

적응 학습방식의 신경망을 이용한 좌심실보조장치의 모델링

김상현*·김훈모**·류정우***

=Abstract=

Adaptively Trained Artificial Neural Network Identification of Left Ventricular Assist Device

Sang Hyun Kim*, Hun Mo Kim**, Jung Woo Ryu***

This paper presents a Neural Network Identification(NNI) method for modeling of highly complicated nonlinear and time varying human system with a pneumatically driven mock circulatory system of Left Ventricular Assist Device(LVAD). This system consists of electronic circuits and pneumatic driving circuits. The initiation of systole and the pumping duration can be determined by the computer program. The line pressure from a pressure transducer inserted in the pneumatic line was recorded. System modeling is completed using the adaptively trained backpropagation learning algorithms with input variables, heart rate(HR), systole-diastole rate(SDR), which can vary state of system. Output parameters are preload, afterload which indicate the systemic dynamic characteristics. Consequently, the neural network shows good approximation of nonlinearity, and characteristics of Left Ventricular Assist Device. Our results show that the neural network leads to a significant improvement in the modeling of highly nonlinear Left Ventricular Assist Device.

Key words : Neural network identification, Left ventricular assist device, Mock circulatory system

서 론

최근에 우리 나라 경제의 발전으로 생활수준이 향상되어 심장관련 질병이 급증하고 있으며 앞으로도 경제 및 생활습관이 선진화되면서 심장질환으로 사망한 사람의 수가 급속히 증가될 것으로 예상된다. 그러나, 약물치료나 수술로는 해결할 수 없고 심장이식수술만이 유일한 치료 방법인 말기 심장질환자는 심장이식수술을 할 수 있는 단계가 되어도 즉시 심장이식수술을 받지 못하는 환자가 거의 대부분이다. 또한, 심장수술 후 심근부전으로 심장이 펌프역할을 제대로 수행하지 못하는 경우 인체의 주요 조직으로 혈액을 공급할 수 있도록 하지 않으면 그 환자

는 생존할 수 없다. 그러므로 이러한 심장질환환자를 위해 심실보조 장치를 사용하여 임시적이거나 영구적으로 인체 순환계내의 심장의 기능을 보조해 줄 수 있다. 이미 선진국에서는 여러 가지 종류의 심실보조장치 및 인공심장을 개발하여 임상에서도 상당한 성공을 거둔 것으로 알려져 있다[1]. 심장질환이 주를 이루는 우리나라에서도 자체 개발이 시급하게 되었다.

심실보조장치는 적용방식에 따라 좌심실보조장치, 우심실보조장치, 양심실보조장치로 구별할 수 있고, 구동방식에 따라 공압식과 전기기계식으로 구별할 수 있다[2-4]. 그리고 제어방식에 따라 비동기 방식과 동기 방식이 있다[5].

〈속보논문〉

*연세대학교 의과대학 심혈관연구소 조교수

**Cardiovascular Research Institute, Yonsei University College of Medicine.

**성균관대학교 공과대학 기계설계학과 조교수

**Department of Mechanical Design, College of Engineering, Sungkyunkwan University

**성균관대학교 공과대학 기계설계학과 대학원

본 연구는 연세대학교 의과대학 1995년 일반과제연구비 지원으로 이루어졌다.

통신처자 : 김상현, (120-752) 서울특별시 서대문구 신촌동 134, Tel.(02)361-7352

본 연구에서는 구조가 비교적 간단하고 오랜 임상 경험으로 신뢰성이 높고 실험데이터나 임상자료가 풍부한 공기구동식을 채택하였다. 이러한 심실보조장치의 개발시스템의 모델링은 심실보조장치의 기계적 동요에 대한 순환장치의 응답을 미리 예측함으로써 바람직한 제어의 방향을 제공하기에 반드시 필요로 한다. 1970년대 이후로 많은 심혈관시스템 모델(CardioVascular System Models, CVSM)이 제시되었으며 이러한 심혈관시스템의 모델링은 시뮬레이션을 수행하기 위한 효과적인 도구로써 사용되어져 오고 있다[6-9]. 그러나 제안된 모델들은 대부분 연속시스템(전기적으로 아날로그 시스템)모델이며 대표적인 예는 Windkessel모델과 1988년 Capello등[7]에 의해 제시된 심실 및 심방의 수축력(forcing function)을 고려한 심혈관시스템 모델 등이다. 생체의 점성, 탄성, 컴플라이언스 성분들이 저항, 코일 그리고 컨텐서의 성분들로 표현되었다[7-9]. 대개의 경우 시스템의 모델이 매우 복잡하기 때문에 McInnis등[10])와 Shimooka 등[11]은 단순한 전기적 순환계 모델(electrical cardiovascular model)을 제시하였다. 그러나 간단한 전기적 소자로 구성되어 있기 때문에 생체가 갖는 여러 가지 특성과 신경계와 호르몬 등의 변화에 의한 돌발적인 상황이 전혀 반영되지 않으며, 그 유효성이 전혀 검정되지 않고 있다.

본 연구에서는 이러한 복잡한 비선형, 시변 시스템의 모델링에 가장 적절한 인공신경망을 이용하여 생체의 시스템을 모델링하였다. 시스템의 구조가 알려지지 않은 비선형시스템의 모델링에 있어 근사화의 방법이 문제가 되어 왔다. Fu와 Farison[12]은 비선형시스템의 모델로 Volteria series를 이용하여 접근하였다. 그러나 그들은 매우 복잡한 시스템의 경우에 대해서는 너무 많은 변수들이 필요하다고 지적하고 있다. 일반적으로 선형시스템의 모델링과 알려진 구조의 비선형시스템에 대한 모델링의 방법들은 알려지지 않은 비선형 시스템의 모델링에 대해서는 적용할 수 없다. 보편적 근사화 방법으로 인공신경망은 비선형 동적 시스템의 모델링에 광범위한 응용이 가능함이 알려졌다[13-17]. 그리고 Narendra와 Parthasarathy[16,17]는 동적시스템의 모델링과 제어에 인공신경망의 가능성을 제시하였다. Bhat등[13,14]은 성공적으로 비선형 화학공정의 모델링에 다층 인공신경망을 적용했다. 그러므로 기존의 모델링으로는 해결할 수 없었던 생체의 여러 돌발적인 상황을 반영하기 위하여 시스템에 대한 정화하고도 정밀한 분석없이도 시스템의 모델링이 가능한 인공신경망을 이용하여 모델링을 수행하고자 한다. 그리고 심실보조장치를 개발함에 있어서 생체의 실제적 상황을 잘 나타내는 생리적 모델을 개발하여 제어시스템의 구현시 바람직한 제어의 방향을 제시하는 것을 목적

으로 한다.

본 논문의 구성은 다음과 같다. 2장에서는 인공신경망의 역전파 학습 알고리즘을, 3장에서는 좌심실보조장치의 실험을 위한 모의순환장치, 4장에서는 모의순환장치시스템에 대한 인공신경망의 모델링에 대해 설명한다. 끝으로, 5장에서 결론을 맺고자 한다.

학습 알고리즘

Stone-Weierstrass의 이론으로부터 어떤 네트워크구조는 일반적으로 해석적인 근사가능성이 있다는 것을 알 수 있다. 역전파 인공신경망의 설계에 있어서 이 이론은 실제 시스템의 함수를 근사화할 수 있다는 것을 뒷받침해주고 있다. 역전파 인공신경망은 n개의 층으로 이루어진 층상화된 신경망이다. 이는 입력 패턴을 직접 받아들이는 입력층과 기대값을 출력하는 출력층, 그리고 활성화 함수로 알려진 이미 정의된 함수의 뉴런들로 이루어진 중간층이 있다. 역전파 학습 알고리즘은 전파와 역전파의 2가지 기본적인 학습 방식을 가지고 있다.

전파의 학습시 입력값은 각 층에 대한 출력값을 계산하기 위해 네트워크의 전방으로 진행되고 이에 의한 실제 출력값은 기대값과 비교되어진다. 역전파의 학습은 시스템의 기대값과 출력값의 오차를 줄이기 위하여 오차를 네트워크의 역방향으로 전파시켜 가중치를 변화시키면서 진행된다. 이번 연구에서 사용된 인공신경망 모델은 입력층 뉴런이 6개이고 출력층 뉴런이 2개이며, 그리고 18개의

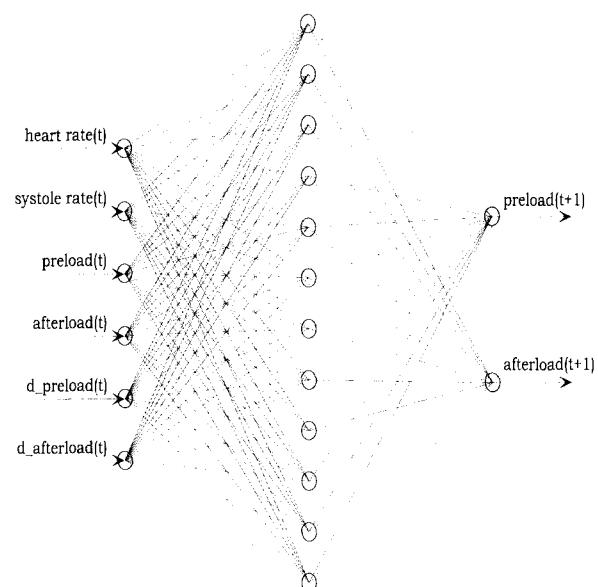


그림 1. 뉴럴 네트워크의 구조
Fig. 1. Neural Network Architecture

중간층 뉴런을 가지고 있다. 그리고 입력변수는 heart rate(HR)와 systole-diastole rate(SDR), preload(좌심방압, LAP), afterload(대동맥압, AoP), 그리고 preload와 afterload의 변화량이며, 출력변수는 preload와 afterload이다.

1. 전파 학습 : 우선 학습방법을 설명하기 전에 인공신경망의 출력값과 입력값, 그리고 가중치의 관계를 정확히 정의하여야 한다. 출력층 k 의 출력값은 벡터 o_k 이며, 뉴런은 활성화 함수 f_k 를 가지고 있다. 그리고 가중치 행렬 w 에 의해 중간층 벡터 o 에 연결되어 있다. 각 뉴런에 대한 입력값은 다음과 같다.

$$net_k = \sum_j o_j w_{jk} \quad (1)$$

이번 논문에서 출력층의 활성화 함수 f_k 는 다음과 같은 선형함수이다.

$$f_k(net_k) = net_k \quad (2)$$

출력값은 다음과 같다.

$$o_k = net_k \quad (3)$$

또한 중간층 j 의 출력값은 벡터 o_j 이며 뉴런은 활성화 함수 f 를 가지고 있다. 그리고 가중치 행렬 w_{jk} 에 의해 입력층 벡터 o 에 연결되어 있다. 각 뉴런에 대한 입력값은 다음과 같다.

$$net_j = \sum_i o_i w_{ij}$$

이번 논문에서 중간층의 활성화 함수 f 는 다음과 같은 시그모이드 함수이다.

$$f_j(net_j) = sig(net_j) \quad (5)$$

그리고 출력값은 다음과 같다.

$$o_j = sig(net_j) \quad (6)$$

최소자승법에 의해 명명되어진 오차함수 E 는 다음과 같이 정의되어 진다.

$$E = \sum_k (t_k - o_k)^2 \quad (7)$$

여기에서 t_k 와 o_k 는 기대값과 실제 네트워크의 출력값이다. 역전파 인공신경망 학습은 오차를 최소화하는 방향으로 진행된다.

2. 역전파 학습 : 주어진 입력 벡터에 대하여 최소 자승법은 기울기 경사법을 사용하여 신경망의 오차를 최소로 하는 가중치 벡터를 찾는다. 학습규칙은 다음과 같다.

$$\Delta w_{ij} = -p \frac{\partial E}{\partial w_{ij}} \quad (8)$$

이러한 방법은 오차가 작아질수록 시스템을 안정된 가중치에 도달하게 한다. 그리고 가중치의 오차에 대한 변화값은

$$\Delta w_{ij} = \epsilon_{adaptive} \delta_i + \alpha \Delta w_{ij} \quad (9)$$

이다. 이러한 관계로부터, $\epsilon_{adaptive}$ 는 학습률이고 α 는 모멘텀 상수이며 이들은 네트워크의 학습의 정도를 나타내주고 있음을 알 수 있다. 본 논문에서는 기존의 일정 상수의 학습률을 가지고는 비선형성이 심한 심실보조장치에 적용하기에는 학습시간이 오래 걸리므로 학습시간을 줄이기 위해 적용학습방법을 사용하였다. 적용 학습방법은 학습이 안정된 상태로 있는 한 가능하게 큰 학습률을 가지는 방법으로 오차값의 비가 증가할 경우 학습률을 감소시키고, 비가 감소할 경우 학습률을 증가시킨다. 그러므로 학습시간의 상당한 단축이 기대된다. 출력층에 대하여 δ_k 는 다음과 같다.

$$\delta_k = (t_k - o_k) f'_k \quad (10)$$

그러나 네트워크내부의 중간층의 델타값은 즉각적으로 구해지지 않는다. 중간층의 δ_j 는 다음을 이용하여 반복적으로 구해진다.

$$\delta_j = f_j \sum_k \delta_k w_{jk} \quad (11)$$

여기에서 δ_j 와 w_{jk} 는 출력층의 오차값에 의해 역전파되어 결정되어지는 값들이다. 그리고 가중치의 변화된 값들은 다음과 같다.

$$w_{jk}^{new} = w_{jk}^{old} + \Delta w_{jk} \quad (12)$$

$$w_{ij}^{new} = w_{ij}^{old} + \Delta w_{ij}$$

이러한 학습규칙을 사용하여 좌심실보조장치의 인공신경망모델을 4000여번의 역전파 학습을 통해 0.01의 오차를 갖는 즉 좌심실보조장치와 같은 시스템으로 간주할 수 있다. 그리고 학습된 인공신경망모델은 제어시스템의 구현시 효과적인 도구로 사용되어진다.

좌심실보조장치

공압식 좌심실보조장치는 혈액펌프와 구동장치로 나누어진다. 혈액펌프는 압축공기를 에너지원으로 하여 혈액을 박출하는 기능을 하며, 구동장치는 혈액펌프에 공급되는 공기의 흐름을 조절하는 기능을 한다. 개발된 심실보조장치는 모의순환장치에 의해 평가되었으며 각각 다음과으로 구성된다.(그림 2)

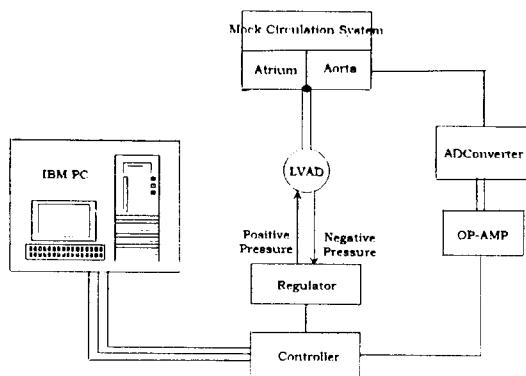


그림 2. 전체시스템회로도

Fig. 2. Overall System Circuits

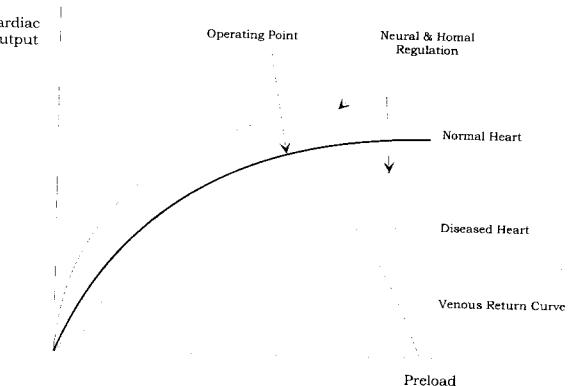


그림 4. 심장의 박출량과 전부하의 관계

Fig. 4. Relation between cardiac output and preload

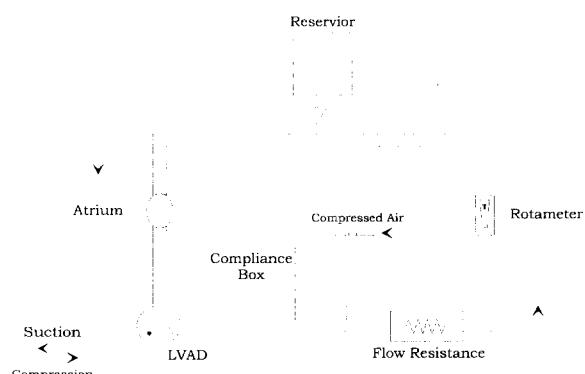


그림 3. 모의순환장치와 좌심실보조장치

Fig. 3. Mock Circulatory System(MCS) & LVAD

– 좌심실보조장치의 구동장치

양압과 음압의 공기압을 발생시키기 위해 양압용과 음압용의 두 개의 펌프를 사용하였다. 그리고 24volt 3way 솔레노이드 밸브를 사용하여 양압과 음압이 교대로 들어가도록 공기통로를 변환시킨다. 제작한 구동장치에는 공기압력, 수축률과 심박동수를 자유로이 조절할 수 있는 기능을 갖추었다. 환자의 상태에 따라 수축기율과 심박동수를 조절할 필요가 있으므로 80×86계열의 personal computer를 사용하여 솔레노이드 밸브의 작동주기를 제어한다. 제어에 사용되는 인터페이스 카드는 8255A-PPI의 LSI를 이용하여 제작하였다. 제어방식은 비동기 방식을 채택하였으며, 구동압력의 조절은 레귤레이터를 이용하여 조정하였다.

– 좌심실보조장치에 대한 모의순환장치

좌심실보조장치의 성능을 시험하기 위하여 모의순환장

치를 제작하였다. 모의순환장치의 구성은 3-element Windkessel model을 기본으로 하였는데 이의 변경된 구조인 2개의 유체저항을 1개로 줄이고 저항을 커뮤니티와 직렬로 연결하여 구성하였다.(그림 3) 유체저항은 순환관의 유효단면적을 기계적으로 줄일 수 있도록 하여 인체혈관의 혈류저항을 유도하였고 혈관의 탄력성을 유도하기 위하여 공기압력실을 만들어 압력실의 공기압을 조절함으로써 인체혈관의 컴플라이언스 효과를 갖도록 하였다. 압력측정을 위해 펌프의 유출관과 유입관, 구동기의 구동선에 각각 압력변환기를 설치하여 구동장치의 압력, 대동맥압(AoP), 좌심방압(LAP)를 측정한다.

신경망을 이용한 모델링

좌심실보조장치를 생체의 생리적 조건에 맞게 제어하기 위해서는 정맥으로 회귀되는 혈류량에 민감한 심박출량의 조절이 가장 기본적으로 이루어져야 하는 중요한 요소이다. 좌심방으로 유입되는 양보다 더 많은 혈액을 좌심실보조장치가 유입하려고 할 때 좌심방압이 감소하게 되며 이러한 동작상태가 계속되면 좌심방합물현상이 발생한다. 그러므로 일정한 심박출량을 보장해주기 위하여 좌심방압의 압력을 적정수준으로 유지시켜야 한다.

매번 60~90회정도의 박동수를 가지는 심장의 심박출량을 가변시킬 수 있는 제어 메커니즘에는 1) 내인성에 의한 조절 2) 신경계에 의한 조절 3) 호르몬에 의한 조절의 세 가지가 있다. 여기에서 내인성에 의한 조절은 심장의 전부하가 변화할 때 Starling 법칙에 따라 1회 박출량이 변화하는 방식이다. 그림 4는 심장의 박출량과 전부하의 관계를 나타낸 것이다. 이는 심장의 sensitivity curve라고도 불리우며 심장의 펌프기능을 반영한다. 정맥 귀환곡선이 교차되는 점이 심장의 동작점이 된다. 신경계에 의한 조절은 신경계의 피드백을 통하여 심박동수, 1회

표 1. 모의순환장치의 변수

Table 1. Parameters of MCS

Parameter	Value	Unit	Remarks
SV	80	cc	심박동량 10회 측정한 평균값
HR	가변	bpm	$\sin(0.5t)$
SDR	가변	%	$\sin(0.75t)$
AoP	가변	mmHg	후부하 0.1초 단위로 측정한 평균값
LAP	가변	mmHg	전부하 0.1초 단위로 측정한 평균값
DP	+	mmHg	구동압력(양압)
	-	mmHg	구동압력(음압)

박출량 및 수축력을 변화시킴으로써 전체 심박출량을 조절하며 주로 생체의 산소요구량이 신경계의 주된 피드백 정보이다. 신경계에 의한 제어가 이루어질 경우 sensitivity curve에서의 동작점이 이동하며, 이는 심박출량의 변화를 수반한다. 호르몬에 의한 조절은 혈액중에 분비된 호르몬의 작용으로 직접적으로 수축 및 확장을 제어한다. 유량이 일정수준을 유지하면 전부하는 좌심실보조장치에 의해 적절한 범위내에 존재하게 된다. 또한 유량은 구동압과 수축률을 조절하여 제어가 가능하다. 그리고 압력이 유량보다 측정하기가 쉽기 때문에, 수축률이 구동압보다 전기적으로 제어하기가 더욱 간단하기 때문에 이번 연구에서는 전부하와 수축률을 생체시스템의 상태를 나타내줄 수 있는 주요 변수로 가정한다. 그러므로 전체의 유량은 심박출량에 민감한 전부하와 둔감한 후부하의 변화에 따라 수축률과 함께 심박동수를 변화시켜서 조절할 수가 있다. 만약 전부하가 증가하면 수축률을 증가시킴으로 유량을 증가시킬 수 있으며, 전부하가 감소하면 수축률을 감소시킴으로 유량을 감소시켜 좌심방합물 등의 현상을 방지할 수 있다.

이번 연구에서 사용된 인공신경망은 6개의 심박동량과 수출률, 그리고 전부하와 후부하, 그리고 전부하와 후부하의 변화량의 입력총 뉴런과 18개의 중간총 뉴런을 가지며 2개의 preload와 afterload의 출력총의 뉴런을 가진다. 적응 학습 방법을 사용하여 오차의 설정치에 도달하였다. 네트워크 각각의 층에서의 가중치들은 난수발생함수를 이용하여 초기화되며, 활성화함수로 시그모이드함수는 중간 층 뉴런에 선형함수는 출력총 뉴런에 사용하였다. 변수들의 값들은 모의순환실험장치에서 0.1초 단위로 샘플링되었으며 이들의 평균값들은 인공신경망 모델의 변수로 써

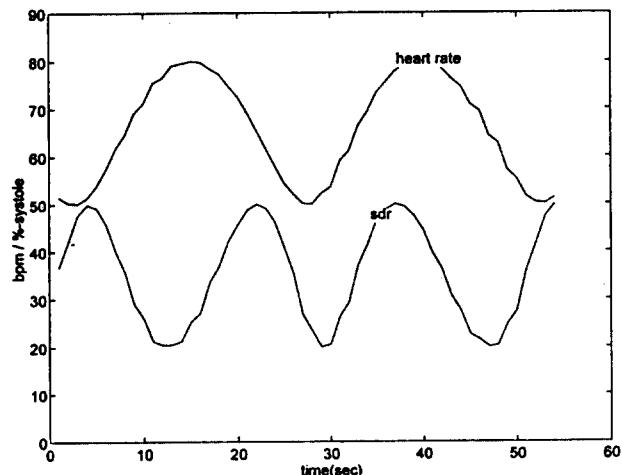


그림 5. 인공신경망의 입력변수들

Fig 5. Input Variables of neural network

사용된다. 이러한 변수값들을 특성을 표 1에 설명하였다. 학습된 후의 인공신경망 모델은 좌심실보조장치 시스템의 입력과 출력의 관계를 잘 나타내주고 있다.

결 과

본 논문에서는 좌심실보조장치의 모델링을 구현하는 방법으로 시스템에 대한 정확하고도 정밀한 분석없이 블랙박스로 시스템의 모델링이 가능한 인공신경망을 사용하여 시스템을 모델링하였다. 그리고 모의순환실험장치를 통하여 인공신경망의 유효성과 그 성능을 검증하였다. 기존의 모델링에서는 신경계와 호르몬 등의 변화에 대응하는 시스템을 구축할 수 없으며 고려해야 할 파라미터의 모든 관계를 수식적으로 표현하는 것은 불가능하다. 또한 비선형성의 실제 시스템을 단순화시켜 선형시스템으로 가정한 후 해석을 하였으므로 좌심실보조장치와 같은 복잡하고 돌발적인 상황이 발생하기 쉬운 실제의 비선형시스템에 적용하기에는 문제점을 가지고 있다. 그러므로 안정성과 복잡한 비선형성 등의 보완을 위하여 간단하면서도 비선형근사성이 우수한 인공신경망을 사용하여 생체시스템을 모델링하였다. 그림 5에는 시간에 대하여 좌심실보조장치가 임의의 주파수를 갖는 시스템으로 나타날 수 있도록 $\sin(0.5t)$ 와 $\sin(0.75t)$ 의 정현파 특성을 가지는 심박동수와 수축비의 입력변수들을 보여주고 있다. 그림 6에서는 입력변수에 대응하여 시간에 대한 출력변수들 즉, 전부하 그리고 후부하를 보여주고 있다. 각각의 파형은 HR과 SDR을 각각 50~80bpm, 20~50%의 범위를 가지는 정

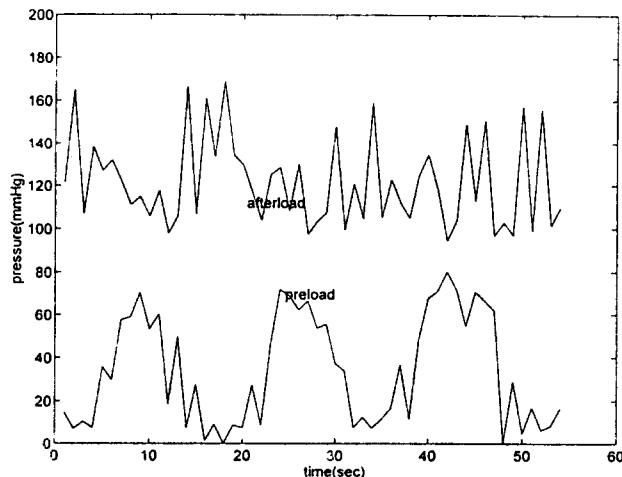


그림 6. 인공신경망의 출력변수들
Fig. 6. Output Variables of neural network

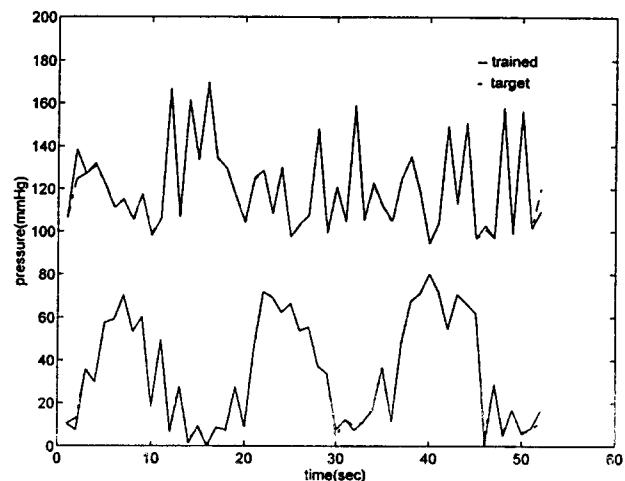


그림 8. 인공신경망의 비선형근사성
Fig. 8. Nonlinear approximation of neuralnetwork

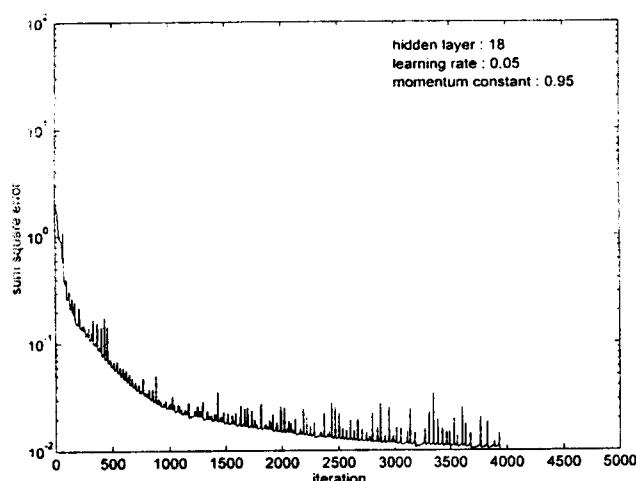


그림 7. 좌심실보조장치의 학습시 오차의 합
Fig. 7. Sum Square Error of LVAD learning

현파 곡선으로 주어졌기에 생체시스템의 모든 상태, 정상 상태와 비정상상태를 나타낼 수 있다. 즉 실험에 사용된 좌심실보조장치는 발생가능한 모든 실제적 상황을 잘 나타내고 있음을 알 수 있다. Preload의 경우 정상적인 경우 0 ~ 20mmHg의 범위를 가지나 인공신경망을 이용하여 구성된 시스템은 0 ~ 60mmHg의 범위를 가지고 있다. 이는 생체 시스템의 가장 비정상적인 상태를 포함하여 생체의 예기치 못한 돌발적인 상황까지도 학습하도록

모델링되었기 때문이다. Afterload의 경우도 생체시스템의 모든 상태를 잘 나타내고 있음을 알 수 있다. 그리고 그림 7에는 학습에 대한 오차를 보여주고 있으며 그림 8. 에서는 인공신경망의 장점인 비선형근사성이 잘 나타나고 있다.

결 론

좌심실보조장치의 모델링이 인공신경망을 이용하여 수행되었다. 이번 연구에서의 인공신경망을 이용한 좌심실보조장치의 모델링은 다음과 같은 점에서 중요한 의미를 가지고 있다.

1) 간단한 전기적 소자로 모델링된 시스템으로는 불가능했던 신경계나 호르몬등의 변화에 대응하는 시스템의 구축이 인공신경망으로는 모든 상황을 반영하는 시스템의 모델링이 가능하다.

2) 기존의 제어의 기반이 된 모델들보다 훨씬 실제적 상황을 잘 나타내는 생리적 모델을 개발하여 사용하였기 때문에 정상상태 또는 비정상상태의 동적 상태를 예측함으로써 실제적 상황에 대처할 수 있는 제어시스템의 구현이 용이하리라 기대된다.

3) 사용한 입출력 변수들이 심박출량의 조절을 위한 중요한 요소들이므로 이들은 심실보조장치의 운영에 있어 중요한 요소인 심박출량을 조절 할 수 있으므로 생체의 생리적 조건에 맞는 심실보조장치를 개발할 수 있는 충분한 가능성을 가지고 있다.

4) 그리고 전부하와 후부하를 변수로 써 고려하기 때문

에 실제 인공심장의 구동시 발생가능한 치명적인 문제점을 방지할 수 있다.

5) 인공신경망 모델은 제안된 임상의 아주 복잡한 비선형 시스템을 적용하기에 충분한 가능성을 나타내주고 있음을 알 수 있다.

향후의 연구과제는 다음과 같다.

- 1) 인공신경망을 이용한 모델링은 학습지연으로 인한 학습시간의 단점을 가지고 있다. 그러므로 인공신경망의 단점을 극복하기 위해 유전자 알고리즘을 이용한 최적화 기법을 이용하여 학습시간을 단축하여야 하겠다.
- 2) 인공신경망을 이용한 모델이 더 유연성을 가지도록 할 필요가 있으며 그렇게 하기 위하여 유량의 변수를 고려하고 좌심실로 연결된 관에서의 압력의 감소와 그리고 심장벽에서의 무리한 부하와 산소소비량을 줄이기 위해 R파 동기식의 제어모드를 고려하고자 한다.
- 3) 그리고 인체 시스템에 적용 가능하도록 인공신경망 모델링 및 제어를 이용하여 시스템을 제어하고자 하는 것 이 앞으로의 연구과제이다.

참 고 문 헌

1. T.E. Oaks, W.E. Pae, Jr., C.A. Miller, and W.S. Pierce, "Combined Registry for the clinical use of mechanical ventricular assist pumps and the total artificial heart in conjunction with heart transplantation", fifth official report-1990, J. Heart & Lung Transplant., 10:621-625, 1991.
2. K.E. Johnson, M. Presto, L.D. Joyce, M. Pritzker, and R.W. Emery, "Summary of the clinical use of the symbiont total artificial heart", a registry report. J. Heart & Lung Transplant., 11:103-16, 1992.
3. D.J. Farrar, J.H. Lawson, P. Litwak, and G. Cederwall, "Thoratec VAD system as a bridge to heart transplantation", J. Heart & Lung Transplant., 9:415-23, 1990.
4. P.M. McCarthy, P.M. Portner, H.G. Tobler, V.A. Starnes, N. Ramasamy, and P.E. Oyer, "Clinical experience with the Novacor ventricular assist system", J. Thorac. Cardiovasc. Surg., 102:578-87, 1991.
5. David J. Farrar, Peter G. Compton, John H. Lawson, James J. Hershon, J. Donald Hill, "Control Modes of Clinical Ventricular Assist Device", IEEE ENGINEERING IN MEDICINE AND BIOLOGY MAGAZINE, March, 1986.
6. G. Avanzolini, P. Barbini, A. Cappello, and G. Cevenini, "Time-varying mechanical properties of the left ventricle a computer simulation", IEEE Trans. Biomed. Eng., BME-32, pp. 756-763, 1985.
7. G. Avanzolini, P. Barbini, A. Cappello, and G. Cevenini, "CADCS Simulation of the Closed-Loop Cardiovascular System", Int. J. Biomed. Computer, vol. 22, pp. 39-49, 1988.
8. H. Suga, "Theoretical Analysis of a Left-Ventricular Pumping Model Based on the Systolic Time-varying Pressure/Volume ratio", IEEE Trans. Biomed. Eng., vol. 18, pp. 47-55, 1971.
9. L. Pater, and De Van Berg, "An Electrical Analogue of the entire Human Circulatory System", Med. Elec. Biol. Eng., no. 2, pp. 161-166, 1964.
10. B.C. McInnis, J.C. Wang, "Adaptive Control System for the Artificial Heart", IEEE Frontiers of Engineering in Health Care-1982.
11. T. Shimooka, Y. Mitamura, T. Yuhta, "Investigation of Parameter Estimator & Adaptive Controller for Assist Pump by Computer Simulation", Artificial organs, vol. 15, No. 2, 1991.
12. F.C. Fu and J.B. Farison, "On the Volterra-series functional identification of nonlinear discrete-time system", Int. J. Contr., vol. 18, no. 6, pp. 1281-1289, 1973.
13. M. Bhat and T.J. McAvoy, "Use of neural nets for dynamic modeling and control of chemical process systems", in Proc. 1990 American Control Conf. pp.1342-1347.
14. M. Bhat, P. Minderman, T.J. McAvoy, and N.S. Wang, "Modeling chemical process systems via neuralcomputation", IEEE control syst. Magazine, Apr. 24-30, 1990.
15. S. Chen, S.A. Billings, and P.M. Grant, "Nonlinear System identification using neural networks", Int.J. Contr., vol.51, no. 6, pp.1191-1214, 1990
16. K.S. Narendra and K. Parthasarathy, "Adaptive identification and control of dynamic systems using neural networks", in Proc. 28th CDC(Tampa,FL), pp.1737-1740, Dec.1989.
17. K.S. Narendra and K. Parthasarathy, "Identification and control of dynamic systems using neural networks", IEEE Trans. Neural Networks, vol.1, pp.4-27, Mar 1990.

=국문초록=

좌심실보조장치의 개발시 시스템의 모델링은 시스템의 응답을 미리 예측함으로써 바람직한 제어의 방향을 제시하기 위하여 수행되어 왔다. 기존의 모델링은 간단한 전기적 소자를 이용하여 수행되었으나 이는 생체가 갖는 특성이 전혀 반영되지 않는다. 그러므로 복잡한 비선형 시변 시스템인 생체의 좌심실보조장치를 모델링하는 방법으로 간단하면서도 비선형근사성이 아주 우수한 인공신경망을 이용하여 모델링하고자 한다. 구성된 인공신경망은 심박동수, 수축이완기비, 전부하, 후부하, 그리고 전부하, 후부하의 변화량으로 구성된 6개의 뉴런으로 구성되어 있으며 출력층은 전부하, 후부하의 2개의 뉴런으로 구성되어 있다. 중간층은 18개의 뉴런으로 구성되어 있다. 학습을 통하여 인공신경망은 좌심실보조장치의 특성을 잘 나타내고 있음을 알 수 있다.