

비선형 시스템규명의 신경회로망응용

丁 吉 道


全北大學校 制御計測工學科

I. 서 론

과거 10년 동안 신경회로망과 관련된 이론과 여러 분야에서의 응용은 놀라운 발전을 해왔다. 신경회로망은 특성상 변화하는 환경에 학습을 통하여 적응하는 능력이 있고, 복잡한 비선형 함수관계를 규명하며, 병렬로 연결되어 신호처리가 신속하고 회로망의 에러에 민감하지 않으며, 알고리즘 자체가 학문적으로 난이도를 요구하지 않아 조금만 관심을 기울이면 쉽게 적용할 수 있는 유용한 공학적인 도구이다. 신경회로망은 이러한 이유 때문에 급격한 성장을 해왔다고 본다. 신경회로망의 적용분야를 살펴보면 공학이나 자연 과학에만 편중된 것이 아니고 질병을 진단하거나, 심전도 그래픽을 해석하고, 여러 가지 상황을 고려하여 예상되는 기후 변화의 예측, 주식시장의 변화추이를 규명 예측하며, 뿐만 아니라, 항공기 예약에도 이용되고 있다. 이러한 이유 때문에 신경회로망과 관련된 국제 학술대회의 투고 논문 편수를 보면, 수천여 편의 논문이 접수되고 여러 기관에서 학술대회를 개최하고 있는 상황이다. 본 논문에서는 일반적인 신경회로망의 소개와 종류, 알고리즘을 살펴보겠다. 또한 신경회로망을 이용하여 비선형시스템 규명에 응용하는 목적이 있으므로 비선형시스템의 규명에 관한 이론도 살펴보겠다. 또한 응용의 예로서 동역학적 시스템의 특성을 규명할 수 있는 회귀성 다층구조 관념소의 시스템규명에 대해 살펴보겠다.

II. 신경회로망

신경회로망(Neural Networks)은 생물학적 뉴런의 구조와 신호의 전달방법을 공학적인 모델링의 구조로 응용한 공학적인 하나의 도구이다(그림 1 참고). 신경회로망의 구조는 간단한 처리요소들 (processing elements)이 생물학적인 신경에서와 같이 다양한 방법으로 연결되어 있다. 처리요소를 절점(Node)이라 부르는데 이 절점에 여러 다른



(Figure 1) Biological Neuron and the Artificial Neural Networks.

절점들이 연결 고리로 연결되어 회로망을 형성한다. 절점에는 입력과 연결된 고리도 있고 출력과 연결된 고리도 있다. 입력을 통해서 들어온 수치를 다양한 수학적 방법으로 처리하고 처리된 값을 응용하고자 하는 시스템의 특성에 적합한 함수에 통과시킨다. 여기에서 발생하는 수치가 각 절점의 출력이 되어 다른 절점들과 연결되거나 신경회로망의 출력 값이 되기도 한다. 절점은 이처럼 간단한 비선형 필터의 형태를 지녔다. 그렇지만 신경회로망은 방대하고 복잡한 비선형 시스템을 규명하는 능력이 있다. 그 이유는 인간의 두뇌 구조에서 찾을 수 있다. 즉 두뇌의 한 세포에 수만 개의 연결고리가 연결되어 있으며 경험하는 과정에서 연결고리들의 강도들이 변화되어 기억하고 배우는 것처럼 신경회로망도 간단한 절점을 많은 연결고리로 연결하고 연결고리의 강도들을 학습을 통해 변화시키므로써 시스템의 특성을 배우도록 되어 있다.

중요한 신경회로망의 장점들을 살펴보면 다음과 같다.^[1, 2]

(1) 적응력과 학습능력;

신경회로망은 여러 개의 입력과 출력을 가진 시스템의 새로운 환경에 적응하고 시스템의 지나간 경험을 통해 특성을 배우는 탁월한 능력을 가지고 있다. 이러한 능력의 기초는 모든 입력(제어 신호, 잡음, 기준치 입력 등)들의 패턴으로부터 관계되는 출력들을 유출해 내는데 있다. 이러한 것을 연상기억능력이라 부르며 본 논문에서 고찰한 신경회로망 구조와 관련이 있다. 또한 신경회로망은 감

지장치의 잘못된 수치들로부터 그 입력에 대한 출력들과 연상해주어 바른 수치들을 유추해낸다. 이를 패턴 인식(pattern recognition)이라 하는데 이 능력은 시스템 구성요소의 고장들을 미리 찾아내고 해결책을 제안하며, 감지장치들이 잡음으로 인해 그 기능을 상실하더라도 바른 수치를 연상해 내어 제어를 가능케 하므로 구조 개선에 큰 박차를 가할 수 있게 해준다.

(2) 산업이용의 용이성;

이것은 신경회로망의 가장 보편적인 장점이다. 신경회로망의 중요한 특성은 각 예마다 쉽게 프로그래밍을 할 수 있다는 점이다. 그래서 특별한 기구들이 필요없고 이용하려는 시스템의 많은 자료를 얻어 학습을 시키면 이루려는 목적이 달성된다. 뿐만 아니라 신경회로망은 그 기본 이론을 이해하기가 쉽다. 이것이 또한 수학적으로 복잡하고 비선형적인 시스템의 제어에 이용되는 중요한 이유가 된다.

(3) 스스로 신경들을 조직하는 능력;

신경회로망은 변화하는 상황에 대처해 자체신경들을 조직하는 능력이 있다. 이것은 특히 시스템의 구성요소들이 노후현상으로 인해 발생하는 매개변수들의 변동에 상당히 중요한 문제 해결점이 된다. 기존에 있는 적응(adaptive)제어 장치들은 매개변수의 큰 오차를 해결해야 하는 많은 문제점이 남아 있어 이 분야의 응용에 좋은 결과가 기대된다.

(4) 병렬 연결;

신경회로망은 원래 많은 회로의 병렬연결형 구조로 되어 있다. 그래서 신경회로망을 학습시키는 경우와 On-line 학습을 통한 신경회로망의 이용에 있어서 여러 개의 CPU(Central Process Unit)의 사용으로 빠른 계산을 할 수 있고, 어느 하나의 연결이 잘못되더라도 전체 기능상 별 문제가 없게 된다.

1. 신경회로망의 구조

신경회로망은 생물학적 뉴런의 특성에 따라 고안되었다. 다른 뉴런의 출력이 입력으로 작용하며, 모든 입력은 생물학적 뉴런의 연결고리 강도(synaptic strength)와 유사한 연결강도(weight)

에 의해 증가된다. 그리고 나서 활동출력(activation)에 필요한 값을 결정하기 위해 연결된 모든 입력과 그 입력에 연결된 연결강도의 곱의 결과가 합산된다. 신경회로망의 구조는 필수성분에 따라 정의된다.^{13, 4)} 즉 :

(1) 회로망 내부의 정보흐름을 결정하는 연결 구조(topology).

(2) 입력 정보와 연결강도가 신경회로망의 활동 수준을 계산하는데 어떻게 사용되는가를 결정하는 전달함수(transfer function); 전달함수는 보통 합이 된다.

(3) 언제, 어떻게 인공신경회로망이 출력을 내는가를 결정하는 활동함수 규칙(activation function rule) - 구별함수(discriminatory function); 활동함수에는 보통 쌍곡선 탄젠트(tangent)의 시그모이드(sigmoid)가 이용된다.

또한 신경회로망은 다른 판단기준에 따라 분류되기도 한다. 즉 학습의 모형(supervised, unsupervised, self-supervised), 동작의 선택(on-line, off-line), 회로망 기능(mapping networks, associative networks, hierarchical networks, spatio-temporal networks), 회로망 연결 구조(feedforward, feedback, recurrent), 그리고 처리된 데이터의 타입(binary, discrete, or continuous)에 따라 분류되기도 한다.

2. 학습 알고리즘(Learning Algorithms)

위에서 언급한 것처럼, 신경회로망의 각 처리요소는 많은 입력을 가지고 있다. 이것들은 여러 가지 연결강도들을 수반한다. 절점들은 연산자(operator)를 통해 입력들과 연결된 연결강도를 처리한다. 일반적으로, 이 연산자는 가중된 입력의 합이다. 이 연산자의 출력신호는 구별함수의 입력이 된다. 이 함수는 설계할 때에 중요한 요소가 되며 유동적으로 변동될 수 없다. 한편, 연결강도는 일반적으로 변할 수 있고 주어진 출력을 내기 위해 유동적으로 조정된다. 신경회로망이 학습 데이터에서 정보를 얻을 수 있도록 하는 이러한 연결강도의 유동적 변경을 학습이라 한다. 학습은 아마도 다른 인공 지능의 형태와 비교할 때 신경회로망의 가장

중요한 구별 특성일 수도 있다.

학습에는 주로 두 가지 타입, 즉, 통제형(supervised)과 비통제형(unsupervised)이 있다. 통제형 학습은 시스템의 입력과 출력을 제공받아 신경회로망을 학습하는 방법이다. 즉, 입력과 출력을 이용하여 시스템의 특성을 추출해 내는 학습방법을 말한다.

비통제 학습은 입력신호 한가지로 규칙성을 알아내 내부 모델들을 만들어내는 방법으로 통제형에서처럼 입력과 출력 데이터가 필요하지 않다. 비통제형 학습방법은 쌍을 이루지 않는 훈련 데이터를 사용하고, 이것은 외부의 어떠한 학습자도 요구하지 않는다. 신경회로망에 데이터가 주어지면, 입력 데이터를 분류 목록으로 요약하는 내부 집단을 형성한다.

마지막으로 한가지를 더 고려한다면 최근에 보고되는 자기통제형(self-supervise) 학습방법으로 이 학습방법은 특별한 종류의 인공신경회로망 학습에 이용되며, 어떠한 외부의 학습자도 필요하지 않다. 예러 신호는 회로망 자체에서 만들어지며 시스템 자체로 회귀(Feedback)시키도록 구성되었다. 올바른 응답은 많은 반복을 통해서 얻어진다.

각 학습 타입은 학습 논리(learning logic)나 규칙(rule)이 존재한다. 학습 처리의 기능은 신경회로망의 입력과 출력의 값에 따라 연결강도를 조절함으로써 이루어진다. 신경회로망의 학습 규칙은 적응제어시스템의 시스템의 적응 규칙과 유사하다.

3. 가장 널리 알려진 신경회로망 모델

현재 연구되고, 또한 응용에 사용되는 신경회로망의 종류는 적어도 30가지가 된다. 이것들 중에서, 가장 일반적인 것들은 다음과 같다^{3, 4, 5, 6)};

(1) 적응공명이론(Adaptive Resonance Theory): 이 모델은 벡터 분류기라고 부를 수 있다. 이 모델은 입력 벡터를 받아들여 이미 분류된 패턴과 비교하여 들어온 입력을 가장 유사한 패턴으로 분류한다. 이 알고리즘은 새로운 패턴을 학습하는 유연성을 가지고 있다. 새로운 패턴은 지금까지 분류된 패턴에는 변화를 주지 않는다.

(2) 아벨란치(Avalanche): 시공(spatio-tem-

poral)에 관계되는 패턴들의 학습하고 인식하기 위한 회로망의 한 종류다.

(3) 다층구조관념소(Multilayer Perceptron): 이것은 역전파 학습규칙을 사용하는 피드포워드(feedforward) 신경회로망이다. 역전파학습 규칙은 여러 신호가 회로망을 통해 피드백 된 통제형 학습 알고리즘이다. 이 회로망은 목표치(desired output)와 예상치(predicted output) 에러의 최소화를 통해 연결강도를 조절한다.

(4) 양방향 관련 메모리(Bidirectional Associative Memory): 이 회로망은 홉필드(Hopfield) 회로망의 특별한 경우이다. 이것은 반연관성(heteroassociative)을 띠며 학습능력을 가지고 있다.

(5) 볼츠만머신(Boltzmann Machine): 이 회로망은 비용(cost function)의 전체적인(Global) 최소 값을 찾기 위해 외란을 주어 국부 최소 값에서 이탈하도록 고안된 회로망이다.

(6) Counterpropagation: 통계적으로 최적의 자기조직(self organizing) 기준표(lookup table)와 확률밀도기능 분석기(probability density function analyzer)의 역할을 하는 회로망이다.

(7) 홉필드(Hopfield) 회로망: 이것은 자동관련(autoassociative) 피드백 회로망이다.

(8) 매달린(MAdaLiNe): 평균 제곱(mean-squared)의 에러를 최소화하는 학습 가능한 선형 결합기의 합성으로 이루어진 회로망이다.

(9) 네오카그니트론(Neocognitron): 다층 체계(multilayer hierarchical) 성격을 띤 인식 회로망이다.

III. 비선형 시스템 규명

시스템 규명은 관측된 시스템 데이터를 이용하여 시스템의 수학적인 모델을 세우는 문제를 다룬다. 많은 선형 시스템 이론들이 개발되어 왔고 실제적인 응용에 있어서 성공적으로 수행되고 있다. 그러나, 실제로 비선형성이 큰 특성들을 가지고 있

는 많은 응용 분야가 있다. 이런 시스템의 경우에, 선형 수학 모델을 세워 시스템을 해석하는 경우엔 상당한 오차가 발생하여 해석이 불가능하게 되는 경우가 있다. 또한 선형 모델로 시스템 해석이 가능하다 할 경우에도, 그 허용 범위가 한정되어 이용 범위가 줄어들게 되므로 비선형 모델링을 하게 되면 이러한 문제들로부터 제약을 받지 않게 된다. 그러므로 주어진 비선형 시스템에 적절한 비선형 모델을 개발하는 것이 필요하다.

비선형 시스템 규명은 전형적으로 Volterra와 Wiener series 같은 함수 시리즈 방법들이 이용되어 왔다. 이들 구조는 많은 비선형 시스템들을 묘사할 수 있는 것으로 알려졌다. 그럼에도 불구하고, 적절한 시스템규명을 위해 필요한 계산 시간들은 제한되어 있고, 또한 이렇게 얻어진 모델들은 분석하기가 어렵다. 뿐만 아니라 함수 시리즈 방법들은 시스템의 차수가 증가함에 따라 필요한 매개변수(parameter)의 수가 기하 급수적으로 늘어나는 단점이 있다. 비선형 블랙박스(black box) 모델들은 1980년대에 Billings^[7] 등에 의해 폭넓게 다루어 졌다. 이 모델들은 지나간 시간대의 입력들과 출력들로 이루어지는 비선형 항들을 복귀시킴으로써 비선형 시스템들을 근사화 규명하였다. 이 모델은 비선형 시스템의 규명에 있어서 가장 두드러진 구조를 제안한 것 중의 하나로 여겨진다. 하지만 이 경우에도 센서에 노이지(Noise)가 많을 경우엔 시스템 규명이 어려운 단점이 있다.

신경회로망을 시스템 규명에 응용한 경우와 동역학적 특성을 지닌 신경회로망을 개발한 연구들을 살펴보면 다음과 같다. Chen과 Billings^[8]은 복잡한 비선형 시스템을 모델링 하기 위한 선택으로 피드포워드(feedforward) 다열 관념소를 이용하였다. 그들은 불연속-시간 비선형 시스템의 규명에 관해 연구하였다. 그들은 순환 예측 오차 평가 알고리즘을 단일 신경회로망에 이용하였다. 이 연구는 "신경회로망으로 비선형 시스템들을 모델링 하는 것은 효과적인 접근 방법이고 이 분야에서 지속적인 연구는 상당한 가치가 있다."라는 결론을 지었다. 또한, Chen^[9]과 그의 연구팀들은 병렬 순환 예측 오차 법을 이용한 새로운 신경회로망

학습 법을 개발했다.

그 외에도 여러 알고리즘이 몇 가지 형태의 순환 신경회로망 즉, 피드백과 상호연결(cross-talk)이 존재하는 회로망들이 개발되었다. Williams과 Zipser,^[10] 그리고 Williams과 Peng^[11]은 소위 동적 역전과라 불리는 Global Feedback 회로망들에 관한 알고리즘을 개발하였다. 연결강도들은 입력과 목표 출력에 기초한 증감들을 동적으로 조절함으로써 계산된다. 여기에서 Global Feedback은 단지 회로망 출력이 입력으로 피드백 된다. Narendra와 Prathasarathy^[12]는 다층 구조관념소에 학습 데이터의 출력을 입력층에 피드백 함으로써 시스템의 동역학적인 요소를 습득할 수 있는 구조를 제안했다. 그렇지만 이 경우에도 학습 데이터에 상당한 센서 노이즈가 존재하게 되면 시스템 모델에 큰 오차가 발생하는 단점이 있다. Werbos^[13]과 Pineda^[14]는 순환 회로망들을 학습하기 위한 알고리즘을 제안하였다. 다른 연구들도 순환 신경회로망에 대한 학습 알고리즘을 제안하였다. 그러나, 이들 제안된 알고리즘의 어느 것도 출력에 많은 외란이 존재하는 경우의 비선형 동적 시스템을 규명하는 좋은 연구가 없었다.

대개 신경회로망을 이용한 비선형규명 방법은 식(1)과 같은 비선형 자동회귀부류(Nonlinear AutoRegressive with eXogenous Input(NA-RX))군에 속하는 확정시스템(deterministic system)에 적용된다.

$$y(k+1) = f[y(k), \dots, y(k-p), u(k), \dots, u(k-q)] \quad (1)$$

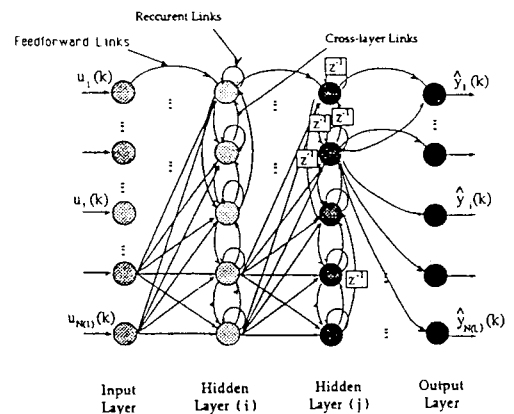
한 개의 은닉층을 가진 신경회로망은 모든 비선형 시스템을 근사화 규명할 수 있는 Cybenko^[15]의 이론에 따라 대부분 역전과학습 알고리즘을 변형시킨 전진과 신경회로망을 이용하여 비선형함수 $f(\cdot)$ 를 근사화 규명하고 있다. 이러한 경우 신경회로망의 입력은 $y(k), \dots, y(k-p), u(k), \dots, u(k-q)$ 가 되고 목표치는 $y(k+1)$ 가 된다. 이 방법에 사용된 p 와 q 의 결과로 추정되는 시스템모형의 차수가 확정된다. 이러한 방법은 Bhat,^[16] Chen,^[17] Narendra^[12]에 의하여 고찰되었다. 최근에는 Qin^[18]

^[18]이 확률적 비선형 시스템 규명에 4가지 신경회로망 구조를 비교 응용한 바 있다. 다음 장에서는 본 논문에서 응용할 회귀성 신경회로망에 대해 보다 자세히 살펴보겠다.

IV. 시간지연 회귀성 다층구조관념소

비선형 시스템을 모델링하기 위하여 선택한 신경회로망의 구조는 Parlos et.al.^[19]에 의해 연구된 회귀성 신경회로망으로 전진과와 역전과 회로망으로 혼합된 것이다. 잘 알려진 다층구조관념소 은닉층(hidden layer)의 절점에 입력층과 연결된 연결고리와 절점의 출력이 본래 절점과 연결되고 또한 같은 은닉층의 이웃한 절점들과도 연결되도록 구성하였다. 이때 신호처리는 전진과 연결의 경우엔 다층구조관념소와 같고 회귀성 연결과 상호연결은 한 스텝 지연된 값들이 연결되어 동적 시스템을 규명하는 역할을 한다. 이런 원리에 기초한 회귀성 다층구조관념소는 비선형 시스템의 특징을 추정함과 동시에 동적 특성을 구현할 수 있다. (그림 2)는 본 연구에서 사용된 일반적인 회귀성 다층구조관념소의 모양을 묘사하고 있다.

자세한 수학적 이론을 살펴보기 위해 L 층으로



(Figure 2) Schematic Diagram of the Recurrent Multilayer Perceptron.

구성된 회귀성 다층구조관념소를 고려해 보자. L 개의 각층은 $N(l)$ 절점을 갖고 있고 $l=1, \dots, L$ 이다. 버퍼(buffer)역할을 하는 첫번째 층에 들어가는 입력은 회로망의 입력이고, 마지막 층의 출력은 신경회로망의 출력이 된다. 신경회로망에 연결되는 입력들은 현재의 제어신호들이고 이 신호들은 모델링 하고자 하는 동적 시스템에 작용하는 외란에 해당된다. 지금까지 보고된 동역학적 신경회로망을 살펴보면 그 외 모두가 과거시간대의 입력신호와 학습데이터 출력 또는 신경회로망의 출력 값을 다시 입력 층에 연결함으로 동역학적 특성을 모델링 하였다. 그렇지만 이 회귀성 신경회로망은 제어신호의 한 단계 앞의 값과 측정된 외란 혹은 출력은 입력으로 다시 연결되지 않는다.

회귀다층구조관념소의 l 번째 층에 위치한 i 번째 절점을 설명한 방정식은 다음 차분 방정식으로 나타낼 수 있다.

$$z_{l,i}(k) = \sum_{j=1}^{N(l)} w_{l,i,j} x_{l,j}(k-1) + \sum_{j=1}^{N(l-1)} w_{l-1,i,j} x_{l-1,j}(k) + b_{l,i} \quad (2)$$

$$x_{l,i}(k) = F_{l,i}(z_{l,i}(k)) \quad (3)$$

여기서 $z_{l,i}(k)$ 는 l 번째 층에서 i 번째 절점의 내부 상태변수이고, $x_{l,i}(k)$ 는 신경회로망 절점의 출력이며, $b_{l,i}$ l 번째 층의 i 번째 절점에 대한 바이어스를 의미한다. $w_{l,i,j}$ 는 l 번째 층의 j 번째 절점에서 l' 번째 층의 i 번째 절점으로 연결된 연결강도이다. $F_{l,i}(\cdot)$ 는 l 번째 층과 관련된 식별함수이다. 이 함수는 선형, S형만곡, 쌍곡탄젠트 중에 하나가 될 수 있다. 본 논문에서는 은닉층에 대해서는 쌍곡탄젠트 식별함수를 사용했고, 반면에 출력층에서는 선형 식별함수를 사용했다.

앞에서 언급한 것처럼 식(2)과 식(3)은 회귀다층구조관념소의 입력과 출력 사이에 전진과 경로에 시간 지연이 없음을 나타내고 있다. 그러므로 이 신경회로망에서 전진과 부분은 잘 알려진 다층구조관념소의 커브핑팅 특성과 같고, 반면에 회귀와 은닉층 상호연결 부분은 동적 특성을 갖는다.

회귀다층구조관념소의 출력들은 현재의 신경회로망의 입력에 대한 함수이고 또한 내부 상태변수에 대한 함수이기도 하다. 결국 과거시간대의 입력과 출력들은 신경회로망에 다시 공급되지 않는다. 왜냐하면 이들의 영향은 회귀다층구조관념소의 내부 상태변수들에 의하여 소멸되기 때문이다.

위에서 제안한 회귀성 신경회로망의 동적 학습 알고리즘은 Zipser와 Williams^[10]의 전진 전파 방법(forward-propagation approach)에 기초하고 다층구조 관념소의 구조에 대한 동적 학습알고리즘을 이용하였다. 동적 학습 알고리즘의 자세한 내용은 Parlos et.al.^[19]를 참고하기 바란다.

V. 신경회로망을 이용한 시스템규명

1. 단순화한 증기 보일러의 시스템규명

신경회로망을 이용한 응용으로 간단한 증기보일러를 회귀성 신경회로망을 이용하여 모델링 하였다. 시스템과 관련된 방정식은 다음과 같다.

$$\dot{P}_d(t) = \frac{1}{\tau_d}(W_{ar}(t) - W_d(t)), \quad (4)$$

$$\dot{P}_t(t) = \frac{1}{\tau_{sh}}(W_d(t) - W_{sh}(t)), \quad (5)$$

$$\dot{P}_r(t) = \frac{1}{\tau_r}(W_{sh}(t) - P_r(t)), \quad (6)$$

$$W_d(t) = [K_{sh}(P_d(t) - P_t(t))], \quad (7)$$

$$W_{sh}(t) = A_{cv}(t)P_r(t), \quad (8)$$


$$MW(t) = K_i W_{sh}(t) + (1 - k_i)P_r(t), \quad (9)$$

여기에서 $P_d(t)$, $P_t(t)$ 와 $P_r(t)$ 은 각각 드럼(drum), 조절판(Throttle) 재가열(Reheat) 압력의 상태변수를 의미한다. 제어입력은 $W_{ar}(t)$ 이며, 필요한 전력생산량에 따라 변동되는 외란 즉 제어입력은 제어 밸브의 위치 $A_{cv}(t)$ 이다. 보일러드럼(Boiler Drum), 고전열기(Superheater), 재가열기(Reheater)의 시정수는 각각 τ_d , τ_{sh} 와 τ_r 로 표시된다. $W_d(t)$ 와 $W_{sh}(t)$ 는 각각 보일러드럼, 고전열기의 증기 유동량을 의미하고, $MW(t)$ 는 전체 발

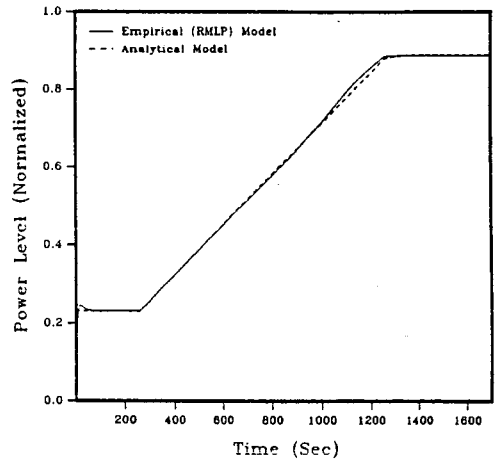
전량을 의미한다. 또한 고성능 터빈을 통한 전기 생산률을 K_1 로 나타낸다.

시스템규명에 이용된 신경회로망의 구조는 입력층에 한 개의 절점과 두 개의 은닉층에 각각 8개와 6개의 절점을 그리고 한 개의 출력절점을 가진 형태를 선택하였다. 물론 이 구조는 여러 가지 경우를 고려해 본 결과 선택했다. 발전소의 증기보일러는 개루프(Open Loop)의 경우 전체 작동 구간 안에서 안정된 시스템이다. 그러므로 입력이 $A_{ev}(t)$ 이며 출력이 $MW(t)$ 인 개루프(open loop) 시스템의 동작상태를 모델링 하는 것이 가능하다. 발전소 운영시 대부분의 경우에 외란이 스텝과 램프로 되어 있다. 따라서 이 두 가지 신호만을 학습과 검증과정에서 고려하였다. 이 응용 예의 학습데이터는 9가지 스텝 즉, 정규화된 전기발전량의 0.01에서 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9의 스텝으로 구동하도록 선택하였으며, 495개의 샘플로 되어 있다. 1-8-6-1 회귀성 신경회로망은 연결강도와 바이어스(bias)의 학습율을 0.05로 400사이클(cycle) 동안 학습되었다. 추가로 또 다시 연결강도와 바이어스의 학습율을 0.01로 하여 500사이클 동안 학습시켰다.


위에서 모델링 한 신경회로망의 모델이 증기 보일러를 정확하게 규명하였는가를 검증하기 위하여 3가지 스텝 외란, 즉, 낮은 발전량, 높은 발전량



(Figure 3) Steam Boiler Power Plant Step Disturbance Response(Intermediate Power).



(Figure 4) Steam Boiler Power Plant Ramp Disturbance Response.



(Figure 5) Steam Boiler Power Plant Ramp-up Ramp-down Disturbance Response.

그리고 중간 발전량으로 시험하였다. 이러한 시험 외란에 대한 신경회로망과 증기보일러의 RMS (Root-Mean-Square) 모델링 에러는 각각 1.1%, 1.5%, 2.2%로 나타났으며 중간 발전량에 대한 응답이 (그림 3)에 나타나 있다. 또한, 스텝 테스트의 경우에 비해 넓은 발전량 영역의 변화를 램프입력으로 구동한 검증의 경우를 시험해 보았으며 이 경우에 응답이 (그림 4)에 나타나 있다. 마지막으로, 상승램프와 하강 램프를 결합한 구동을 검증실험으로 고려하였으며, 이때 응답은 (그림 5)에 나타

나 있고, RMS 모델링 에러는 각각 1.3%, 1.4%이다.

$$Error = \frac{\sqrt{\sum_{k=1}^K \sum_{i=1}^{N(L)} (x_{T,L,i}(k) - y_i(k))^2}}{\sqrt{\sum_{k=1}^K \sum_{i=1}^{N(L)} y_i^2(k)}} \quad (10)$$

2. 외란이 존재하는 다중입력 다중출력 비선형 시스템규명

외란이 존재하는 다음과 같은 다중입력 다중출력(MIMO) 시스템에 대해 신경회로망을 이용하여 모델링 해보았다.

$$x_1(k) = 0.5(x_1^2(k-1))^{\frac{1}{3}} + 0.3x_2^2(k-1)x_3(k-1) + 0.2u_1(k-1) + n_{x1}^{Pr}(k), \quad (11)$$


$$x_2(k) = 0.5(x_2^2(k-1))^{\frac{1}{3}} + 0.3x_3(k-1)x_1(k-1) + 0.2u_1(k-1) + n_{x2}^{Pr}(k), \quad (12)$$

$$x_3(k) = 0.5(x_3^2(k-1))^{\frac{1}{3}} + 0.3x^2(k-1)x_2(k-1) + 0.2u_2(k-1) + n_{x3}^{Pr}(k), \quad (13)$$

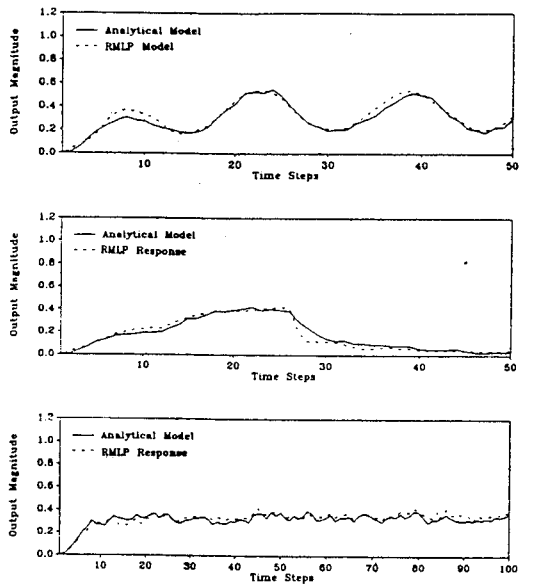
$$y_1(k) = 0.5(x_1(k) + x_2(k) + x_3(k)), \quad (14)$$

$$y_2(k) = 2(x_1^2(k))^2, \quad (15)$$

여기에서 $n_{xi}^{Pr}(k)$ 는 $i=1,2,3$ 에 대하여 각각 시스템의 공정과정의 외란을 의미한다. 본 예제에서 사용된 회귀성 신경회로망은 2개의 입력노드, 2개의 은닉층(각각 12개와 10개의 노드를 지님), 2개의 출력 노드로 이루어졌다(2-12-10-2). 학습데이터는 크기가 0.125, 0.25, 0.375, 0.5인 모든 가능한 25개의 스텝의 조합(입력 채널에서 0입력도 포함)으로 이루어져 있고 각 스텝의 경우에 15개씩 샘플링 하여 375개의 데이터를 선택하고 추가적으로 5개의 펄스를 각각 40개씩 샘플링 하여 전체 575개의 샘플을 학습데이터로 설정했다. 외란은 평균이 0이며, 표준편차가 0.02인 백색잡음을 사용하였다. 연결강도와 바이어스 학습율이 0.01이고 3600번을 학습시켰다.



(Figure 6) Response for High Noise Environment RMLP Model First Output; Top: Sinusoidal Input; Middle: Ramp Input; Bottom: Step Input.



(Figure 7) Response for High Noise Environment RMLP Model Second Output; Top: Sinusoidal Input; Middle: Ramp Input; Bottom: Step Input.

첫번째 검증의 입력신호는 $u_1(k)=0.3+0.2\sin(\pi k/8)$, $u_2(k)=0.2$ 이다. 여기서 두번째 채널의 스텝입력은 첫번째 채널에서의 입력과 비교하여 5단계 시간 지연된다. 두번째의 검증 신호는 펄스이며, 마지막 검증신호는 0.1의 표준편차를 가지고 백색 가우스 잡음의 평균값이 0인 신호가 가미된 스텝으로 이루어져 있다. y_1 의 응답은 <그림 6>에 나타나 있고 RMS오차는 사인, 펄스, 외란이 존재한 스텝의 경우에 각각 7.67×10^{-2} , 5.66×10^{-2} , 0.16이다. 또한 y_2 의 응답은 <그림 7>에 나타나 있으며, RMS오차는 사인, 펄스, 외란의 스텝의 경우에 각각 6.74×10^{-2} , 3.42×10^{-2} , 0.22이다.

V. 결 론

신경회로망의 기초적인 이론과 종류에 관해 살펴 보았으며, 비선형 시스템의 규명과 동적 변화상태의 모델링이 가능한 회귀성 신경회로망을 살펴 보았다. 회귀성 신경회로망의 피드포워드 부분은 다층구조관념소의 형태이고, 피드백 부분은 회귀연결과 각 층들의 혼성연결로 이루어졌다. 신경회로망의 응용으로 단순화한 증기 보일러의 시스템 모델링과 외란이 존재하는 다중입력 다중출력의 복잡한 비선형 시스템을 규명해 보았다. 결과적으로 회귀성신경회로망은 시스템의 동특성을 전혀 모르는 구조적인 비선형성을 지닌 시스템의 동역학적인 상태변화를 규명하는데 매우 효과적임을 알 수 있었다. 시스템규명을 통해 구한 모델의 검증시 나타난 RMS 모델링 오차는 이 결론을 확인해주며 회귀신경회로망이 더 복잡한 비선형시스템에의 규명에도 효과적으로 쓰일 수 있음을 시사한다.

참 고 문 헌

[1] Pabon, J. A., "A Neural Network Model of Adaptation in Motor Coordination", Ph.

D. Dissertation, Mechanical Engineering Dept., MIT, Cambridge, MA, 1988.

- [2] Rosen R., *Theoretical Biology and Complexity*, NY, NY, Academy Press, 1985.
- [3] R. Hecht-Nielsen, *Neural Computing*, Addison-Wesley Publishing Company, Reading, MA, 1990.
- [4] P. D. Wasserman, *Neural Computing : Theory and Practice*, Van Nostrand Reinhold, New York, NY, 1989.
- [5] S. Y. Kung, *Digital Neural Networks*, Prentice Hal, Englewood Cliffs, N. J., 1993.
- [6] Jacek M. Zurada, *Introduction to Artificial Neural Systems*, West Publishing Company, St. Paul, NM, 1992.
- [7] S. A. Billings, "Identification of Nonlinear Systems-A Survey," *IEEE Proc. D, Control Theory and Applications*, Vol. 127, (6) pp.272~285, 1980.
- [8] S. Chen, S. S. Billings and P. M. Grant, "Nonlinear System Identification Using Neural Networks," *Int. J. Control*, Vol. 51, No.6, pp.1191~1214, 1990.
- [9] S. Chen, F. N. Cowan and S. S. Billings, "Parallel Recursive Prediction Error Algorithm for Training Layered Neural Networks," *Int. J. Control*, Vol. 51, No. 6, pp. 1215~1228, 1990.
- [10] R.J. Williams, and D. Zipser, "A Learning Algorithm for Continually Running fully Recurrent Neural Networks," *Neural Computation*, Vol. 1 pp.270~280, 1989.
- [11] R. J. Williams and J. Peng, "An Efficient Gradient-Based Algorithm for On-line Training of Recurrent Network Trajectories," *Neural Computation*, Vol. 2, pp.490~501, 1990.
- [12] K. S. Narendra and K. Paratharathy, "Identification and Control of Dynamic System Using Neural Networks," *IEEE*

- Transactions on Neural Networks*, Vol. 1, No. 1, pp.4~27, 1990.
- [13] P. J. Werbos, "Backpropagation Through Time : What it Does and How to Do It," *Proceedings of the IEEE*, Vol. 78, No. 10, pp.1550~1560, 1990.
- [14] F. J. Pineda, "Recurrent Backpropagation and the Dynamical Approach to Adaptive Neural Computation," *Neural Computation*, Vol. 1, pp.161~172, 1989.
- [15] Cybenko, G., "Approximation by Superposition of a Sigmoidal Function" *Mathematics of Control, Signal, and Systems*, 2 : 303-314(1989).
- [16] Bhat, N. and McAvoy, T. J., "Use of neural Nets for Dynamic Modeling and Control of Chemical Process Systems," *Computers and Chemical Engineering*, Vol. 14, No. 4/5, pp.573~583, 1990.
- [17] S. Chen, C. F. N. Cowan, S. A. Billings and P. M. Grant, "A Parallel Recursive Prediction Error Algorithm for Training Layered Neural Networks," *Int. Journal of Control*, Vol. 51, pp.1215~1228, 1990.
- [18] Qin, S. -Z, H. -t. Su, and t. J. McAvoy, "Comparison of Four Neural Net Learning Methods for Dynamic System Identification," *IEEE Transactions on Neural Networks*, Vol. 3, No. 1, pp.122~130, 1992.
- [19] Parlos, Chong, Atiya, "Application of the Recurrent Multilayer Perceptron in Modeling Complex Process Dynamics," *IEEE Trans. Neural Network*, Vol. 5, No. 2, pp. 255~266, Mar. 1994.

저 자 소 개



丁 吉 道

1960年 7月 24日

1984年 6월 美 오레곤 주립대(OSU) 기계공학 학사

1986年 12월 美 조지아 공대(Georgia Tech) 기계공학 석사

1993年 5월 美 텍사스 A&M 대학(Tx A&M U.) 기계공학 박사

1984年 6月~1984年 12월 美 Exodus Inc. 研究員

1987年 1月~1988年 9월 美 Exodus Inc. 研究員

1993年 9월~1995年 2월 영남대학교 전임강사

1995年 3월~현재 전북대학교 전임강사

주관심분야 : 자동제어이론, 공장자동화, 신경회로망 이론과응용