
 論 文

大韓造船學會論文集
 第 34 卷 第 2 號 1997年 5月
 Journal of the Society of
 Naval Architects of Korea
 Vol. 34, No. 2, May 1997

신경망을 이용한 선박용 자동조타장치의 제어시스템 설계 (I)

곽문규*, 서상현**

Design of Neural-Network Based Autopilot Control System(I)

by

Moon Kyu Kwak* and Sang-Hyun Suh**

요 약

본 논문에서는 신경망을 이용한 자동조타장치의 개발에 관한 연구결과를 소개한다. 본 연구에서는 먼저 신경망이론에 사용되는 대표적인 방법인 Back-Propagation 알고리즘의 원리를 설명하고 이를 이용하여 선박의 조종모델을 신경망으로 재구성하는 방법을 제시하였다. 신경망이론을 사용하여 선박운동모델을 System Identification 하는 경우의 문제점을 간단한 조종모델을 이용하여 수치적으로 검증하고 보다 복잡한 모델로 적용하는 경우에 대한 토의를 하였다. 본 논문에서 개발된 신경망이론들은 비선형성을 내포하고 있는 선박운동을 재구성하는데 효과적으로 사용될 수 있을 것으로 기대된다.

Abstract

This paper is concerned with the design of neural-network based autopilot control system. In this paper, the back-propagation algorithm is introduced and explained in detail. The system identification method based on neural networks for ship motion is developed and its efficacy is verified by using a simple ship maneuvering model. Problems which may arise in a complex maneuvering model are then discussed. The neural-network based system identification method developed in this paper can be used effectively for reconstructing the ship maneuvering model which is known to have nonlinearity.

발 표: 1995 년도 대한조선학회 추계연구발표회 ('95. 11. 9)

접수일자: 1996 년 8월 19일, 재접수일자: 1997년 3월 17일

* 정회원, 동국대학교 기계공학과

** 정회원, 한국기계연구원 선박 해양공학 연구센터

1. 서언

선박을 통한 해상운송량의 증가는 연해와 근해에서의 해상사고 증가의 원인이 되었고 이러한 해상사고는 바로 인근해역의 해양오염으로 이어져 심각한 경제적, 사회적 문제를 유발하였다. 이와 같은 해난사고 방지를 미연에 방지하기 위해서는 선박의 안전운항을 보장할 수 있는 항해장비의 개발이 필수적이다. 최근에는 GPS (Global Positioning System) 와 같은 정확한 위치감지기를 사용할 수 있게 되었고 또한 전자해도의 도입으로 해도정보의 전산처리가 가능하게 되어 선박을 안전하게 자동운항하는데 있어서 필요한 기초적인 장비가 해결되었다고 말할 수 있다. 그러나 선장의 경험에 의한 수동운항의 위험성을 보완할 수 있고 상대적인 안정성과 신뢰성을 확보하기 위해서는 보다 지능적이고 변화되는 상황에 대처할 수 있는 선박자동조타제어장치가 개발되어야 한다.

선박의 운동특성은 하중조건, 바다의 깊이, 그리고 선박의 속력에 의해서 바뀌어지기 때문에 선박운동에 관한 이론적인 모델은 어느 정도의 불확실성을 포함하고 있다. 이런 불확실성을 소멸하기 위해서는 무엇보다도 선박과 유체간의 상호 연성작용 즉 유체동력학적인 힘의 정확한 추정이 필요하게 된다.[3] 그러나, 실선의 유체동력학적인 힘을 정확히 추정한다는 것은 불가능하기 때문에 모델의 정확도를 높일 수 있는 방법이 개발되어야 한다. 이를 위하여는 여러 가지 형태의 System Identification 방법들이 사용되고 있으나 선박운동의 경우 비선형항으로 인하여 정확한 모델의 추정 은 불가능한 상태이다. 본 논문에서는 먼저 비선형성을 재구성할 수 있는 기능을 지닌 것으로 알려진 신경망이론을 소개하고 이를 간단한 조종모델에 적용하여 그 타당성을 조사하고자 한다.

신경망은 인간의 두뇌신경조직에 대한 간단한 모델로부터 출발하는데 데이터처리에 있어서 그 효용성이 입증되었다[4,5]. 인공적인 신경망은 과거의 경험을 학습하여 추상적인 값을 구체화하는

전산조직인데 서로 상관관계가 없는 데이터로부터 어떤 특징을 추출해 낸다거나 추정할 수 없는 입력들로부터 결과를 일반화할 수 있는 방법을 제공한다. 순차(Sequential) 계산을 하는 일반적인 디지털 계산기와는 달리 신경망은 계산처리를 하는 요소들이 매우 복잡하게 연결되어 있어 생물학에서 보여지는 신경조직과 유사함을 알 수 있다. 이와 같은 조직을 사용하면 정보의 저장과 흐름을 분산할 수 있어 조직내의 장치 하나가 작동하지 않는다 해도 전체 기능이 심하게 저하 되지 않는다고 믿어지고 있는데 이는 생물학상의 결과로부터 추론할 수 있다. 이런 기능은 각 장치의 완벽한 기능을 필요로 하는 현재의 초고속 Von-Neumann 계산기의 기능에 상반된다. 그러나 서로 복잡하게 연결된 조직을 구현하기 위해서는 병렬 (Parallel) 계산을 하게되어 대단위계산 (Large Scale Computation) 방법이 필요하게 되었다.

이와 같은 신경망은 임의의 연속함수를 근사시킬 수 있는 기능을 지니고 있어 비선형성을 포함하고 있는 시스템을 Identification 하는데 적합하다. 여러 신경망중 Back-Propagation 알고리즘은 임의의 정확도를 가지고 함수를 근사시킬 수 있음이 입증되었는데 Back-Propagating 알고리즘은 많은 경우에 그 효용성이 입증되기는 하지만 국부 최소점에 갇힐 수 있는 가능성도 있다. Back-Propagation 알고리즘은 또한 제어기법으로도 사용되는데[6] 이 경우 어떤 조건을 만족하게 한다던가 아니면 원하는 출력이 나오도록 제어신경망을 설계하게된다.

본 논문에서는 먼저 Back-Propagation 알고리즘을 사용하여 선박의 조종모델을 재구성할 수 있는 방법을 제시하고 이에 관련된 제반 문제를 토의하고자 한다. 간단한 수치모델을 사용하여 신경망이론의 실용성을 조사하여 보다 복잡한 모델로의 적용시 지표로 삼고자 하는 것이 본 논문의 목적이다.

2. 선박조종모델

일반적으로 선박조종모델에 관한 운동방정식은 뉴턴 제이 법칙을 적용하여 얻어진다. 매우 큰 선박의 경우에 대해서는 수직면상에서의 운동을 무시할 수가 있는데 이 경우 선박의 운동은 다음의 좌표계를 이용하여 표현한다. (Fig. 1)




Fig. 1 The Coordinate system for a ship maneuvering model

선박의 선수각에 대한 동적 거동을 표현하는 가장 간단한 수치모델은 다음과 같은 미분방정식으로 표현될 수 있다[4].

$$T \ddot{\psi} + \dot{\psi} = K\delta \quad (1)$$

여기서 ψ 는 선박의 선수각이며 δ 는 타각을 나타낸다. 신경망제어의 출력을 ± 1 로 제한하고 최대와 최소를 타각의 최대와 최소로 등치시키면 다음과 같은 식을 유도할 수 있다.

$$T \ddot{\psi} + \dot{\psi} = K\delta_{\max} u \quad (2)$$

식 (2)를 상태방정식(State Eq.) 형태로 고치면 다음과 같이 쓸 수 있다.

$$\dot{x} = Ax + Bu \quad (3)$$

여기서 $x = [\psi \ \dot{\psi}]^T$ 는 상태벡터이고

$$A = \begin{bmatrix} 0 & 1 \\ 0 & -\frac{1}{T} \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ \frac{K\delta_{\max}}{T} \end{bmatrix} \quad (4)$$

는 계수행렬들이다. 신경망을 이용한 Identification 를 위하여 본 논문에서는 $T = 166.7 \text{ s}^{-1}$,

$K = 0.1205 \text{ s}$, $\delta_{\max} = 35/180 * \pi$ 를 사용하였다 [8]. 이 값들을 대입하면 계수행렬들은 다음과 같이 된다.

$$A = \begin{bmatrix} 0 & 1 \\ 0 & -0.0060 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ 0.4417 \end{bmatrix} \times 10^{-3} \quad (5)$$

식 (5) 의 계수행렬을 갖는 식 (4) 를 자료추출 주기, $\Delta t = 1 \text{ s}$ 로 이산화하면 다음과 같은 식이 얻어진다.

$$\begin{aligned} x_{k+1} &= x_k + dx_k(x_k, u_k) \\ dx_k(x_k, u_k) &= \Phi x_k + \Gamma u_k \end{aligned} \quad (6)$$

여기서

$$\Phi = \begin{bmatrix} 0 & 0.9970 \\ 0 & -0.0060 \end{bmatrix}, \quad \Gamma = \begin{bmatrix} 0.2204 \\ 0.4403 \end{bmatrix} \times 10^{-3} \quad (7)$$

가 되는데 식 (5) 또는 (7) 로 부터 알 수 있는 사실은 타각이 선수각과 각속도에 미치는 영향이 미소하다는 것이다. 이는 바로 타의 제어성능 (Controllability) 을 나타내는 지표이기도 하는데 선수각에 대한 운동방정식 하나만 보더라도 제어 성능이 비교적 낮음을 알 수 있다. 그러므로 제어 성능이 낮은 타를 조종하여 최대의 조종효과를 얻기 위해서는 제어기법의 선택상 주의를 요한다.

3. 신경망이론

신경망(Neural Network) 알고리즘은 서로 연결된 기하학적인 형태, 신경조직상의 특징, 학습법칙으로 표현된다. 개개의 신경전달단위는 오직 국부적인 정보에 근거하여 계산을 수행하는데 이렇게 생물학으로부터 유래된 계산흐름은 새로운 형태의 종합적인 계산흐름을 제공한다. S 자 형태의 활성화단위 (Activation Unit) 를 갖는 신경망은 임의의 함수를 근사시킬 수 있는 기능을 갖춘 것으로 입증되었는데 이는 수학적으로 Back-Propagation 신경망이 사상 (Mapping) 을 할 수 있는 능력을 지니고 있음을 의미한다. 이런 수학적인 기초에 근거하여 Back-Propagation 신

경망이 군사암호체계, 의학 진단, 언어인식, 로봇 제어 등에 성공적으로 적용되었다[6].

신경망에는 여러개의 신경층이 사용될 수 있는데 신경망의 k 번째 층(Layer) 의 i 번째 활성화신경단위의 입력과 출력에 대한 계산은 다음과 같이 진행된다.

$$u_i^k = \sum_{j=1}^{N^{k-1}} W_{ij}^k v_j^{k-1} + b_i^k, \quad i=1,2,\dots,N^k \quad (8)$$

$$v_i^k = g_i^k(u_i^k), \quad i=1,2,\dots,N^k \quad (9)$$

여기서 $g_i^k(u_i^k)$ 는 보통 활성화함수로 불리는데 연속적으로 미분가능하고 단조증가함수이어야 한다. N^{k-1} 는 $(k-1)$ 번째 층의 신경단위수를 나타내며, v_j^{k-1} 은 $(k-1)$ 층의 j 번째 신경단위의 출력을 나타내고 u_i^k 는 k 층의 활성화함수를 통과하기전의 중간값을 나타낸다. W_{ij}^k 는 $(k-1)$ 층의 j 번째 신경단위의 출력과 k 층의 i 번째 신경단위의 입력사이의 연결가중치를 나타낸다. b_i^k 는 k 층의 i 번째 신경단위의 외부편심을 나타내는데 편심은 정보의 치우침을 보정하기 위하여 도입된다. 이들 연결 가중치와 편심은 최종 출력의 오차에 근거하여 조정되어진다. 이렇게 조정되어지는 과정을 일반적으로 신경망학습이라고 칭한다.




Fig. 2 Functional diagram for a single neuron

한 개의 신경단위에 대한 기능을 표현한 식 (9) 간략하게 도식화한 그림이 Fig. 2 이다. 이와 같은 한 개의 신경단위가 다층신경망으로 Fig. 3 에 보

이는 바와 같이 결합되면 비선형 사상을 할 수 있는 기능을 갖추게된다. 첫번째 층은 입력이 이들 신경단위 들에 직접 영향을 주기 때문에 입력층이라고 칭해지며 마지막층은 신경망의 출력이 이들 신경단위들의 출력이기 때문에 출력층이라고 칭해진다. 출력층의 값과 원하는 값을 비교하여 같은 값이 되도록 가중치와 편심을 조절하게 된다. 실제로는 다음과 같이 표현되는 출력오차들의 제곱을 합한 값을 최소화하는 것이다.

$$E = \frac{1}{2} \sum_{i=1}^{N^l} (d_i - o_i)^2 \quad (10)$$

여기서 o_i 는 i 번째 흐름 단위의 실제출력이고 d_i 는 i 번째흐름 단위의 원하는 출력이다. 이 식은 신경망 훈련에 사용되는 일반적인 표현식이고 선박조종에 사용하기 위하여는 변형이 필요하다. 이에대해서는 다음 논문에서 다루기로 한다. 신경망의 가중치와 편심을 조정하는 과정은 최적화기법과 매우 유사하다. 연결가중치와 외부편심을 오차가 최소로 되도록 재조정하기 위해서는 E 의 Gradient Descent 가 필요하다. 숨겨진 층이 없을 경우에 연결가중치와 편심에대한 Gradient Descent 는 다음과 같이 유도된다.




Fig. 3 Multilayered back-propagation neural networks

$$\Delta w_{ij} = -\eta (d_i - o_i) \frac{\partial g_i(u_i)}{\partial u_i} I_j \quad (11)$$

$$\Delta b_i = -\eta (d_i - o_i) \frac{\partial g_i(u_i)}{\partial u_i} \quad (12)$$

여기서 η 는 학습율을 나타내며 I_j 는 j 번째 입력을 나타낸다. Δw_{ij} 와 Δb_i 는 주어진 입력과

원하는 값의 차이를 줄이기위하여 연결가중치와 편심에 적용되는 변화량을 의미한다.

이를 바탕으로 개개의 가중치와 편심이 조정되게 된다. 그렇지만 다층의 신경망조직에서는 원하는 신경망출력과의 오차가 신경망내의 개개의 요소에 대한 출력오차로 바로 이어지지 않는다. 이런 이유로 입력층과 출력층 사이의 층들은 숨겨진 층으로 불린다. 이렇게 숨겨진 층들의 가중치와 편심을 재조정하는 방법에 대한 의문이 생기는데 이를 해결하는 방법으로 제시된 것이 Back-Propagation 학습 알고리즘이다. 층 하나를 갖는 신경망의 경우와 마찬가지로 가중치와 편심들은 Gradient Descent 기법을 사용하여 조정되는데 이 과정에서 최종의 출력층으로부터 앞층으로 차례로 오차가 전파되어 조정이 됨으로 인해 Back-Propagation 이라고 불리게 되었다. Updating 법칙은 다음과 같이 표현된다.

$$\Delta w_{ij}^p = -\eta(d_i - o_i) \frac{\partial g_i^p(u_i^p)}{\partial u_i^p} v_j^{p-1} = \eta \delta_i^p v_j^{p-1} \quad (13)$$

$$\Delta b_i^p = -\eta(d_i - o_i) \frac{\partial g_i^p(u_i^p)}{\partial u_i^p} = \eta \delta_i^p \quad (14)$$

여기서

$$\delta_i^p = -(d_i - o_i) \frac{\partial g_i^p(u_i^p)}{\partial u_i^p} \quad (15)$$

이며 δ 변수를 도입한 것은 숨겨진 층에 대한 계산 알고리즘을 간략화하기 위한 것이며 개개의 δ_i^k 는 신경망을 통해 앞의 층으로 전달되는 오차로 생각할 수 있다.

실제 수치계산을 위하여는 국부최소점에 빠질 위험성을 배제하기 위하여 다음과 같이 모멘텀을 포함한 식을 사용하게 된다.

$$\Delta w_{ij}^p = \eta \delta_i^p v_j^{p-1} + \alpha (\Delta w_{ij}^p)_{previous} \quad (16)$$

$$\Delta b_i^p = \eta \delta_i^p + \alpha (\Delta b_i^p)_{previous} \quad (17)$$

여기서 α 는 전진방향으로 모멘텀을 주기위한 상수이다. 이외에도 신경망의 수렴성을 높이기위한 여러가지 방법이 제안되었으나 본 논문에서는 식 (16) 과 (17) 을 이용하여 계산하였다.

위에서 소개한 Back Propagation 방법은 일반적인 형태이어서 선박조종모델 Identification 및 자동제어에 적합하지 않다. 그래서 본 논문에서는 선박조종모델과 제어기설계에 합당하도록 새로운 Identification 방법을 제시하였고 신경망제어기설계방법을 개발하였다.

4. 신경망 System Identification

선박조종모델은 비선형성을 포함하고 있고 또한 시간에 따라 변화하는 외부교란의 영향을 받고 있는 관계로 제어설계의 성공여부는 시스템 모델의 정확도에 의해서 좌우된다. 이는 선박의 선수각을 원하는 각도로 유지 또는 방향을 바꾸고자 할 경우에 정확한 시스템모델에 근거한 제어력을 산출하여야 한다는 것을 의미한다. 앞에서 소개한 간략화된 선박조종모델을 대상으로 신경망을 이용한 시스템 Identification 이 어떻게 이루어지는지를 조사하여 보기로 하자. 신경망을 이용한 시스템 Identification 은 Fig. 4 와 같은 블록선도를 이용하여 이루어진다. Fig. 4 의 ANN 은 인공신경망 (Artificial Neural Networks)을 나타낸다. 그림에서 보이듯이 현재의 상태와 타각이 배에 제공되는 경우에 대해 1 초후의 상태변화량을 신경망이 정확히 예측하도록 훈련되고 있다.




Fig. 4 System identification using artificial neural networks

그래서 우리가 최소화해야 하는 오차는 다음과 같

은 식으로 표현할 수 있다.

$$E = \frac{1}{2} \sum (\overline{dx_k} - dx_k)^T Q (\overline{dx_k} - dx_k) \quad (18)$$

여기서 Q 는 상태벡터변화량 dx_{k+1} 의 변수들 간의 영향을 조절하기 위한 가중치행렬이고 \sum 은 여러경우의 학습데이터에 관한 합을 의미한다. 이 경우에 Gradient Descent 는 다음과 같이 계산 되는데

$$\frac{\partial E}{\partial \beta} = - \sum \frac{\partial dx_k^T}{\partial \beta} Q (\overline{dx_k} - dx_k) \quad (19)$$

여기서 β 는 가중치 또는 편심이다. 이식을 이용하여 신경망의 가중치와 편심이 조정되게 된다. 본 논문에서 사용한 가중치행렬은 다음과 같다.

$$Q = \begin{bmatrix} 1 & 0 \\ 0 & 100 \end{bmatrix} \quad (20)$$

각속도에 대한 가중치를 크게한 이유는 배의 각속도가 매우 작기 때문이다. 신경망 모델이 정확한 값을 출력하도록 훈련하기 위하여는 많은 양의 학습데이터가 필요하다. 학습데이터는 실제 선박의 운용상태에서 구해질 수가 있지만 이런 방식으로 학습데이터를 확보하는데는 오랜 시간이 소요될 수 있다. 그래서 비교적 정확한 이론적인 수치 모델을 이용하여 신경망모델을 훈련하고 다시 실제 데이터로 재학습을 시키는 것이 합리적인 것으로 생각된다. 본 논문에서는 이론적으로 주어진 선박조종모델, 식 (6)을 사용하여 데이터를 구축하였는데 Ψ 와 $\tilde{\Psi}$, u 가 ± 1 사이의 값중에서 임의의 값을 취하도록 하고 1 초후의 상태벡터변화량, 즉 $dx_k(x_k, u_k)$ 를 식 (6) 을 이용하여 구한다. 이 값과 신경망의 출력이 같아지도록 신경망을 학습시켰다. 이와같은 학습을 위하여 2 개의 신경층을 이용하였는데 입력층은 3개의 입력단위 신경이 존재하고 그 다음층은 10개의 단위신경으로 이루어진다. 출력단위신경의 수는 2 개인데 이는 상태방정식이 2 개의 상태변수와 한개의 입력으로 이루어진 것에 기인한다. 두번째층의 신경단위수는 임의로 결정할 수 있다. 두번째층의 신경

단위수가 신경망의 수렴성에 미치는 영향은 본 논문의 목적에 부합되지 않아 다루지 않았지만 앞으로 보다 복잡한 모델을 다룰 경우에는 중요한 변수로 작용될 것이므로 추후의 연구과제라고 말할 수 있다. 각 신경단위의 활성화함수는 선형함수를 사용하였는데 이는 Identification 하려는 모델자체가 선형계이기 때문에 선형함수로서의 근사가 쉽기 때문이다. 물론 Sigmoidal 함수와 같은비선형활성함수를 이용할 수도 있다. 본 연구에서 고려한 시스템이 선형계이기 때문에 비선형활성함수를 사용하는 경우에는 수렴도가 낮았지만 실제 시스템이 비선형계라면 비선형활성함수를 사용하는 것이 바람직스럽다.

이와같이 구축된 학습데이터를 이용하여 신경망을 훈련하였는데 학습회수에 따른 오차감소는 Fig. 5 에 나타난 바와 같다. 그림에서 보이듯이 상당히 적은 학습회수로도 비교적 정확도가 높은 신경망모델을 얻을 수 있었는데 이는 선박조종모델이 간단한 2 차 선형미분방정식으로 주어진 때문인 것으로 생각된다. 신경망을 이용하여 System Identification 수행하는데 있어 학습을 15,000번까지 실시한 이유는 선박조종모델의 1 초후 변화량, 그중에서도 각속도 변화량이 매우 작아서 오차값 자체가 너무 작아지기때문이다. 이는 선박의 동적 거동 자체가 느려 1 초후의 변화가 작은 사실에 기인한다.

신경망에 사용한 활성화함수가 선형함수이기때문에 신경망자체도 선형계가 된다. 그렇다면 신경망의 식이 과연 식 (6) 으로 주어진 선형계와 같아지는지 조사할 필요가 있다. 15,000 번의 학습후 얻어진 신경망의 식은 다음과 같다.

$$(dx_k)_{nm} = \begin{bmatrix} 0 & 0.9970 \\ 0 & -0.0060 \end{bmatrix} x_k + \begin{bmatrix} 0.2204 \\ 0.4402 \end{bmatrix} \times 10^{-3} u_k \quad (21)$$

식 (21) 을 식 (7) 과 비교해 보면 신경망모델이 실제모델과 거의 일치함을 알 수 있다.

이와같이 학습된 신경망모델과 실제조종모델에 임의의 타각을 입력시켜 구한 결과를 비교한 결과가 그림 6 부터 7 에 나타나 있다. 이들 그림에서 볼 수 있듯이 신경망모델은 거의 차이를 볼 수 없을 정도로 정확한 결과를 보여주고 있다. 그림에서 \times 는 이론모델로 부터 얻어진 값을 나타내며 실선은 신경망모델로 부터 얻어진 Simulation 결과를 나타낸다.




Fig. 5 Training error in neural network system identification

이론모델에 가해졌던 20 도 Zig-Zag 조종이 학습을 통하여 얻어진 등가 신경망 조종모델에 같은 시간에 가해진 결과가 그림 6 부터 7에 보여지고 있다. 이들 그림에서 보여지듯이 이론모델과 신경망모델로 부터 얻어지는 결과에는 거의 차이가 없음을 알 수 있다. 다음으로 타틀 35 도로 고정된 Turning 조종에 대한 Simulation 결과가 Fig. 8 과 9 에 나타나있다.

Fig. 8 에서 보이듯이 시간이 진행됨에 따라 오차가 약간 커지고 있음을 알 수 있다. 이는 각도가 계속해서 커짐으로 인해 학습에 사용되었던 각도보다 큰 값이 신경망에 제공되고 이로 인해 신경망모델의 출력에 오차가 생기기 때문이다.

이상과 같은 수치계산에서 관찰되듯이 신경망 모델이 이론모델을 대체할 수 있음을 알 수 있다. 더 나아가서 비선형활성함수를 사용하는 신경망을 이용한다면 이론모델에서 예측할 수 없는 비선형성을 구현할 수 있으므로 신경망모델의 효용성이

이론모델보다 높다고 말할 수 있다. 그러나 보다 정확한 신경망모델을 구축하기 위해서는 선박의 운동에 영향을 미치는 변수들을 신경망모델의 입력으로 제공하는 것이 바람직하다. 단, 이들 변수들은 정량적으로 계측가능한 변수이어야 한다.




Fig. 6 Time history of heading angle for 20 / 20 degree zig-zag test




Fig. 7 Time history of yaw rate for 20 / 20 degree zig-zag test

5. 고찰 및 결론

본 연구에서 선박용 자동조타 시스템 개발을 위하여 비선형성이 포함되고 있는 선박조종모델을 System Identification 할 수 있는 기법으로서 인공신경망을 이용한 System Identification 방법을 제시하였다. 신경망은 글자인식, 형상인식과 같이 입력과 출력사이의 관계식을 설정하기 어려운 문제들에 적용되어 그 효용성을 입증하였는데




Fig. 8 Time history of heading angle for 35° port rudder turn




Fig. 9 Time history of yaw rate for 35° port rudder turn

기존의 제어방법으로 접근이 어려웠던 문제를 해결하는 한 방법으로 제시되어 사용되고 있다. 본 연구에 도입된 신경망기법은 설계자가 원하는 형태로 변형될 수 있으며 시스템의 파라미터가 변화될 경우에는 그 변화량을 신경망모델을 통하여 재학습하여 변화에 적응할 수 있는 성능이 우수한 방법이다.

본 연구에서는 신경망기법을 이용하여 선박의 자동조타장치를 개발하기 위해서 신경망의 선박조종모델 대체가능성을 조사하였다. System Identification 결과 신경망이 선박조종모델을 대체할 수 있음을 입증하였는데 보다 복잡한 형태의 조종방정식에도 적용이 가능할 것으로 예상된다.

신경망 제어기법을 선박조종에 적용하는데 있어

서 가장 큰 문제점은 학습데이터를 어떻게 구축할 것인가이다. 이런 문제점을 해결하기 위해서는 비교적 정확한 이론모델을 가지고 데이터를 산출하여 신경망모델을 훈련하고 후에 실제데이터를 이용하여 재학습하는 2단계 학습이 합리적일 것으로 보인다.

후기

본 연구는 한국기계연구원 선박해양공학연구센터의 위탁과제로서 수행되었다.

참고 문헌

- [1] Minorsky, N., "Directional Stability of Automatically Controlled Steered Bodies", J. Amer. Soc. Nav. Eng., Vol. 34, 1922.
- [2] 서상현외, "선박용 Auto-Pilot 시스템 개발 (I)", 한국기계연구원 선박해양공학연구센터 보고서, UCN 295-1725 D, 1993.
- [3] 김선영외, "조종성능 추정기법 개발 (I)", 한국기계연구소 보고서, UCE 337-1082 D, 1988.
- [4] White, D.A and Sofge, D.A., Handbook of Intelligent Control - Neural, Fuzzy, and Adaptive Approaches, Van Nostrand Reinhold, New York, 1992.
- [5] Hertz, J.A, Krogh, A.S., and Palmer, R.G., Introduction to the Theory of Neural Computations, Addison-Wesley, Redwood City, 1991.
- [6] Nadrendra, K.S. and Parthasarathy, K., "Identification and Control of Dynamical Systems Using Neural Networks", IEEE Trans. on Neural Networks, Vol. 1, No. 1, 1990, pp. 4-27.
- [7] Biancardi, C.G., "On a Simplified Mathematical Model for an Onboard Maneuvering Simulator and its Potential Applications to Ship Control", International Shipbuilding Progress, Vol. 35, 1988, pp. 401.
- [8] Layne, J.R. and Passino, K.M., "Fuzzy Model Reference Learning Control for Cargo Ship Steering", IEEE Control Systems, December 1993, pp. 23-34.