

상태피드백 실시간 회귀 신경회로망을 이용한 EEG 신호 예측

論文

51D-1-6

EEG Signal Prediction by using State Feedback Real-Time Recurrent Neural Network

金 宅 淮*
(Taek-Soo Kim)

Abstract - For the purpose of modeling EEG signal which has nonstationary and nonlinear dynamic characteristics, this paper propose a state feedback real time recurrent neural network model. The state feedback real time recurrent neural network is structured to have memory structure in the state of hidden layers so that it has arbitrary dynamics and ability to deal with time-varying input through its own temporal operation. For the model test, Mackey-Glass time series is used as a nonlinear dynamic system and the model is applied to the prediction of three types of EEG, alpha wave, beta wave and epileptic EEG. Experimental results show that the performance of the proposed model is better than that of other neural network models which are compared in this paper in some view points of the converging speed in learning stage and normalized mean square error for the test data set.

Key Words : State Feedback Recurrent Neural Network, Nonlinear Dynamic System, EEG, Prediction

1. 서 론

신경회로망은 입·출력 및 내부 상태에 대한 메모리의 유무에 따라 정적 신경회로망과 동적 신경회로망으로 구분할 수 있다. 정적 신경회로망은 메모리를 갖지 않는 신경회로망으로 시스템의 출력은 과거 입·출력 및 상태에 의존하지 않고 단지 현재 입력에 의해서만 결정된다. 반면에 동적 신경회로망은 메모리를 가지고 있어 시스템의 출력이 과거 및 현재의 입·출력 및 내부 상태에 의존하며 입·출력 관계가 미분 방정식 혹은 차분 방정식으로 표현 된다. 정적 신경회로망의 대표적인 예로 Rumelhart 등의 역전파 알고리즘, Radial Basis 함수를 이용한 신경회로망 및 벡터 양자화기 (Vector Quantizer)[1] 등을 들 수 있고, 동적 신경회로망의 대표적인 예는 출력 및 내부 상태를 피드백시키는 회귀 신경회로망을 들 수 있다. 특히 회귀 신경회로망은 피드백 구조를 갖기 때문에 시간적 변이를 수용할 수 있는 단기간의 메모리를 가지므로 신경회로망의 시간적 사상 능력의 향상을 기대할 수 있으며, 피드 포워드 계열의 다층 퍼셉트론에 비해 더 적은 노드 수로 시스템을 구성할 수 있어 계산 시간상의 효율성을 기대할 수 있다는 장점을 갖는다[2][3].

본 논문에서는 비선형 동역학적 특성을 갖는 뇌파신호의 예측 모델로서 학습수렴 속도가 뛰어나고 예측성능이 우수

한 상태 피드백 실시간 회귀 신경회로망 (State Feedback Real-Time Recurrent Neural Network)을 제안한다. 그리고 이 모델을 결정론적 비선형 동역학 시스템으로부터 발생하는 Mackey-Glass 시계열의 예측에 적용하여 비선형 동역학 시스템에 대한 예측 능력을 학습 수렴 속도 및 NMSE (Normalized Mean Square Error) 관점에서 검증하고 생체 시스템 중에서 가장 복잡하면서 비선형 동역학적 특성을 내재하고 있는 뇌파신호의 예측 모델에 적용한다.

2. 상태 피드백 실시간 회귀 신경회로망

본 논문에서 제안하는 회귀 신경회로망은 비선형 동역학 시스템을 모델링하기 위하여 Williams와 Zipser가 제시한 실시간 회귀 신경회로망[4]을 기간으로 한 상태 피드백 실시간 회귀 신경회로망을 제안한다. 상태 피드백 회귀 신경회로망은 Elman이 제안한 회귀 신경회로망[5]과 유사한 구조를 가지나 수렴속도를 높이기 위하여 그 학습방법을 달리한다. 즉, Elman의 모델의 경우 다층 퍼셉트론을 학습시키기 위해 feed forward형 학습방법을 사용하였는데 이 학습 방법은 정적 모델을 위한 방법으로서 시변성의 동적 모델을 학습하는데는 수렴 속도 등의 측면에서 문제점을 가지고 있다. 이러한 단점을 보완하기 위하여 본 논문에서는 신경회로망의 출력 값이 아닌 은닉 층의 상태를 피드백시킴으로서 수렴속도를 개선할 수 있는 상태 피드백 실시간 회귀 신경회로망을 제안한다. 그 구조는 그림 1과 같으며 다음과 같은 학습방법을 이용한다.

상태 피드백 실시간 회귀 신경회로망은 그림 1과 같이 M 개의 외부 입력, H개의 은닉 층 뉴런, N개의 출력 층 뉴런

* 正會員 : LG電子技術院 責任研究員, 工博

接受日字 : 2001年 11月 7日

最終完了 : 2001年 12月 10日

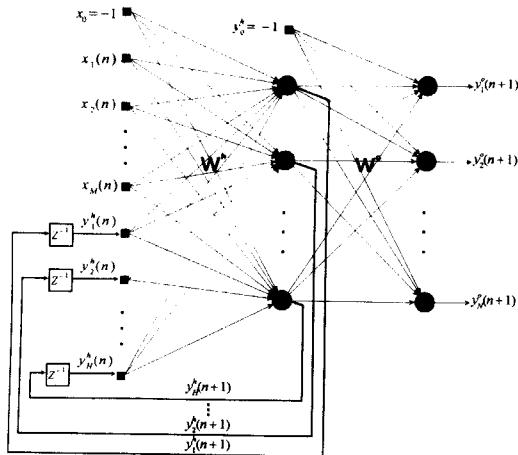


그림 1 상태 피드백 실시간 회귀 신경회로망의 구조
Fig. 1 The architecture of the state feedback real-time recurrent neural network

을 갖는다. $\mathbf{x}(n)$ 은 실시간 회귀 신경회로망에서와 마찬가지로 이산 시간 n 일 때의 외부 입력, $\mathbf{y}^h(n+1)$ 은 1 스텝이 경과한 이산 시간 $n+1$ 일 때의 은닉 층 뉴런의 출력으로 시스템의 내부 상태에 해당하며 입력 층으로 피드백되어 입력 $\mathbf{y}(n)$ 과 합하여져 $(H+N) \times 1$ 벡터 $\mathbf{u}(n)$ 이 된다.

벡터 $\mathbf{u}(n)$ 의 원소들은 식 (1)과 같으며,

$$u_i(n) = \begin{cases} x_i(n) & \text{if } i \in A \\ y_i(n) & \text{if } i \in B \end{cases} \quad (1)$$

$\mathbf{y}^h(n+1)$ 은 동시에 출력 층에 대한 입력으로도 사용된다. 입력 층에서 은닉 층으로의 가중치는 \mathbf{W}^h , 은닉 층에서 출력 층으로의 가중치는 \mathbf{W}^o 라 표시한다. 이때, 은닉 층과 출력 층의 내부 활동 전위와 뉴런의 출력은 각각 식 (2), (3), (4), (5)과 같이 정의된다.

$$v_j^h(n) = \sum_{i \in A \cup B} w_{ji}^h u_i(n) \quad (2)$$

$$y_j^h(n) = \phi(v_j^h(n)) \quad (3)$$

$$v_k^o(n) = \sum_{j=0}^{H-1} w_{kj}^o y_j^h(n) \quad (4)$$

$$y_k^o(n) = \phi(v_k^o(n)) \quad (5)$$

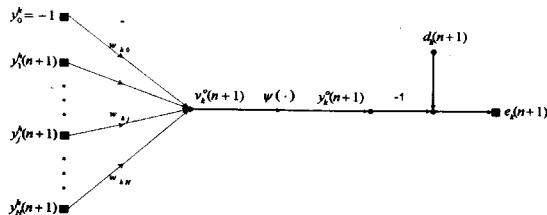


그림 2 은닉층 뉴런에서 출력층 뉴런으로의 신호 흐름도
Fig. 2 Signal flow graph of output neuron connected to hidden neuron

상태 피드백 실시간 회귀 신경회로망의 학습은 그림 2와 같이 출력 층에서부터 시작한다. 출력 층에서 각 노드의 기대 출력을 $d_k(n)$ ($k=1, 2, \dots, N$)이라고 하면 시간 n 에서의 오차 차승의 순서 합은 다음과 같이 정의된다. 즉,

$$\xi(n) = \frac{1}{2} \sum_{k=1}^N \{ e_k^o(n) \}^2 \quad (6)$$

여기서 $e_k^o(n) = d_k(n) - y_k(n)$ 이다.

한편, 은닉 층에서의 출력 층으로의 가중치 \mathbf{W}^o 의 순서 증감은 식 (7)과 같이 구한다.

$$\Delta w_{kj}^o = -\eta \frac{\partial \xi(n)}{\partial w_{kj}^o(n)} \quad (7)$$

여기서 η 는 은닉 층의 학습률을 결정하는 파라미터이며, $\partial \xi(n) / \partial w_{kj}^o(n)$ 은 연쇄 미분 법칙에 의해 식 (8)과 같이 구할 수 있다.

$$\begin{aligned} \partial \xi(n) / \partial w_{kj}^o &= \partial \xi(n) / \partial e_k^o(n) \cdot \partial e_k^o / \partial v_k^o(n) \\ &\quad \cdot \partial v_k^o(n) / \partial w_{kj}^o(n) \cdot \partial v_k^o(n) / \partial w_{kj}^o(n) \\ \partial \xi(n) / \partial e_k^o(n) &= e_k^o(n) \\ \partial e_k^o(n) / \partial y_k^o(n) &= -1 \\ \partial y_k^o(n) / \partial v_k^o(n) &= \phi'(v_k^o(n)) \\ \partial v_k^o(n) / \partial w_{kj}^o(n) &= y_j^h(n) \end{aligned} \quad (8)$$

따라서,

$$\partial \xi(n) / \partial w_{kj}^o(n) = -e_k^o(n) \cdot \phi'(v_k^o(n)) y_j^h(n) \quad (9)$$

이 되며,

$$\begin{aligned} \Delta w_{kj}^o(n) &= -\eta \partial \xi(n) / \partial w_{kj}^o(n) \\ &= \eta e_k^o(n) \cdot \phi'(v_k^o(n)) \cdot y_j^h(n) \end{aligned} \quad (10)$$

가 된다. 한편, 은닉 층 뉴런의 출력 오차는 역전파 방법에서의 오차 역전파와 같은 방법을 사용하면

$$e_i^h(n) = \sum_{k=1}^N e_k^o(n) \cdot \phi'(v_k^o(n)) \cdot w_{ki}^o(n) \quad (11)$$

이 되며, 이는 출력 층의 오차로부터 은닉 층 뉴런의 출력 오차를 계산할 수 있다는 의미가 된다. 은닉 층 뉴런의 출력 오차의 계산이 끝나면 입력 층에서 은닉 층으로의 가중치 \mathbf{W}^h 는 실시간 회귀 신경회로망에서와 같은 방법으로 구할 수 있다. 즉, 식 (12)와 식 (13)과 같다.

$$\begin{aligned} \partial y_i^h(n+1) / \partial w_{ji}^h(n) &= \phi'(v_i^h(n)) \\ &\quad \cdot [\sum_{s=1}^H w_{sj}^h(n) \cdot \partial y_s^h(n) / \partial w_{sj}^h(n) + \delta_{ii} u_i(n)] \\ \partial y_i^h(0) / \partial w_{ji}^h(0) &= 0, \quad i=1, \dots, H+M \end{aligned} \quad (12)$$

$$\Delta w_{ji}^h = \alpha \sum_{s=1}^H e_s^h(n) \cdot \partial y_s^h(n) / \partial w_{sj}^h(n) \quad (13)$$

여기서 α 는 출력 층의 학습률을 결정하는 파라미터이다.

3. 실험 및 결과고찰

3.1 실험 대상 데이터

본 논문에서 제안한 상태 피드백 실시간 회귀 신경회로망의 성능을 평가하기 위하여 그림 2의 Mackey-Glass 시계열 [6]을 사용하였다. 과도 특성을 고려하여 초기 1,000개의 데이터는 제거하고 30,000개의 데이터를 발생시켜 29,000개의 데이터로 학습시키고 나머지 1,000개의 데이터는 테스트 데이터로 사용하여 단 단계 예측 실험을 하였다.

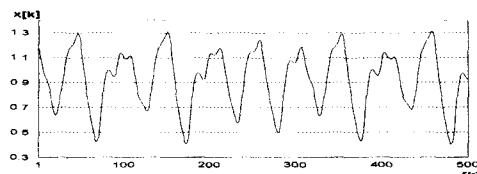
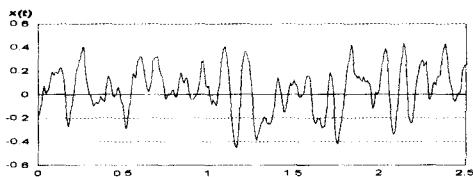


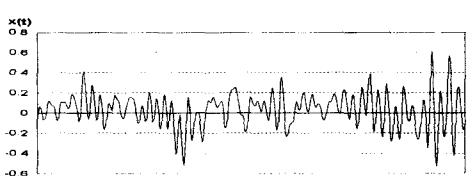
그림 3 Mackey-Glass 시계열

Fig. 3 Mackey-Glass Time Series

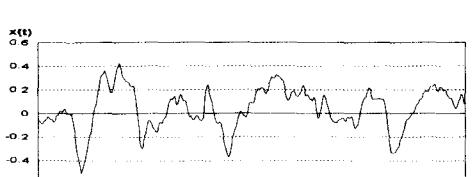
제안한 상태 피드백 실시간 회귀 신경회로망을 생체 비선형 시스템 예측 모델의 학습에 적용하기 위하여 뇌파신호 중에서 그림 3과 같은 α 파형의 뇌파, β 파형의 뇌파 그리고 간질성 뇌파 데이터를 각각 10,000개씩 대상으로 하였고 학습을 위해 9,000개, 테스트를 위해 1,000개를 사용하였다.



(a) Alpha EEG



(B) Beta EEG



(C) Epileptic EEG

그림 4 실험 대상 EEG

Fig. 4 EEG signals used in experiments

3.2 학습 수렴속도 비교

제안한 상태 피드백 실시간 회귀 신경회로망의 성능을 비교 평가하기 위하여 Williams 등이 제안한 실시간 회귀 신경회로망을 표준형으로 하고 이를 변형한 교사 강제형 실시간 회귀 신경회로망을 비교 대상으로 한다. 또한 정적 신경회로망으로 대표되는 Backpropagation 알고리즘도 단단계 예측 성능면에서 비교 대상으로 포함 시켰다.

신경회로망의 학습 수렴속도를 비교하기 위하여 동일한 학습 파라미터 ($\eta = 0.01$)를 선정하였고 실험 결과는 그림 4와 같다. 그림에서 MSE는 100개의 데이터에 대한 평균 값으로 하였고 총 데이터는 24,000개를 사용하였다. 그림에서 곡선 a는 상태 피드백형 실시간 회귀 신경회로망(sfrrtn: state feedback real time recurrent neural network), b는 표준형 실시간 회귀 신경회로망(strrtn: standard real time recurrent neural network), c는 교사 강제형 실시간 회귀 신경회로망(tfrtrn: teacher forced real time recurrent neural network), d는 오차 피드백형 실시간 회귀 신경회로망(efrrtn: error feedback real time recurrent neural network)의 결과를 나타낸다. 그림에서 보는 바와 같이 상태 피드백형 실시간 회귀 신경회로망은 초기의 과도 상태에서의 MSE는 크게 나타나지만 수렴 속도가 빨라 약 250개의 데이터 학습을 한 후에는 다른 신경회로망에 비해 학습 성능이 뛰어남을 알 수 있다. 과도 상태가 지난 후의 수렴 속도는 상태 피드백형이 가장 빠르고, 오차 피드백형, 교사 강제형, 표준형 순으로 수렴 속도가 빠름을 볼 수 있다.

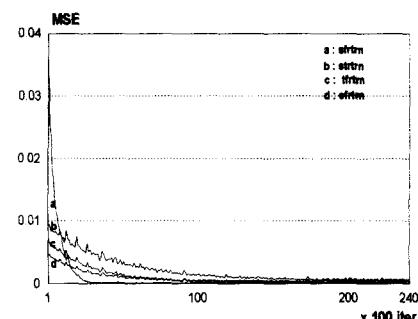


그림 5 Mackey-Glass 시계열에 대한 학습 수렴속도 비교

Fig. 5 Convergence rate comparison for the Mackey-Glass time series

3.3 예측 성능 비교

표 1은 Mackey-Glass 시계열에 대한 학습 및 테스트 과정에서의 각 신경회로망의 단 단계 예측결과를 보인 것이다. 학습 결과는 학습을 마친 시점에서 이전의 1,000개의 데이터에 대한 오차를, 테스트 결과는 학습을 마친 후의 1,000개의 데이터에 대한 오차를 기준으로 각각 MSE와 NMSE를 구하였다. 상태 피드백형 실시간 회귀 신경회로망의 NMSE는 34.90 [dB]로 가장 높게 나왔으며 이는 표준형보다 약 6.7[dB]의 성능 향상을 보인 것이다.

표 1 Mackey-Glass 시계열에 대한 단 단계 예측 성능
Table 1 Performance of single step prediction for Mackey-Glass time series

	Training Error		Running Error	
	MSE	NMSE[dB]	MSE	NMSE[dB]
Standard BP	0.00018750	-29.41	0.00012088	-26.37
Standard RTRN	0.00006427	-34.06	0.00008005	-28.16
T.F. RTRN	0.00004259	-35.84	0.00007522	-28.43
S.F. RTRN	0.00001531	-40.29	0.00001698	-34.90

또한 정적 모델인 BP 보다는 동적인 모델인 회귀 계열의 신경회로망이 비선형 동역학 시스템으로부터 발생한 시계열인 Mackey-Glass 시계열을 예측하는데 있어서 성능이 우수함을 볼 수 있다.

표 2, 3, 4는 각각 α 파형의 뇌파, β 파형의 뇌파 그리고 간질성 뇌파 데이터 대한 학습 및 테스트 과정에서의 각 신경회로망의 단 단계 예측 결과이다.

표 2 α 파 EEG 신호에 대한 단 단계 예측 성능Table 2 Performance of single step prediction for α -wave

	Training Error		Running Error	
	MSE	NMSE[dB]	MSE	NMSE[dB]
Standard BP	0.0005664	-23.15	0.0002954	-22.47
Standard RTRN	0.0002461	-26.77	0.0002854	-22.62
T.F. RTRN	0.0002984	-25.93	0.0002555	-23.10
S.F. RTRN	0.00005354	-30.26	0.00005764	-29.57

표 3 β 파 EEG 신호에 대한 단 단계 예측 성능Table 3 Performance of single step prediction for β -wave

	Training Error		Running Error	
	MSE	NMSE[dB]	MSE	NMSE[dB]
Standard BP	0.0006423	-19.10	0.0002984	-15.93
Standard RTRN	0.0001239	-25.75	0.0001467	-22.06
T.F. RTRN	0.00006108	-28.02	0.0002007	-20.70
S.F. RTRN	0.00002598	-28.66	0.00002945	-28.03

표 4 간질성 EEG 신호에 대한 단 단계 예측 성능

Table 4 Performance of single step prediction for epileptic EEG

	Training Error		Running Error	
	MSE	NMSE[dB]	MSE	NMSE[dB]
Standard BP	0.0004807	-21.83	0.0001420	-23.31
Standard RTRN	0.0004385	-22.30	0.0001295	-23.71
T.F. RTRN	0.0003159	-23.72	0.0001477	-23.14
S.F. RTRN	0.00001601	-34.58	0.00004757	-28.06

학습 결과는 Mackey-Glass 시계열에 대한 실험에서와 같이 학습을 마친 시점에서 이전의 1,000개의 데이터에 대한 오차를, 테스트 결과는 학습을 마친 후의 1,000개의 데이터에 대한 오차를 기준으로 각각 MSE와 NMSE를 구하였다. 표 2, 3, 4에서 보는 바와 같이 상태 피드백형 실시간 회귀 신경회로망의 NMSE는 표준형보다 약 4.89~6.95 [dB] 만큼의 성능 향상을 보였다.

3. 결 론

비선형 동역학적 특성을 갖는 뇌파의 예측 모델을 위하여 Williams 등의 실시간 회귀 신경회로망을 기반으로 상태 피드백 회귀 신경회로망을 제안하였다. 그리고 이 모델을 결정론적 비선형 시스템으로부터 발생하는 시계열인 Mackey-Glass 시계열 학습에 적용하여 비선형 동역학 시스템에 대한 학습 성능을 검증하고 생체 비선형 시스템인 뇌파의 예측에 적용하였다.

제안한 상태 피드백 실시간 회귀 신경회로망의 수렴 속도는 기존의 실시간 회귀 신경회로망 및 교사 강제형 실시간 회귀 신경회로망, 오차 피드백형 실시간 회귀 신경회로망에 비하여 훨씬 빠른 것을 확인 할 수 있었다. 그리고 예측 성능의 면에서도 상태 피드백 실시간 회귀 신경회로망의 NMSE는 기존의 모델과 비교하였을 때, Mackey-Glass 시계열에 대해서는 6.7[dB], 뇌파 신호에 대해서는 4.89~6.95[dB] 낮았다. 따라서 제안한 상태 피드백 실시간 회귀 신경회로망은 비선형 생체 시스템인 뇌파의 예측 모델에 있어서 비교 대상이 되었던 다른 모델보다 우수하다는 결론을 내릴 수 있었다.

참 고 문 헌

- [1] de Wet, A.P.C, Nel, A.L., "Systems of Feedforward ANNs Neural Networks," IEEE Int. Conf. on Computational Intelligence., vol. 4, pp. 2209~2212, 1994
- [2] Sagdinc, I., Kirac, S., Engin, M., Erkan, K., Butun, E., "Dynamic EEG Modeling and Single-Evoked Potential Extraction Using Real-Time Recurrent neural network," Proc. of the 1998 IEEE Int. Conf. on Control Application, Vol.1, pp.358~362, 1998
- [3] Yamamoto, Y., Nikiforuk, P.N., "A Learning Algorithm for Recurrent Neural Networks and Its Application to Nonlinear Identification," Proc. of the IEEE Int. Symp. on Computer Aided Control System Design, pp. 551~556, 1999
- [4] R. J. Williams and D. Zipser, "A Learning Algorithm for Continually Running Fully Recurrent Neural Networks," Neural Computation, Vol. 1, pp.270~280, 1989
- [5] J. L. Elman, "Finding Structure in Time," Cognitive Science, Vol. 14, pp.179~211, 1990
- [6] M. C. Mackey and M. Glass, "Oscillation and Chaos in Physiological Control Systems," Science, Vol. 197, pp.287~289, 1977