

감마 다층 신경망을 이용한 시스템 식별

System Identification Using Gamma Multilayer Neural Network

고일환*, 원상철*, 최한고*

Il-Whan Go, Sang-Chul Won, Han-Go Choi

요약

동적 신경망은 temporal 신호처리가 요구되는 여러 분야에 사용되어 왔다. 본 논문에서는 다층 신경망의 동특성을 향상시키기 위해 감마 신경망(GAM) 다루고 있다. GAM 신경망은 순방향 다층 신경망의 히든층에 감마 메모리 커널을 사용하고 있다. GAM 신경망은 선형 및 비선형 시스템 식별을 통해 평가되었으며 상대적인 성능평가를 위해 순방향 신경망(FNN)과 리커런트 신경망(RNN)과 비교하고 있다. 실험결과에 의하면 GAM 신경망은 학습속도와 정확도에서 더 우수하게 동작하였으며, 이러한 사실은 시스템 식별에 있어서 GAM 신경망이 기존의 다른 다층 신경망보다 더 효과적인 신경망이 될 수 있음을 보여주었다.

Abstract

Dynamic neural networks have been applied to diverse fields requiring temporal signal processing. This paper presents gamma neural network(GAM) to improve the dynamics of multilayer network. The GAM network uses the gamma memory kernel in the hidden layer of feedforward multilayer network. The GAM network is evaluated in linear and nonlinear system identification, and compared with feedforward(FNN) and recurrent neural networks(RNN) for the relative comparison of its performance. Experimental results show that the GAM network performs better with respect to the convergence and accuracy, indicating that it can be a more effective network than conventional multilayer networks in system identification.

Keywords : Gamma neuron, Multilayer neural network, System identification

I. 서론

최근에 동적 신경망은 시스템 식별, 플랜트 제어, 패턴 인식, 시계열 예측, 비선형 필터링과 같이 temporal 신호 처리가 요구되는 분야에 많이 적용하고 있다[1-4]. 이 중 시스템 식별(identification)이란 미지의(unknown) 변수를 갖는 plant나 process를 모델링하는 것으로서, 신경망을 사용할 경우 plant의 입출력 데이터를 수집한 후 반복적인 학습을 통해 미지 시스템을 실험적으로 구한다. 신경망은 회로망 내부에 비선형적인 처리능력을 갖춘 유닛으로 구성되어 있고 주위 환경에 적응할 수 있는 학습능력을 갖고 있으므로 비선형 및 비정적 시스템 식별에 적절한 모델이라 할 수 있다. 그러나 미지 시스템의 비선형적 특성이 강할수록 만족스런 식별을 위해 동특성이 우수한 신경망이 요구되는데, 이러한 동적 신경망은 기존의 정적

신경망에 동특성을 추가하기 위해 신경망 내에 버퍼(buffer)를 두어 과거 입력에 대한 메모리로 사용하거나 케환(feedback)을 사용함으로써 신경망 내부에 temporal 동특성을 갖도록 하였다.

신경망 구조에서 가장 일반적으로 사용되고 있는 다층 신경망을 이용하여 지금까지 제안되어 구현되고 있는 동특성 신경망은 크게 두 부류로 대별된다. 첫 번째 구조로는 신경망 내에 버퍼를 사용하는 구조로 신경망 입력에 TDL(tapped delay line) 구조의 버퍼를 사용한 buffered 다층 퍼셉트론(multilayer perceptron, MLP)과 각 뉴런의 입력이 FIR(finite impulse response) 필터 시냅스(synapse)를 갖는 FIR 신경망 혹은 시지연 신경망(Time delay neural networks, TDNN)이 있다[5-7]. FIR 신경망 입력의 내부버퍼가 신경망의 외부버퍼로 구현될 수 있기 때문에 buffered MLP와 FIR 신경망은 이론적으로 동일하다고 할 수 있다.

두 번째로는 케환구조의 신경망인데 지역케환 신경망(locally RNN)과 광역케환 신경망(globally RNN)이 있다. 광역케환 신경망으로는 한 층의 모든 뉴런 출력들이 다른 층의 모든 뉴런 입력들과 연결된 구조, 즉, fully

* 금오공과대학교

투고 : 2008. 5. 23 수정완료 : 2008. 7. 14
게재확정일자 : 2008. 7. 25

connected 리커런트 신경망으로서 가장 대표적인 신경망으로 Elman과 Jordan 신경망이 있다[2,8-10]. 지역 궤환 구조로는 뉴런과 뉴런 사이에 이산시간 내부 메모리를 갖는 시냅스를 사용하고 있다. 즉, 기존의 시냅스를 FIR 필터나 IIR(infinite impulse response) 필터로 대체한 구조로서 이러한 FIR-MLP 혹은 IIR-MLP는 기존의 선형 FIR 혹은 IIR 필터의 비선형 확장으로 생각할 수 있다[11].

본 논문에서는 기존의 순방향 다층 신경망의 특성을 유지하면서 다층신경망의 동특성을 더욱 더 향상시키기 위해 하든 층의 기존 뉴런 대신에 gamma memory kernel[13]을 수정없이 사용하여 gamma 다층 신경망(GAM)이라 명명하고 시스템 식별을 수행하였다. GAM 신경망은 buffered 다층 퍼셉트론의 발전된 구조로서 비선형 동적 특성이 향상된 신경망이며, 학습방법으로는 오차 역전파(error backpropagation) 학습 알고리즘을 사용하였다. GAM 신경망이 기존의 다층 신경망보다 더 우수한 시스템 식별을 수행할 수 있음을 확인하기 위해 선형과 비선형 시스템 식별을 통해서 GAM 신경망 특성을 조사하였으며, 상대적인 성능평가를 위해 기존의 FNN과 다층 리커런트 신경망으로서 가장 많이 사용하고 있는 Elman RNN의 시스템 식별결과와 상호 비교함으로써 GAM 신경망이 시스템 식별에 더 우수한 신경망임을 확인하고자 한다. 시뮬레이션 결과를 살펴보면 GAM 신경망에 의한 시스템 식별은 FNN과 RNN보다 수렴특성과 시스템 안정성, 즉, 시스템 오차면에서 더 우수한 성능을 보여주었다.

II. Gamma 다층 신경망

GAM 신경망은 FNN 신경망과 Gamma memory의 합성구조이다. 그림 1은 신경망에 사용하고 있는 gamma memory의 신호 흐름도를 보여주고 있다[13].

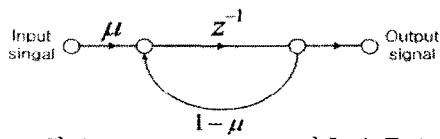


그림 1. gamma memory 신호 흐름도

Fig. 1. Signal flow of gamma memory

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

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

안정화를 위해 $G(z)$ 의 단 극점 $z=1-\mu$ 은 z 평면에서 단위 원 안에 존재하여야 한다. 즉, 조절 파라미터인 μ 는 다음 조건을 만족하여야 한다.

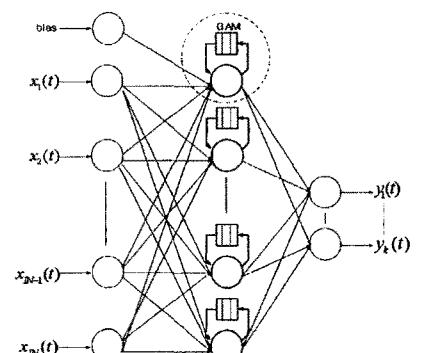
$$0 < \mu < 2 \quad (2)$$

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

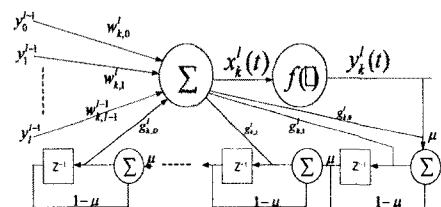
$$g(n) = \mu(1-\mu)^{n-1}, \quad n \geq 1 \quad (3)$$

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

그림 2는 gamma kernel을 포함하고 있는 GAM 신경망의 구조를 보여주고 있는데, 그림 2(a)에서와 같이 기존의 순방향 다층 신경망에서 하든층에 gamma 메모리 모듈이 추가되어 있다.



(a) 전체 신경망 구조



(b) 하든층 뉴런의 확대된 모습

그림 2. GAM 신경망 구조

Fig. 2. Structure of GAM neural network

그림 2(b)는 그림 2(a)의 점선 부분을 확대한 것으로 하든층 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, 하든 층의 모든 뉴런 출력이 입력층으로 재환되어 외부입력과 함께 입력으로 사용되는 구조가 Elman RNN이다.

Gamma 다층 신경망에 하든층에서의 출력은 다음과 같은 식으로 정의된다.

$$y_k^l(t) = f(x_k^l(t)) \quad (4)$$

$$x_k^l(t) = \sum_{i=0}^{N_l-1} w_{k,i}^l y_i^{l-1}(t) + \sum_{j=0}^K g_{k,D}^l z_{k,D}^l(t) + b_k^l \quad (5)$$

$$z_{k,D}^l(t) = (1-\mu)z_{k,D}^l(t-1) + \mu z_{k,D-1}^l(t-1) \quad (6)$$

$$\begin{aligned} z_{k,D}^l(t) &= y_k^l(t-1), & t > 0, D = 0 \\ z_{k,D}^l(t) &= 0, & t = 0, D > 0 \end{aligned} \quad (7)$$

여기에서, $g_{k,D}^l$ 은 l 층에서의 k 번째 뉴런에 연결되는 gamma memory의 weight 연결 모듈 D이다. $z_{k,D}^l$ 는 l 층에서의 k 번째 뉴런과 관련된 필터 모듈 D의 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 파라메터이다.

히든층과 출력층 뉴런의 내부 전달함수는 양극 시그모이드(bipolar sigmoid)함수를 사용하였으며, 출력층의 k 번째 뉴런 출력 $y_k(k)$ 과 다음과 같다.

$$y_k(k) = \phi(v_k(k)) = \frac{1 - e^{-s \cdot v_k(k)}}{1 + e^{-s \cdot v_k(k)}} \quad (8)$$

$$v_k(k) = \sum_{j=1}^{HN} w_{kj}(k) y_j(k) \quad (9)$$

여기서 s 는 양극 시그모이드 함수의 기울기이며, $y_j(k)$ 는 히든층 뉴런의 출력이고 $w_{kj}(k)$ 은 히든층의 j 번째와 출력층의 k 번째 뉴런간의 연결계수이다.

GAM 신경망의 학습방법은 아래와 같이 오차 역전파 알고리즘을 사용하였다.

$$\Delta w(k) = -\eta \frac{\partial J(k)}{\partial w(k)} + \alpha \Delta w(k-1) \quad (10)$$

$$J(k) = [e(k)]^2/2 = [d(k) - y(k)]^2/2 \quad (11)$$

위 식에서 $\Delta w(k)$ 는 개선될 연결강도 값이고, η 는 신경망의 학습율(learning rate), α 는 모멘텀률(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 $w(k)$ 가 변하게 된다.

상대적 성능 비교를 위한 FNN과 Elman RNN에서도 GAM 신경망과 같은 활성함수 및 학습방법을 사용하였다.

III. 실험결과

시스템 식별을 위한 접근 방법으로는 state-space 모델링이나 input-output 모델링을 사용하여 구현하고 있다. 그림 3은 input-output 모델링 방식으로서 신경망을 사용하여 시스템 식별을 수행하기 위한 구성도를 보여주고 있다. 신경망 출력 $\hat{d}(k)$ 은 실제 시스템 출력 $d(k)$ 의 추정치이며, 이들 간의 오차 $e(k)$ 는 다음과 같다.

$$\hat{d}(k) = f\{s(k-1), \dots, s(k-N), h(k-1), \dots, h(k-M)\} \quad (12)$$

$$e(k) = d(k) - \hat{d}(k) \quad (13)$$

여기서 N 은 미지 시스템 차수이며, $h(n)$ 은 신경망에서 히든 층이나 출력 층으로부터 입력층으로의 케환입력이

다. GAM과 FNN 신경망의 입력으로는 지연된 외부입력($s(k)$)만을 사용하였으며, RNN 신경망에서는 지연된 외부입력과 히든 층으로부터 케환된 신호($h(k)$)를 추가하여 사용하였다.

그림에서 미지의 시불변(time invariant) 시스템과 신경망에 인위적으로 발생시킨 랜덤 신호 $s(k)$ 를 가하여, 아래와 같이 실험에 사용될 입력과 출력 쌍을 생성한 후 오차 $e(k)$ 가 최소가 되도록 신경망을 학습함으로써 최적의 신경망 계수가 결정된다.

$$\{s(k), s(k-1), \dots, s(k-N)\}, d(k), \quad k = 1, 2, \dots, L \quad (14)$$

여기서 L 은 학습 데이터 구간을 나타낸다. GAM 신경망의 성능을 평가하기 위해 3.1과 3.2에서 기술된 선형 및 비선형 시스템 모델에 대해 실험하였으며, 상대적인 성능 평가를 위해 FNN과 RNN에 의한 식별결과와 상호 비교하였다.

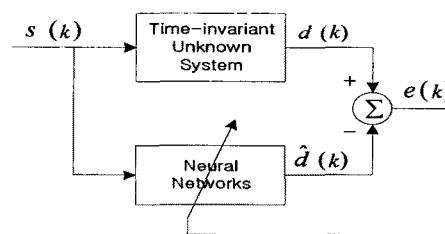


그림 3. 신경망을 사용한 시스템 식별

Fig. 3. System identification using neural networks

3.1 선형 시스템 식별

미지의 선형 시스템 식별을 수행하기 위해 다음 식으로 정의되는 시불변 시스템을 사용하였다.

$$d(k) = 0.921s(k) + 0.107s(k-1) + 0.336s(k-2) + s(k-3) + 0.336s(k-4) + 0.107s(k-5) + 0.921s(k-6) \quad (15)$$

사용된 신경망의 구조는 FNN의 경우 신경망 입력층 유닛은 4개, 히든층과 출력층의 유닛개수는 각각 6개와 1개로 (4x6x1)로 구성하였으며, 입력층에 바이어스 항도 추가하여 바이어스항의 계수도 개선하였다. RNN의 경우 (4x4x1)개의 뉴런으로 구성하였고, 히든층 출력을 입력층으로 케환시켰다. GAM 신경망은 4x6x1개의 뉴런으로 구성하였고, gamma memory의 개수는 8개로 설정하였다. 따라서 실험에 사용된 각 신경망 모델의 전체 계수 수는 FNN이 30개, RNN이 36개, GAM이 30으로서 상대적 성능비교를 위해 신경망 모델 간의 시스템 계수 수를 비슷하게 설정하였으며, 각 신경망의 학습율(0.03), 모멘텀율(0.01), 활성함수의 이득(1.0) 및 기울기(0.9) 등의 변수 값은 시스템 오차가 최소가 되도록 실험을 통하여 결정하였다.

입력 신호 $s(k)$ 는 평균이 영이고 1.0의 표준편차를 갖는 백색 가우시안 랜덤 신호이며, 학습과정에서 1000 샘

풀에 대해 안정된 수렴이 이루어질 때까지 1000번 학습을 수행하였다. 학습결과를 살펴보면 GAM 신경망이 다른 신경망보다 빠르게 수렴하였으며 더 안정된 시스템 오차를 보여주었다. 그럼 4와 5는 사용된 신경망 모델들에 대해 샘플구간 100~200과 주파수 구간 0~0.5(rad)에서 시스템 식별결과를 확대한 것으로서, 시간영역과 주파수 영역에서 선형 시스템 출력(점선으로 표시)과 각 신경망 출력(실선으로 표시)과의 차이를 확인할 수 있다.

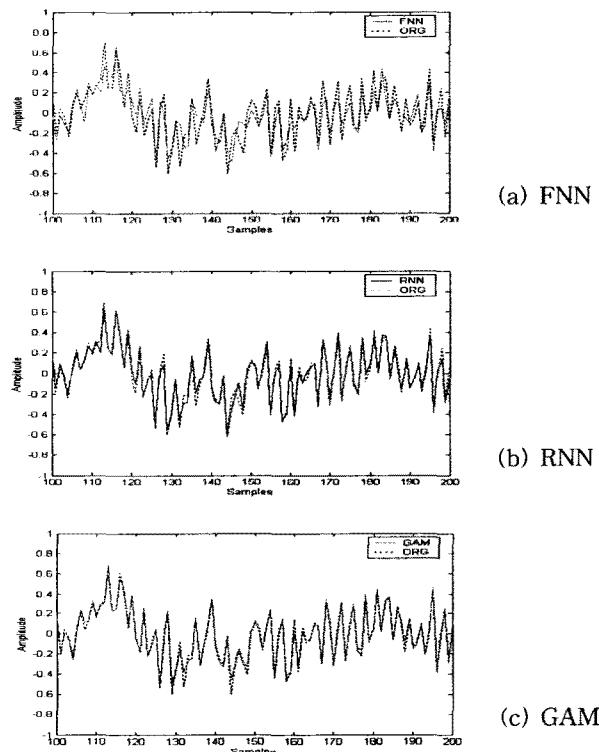


그림 4. 샘플구간 100~200에서의 선형 시스템 식별결과
Fig. 4. Identification results of linear system in sample 100~200

그림을 통해서 GAM 신경망이 다른 신경망보다 우수함을 확인할 수 있으나 시스템 식별결과에 대한 정확한 성능차이를 정량적으로 조사하기 위해 아래 식을 사용하여 시간과 주파수 영역에서 오차를 상호 비교하였다.

$$t_{err} = \frac{1}{N} \sum_{k=N_1}^{N_2} |d(n) - \hat{d}(n)|^2 \quad (16)$$

$$f_{err} = \frac{1}{N} \sum_{k=N_1}^{N_2} \|fft(d(n)) - fft(\hat{d}(n))\|^2 \quad (17)$$

여기서 $d(n)$ 과 $\hat{d}(n)$ 은 미지 시스템과 신경망의 출력을 각각 나타낸다. 표 1은 각 신경망에 대해 위 식을 사용하여 계산된 결과로서 시스템의 계수 초기치가 서로 다른 조건에서 5번을 반복하여 평균한 값들이다. 시간영역에서 살펴보면 GAM에 의한 시스템 식별이 FNN보다 9배 정

도, RNN에 비해 1.77배 정도 우수하였으며, RNN은 FNN에 비해 5.09배 정도 우수하였다. 주파수 영역에서는 GAM에 의한 시스템 식별은 FNN보다 8.83배 정도, RNN에 비해 1.6421배 정도 우수하였으며, RNN은 FNN에 비해 5.379배 우수하였다. 따라서 선형 시스템 식별에서 시간과 주파수 영역 모두 GAM 신경망이 다른 신경망에 비해 우수하며, RNN 신경망은 FNN 보다 우수한 성능을 보여주었다.

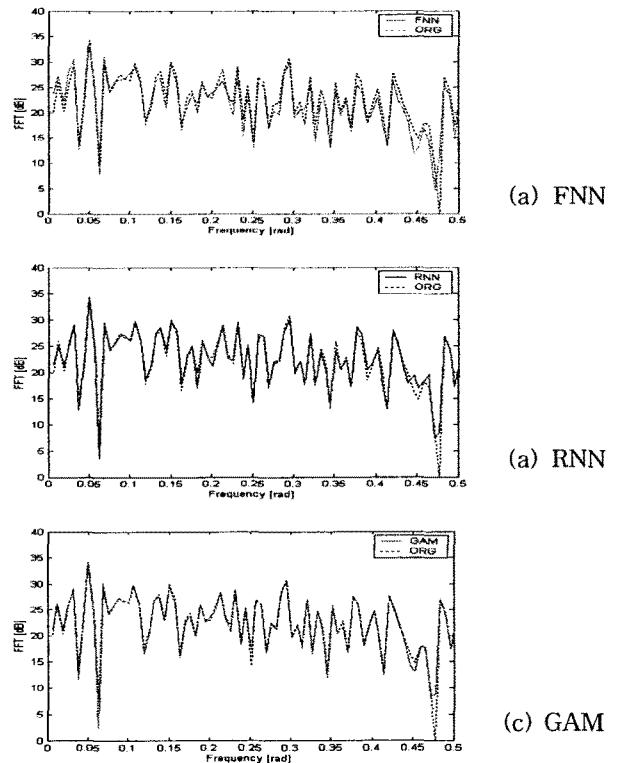


그림 5. 주파수 구간 0~0.5[rad]에서 선형시스템 식별결과
Fig. 5. Identification results of linear system in frequency 0~0.5[rad]

표 1. 선형 시스템 식별에서 시간과 주파수 영역에서 신경망 모델간의 오차 비교
Table 1. Error comparison of time and frequency domains among network models in linear system identification

신경망	오차	
	t_{err}	f_{err}
FNN	0.0163	6.9681
RNN	0.0032	1.2953
GAM	0.0018	0.7888

3.2 비선형 시스템 식별

미지의 비선형 시스템 식별을 위해 아래와 같은 차분방정식으로 정의되는 서로 다른 두 시스템을 사용하였는

데, 첫 번째 시스템은 Back-Tsoi[12]가 사용한 시스템이며, 두 번째 시스템은 선형 시스템 식별에 사용하였던 시스템에 비선형 특성을 추가하여 사용하였다.

(1) 비선형 시스템 #1

$$\begin{aligned} z(k) = & 0.0154s(k) + 0.0462s(k-1) + 0.0462s(k-2) + \quad (17) \\ & 0.0154s(k-3) + 1.99z(k-1) - 1.572z(k-2) + \\ & 0.4583z(k-3) \end{aligned}$$

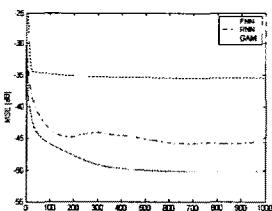
$$d(k) = \sin(z(k)) \quad (18)$$

(2) 비선형 시스템 #2

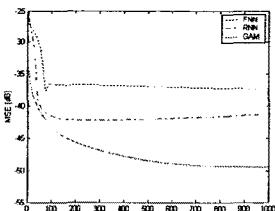
$$\begin{aligned} d(k+1) = & 0.15d(k) + 0.3d(k-1) + 0.1s^3(k) + \quad (19) \\ & 0.18s^2(k) + 0.921s(k) + 0.107s(k-1) \\ & + 0.336s(k-2) + s(k-3) + 0.336 \\ & s(k-4) + 0.107s(k-5) + 0.921s(k-6) \end{aligned}$$

비선형 시스템 식별에 사용된 신경망 구조와 계수의 수, 시스템 변수 값, 입력신호, 그리고 학습방법들은 선형 시스템 식별의 경우와 동일하게 사용하였다.

그림 6은 비선형 시스템 #1과 #2의 모델링에 대한 학습오차 변화과정을 보여주고 있는데 GAM 신경망이 다른 신경망보다 수렴속도와 시스템 오차면에서 더 우수한 수렴특성을 보여주고 있다. 그림 7과 8은 신경망 모델들에 대해 시간과 주파수 영역에서 비선형 시스템 #1의 식별 결과의 일부(시간영역에서의 샘플구간 100~200과 주파수 구간 0~0.5[rad])를 보여주고 있는데, 그림에서 비선형 시스템 출력(점선으로 표시)과 각 신경망 출력(실선으로 표시)을 통해 각 모델의 식별능력과 모델간의 식별차 이를 확인할 수 있다.



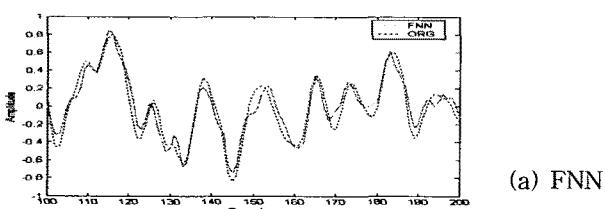
(a) 시스템 #1



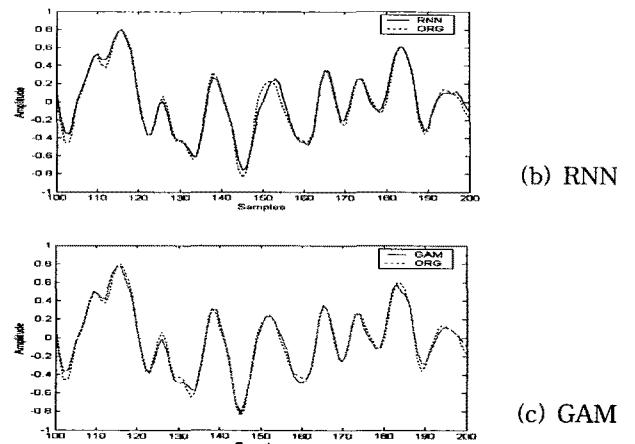
(b) 시스템 #2

그림 6. 비선형 시스템의 학습오차 변화과정

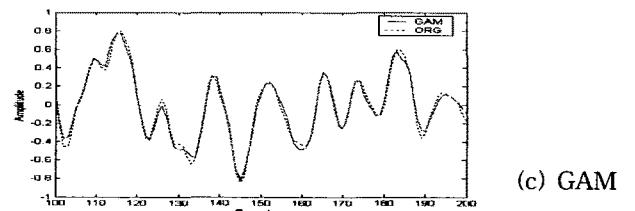
Fig. 6. Comparison of learning error for nonlinear systems



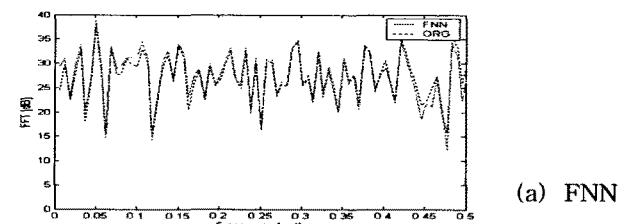
(a) FNN



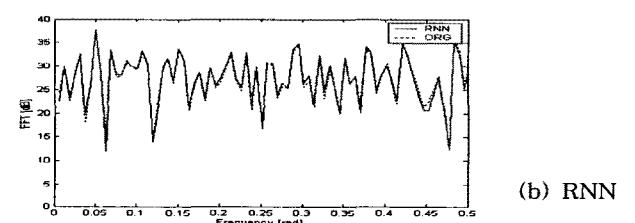
(b) RNN



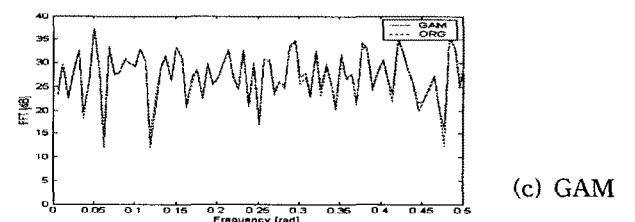
(c) GAM

그림 7. 샘플구간 100~200에서 비선형 시스템 #1 식별결과
Fig. 7. Identification results of nonlinear system #1 in samples 100~200

(a) FNN



(b) RNN



(c) GAM

그림 8. 주파수 구간 0~0.5(rad)에서 비선형 시스템 #1 식별 결과

Fig. 8. Identification results of nonlinear system #1 in frequency 0~0.5[rad]

위의 그림으로부터 GAM 신경망이 더 우수한 시스템 모델링 성능을 보여주고 있음을 추측할 수 있으며, 비선형 시스템 #2에 대해서도 시스템 #1의 식별결과와 유사하였다. 그러나 정확한 성능차이는 확인할 수 없으므로 정량적인 성능평가를 위해서 시간영역과 주파수 영역에서 식 (16)과 식 (17)을 사용하여 각 신경망에 대해 계산한 결과를 상호 비교하였다. 표 2는 두 시험 모델에 대한 결

과를 비교하고 있는데, 표에 나타난 수치는 시스템 계수의 초기치가 서로 다른 조건에서 5번 반복 수행 후 평균하였다.

시험 모델 #1에 대해 시간영역에서 GAM의 시스템 식별 성능은 FNN과 RNN에 비해 3.4375배와 1.875배 정도 우수하며, 주파수 영역에서는 6.01배와 1.191배 정도 더 우수하였다. 그리고 RNN의 시스템 식별 성능이 FNN보다 시간영역에서 1.733배, 주파수 영역에서 5.042배 정도 우수하였다. 시험 모델 #2에 대해 시간영역에서 GAM의 시스템 식별 성능은 FNN과 RNN에 비해 6.538배와 2.575배 정도 우수하며, 주파수 영역에서는 6.138배와 2.288배 정도 더 우수하였다. 그리고 RNN의 시스템 식별 성능은 FNN보다 시간영역에서 2.575배, 주파수 영역에서 2.288배 정도 우수하였다. 요약하면 선형 시스템 식별 경우처럼 케환 구조를 갖는 RNN이 케환 구조가 없는 FNN에 비해 더 우수한 비선형 시스템 식별을 수행하였으며, GAM은 RNN보다 더 정확하게 비선형 시스템을 모델링하였다.

표 2. 비선형 시스템 식별에서 시간과 주파수 영역에서 신경망 모델간의 오차 비교

Table 2. Error comparison of time and frequency domains among network models in nonlinear system identification

신경망	비선형 시스템 #1		비선형 시스템 #2	
	<i>t_err</i>	<i>f_err</i>	<i>t_err</i>	<i>f_err</i>
FNN	0.0052	9.7355	0.0085	10.367
RNN	0.0030	1.9307	0.0033	4.5307
GAM	0.0016	1.6200	0.0013	1.6890

3.3 시뮬레이션 결과

시스템 식별에 대해 위에서 실험한 결과를 요약하면 다음과 같다. 선형 시스템과 비선형 시스템 식별에 대해서 RNN이 FNN보다 성능이 우수하였고, GAM 신경망이 다른 두 신경망보다 더 우수하였다. 특히, 신경망간의 상대적인 오차차이에서 선형 시스템 식별의 경우 비선형 시스템에 비해 RNN이 FNN보다 훨씬 더 우수한 성능을 보여주었으며, 비선형 시스템 식별의 경우 선형 시스템에 비해 GAM이 RNN 보다 더 우수한 시스템 식별을 수행하였다. 이와 같은 결과는 시간영역과 주파수 영역 모두에서 비슷한 성능 차이를 보여주었다.

IV. 결 론

본 논문에서는 기존의 순방향 다층 신경망에 동특성을 향상시키기 위해 gamma memory kernel을 추가한 신경망을 사용하여 시스템 식별을 수행하였다. 실험결과에 의하면 GAM 신경망은 선형 시스템뿐만 아니라 비선형 시스템의 식별을 수행하는데 있어서 기존의 FNN과 RNN 신경망보다 식별성능이 우수하였다. 즉, 서로 다른 세 시험 모

델에 대해 GAM 신경망은 신경망의 학습 수렴속도와 식별오차에서 더 우수한 모델링 성능을 갖고 있음을 확인함으로써 시스템 식별을 수행하는데 우수한 신경망 모델이라 할 수 있다.

GAM 신경망은 시스템 구조가 다소 복잡하지만 시스템 동특성이 기존의 다층 신경망에 비해 향상되었으므로 더 높은 차수의 비선형 및 비정적 시변 신호처리뿐만 아니라 temporal 동특성이 요구되는 다른 분야에서도 사용할 수 있으리라 판단된다.

참고문헌

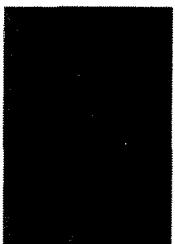
- [1] R. Grino, G. Cembrano, and C. Torras, "Nonlinear system identification using additive dynamic neural networks - two on-line approaches", IEEE Transaction on circuits and systems a publication of the IEEE Circuits and System Society. I, Fundamental theory and applications, vol. 47, no. 2, pp. 150-165, 2000.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] S. Haykin, Neural Networks: A Comprehensive Foundation, IEEE Press, New York, 1994.
- [6] 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.
- [7] E. A. Wan, "Temporal backpropagation for FIR neural networks", in Proc. Int. Joint Conf. Neural Networks, vol. 1, pp. 575-580, 1990.
- [8] R. J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks", Neural Comput., vol. 1, pp. 270-280, 1989.
- [9] J. L. Elman, "Finding structure in time", Cognitive Science, vol. 14, pp. 179-211, 1990.
- [10] M. Jordan, "Serial order: A parallel distributed processing approach", Univ. California San Diego, Inst. Cognitive Science, ICS Rep. 8604, 1986.

- [11]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.
- [12]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.
- [13]deVries B. and J.C. Principe, "The gamma model -
A new neural model for temporal processing",
Neural Networks, vol. 5, pp.565-576, 1998.
-



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

관심분야: 디지털 신호처리, 신경망, 적응제어



원 상 철 (Sang-Chul Won)
1999년 금오공과대학교
전자제어공학과 (공학사)
2001년 금오공과대학교
전자제어공학과 (공학석사)
2001년 ~ 현재 삼성전자 영상
디스플레이 사업부, 연구원

관심분야: 영상신호처리, 신경망, TV Color mapping



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, 연구원
1993년 ~ 현재 금오공과대학교 전자공학부 교수

관심분야: 실시간 DSP, 패턴인식, Machine Vision
