 학습시간을 더욱 단축시키는 것이다.

참 고 문 헌

- [1] C.Y.Suen et al., "Computer Recognition of Unconstrained Handwritten Numerals", *Proceeding of the IEEE*, Vol. 80, No.7, pp.1162-1180, 1992., July 1992.
- [2] Y.Le Cun et al., "Constrained Neural Network for Unstrained Handwritten Digit Recognition", Montreal, Canada, pp.145-154, Apr. 1990
- [3] Wieland and R.Leighton, "Geometric Analysis of Neural Network Capabilities", *Proc. of IEEE Int. Conf. on Neural Networks*, Vol. 3, San diago, USA, pp.385-392, 1987.
- [4] A.W.Senior, "Off-line Handwriting Recognition : A Review and Experiments", Technical Report, TR105, Engineering Department, Cambridge University, 1992.
- [5] Elman,J.L. "Finding Structure in Time", *Cognitive Science*, 14 : pp.9-211, 1990.
- [6] Cleeremans, A., D. Servan-Schreiber, and J. L. McClelland, "finiteState Automata and Simple Recurrent Networks", *Neural Computation* 1, pp.372-381, 1989.
- [7] Bengio, Y., R. Cardin and R. De Mori. Speaker Independent Speech Recognition with Neural Networks and Speech Knowledge. In *Advances in Neural Information Processing Systems 2*(Denver 1989), ed. D.S. Touretzky, pp.218-225. San Mateo : Morgan Kaufmann, 1990.
- [8] Stornetta, W. S., T. Hogg, and B. A.Huberman, "A Dynamical Approach to Temporal Pattern Processing". In *Neural Information Processing Systems* (Denver 1987), ed D.Z. Anderson, pp.750-759. New York : American Institute of Physics, 1988.
- [9] Anderson, S., J.W.L. Merrill, and R. Port, "Dynamic Speech Categorization with Recurrent Networks". In *Proceedings of the 1988 Connectionist Models Summer School* (Pittsburg 1988), eds. D. Touretzky, G. Hinton, and T.

- Sejnowski, pp.398-406. San Maeto :Morgan Kaufmann. 1989.
- [10] Jordan Attractor Dynamics and Parallelism in a Connectionist Sequential Machine. In proceedings of the English Annual Conference of the Cognitive Science Society (Amherst 1986), pp.531-546. 1986.
- [11] Jordan Serial Order. "A Parallel, Distributed Processing Approach. In Advances in Connectionist Theory", Speech, eds. J.L. Elman and D.E. Rumelhart, Hillside :Erlbaum, 1989.
- [12] Mozer, M. C. "A Focused Back-Proagation Algorithm for Temporal Pattern Recognition. Complex Systems 3", pp.349-381. 1989.
- [13] Shimohara, K., T.Uchiyama, and Y. Tokunaga. "Back-Propagation Networks for Event-Driven Temporal Sequence Processing". In IEEE International Conference on Neural Networks (San Diego 1988), vol. pp.665-672. New York : IEEE., 1988.
- [14] Y.Le Cun et al., "Constrained Neural Network for Unstrained Handwritten Digit Recognition", Montreal, Canada, pp.145-154. Apr. 1990
- [15] D.E. Rumelhart, G.E. Hinton, and R.J.Williams, " Learning Internal Representation by Error Propagation", Parallel Distributed Processing, Vol.1, Cambridge, USA : MIT Press, pp.318-362, 1986.
- [16] J.F.Kolen, "Exploring the Computational Capability of Recurrent Neural Networks", A thesis for the Ph. D. Degree, Ohio State University, 1994.
- [17] 김영준,이성환, "효과적인 패턴분류를 위한 새로운 형태의 순환신경망", '95봄학술발표논문집, 제22권1호, 한국정보과학회, pp.1013-1016, 1995.

□ 著者紹介



정 낙 우

1980년 동국대학교 전자계산학과 졸업
1982년 조선대학교 산업대학원 전자계산전공(공학석사)
1994년 전남대학교 전자계산과 박사과정 수료
1984년 ~ 현재 서강전문대학 전자계산과 부교수

※ 관심 분야 : 패턴인식, 신경망, 인공지능, 소프트웨어 공학

김 병 기

1978년 전남대학교 수학과 졸업
1980년 전남대학교 대학원 수학과(응용수학) 졸업(이학석사)
1987년 ~ 1990년 한국정보과학회 학회지 편집위원
1994년 ~ 현재 한국정보과학회, 한국정보처리학회 이사
1981년 ~ 현재 전남대학교 전산학과 교수
1994년 ~ 현재 전남대학교 전자계산소 소장

※ 관심 분야 : 소프트웨어공학, 신경망, 병렬처리프로그래밍