

다층 신경 회로망과 가우시안 포텐셜 함수 네트워크의 구조적 결합을 이용한 효율적인 학습 방법

正會員 朴 相 奉* 正會員 朴 來 正* 正會員 朴 哲 薰*

Efficient Learning Algorithm using Structural Hybrid of Multilayer Neural Networks and Gaussian Potential Function Networks

Sangbong Park*, Lae-Jeong Park* and Cheol Hoon Park* *Regular Members*

要 約

기울기를 따라가는 방식(gradient descent method)에 바탕을 둔 오류 역전파(EBP: Error Back Propagation) 방법이 가장 널리 사용되는 신경 회로망의 학습 방법이지만, 문제 해결의 정확성을 얻기 위해서는 상당한 노력과 시간이 요구된다. 본 논문은 EBP 학습 방법에서 문제가 되는 지역 최소값(local minima), 느린 학습 시간, 신경망 구조(structure), 그리고 초기의 연결 강도(interconnection weight) 등을 기존의 다층 신경 회로망에 지역적인 학습 능력을 가진 가우시안 포텐셜 네트워크(GPFN: Gaussian Potential Function Networks)를 병렬적으로 부가하여 해결함으로써 지역화된 오류 학습 패턴들이 나타내는 문제에 대하여 학습 성능을 향상시킬 수 있는 새로운 학습 방법을 제시한다. 함수 근사화 문제에서 기존의 EBP 학습 방법과의 비교 실험으로 제안된 학습 방법이 보다 개선된 일반화 능력과 빠른 학습 속도를 가짐을 보여 그 효율성을 입증한다.

ABSTRACT

Although the error backpropagation(EBP) algorithm based on the gradient descent method is a widely-used learning algorithm of neural networks, learning sometimes takes a long time to acquire accuracy. This paper develops a novel learning method to alleviate the problems of EBP algorithm such as local minima, slow speed, and size of structure and thus to improve performance by adopting other new networks, Gaussian Potential Function networks(GPFN), in parallel with multilayer neural networks. Empirical simulations show the efficacy of the proposed algorithm in function approximation, which enables us to train networks faster with the better generalization capabilities.

* 한국 과학 기술원 전기 및 전자공학과
Department of Electrical Engineering Korea Advanced Institute of Science and Technology
論文番號: 94195
接受日字: 1994年 7月 23日

I. 서 론

인간의 행동과 뇌를 모사하는 인공 신경 회로망과 같은 지능 시스템은, 기존의 방법으로는 만족할 만한 성능을 얻지 못하는 분야에 대한 하나의 해결방안으로써 상당한 주목을 끌어들였다. 일반적으로, 신경 회로망은 입력과 출력에 관한 정보만으로 신경 회로망내의 시그모이드 활성화 함수를 사용하는 기본적인 비선형 유닛과 그 연결 강도들을 이용해서 시스템의 입출력간 관계를 학습하는 일종의 정보 처리 시스템이다. 지금까지 신경 회로망은 패턴 인식, 시스템 동정화(identification), 신경망 제어기 구축, 그리고 시계열 정보의 예측 등과 같은 여러 응용 분야에서 좋은 성과를 보였다. 대부분은 시그모이드 유닛을 가진 신경 회로망에 EBP 학습 방법을 사용[1, 2, 3]하거나 Radial Basis 함수 네트워크(RBFN)[4]를 사용하였으며, 미분을 통한 학습 방법이 힘들 경우에는 유전 알고리즘(Genetic Algorithm)과 같은 탐색(search) 방법[5, 6]도 이용하였다. 신경 회로망에서 가장 중요한 것은 주어진 문제에 적합한 최적의 구조를 구하는 것과 효과적인 학습 알고리즘을 얻는 것이다. 본 논문에서는 주학습 알고리즘으로 가장 널리 이용되는 EBP 학습 방법을 이용한다. 비록 미분 가능한 squashing 활성화 함수를 가진 다층 신경 회로망(MLP : Multi-Layer Perceptrons)이 2층 구조만으로 N 차원에 정의된 어떤 연속 함수도 근사화가 가능하지만[7], 주어진 성능을 얻기 위해서는 신경망의 은닉 노드의 갯수나 초기 연결강도 설정에 많은 노력과 시간이 소요되며, 때때로 지역 최소값으로 인해 많은 학습 시간이 요구되거나, 학습 자체가 실패한다. 비록 연결 강도 공간의 차원을 매우 크게 늘리는 것이 하나의 해결책으로 제시될 수도 있지만, 반드시 모든 차원에서 그것이 효과적임은 보이기 힘들며, 오히려 학습 시간과 신경망의 일반화 능력에 역효과가 미친다[8]. S. E. Fahlman 등에 의해 제안된 Cascaded Correlation 방법은 학습 속도의 향상과 자율적인 구조 결정 등에는 효과적이거나[9], 함수 근사화 문제에서 중요한 일반화 능력 성능이 떨어지며 필요 이상의 은닉 노드가 생성된다[10]. 최근에는 주어진 신경망 구조에서 은닉 층의 노드 갯수를 노드간 또는 노드와 출력 단간의 상호관련성에 정보 이론(Information Theory)를 이용하거나, 최적 함수 근사화 이론에 따라 각 은닉층의 갯수를 결정하는 방법들이 제시되었다[11, 12]. 그러나,

EBP를 이용한 MLP의 여러 문제를 효율적으로 해결하기 위한 다른 방법으로 주어진 신경 회로망만 의존하지 않고 다른 부수 네트워크를 이용하거나 EBP 학습 방법의 다른 학습 알고리즘을 부가적으로 이용함으로써, 학습 성능을 향상시킬 수 있다[10, 13].

MLP와 RBFN은 모두 잘 알려진 함수 근사화기이지만, 시그모이드 유닛을 가진 MLP은 유닛의 문제 공간에 대한 전체적인 학습능력의 특성에 의해 일반화 특성이 우수하나 아주 빠르게 변화하는 부분이나 침점 지역을 학습하는 데 상당한 시간이 요구되며, 한편으로 RBF 중에 하나인 GPFN은 쉬운 학습 방법과 이론적으로 최적의 근사화가 가능하기 때문에 [14] 다양한 분야에서 응용되어왔는데, 입력 공간에서 일정한 영역에서만 활성화되는 유닛의 지역적 특성 때문에 문제 공간이 크고 복잡한 경우에는 주어진 학습 성능을 얻기 위해서는 상당히 많은 은닉 노드가 필요하다. 본 논문에서 제안하는 학습 방법은 신경망내의 노드 수의 증감이 아니고, 그림 1에서처럼 네트워크간의 효과적 결합을 통해 학습 성능을 향상시키는 방법이다. MLP와 GPFN의 결합은 이미 패턴 분류의 응용에 제시되어, 그림 2와 같이 오류가 나타나는 패턴이 지역화되고 집단화되는 문제에 적용하여 그 가능성을 보였는데[15], 본 논문은 함수 근사화 문제에서 MLP와 GPFN의 서로의 장단점을 보완하기 위해, MLP 학습을 통해 지역화된 오류 패턴들을 MLP와 병렬로 부가된 GPFN으로 학습시킴으로써 빠른 학습 속도와 좋은 일반화 능력을 얻을 수 있는 학습 방법을 제시한다. 오류 패턴들이 카오스 시계열




그림 1. 신경망과 GPFN의 구조적 결합된 제안된 모델.
Figure. 1. Structural hybrid of MLP and GPFN.




그림 2. 신경망 학습시 지역화된 오류 패턴들이 나타나는 도넛 형태의 학습 패턴.
 Figure. 2. Donut-type training data which show local error patterns in learning.

정보의 예측에서와 같이 입력공간에 균일하게 분포되어 있는 경우는 지역적 특성을 갖는 GPFN으로 그 보상이 어렵고 이때는 GPFN 대신 새로운 신경회로망을 부가적으로 첨가하여 오류를 보상한다[10].

다음 장에서는 제안된 신경 회로망의 학습 방법에 대해 구체적으로 설명하고, 3장에서는 제안된 학습 방법의 우수성을 보이기 위해 함수 근사화에 관한 기존의 방법들과 컴퓨터 시뮬레이션 결과를 비교, 고찰한다. 마지막으로 4장에서 결론을 맺는다.

II. 제안된 MLP와 GPFN의 구조적 결합 방법

RBFN은 임의의 연속 함수를 입력 공간에서 단지 제한된 좁은 지역에서만 반응하는 지역화된 bump 형태의 응답을 가진 유닛을 이용하여 하나의 은닉 층만으로 표현가능하며[16], 각 지역은 지역내의 패턴들을 이용하여 그 편차(variance)와 그 평균값을 얻을 수 있다. GPFN은 다음과 같이 정의될 수 있다.

$$f(\vec{x}) = \sum_{i=1}^M C_i \exp(-(\vec{x} - m_i)^t K^2(\vec{x} - m_i)) \quad (1)$$

여기서 \vec{x} 는 입력 데이터, m_i , C_i 그리고 K^2 은 각각 i 번째 노드의 평균 벡터, 은닉 노드와 출력 단간의 연결 강도, 상호 편차 행렬이다.

각 은닉 노드의 평균, 편차, 연결 강도등의 변수들은 매 순간 제공되는 입력 데이터를 이용하여 gradient descent 방법으로 구해지며, 필요한 은닉 노드의

갯수 또한 주어지는 학습 패턴에 따라 자동적으로 설정되는 자율적 조직 학습 방법(SOL: Self-Organizing Learning)[17]을 따른다. 그러나, 초기 평균값, 초기 편차값, 그리고 SOL에서 필요한 오차 한계값등 변수 등을 각 문제 영역에 따라 결정하는 데 많은 노력이 필요하다. 예를 들어 초기 편차값이 클 경우에는 주어진 학습 성능을 얻기위해서 많은 학습 시간이 소요되며, 오차 한계값이 너무 작을 때는 많은 수의 은닉 노드가 생성된다. 이론적으로 각 입력 데이터에 하나의 은닉 노드가 생성된다면 학습면에서는 좋은 성능을 보일 것이다. 비교적 쉬운 학습 방법에도 불구하고 GPF 유닛의 지역화 특성때문에 주어진 문제가 복잡할 경우에는 입력 데이터에 따라 MLP 보다 훨씬 많은 수의 은닉 노드가 필요하며 일반화 특성도 좋지 못하다.

따라서, EBP를 이용한 신경망 학습에 나타나는 문제를 효과적으로 해결하기 위해, 신경망의 학습 후 평균적인 오차 미인 이상의 오차를 가진 지역화된 데이터들을 제한된 영역에서만 활성화되는 GPF 유닛의 특성을 이용하여 신경망의 오차를 GPFN이 효과적으로 보상한다. 제안된 GPFN을 이용한 학습 방법은 그림 3에 설명되어져 있으며, 그림 1은 제안된 모델의 전체적인 구조이다.

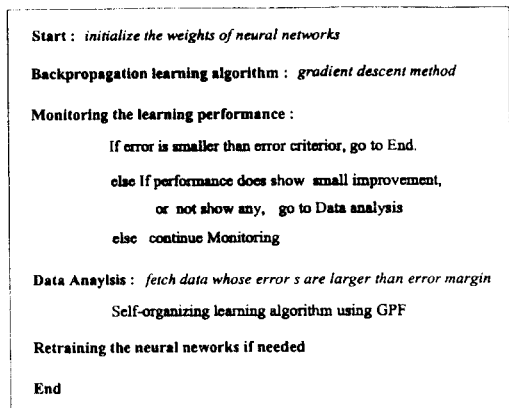


그림 3. 제안된 학습 방법의 전체적인 흐름도.
 Figure. 3. The outline of the proposed learning algorithm.

III. 실험

제안된 학습 방법과 구조의 효율성을 보이기위해,

정적 시스템과 동적 시스템에 대하여 각각 기존 MLP의 EBP, GPFN과 제안된 학습 방법과의 학습 성능을 컴퓨터 비교, 실험을 해 보았다. 학습 성능은 MLP의 EBP, GPFN의 SOL 방법, 그리고 제안된 학습 방법이 학습 속도, root mean square(rms) 오차, 그리고 사용된 은닉 노드의 갯수등의 관점에서 각각 비교되었다.

식 (2)는 주어진 영역에서 복잡한 함수(그림 4)의 근사화 문제에 대하여 고려된 정적 시스템이다.

$$f(x_1, x_2) = 1.9(1.35 + e^{x_1} \sin(15(x_1 - 0.6)^2))e^{-x_2} \sin(8x_2). \quad (2)$$




그림 4. 함수 $f(x_1, x_2) = 1.9(1.35 + e^{x_1} \sin(15(x_1 - 0.6)^2))e^{-x_2} \sin(8x_2)$.
Figure. 4. Perceptive graph of function $f(x_1, x_2) = 1.9(1.35 + e^{x_1} \sin(15(x_1 - 0.6)^2))e^{-x_2} \sin(8x_2)$.

식 (2)의 함수에서 학습 입력 데이터는 2차원의 $[0, 1]^2$ 영역에서 랜덤하게 300개를 선택했으며, 일반화 성능을 평가하기 위해 격자로 5,000개의 데이터를 추출했다.

그림 5는 MLP의 EBP와 신경 회로망의 재학습 기능을 가진 제안된 학습 방법간의 학습 속도에 관한 비교이다. 사용된 신경망의 구조는 2-6-3-1이다. 제안된 학습 방법에서 GPFN은 MLP 학습 방법으로 어느 정도 학습이 이루어진후 학습 성능을 일정한 학습 횟수에서 평가함으로써 MLP 학습만으로 더이상 학습 성능이 향상되지 않거나 그 속도가 미진할 때 활성화되었다. 학습의 정확도와 생성된 은닉 노드의 갯수, 학습 속도들이 학습 변수들에 의해 전체 학습 성능에 상당한 영향을 미치기 때문에 주의가 필요하다. 실험 상에서 GPFN의 학습을 위해서, 은닉 노드와 출력 노드간의 연결 강도, 그리고 노드내의 편차와 평균

벡터의 학습율은 각각 0.03, 0.002, 0.001로 설정했다. 20번의 실험을 통한 MLP와 제안된 학습 방법, GPFN의 성능 비교는 표 1에 나타나 있다. GPFN은 주어진 입력 데이터에 대하여 GPF 유닛을 설정하는 자율적 조직 학습을 사용함으로써 학습 변수가 설정된 후 한번의 실험이 이루어 졌다. MLP의 재학습을 통해서 제안된 학습 방법이 재학습이 없는 것에 비해 좋은 일반화 능력을 보이지만, 그만큼 많은 학습 시간이 필요하며, 재학습을 위해 사용되었던 모든 입력 데이터가 저장되어 있어야 한다. 실험 결과에서 GPFN은 학습 초기에 빠른 속도의 학습을 보여주었으나 좋은 일반화 능력을 얻기위해 네트워크의 파라미터 학습에 비교적 많은 시간을 소요했다. GPFN은 주어진 문제에 대해 많은 은닉 노드(30개)가 생성되었으며, 우수한 일반화 능력을 보여준다. 한편 제안된 학습 방법은 신경망의 구조나 초기 연결 강도에 관한 여러 번의 시행착오 없이, 그리고 GPFN에서 나타나는 은닉 노드의 생성 갯수나 일반화 능력 문제 등을 MLP 학습에 나타난 오차를 발생시키는 패턴들을 GPFN을 통해 기억 학습시킴으로써 효과적으로 좋은 학습 성능을 보이며, 지역화된 데이터를 이용하여 GPFN을 학습 시키기 때문에 비교적 적은 수(16.7개)의 은닉 노드가 생성되었다. 제안된 MLP + GPFN구조는 모두 25.7개(6 + 3 + 16.7)의 은닉 노드가 사용되었으나, MLP(BP)구조에서 임의로 은닉 노드 수의 증가는 CPU 학습시간이나 일반화 능력 면에서 제안된 구조와 비교할 때 좋은 성능을 보여주지 못했다. 제안된 학습 방법은 20번의 다른 랜덤 초기화 실험에서 18번에 대하여 GPFN이 활성화 되었다. 표 1에서 GPFN이 정적인 시스템에 대해서 주어진 공간에서




그림 5. MLP(BP)와 제안된 MLP(BP) + GPFN의 학습 성능에 관한 비교.
Figure. 5. Comparison of learning performance between MLP(BP) and MLP(BP) + GPFN.

표 1. $f(x_1, x_2) = 1.9(1.35 + e^{x_1} \sin(15(x_1 - 0.6)^2) e^{-x_2} \sin(8x_2))$ 를 이용한 복잡한 함수 근사화 문제에 대한 MLP(BP), GPFN과 제안된 MLP(BP) + GPFN과의 일반화 성능 비교.

Table 1. Comparison of generalization capabilities for function approximation of $f(x_1, x_2) = 1.9(1.35 + e^{x_1} \sin(15(x_1 - 0.6)^2) e^{-x_2} \sin(8x_2))$ between MLP(BP), GPFN, and proposed MLP(BP) + GPFN.


	MNNs			GPFN	MNNs + GPFN	
	MNNs I (2-6-3-1)		MNNs II (2-15-6-1)		MNNs(2-6-3-1)	
Iter.	15,000	30,000	15,000	2,000	1,000(GPFN) Avg : 8720 + 1,500(retrain)	
Min.	1.98xe-1	1.88xe-1	1.60xe-1		1.05ex-1	1.00xe-1
Avg.	2.88xe-1	2.31xe-1	2.33xe-1	5.43xe-2	1.64xe-1	1.49xe-1
STD.	9.13xe-2	4.49xe-2	8.32xe-2		3.72xe-2	3.20xe-2
#.GPF				30	16.7	16.7
#.var	43		148	330	226.7	

* In MNNs + GPFNs, for 2 of 20 trials GPFNs are not generated.


* MNNs + GPFNs : Avg 585 sec. (CPU time for 18 trials)

* MNNs I (15,000 Iter.) : 622 sec.


* GPFNs(2,000 Iter.) : 731 sec.



(a)



(c)



(b)

그림 6. 각 학습 방법에 대한 일반화 성능: (a) 제안된 학습 방법, (b)GPFN, (c)MLP(2-6-3-1).

Figure 6. Generalization capabilities for each learning algorithm: (a)proposed learning algorithm, (b)GPFN, (c)MLP(2-6-3-1).

충분한 데이터가 있는 경우 적은 학습 횟수에 비해 가장 좋은 일반화 성능을 보여주나, 학습에 필요한 변수에 대해서는 가장 많은 수(330개)가 요구되며, 주어진 학습 횟수에서 많은 CPU 시간이 소요된다. 그림 6은 주어진 학습 횟수에서 각 학습 방법에 대한 일반화 성능을 그래프로 보여준다. GPFN이 적은 학습 횟수에 비해 비교적 좋은 일반화 성능을보여주나 부분적으로 local 특성이 아직 존재하며, 제안된 학습

방법은 MLP와 GPFN의 global과 local 특성을 적절히 이용함으로써 적은 학습 시간에 비해 전체적으로 우수한 일반화 능력을 보여준다.

동적인 시스템에 대하여 기존의 방법들과 제안된 학습 방법과의 비교를 위해 다음과 같은 비선형 동적 시스템이 고려되었다.

$$y(k+1) = \frac{y(k)}{(1+y(k)^2)} + u(k)^3. \quad (3)$$

학습을 위해 고려된 입력 데이터는 특정 주파수와 그 harmonics로 이루어진 sine 함수의 선형합으로 이루어졌으며(식 4), 공정한 성능 비교를 위해 각각 15번의 실험을 통해 평균, 편차를 구했다. 학습된 네트워크의 일반화 능력을 알기 위해 식 5의 신호에 대하여 각각 고, 중, 저주파수와 그 harmonics로 이루어진 테스트 신호(식 6-8)들로 시스템의 tracking 문제에 적용해 보았다.

$$\begin{aligned} \text{Train Signal : } y(k+1) = & 1.5 \left[0.3 \sin\left(\frac{2\pi k}{25}\right) + \right. \\ & 0.1 \sin\left(\frac{2\pi k \times 3}{25}\right) + 0.15 \sin\left(\frac{2\pi k \times 5}{25}\right) + \\ & 0.12 \sin\left(\frac{2\pi k \times 7}{25}\right) + 0.1 \sin\left(\frac{2\pi k \times 9}{25}\right) + \\ & \left. 0.15 \sin\left(\frac{2\pi k \times 11}{25}\right) + 0.1 \sin\left(\frac{2\pi k}{250}\right) \right]. \quad (4) \end{aligned}$$

$$\text{Test Singal : } y(k+1) = 0.3 \sin\left(\frac{2\pi k}{F}\right) +$$

$$\begin{aligned} & 0.1 \sin\left(\frac{2\pi k \times 3}{F}\right) + 0.15 \sin\left(\frac{2\pi k \times 5}{F}\right) + \\ & 0.12 \sin\left(\frac{2\pi k \times 7}{F}\right) + 0.1 \sin\left(\frac{2\pi k \times 9}{F}\right) + \\ & 0.15 \sin\left(\frac{2\pi k \times 11}{F}\right), \quad (5) \end{aligned}$$

$$\text{Test 1 : } F = 25 (\text{저주파수}), \quad (6)$$

$$\text{Test 2 : } F = 70 (\text{중주파수}), \quad (7)$$

$$\text{Test 3 : } F = 250 (\text{고주파수}). \quad (8)$$

표 2은 동적인 시스템에 대한 MLP, GPFN, 그리고 제안된 학습 구조의 tracking에 관한 일반화 능력을 보여준다. 표 2에서 테스트 신호의 dynamic 범위에 영향받지 않도록 일반적인 rms 값에 대하여 신호의 편차를 나눈 norm alized rms를 사용했다. 여기서, 고려된 MLP 구조는 5-8-1이고, 제안된 방법의 실험 결과는 GPFN의 학습이 끝난 후, 다시 MLP를 재학습 시켰다. 제안된 학습 방법이 정적 시스템에 대한 실험 결과처럼 GPFN 학습 방법에 의한 GPF 유닛(55개)에 비해 훨씬 작은 수(19.4개)가 생성되어지며, 보다 작은 수의 학습 변수가 요구된다. 또, 제안된 학습 방법이 주어진 학습 횟수(50,000)에 대하여 MLP(BP)보다 평균적으로 작은 횟수(18,000)에서 학습이 가능하여 가장 짧은 CPU 시간이 소요되었다. 각기 다른 주파수 특성의 테스트 신호에 대하여, GPFN은 유닛의 지역화 특성때문에 학습시 가장 좋

표 2. 비선형 동적 시스템 $y(k+1) = \frac{y(k)}{(1+y(k)^2)} + u(k)^3$ 에서 여러 가지 테스트 신호에 대한 MLP(BP), GPFN

과 제안된 학습 방법과의 일반화 성능 비교.

Table 2. Comparison of generalization capabilities for function approximation of nonlinear dynamical system

$y(k+1) = \frac{y(k)}{(1+y(k)^2)} + u(k)^3$ between MLP(BP), GPFN, and proposed MLP(BP)+GPFN.

Iter.	MNNs			GPFN			MNNs + GPFN		
	50,000 (5-8-1)			5,000			3,000(GPFN) Avg : 14770 + 2,000(retrain)		
Input	T1	T2	T3	T1	T2	T3	T1	T2	T3
Min.	8.1xe-2	5.6xe-2	5.3xe-2				5.3xe-2	3.2xe-2	2.4xe-2
Avg.	9.7xe-2	6.3xe-2	5.9xe-2	4.5xe-1	2.8xe-1	2.1xe-1	6.9xe-2	4.3xe-2	3.5xe-2
STD.	4.9xe-3	2.6xe-3	2.8xe-3				1.0xe-2	5.7xe-3	5.7xe-3
#.GPF				55			19.4		
#.var	49			565			262.4		

*MNNs + GPFNs : 2,300 sec. (Avg.)

*MNNs : 4,650 sec.

*GPFNs(2,000 Iter.) : 6,440 sec.

은 능력을 보여주었지만, 학습 영역에서 벗어나는 다른 영역의 신호의 tracking 문제에서는 저조한 일반화 능력을 보여준다. 제안된 학습 방법은 전체적으로 짧은 시간내에서 비교적 작은 변수를 이용하여 동적 시스템 근사화 문제에서 MLP를 통해 global 특성을 얻고, GPFN로부터 우수한 지역화 특성을 얻어 좋은 일반화 성능을 보여준다.

IV. 결 론

본 논문은 MLP와 GPFN의 구조적 결합을 통해, MLP의 시그모이드 유닛이 가지는 문제 공간상에서의 전체적인 학습 능력과 MLP에서의 오류 패턴들이 지역적으로 집단화되어 있는 경우 RBF의 지역적 학습 능력을 효과적으로 이용하는 학습 방법을 제시했다. 함수 근사화의 컴퓨터 실험 결과에서 나타난 MLP와 RBF만의 학습에 비해 빠른 학습 속도와 좋은 일반화 능력, MLP의 구조 문제의 해결 등은 제안된 학습 방법이 상당히 효과적임을 보이나, 제안된 방법이 구조적 결합이기 때문에 각 구조가 갖는 근본적인 문제를 해결해야하는 연구가 필요하다. 따라서 보다 나은 학습 성과를 얻기 위해서는, 본 논문에서 제안한 구조적인 네트워크간의 결합이 아닌 시그모이드와 GPF 유닛이 가지는 특성을 동시에 가지는 새로운 유닛의 개발을 고려할 수 있다.[18]

참 고 문 헌

1. K. S. Narendra, and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Trans. on Neural Networks*, pp.4-27, vol. 1, no. 1, Mar. 1990.
2. L. J. Park, J.M. Kwon, and C.H. Park, "Invariant Target Recognition with Morphological Filters and Third Order Neural Networks," *Procs. of IFSA'93*, 1, pp. 119-122, Seoul, Korea, 1993.
3. M. Lee, S. Y. Lee, and C. H. Park, "Neural Controller of Nonlinear Dynamic Systems Using Higher Order Neural Networks," *Elec. Letter*, vol. 2, no. 3, pp. 276-277, 1992.
4. R. M. Kil, and J. Y. Choi, "Time series prediction based on global and local estimation models," *Procs. of World Congress on Neural Networks*, vol. 4, pp. 617-621, 1993.
5. J.D. Schaffer, D. Whitley, and L. J. Eshelman, "Combination of Genetic Algorithms and Neural Networks: A Survey of the State of Art," *Proc. of COGANN-92*, pp. 1-37, Baltimore, June 1992.
6. S. Park, L. J. Park, C. H. Park, and Z. Bien, "A Novel Neuro-controller for Nonminimum Phase Systems," *Proc. of the 3rd Inter. Conf. on Fuzzy Logic and Neural Networks*, pp. 127-128, Iizuka, Japan, August, 1994.
7. K. Hornik, "Approximation capabilities of multi-layer feedforward networks," *Neural Networks*, 4(2), pp. 251-257, 1991.
8. J. Hertz, A. Krogh, and R. G. Palmer, *Introduction to the Theory of Neural Computation*, Santa Fe Institute, Addison Wesley, 1991.
9. S. E. Fahlman, and C. Lebiere, "The Cascade-correlation Learning Architecture," *Advances in Neural Information Processing Systems II*, pp. 524-532, Morgan Kaufmann Publishers Inc., CA, 1990.
10. S. Park, L. J. Park, and C. H. Park, "Novel Learning Methods of Neural Networks and Their Applications to Function Approximation," *Procs. of ICONIP*, vol. 3, pp. 1758-1763, Seoul, Korea, Oct., 1994.
11. E. B. Bartlett, "Dynamic Node Architecture Learning: An Information Theoretic Approach," *Neural Networks*, vol. 7, no. 1, pp. 129-140, 1994.
12. Z. Wang, C. D. Massimo, M. T. Tham, and A. J. Morris, "A Procedure for Determining the Topology of Multilayer Feedforward Neural Networks," *Neural Networks*, vol. 7, no. 2, pp. 291-300, 1994.
13. S. Park, L. J. Park, and C. H. Park, "Structural Hybrid of Multilayer Neural Networks and Gaussian Potential Function Networks," *Procs. of ICONIP*, vol. 3, pp. 1393-1397, Seoul, Korea, Oct., 1994.
14. E. Hartman, et. al, *Layered Neural Networks with Gaussian Hidden Units As Universal Approximations*, *Neural Computation* 2, pp. 210-215, 1990.
15. C. H. Park, S.B. Park, and M. Lee, "New

Neural Architecture and Learning Method Using Multilayer Neural Networks and Adaptive Gaussian Potential Functions," *Procs. of JCEANF*, pp. 221-225, Seoul, Korea, 1993.

16. J. Moody, and C. J. Darken, "Fast learning in networks of locally-tuned processing units," *Neural Computation*, vol. 1, pp. 281-294, 1989.

17. Barto Kosko, *Neural Networks for Signal Processing*, prentice-hall, 1992.

18. L. J. Park, S. Park, and C. H. Park, "Fast training of neural approximators with gutter-type units," *Procs. of ICONIP*, vol. 1, pp. 401-405, Seoul, Korea, Oct. 1994.



朴相奉(Sangbong Park) 정회원
1969年 1月 29日生
1991年 2月: 서울대학교 전기공학과 졸업
1994年 8月: 한국 과학 기술원 전기 전자공학과(석사)
현재: 한국 과학 기술원 전기 전자 공학과 박사과정 재학중
※주관심분야: 함수 근사화, 비선형 신경망 제어, 유전 알고리즘 등임



朴來正(Lae-Jeong Park) 정회원
1968年 12月 29日生
1991年 2月: 서울대학교 전기공학과 졸업
1993年 2月: 한국 과학 기술원 전기 전자 공학과(석사)
현재: 한국 과학 기술원 전기 전자 공학과 박사 과정 재학중
※주관심분야: 유전 알고리즘과 최적화 기법 등임.

朴哲薰(Cheol Hoon Park) 정회원
1961年 4月 14日生
1984年 2月: 서울대학교 전자공학과 졸업
1985年~1990年: 미국 California Institute of Technology 공학 석사 및 박사 학위 취득
1991年~현재: 한국 과학기술원 전기 및 전자공학과 조교수로 근무중
※주관심분야: 패턴 인식, 음성 인식, 신경망 제어, 유전 알고리즘 등임.