

Gamma 다층 신경망을 이용한 비선형 적응예측

Nonlinear Prediction using Gamma Multilayered Neural Network

김종인*, 고일환**, 최한고*

Jong-In Kim*, Il-Hwan Go**, Han-Go Choi*

요약

동적 신경망은 시스템 식별과 신호예측과 같이 temporal 신호처리가 요구되는 여러 분야에서 적용되어 왔다. 본 논문에서는 신경망의 동특성을 향상시키기 위해 순방향 다층 신경망의 히든 층에 감마(Gamma) 메모리 커널을 사용하는 감마 신경망(GAM)을 제안하고, 적응필터로 제안된 신경망을 사용하여 비선형 적응예측을 다루고 있다. 제안된 신경망은 비선형 신호예측을 통해 평가되었으며, 예측성능의 상대적인 비교를 위해 순방향 신경망(FNN)과 리커런트 신경망(RNN)과 비교하였다. 시뮬레이션 결과에 의하면 GAM 신경망은 수렴속도와 예측의 정확도에서 이러한 신경망보다 더 우수한 동작을 수행함으로써, 제안된 신경망이 기존의 다층 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 system identification and signal prediction. This paper proposes the gamma neural network(GAM), which uses gamma memory kernel in the hidden layer of feedforward multilayered network, to improve dynamics of networks and then describes nonlinear adaptive prediction using the proposed network as an adaptive filter. The proposed network is evaluated in nonlinear signal prediction and compared with feedforward(FNN) and recurrent neural networks(RNN) for the relative comparison of prediction performance. Simulation results show that the GAM network performs better with respect to the convergence speed and prediction accuracy, indicating that it can be a more effective prediction model than conventional multilayered networks in nonlinear prediction for nonstationary signals.

Keywords : Gamma kernel, Dynamic neural networks, Adaptive filter, Nonlinear prediction

I. 서론

신호예측은 음성신호 분석, 시스템 모델링 혹은 식별, 데이터 전송 및 압축, 주기변동 예측 등 여러 분야에 적용되고 있으며, 이러한 분야에서 다루는 대부분의 신호는 비선형(nonlinear) 및 비정적(nonstationary) 특성을 갖고 있으므로 LMS(Least Mean Square)와 같은 선형예측 방법으로는 만족할 만한 예측을 수행하기가 어렵다. 이를 개선하기 위해 신경망을 이용한 비선형 예측이 수행되고 있는데[1,2], 신경망은 회

로망 내부에 비선형적인 처리능력을 갖춘 유닛으로 구성되어 있고 주위 환경에 적응할 수 있는 학습능력을 갖고 있으므로 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 신호예측 뿐만아니라 플랜트 제어, 패턴인식, 비선형 필터링과 같이 temporal 신호처리가 요구되는 여러 분야에 많이 사용되고 있다[3-6].

이러한 동적 신경망은 기존의 정적(static) 신경망에 동특성을 추가하기 위해 신경망 내부에 버퍼(buffer)를 두어 과거 입력에 대한 메모리로 사용하거나, 피드백(feedback) 구조를 사용함으로써 신경망에 temporal 동특성을 갖도록 하였다. 지금까지 제안되어 가장 일반적으로 사용되고 있는 동특성 다층 신경망 구조는 크게 두 부류로 구분할 수 있다. 첫 번째 구조

*금오공과대학교 전자공학부 **삼성전자 무선개발팀

논문 번호 : 2006-2-12 접수 일자 : 2006. 2. 13

심사 완료 일자 : 2006. 4. 17

※본 연구는 금오공과대학교 학술연구비에 의하여 연구된 논문입니다.

로는 신경망 내부에 버퍼를 사용하는 구조로 신경망 입력에 TDL(tapped delay line) 구조를 사용한 buffered 다층 퍼셉트론(multilayer perceptron, MLP)[7]과 각 뉴런 입력이 FIR(finite impulse response) 필터 시냅스(synapse)를 갖는 FIR-MLP가 있다[8,9].

두 번째로는 케환구조의 신경망으로 지역 및 광역케환 신경망이 있는데, 광역케환 신경망은 한 층의 뉴런 출력들이 다른 층의 모든 뉴런 입력들과 연결된 구조, 즉, fully connected 리커런트 신경망(Recurrent Neural Networks, RNN)[3,10]으로서 가장 대표적인 신경망으로 Elman[11]과 Jordan RNN 신경망[12]이 있다. 지역케환 신경망은 최근에 제안된 구조로 뉴런과 뉴런 사이에 이산시간 내부 메모리를 갖는 시냅스를 사용하고 있는데, 기존의 시냅스를 FIR 필터나 IIR(infinite impulse response) 필터로 대신한 구조로서 이러한 FIR-MLP 혹은 IIR-MLP는 기존의 선형 FIR 혹은 IIR 필터의 비선형 확장으로 생각할 수 있다[13]. 이러한 케환구조의 신경망은 상대적으로 동특성이 우수하나 구조가 복잡하며 학습 알고리즘 또한 많은 계산량이 요구된다.

본 논문에서는 순방향 신경망 특성을 유지하면서 신경망의 동특성을 향상시키기 위해 다층 신경망의 히든층 활성화함수에 감마(Gamma) 메모리[14]가 합성된 구조를 사용한 신경망을 제안하며(Gamma Neural Network, GAM), 제안된 신경망을 이용한 비선형 예측이 기존의 다층 동특성 신경망보다 더 우수한 예측을 수행할 수 있음을 확인하고자 한다.

제안된 GAM 신경망은 순방향 다층 신경망인 TDNN(Time Delayed Neural Network)의 발전된 구조로서 케환구조의 단점을 보완하고 신경망 구조 및 학습 알고리즘을 단순화 시킬 수 있다. 학습방법으로는 오차 역전파(error backpropagation) 알고리즘을 사용하여 시스템 오차가 최소화 되도록 기존의 다층 신경망의 계수와 Gamma 메모리의 계수들을 갱신하였다.

GAM 신경망은 특성은 Mackey-Glass 시계열(time series)과 음성신호 예측을 통해서 조사하였으며, 상대적인 성능평가를 위해 기존의 순방향 신경망인 FNN과 대표적인 케환구조의 신경망인 Elman RNN과의 예측결과를 상호 비교함으로써 제안된 신경망의 우수성을 확인하였다. 예측에 대한 평가내용으로는 수렴특성과 시스템 안정성, 즉, 시스템 오차를 상호 비교하여 성능을 평가하였다. 시뮬레이션 결과를 살펴보면 제안된 GAM 신경망이 기존의 다층 신경망보다 더 우수한 예측 성능을 보여주었다.

II. Gamma 다층 신경망

2.1 Gamma Memory

그림 1은 제안된 신경망에 사용하고 있는 Gamma memory의 신호 흐름도이다.

이 메모리 구조에서 각각의 섹션은 단위 지연인자인 z^{-1} 와 조절 파라메터인 μ 를 가진 피드백 루프 구조를 형성하고 있으며 Gamma memory kernel의 전달함수 $G(z)$ 은 다음과 같다.




그림 1. Gamma memory 신호 흐름도
Fig. 1. Signal flow of Gamma memory

$$G(z) = \frac{\mu z^{-1}}{1 - (1 - \mu)z^{-1}} = \frac{\mu}{z - (1 - \mu)} \quad (1)$$

안정화를 위해서 $z = 1 - \mu$ 에서 $G(z)$ 의 단 극점은 z 평면에서의 단위 원 안에 존재하여야 한다. 즉, 조절 파라메터인 μ 는 다음 조건을 만족하여야 한다.

$$0 < \mu < 2 \quad (2)$$

Gamma memory $G(z)$ 의 역변환 $g(n)$ 은 다음과 같다.

$$g(n) = \mu(1 - \mu)^{n-1}, \quad n \geq 1 \quad (3)$$

위의 조건에서 n 이 0에서 무한으로 가까워짐에 따라 $g(n)$ 은 지수적으로 감소한다.

감마 메모리에서의 임펄스 응답은 다음 전달함수의 역 z -변환이다.

$$G_p(z) = \left(\frac{\mu z^{-1}}{1 - (1 - \mu)z^{-1}} \right)^p \quad (4)$$

$$g_p(n) = \binom{n-1}{p-1} \mu^p (1 - \mu)^{n-p}, \quad n \geq p \quad (5)$$

위 식에서 $\binom{n}{p}$ 는 n 과 p 의 값을 구하기 위해 다음 식으로 정의되어지는 바이노미날 계수이다.

$$\binom{n}{p} = \frac{n(n-1)\cdots(n-p+1)}{p!} \quad (6)$$


다양한 p 에 대한 임펄스 응답인 $g(n)$ 은 감마 함수의 이산적 표현방법이다.

2.2 Gamma Multilayered Neural Network (GAM)


그림 2는 Gamma kernel을 포함하고 있는 신경망 구조를 보여주고 있는데, 그림 2(a)에서와 같이 기존의 순방향 다층 신경망에서 히든층에 Gamma 메모리 모듈이 추가되어 있다.

그림 2(b)는 그림 2(a)의 점선 부분을 확대한 것으로서 히

든층 뉴런에서 여러 개의 Gamma memory kernel이 연결되어 있는 구조로서, 이러한 메모리는 신경망의 동특성을 향상시킨다. 그림 2(a)에서 GAM memory kernel이 없는 구조가 FNN 신경망이며, 히든 층의 모든 뉴런 출력이 입력층으로 케환되어 입력으로 사용되는 구조가 Elman RNN이다.



(a) 전체 신경망 구조



(b) 히든층 뉴런의 확대된 모습

그림 2. Gamma 신경망 구조

Fig. 2. Structure of Gamma network

Gamma 다층 신경망에 적용된 히든층에서의 출력은 다음과 같은 식으로 정의된다.

$$y_k^l(t) = f(x_k^l(t)) \quad (7)$$

$$x_k^l(t) = \sum_{i=0}^{N-1} w_{k,i}^l y_i^{l-1}(t) + \sum_{D=0}^K g_{k,D}^l z_{k,D}^l(t) + b_k^l \quad (8)$$

$$z_{k,D}^l(t) = (1-\mu)z_{k,D}^l(t-1) + \mu z_{k,D-1}^l(t-1) \quad (9)$$

$$\begin{aligned} z_{k,D}^l(t) &= y_k^l(t-1), & t > 0, & D=0 \\ z_{k,D}^l(t) &= 0, & t=0, & D > 0 \end{aligned} \quad (10)$$

여기에서, $g_{k,D}^l$ 은 l 층에서의 k 번째 뉴런에 연결되는 Gamma memory의 weight 연결모듈 D 이다. $z_{k,D}^l$ 는 l 층에서의 k 번째 뉴런과 관련된 필터모듈 D 의 출력이다. b_k^l 는 l 층에서의 k 번째 뉴런에 대한 바이어스 입력이다. μ_k^l 는 l 층에서의 k 번째 뉴런에 대한 Gamma memory의 지연 파라미터이다.

히든층과 출력층 뉴런의 내부 전달함수는 양극 시그모이드

(bipolar sigmoid)함수를 사용하였다. 출력층의 k 번째 뉴런 출력 $y_k(t)$ 과 다음과 같다.

$$y_k(k) = \phi(v_k(k)) = \frac{1 - e^{-s \cdot v_k(k)}}{1 + e^{-s \cdot v_k(k)}} \quad (11)$$

$$v_k(k) = \sum_{j=1}^{HN} w_{kj}(k) y_j(k) \quad (12)$$

여기서 α 는 양극 시그모이드 함수의 기울기이며, $y_j(k)$ 는 히든층 뉴런의 출력이고 $w_{kj}(k)$ 은 히든층의 j 번째와 출력층의 k 번째 뉴런간의 연결계수이다. 상대비교를 위한 FNN과 Elman RNN에서도 같은 활성화함수를 사용하였다.

GAM 신경망의 학습방법은 오차 역전파 알고리즘을 사용하였다.

$$\Delta w(k) = -\eta \frac{\partial J(k)}{\partial w(k)} + \alpha \Delta w(k-1) \quad (13)$$

$$\Delta g(k) = -\eta \frac{\partial J(k)}{\partial g(k)} + \alpha \Delta g(k-1) \quad (14)$$

$$J(k) = \frac{1}{2} [e(k)]^2 = \frac{1}{2} [d(k) - y(k)]^2 \quad (15)$$

위 식에서 $\Delta w(k)$ 와 $\Delta g(k)$ 는 갱신될 연결강도로서 $w(k)$ 는 층간 뉴런사이의 연결계수이고 $g(k)$ 는 히든 층에서 감마 메모리와 뉴런간의 연결계수이며, η 는 신경망의 학습율 (learning rate), α 는 모멘텀율(momentum rate)이다. 그리고 cost function $J(k)$ 는 desired 신호 $d(k)$ 와 신경망 출력 $y(k)$ 와의 에너지 오차로서 정의된다. 즉, cost function의 값이 최소가 되도록 계수값 $w(k)$, $g(k)$ 가 변하게 된다.

III. 실험결과

신호예측은 과거 신호들을 이용해서 미래 신호를 추정하는 것으로서, 단 단계(single-step)예측과 다 단계(multi-step) 예측으로 분류할 수 있다.

그림 3은 예측구조를 보여주고 있는데, 단 단계예측은 주어진 과거의 입력 신호들로부터 한 단계 미래의 신호를 예측하는 것이며, 다 단계예측은 주어진 과거의 입력신호들로부터 미래 신호를 예측하고 예측된 신호 값을 입력으로 케환시켜 구성된 새로운 입력신호로부터 다음 시간의 신호를 예측하는 것이다. 필터출력 $\hat{y}(k)$ 은 지연입력 $x(k-M)$ 을 사용하여 $y(k)$ 를 예측하는데, 예측필터의 계수는 오차신호 $e(k) = y(k) - \hat{y}(k)$ 를 최소화함으로써 결정된다. 그림 4는 그림 3의 예측필터에 사용되는 신경망에 대한 구조를 보여주고 있다.

제안된 신경망의 예측성능을 평가하기 위해 카오스 특성의 Mackey-Glass 시계열(time series)과 비정적 성질을 갖는 음

성신호에 대하여 실험하였으며, 예측필터로 사용된 FNN, RNN, 그리고 GAM 신경망에 대해 단 단계 예측과 다 단계 예측결과를 상호 비교함으로써 제안된 신경망의 예측성능을 평가하였다.

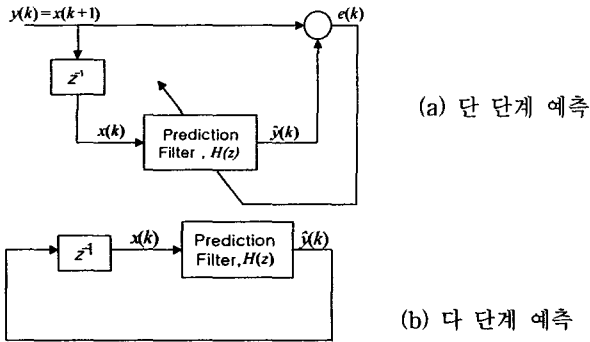


그림 3. 신호 예측 구조
Fig. 3. Structure of signal prediction




그림 4. 예측필터의 신경망 구조
Fig. 4. Network structure of prediction filter

3.1 단 단계 예측

(1) Mackey-Glass 시계열 예측

예측성능 평가를 위해 일반적으로 사용되고 있는 Mackey-Glass 시계열은 식 (16)과 같은 방정식을 이용해서 생성된다.

$$\frac{ds(k)}{dt} = -bs(k) + \frac{\rho s(k-\tau)}{1 + s^{10}(k-\tau)} \quad (16)$$

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 5는 Mackey-Glass 시계열에 정현파 신호를 추가한 합성신호를 보여주고 있다.

예측에 사용된 신경망 구조는 FNN의 경우 신경망 입력 층 유닛은 4개, 히든 층과 출력 층의 유닛개수는 각각 5개와 1개로 (4x5x1)로 구성하였다. RNN의 경우 (4x3x1) 개의 뉴런으로 구성되었고, 히든층은 입력층으로 재환시켰다. 제안된

GAM 신경망 경우에는 4x5x1개의 뉴런으로 구성되어 있어 FNN과 같으나 Gamma memory는 8개가 추가되었으며, $\mu=0.2$ 를 사용하였다. 따라서 예측모델들에 대한 시스템 계수들의 수는 FNN이 25개, RNN이 24개, 그리고 GAM이 25개로 됨으로써 예측모델간에 계수 수를 비슷하게 설정하였으며, 예측 신경망의 입력으로는 현재 입력과 3개의 과거입력을 사용하였다. 시스템의 구조와 변수 값들은 최적의 예측이 되도록 반복 실험을 통하여 결정하였다.




그림 5. 정현파가 추가된 Mackey-Glass 시계열 신호
Fig. 5. Mackey-Glass time series added sine wave




그림 6. Mackey-Glass 시계열의 학습오차 비교
Fig. 6. Learning error comparison in MG time series




그림 7. GAM 신경망의 예측결과
Fig. 7. Prediction result of GAM network

1000샘플의 시험 신호 중 전반부 400샘플을 학습신호로 사용하였으며, 1000번 학습 후 후반부 600샘플 신호에 대하여 단 단계 예측을 수행하였다. 그림 6은 각각의 신경망에 대한 학습 오차로서, 실선으로 표시된 GAM 신경망이 가장 적은 오차를

보여주고 있으며, 그림 7은 400-1000 샘플구간에 대한 GAM 신경망의 예측결과로서 점선이 원 신호를 나타내며 실선이 GAM에 의한 예측결과로서 신호예측 수행능력이 우수함을 보여주고 있다.

그림 8은 시간영역에서 예측모델간의 오차 $|y(k) - \hat{y}(k)|^2$ 를 그림으로 비교하고 있다. 그림 8에서 알 수 있듯이 RNN에 의한 비선형 예측이 FNN 신경망에 의한 비선형 예측보다 우수하며, GAM 신경망이 RNN에 비해 예측성능이 우수하다. 특히, 신호가 급격히 변하는 주위에서는 신호의 동특성이 강한 부분으로서 GAM의 예측결과가 더 우수함을 확인할 수 있다.




그림 8. Mackey-Glass에 대한 예측오차 비교
Fig. 8. Prediction error comparison for MG series

예측오차를 정량적으로 조사하기 위해 식 (17)과 같이 정의된 평균자승오차(Mean Square Error, MSE)를 사용하여 비교하였다.

$$MSE = \frac{1}{(N_1 + N_2 - 1)} \sum_{k=N_1}^{N_2} [y(k) - \hat{y}(k)]^2 \quad (17)$$

여기서 N 은 전체 샘플수이며, $y(k)$ 는 원 신호이고, $\hat{y}(k)$ 는 예측신호이다. 표 1은 학습신호에 대한 MSE로서 제안된 GAM 신경망이 FNN 신경망보다 2.33배 정도, RNN 신경망보다 2.15배 적은 오차를, RNN 신경망은 FNN 신경망보다 1.08배 적은 오차가 발생되었다.

표 1. 시험신호 예측에 대한 평균자승오차
Table 1. Prediction MSE of test signal

	FNN	RNN	GAM
Mackey-Glass	4.091×10^{-4}	3.784×10^{-4}	1.752×10^{-4}
음성신호	4.319×10^{-4}	2.629×10^{-4}	1.561×10^{-4}

(2) 음성신호 예측

사용된 음성신호는 한국 남성의 음성으로서 11[KHz]의 샘플링 주파수로 1000개의 신호를 수집하였으며, 고주파 성분의 잡음을 제거하기 위해서 차단주파수가 2.2[KHz]인 저역통과

필터를 통과시켜 사용하였다. 그림 9는 실험에 사용된 음성신호를 보여주고 있다. 신경망 구조는 Mackey-Glass 시계열 예측을 위해 사용된 구조와 동일하며, 신경망에서 사용된 변수 값들은 최적의 예측이 되도록 실험을 통해서 결정하였다.

음성신호 예측에 있어서 1000샘플 시험신호 중 앞부분 400 샘플 신호를 단 단계예측을 위한 학습신호로 1000번 학습하였으며, 학습 후 나머지 600샘플 신호에 대하여 비선형 예측을 수행하였다. 음성신호에 대한 학습에서도 Mackey-Glass 시계열 경우와 마찬가지로 GAM 신경망이 수렴속도와 안정성에서 다른 신경망보다 우수하였다.




그림 9. 예측에 사용된 음성신호
Fig. 9. Speech signal used in prediction




그림 10. GAM 신경망에 의한 음성신호 예측결과
Fig. 10. Prediction result of speech signal in GAM network





그림 11. 음성신호에 대한 예측오차 비교
Fig. 11. Prediction error comparison for speech signal

실험결과에 의하면 학습 및 시험 구간에 대해 모든 신경망 모델이 만족스런 예측결과를 보여주었는데, 그림 10은 음성신호 시험구간에 대한 GAM 신경망에 의한 예측결과이며, 그림 11은 시간영역에서 각 신경망 예측모델간의 오차 $|y(k) - \hat{y}(k)|^2$ 를 보여주고 있다. 그림에서 살펴보면 비정적인 성질을 갖는 음성신호의 경우에 대해서도 Mackey-Glass 시계열의 결과와 같이 제안된 GAM 신경망에 의한 예측결과가 다른 신경망 예측모델보다 더 우수함을 확인할 수 있다.


정량적 비교를 위해 식 (17)을 사용하여 계산된 결과가 표 1에 나타나 있는데, 제안된 GAM 신경망에 의한 예측결과가 FNN 모델에 의한 예측결과보다 2.76배, RNN 신경망보다 1.68 배 정도 우수하며, RNN 신경망은 FNN 신경망보다 1.64배 정도의 적은 오차를 보여주고 있다.

3.2 다단계예측

더 정확한 예측능력을 조사하기 위해서 일반적으로 다 단계 예측을 이용하여 평가하고 있다. 다 단계예측은 예측된 신호가 입력으로 케환되어 다시 사용된다는 사실을 제외하고는 실험 내용 및 방법, 그리고 신경망의 구조와 변수 값들은 단 단계예측 실험에서와 동일하다.



(a) Mackey-Glass 시계열에 대한 예측



(b) 음성신호에 대한 예측

그림 12. 예측모델들에 대한 다 단계 예측결과

Fig. 12. Multi-step prediction result for prediction models

그림 12는 Mackey-Glass 시계열과 음성신호에 대해 제안

된 GAM 신경망과 다른 신경망 모델들에 의한 다 단계 예측 결과를 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 GAM 신경망과 다른 신경망 예측모델들 모두 시간이 지남에 따라서 예측결과의 오차가 커지는 현상을 보이고 있는데 이는 예상된 결과이다. 그러나 시험신호들 모두에 대해 다른 예측모델들에 대한 예측결과가 제안된 신경망의 예측결과보다 다 단계 예측오차가 훨씬 크다.

3.3 실험결과 요약

위에서 실험한 예측결과를 요약하면 두 시험신호에 대해 RNN 신경망에 의한 예측은 FNN 신경망 예측보다 성능이 우수하며, GAM 신경망은 FNN과 RNN보다 예측성능이 더 우수하였다. 다른 연구에서 RNN이나 FNN이 선형 TDL 구조에서 LMS 알고리즘을 사용한 선형 예측보다 성능이 우수함을 보여주었으므로[15], 본 논문의 결과와 종합하면 제안된 GAM 신경망이 기존의 선형 TDL 예측모델과 FNN과 RNN 신경망들보다 비정적 신호에 대한 비선형 예측이 더 우수하다고 할 수 있다.

III. 결론


본 논문에서는 비선형 적응필터로 동적 다층 신경망을 이용한 신호예측을 다루고 있다. 특히, 기존의 다층 순방향 신경망의 동특성을 더욱 향상시키기 위하여 Gamma memory kernel을 추가한 신경망을 제안하고, 이 신경망을 이용하여 비선형 및 비정적 신호의 예측을 수행하였다. 비선형 예측성능의 상대적인 평가를 위해 비슷한 연결계수를 사용한 기존의 다층 신경망과의 예측결과를 살펴보면 제안된 신경망은 학습의 수렴속도와 시스템 정확도(안정성)에서 더 우수한 예측 성능을 보여주었다. 따라서 제안된 신경망은 비정적 신호에 대한 비선형 적응예측에 효과적인 예측모델로 사용할 수 있음을 확인하였다.

제안된 신경망은 시스템의 구조가 다소 복잡하지만 시스템 동특성이 더 향상된 신경망이므로 높은 차수의 비선형 및 비정적 시변 신호처리가 요구되는 다른 분야에서도 사용할 수 있는 신경망 모델이라 할 수 있다.

참고문헌


[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., Chicago, U.S.A., vol. 27, no. 6, Jul. 2000.*
- [7] S. Haykin, *Neural Networks: A Comprehensive Foundation*, IEEE Press, New York, 1994.
- [8] 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.
- [9] E. A. Wan, "Temporal backpropagation for FIR neural networks", in *Proc. Int. Joint Conf. Neural Networks*, vol. 1, pp. 575-580, 1990.
- [10] R. J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks", *Neural Comput.*, vol. 1, pp. 270-280, 1989.
- [11] J. L. Elman, "Finding structure in time", *Cognitive Science*, vol. 14, pp. 179-211, 1990.
- [12] M. Jordan, "Serial order: A parallel distributed processing approach", *Univ. California San Diego, Inst. Cognitive Science, ICS Rep. 8604*, 1986.
- [13] 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.
- [14] B. deVrijs and J. C. Principe, "The gamma model - A new neural model for temporal processing", *Neural Networks*, vol. 5, pp. 565-576, 1994.
- [15] 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.



김 종 인(Jong-In Kim)
 2000년 금오공과대학교
 전자제어공학과 (공학사)
 2004년 금오공과대학교
 전자제어공학과 (공학석사)
 2004년 ~ 현재 금오공과대학교
 박사과정 재학중

관심분야: 디지털 신호처리, 신경회로망, 영상처리



고 일 환(II-Whan Go)
 2002년 금오공과대학교
 전자제어공학과 (공학사)
 2004년 금오공과대학교
 전자제어공학과 (공학석사)
 2004년 ~ 현재 삼성전자 무선개발팀
 연구원

관심분야: 디지털 신호처리, 회로설계, 신경회로망



최 한 고(Han-Go Choi)
 1979년 경북대학교 전자공학과 (공학사)
 1988년 Univ. of Florida, USA
 전기 및 전자공학과 (공학석사)
 1992년 Univ. of Florida, USA
 전기 및 전자공학과 (공학박사)
 2001년 MIT, USA (Research Scientist)

1979년 ~ 1986년 국방과학연구소

1993년 ~ 현재 금오공과대학교 전자공학부 교수

관심분야: 디지털 및 적응신호처리, 영상처리, 신경회로망