

論文2003-40SP-1-17

지역 및 광역 리커런트 신경망을 이용한 비선형 적응예측

(Nonlinear Adaptive Prediction using Locally and Globally Recurrent Neural Networks)

崔瀚卓 *

(Han-Go Choi)

要 约

동적 신경망은 신호예측과 같이 temporal 신호처리가 요구되는 여러 분야에 적용되어 왔다. 본 논문에서는 다층 리커런트 신경망(RNN)의 동특성을 향상시키기 위해 지역 궤환 신경망(LRNN)과 광역 궤환 신경망(GRNN)으로 구성된 합성 신경망을 제안하고, 적응필터로 제안된 신경망을 사용하여 비선형 적응예측을 다루고 있다. 합성 신경망은 LRNN으로 IIR-MLP와 GRNN으로 Elman RNN 신경망으로 구성되어 있다. 제안된 신경망은 비선형 신호예측을 통해 평가되었으며, 예측 성능의 상대적인 비교를 위해 Elman RNN과 IIR-MLP 신경망과 상호 비교하였다. 실험결과에 의하면 합성 신경망은 수렴속도과 정확도에서 더 우수한 성능을 보여줌으로써, 제안된 신경망이 기존의 다층 리커런트 신경망보다 비정적 신호에 대한 비선형 예측에 더 효과적인 예측모델임을 확인하였다.

Abstract

Dynamic neural networks have been applied to diverse fields requiring temporal signal processing such as signal prediction. This paper proposes the hybrid network, composed of locally(LRNN) and globally recurrent neural networks(GRNN), to improve dynamics of multilayered recurrent networks(RNN) and then describes nonlinear adaptive prediction using the proposed network as an adaptive filter. The hybrid network consists of IIR-MLP and Elman RNN as LRNN and GRNN, respectively. The proposed network is evaluated in nonlinear signal prediction and compared with Elman RNN and IIR-MLP networks for the relative comparison of prediction performance. Experimental results show that the hybrid network performs better with respect to convergence speed and accuracy, indicating that the proposed network can be a more effective prediction model than conventional multilayered recurrent networks in nonlinear prediction for nonstationary signals.

Keyword : IIR-MLP, Recurrent neural networks, LGRNN, Nonlinear signal prediction

I. 개 요

신호예측은 음성신호 분석, 시스템 모델링, 데이터 전

송 및 압축, 주변동의 예측 등 여러 분야에서 적용되고 있으며, 이러한 분야에서 다루는 대부분의 신호는 비선형 및 비정적(nonstationary) 특성을 갖고 있으므로 선형예측 방법으로는 만족할 만한 예측을 수행하기가 어렵다. 이를 해결하기 위해 신경망을 이용한 비선형 예측이 수행되고 있는데^[1,2], 신경망은 회로망 내부에 비선형적인 처리능력을 갖춘 유닛으로 구성되어 있고 주위 환경에 적응할 수 있는 학습능력을 갖고 있으므로

* 正會員, 金烏工科大學校 電子工學部

(School of Electronic Engineering Kumoh National Institute of Technology)

接受日字: 2002年7月31日, 수정완료일: 2002年11月11日

비정적 신호에 대한 비선형 적응예측에 적합한 모델이라 할 수 있다. 그러나 만족스런 비정적 시변(time-varying) 신호를 예측하기 위해서는 동특성이 우수한 신경망이 요구되는데 최근에 사용되고 있는 동적 신경망은 비정적 신호 예측뿐만 아니라 시스템 식별, 플랜트 제어, 패턴인식, 비선형 필터링과 같이 temporal 신호처리가 요구되는 여러 분야에 많이 사용되고 있다^[3~7].

이러한 동적 신경망은 기존의 정적(static) 신경망에 동특성을 추가하기 위해 신경망 내부에 버퍼(buffer)를 두어 과거 입력에 대한 메모리로 사용하거나 궤환(feedback)을 사용함으로써 신경망에 temporal 동특성을 갖도록 하였다. 지금까지 제안되어 가장 일반적으로 사용되고 있는 동특성 다층 신경망 구조는 크게 두 부류로 대별할 수 있다. 첫 번째 구조로는 신경망 내에 버퍼를 사용하는 구조로 신경망 입력에 TDL(tapped delay line) 구조를 사용한 buffered 다층 퍼셉트론(multilayer perceptron, MLP)^[8]과 각 뉴런 입력이 FIR(finite impulse response) 필터 시냅스(synapse)를 갖는 FIR-MLP^[9,10](혹은 time delay neural networks)가 있는데, FIR-MLP 입력의 내부버퍼가 신경망의 외부버퍼로 구현될 수 있기 때문에 buffered MLP와 FIR-MLP는 이론적으로 동일하다고 할 수 있다.

두 번째로는 궤환구조의 신경망인데 지역궤환 신경망(locally or internally recurrent neural networks, LRNN)과 광역궤환 신경망(globally or externally RNN, GRNN)이 있다. 광역궤환 신경망은 한 층의 뉴런 출력들이 다른 층의 모든 뉴런 입력들과 연결된 구조, 즉, fully connected 리커런트 신경망(RNN)^[3,11]으로서 가장 대표적인 신경망으로 Elman^[12]과 Jordan^[13] 신경망이 있다. 지역궤환 신경망은 최근에 제안된 구조로 이산시간 내부 메모리를 갖는 시냅스를 사용하고 있다. 즉, 기존의 시냅스를 FIR 필터나 IIR(infinite impulse response) 필터로 대치한 구조로서 이러한 FIR-MLP 혹은 IIR-MLP는 기존의 선형 FIR 혹은 IIR 필터의 비선형 확장으로 생각할 수 있으며, fully connected RNN 보다 덜 복잡한 구조이다^[14]. 특히, IIR-MLP 구조는 Back-Tosi^[15]에 의해 제안되었는데 기존의 정적 신경망 시냅스를 ARMA (Autoregressive moving average) 모델의 IIR 적응필터로 대치한 것으로 이러한 구조의 동특성 다층 신경망은 기존의 정적 다층 신경망이나 GRNN의 MLP나 FIR-MLP에 비해 시스템 식별과 같이 비선형 혹은 비정적 신호처리에서 더 우수한 성능

을 보여주고 있다.

본 논문에서는 LRNN의 특성을 유지하면서 신경망의 동특성을 더욱 더 향상시키기 위해 LRNN과 GRNN이 합성된 구조의 신경망(locally and globally RNN, LGRNN)을 제안하고 있으며, 제안된 신경망을 이용한 비선형 예측이 기존의 다층 동특성 신경망보다 더 우수한 예측을 수행할 수 있음을 확인하고자 한다. 합성신경망인 LGRNN의 구조는 LRNN의 대표적인 신경망인 IIR-MLP 구조^[15]와 GRNN으로 많이 사용하고 있는 Elman RNN 구조로 구성되어 있으며, 학습방법으로는 제안된 구조와 IIR-MLP에 대해서는 Campolucci가 사용한 on-line RBP(recursive backpropagation) 알고리즘^[14], GRNN에 대해서는 기존의 오차 역전파(error backpropagation) 학습 알고리즘을 사용하였다.

제안된 신경망의 특성은 Mackey-Glass 시계열(time series)과 음성신호 예측을 통해서 조사하였으며, 상대적인 성능평가를 위해 GRNN으로 기존의 Elman RNN과 LRNN으로 IIR-MLP와의 예측결과를 상호 비교함으로써 제안된 신경망의 우수성을 확인하였다. 지금부터 본 논문에서는 GRNN은 Elman 신경망을, 그리고 LRNN은 IIR-MLP를 각각 의미한다. 실험결과를 살펴보면 제안된 LGRNN에 의한 신호예측은 LRNN과 GRNN보다 수렴특성과 시스템 안정성, 즉, 시스템 오차 면에서 더 우수한 성능을 보여주었다.

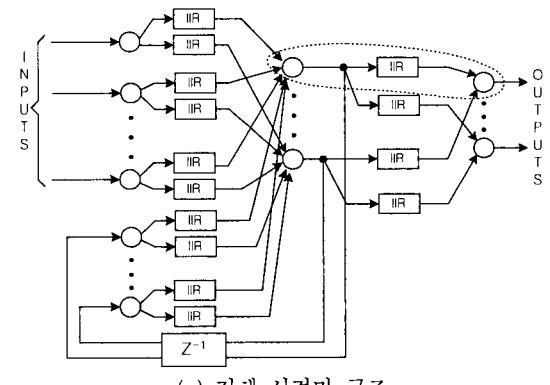
II. Locally and Globally RNN

1. 신경망 구조

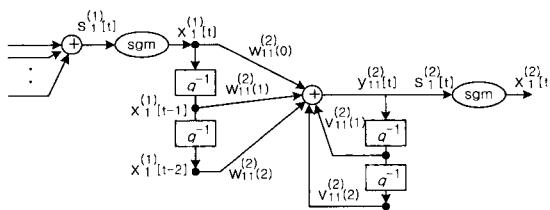
제안된 LGRNN은 Elman의 RNN과 Tsoi의 IIR-MLP가 합성된 다층 신경망이다. <그림 1>은 LGRNN의 구조를 보여주고 있는데 <그림 1(a)>에서와 같이 LGRNN의 입력층은 외부 입력과 하든 층의 모든 뉴런으로부터의 궤환입력으로 구성되어 있으며, 입력층과 하든층의 모든 뉴런 출력이 IIR 시냅스를 통과하여 하든층과 출력층의 뉴런으로 연결되어 있다.

<그림 1(b)>는 <그림 1(a)>의 점선 부분, 즉, 층간의 연결계수로 사용하고 있는 시냅스 구조를 확대한 것으로서 LGRNN의 입력층과 하든층, 그리고 하든층과 출력층간에 연결된 모든 시냅스의 내부 연결계수들을 자세히 도시한 것이다. 시냅스는 AR(autoregressive)과 MA(moving average) 구조를 갖는 IIR 적응필터를 사

용하고 있으며 <그림 1(b)>에서는 MA 차수가 3, AR 차수가 2인 경우이다. <그림 1(a)>에서 하든층으로부터 입력층으로의 케환이 없는 구조가 IIR-MLP 신경망이며, IIR 시냅스 대신 한 개의 연결계수로만 이루어진 구조가 Elman RNN 신경망이다. 이와 같이 층간의 케환과 시냅스 내부에서의 케환구조는 케환이 없는 다층 신경망 구조보다 동특성을 더욱 향상시킬 수 있다.



(a) 전체 신경망 구조
(a) Structure of neural networks



(b) 확대된 IIR 시냅스 구조
(b) Structure of enlarged IIR synapse

그림 1. LGRNN 신경망 구조
Fig. 1. Structure of LGRNN networks.

입력층의 뉴런은 입력신호의 처리없이 단순히 다음 층으로 신호전달 역할만 수행하며, 하든층 뉴런의 내부 전달함수는 양극 시그모이드(bipolar sigmoid)함수를 사용하였고, 출력층에서는 이득이 1인 선형 전달함수를 사용하였다. 하든층의 j 번째 뉴런 출력 $x_j(t)$ 과 출력층의 k 번째 뉴런 출력 $x_k(t)$ 는 각각 다음과 같다.

$$x_j(t) = \text{sgm}\{s_j(t)\} = \frac{1 - e^{-\alpha \cdot s_j(t)}}{1 + e^{-\alpha \cdot s_j(t)}} \quad (1)$$

$$x_k(t) = s_k(t) \quad (2)$$

여기서 α 는 양극 시그모이드 함수의 기울기이며, $s_j(t)$ 와 $s_k(t)$ 는 하든층의 j 번째와 출력층의 k 번째 뉴런의 입력을 나타낸다. 상대비교를 위한 Elman RNN에서도

같은 활성함수를 사용하였다.

2. 신경망 학습

LGRNN의 IIR 시냅스 학습 알고리즘은 LRNN의 학습과 동일하다. LRNN에서의 학습은 recursive back-propagation(RBP) 알고리즘을 제안하고 있는데, on-line 구현이 가능하도록 알고리즘을 수정한 causal RBP에 학습속도를 향상시키기 위해 이를 근사화한 instantaneous recursive backpropagation(IRBP)를 사용하고 있다^[14]. 제안된 LGRNN 신경망의 학습방법으로 IRBP 알고리즘을 적용하여 on-line 학습이 수행되도록 하였다. IRBP 학습 알고리즘을 요약하면 다음과 같다.

$$\Delta w_{nm(p)}^{(l)}[t+1] = -\frac{\eta}{2} \frac{\partial E}{\partial s_n^{(l)}[t]} \frac{\partial s_n^{(l)}[t]}{\partial w_{nm(p)}^{(l)}} = \eta \delta_n^{(l)}[t] \frac{\partial s_n^{(l)}[t]}{\partial w_{nm(p)}^{(l)}} \quad (3)$$

$$\Delta v_{nm(p)}^{(l)}[t+1] = -\frac{\eta}{2} \frac{\partial E}{\partial v_{nm(p)}^{(l)}[t]} \frac{\partial v_{nm(p)}^{(l)}[t]}{\partial s_n^{(l)}[t]} = \eta \delta_n^{(l)}[t] \frac{\partial s_n^{(l)}[t]}{\partial v_{nm(p)}^{(l)}} \quad (4)$$

여기서, $\Delta w_{nm(p)}^{(l)}[t+1]$ 와 $\Delta v_{nm(p)}^{(l)}[t+1]$ 는 시냅스 내부의 MA와 AR의 연결계수 증가량을, η 는 학습율을, E 는 학습샘플에 대한 자승에러를, $s_n^{(l)}[t]$ 는 l 층의 n 번째 뉴런에서 전달함수 이전의 내부 시냅스의 합을 나타낸다. 그리고,

$$\frac{\partial s_n^{(l)}[t]}{\partial w_{nm(p)}^{(l)}} = x_m^{(l-1)}[t-p] + \sum_{r=1}^{l-1} w_{nm(r)}^{(l)} \frac{\partial s_n^{(l)}[t-r]}{\partial w_{nm(p)}^{(l)}} \quad (5)$$

$$\frac{\partial s_n^{(l)}[t]}{\partial v_{nm(p)}^{(l)}} = y_{nm}^{(l-1)}[t-p] + \sum_{r=1}^{l-1} v_{nm(r)}^{(l)} \frac{\partial s_n^{(l)}[t-r]}{\partial v_{nm(p)}^{(l)}} \quad (6)$$

여기서 $x_m^{(l-1)}[t-p]$ 는 시간 $(t-p)$ 에서 l 층의 n 번째 뉴런 출력이며, 특별히 $n=0$ 는 바이어스 입력을 나타낸다. $y_{nm}^{(l-1)}[t-p]$ 는 시간 $(t-p)$ 에서 l 층의 n 번째 뉴런의 m 번째 입력과 관련된 시냅스 필터의 출력을 의미한다. $w_{nm(r)}^{(l)}$ 과 $v_{nm(r)}^{(l)}$ 는 내부 시냅스의 MA 부분과 AR 부분의 연결계수를 각각 나타낸다. 그리고

$$\delta_n^{(l)}[t] = e_n^{(l)}[t] \cdot \text{sgm}'(s_n^{(l)}[t]) \quad (7)$$

이며, $e_n^{(l)}[t]$ 는 다음과 같다.

$$e_n^{(l)}[t] = \begin{cases} e_n[t], & \text{for } l=M \\ \sum_{q=1}^{N_{l+1}} \delta_q^{(l+1)}[t] w_{qn(0)}^{(l+1)}, & \text{for } 1 \leq l < M \end{cases} \quad (8)$$

$e_n(t)$ 는 원하는 출력과 실제 출력과의 차이를 나타내며, $sgm'(s_n^{(l)}[t])$ 은 뉴런 내부의 시냅스 합에 대한 시그모이드 함수의 미분치를 나타내며, M 은 신경망의 층의 개수이며, l 은 인덱스로 $l=0$ 과 $l=M$ 은 각각 입력층과 출력층을 의미한다.

RNN의 학습 방법으로는 오차 역전파 알고리즘을 사용하였으며, 학습속도를 향상시키기 위해서 모멘텀항을 추가하였다.

$$\Delta w[t+1] = -\eta \frac{\partial E}{\partial w[t]} + \alpha \Delta w[t] = \eta \delta[t] y(t) + \alpha \Delta w[t] \quad (9)$$

여기서 η 는 학습율을, α 는 모멘텀율을 의미하며 α 를 포함하는 항이 모멘텀항이다. $\delta(t)$ 는 뉴런 내부상태를 나타내는데, 출력층의 $\delta_k(t)$ 와 히든층의 $\delta_j(t)$ 는 각각 다음과 같다.

$$\delta_k[t] = \frac{\partial E}{\partial h_k[t]} = -e_k[t] f(h_k[t]) \quad (10)$$

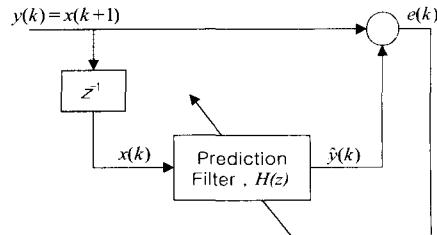
$$\delta_j[t] = \frac{\partial E}{\partial h_j[t]} = f(h_j[t]) \sum_k \delta_k[t] w_{kj}[t] \quad (11)$$

여기서 $e_k[t]$ 는 실제 출력과 원하는 출력과의 차이이며 $f(\cdot)$ 는 뉴런 활성함수의 미분치이고 $h_j[t]$ 와 $h_k[t]$ 는 히든층 뉴런과 출력층 뉴런의 내부 상태를 나타낸다.

III. 실험 결과

제안된 LGRNN의 성능을 조사하기 위해 비선형 및 비정적 신호에 대한 신호 예측을 수행하였으며, 상대적인 성능평가를 위해 광역체환 구조인 GRNN과 지역체환 구조인 LRNN의 예측결과와 상호 비교하였다.

신호예측이란 과거 신호들을 이용해서 미래 신호를 추정하는 것으로서, 단 단계 예측(single-step prediction)과 다 단계 예측(multi-step prediction)으로 분류할 수 있다. 단 단계 예측은 주어진 과거의 입력 신호들로부터 한 단계 미래의 신호를 예측하는 것이며, 다 단계 예측은 과거의 입력신호들로부터 미래 신호를 예측하고 예측된 신호 값을 입력으로 체환시켜 구성된 새로운 입력신호로부터 다음 시간의 신호를 예측하는 것이다. 이와 같이 예측된 값들로 이루어진 입력을 이용하여 원하는 단계까지의 예측을 수행하는 것이다. <그림 2>는 단 단계 예측과 다 단계 예측을 수행하기 위한 예측구조를 나타내며, <그림 3>은 예측필터에 사용된 신경망에 대한 구조를 보여주고 있다.



(a) 단 단계 예측



(b) 다 단계 예측

(b) Multi-step prediction

그림 2. 단 단계 예측과 다 단계 예측구조
Fig. 2. Prediction structure of single-step and multi-step.

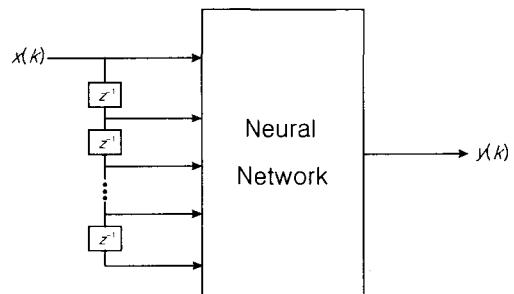


그림 3. 예측필터의 신경망 구조
Fig. 3. Network structure of prediction filter.

제안한 신경망의 예측능력을 조사하기 위하여 카오스 성질을 갖고 있는 Mackey-Glass 시계열과 비정적 성질을 갖는 음성신호에 대하여 실험하였으며, 예측 필터로 사용된 GRNN, LRNN, 그리고 LGRNN 신경망에 대해 단 단계 예측과 다 단계 예측결과를 비교함으로써 제안된 신경망의 예측성능을 평가하였다.

1. 단 단계 예측

(1) Mackey-Glass 시계열 예측

예측성능 평가를 위해 일반적으로 사용되고 있는 Mackey-Glass 시계열은 식 (12)와 같은 방정식을 이용해서 생성된다^[16].

$$\frac{ds(k)}{dt} = -bs(k) + \frac{\rho s(k-\tau)}{1+s^{10}(k-\tau)} \quad (12)$$

여기서 $\tau=21$, $\rho=0.2$, $b=0.1$, 그리고 초기조건으로 $s(k-\tau)=1.2$, $0 \leq k \leq \tau$ 를 사용하였다. Mackey-Glass 시계열은 정적신호로서 비선형 특성을 갖도록 미약한 크기의 정현파 신호 $-0.1 \sin(20\pi k/1000)$ 를 추가하여 1000개의 샘플을 갖는 신호를 발생시켰다. <그림 4>는 Mackey-Glass 시계열에 정현파 신호를 추가한 합성신호를 나타낸다.

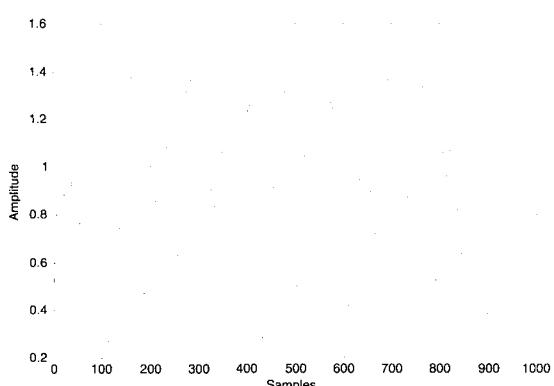


그림 4. 정현파가 추가된 Mackey-Glass 시계열
Fig. 4. Mackey-Glass time series added with sinusoidal waves.

Mackey-Glass 시계열 예측에 사용된 신경망의 구조는 GRNN의 경우 신경망 입력층 유닛은 4개, 히든층과 출력층의 유닛개수는 각각 5개와 1개로 ($4 \times 5 \times 1$)로 구성하였다. 그리고 입력층에 바이어스 항이 추가되었으며 바이어스항의 계수도 생신하였다. LRNN의 경우 ($4 \times 5 \times 1$) 개의 뉴런으로 구성되어 있고, 시냅스 내부 계수는 $MA=1$, $AR=1$ 이다. LGRNN 신경망의 경우에는 ($4 \times 3 \times 1$) 개의 뉴런으로 구성되어 있고, 시냅스 내부 계수는 LRNN의 경우와 같다. LRNN과 LGRNN에서 시냅스에 +1의 상수 바이어스가 사용되었으며, 바이어스 항의 계수는 생신하지 않았다. 예측 신경망의 입력으로는 현재 입력과 3개의 과거입력을 사용하였다. 예측모델들에 대한 시스템 계수들의 수는 GRNN이 55개, LRNN이 50개, 그리고 LGRNN이 48개로 구성함으로써 예측모델간에 계수 수를 비슷하게 설정하였으며, 시스템의 구조와 변수 값들은 최적의 예측이 되도록 실험을 통하여 결정하였다.

1000샘플의 시험 신호 중 전반부 400샘플은 학습신호로 사용하였으며, 1000번 학습 후 후반부 600샘플 신호에 대하여 단 단계 예측을 수행하였다. <그림 5>는 각각의 신경망에 대한 학습오차의 변화 곡선을 보여주고 있으며, LGRNN이 가장 적은 오차를 보여주고 있다. 실험결과에 의하면 학습 및 시험구간에 대해 GRNN, LRNN, 그리고 LGRNN 모두 만족스런 예측결과를 보여주었는데, <그림 6>은 시험구간에 대해 LGRNN의 예측결과이며, <그림 7>은 시간영역에서 예측모델간의 오차 $|y(k) - \hat{y}(k)|^2$ 를 상호 비교하고 있다.

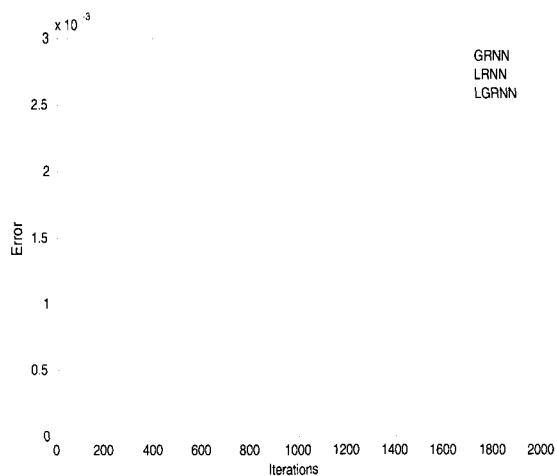


그림 5. 신경망 모델간의 Mackey-Glass 시계열의 학습오차 비교
Fig. 5. Comparison of learning error for Mackey-Glass time series among network models.

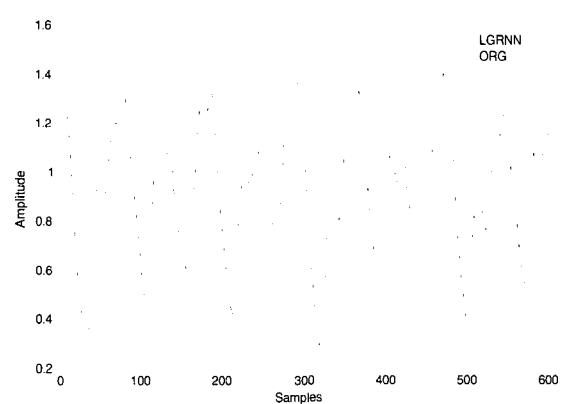


그림 6. Mackey-Glass 시계열에 대한 LGRNN 모델의 예측결과
Fig. 6. Prediction result of LGRNN model for Mackey-Glass time series.

<그림 6>에서 ORG로 표시된 점선(dotted-line)은 정현파가 추가된 Mackey-Glass 시계열 신호이며, 연속선(solid-line)은 LGRNN에 의한 예측결과이다. <그림 7>에서 확인할 수 있듯이 실험결과에 의하면 LGRNN 신경망에 의한 비선형 예측은 LRNN 신경망에 의한 비선형 예측보다 우수하며, LRNN은 GRNN에 비해 예측성능이 우수하였다. 특히, 신호가 급격히 변하는 최대, 최소 주위에서는 신호의 동특성이 강한 부분으로서 LGRNN의 예측결과가 더 우수하였다.

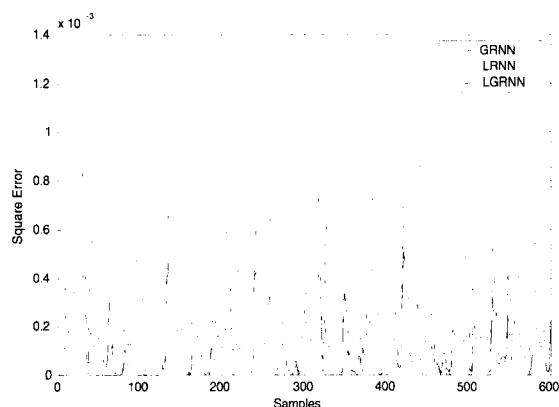


그림 7. Mackey-Glass 시계열에 대해 예측모델간의 예측오차 비교

Fig. 7. Comparison of prediction error among prediction models for Mackey-Glass time series.

예측오차를 정량적으로 조사하기 위해 식 (13)과 같이 정의된 평균자승오차(Mean squared error, MSE)를 사용하여 비교하였다.

$$MSE = \frac{1}{(N_1 + N_2 - 1)} \sum_{k=N_1}^{N_2} [y(k) - \hat{y}(k)]^2 \quad (13)$$

여기서 N_1 과 N_2 는 오차 계산구간을 나타내는 샘플이며, $y(k)$ 는 원 신호이고, $\hat{y}(k)$ 는 예측신호이다. <표

표 1. Mackey-Glass 시계열 예측에 대한 평균자승오차

Table 1. MSE in Mackey-Glass time series prediction.

	GRNN	LRNN	LGRNN
Mackey-Glass	3.919×10^{-4}	2.464×10^{-4}	1.080×10^{-4}
음성신호	1.621×10^{-4}	1.006×10^{-4}	0.421×10^{-4}

1>은 식 (13)을 사용하여 시험신호에 대한 MSE로서 제안된 LGRNN 신경망은 GRNN 신경망보다 72.4%, LRNN 신경망보다 56.2% 정도 적은 오차를, LRNN 신경망은 GRNN 신경망보다 보다 37.1% 적은 오차가 발생되었다.

(2) 음성신호 예측

사용된 음성신호는 한국 남성의 음성으로서 11[KHz]의 샘플링 주파수로 1000개의 신호를 생성하였으며, 고주파 성분의 잡음을 제거하기 위해서 차단주파수가 2.2[KHz]인 저역통과 필터를 통과시켜 사용하였다^[16]. <그림 8>은 실험에 사용된 음성신호를 보여주고 있다. 신경망 구조는 Mackey-Glass 시계열 예측을 위해 사용된 구조와 동일하며, 신경망에 사용된 변수 값들은 최적의 예측이 되도록 실험을 통해서 결정하였다.

음성신호 예측에 있어서 1000샘플 시험 신호 중 앞부분 400샘플 신호를 단 단계 예측을 위한 학습신호로 1000번 학습하였으며, 학습 후 나머지 600샘플 신호에 대하여 비선형 예측을 수행하였다. 음성신호에 대한 학습에서도 Mackey-Glass 시계열의 경우와 마찬가지로 LGRNN이 수렴속도와 안정성에서 다른 신경망보다 우수하였다. 실험결과에 의하면 학습 및 시험 구간에 대해 모든 신경망 모델이 만족스런 예측결과를 보여주었는데, <그림 9>는 음성신호의 시험구간에 대한 LGRNN의 예측결과이며, <그림 10>은 시간영역에서 각 신경망 예측모델간의 오차 $|y(k) - \hat{y}(k)|^2$ 을 보여주고 있다. 그림에서 살펴보면 비정적인 성질을 갖는 음성신호의 경우에 대해서도 Mackey-Glass 시계열의 결과와 같이 제안된 LGRNN 신경망에 의한 예측결과가 다른 신경망 예측모델보다 더 우수함을 확인할 수 있다. 또

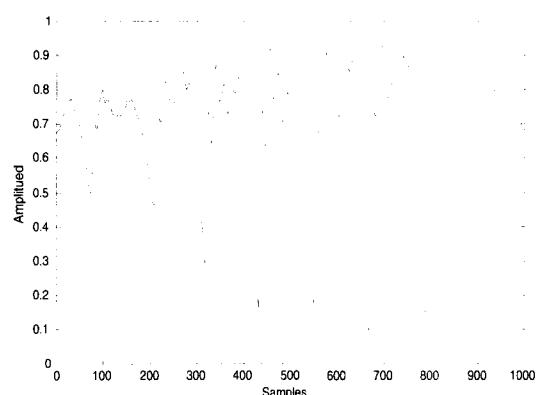


그림 8. 예측에 사용된 음성신호

Fig. 8. Speech signal used in prediction.

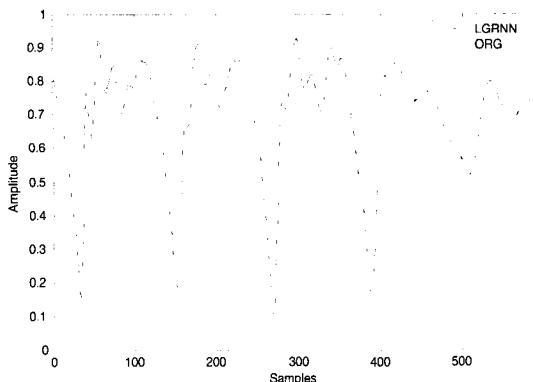


그림 9. 음성신호에 대한 LGRNN 예측모델의 예측결과
Fig. 9. Predictiton result of LGRNN model for speech signal.

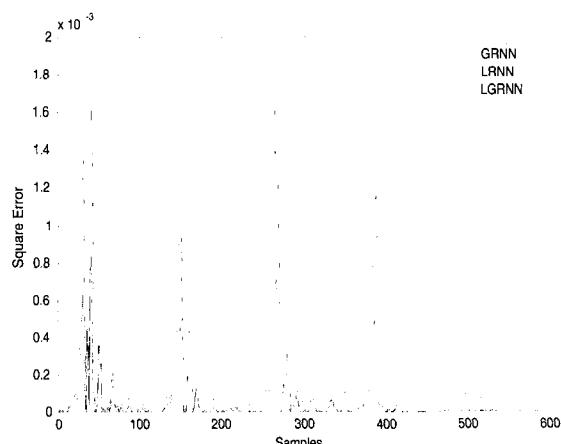


그림 10. 음성신호에 대해 예측모델간의 예측오차 비교
Fig. 10. Comparison of prediction error among prediction models for speech signal.

한, 신호가 급변하는 부분에서도 제안된 신경망 구조가 다른 예측 신경망 모델들보다 우수하였다.

정량적 비교를 위해식 (13)을 사용하여 계산된 결과가 <표 1>에 나타나 있는데, 제안된 LGRNN 신경망에 의한 예측결과는 GRNN 모델에 의한 예측결과보다 74.0% 정도, LRNN 신경망보다 58.2% 정도 적은 오차를, LRNN 신경망은 GRNN 신경망보다 37.9% 적은 오차를 보여주고 있다.

2. 다 단계 예측

더 정확한 예측능력을 조사하기 위해서 일반적으로 다 단계 예측결과를 이용하여 평가하고 있다. 다 단계 예측은 입력신호로 원 신호를 사용하지 않고 예측된

출력신호를 입력신호로 다시 사용하는 방법이다. 따라서 예측된 신호가 입력으로 재활용되어 다시 사용된다는 사실을 제외하고는 실험내용 및 방법, 그리고 신경망의 구조와 변수 값들은 단 단계 예측실험에서와 동일하게 사용하였다.

<그림 11>은 Mackey-Glass 시계열과 음성신호에 대해 제안된 LGRNN 신경망과 다른 예측 신경망 모델들에 의한 다 단계 예측결과를 보여주고 있다. 다 단계 예측결과는 시험구간에서 임의로 선정한 5군데에서 다 단계 예측을 수행하여 평균한 결과로서 각 단계에서의 오차는 $20 \log_{10} |y(k) - \hat{y}(k)|$ 로 계산하였다. 제안된 LGRNN 신경망과 다른 신경망 예측모델들 모두 시간

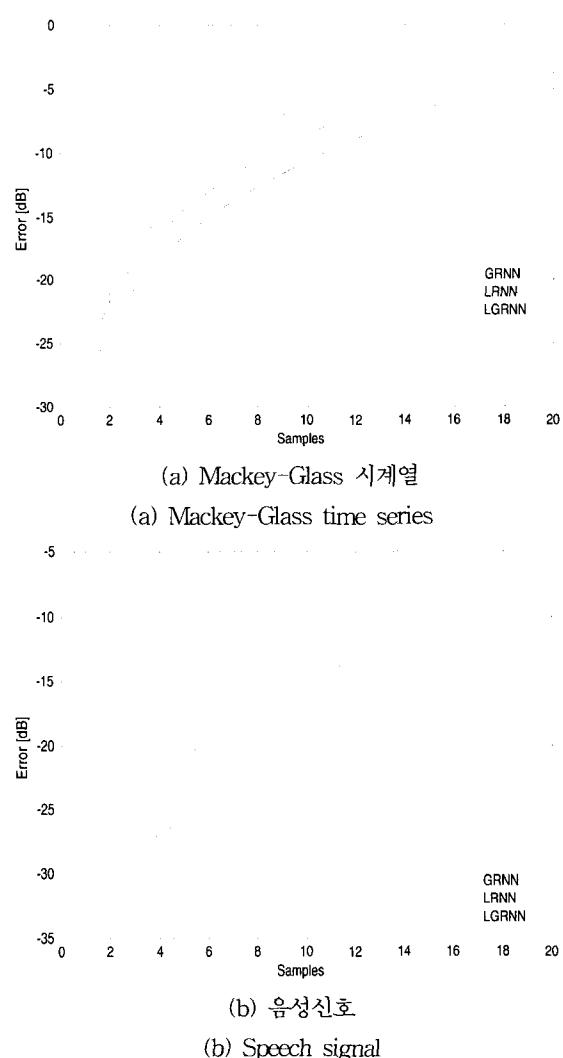


그림 11. 예측모델들의 다 단계 예측결과
Fig. 11. Results of multi-step prediction for models.

이 지남에 따라서 예측결과의 오차가 커지는 현상을 보이고 있는데 이는 예상된 결과이다. 그러나 다른 예측모델들에 의한 예측결과가 제안된 신경망의 예측결과보다 다 단계 예측오차가 훨씬 크며, 단계가 진행됨에 따라서 신경망 모델간의 오차크기는 계속 증가하고 있음을 알 수 있다.

3. 실험결과 요약

위에서 실험한 예측결과를 요약하면 두 시험신호에 대한 단 단계 예측에서는 지역궤환 신경망이 광역궤환 신경망보다 예측성능이 우수함을 보여주었다. 구체적으로 LRNN은 GRNN보다 성능이 우수하며 제안된 LGRNN은 LRNN보다 예측성능이 더 우수하였다. 다 단계 예측에서도 두 시험신호 모두에 대해 제안된 신경망이 다른 신경망보다 더 우수한 예측성능을 보여주었다.

다른 연구에서 GRNN이 TDL 구조에서 LMS(least mean square) 알고리즘을 사용한 선형 예측보다 성능이 우수함을 보여주었으므로^[17], 본 논문의 결과와 종합하면 제안된 LGRNN 신경망이 기존의 선형 TDL 예측 모델, GRNN, 그리고 LRNN 신경망들보다 비정적 신호에 대한 비선형 예측이 더 우수하다고 할 수 있다.

IV. 결 론

본 논문에서는 비선형 적응필터로 동적 다층 신경망을 이용한 신호예측을 다루고 있다. 특히, 다층 신경망의 동특성을 더욱 향상시키기 위하여 기존의 지역궤환 신경망과 광역궤환 신경망의 합성구조인 hybrid 신경망을 제안하고, 이 신경망을 사용하여 비선형 및 비정적 신호 예측을 수행하였다. 제안된 신경망은 지역궤환 신경망으로 IIR-MLP와 광역궤환 신경망으로 Elman RNN 신경망 구조로 이루어져 있으며, 학습 알고리즘으로는 IIR-MLP의 시냅스 계수 개수 개수로 사용되었던 Campolucci의 on-line instantaneous recursive back-propagation 알고리즘을 사용하였다.

제안된 합성 신경망에 의한 비선형 예측 성능의 상대적인 평가를 위해 비슷한 개수의 연결계수를 사용한 다른 다층 궤환 신경망의 예측결과를 살펴보면 제안된 신경망은 학습의 수렴속도와 시스템 정확도(안정성)에서 기존의 다층 신경망보다 더 우수한 예측성능을 보여주었다. 따라서 제안된 신경망은 비정적 신호에 대한

비선형 적응예측에 효과적인 예측모델로 사용할 수 있음을 확인하였다. 제안된 신경망은 시스템 구조가 다소 복잡한 단점은 있지만 시스템 동특성이 기존의 다층 궤환 신경망에 비해 더 향상된 신경망이므로 더 높은 차수의 비선형 및 비정적 시변 신호처리뿐만 아니라 temporal 동특성이 요구되는 다른 응용분야에서도 사용할 수 있는 다층 신경망 모델이라 할 수 있다.

참 고 문 헌

- [1] P. M. Ferreira, E. A. Faria, and A. E. Ruano, Yazdizadeh and K. Khorasani, "Neural network models in greenhouse air temperature prediction", *Neurocomputing*, Vol. 43, No. 1/4, pp. 51~75, 2002.
- [2] J. Park and D. W. Edington, Yazdizadeh and K. Khorasani, "A sequential neural network model for diabetes prediction", *Artificial intelligence in medicine*, Vol. 23, No. 3, pp. 277~293, 2001.
- [3] A. Yazdizadeh and K. Khorasani, "Adaptive time delay neural network structures for nonlinear system identification", *Neurocomputing*, Vol. 47, No. 1/4, pp. 207~240, 2002.
- [4] L. Wang and K. Chen, "Capture interspeaker information with a neural network for speaker identification", *IEEE transactions on neural networks*, Vol. 13, No. 2, pp. 436~445, 2002.
- [5] S. A. Vorobyov and A. Cichocki, "Hyper radial basis function neural networks for interference cancellation with nonlinear processing of reference signal", *Digital signal processing*, Vol. 11, pp. 204~221, 2001.
- [6] H. G. Choi and E. B. Shim, "Enhancement of QRS complex using a neural network based ALE", *22nd Int. Conf. of the IEEE EMB, World Congress on Medical Physics and Biomed. Eng.*, Vol. 27, No. 6, Chicago, U.S.A., Jul. 2000.
- [7] D. Bhattacharya and A. Antoniou, "Design of equiripple FIR filters using a feedback neural network", *IEEE Transactions on circuits and*

- systems II: analog and digital signal processing*, Vol. 45, issue 4, April 1998, pp. 527~531, April 1998, pp. 527~531.
- [8] S. Haykin, *Neural Networks: A Comprehensive Foundation*, IEEE Press, New York, 1994.
- [9] A. D. Back and A. C. Tsoi, "FIR and IIR synapses, a new neural network architecture for time series modeling", *Neural Comput.*, Vol. 3, pp. 375~385, 1991.
- [10] E. A. Wan, "Temporal backpropagation for FIR neural networks", in *Proc. Int. Joint Conf. Neural Networks*, Vol. 1, pp. 575~580, 1990.
- [11] R. J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks", *Neural Comput.*, Vol. 1, pp. 270~280, 1989.
- [12] J. L. Elman, "Finding structure in time", *Cognitive Science*, Vol. 14, pp. 179~211, 1990.
- [13] M. Jordan, "Serial order: A parallel distributed processing approach", Univ. California San Diego, Inst. Cognitive Science, ICS Rep. 8604, 1986.
- [14] P. Campolucci, A. Uncini, F. Piazza, and B. D. Rao, "On-line learning algorithm for locally recurrent neural networks", *IEEE Trans. Neural Networks*, Vol. 10, pp. 253~271, 1999.
- [15] A. C. Tsoi and A. D. Back, "Locally recurrent globally feedforward neural networks: A critical review of architectures", *IEEE Trans. Neural Networks*, Vol. 5, pp. 229~239, 1994.
- [16] H. G. Choi, H. S. Lee, and S. H. Kim, "Adaptive prediction of nonstationary signals using chaotic neural networks", *IEEE IJCNN'98*, Alaska, U.S.A., pp. 1943~1947, May 1998.
- [17] H. G. Choi, H. S. Lee, and S. H. Kim, "Nonlinear prediction of nonstationary signals using neural networks", *J. of IEEK, IEEK*, Vol. 35, No. 10, pp. 166~174, Nov. 1998.

저자소개



崔瀚 博(正會員)

1979년 경북대학교 전자공학과 졸업
(학사). 1988년 Univ. of Florida 전
기공학과 졸업(석사). 1992년 Univ.
of Florida 전기공학과 졸업(박사).
1979년~1986년 국방과학연구소 근
무. 1993년~현재, 금오공과대학교
전자공학부 부교수. <주관심분야 : 실시간 신호처리 및
적응신호처리, 신경회로망, 패턴인식, 의용전자>