

論文98-35S-10-17

신경망을 이용한 비정적 신호의 비선형 예측

(Nonlinear Prediction of Nonstationary Signals using Neural Networks)

崔瀚卓*, 李皓燮*, 金相熙*

(Han Go Choi, Ho Sub Lee, and Sang Hee Kim)

요 약

신경망은 분산된 비선형 처리구조와 학습능력 때문에 높은 차수의 비선형 동특성 구현능력을 갖고 있으므로 비정적 신호에 대한 적응예측을 수행할 수 있다. 본 논문에서는 두 가지 방법(비선형 모듈구조와 비선형과 선형모듈이 직렬로 연결된 예측구조)으로 비정적 신호의 비선형 예측을 다루고 있다. 완전 케환된 리커런트 신경망과 기존의 TDL(tapped-delay-line) 필터가 비선형과 선형모듈로 각각 사용되었다. 제안된 예측기의 동특성은 카오스 시계열과 음성신호에 대해 시험하였으며, 예측성능의 상대적인 비교를 위해 기존의 ARMA (autoregressive moving average) 구조의 선형 예측모델과 비교하였다. 실험결과에 의하면 신경망을 이용한 적응 예측기는 선형 예측기보다 예측성능이 훨씬 우수하였으며, 특히 직렬구조의 예측기는 신호가 크게 변화하는 시계열의 예측에 효과적으로 사용할 수 있음을 확인하였다.

Abstract

Neural networks, having highly nonlinear dynamics by virtue of the distributed nonlinearities and the learning ability, have the potential for the adaptive prediction of nonstationary signals. This paper describes the nonlinear prediction of these signals in two ways; using a nonlinear module and the cascade combination of nonlinear and linear modules. Fully-connected recurrent neural networks (RNNs) and a conventional tapped-delay-line (TDL) filter are used as the nonlinear and linear modules respectively. The dynamic behavior of the proposed predictors is demonstrated for chaotic time series and speech signals. For the relative comparison of prediction performance, the proposed predictors are compared with a conventional ARMA linear prediction model. Experimental results show that the neural networks based adaptive predictor outperforms the traditional linear scheme significantly. We also find that the cascade combination predictor is well suitable for the prediction of the time series which contain large variations of signal amplitude.

I. 서 론

신호예측은 음성신호의 분석, 시스템의 모델링, 데이터의 전송 및 압축, 제어시스템의 모사, 주기변동의 예

측 등 여러 분야에서 적용되고 있다^[1,2]. 초기의 신호 예측으로는 선형예측방법이 많이 사용되었으나, 우리가 다루고 있는 대부분의 물리적인 신호는 비선형 및 비정적(nonstationary) 특성을 갖고 있으므로 선형예측 방법으로는 이러한 비정적 신호에 대해서 만족할 만한 예측을 수행하기가 어렵다. 이에 대응하기 위해 비선형 처리기법이 사용되었으나^[3] 최근에는 신경망을 이용한 비선형 예측이 수행되고 있다^[4,5].

최근에 여러 분야에서 적용되고 있는 신경망은 회로

* 正會員, 金烏工科大學校 電子工學部

(Dept. of Electronics, Kumoh National University of Technology)

接受日字: 1998年1月14日, 수정완료일: 1998年7月1日

망 내부에 비선형적인 처리능력을 갖춘 유닛으로 구성 되어 있으며, 주위 환경에 적응할 수 있는 학습능력을 갖고 있으므로 비정적 신호에 대한 비선형 적응 예측에 적합한 모델이라 할 수 있다. 신경망은 입력과 출력간의 표현에 따라서 정적과 동적 신경망으로 구분될 수 있는데, 신호예측에 자주 사용되어 왔던 순방향 다층 퍼셉터론 신경망은 정적인 입출력 맵핑만을 학습하는 단점이 있으므로^[6], 정적신호의 비선형 예측을 수행하는데 사용할 수 있다^[7,8]. 즉, 순방향 신경망은 신호의 spatial 정보에 따라서 신호의 모델링을 수행하게 되므로 시변신호에 대해서는 효과적인 예측을 수행할 수 없다.

시간에 따라서 신호의 통계적 특성이 변하는 비정적 신호를 예측하기 위해서는 신경망의 동적 특성을 향상 시킴으로써 신호의 temporal 정보를 처리할 수 있어야 한다. 이를 구현하기 위해 신경망에 새로운 입력을 추가하는 대신에 일반적으로 신경망의 출력에 영향을 미칠 수 있도록 신경망 내부에 메모리를 추가함으로써 temporal 정보 처리를 효과적으로 수행할 수 있다. 이러한 구조를 갖는 신경망은 크게 두 가지 형태가 소개되고 있는데, 첫 번째로는 신경망의 층간에 시간지연을 추가하고 학습단계에서 계수를 조정하는 방법이며, 두 번째로는 뉴런의 출력을 입력으로 다시 사용하는 궤환 구조를 이용하는 방법이다.^[9,10,11]

본 연구에서는 두 가지 예측구조를 사용한 신호예측을 다루고 있는데, 첫 번째 구조로는 히든층의 모든 유닛으로부터 입력층으로 궤환되는 리커런트 신경망 (fully-connected RNNs)을 사용한 예측구조로서 비정적 신호에 대해 신경망을 이용한 비선형 적응예측이 기존의 선형예측 방법보다 우수한 예측을 수행할 수 있음을 확인하고자 한다. 본 연구에서 사용된 선형예측 방법으로는 기존의 방법중에서 성능이 뛰어난 Steiglitz-McBride 반복법을 사용한 ARMA 모델을 사용하였다. 시험신호로는 카오스 특성을 갖고 있는 chaotic 시계열(time series)과 비정적 특성을 갖고 있는 음성신호를 사용하였으며, 수행된 예측결과를 상호 비교함으로써 신경망에 의한 예측성능의 상대적인 평가를 조사하였다. 실험결과에 의하면 신경망에 기초한 예측은 만족스런 결과를 보여 주었으며, 기존의 선형 예측방법보다는 리커런트 신경망에 의한 예측성능이 월등히 우수함이 확인되었다. 그러나 리커런트 신경망에 의한 예측결과를 자세히 살펴보면 전반적으로

만족스런 예측을 수행하였으나 신호의 변화가 크게 발생하는 부분에서는 예측성능의 향상이 필요함을 알 수 있다.

이러한 현상을 개선하기 위하여 본 논문에서는 비선형 모델과 선형모델을 직렬로 연결된 또 다른 구조를 제안하여 비정적 신호에 대한 예측을 다루고 있다. 본 연구에서 사용된 비선형 모델은 리커런트 신경망을 사용하였고, 선형 모델로서는 기존 TDL 구조의 FIR 필터를 사용하였다. 제안된 구조에 의한 예측성능을 확인하기 위하여 첫 번째 예측구조에서 사용된 시험신호를 이용하여 예측성능을 평가하였다. 실험결과에 의하면 제안된 직렬구조에 의한 예측은 리커런트 신경망에 의한 예측결과에 비해 더 적은 수의 예측 시스템 계수를 사용하면서도 성능면에서 더 우수함이 확인되었다.

II. 신호예측 구조 및 방법

신호예측이란 과거 신호들을 이용해서 미래 신호를 추정하는 것으로서, 단 단계예측(single-step prediction)과 다 단계예측(multi-step prediction)으로 분류할 수 있다. 그림 1은 이러한 예측을 수행하기 위한 시스템 구조로서 예측필터의 임펄스 응답은 오차신호 $e(k) = y(k) - \hat{y}(k)$ 에 의해서 결정된다.

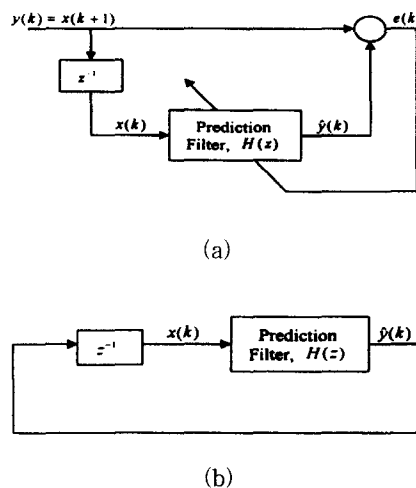


그림 1. 예측 시스템 구성도
(a) 단 단계예측, (b) 다 단계예측
Fig. 1. Block diagram of prediction system.
(a) Single-step prediction, (b) Multi-step prediction

그림 1(a)은 단 단계예측을 위한 구조로서 주어진 과거의 입력신호들($x(k)$)로부터 미래 신호($y(k)$)를 예측($\hat{y}(k)$)하는 것이며, 그림 1(b)의 다 단계예측은 주어진 과거의 입력신호들로부터 미래 신호를 예측하고, 예측된 신호 값을 입력으로 케환시켜 구성된 새로운 입력신호들로부터 다음 시간의 신호를 예측하는 것이다.

본 연구에서 제안된 구조에 의한 비선형 예측성능의 상대적인 평가를 위해서 사용된 선형 예측방법은 과거 입력신호들의 선형결합에 의해서 미래신호를 예측한다. 예측 시스템의 필터계수들을 구하는 방법은 여러 가지가 존재하는데 대표적인 경우로 시스템의 전달함수, $H(z)$ 의 모든 극점을 찾는 AR(autoregressive) 모델링으로서 LPC(linear prediction coefficients)방법이 있으며, 시스템의 영점과 극점 모두를 찾는 ARMA 모델링으로서 Prony 방법과 Steiglitz-McBride (STMCB)방법이 있다. 이러한 선형예측 방법들은 예측필터의 전달함수 $H(z)$ 가 다음 식 (1)과 같이 표현될 때

$$H(z) = \frac{\sum_k a_k z^{-k}}{\sum_k b_k z^{-k}} \quad (1)$$

영점과 극점들을 포함하고 있는 a_k 와 b_k 값들을 구하는 것으로서, 요구신호(신호의 미래신호)와 시스템 출력의 차이 오차신호의 크기를 최소화하는 계수들을 결정한다. 본 논문에서는 세 가지 모델링 방법 중 성능이 우수하고 빠르게 수렴하는 STMCB 반복법을 이용한 선형예측을 수행하였으며, 요구되는 영점과 극점의 수는 최소의 오차로 수렴되도록 실험을 통해서 결정하였다.

1. 신경망에 의한 신호예측

비정적인 신호 예측에는 비선형성이 강하고 동특성이 우수한 리커런트 신경망을 이용하여 예측능력을 향상시킬 수 있다. 본 연구에서는 리커런트 신경망만을 사용한 비선형 예측과 리커런트 신경망과 TDL 필터가 직렬로 구성된 구조에 의한 예측을 수행하였으며, 제안된 직렬 예측구조는 그림 2와 같다.

리커런트 신경망은 입력신호를 선형화시키기 위하여 입력공간으로부터 임의의 중간공간으로의 비선형 맵핑을 수행하며, 선형모델로 사용된 TDL 필터는 중간공

간으로부터 출력공간으로 선형맵핑을 수행하게 된다. 비선형 모델은 신호의 과거 값들, $x(k-1)$, $l=1, \dots, M$ 을 이용하여 현재의 신호 $x(k)$ 를 예측하고, 선형모델은 비선형 모델에서 예측된 신호들, $\hat{x}(k)$, $l=1, \dots, N$ 을 이용하여 다음 시간의 미래신호 $x(k+1)$ 를 예측한다. 리커런트 신경망과 TDL의 계수들은 각각의 오차신호 $\{x(k) - \hat{x}(k)\}$ 와 $\{x(k+1) - \hat{x}(k+1)\}$ 이 최소가 되도록 갱신된다.




그림 2. 제안된 직렬 예측구조

Fig. 2. Proposed cascade structure of prediction.

2. 리커런트 신경망의 구조

그림 3은 적응예측 필터로 사용된 리커런트 신경망으로서 히든층의 모든 유닛 출력이 입력으로 케환된 구조를 보여주고 있는데^[5] 케환이 없는 구조보다 동특성을 더욱 향상시킬 수 있다. 따라서 외부입력과 케환입력으로 구성된 신경망의 입력 $z(k)$ 는 식 (2)와 같다

$$z(k) = \{ \text{Bias}, x_1(k), \dots, x_{IN}(k), h_1(k-1), \dots, h_{HN}(k-1) \} \quad (2)$$

여기서 Bias 입력은 상수 1.0이며, IN 은 외부 입력, HN 는 히든층으로부터 케환되는 입력 개수이다. 입력층의 유닛은 입력신호를 처리하지 않고 직접 히든층의 모든 유닛으로 전달되며 히든층과 출력층에서 사용되는 전달함수는 시그모이드 함수를 사용하였으며, 각 유닛의 출력 $y(k)$ 는 다음과 같다.

$$y(k) = f(I(k)) = \frac{1}{1 + e^{-s \cdot I(k)}} \quad (3)$$

$$I(k) = \sum_m w(m) u(m) \quad (4)$$

여기서 $I(k)$ 는 시간 k 에서 유닛의 내부상태를 나타내며, $w(m)$ 과 $u(m)$ 은 층간의 연결계수와 이전 층의 뉴런출력을 각각 나타내며, s 는 시그모이드 함수의 기울기이다. 리커런트 신경망의 학습방법은 오차 역전파(error back-propagation) 학습 알고리즘을 사용하여 연결계수를 갱신하였으며 학습속도를 향상시키기 위해

모멘텀(momentum) 항이 추가되었다.

$$w(k+1) = w(k) - \eta \frac{\partial J(k)}{\partial w(k)} + \alpha \Delta w(k-1) \quad (5)$$

$$J(k) = \frac{1}{2} [d(k) - o(k)]^2 \quad (6)$$

위 식에서 η 는 학습율을 나타내며, 모멘텀을 α 를 포함하는 항은 모멘텀항이다. 그리고 오차함수(cost function) $J(k)$ 는 원하는 출력 $d(k)$ 와 신경망의 출력 $o(k)$ 와의 차이의 제곱으로 정의되는데, 입력층과 히든층의 유닛개수와 학습율 및 모멘텀은 실험을 통해서 오차함수 값이 최소가 되도록 결정되었다.




그림 3. 리커런트 신경망 구조
Fig. 3. Structure of recurrent neural networks.

3. TDL 구조

예측성능 향상을 위해 사용된 TDL의 구조는 그림 4와 같다.




그림 4. TDL 구조
Fig. 4. Structure of TDL.

TDL의 계수는 다음 식과 같이 표현된다.

$$w(k) = \{w(k,0), w(k,1), \dots, w(k,q-1)\} \quad (7)$$

여기서 q 는 전체 탭(tap)의 개수이다. TDL의 탭 입

력 $\hat{x}(k)$ 는 리커런트 신경망에서 계산된 현재 출력 $y(k)$ 와 $(q-1)$ 개의 이전 출력값들로 구성되며, 이러한 값들에 의해 다음 시간 $(k+1)$ 의 예측값인 $\hat{x}(k+1)$ 는 각각 다음과 같이 표현될 수 있다.

$$\hat{x}(k) = \{y(k), y(k-1), \dots, y(k-q+1)\} \quad (8)$$

$$\hat{x}(k+1) = \sum_{m=0}^{q-1} w(m) \hat{x}(m) \quad (9)$$

선형 모델의 출력인 $\hat{x}(k+1)$ 는 원신호 $x(k+1)$ 의 추정값이며, TDL 필터의 계수는 각 샘플마다 식 (10)의 LMS(least mean square)에 의해서 갱신된다.

$$w(k+1) = w(k) + 2\mu e(k) \hat{x}(k) \quad (10)$$

여기서 μ 는 수렴율을 나타내며, 오차 $e(k)$ 는 원신호 $x(k)$ 와 예측된 신호 $\hat{x}(k)$ 와의 차이이다.

III. 실험내용 및 결과

예측성능을 조사하기 위해 시험신호로는 카오스 특성을 갖는 Mackey-Glass 시계열과 비정적인 성질을 갖는 음성신호를 사용하였다. 선형 예측방법으로는 ARMA 구조에 STMCB 반복법을, 비선형 예측으로는 리커런트 신경망만을 이용한 경우와 리커런트 신경망과 TDL 필터의 직렬 결합 구조에 의한 방법으로서 기울기 강하법(gradient descent method)을 각각 사용하여 단 단계예측과 다 단계예측을 수행하였다.

1. Mackey-Glass 시계열 예측

예측성능 평가를 위해 많이 사용되고 있는 Mackey-Glass 시계열^[7]은 지연 미분방정식으로서 식 (11)을 이용하여 생성되며, 방정식의 변수와 지연 값에 따라서 서로 다른 카오스 특성을 갖는다.

$$\frac{ds(k)}{dt} = -bs(k) - \frac{\rho s(k-\tau)}{1 + s^{10}(k-\tau)} \quad (11)$$

여기서 $\tau = -21$, $\rho = 0.2$, $b = 0.1$, 그리고 초기조건으로 $s(k-\tau) = 0.5$, $0 \leq k \leq \tau$ 를 사용하였으며, 정적신호인 Mackey-Glass 시계열에 작은 크기의 정현파 $(0.1 \cdot \sin(\pi k/1000))$ 를 추가함으로써 강한 비선형 특성을 갖는 신호로 만든 후 1000개 샘플의 시험신호를 발생시켜 실험하였다.


선형예측 모델로 사용된 ARMA 구조의 영점과 극점 수는 각각 20과 70으로 선택하였다. 리커런트 신경망 구조는 입력층의 유닛개수를 4개, 히든층과 출력층의 유닛개수를 각각 8개와 1개로 구성하였다. 즉, 과거 신호로서 4개의 지연된 외부입력을 사용하여 현재의 신호를 예측하는데 예측된 값과 실제 값의 차이가 되도록 신경망이 학습되었다. 이러한 학습은 오차가 더 이상 감소되지 않을 때까지 수행되었는데 실험에 의하면 모든 시험신호가 1000번 학습 후에는 오차가 거의 일정한 값으로 수렴되었으므로 모든 학습신호에 대한 학습회수는 1000번 수행하였다. 학습신호로 사용된 Mackey-Glass 시계열에서 전반부 400 샘플에 대한 학습오차는 0.0129이며, 학습 후 후반부 600개 샘플 신호에 대하여 비선형 예측을 수행하였다. 리커런트 신경망의 학습율과 모멘텀은 각각 0.4와 0.6을 사용하였으며 시그모이드 함수의 기울기는 모든 시험신호에 대해 0.9를 사용하였다. 예측구조와 사용된 변수 값들은 실험을 통해서 최적의 예측이 되도록 결정되었다. 그림 5는 학습구간을 제외한 나머지 구간에 대한 단 단계 예측결과를 보여주고 있다.

그림 5에서 점선으로 표시된 신호는 정현파가 추가된 Mackey-Glass 시계열 신호이며 연속선은 예측된 신호를 나타내는데, 비선형적인 신경망에 의한 예측방법이 우수한 예측결과를 보여주는 반면, 선형적인 ARMA 방법은 만족스런 예측결과를 보여주지 못하고 있다. 예측오차를 정량적으로 조사하기 위해 식 (12)와 같이 정의된 평균 자승오차식(MSE)을 사용하였다.


$$\text{오차} = \frac{1}{N} \sum_{k=1}^N [y(k) - \hat{y}(k)]^2 \quad (12)$$

여기서 $N(=600)$ 은 전체 샘플수이며, $y(k)$ 는 원신호이고, $\hat{y}(k)$ 는 추정된 예측값이다. 식 (12)에 의해 계산된 결과를 살펴보면, ARMA에 의한 오차는 0.016198이며, 리커런트 신경망에 의한 오차는 0.000155로서 신경망에 의한 방법이 ARMA보다 20.2 [dB] 적은 오차가 발생되었다. 따라서 신경망 필터는 Mackey-Glass 시계열의 동특성을 효과적으로 모델링할 수 있는 시스템임을 알 수 있다.


그림 5(b)에서 알 수 있듯이 신호가 급격히 변하는 최대, 최소 주위에서는 신호의 동특성이 강한 부분으로서 주어진 리커런트 신경망 구조에 의한 예측은 한계가 있음을 확인할 수 있다. 이러한 신호부분에서의



(a)



(b)



(c)

그림 5. Mackey-Glass 시계열에 대한 단 단계 예측결과 (a) ARMA, (b) 리커런트 신경망, (c) 직렬구조

Fig. 5. Experimental results of one-step prediction for Mackey-Glass time series. (a) ARMA, (b) RNN, (c) Cascade structure

예측성능을 더욱 더 향상시키기 위해서 제안된 직렬구조에 의한 예측결과를 조사하였다. 직렬구조에 사용된 신경망은 위에서 사용된 리커런트 신경망 구조와 동일하며 단지 히든층의 유닛개수를 4개 사용하였고, TDL의 탭수는 모든 시험신호에 대해 10개를 사용하였다. 신경망의 학습율과 모멘텀율은 각각 0.3과 0.7이며, TDL의 수렴율은 0.01을 사용하였다. 전반부 400샘플의 학습신호에 대한 오차는 0.0124이며, 학습 후 600개의 신호에 대하여 비선형 예측을 수행하였다. 신경망에 의한 예측구조에서 리커런트 신경망만을 사용하였을 때 연결계수들의 수는 104개인데 비해서 직렬구조에서는 모두 46개로서 훨씬 적은 계수가 사용되었다.

그림 5(c)는 제안된 직렬구조를 사용하였을 때 예측 결과로서 600샘플 구간에 대한 결과를 보여주고 있다. 그림 5의 (b)와 (c)에서 알 수 있듯이 직렬 예측구조가 리커런트 신경망만을 사용한 경우보다 신호가 급격히 변하는 부분에서 더 우수한 예측성능을 보여주고 있다. 예측오차를 정량적으로 조사하기 위해 식 (12)에 의해 계산된 결과를 살펴보면, 직렬구조에 의한 전체오차는 0.000123로서 리커런트 신경망만에 의한 예측보다 약 1.14 [dB] 정도 더 적은 오차가 발생되었으며, 급격한 신호변화 부분에서는 오차의 차이가 훨씬 크다.

2. 음성신호 예측

음성신호로는 한국 남성의 음성을 11 [KHz]의 샘플링 주파수로 1000개의 신호를 생성하였으며, 잡음성분에 의한 예측성능의 영향을 배제하기 위하여 차단주파수가 2.2 [KHz]인 저역통과 필터를 사용하여 고주파 성분의 잡음을 제거하였다. ARMA 구조의 영점과 극점의 수는 각각 20과 50으로 선택하였으며, 리커런트 신경망과 제안된 직렬구조는 Mackey-Glass 시계열 실험에 사용된 구조와 동일하며, 리커런트 신경망에서의 학습율과 모멘텀율은 각각 0.3과 0.6, 직렬구조에서는 각각 0.4와 0.6, 그리고 TDL의 수렴율은 0.02를 사용하였다. 실험내용은 1000샘플의 시험신호 중 전반부 400샘플 신호를 단 단계예측을 위한 학습신호로 사용하였으며, 첫 번째 구조인 리커런트 신경망의 학습오차는 0.0084, 직렬구조의 오차는 0.0081이었으며, 학습 후 600개의 신호에 대하여 비선형 예측을 수행하였다. 그림 6은 시험에 사용된 음성신호를 보여주

고 있으며, 그림 7은 ARMA와 리커런트 신경망, 그리고 제안된 직렬구조를 사용한 단 단계예측결과이다.





그림 6. 음성 시험신호
Fig. 6. Speech signal as a test signal.


그림 7에서 보면 음성신호의 경우에 대해서도 Mackey-Glass 시계열의 결과와 같이 리커런트 신경망의 예측결과가 ARMA 방법보다 훨씬 더 우수함을 확인할 수 있다. 또한 직렬구조에 의한 예측이 리커런트 신경망만에 의한 예측보다 예측성능이 더욱더 향상되었음을 알 수 있으며, 특히 신호가 급격히 변화하는 부분에서 예측결과가 더 우수함을 확인할 수 있다. 정량적 오차비교를 위해 식 (12)를 사용하여 계산된 결과를 살펴보면, $N=600$ 일 때 ARMA에 의한 오차는 0.006001이며, 리커런트 신경망에 의한 오차는 0.000493, 그리고 직렬구조의 의한 오차는 0.000380로서 리커런트 신경망만에 의한 예측이 ARMA 방법보다 11 [dB] 적은 오차를 발생시켰으며, 직렬구조는 리커런트 신경망만을 사용한 경우보다 1.14 [dB]의 더 적은 오차를 발생시켰다. 따라서 음성신호의 예측에서도 직렬구조가 ARMA 모델이나 리커런트 신경망보다 더 우수한 성능을 보여주었으며, Mackey-Glass 시계열 경우에서와 같이 급격한 음성신호 변화부근에서 직렬구조의 예측오차는 훨씬 적다.

제안된 직렬 예측구조는 가끔 신호의 일부분에서 예측신호가 미세하게 지연되는 현상이 발생할 수도 있는데 이러한 현상은 TDL 필터에 의해 발생하는 것으로 필터의 탭수와 사용되는 수렴율에 따라서 지연정도가 변화하므로 적절한 구조의 TDL 필터 사용이 요구된다. 그리고 TDL에서 큰 값의 수렴율을 사용할 경


우 직렬 예측구조는 발산할 가능성이 있으나 리커런트 신경망의 변수 값들은 시스템 안정성에 영향을 거의 미치지 못함을 실험을 통해 확인되었다.



(a)



(b)




(c)


그림 7. 음성신호에 대한 단 단계예측결과 (a) ARMA, (b) 리커런트 신경망, (c) 직렬구조
Fig. 7. Experimental results of single-step prediction for speech signal. (a) ARMA, (b) RNN, (c) Cascade structure

3. 다 단계예측 결과

더 정확한 예측능력을 조사하기 위해서 일반적으로 다 단계예측 결과를 이용하여 예측성능을 평가하고 있다. 다 단계예측은 학습 후 입력신호로 원 신호를 사용하지 않고 예측된 출력신호를 입력으로 사용하기 위해 케환시키는 구조를 제외하고는 단 단계예측 구조에서의 실험내용과 동일하다. 그림 8은 Mackey-Glass 시계열 신호와 음성신호에 대해 30 단계까지의 다 단계예측 결과를 보여주고 있다. 모든 예측필터는 시간이 지남에 따라서 예측결과와 오차가 증가하는 현상을 보이고 있는데 이는 예상된 결과이다. 그러나 두 시험 신호 모두에 대해 ARMA 구조나 리커런트 신경망만을 사용하는 경우가 직렬구조에 의한 다 단계예측 결과의 오차보다 훨씬 크며 단계가 진행됨에 따라서 비슷한 오차크기를 계속 유지하고 있음을 알 수 있다.



(a)



(b)

그림 8. 다 단계예측시 NMSE(dB)
(a) Mackey-Glass 시계열, (b) 음성신호
Fig. 8. NMSE of multi-step prediction. (a) Mackey-Glass time series, (b) Speech signal

단 단계와 다 단계예측 결과를 살펴보면 정적신호인 Mackey Glass 시계열과 비정적 음성신호에 대해 신경망에 의한 비선형 예측이 ARMA 구조의 선형예측보다는 훨씬 더 우수한 예측을 수행할 수 있음을 알 수 있다. 그리고 신경망에 의한 예측에서도 직렬 예측 구조는 리커런트 신경망만을 사용한 경우보다 예측성능을 향상시켰으며, 리커런트 신경망에 의한 예측에서의 단점을 보완할 수 있는 예측구조임을 알 수 있다.

IV. 결 론

본 논문에서는 비선형 예측모델을 이용한 비정적 신호의 예측을 다루고 있다. 본 연구에서 사용된 예측 시스템은 리커런트 신경망을 사용한 경우와 리커런트 신경망과 TDL 필터를 직렬로 연결된 두 가지 구조를 사용하고 있다. 실험결과에 의하면 기울기 급강하 방법을 사용한 신경망 구조의 비선형 적응 예측모델은 기존의 Steiglitz-McBride 반복법을 이용한 ARMA 구조의 선형 예측모델보다 훨씬 우수한 예측성능을 보여주었다. 특히, 신호가 급변하는 부분에서는 제안된 직렬 예측구조가 리커런트 신경망만을 사용한 예측결과에 비해 더 적은 수의 시스템 계수를 사용하면서도 예측성능을 향상시킬 수 있음을 확인할 수 있었다. 본 연구에서 제안된 예측구조는 비정적 신호에 대한 비선형 적응예측에 효과적인 예측 모델로 사용할 수 있으며, 시간에 따라서 변화하는 잡음제거등의 다른 시변 신호의 처리분야에도 적용할 수 있으리라 판단된다.


참 고 문 헌

- [1] J. Thyssen, H. Nielsen, and S. D. Hansen, "Nonlinear short-term prediction in speech coding," IEEE Int'l Conference on Acoustics, Speech, and Singal Processing, pp. I185 - I188, 1994.
- [2] L. R. Rabiner and R. W. Schafer, *Digital Processing of Speech Signals*, New York, Academic, 1985.
- [3] N. S. Jayant and P. Noll, *Digital Coding of Waveforms*, Englewood Cliffs, NJ, Prentice-Hall, 1984.
- [4] D. Yip, E. Hines, and W. yu, "Application of artificial neural networks in sales

forecasting," IEEE Int'l Conference on Neural Networks, vol. 4, pp. 2116-2120, Jun. 1997.

- [5] H. P. Lin and Y. C. Ouyang, "Neural networks based traffic prediction for cell discarding policy," IEEE Int'l Conference on Neural Networks, vol. 4, pp. 2051-2056, Jun. 1997.
- [6] S. Haykin, *Neural Networks: A comprehensive foundation*, Macmillan College Publishing Company, New York, 1994.
- [7] E. S. Chng, S. Chen, and B. Mulgrew, "Gradient radial basis function networks for nonlinear and nonstationary time series prediction," IEEE Trans. on Neural Networks, vol. 7, no. 1, pp. 190-194, 1996.
- [8] A. Wieland and R. Leighton, "Geometric analysis of neural-network capabilities," in Proc. IEEE Int. Conf. Neural Networks, vol. III, San Diego, CA, pp. 385-392, 1987.
- [9] F. Bartolini, V. Cappellini, and S. Nerozzi, "Recurrent neural network predictors for EEG signal compression," IEEE Int'l Conference on Acoustics, Speech, and Signal Processing, pp. 3395-3398, 1995.
- [10] G. Kechriotis, E. Zervas, and E. Manolakos, "Using recurrent neural networks for adaptive communication channel equalization," IEEE Trans. on Neural Networks, vol. 5, no. 2, pp. 267-278, Mar. 1994.
- [11] J. L. Elman, "Finding structure in time," Cognitive Sci., vol. 14, pp. 179-211, 1990.

저 자 소 개



崔 瀚 阜(正會員)

1958년 5월 3일생. 1979년 경북대 전자공학과 졸업. 1988년 Univ. of Florida 전기공학과 졸업(석사). 1992년 Univ. of Florida 전기공학과 졸업(공학). 1979년 ~ 1986년 국방과학연구소 근무. 1993년 ~ 1995년 금오공대 전임강사. 1995년 ~ 현재 금오공대 전자공학부 조교수. 관심분야: 디지털 신호처리, 신경회로망, 의용전자



李 晧 燮(正會員)

1972년 12월 3일생. 1996년 금오공대 전자제어공학과 졸업. 1998년 금오공대 전자제어공학과 졸업(석사). 1998년 ~ 현재 금오공대 전자공학부 박사학위중. 관심분야: 제어계측, 신경회로망, 영상처리



金 相 熙(正會員)

1960년 1월 19일생. 1983년 홍익대 전기공학과 졸업. 1985년 연세대 대학원 전기공학과 졸업(석사). 1992년 Texas A&M University 졸업(공학). 1993년 ~ 1995년 금오공대 전임강사. 1995년 ~ 현재 금오공대 전자공학부 조교수. 관심분야: 제어계측, 신경회로망, 카오스