

셀룰라신경회로망의 연상메모리를 이용한 영상 패턴의 분류 및 인식 방법

Image Pattern Classification and Recognition by using Associative Memories with Cellular Neural Networks

신윤철, 박용훈, 강훈

중앙대학교 전자전기공학부

Yoon-Cheol Shin, Yong-Hun Park and Hoon Kang

School of Electrical and Electronic Engineering, Chung-Ang University

E-mail : jdprist@sirius.cie.cau.ac.kr, hkang@cau.ac.kr

ABSTRACT

셀룰라 신경회로망의 연상 메모리를 이용하여 시각적인 입력 데이터의 연산을 통하여 영상 패턴의 분류와 인식을 수행한다. 셀룰라 신경회로망은 일반적인 신경회로망과 같이 비선형 데이터의 실시간 처리가 가능하고, 세포자동자와 같이 격자구조의 셀로 이루어져 인접한 셀과 직접 정보를 주고받는다. 응용 분야로는 최적화, 선형/비선형화, 연상 메모리, 패턴인식, 컴퓨터 비전 등에 적용할 수 있다. 영상의 이미지 픽셀을 셀룰라 신경회로망의 셀에 대응하여 전체 이미지 영상을 모든 셀룰라 신경회로망의 셀에서 동시에 병렬로 처리할 수 있어 2-D 이미지 처리에 적합하다. 본 논문은 셀룰라 신경회로망에 의한 연상 메모리 구조를 설계하고, 학습된 하중값 메모리에서 가장 적당한 하중값을 선택하여 학습된 영상과 정확히 일치하는 출력을 얻는 방법을 제시한다. 학습을 통한 연상 메모리 구현에는 각각의 뉴런에서 일정하지 않은 다른 템플릿을 사용한다. 각각의 템플릿은 뉴런들 간의 연결 하중값을 나타내고 학습에 따라 갱신된다. 학습방법으로는 템플릿 하중값 학습에 뉴런들 간의 연결 하중값을 조정하는 가장 단순한 규칙인 Hebb의 학습방법이 사용되었고 분류값 학습에 LMS 알고리즘이 사용되었다.

Key words : cellular neural network, associative memory, pattern recognition, local/global weight, weight selection

I. 서 론

셀룰라 신경회로망(Cellular Neural Networks: CNN) [1,2,3]은 신경회로망(Neural Network) [4]과 같이 비선형 데이터의 실시간 병렬처리가 가능하고, 세포자동자(Cellular Automata) [5]와 같이 격자구조의 셀로 이루어져 인접한 셀과 직접 정보를 주고받는다 [1,2]. 다수의 입력과 한 개의 출력을 가지며, 한 층의 셀들은 모두 연결되어 각 셀의 정보는 인접한 셀과 그 인접한 셀을 통하는

주변의 다른 셀에 의해 직접 갱신된다. 응용 분야로는 최적화, 선형/비선형화, 연상메모리, 패턴인식, 컴퓨터 비전 등에 적용할 수 있다 [1,3]. 특히, 영상의 특징점 추출, 영상처리 및 패턴인식 분야에서 많은 연구가 진행되어 왔고 최근에 Discrete-time Cellular Neural Networks(DTCNN)을 이용한 연상메모리 분야의 연구가 활발히 진행중이다. 그 방법으로는 Hebbian rule, relaxation algorithm, eigenstructure method, pseudo-inversion technique [6,7,8,9] 등이 있다. 본 논문에서는

CNN을 시작적인 입력 데이터의 연산장치의 하나로 영상처리 부분에 응용하여 입력패턴의 분류와 인식을 수행한다. CNN에 의한 연상메모리 구조를 설계하고, 학습된 하중값 메모리에서 가장 적당한 하중값을 선택하여 학습된 영상과 정확히 일치하는 출력을 얻는 방법을 제시한다.

II. 본 론

2.1 Discrete-time Cellular Neural Networks

이산 시간 셀룰라 신경회로망(Discrete-Time Cellular Neural Networks: DTCNN)은 이차원 영상신호처리에 사용하기 위하여 CNN의식을 변형하여 식 (1)과 같이 2차원 영상의 변환식으로 표현 할 수 있다. 또한 간략히 식 (2)와 같이 나타낼 수 있다.

$$X_{ij}(n+1) = \sum_{C(k,l) \in N_r(i,j)} A(i,j,k,l) y_{kl}(n) + \sum_{C(k,l) \in N_r(i,j)} B(i,j,k,l) u_{kl}(0) + I_{ij} \quad (1)$$

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

$$T(i,j) : \text{Templates matrix}$$

그림 1은 하나의 셀 $C(i, j)$ 의 연산을 나타내고 모든 셀에 일관적으로 적용된다.




그림 1. DTCNN 템플릿 연산

$$x_{ij}^N = \{x(i-1, j-1), x(i, j-1), x(i+1, j-1), x(i-1, j), x(i, j), x(i+1, j), x(i-1, i+1), x(i, j+1), x(i+1, j+1)\} \quad (3)$$

$$T_{ij}^N = \{t1, t2, t3, t4, t5, t6, t7, t8, t9\}$$

$$x_{ij}(t+1) = \sum_{N=1}^9 T_{ij}^N x_{ij}^N(t) + I \quad (4)$$

2.2 Cellular Neural Network with Associative Memory

연상 메모리(Associative Memory)는 주어진 자료에 대해 정보를 저장하는 장치이며, Content-Addressable Memory의 일종으로 간주할 수 있다. 대표적인 연상 메모리로는 Bart Kosko의 쌍방향 연상메모리(Bidirectional Associative Memory, BAM)와 John Hopfield의 Hopfield Memory가 있다. 본 논문의 셀룰라 신경회로망을 사용한 연상메모리는 비교사학습(Hebbian 학습)과 교사학습(LMS 학습)의 2가지의 방법을 사용하여 학습된 패턴의 정확한 분류와 왜곡된 패턴의 완벽한 복원, 분류를 수행한다. 각 셀에 적용하는 템플릿은 일정하지 않은 non-cloning template으로 이웃한 셀 간의 상태값에 따른 학습된 하중값을 나태낸다. 각 입력 패턴은 LMS 알고리즘에 의해 먼저 분류값이 정해지고, Hebb의 학습방법에 따라 CNN의 각 셀의 템플릿 하중값을 구한다.




그림 2. CNN 연상 메모리

2.3 Gobal Weight & Local Weight

Hebb의 학습방법을 이용한 CNN 연상메모리는 적은 수의 학습 데이터와 학습원본과 같은 입력에서는 우수한 성능을 보이나 학습 데이터 수가 증가할수록 그리고 왜곡된 입력에서는 정확한 출력을 얻을 수 없다. 본 논문에서는 CNN의 학습 방법을 2가지로 분류하여 쉽게 왜곡된 입력에서도 원본 학습 데이터를 정확히 추출 할 수 있다.

2.3.1 Local Weight

부분 하중값(Local weight)은 패턴의 하중

값을 모두 더한 값으로 설정했다. 즉, 패턴의 수만큼의 부분 하중값이 존재한다.

$$LW_{ij,k}^N = x_{ij,k} x_{ij,k}^N \quad k=1,,P \quad (5)$$

2.3.2 Global Weight

전체 하중값(Global weight)은 모든 패턴의 하중값이다. 즉, 모든 부분 하중값의 합이다.

$$GW_{ij}^N = \sum_{k=1}^n LW_{ij,k}^N = x_{ij,k} x_{ij,k}^N \quad (6)$$

2.4 Weight Selection

하중값 선택은 하중값 메모리의 부분하중값 패턴 중에서 하나의 하중값 패턴을 선택한다. 입력이미지는 전체하중값과 모든 부분하중값에 적용되어 P개의 학습데이터중 하나의 입력에 1개의 전체하중값 출력과 P개의 부분하중값 출력이 존재하며, 출력 분류값을 구하여 선택 알고리즘에 따라 가장 최적의 하중값 패턴을 선택하여 전체하중값 출력에 적용한다. 선택된 하중값 패턴으로 반복하면 정확한 학습된 출력 영상을 볼 수 있다.

그림 3은 분류값이 일치하는 경우, 그림 4는 분류값이 일치하지 않은 경우의 예이다.

* 하중값 선택 알고리즘 (그림 3 참조)

1. local pattern의 위치와 부분 하중값 출력의 분류값(L0, L1,..., LP-1)이 같은 패턴들을 선택 (패턴 1이 일치)
2. 선택된 패턴들 중 전체 하중값 출력의 분류값(G)과 일치하는 패턴을 선택 (전체 분류값 1, 일치하는 1번째 패턴 선택)
3. 선택된 패턴의 부분 하중값을 전체 하중값 출력에 적용




그림 3. 하중값 선택 I




그림 4. 하중값 선택 II

1번에서 일치하는 패턴이 없을 경우 일치하는 값이 있을 때까지 반복 수행한다. (그림 4 참조)

2번에서 일치하는 패턴이 없을 경우 전체 하중값 출력의 분류값과 가까운 패턴을 선택한다. (그레이 코드의 분류값에서 가까운 패턴)

2.5 시뮬레이션 결과

시뮬레이션에서는 0~9의 아라비아 숫자 이미지와 16개의 교통 표지판 이미지를 분류 인식하였다. 분류기에 4개의 출력노드를 두어 16개의 이미지를 분류 인식 할 수 있고 입력 이미지는 256의 그레이 영상을 사용한다. 출력노드의 출력값은 1 또는 -1이고 오차 범위는 0.0001 학습률은 0.00001 이다.

숫자 영상들을 분류하기 위해 흑백의 2진 이미지를 입력으로 사용하였다. 각 이미지의 크기는 50×50 이고, 이미지의 글자체는 돌움체를 사용하였다. 9개의 이웃셀을 가진 CNN은 52×52 크기를 가지고, 25개의 이웃셀을 가진 CNN은 54×54크기를 가지고 있다. 각 픽셀은 +1(흑)과 -1(백)의 값을 가지고 경계셀의 값은 항상 0이다.




그림 5. 숫자 이미지 인식, 복원 과정



그림 6은 심하게 왜곡된 입력 데이터에 대한 결과이다. 입력은 잡음으로 인해 데이터의 일부가 소실된 영상이다. 위의 경우와 마찬가지로 부분 하중값을 선택하여 원래의 학습 이미지를 복원하고 인식할 수 있다.

III. 결 론

본 논문에서는 셀룰라 신경회로망을 이용하여 학습과 패턴 매칭을 통한 영상의 분류와 인식 방법을 제안하였으며, 숫자 이미지와 교통 표지판 이미지에 적용하여 그 유용성을 입증하였다.

기존의 Hebb 학습방법만을 이용한 셀룰라 연상 메모리는 입력 이미지의 유사성에 따라 학습률과 학습량에 제한이 있으나 제안된 방법은 메모리의 크기만 충분하면 학습량의 제한을 받지 않는다. CNN의 자체 특성상 이미지 처리에서는 어느 정도 잡음을 제거할 수 있기 때문에 전체 하중값 출력만으로도 학습된 이미지를 분류하고 인식할 수 있지만, 크게 훼손된 이미지는 분류할 수 없고 학습된 이미지의 모양을 알 수 없다. 이 문제는 부분 하중값 선택으로 적합한 하중값을 선택하여 최종 출력은 학습된 이미지와 같은 출력을 얻을 수 있다. 인간의 뇌를 공학적으로 모델링함으로써 뇌의 기억·연상 메커니즘을 분석하기 위해 이 방법을 인간 두뇌의 연상 작용과 기억 방식에 비교한다면, 하중값 선택과 전체 하중값의 출력은 해마의 연상 작용이라 할 수 있으며, 영구적인 기억은

부분 하중값의 학습이라 할 수 있다.

하중값 패턴을 글자 수에 맞추어 학습을 하면 영문 알파벳에 적용할 수 있고, 한글의 모음 자음 패턴에 적용 하면 음소 단위의 문자인식을 통한 한글 인식도 가능할 것이다.

감사의 글 : 본 연구는 과학기술부 뇌신경 정보학 사업(M10107000005-01A2200-00210)의 연구비 지원으로 수행되었으며 연구비 지원에 감사 드립니다.

IV. 참고문헌

- [1] L. O. Chua and L. Yang, "Cellular neural networks", IEEE International Symposium on circuits and systems, pp. 985–988, 1988.
- [2] L. O. Chua and L. Yang, "Cellular neural networks: Theory", IEEE Trans. on circuits and systems, vol. 35, pp. 1257–1272, Oct. 1988.
- [3] L. O. Chua and L. Yang, "Cellular neural networks: Applications", IEEE Trans. on circuits and systems, vol. 35, pp. 1273–1290, Oct. 1988.
- [4] J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", Proc. Nat. Acad. Sci. vol 79, pp. 2554–2558, Apr. 1982
- [5] S. Wolfram, Theory and Applications of Cellular Automata, New York: World Scientific, 1986
- [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
- [7] G. Martinelli and R. Perfetti, "Associative memory design using space-varying cellular neural networks for associative memories", Proc. of Symposium on circuits and systems, pp. 549–552, 1994.
- [8] D. Liu and A. N. Michel, "Cellular neural networks for associative memories", IEEE Trans. on circuits and systems, vol. 40, pp. 119–121, 1993.
- [9] 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