

論文94-31B-11-18

附加的인 Feedback 연결을 가진 循環神經回路網의 學習과 韓國語 숫자음 認識에의 應用

(Learning of the Recurrent Neural Networks with Additional Feedback Connections and Application to the Recognition of Korean Spoken Digits)

呂 珍 璟*, 鄭 鎬 宣*

(Jin Kyung Ryeu and Ho Sun Chung)

要約

본 논문에서는 기존의 循環神經回路網에서의 學習性能을 개선하고 局部최소해 문제를 해결하기 위한 노력의 일환으로서 附加적인 피드백 연결을 가진 순환신경회로망과 그 학습 알고리즘을 제안하였다. 이 방법에서는 회로망은 한번 반복하는동안 고정된 연결 가중치를 가지고, 주어진 時變入力과 初期條件下에서 주어진 週期동안 동작한다. 가중치는 最急降下法에 의해 총에너지가 가장 많이 감소하는 방향으로 변화된다. 만일 이러한 과정을 일정 반복횟수동안 수행한 후에도 에너지가 충분히 감소하지 않으면, 附加적인 피드백 연결이 도입되고 회로망의 외부입력이 주어진 식에 따라 다시 정의된다. 또한 제안된 회로망의 응용으로서 한국어 숫자음 인식에 대한 실험을 행하였다.

Abstract

We propose a new learning method of recurrent neural networks as an effort to solve local minima problem. In this method the network with fixed connection weights is run for a given period time under given time-variant external inputs and initial conditions. The weights are changed in the direction that the total error is maximally decreased by using the steepest gradient method. If the obtained error is not sufficiently small even after iterating this procedure, additional feedback connections are introduced. Then, the external input signal is redefined. And we execute experiments on the recognition of Korean spoken digits as an application of the proposed network.

1. 서론

최근에 와서 신경회로망 연구부문에 많은 발전이 이루어지고 있다.^[1,2] 신경회로망의 구조는 크게 두가

지로 나뉘어 질 수 있다. 그 하나는 피드 포워드 회로망이다. 이러한 회로망은, 다층신경회로망에서의 EBPA(Error Back Propagation Algorithm)가 Rumelhart, Hinton 그리고 Williams^[3]에 의해 개발된 이래 상당히 활발하게 연구되어져 왔다. 다층퍼셉트론 신경회로망은 EBPA에 의해 학습될 수 있는 canonical 피드 포워드 회로망이다. EBPA는, 같은 오차가 다시 일어나지 않게 하기 위해 가중치를 조정

*正會員, 慶北大學校 電子工學科
(Dept. of Elec. Eng., Kyungpook Nat'l Univ.)
接受日字 : 1994年 4月 15日

하면서 오차 신호를 회로망을 통해서 피드백시키는 것이다. 회로망은 실제패턴과 원하는 출력패턴을 비교함으로써 학습된다. 회로망을 학습한다는 것은 전체 오차를 최소화하는 최소화문제로 생각되어 질 수 있다. BP는 XOR 함수, NetTalk, Backgammon play, 그리고 필기체 인식등 많은 응용에서 실험되어지고 있다.

퍼셉트론, Adaline등에 사용되는 피드 포워드의 회로망에서는, 출력이 그 시점의 입력패턴의 합수로 정해져 버린다. 그러나 음성이나 언어의 이해, 운동의 제어등은, 단순히 그 시점에서 주어지는 입력패턴에 대해 반사적으로 출력을 내는 것이 아니고, 입력의 시계열(time series) 패턴을 식별하거나, 자율적으로 공간적인 패턴을 발생하는 동적(dynamical)인 것이다. 이러한 정보처리기구를 모델화하기 위해서는, 회로망의 구조를, 보다 다양하고 자율적인 다이내믹스를 가질 수 있게 하지 않으면 안된다. 이러한 회로망 모델을 순환신경회로망이라 한다. Hopfield^[4], Cohen 그리고 Grossberg^[5]는, 대칭적인 연결을 가지는 순환회로망은 궁극적으로 하나의 안정상태에 도달한다는 것을 보였다. 이것은, 시스템이 에너지 함수의 (국부)극소로 수렴하도록 하기 위해, 이러한 회로망이 시간에 따라 단조적으로 감소하는 에너지 함수를 가진다는 사실로부터 유도된다. 이러한 형태의 회로망은 최적화문제를 푸는데 응용되어 왔고^{[6],[7]}, 연상기억장치로도 사용되었다.^{[8],[9]} 최근에 Pineda^[10]가 이러한 회로망에 대한 학습 알고리즘을 제안하였다. 그 알고리즘에서는, 시스템의 오차는 그 시스템의 안정된 출력과 원하는 출력사이의 거리에 의해 측정된다. 시스템의 가중치는, 그 시스템의 오차가 최대한 줄어드는 방향으로 수정된다. 이 방법은 목표 시스템으로의 궤적만을 조절한다. Sato^[11]는 순환회로망에 대한 실시간 학습 알고리즘을 제안하였다. 이 방법은, 출력이 원하는 값에 수렴하는 목표 시스템으로의 적정궤적을 찾는 것이다. 회로망의 시스템 오차는, 전체적에 걸쳐 뉴런의 교사신호로부터의 전체 오차에 의해 측정된다. 에너지함수는, 시스템 오차의 합과 가중치 변경을 위한 에너지 항으로 정의된다. 가중치는, 운동방정식의 해에 의해 에너지 함수가 최소가 되도록 실시간으로 변경된다. 만일 이산시간 규정이 채택된다면, 이 알고리즘은 순환회로망에서의 백프로파게이션(back propagation) 방법과 같다. BP 알고리즘과 마찬가지로 이 방법도 국부최소해 문제를 가지고 있다. 전역적 최소해(global minimum)에의 수렴은 그것이 가중치의 초기선택에 의존하기 때문에 보증되지 않는다.

본 논문에서는 입력력간의 時變變換을 처리하기 위해 이러한 最急降下法을 이용하여 학습과정을 수행할 때 국부최소해 문제를 해결하기 위한 한 노력으로서, 시스템이 한 국소해에 빠졌을 경우, 회로망에 附加적인 피드백을 도입한 순환회로망과 그 학습 알고리즘을 제안하였다. 이 방법은, 한 뉴런의 출력을 결정하는데 모든 이전의 결과가 고려된다는 점과, 만일 시스템이 국소해에 빠지면 附加적인 연결이 더해진다는 의미에서, PLDMLP 모델^[12]과 비슷한 개념이다. 또한 이 회로망의 실제적인 응용으로서 한국어 숫자을 인식에 대한 실험을 행하였다.

II. 附加적인 피드백을 가진 순환신경회로망

시변 데이터의 지도학습은 연결 가중치 w 를 조정함으로써 에너지 함수 E 의 향으로써 뉴런의 출력 $x(t)$ 와 원하는 출력 $X(t)$ 의 차를 줄여 나가는 산술적인 과정이다. 학습패턴은 외부입력 $A(t)$ 와 원하는 출력 $X(t)$ 의 조합이다. 즉 교사신호와 외부 바이어스는 시간에 의존하는 신호이다. 회로망은 다음 운동방정식을 만족하는 N 개의 뉴런으로 구성되어 있다.

$$x_i(t) = f(y_i(t)) \quad (1)$$

$$y_i(t) = -y_i(t) + \sum_j w_{ij} x_j(t) + A_i(t) \quad (2)$$

$$(i = 1, \dots, N)$$

$$f(y_i) = \frac{1}{1 + e^{-\lambda y_i}} \quad (3)$$

이때 y_i 와 x_i 는 각각 i 번째 유닛의 내부상태와 출력이다. (1)에서 $f(\cdot)$ 는 (3)에서의 출력함수를 나타내고, (2)에서 \cdot 은 시간에 관한 미분을 나타낸다. λ 는 시간지연 상수이다. i 번째 유닛의 바이어스 입력 $A_i(t)$ 는 주어진 시간종속 함수이다.

이 알고리즘에서 회로망은 주어진 초기조건과 외부 입력하에서 주어진 주기시간동안 동작한다. 이 기간 동안 회로망의 연결 가중치는 고정되고 시스템의 오차가 측정된다. 학습함수는 이 기간동안 가시출력의 교사신호로부터의 총 오차로 주어진다:

$$E(w) = \int_0^T \sum_i \frac{1}{2} (x_i(t) - X_i(t))^2 dt \quad (4)$$

가중치 변경법칙은 최급강하법으로 주어진다.

$$\Delta w_{ij} = -\eta \frac{\partial E(w)}{\partial w_{ij}} \quad (5)$$

이때 η 는 양의 상수이다. $\partial E / \partial w_{ij}$ 를 구하기 위해

$E(w)$ 의 변화 $\delta E(w) \equiv E(w + \delta w) - E(w)$ 를 고려하는데, 이 때 라그랑제 승수 L_i 를 사용하였다. $y_i(t)$ 와 $x_i(t)$ 는 운동방정식 (1)과 (2)를 만족하기 때문에, 에너지 함수 $E(w)$ 는 다음과 같이 표현될 수 있다.

$$E(w) = \int_0^T \left[\frac{1}{2} \sum_i^N (x_i(t) - X_i(t))^2 - \sum_i^N L_i \left\{ \tau_i \dot{y}_i + y_i(t) - \sum_j^N w_{ij} x_j(t) - A_i(t) \right\} \right] dt \quad (6)$$

이 때 L_i 는 라그랑제 승수이다.

여기서, 이산시간에 대해 고려하면, 식 (2)는 다음과 같이 쓰여진다.

$$y_i(t+1) = \sum_j^N w_{ij} x_j(t) + A_i(t) \quad (7) \quad (i=1, \dots, N)$$

그러므로 식 (6)을

$$E(w) = \sum_{i=0}^T \left[\frac{1}{2} \sum_i^N (x_i(t) - X_i(t))^2 - \sum_i^N L_i \{ y_i(t+1) - \sum_j^N w_{ij} x_j(t) - A_i(t) \} \right] dt \quad (8)$$

와 같이 다시 쓸 수 있다.

변수 $\delta y_i(t)$, $\delta x_i(t)$, $\delta L_i(t)$ 를 각각 가중치 변화에 따른 y_i , x_i , L_i 의 변화로 정의하면, $E(w)$ 의 변화는 다음 식으로 나타내어진다.

$$\begin{aligned} \delta E(w) &= \sum_{i=0}^T \sum_i^N (x_i(t) - X_i(t)) f'_{x_i}(y_i(t)) \delta y_i(t) \\ &- \sum_{i=0}^T \sum_i^N \delta L_i(t) \{ y_i(t+1) - \sum_j^N w_{ij} x_j(t) - A_i(t) \} \\ &- \sum_{i=0}^T \sum_i^N \delta y_i(t) \{ L_i(t-1) - \sum_j^N L_j w_{ji} f'_{y_j}(y_j(t)) \} \\ &- \sum_i^N L_i(T) \delta y_i(T+1) + \sum_{i=0}^T \sum_{j=0}^N L_i(t) x_j(t) \delta w_{ij} \end{aligned} \quad (9)$$

위 식에서 고정된 초기조건으로부터 $\delta y_i(t)(0) = 0$ 이고, 또한 라그랑제 승수 L_i 가 경계조건 $L_i(T) = 0$ 하에서 다음 식

$$L_i(t-1) = \sum_j^N L_j(t) w_{ji} f'_{y_j}(y_j(t)) + \delta_{ij} (x_j(t) - X_j(t)) f'_{x_j}(y_j(t)) \quad (10)$$

을 만족할 경우, 식 (9)는

$$\delta E(w) = \sum_{i=0}^T \sum_{j=0}^N L_i(t) x_j(t) \delta w_{ij} \quad (11)$$

로 된다. 그러므로 가중치 변경법칙은 다음 식으로 주어진다.

$$\Delta w_{ij} = -\eta \frac{\partial E(w)}{\partial w_{ij}} = -\eta \sum_{i=0}^T L_i(t) x_j(t) \quad (12)$$

이 때 $L_i(t)$ 는 식 (10)에 따라 시간에 대해 역방향으로 구한다. 식 (10)에서 δ_{ij} 는 Kronecker의 델타로서 $i \in V$ 이면 1이고 그렇지 않으면 0인 값이다. 이 방법은 순환신경망에서의 오차 백프로퍼게이션 방법과 같다.

만일 정해진 수의 반복후에도 에너지 함수 E 의 최소값이 전역적 최소해가 되기에 충분히 적어지지 않으면, 附加적인 피드백 연결을 도입하여, 새롭게 정의된 외부입력신호를 사용하여 학습과정을 다시 거치게 된다. 이 회로망의 구조는 그림 1과 같다.

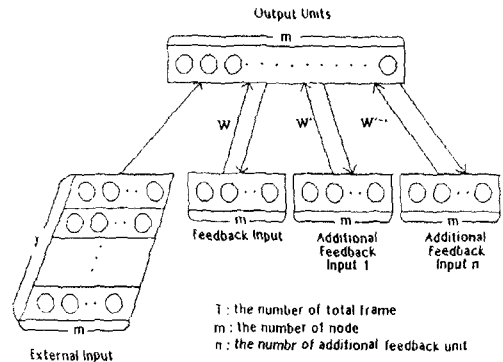


그림 1. 附加적인 피드백 연결을 가진 순환신경회로망의 구조

Fig. 1. Structure of the recurrent neural net with additional feedback connections.

학습과정을 살펴보면 다음과 같다.

- 1) 모든 가중치와 $y(0)$ 를 랜덤값으로 초기화한다.
- 2) 뉴런 상태 $y(t)$ 를 식 (7)에 따라 시간진행방향으로, 즉 $y(0) \rightarrow y(T)$ 로 계산한다.
- 3) 라그랑제 승수 $L_i(t)$ 를 식 (10)에 따라 시간의 역방향으로, 즉 $L_i(T) \rightarrow L_i(0)$ 로 계산한다. 이 때 경계조건은 $L_i(T) = 0$ 이다.
- 4) 에너지 함수 E 의 값이 어떤 문턱치보다 적으면 학습을 종료하고, 그렇지 않으면 최급 강하법에 의해 식 (12)에 따라 가중치를 가변한다. 이 때 $x(t)$ 와 $L(t)$ 는 과정 2)와 3)에서 구한 값

을 사용한다.

5) 정해진 반복횟수동안 위의 과정을 반복한다.

만일 그 후에도 에너지 함수의 값이 충분히 적어지지 않으면, 附加적인 피드백 연결을 도입하고, 외부입력신호는 다음과 같이 다시 정의한다.

$$A_i(t) = A_i^0(t) + \sum_j w_{ij}^f x_j^f(t) \quad (13)$$

$A_i(t)$: 다시 정의된 i 번째 외부입력신호

$A_i^0(t)$: 원래의 i 번째 외부입력신호

w_{ij}^f : 한 사이클의 학습이 수행되고 난 후의 연결가중치 (at a local minimum)

$x_j^f(t)$: 국부최소해에서의 j 번째 뉴런의 출력

여기서 부가적인 피드백 연결을 도입하여 새롭게 정의된 외부입력신호를 인가하는 것은, PLDMLP 모델에서의 개념과 같이, 시스템이 오차가 더 이상 줄어들지 않는 국부최소해에 빠졌을 때, 원래의 입력뿐 아니라, 앞 단계에서의 뉴런의 출력중 가장 오차가 적었던 때의 결과를 모두 고려하여 다시 학습과정을 수행함으로써, 국부최소해로부터의 탈출을 시도하는 것이다. 이 때 증가된 피드백 입력은 실제로 연결이 늘어나는 것이 아니라, 학습시 계산상으로만 고려되는 가상적인 것이다.

III. 인식실험

본 절에서는 제안된 학습 알고리즘에 의한 附加적인 피드백 연결을 가진 순환신경회로망의 실제적인 응용으로서 화자중속 한국어 숫자음 인식실험을 행하였다. 음성신호의 분석은 TC8861F라는 신호처리 칩을 이용하여 하드웨어로 구현된 음성분석보드를 사용하였다. TC8861F로부터 얻을 수 있는 데이터는 7채널 대역필터를 통과한 8비트 디지털 데이터로 이 회로망의 입력데이터로 이용하기 위하여 0에서 1사이의 값으로 정규화하였다. 이 데이터를 이용하여 제안된 회로망으로 학습한 후 인식실험을 수행하였다.

1. 전처리 과정

음성신호의 전처리는 신경회로망의 입력에 사용되는 데이터의 추출과정이다. 그 전처리 과정은 다음과 같다.

1) 분석된 음성신호의 입력

먼저 마이크에서 입력된 음성 신호를 신호처리 보드를 통해 7 채널 대역 필터뱅크의 출력을 얻는다. 이 때 받아들여진 데이터는 20ms의 분석 주기로 분석되어진 8bit 데이터이다. 입력된 데이터는, 앞서

설명한 바와 같이 각 분석 주기당 주파수축 상에서 200Hz에서 5.5kHz까지 7 채널의 MEL scale로 나눠져 각 채널당 8 bit의 해상도를 가진다.

2) 음성 구간의 검출

7채널 대역 필터뱅크로 분석된 음성 데이터에서 음성구간을 검출해야 한다. 먼저 한 프레임에서 각 채널의 출력을 모두 합한 값을 총에너지로 정의하고 이 값이 정해 놓은 문턱치보다 클 경우에만 그 프레임을 음성구간으로 정하였다.

이 음성구간은 입력된 음성신호의 크기에 밀접한 관계를 가지고 있는데 음성입력 신호가 클 경우 총에너지의 값이 커지므로 음성구간이 늘어나게 되며, 입력범위를 초과할 경우 포화되어 각 채널에서 255의 값이 나타나게 된다. 본 실험에서는 입력신호에 적절한 조건을 결정한 다음 학습과 인식시 동일한 조건을 적용하였다.

3) 음성데이터의 정규화

음성구간으로 검출된 데이터를 신경회로망의 입력으로 사용하기 위해서 음성 데이터의 길이와 크기의 정규화가 필요하다. 음성은 한사람이 같은 말을 여러번 반복해서 발음하더라도 음성구간의 길이가 같을 경우가 거의 없으므로 시간축 정규화가 필요한데, 본 실험에서는 여러번의 발음을 통해 가장 적절하다고 판단되어진 25 프레임으로 음성 데이터를 정규화하였다.

표 1. 숫자음 '7'의 음성구간 검출후의 데이터

Table 1. Data of spoken digit '7' after speech detection.

Frame	F1	F2	F3	F4	F5	F6	F7	Total
1	148	4	3	40	73	69	53	337
2	165	21	0	28	6	37	30	313
3	149	24	0	38	91	102	53	404
4	148	13	0	53	112	110	68	436
5	107	22	0	33	108	99	48	369
6	120	56	0	35	102	122	57	435
7	90	45	0	35	99	100	50	369
.
26	157	110	0	53	87	53	55	460
27	192	107	0	43	74	37	81	453
28	202	104	3	61	101	55	101	526
29	200	59	0	49	73	59	55	440
30	145	0	0	21	47	30	0	243
31	116	5	0	32	59	38	0	250
32	82	3	0	43	59	38	0	225
33	47	22	0	38	60	47	0	214

표 2. 전처리 과정을 거친 후의 데이터
Table 2. Data of spoken digit '7' after preprocessing.

Frame	F1	F2	F3	F4	F5	F6	F7
1	0.583	0.016	0.012	0.157	0.287	0.272	0.209
2	0.650	0.083	0.000	0.110	0.244	0.146	0.118
3	0.583	0.051	0.000	0.207	0.441	0.433	0.268
4	0.421	0.087	0.000	0.130	0.425	0.390	0.224
5	0.472	0.220	0.000	0.138	0.401	0.481	0.213
6	0.339	0.279	0.000	0.173	0.441	0.335	0.213
7	0.339	0.279	0.000	0.173	0.441	0.335	0.213
8	0.339	0.279	0.000	0.173	0.441	0.335	0.213
9	0.339	0.279	0.000	0.173	0.441	0.335	0.213
10	0.339	0.279	0.000	0.173	0.441	0.335	0.213
11	0.339	0.279	0.000	0.173	0.441	0.335	0.213
12	0.339	0.279	0.000	0.173	0.441	0.335	0.213
13	0.339	0.279	0.000	0.173	0.441	0.335	0.213
14	0.339	0.279	0.000	0.173	0.441	0.335	0.213
15	0.339	0.279	0.000	0.173	0.441	0.335	0.213
16	0.339	0.279	0.000	0.173	0.441	0.335	0.213
17	0.339	0.279	0.000	0.173	0.441	0.335	0.213
18	0.520	0.366	0.000	0.228	0.327	0.201	0.161
19	0.756	0.421	0.000	0.169	0.291	0.146	0.319
20	0.795	0.409	0.012	0.240	0.398	0.217	0.398
21	0.787	0.232	0.000	0.193	0.287	0.232	0.217
22	0.457	0.020	0.000	0.126	0.232	0.149	0.000
23	0.323	0.012	0.000	0.169	0.232	0.150	0.000
24	0.185	0.087	0.000	0.150	0.236	0.185	0.000
25	0.173	0.000	0.000	0.122	0.189	0.114	0.000

시간축으로 그 길이가 정규화된 음성 데이터를 순환 신경회로망의 입력 데이터로 사용하기 위해서 각 채널에서의 데이터의 크기 또한 정규화하였다. 단어를 발음할 경우 발성의 강약에 따라 입력된 음성신호의 크기가 각각 다르므로 크기의 정규화가 필요하다. 본 실험에서는 입력되어진 각 발음의 데이터 중 가장 큰 값의 데이터를 기준으로 하여 이를 '1'로 할당하고 이를 기준으로 하여 각각의 데이터의 크기를 '0'에서 '1' 사이의 아날로그 값으로 결정하였다.

표 1과 표 2는 각각 숫자음 '7'의 음성구간 검출 후의 데이터와 전처리 과정을 모두 거친 후의 데이터이다.

2. 학습

학습대상으로 사용한 입력 데이터로는 한국어 숫자음 '0' (영)에서 '9' (구)까지를 한 화자가 5번씩 발음한 것을 사용하였다. 그림 2는 학습에 사용한 숫자음 '7'의 첫번째 채널의 데이터이다. 이렇게 5번씩 발음된 데이터를 평균하여 원하는 출력으로 정하였다. 그림 3은 그림 2에서 정의된 원하는 출력의 파형이다. 이 때 파라미터로는 학습상수 $\eta=0.0003$, 시그모이드 (sigmoid) 함수의 기울기 $\lambda=0.25$ 를 사용하였다.

표 3은 학습결과 각 스텝에서의 최적결과를 보여준다. 각 스텝은 附加적인 피드백 레이어의 도입횟수를 나타낸다.




그림 2. 숫자음 '7'의 첫번째 채널의 데이터
Fig. 2. Learning data of spoken digit '7' at channel 1.




그림 3. 그림 2에서 정의된 원하는 출력
Fig. 3. Desired output defined in Fig. 2.

표 3. 각 step에서의 학습결과
Table 3. The result of learning at each step.

Step	Total Error
0	28.236
1	26.571
2	24.542
3	26.394

실험결과에서, 附加적인 피드백 연결을 도입했을 때의 결과가 기존 회로망의 결과(step 0)에 비해 개선

되었다는 것을 알 수 있다. 한편, 표 3으로부터 附加적인 피드백 입력을 계속 늘인다고 좋은 결과가 나오는 것은 아니라는 것을 알 수 있는데, 실제로 recall에 사용하는 가중치로는 그 중 가장 좋은 결과를 채택하게 된다. 본 실험에서는 2개의 附加적인 피드백 레이어를 사용했을 때 가장 좋은 결과를 얻었다.

3. 인식

인식실험은 학습된 데이터와 마이크에서 직접 입력된 학습되지 않은 데이터를 대상으로 행하였다. 표 4는 인식실험 결과 인식률을 나타낸다. 표 4에서 보여지는 것처럼 학습된 데이터에 대해서는 100%의 인식률을 보였으며, 마이크에서 직접 30번 발음한 학습되지 않은 데이터에 대해서는 95.67%의 인식률을 보였다. 이 때 '6'과 '7'의 인식률이 좋지 않았는데, 그 이유는 '6'의 경우는 '9'와, '7'은 '1'과 모음부분이 비슷하기 때문에 자음부분을 강조해서 뚜렷하게 발음하지 않는 경우는 구분이 힘든 것으로 분석된다.

인식률을 높이고, 대상단어를 늘이기 위해서는 먼저, 모음의 특성을 잘 구분할 수 있는 특징으로 비슷한 모음을 가지는 음성을 하나의 집단으로 분류하고, 그 집단내에서 다시 자음부분을 구분해 내는등과 같은 階層的인 회로망을 구현하는 방법이 효과적이라고 생각된다.

표 4. 학습된 데이터와 학습되지 않은 데이터에 대한 인식률

Table 4. Recognition rates for learned data and unlearned data.

() : 학습된 데이터의 경우
 ____ : 마이크로 직접 입력된 학습되지 않은 데이터의 경우

	0	1	2	3	4	5	6	7	8	9	Recognition Rate (%)
	·영'	·일'	·이'	·삼'	·사'	·오'	·육'	·칠'	·팔'	·구'	
0	30(5)										100 (100)
1		30(5)									100 (100)
2			30(5)								100 (100)
3				30(5)							100 (100)
4					30(5)						100 (100)
5						27(5)				3	90 (100)
6							25(5)			5	83.3(100)
7		4						28(5)			86.7(100)
8						1			29(5)		96.7(100)
9										30(5)	100 (100)
Total Recognition Rate (%)											95.67(100)

IV. 결론

본 논문에서는 음성등 時變패턴의 학습에 적절한 순환신경회로망과 Sato가 제안한 한정시간(finite time) 학습 알고리즘에서의 학습성능을 개선하여, 국

부최소해 문제를 해결하고자 하는 노력의 일환으로서, 정적패턴의 학습에 주로 사용되는 PLDMLP 신경회로망 모델의 개념을 도입한 附加적인 피드백 연결을 가진 순환신경망과 학습 알고리즘을 제안하였다. 또한 그 회로망의 응용으로서 한국어 숫자음 인식에 관한 실험을 행하였다. 그 결과, 기존의 회로망에 비해 학습성능이 향상된 것을 알 수 있었다. 앞으로는 국부최소해를 빠져나오는 구체적인 메카니즘을 정립하고, 전역적 최소해에 도달하기 위하여 카오스(chaos)적 最急降下法등과 같은 새로운 가중치 변경법칙을 적용하는 방법등에 대해 계속 연구해 나갈 것이다. 또한 階層的 회로망이나 자기조직화(self-organization) 방법등을 도입하여 認識率의 향상과 함께 話者獨立 認識에 관한 연구도 병행할 것이다.

參考文獻

[1] J. L. McClelland and D. E. Rumelhart, "Parallel distributed processing", vol. I, II, MIT Press, 1986.

[2] J. D. Cowan and D. H. Sharp, "Neural Nets.", *Rev. Biophys.* vol. 21, pp. 365-427, 1988.

[3] G. E. Hinton, D. E. Rumelhart and R. J. Williams, "Learning internal representations by error back propagation", MIT Press, pp. 318-362, 1986.

[4] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", *Proc. Natl. Acad. Sci. USA* vol. 81, pp. 2554-2558, 1982.

[5] M. A. Cohen and S. Grossberg, "Absolute stability of global pattern formation and parallel memory storage by competitive neural networks", *IEEE Trans. SMC-13*, pp. 815-825, 1983.

[6] J. J. Hopfield and D. W. Tank, "Neural computation of decisions in optimization problems", *Biol. Cybern.*, vol. 52, pp. 141-152, 1985.

[7] J. J. Hopfield and D. W. Tank, "Simple neural optimization networks: an A/D Converter, signal decision circuit, and a linear programming

- circuit", *IEEE Trans. CS-5*, pp. 533-541, 1986.
- [8] K. Nakano, "Associatro - model of associative memory", *IEEE Trans. SMC-2*, pp. 380-388.
- [9] S. Amari, "Neural theory of association and concept-formation", *Biol. Cybern.* vol. 26, pp. 175-185, 1977.
- [10] F. J. Pineda, "Generalization of back-propagation to recurrent neural networks", *Phys. Rev. Lett.* vol. 59, pp. 2229-2232, 1987.
- [11] M. Sato, "A learning algorithm to teach spatiotemporal patterns to recurrent neural networks", *Biol. Cybern.*, pp. 259-263, 1990.
- [12] 백 승엽, "PLDMLP 신경회로망을 이용한 한글문자 인식" 경북대학교 석사학위논문, 1990年 12月

著 者 紹 介

呂 珍 環(正會員) 第 28卷 B編 第 10號 參照
 현재 경북대학교 전자공학과 박사
 과정 재학중

鄭 鎬 宣(正會員) 第 28卷 B編 第 9號 參照
 현재 경북대학교 전자공학과 교수
 재직중