

셀룰라 연상 신경회로망을 이용한 교통표지판 분류

The Traffic Sign Classification by using Cellular Associative Neural Networks

신윤철, 강훈

중앙대학교 전자전기공학부

Yoon Cheol Shin, Hoon Kang,
School of Electrical and Electronics Eng., Chung-Ang Univ.
(maytime@sirius.cie.cau.ac.kr)

ABSTRACT

인간 두뇌의 연상과 기억 작용의 모델링을 통한 구현의 일부분으로, 본 논문에서는 Hebb 의 학습방법과 non-cloning template을 사용하여 discrete-time cellular neural networks의 연상메모리 기능을 구현한다. 본 논문에서 사용된 학습방법은 각 셀의 인접한 셀과의 연결상태에 따라 하중값 매트릭스를 구현한다. 이러한 방법은 새로운 패턴의 추가 학습과 삭제가 쉽고, 또한 쉽게 구현할수 있는 장점이 있다. 이 방법으로 모의 실험에서는 교통표지판의 분류에 사용한다.

Keywords : Cellular Neural Networks, Associative Memory, Hebbian learning, Pattern Recognition

1. 서론

Cellular Neural Networks(CNN)은 영상의 특징점 추출, 영상처리 및 패턴인식 분야에서 많은 연구가 진행되어져 왔고, 최근에 Discrete-time Cellular Neural Networks(DTCNN)을 이용한 연상메모리 분야가 활발히 진행중이다. 또한 인간의 뇌의 공학적인 모델링을 통한 기억·연상 메커니즘 분석을 위하여 적용되고 있다. 시각적인 입력 장치의 하나로 영상처리 부분에 응용하여, CNN 은 2차원 영상처리로서 정의된 일정한 템플릿을 적용하여 기존의 영상처리의 이미지 변환을 나타낼수 있고, 학습을 통한 연상메모리 구현에는 각각의 뉴런에서 일정하지 않은 다른 템플릿을 사용한다. 각각의 템플릿은 뉴런들간의 연결 하중값을 나타내고 학습 따라 갱신된다. 본 논문에서는 CNN에 의한 연상메모리 구조를 설계하고, 학습 방법으로는 뉴런들간의 연결 하중값을 조정하는 가장 단순한 규칙인 Hebb의 학습방법이 사용되었다. 이 방법은 학습 저장능력에 제한이 있지만 구조가 간단하고 학습률, 학습속도, 패턴추출에서

우수한 성능을 가지고 있다. 그리고 CNN을 사용한 연상메모리는 다른 방법의 것과 비교하여 우위의 저장능력을 나타낸다. 전체의 하중값은 입력 영상($m \times n$)의 크기와 같은 크기의 행렬($m \times n$)이 9개(이웃한 뉴런수)가 중첩된 모양으로 구성된다.




그림 1. 셀룰라 신경회로망

모의 실험에서는 교통표지판 분류에 적용하여 학습된 패턴의 추출을 통한 표지판 인식분야에 사용하였다. 실제의 표지판 이미지를 흑/백의 2진 영상으로 바꾸어 학습 및 추출한다.

II. 본 론

2.1 DTCNN

CNN은 셀이라 불리는 연산요소(뉴런)들로 이루어진다. 하나의 셀은 다수의 입력과 하나의 출력을 가지며 그림 1.과 같이 한 층의 셀들은 모두 연결되어 각 셀의 정보는 인접한 셀과 그 인접한 셀을 통하는 주변의 다른 셀에 의해 갱신된다. 출력은 입력과 셀 상태값에 의해 결정되고 다시 입력으로 반복되어 연속적인 움직임을 얻을 수 있다.

$$x_{ij}(n+1) = \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l)y_{kl}(n) + \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l)u_{kl}(n) + I$$

$$y_{ij}(n) = f(x_{ij}(n)) = \frac{1}{2}(|x_{ij}(n)+1| - |x_{ij}(n)-1|)$$

x_{ij} state
 y_{ij} output $i=1, \dots, m$
 u_{ij} input $j=1, \dots, n$
 I_{ij} bias

(1)




그림 2. CNN 출력 특성

본 논문에서는 DTCNN을 사용하여 2차원의 영상처리분야에 적용하였다. 하나의 셀에서의 상태값과 출력은 식 1. 과 같이 2차원 영상의 변환식으로 표현 할 수 있다. 수식에 사용되는 A, B는 출력 제한값과 입력값에 적용하는 3×3 ($r=1$ 일 때) 또는 5×5 ($r=2$ 일 때)의 연산자(템플릿)이며 A는 이웃한 셀의 출력값에 미치는 영향, B는 입력의 영향을 나타낸다. A, B 에 적당한 값을 취하면 기존의 이미지 변환과 같은 이미지 처리를 표현 할 수 있다.

교통표지판 : 우로 굽은 도로




그림 3. 입력 영상

2.2 영상처리

그림 3.과 같이 실제의 CCD 카메라 영상을 그레이 스케일 영상으로 변환 후 흑/백의 2진 영상

을 만들어 낸다. 입·출력과 학습에 사용되는 2진 영상은 +1(흑)과 -1(백)의 값을 가지고 있고, 각 픽셀의 값은 CNN 셀의 상태값과 대응된다. 경계에 있는 셀의 처리를 위해 $m \times n$ 영상에 대하여 $(m+2) \times (n+2)$ 의 셀 수를 가진 CNN을 설정하고 주변 셀은 항상 -1의 상태값을 가진다.




그림 4. 연결 구조

$$y_{ij} = f(s_{ij}) = f\left(\sum_{Q=1}^9 w_{ij}^Q x_{ij}^Q\right)$$

$$f(s) = \begin{cases} 1 & s \geq 0 \\ -1 & s < 0 \end{cases}$$

$$x_{ij}^Q = \{x(i-1, j-1), x(i, j-1), x(i+1, j-1), x(i-1, j), x(i, j), x(i+1, j), x(i-1, j+1), x(i, j+1), x(i+1, j+1)\}$$

(2)

$$w_{ij}^Q = \{w1, w2, w3, w4, w5, w6, w7, w8, w9\}$$

각각의 셀의 연결 하중값은 그림 4.와 같이 연결되고, x_{ij}^Q 는 ij번째 셀과 인접한 Q번째 셀, w_{ij}^Q 는 ij번째 셀과 인접한 Q번째 셀간의 연결 하중값을 나타낸다. 셀 출력은 식 2.와 같이 인접한 9개의 셀의 상태값과 연결된 하중값의 영향을 받고, 출력함수의 문턱값에 따라 출력값이 결정된다.

2.3 학습방법

CNN 연상메모리의 학습에 사용한 Hebbina Learning은 인접한 셀들의 상태값에 따라 연결된 하중값을 조정한다. 하중값은 모두 0 으로 초기화하고, 식 3.과 같이 떨어진 셀의 영향은 고려하지 않고 인접한 셀의 영향만 받는다.

$$W_{ij}^Q = \sum_{k=1}^p P_{ij,k} P_{ij,k}^Q$$

$$P_k : k=1, \dots, p$$

$$P_{ij,k} : x(i, j)_k$$

$$P_{ij,k}^Q : x_{ij,k}^Q$$

(3)

입력 패턴은 p개의 패턴이 정의 되었고 $P_{y,k}$ 은 k번째 패턴의 ij셀의 값을 나타내고, $P_{y,k}^0$ 은 k번째 패턴의 ij셀과 연결된 Q번째 셀의 값이다. 전체의 하중값은 표 1.과 같은 구조의 3차원 행렬 형식으로 나타내어진다. 즉, $m \times n$ 행렬이 9개 중첩된 모양이다.

표 1. weight matrix W_{ij}^q

j \ i	1	...	n
1	(w1,w2,...w9)	...	(w1,w2,...w9)
...
n	(w1,w2,...w9)	...	(w1,w2,...w9)

본 논문에서 사용한 학습방법은 새로운 학습 패턴 추가 삭제시 전체의 패턴을 학습하지 않고 주어진 패턴만 추가, 삭제하여 학습 시간이 빠르고 새로운 패턴의 학습과 제거가 쉽다.

새로운 학습패턴 추가 : $W_{ij}^q = W_{ij}^q + W_{ij,p+1}^q$

학습된 패턴 삭제 : $W_{ij}^q = W_{ij}^q - W_{ij,k}^q$ (4)

2.4 모의실험

모의 실험에서는 그림 3.과 같은 100 pixel \times 100 pixel 크기의 입력을 사용하고, $9 \times 100 \times 100$ 의 하중값, 102×102 의 CNN을 설정한다.

```

weight 초기화
k=1
while
  if 학습되지 않은 패턴의 추가
    for j = 1 : image size y
      for i = 1 : image size x
         $W_{ij}^0 = W_{ij}^0 + x_{y,k} x_{ij,k}^0$ 
      k=k+1
    if 학습된 패턴의 삭제
      for j = 1 : image size y
        for i = 1 : image size x
           $W_{ij}^0 = W_{ij}^0 - x_{y,k} x_{ij,k}^0$ 
        k=k-1
  
```

그림 5. 학습 알고리즘

그림 6.과 같은 비슷한 직진금지, 우로굽은도로, 우회전, 우회전금지 등 4종류의 학습 패턴과 다른 6가지 등 모두 10개의 입력 패턴을 사용하였고 출력층에서 정의된 4종류의 패턴을 분류하였다.

DTCNN 각 셀에서의 출력함수의 문턱값 θ 는 0의 값을 사용하였으나 학습 패턴이 많아 질수록 하중값이 커지는 관계로 학습되지 않은 패턴도 정확한 출력으로 나타날 수 있는 가능성이 커지고 반복된 연산에서 모든 셀이 1로 수렴하는 현상이 나타난다. 따라서 학습패턴 수에 따라 문턱값이 비례하도록 조정하여 문제를 해결할 수 있는 방법을 적용할 수 있다.



그림 6. 입력 패턴




그림 7. 패턴 분류기

그림 8. 은 우회전 금지 패턴의 입력과 출력을 나타낸다. 학습 후에는 정확한 패턴을 추출 할 수 있다.



그림 8. 출력 패턴 I

그림 9.에서와 같이 잡음이 첨부된 입력에서도

같은 결과를 얻을 수 있다. 그림 8.과 그림 9.의 출력은 모두 3번의 반복후에 나타난 이미지 이다.



그림 9. 출력 패턴 II

III. 결론

DTCNN을 이용한 연상메모리를 설계하여 학습 패턴의 분류에 적용하였다. 학습에 사용된 Hebbian learning은 학습방법이 간단하여 쉽게 적용할 수 있고 쉽게 패턴의 추가 삭제를 할 수 있고 이를 모의실험을 통하여 학습된 패턴의 정확한 추출을 볼 수 있다. 그러나 학습방법의 기본적인 학습용량의 문제점과 패턴의 일부만을 이용한 연상메모리의 결과로는 부족한 점이 있어 실제에 적용하기엔 어려움이 있을 수도 있을 것이다. 다층 구조의 CNN을 사용하면 컬러추출과 많은 데이터의 학습을 통한 문제점을 해결할 수 있으리라 생각되어지고 정보의 학습과 기억의 메커니즘의 분석에 도움이 될 것이다. 또한 인간 두뇌의 연상을 담당하는 해마 기능의 모델링을 통한 학습, 기억, 연상의 구현에 적용할 수도 있을 것이다.

감사의 글 : 본 연구는 과학기술부 뇌공학연구 사업에 의해 지원 받았습니다.

IV. 참고문헌

- [1]O. Bandaman, and S. Pudov, "Design and Simulations of Cellular Neural-like Associative Memory," *Int. Workshop on Distributed Interactive Simul. and Real Time App.*, pp. 49-56, 1997
- [2]M. Brucoli, L. Carnimeo and G. Grassi, "Discrete-Time Cellular Neural Networks for Associative Memories: A New Design method via Iterative Learning and Forgetting Algorithms," *Proceedings of the 38th Midwest Symposium on Circuit and Systems*, vol. 1, pp. 542-545, 1996
- [3]L. O. Chua and L. Yang, "Cellular neural

networks," *IEEE Trans. on circuits and systems*, vol. 35, pp. 1257-1272, July, 1988.

[4]G. Grassi, "On Discrete-Time Cellular Neural Networks for Associative Memories" *IEEE Trans. on Circuits and Systems I*, vol. 48, no. 1, pp. 107-201, Jan. 2001.

[5]H. Kawabata, M. Nanba and Z. Zhang, "On the Associative Memories in Cellular Neural Networks," *IEEE Int. Conference on Computational Cybernetics and Simulations*, vol. 1, pp. 929-933, 1997

[6]S. Tan, J. Hao and J. Vandewalle, "Cellular Neural Networks as a Model of Associative Memories," *Proc. of IEEE Int. Workshop on Cellular Neural networks and Their Applications*, pp. 26-35, 1990