

신경 진동자 위상모델의 동기화를 이용한 한글인식

권용범\*, 송홍준\*, 박영식\*\*, 이준탁\*\*\*

\*동아대학교 전기공학과, \*\*동의대학교 컴퓨터 과학과, \*\*\*동아대학교 전기전자컴퓨터공학부

Recognition of the Korean alphabet Using Neural Oscillator Phase model Synchronization

\*Yong-Bum Kwon, \*Hong-Jun Song, \*\*Young-Sik Park, \*\*\*Joon-Tark Lee

\*Dept. of Electrical Eng Dong-A Univ, \*\*Dept. of Computer Science Dong-eui Univ, \*\*\*Dept. of Electrical Electronic & Computer Dong-A Univ Eng.

**Abstract** - 신경 진동자는 이미지정보의 해석, 음성인식, 지질 변화 예측 등의 진동하는 시스템에 응용되어진다. 이러한 진동하는 시스템에 기존의 역전파 알고리즘을 이용하는 경우, 복잡 다양한 입력 패턴을 추정하기가 어려우므로 학습단계에서 더 많은 양의 학습 데이터가 필요하게 되며 수렴 속도의 지연과 근사화가 어렵다. 따라서 본 논문에서는 모델에 대한 함수의 근사화가 쉬우며 학습하는 구조를 가지는 신경 진동자에 의한 위상 동기화 특성을 연구하고 이를 이용한 한글 문자 인식시스템을 구현하였다.

1. 서 론

진동을 수반하는 시스템은 물리계에 흔히 존재해 있으며 특히 뉴런과 뇌의 동특성에서 잘 나타난다. 이러한 진동하는 시스템에서 뇌의 뉴런들의 정보처리 시스템은 발화되는 뉴런들의 동조현상과 주기적인 특성을 가지고 있다. 그러나 기존의 신경망을 이용한 연구는 주로 진동하지 않는 시그모이드 뉴런들에 초점이 맞추어져 왔으며 이러한 뉴런들에서 발화의 정밀한 샘플링 시간은 무시되어져 왔었다. 따라서 진동하는 신경망의 신경 연산 특성을 이해하기 위해서는 각각의 뉴런들이 주기적인 특성을 보인다는 것을 생각해 볼 필요가 있다. 이런 진동하는 신경망은 뉴런의 위상 모델에 의해 표현할 수 있다. 진동하는 신경망은 그림 1과 같이 Hopfield network의 신경 연산 특성을 가지면서 진동하는 위상의 동기화에 의한 신경 연산 특성을 보인다.




그림 1. 일반적인 신경망과 신경 진동자

따라서 본 논문에서는 진동하는 시스템의 하나로서 뇌에서 뉴런의 발화시 뉴런과 다른 뉴런 사이의 막전위가 주기적인 특성을 보이며 진동하는 현상인 신경 진동자의 동기화를 이용하여 문자의 임의 패턴이 입력되었을 때 기억되어진 패턴을 추종하는 한글인식 시스템을 구현하고자 한다.

2. 신경진동자의 위상모델

2.1 연결강도가 약한 뉴런들의 정규화 모델

일반적으로 뉴런들의 연결강도가 약하게 되어있을 경우 뉴런사이의 시냅스 후전압은 1 [mV]로서 방전에 필요한 전압 20 [mV]와 활동전위 100 [mV]와 비교하여 대단히 적은 값이다. 여기서 뉴런의 연결강도가 약할 경우의 수학적 모델링은 다음과 같다.

$$\dot{x} = f(x_i, \lambda_i) + \epsilon \sum_{j=1}^n g_{ij}(x_j, x_i, \epsilon) \tag{1}$$

벡터  $x$ 는 막전위와 게이팅 변수 그리고  $i$ 번째 뉴런의 전기생물학적 변수를 나타낸다. 함수  $f$ 는 뉴런의 동특성을 나타내며 함수  $g_{ij}$ 는 뉴런들 사이의 연결을 나타낸다. 또한  $\epsilon$ 은 뉴런 사이의 연결강도이며  $\epsilon \ll 1$ 이면 연결강도가 약하다는 것을 의미한다. 여기서 식(1)을 식(2)와 같이 변환할 수 있고  $r_i$ 와  $s_{ij}$ 를 제외한  $g_{ij}$ 와  $\lambda_i$ 는 변환된 후 더 이상 쓰여지지 않는다. 식(2)는 비선형 항  $y_i^3$ 과 두 개의 내부 파라미터  $r_i$ 와  $s_{ij}$ 로 구성되며 코헨-그로스버그-홉필드(Cohen-Grossberg-Hopfield) 수렴정리를 이용하여 얻어진다. 즉,

$$y_i' = r_i - y_i^3 + \sum_{j=1}^n s_{ij} y_j \tag{2}$$

에서 코헨-그로스버그-홉필드 수렴정리는 다음과 같다.

$$E(y) = - \sum_{i=1}^n (r_i y_i - \frac{1}{4} y_i^4) - \frac{1}{2} \sum_{i,j=1}^n s_{ij} y_i y_j \tag{3}$$

로 된다. 식(3)에서  $y_i' = -\partial E / \partial y_i$ 로 두면 식(2)과 같이 된다.

2.2 진동하는 신경망의 동기화

일반적으로 뉴런과 뉴런사이의 막전위는 진동 특성을 보이는데 이러한 진동은 주기적이며 변수들이 지속적으로 변한다고 한다면 연결강도가 약한 신경망을 나타내는 식(1)은 식(4)과 같이 변환할 수 있다.

$$z_i' = (r_i + i\omega_i)z_i - z_i |z_i|^2 + \sum_{j=1}^n c_{ij} z_j \tag{4}$$

여기서  $i = \sqrt{-1}$ 이며 복소변수  $z_i$ 는  $i$ 번째 뉴런의 진동을 나타낸다. 만약 식(3)의 모든 뉴런들이 같은 주파

수 ( $\omega_1 = \dots = \omega_n$ )를 가지고 연결 행렬  $C = (c_{ij})$ 에서 모든  $i$ 와  $j$ 에 대해  $c_{ij} = \overline{c_{ji}}$ 가 되며 이때  $c_{ij} = s_{ij} e^{i\psi_{ij}}$ 이고  $\overline{c}$ 는 공액복소수를 의미한다. 복소변수  $z_j$ 와 연결행렬  $c_{ij}$ 를 사용하면 식(3)은 다음과 같이 변환될 수 있다.

$$E(z) = - \sum_{i=1}^n (r_i |z_i|^2 - \frac{1}{2} |z_i|^4) - \sum_{i,j=1}^n c_{ij} \overline{z_i} z_j \quad (5)$$

연결강도가 약한 신경망에서 뉴런들이 외부의 자극에 대해 어떠한 반응을 보이는지를 나타내는 그림 2의 Morris-Lecar 모델처럼 막전위의 전압이 주기적인 spike 형태를 가진다고 생각해 보자. 즉 뉴런들이 거의 동일한 주파수를 가질 때 다음과 같은 위상 모델로 바꿀 수 있다.

$$\varphi_i' = \omega_i + \sum_{j=1}^n H_{ij}(\varphi_j - \varphi_i) \quad (6)$$

여기서  $\varphi_i$ 는  $i$ 번째 진동자의 위상을 나타내며  $H_{ij}$ 는 연결함수이다.




그림 2. 주기적으로 진동하는 뉴런모델(Morris-Lecar Model)

만약 식(6)에서 진동자들이 모든  $i$ 와  $j$ 에 대하여 주파수가 같으며 ( $\omega_1 = \dots = \omega_n$ ) 연결함수  $H_{ij}$ 가 기함수이면 식(6)의 위상모델은  $\varphi_i(t) \rightarrow \omega_1 t + \phi_i$ 로 수렴하게 된다.

### 2.3 위상모델의 동기화

위상모델을 나타내는 식(6)은  $\varphi_i' = -\frac{\partial U}{\partial \varphi_i}$ 에 의해 다음과 같은 에너지 함수로 바꿀 수 있다.

$$U(\varphi) = \frac{1}{2} \sum_{i,j=1}^n R_{ij}(\varphi_j - \varphi_i) \quad (7)$$

여기서  $R$ 은  $H$ 에서 유도되어진다. 즉  $R = H$ 이다. 만약 시냅스 연결이 대칭이면 네트워크는 식(6)에 의해 위상관계의 패턴들을 동기화할 수 있다.

이제 동기화된 위상들을 이용하여 문자열의 패턴을 인식하여 보자. 우선 그림 3에서 보듯이 추종할 패턴을 미리 기억해 놓기 위해 다음과 같은 벡터의 집합을 생성한다.

$$\xi_i^k = (\xi_1^k, \xi_2^k, \dots, \xi_n^k), \quad \xi_i^k = \pm 1, \quad k=0, \dots, p \quad (8)$$

여기서  $\xi_i^k = \xi_j^k$ 의 의미는  $i$ 번째와  $j$ 번째의 진동자들이 동위상 ( $\varphi_i = \varphi_j$ )에 있다는 것이며  $\xi_i^k = -\xi_j^k$ 의 의미는 반대의 위상 ( $\varphi_i = \varphi_j + \pi$ )에 있다는 것이다.




그림 3. 추종하기 위해 기억되어져 있는 패턴들.




그림 4. 인식하기 위한 임의의 입력 패턴

여기에서 패턴인식을 위해 식(9)의 Hebbian-Learning rule을 적용한다.

$$s_{ij} = \frac{1}{n} \sum_{k=0}^p \xi_i^k \xi_j^k \quad (9)$$

우선 한글 인식을 하기위해 대표적으로 그림 3의 "가", "나", "다"의 세가지 이미지들을 선택하였다. 그림 4는 그림 3에서 "가"의 왜곡된 이미지이며 "가"를 인식하기 위해 주어지는 초기 위상 패턴이다. 여기서 일단 이 시스템의 두 개의 출력  $V(\theta_1)$ 과  $V(\theta_2)$  그리고  $\varphi_1$ 과  $\varphi_2$ 에 의해 유도되는 출력의 위상을 얻을 수 있다. 얻어진 위상 패턴을 명확히 하려면 인식되어진 이미지의 진동하는 위상에서 고주파수를 제거해야한다. 식(10)은 이러한 low-pass filtering의 과정이다.

$$V(\theta_1)V(\theta_2) \rightarrow \cos(\theta_1 - \theta_2) = \cos(\varphi_1 - \varphi_2) \quad (10)$$

### 2.4 위상의 동기화에 의한 패턴인식

다음의 뉴런 위상모델을 생각해 보자.

$$\theta_i' = \Omega + V(\theta_i) \sum_{j=1}^n s_{ij} V(\theta_j - \frac{\pi}{2} + \varphi_{ij}) \quad (11)$$

여기서  $\varphi_{ij}$ 는 각 뉴런들 사이의 시냅스 연결에 대한 위상차를 나타낸다. 모든  $i$ 와  $j$ 에 대해 연결 행렬은  $c_{ij} = \overline{c_{ji}}$ 이며 이것은  $c_{ij} = s_{ij} e^{i\psi_{ij}}$ 로 표현된다. 추종할 패턴을 미리 기억하기 위한 벡터는 다음과 같이 된다.

$$\xi_i^k = (\xi_1^k, \xi_2^k, \dots, \xi_n^k), \quad \xi_i^k = \pm 1 \quad (12)$$

여기서 이미지 "가"를 인식하기 위해서 추종할 패턴 "가"를 미리 입력하며 이때 Hebbian-Learning rule인 식(9)을 사용하여 패턴을 추종해 나간다.

여기서 출력 패턴이  $V(\theta) = \sin \theta$ 이면 식(11)은 다음의 형태가 된다.

$$\theta_i = \Omega + V(\theta_i) \sum_{j=1}^n (v_{ij} V(\theta_j - \frac{\pi}{2}) + w_{ij} V(\theta_j)) \quad (13)$$

단,  $v_{ij} = \text{Rec}_{ij} = s_{ij} \cos \varphi_{ij}$ 이며  $w_{ij} = \text{Imc}_{ij} = s_{ij} \sin \varphi_{ij}$  이다.

### 2.5 결과 및 고찰

문자 "가"를 인식하기 위해 신경 진동자의 위상 동기화를 사용하여 패턴을 인식한 결과이다(그림 5). 그림 5의 각 픽셀은 첫째칸  $\xi_1^k$ , 둘째칸  $\xi_2^k, \dots$ , 마지막칸  $\xi_{70}^k$  까지 총 70칸이다. 패턴의 인식에 걸리는 총시간은 10초이며 샘플링 시간은 0.3초이다. 즉 초기시간  $t=0[\text{sec}]$ 에서 임의의 패턴이 입력되었을 때 미리 기억해 놓은 "가"를 추종하여  $t=10[\text{sec}]$ 가 된 후에 인식에 성공하였다.

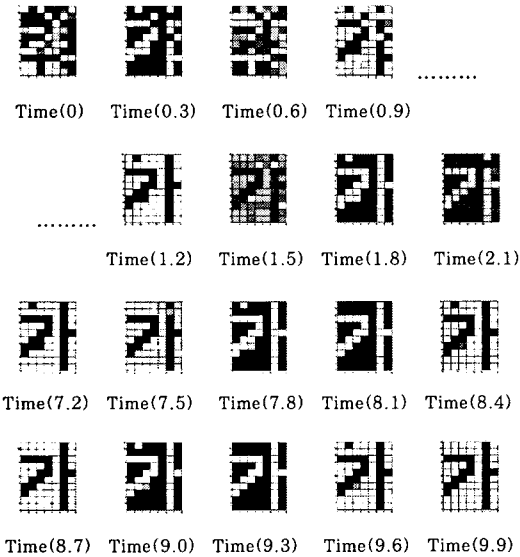


그림 5. Hebbian- Learning rule을 적용하여 구현한 "가"의 패턴 인식




그림 6. 문자 인식시의 위상 동기화과정




그림 7. 인식한 패턴의 위상 동기화과정

여기서 그림 5의 출력과 위상을 각각 그림 6.과 그림 7에서 도시하였다. 그림 6의  $V(\theta_1)$ 과  $V(\theta_2)$ 는 그림 5의  $\xi_1^k$ 와  $\xi_2^k$ 의 출력에 해당하며 그림 7은 이런 출력의 위상을 나타낸다. 그림 7의 두 위상  $\varphi_1$ 과  $\varphi_2$ 가 시간이 지남에 따라 점점 동기화됨을 볼 수 있다.

### 3. 결 론

본 논문에서는 학습하는 구조를 가지는 신경 진동자의 위상 동기화를 이용하여 한글 문자의 인식시스템을 구현하였다. 특히 일반적인 신경망 제어기와 비교하여 보다 정밀한 샘플링 시간을 가질 수 있었다. 다만 패턴을 인식하는데 걸리는 전체시간(10초)이 길다는 점은 개선해야 될 부분으로 생각되어지며 앞으로 필기체등의 인식뿐만 아니라 음성인식, 영상해석, 지질변동의 예측 등 진동이 수반되는 시스템의 다양한 분야에 응용할 수 있을 것이다.

### (참 고 문 헌)

- [1] Hoppensteadt F.C. and Izhikevich E.M, "Oscillatory Neurocomputers With Dynamic Connectivity", Physical Review Letters, 82호, 2983-2986, (1999)
- [2] Abhijit S. Pandya and Robert B.Macy, "Pattern Recognition with Neural Networks in C++", (1995)
- [3] Dorel M. Sala and Krzysztof J.Cios, "Solving Graph Algorithms with Networks of Spiking Neurons", IEEE, 10호, 4, (1999)
- [4] Steven Elliot, "Pattern Recognition", (1992)
- [5] Izhikevich E.M, "Simple Model of Spiking Neurons" IEEE Transactions on Neural Networks, (2003)
- [6] Gail A. Carpenter and Stephen Grossberg, "Pattern Recognition by Self-Organizing Neural Networks", (1991)