

인공신경망을 이용한 선박의 자동접안 제어에 관한 연구

배철한† · 이승건* · 이상의** · 김주한***

†, ***부산대학교 조선해양공학과 대학원, *부산대학교 조선해양공학과 교수, **부산대학교 조선해양공학과

A Study of the Automatic Berthing System of a Ship Using Artificial Neural Network

Cheol-Han Bae† · Seung-Keon Lee* · Sang-Eui Lee** · Ju-Han Kim***

†, ***Graduate school of Department of Naval Architecture and Ocean Engineering
Pusan National University, Busan 609-735, Korea

*, **Department of Naval Architecture and Ocean Engineering
Pusan National University, Busan 609-735, Korea

요약 : 선박의 접안운동을 자동화하기 위하여 인공신경망(Artificial Neural Network, 이하 ANN)에 의한 제어를 수행하였다. ANN은 시스템의 비선형성이 표현 가능하므로 접안운동과 같은 비선형성이 강한 조종운동에 적합하다. 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 다층 인식자(Multi-layer perceptron)를 사용하였고, 교사 데이터(Teaching data)와 역전파(Back-propagation) 알고리즘을 사용하여 신경망의 출력값과 목표 출력값 사이의 오차가 최소가 되도록 신경망 학습을 수행하였다. 접안 시 저속조종 수학모델을 사용하여 접안 시뮬레이션을 수행하였으며, ANN의 입력층 성분(unit)이 8개인 구조와 6개인 구조의 접안 제어를 비교하였다. 시뮬레이션 결과, 두 ANN에 의하여 접안 경로 선택에 차이가 나타났으나 접안 조건은 모두 만족하였다.

핵심용어 : 자동접안, 인공신경망, 저속조종 수학모델, 다층 인식자, 오류 역전파 알고리즘

Abstract : In this paper, Artificial Neural Network(ANN) is applied to automatic berthing control for a ship. ANN is suitable for a maneuvering such as ship's berthing, because it can describe non-linearity of the system. Multi-layer perceptron which has more than one hidden layer between input layer and output layer is applied to ANN. Using a back-propagation algorithm with teaching data, we trained ANN to get a minimal error between output value and desired one. For the automatic berthing control of a containership, we introduced low speed maneuvering mathematical models. The berthing control with the structure of 8 input layer units in ANN is compared to 6 input layer units. From the simulation results, the berthing conditions are satisfied, even though the berthing paths are different.

Key words : Automatic berthing system, Artificial neural network(ANN), Low speed maneuvering mathematical model, Multi-layer perceptron, Back-propagation algorithm

1. 서 론

선박의 조종운동 중 중요한 과제인 접안을 자동화하기 위하여 ANN(Artificial Neural Network)에 의한 제어와 관련된 연구가 Hasegawa 등(1993)과 곽 등(1997), 이 등(1998)에 의해 행해진 바 있다. ANN은 입력층, 중간층, 출력층의 구조로 구성되어 있으며 각 층은 하나 이상의 성분들로 이루어져 있다. Hasegawa 등(1993)과 이 등(1998), 임(2007)은 ANN의 입력층 성분을 8개로 구성하였다. 본 연구에서는 ANN의 중요한 성분인 입력층, 은닉층 및 출력층을 각각 6개, 6개, 2개로 구성(6-6-2 ANN) 하였고, 입력층이 8개의 성분(unit)으로 구성된 ANN(8-8-2 ANN)과

다방향으로 목표점에 접근하는 것을 비교하여 6-6-2 ANN으로도 선박의 접안 제어가 가능하다는 것을 시뮬레이션을 통하여 나타내었다. 시뮬레이션에 사용된 선박은 304 미터(m)의 유조선(Tanker)이며, 조종운동 수학모델은 Kose(1984)의 저속조종 수학모델을 사용하였고, 프로펠러 역전에 의한 유체력을 Hasegawa(1983) 등의 모형시험결과를 인용하였다.

2. 저속 시 조종운동 수학모델

Fig. 1은 선박에 적용된 좌표계로, $O_0 - x_0, y_0$ 는 공간 좌표계이고 $O - x, y$ 는 선체중심고정 좌표계이다. u, v 는 각각 전

† 교신저자 : 배철한(정희원), foch1130@pusan.ac.kr 051)510-2755

* 종신회원, leesk@pusan.ac.kr 051)510-2441

** 정희원, euuizoo@pusan.ac.kr 051)510-2755

*** 정희원, kjh9461@naver.com 051)503-9461

후요(Surge), 좌우요(Sway) 방향의 속도이며 U 는 선박의 속도이다. r 과 ψ 는 각각 선수요(Yaw) 방향의 각속도와 방위각이며 δ 는 타각, β 는 편류각이다.

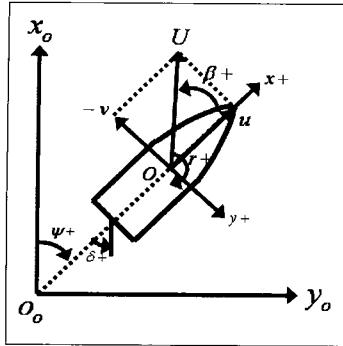


Fig. 1 Coordinate system

시뮬레이션에 사용된 선박의 3자유도 조종운동방정식은 MMG model을 사용하였고(Ogawa et al., 1997; Hamamoto et al., 1997; Kasai et al., 1997), 선박의 3자유도 조종운동방정식은 아래와 같이 표현된다.

$$(m+m_x)\dot{u} = (m+m_y+X_{vr})vr + X_{uu}|u|u + X_{uvv}uv^2/U + X_{vvr}|v|r/vr/U + X_P - (1-t_R)F_N \sin \delta - R \quad (1)$$

$$(m+m_y)\dot{v} - Y_r \dot{r} = Y_r v U + Y_{vv}|v|r + Y_{vvvv}v^5 U^3 + Y_r r + Y_{ur} ur + Y_{u vr} uv^2 r/U^2 + Y_{v rr} vr^2/U + Y_P - (1+a_H)F_N \cos \delta \quad (2)$$

$$(I_{zz} + J_{zz})\dot{r} - N_v \dot{v} = N_{uv} uv + N_r r + N_{rrr} r^3 + N_{ur} ur + N_{vvr} v^2 r + N_P - (x_R + a_H x_H)F_N \cos \delta \quad (3)$$

단, R 은 전저항

항만에서의 접안 시, 선박은 저속으로 항행을 한다. 따라서 중고속 조종수학모델과 저속조종 수학모델과의 큰 차이점은 선체(Hull) 유체력이며, 이를 위하여 선체 유체력으로 Kose (1984) model을 이용하였다. 선박이 정지를 위하여 프로펠러를 역전시킬 경우, 순전 시와 달리 비대칭적인 좌우요 힘(sway force)과 선수요 모멘트(yaw moment)가 선체에 작용하게 되며, 이로 인한 프로펠러의 역전에 의한 유체력은 Hasegawa 등 (1994)에 의한 실험결과를 사용하였으며, 부가질량과 부가관성 모멘트는 Motora(1960) 추정법에 의하여 구하였다. 선박의 제원 및 유체력 계수들과 식(1)~(3)의 조종운동방정식의 자세한 내용은 Hasegawa 등(1993)을 참조하기 바란다.

3. 인공신경망의 적용

3.1 인공신경망의 구조

ANN은 뇌와 같은 생물학적 신경 시스템이 정보를 처리하는

방법에 의하여 생겨난 정보를 처리하는 패러다임이다. ANN은 초기 경험(initial experience)이나 훈련(training)을 위해 주어진 데이터를 기초로 하여 학습을 하고, 학습하는 시간동안 정보의 의미를 받아들이거나 스스로의 체계를 생성할 수 있다.

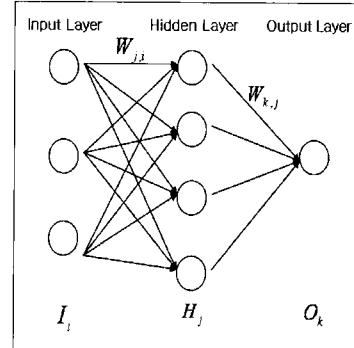


Fig. 2 Multi-layer perceptron

다층 인식자(Multi-layer perceptron)는 입력층(Input Layer)과 출력층(Output Layer) 사이에 하나 이상의 중간층(은닉층, Hidden Layer)이 존재하는 신경망으로 Fig. 2와 같은 구조를 가진다. 입력층, 은닉층, 출력층 방향으로 네트워크가 연결되어 있는 전방향(feedforward) 네트워크이다.

3.2 인공신경망의 학습

역전파(Back-propagation)는 신경망을 훈련시키기 위한 것이고 전방향 네트워크를 위해서만 사용한다. 신경망의 학습을 위해 입력 및 목표 출력 패턴이 네트워크에 제시된다. 네트워크의 입력층에서 주어진 입력 패턴이 출력층으로 전파되고, 출력층에서의 출력 패턴을 목표 패턴과 비교하게 된다. 출력된 패턴이 목표 패턴과 일치하지 않는 경우, 출력 패턴과 목표 패턴의 차이를 감소시키는 방향으로 네트워크의 연결강도를 조절하여 학습을 하게 되며, 출력 패턴과 목표 패턴이 일치하는 경우에는 학습이 일어나지 않는다. 오류역전파 알고리즘은 Fig. 3에 나타나 있으며, 다음의 방법으로 계산되어 ANN이 학습된다.

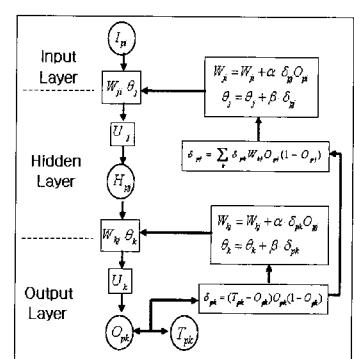


Fig. 3 Error back-propagation algorithm

$$U_j = \sum_i W_{ji} I_{pi} + \theta_j \quad (4)$$

$$H_{pj} = Sg(U_j)$$

(5) j 의 편이량 θ_j 를 수정한다.

$$U_k = \sum_j W_{kj} H_{pj} + \theta_k$$

$$\begin{aligned} (6) \quad & W_{ji} = W_{ji} + \alpha \delta_{pj} I_\pi \\ & \theta_j = \theta_j + \beta \delta_{pj} \end{aligned} \quad (11)$$

$$O_{pk} = Sg(U_k)$$

(7) 단, α , β 는 학습율

여기서

 I_{pi} : 패턴 p 의 입력층의 성분 i 의 출력 H_{pj} : 패턴 p 의 은닉층의 성분 j 의 출력 O_{pk} : 패턴 p 의 출력층의 성분 k 의 출력 U_j : 은닉층의 성분 j 의 활성(Activation) U_k : 출력층의 성분 k 의 활성 T_{pk} : 패턴 p 의 출력층의 성분 k 에 대한 목표출력 θ_j : 은닉층의 성분 j 의 편이량(offset) θ_k : 출력층의 성분 k 의 편이량 W_{ji} : 은닉층 성분 j 와 입력층 성분 i 의 연결가중치 W_{kj} : 출력층 성분 k 와 은닉층 성분 j 의 연결가중치 Sg : 시그모이드 함수, $f(x) = \frac{1}{1+e^{-x}}$

학습 패턴의 목표 출력 T_{pk} 와 실제 출력 O_{pk} 와의 차로부터 출력층 성분 k 에 연결된 연결강도와 출력층 성분 k 의 편이량에 대한 오차 δ_{pk} 를 구한다.

$$\begin{aligned} \delta_{pk} &= (T_{pk} - O_{pk}) f'_k(NET_{pk}) \\ &= (T_{pk} - O_{pk}) O_{pk}(1 - O_{pk}) \end{aligned} \quad (8)$$

오차 δ_{pk} 와 중간층과 출력층 간의 연결강도 W_{kj} 와 중간층의 출력 H_{pj} 로부터 중간층 성분 j 에 연결된 연결강도와 중간층 성분의 편이량에 대한 오차 δ_{pj} 를 구한다.

$$\begin{aligned} \delta_{pj} &= f'_k(H_{pj}) \sum_k \delta_{pk} W_{kj} \\ &= \sum_k \delta_{pk} W_{kj} H_{pj} (1 - H_{pj}) \end{aligned} \quad (9)$$

출력층 성분 k 에서의 오차 δ_{pk} , 중간층 성분 j 의 출력 H_{pj} , 정수 α 와의 곱을 더하여 중간층 성분 j 와 출력층 성분 k 에 연결된 연결강도 W_{kj} 를 수정한다. 또한 오차 δ_{pk} 와 정수 β 와의 곱을 더하여 출력층 성분 k 의 편이량 θ_k 를 수정한다.

$$\begin{aligned} W_{kj} &= W_{kj} + \alpha \delta_{pk} H_{pj} \\ \theta_k &= \theta_k + \beta \delta_{pk} \end{aligned} \quad (10)$$

역시 같은 방법으로 중간층 성분 j 의 오차 δ_{pj} 를 이용하여 입력층과 중간층 성분에 연결된 연결강도 W_{ji} 와 중간층 성분

이러한 방법으로 다음 패턴을 학습시켜 모든 패턴에 대해 신경망을 학습을 시키게 된다. 이 때, 패턴 p 의 교사 데이터에 대한 오차를

$$E_p = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (12)$$

로 정의하면 전체 패턴의 교사 데이터에 대한 오차는

$$E = \sum_p E_p \quad (13)$$

와 같이 정의될 수 있다. 전체 교사 데이터에 대한 오차 E 가 최소가 될 때까지 가중치들을 조절해 나가는 것이 인공신경망을 훈련시켜 나가는 과정이며, 오차 E 가 작을수록 인공신경망의 정도는 높아지게 된다.

3.3 인공신경망의 선박에의 적용

본 연구에서 비교를 위해 사용된 8-8-2 ANN과 6-6-2 ANN의 구조를 Fig. 4에 나타내었다. 선박의 회두각과 선속을 제어하기 위하여 출력값은 δ (타각)와 n (rps)이 되며, 이를 출력값에 영향을 주는 항들이 바로 입력층의 성분들이다. 8-8-2 ANN은 Fig. 5에 나타나 있는 것과 같이, 점안점을 원점으로 하는 공간 좌표계를 각각 y_0/L 와 x_0/L 로 무차원화한 ξ 와 η , 선체 중심고정 좌표계인 x 와 y 그리고 u , v , r , ψ 를 입력층의 성분으로 가진다. 6-6-2 ANN은 8-8-2 ANN에서 좌표계 성분이 두 쌍이 존재하므로 x 와 y 를 제외한 나머지 6개의 성분으로 입력층의 unit이 구성하였다.

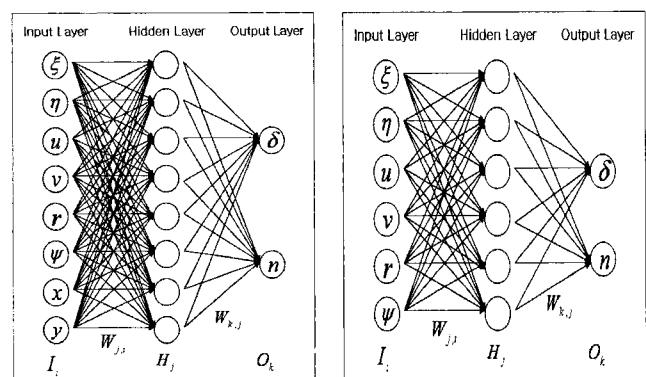


Fig. 4 Structures of neural network adopted as a controller

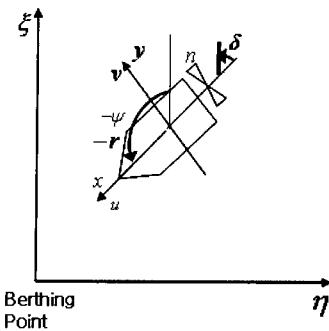


Fig. 5 Coordinate system for ship berthing

한국항만협회(2005)의 접안상황에 따르면, 유조선의 경우 계류시설에서 약간 떨어진 위치에 계류시설과 평행이 되도록 정지한 후 수 척의 끝배로 천천히 밀면서 접안하고, 선박이 방충재에 접촉할 때의 접안각도는 통상 $0^{\circ} \sim 10^{\circ}$ 로 설계조건에 주어져 있다. 따라서 시뮬레이션 상의 가정으로, 계류시설에 약간 떨어진 위치를 접안점이라 가정하였고, 접안점에서 선박이 계류시설과 0° 에서 최대 20° 의 접안각을 이루도록 하였으며, 접안점과 선박 중심과의 거리가 $1L$ 이내이며 선박의 속도가 $0.1 m/s$ 이하가 되면 제어가 끝난 것으로 가정하였다. 이 접안점을 향하여 다양한 방향에서 접근하는 경우에 대하여 8-8-2 ANN과 6-6-2 ANN을 비교하였다.

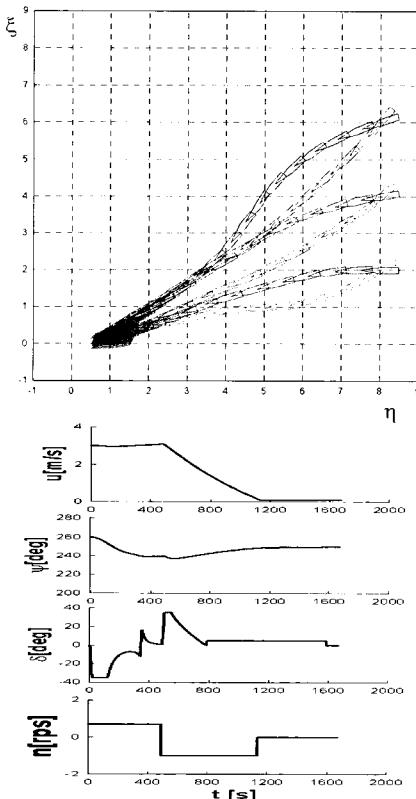


Fig. 6 Patterns of Teaching Data

ANN을 훈련시키기 위한 교사 데이터를 Fig. 6에 나타내었다. Fig. 6의 그래프는 교사 데이터 중에서 하나의 패턴에 대

한 데이터를 예로 나타내었다. $[0, 0]$ 지점을 접안점으로, $[0, -1]$ 지점을 계류시설로 가정하였다. 접안점인 $[0, 0]$ 을 중심으로 반경 L 안에 선박의 중심이 들어오면 접안점에 도착하였다고 가정하였다. PD 제어에 의해 선박을 접안시킨 하나의 경로에 대해 입·출력층에 필요한 데이터들을 수집하였으며, 이러한 과정을 Fig. 6과 같이 6개의 경로들에 대하여 시행한 것으로 교사 데이터를 구성하였다. 데이터를 수집한 개수는 각 경로마다 일정시간 간격으로 경로당 50개의 데이터를 받아 총 300개의 데이터가 사용되었다. 8-8-2 ANN과 6-6-2 ANN에 동일한 교사 데이터를 이용하여 신경망을 훈련시켰다.

4. 접안 시뮬레이션 결과

학습된 ANN을 이용한 접안 시뮬레이션은 Fig. 7과 같은 알고리즘으로 수행하였다.

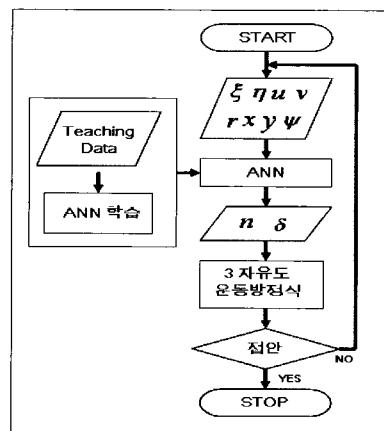


Fig. 7 Flowchart for berthing simulation with ANN

학습된 ANN을 통한 접안 시뮬레이션 결과를 아래에 나타내었다. 각 그림에서 $[\xi, \eta, \psi]$ 는 초기위치와 방위각을 나타낸다. 시뮬레이션의 초기조건은 $u_0 = 3 m/s$, $n = 0.7$, $\delta = 0^{\circ}$ 이다. 그림에서 'x'는 교사 데이터의 시작점을 나타내며, '■'는 계류시설을 나타낸다. 모든 시뮬레이션 결과에서, 시간에 따른 선박의 궤적을 나타내는 그림의 시간 간격은 80초이며, 그래프의 데이터는 1초 간격으로 받아들였다. 두 ANN은 동일한 교사 데이터로 훈련을 시켰다.

Fig. 8에서 Fig. 16까지 모든 시뮬레이션에서 선박이 접안 점 가까이에서 횡축 방향으로 이동하며 방위각이 변하는 것을 볼 수 있다. 이것은 선속의 감소를 위하여 프로펠러를 역전시킬 경우, 순전 시와 달리 비대칭적인 좌우요 힘과 선수요 모멘트가 선체에 작용하게 되었기 때문이다(Hasegawa 등, 1994). 따라서 프로펠러가 역전을 하는 $n < 0$ 인 구간에서는 선박이 횡축 방향으로 이동을 하고 선박의 방위각도 변화한다(Hasegawa 등, 2004). 그러나 프로펠러가 역전하는 초기에는 선박의 전진속도에 의한 힘이 프로펠러의 역전에 의해 선체에 작용하는 좌우요 힘과 선수요 모멘트에 비하여 상당히 크기

때문에 이들의 영향이 크지 않지만, 선속이 점차 감소함에 따라 이들의 영향이 점점 크게 나타나게 되어 선속이 작은 접안점 가까이에서는 선박이 이들의 영향을 크게 받게 된다. Fig. 8의 경우, 시뮬레이션이 시작되고 약 1200초 이후에 선박이 접안점 가까이에서 횡축 방향으로 이동하며 방위각이 조금씩 변하는 것을 볼 수 있다. 즉 선속이 작은 프로펠러의 역전이 끝나는 시점에서 좌우요 힘과 선수요 모멘트의 영향이 두드러지게 나타났다.

Fig. 8~9는 선박의 초기 위치가 교사 데이터의 시작점 중 한곳이며 초기 방위각만을 달리한 시뮬레이션의 결과이며, Fig. 10~13은 교사 데이터의 시작점이 아닌 곳을 선박의 초기 위치로 하여 시뮬레이션을 한 결과이다. Fig. 8~13의 결과에서, 두 ANN에 의한 선박의 접안은 모두 접안 조건을 만족하는 제어를 보여 주었다. 그러나 ANN의 입력층의 성분이 8개에서 6개로 줄어들면서 출력층의 두 성분 중 조타제어에 차이가 나는 것을 볼 수 있다. 모든 결과에서, 프로펠러의 역전에 의한 선박의 속도 제어는 두 ANN이 거의 일치하는 제어를 보여 주었다. 그러나 Fig. 10과 같이 선박의 궤적이 거의 일치하는 하는 경우에도 접안점이 가까워짐에 따라 타각의 차이가 나타났으며, Fig. 12~13과 같은 경우에는 처음부터 조타의 제어를 달리하여 다른 접안 경로로 이동하는 제어를 하였다. 즉 ANN의 입력층의 성분에서 두 좌표계 중 한 쌍을 제거함으로써 선박의 접안 경로 선택에 차이가 나게 되었다. Fig. 4에서, ANN의 입력층의 모든 성분들은 출력층의 두 성분에 영향을 주도록 구성되어 있지만 입력층의 좌표계 성분 한 쌍을 제거함으로써 조타 제어에 남은 한 쌍의 좌표계의 영향이 그만큼 증가하게 되었다. 따라서 이러한 영향은 시작점에서 접안점까지의 경로 선택의 차이를 가져왔으며, 접안점 가까이에서 선박의 최종 방위각이 비록 접안 조건에 만족하는 범위에 있으나 두 ANN에 의하여 조금씩 차이가 나는 것을 볼 수 있다. 이것은 6개의 교사 데이터의 궤적 범위 내에서 선박의 초기 위치를 설정한 Fig. 8~11의 결과 보다 교사 데이터의 궤적 범위 밖에서 선박의 초기 위치를 설정한 Fig. 12~13의 결과에서 더욱 두드러지게 나타났다. 또한 ANN에 의한 경로의 차이는 선박의 초기 위치가 Fig. 9, 11, 13에서와 같이 ξ 가 접안점에 가까울수록 8-8-2 ANN이 선박을 접안점에 도착하였을 때 계류시설과 좀 더 평행하게 제어하는 경향이 나타났다. 이와 반대로 선박의 초기 위치가 Fig. 10, 12와 같이 ξ 가 접안점에서 멀리 떨어질수록 6-6-2 ANN에 의해 선박이 접안점에 도착하였을 때 계류시설과 좀 더 평행하게 되는 경향을 보였다.

Fig. 8~13의 시뮬레이션 결과를 통하여 6-6-2 ANN으로 접안 조건을 만족하는 제어가 가능하다는 것을 알 수 있었다. 따라서 6-6-2 ANN을 사용하여 Fig. 14~16에서 교사 데이터에 의해 훈련되지 않은 영역에서 대해서 선박의 접안 제어를 시뮬레이션 한 결과를 나타내었다. 시뮬레이션의 시작부터 종료까지 모든 제어는 ANN에 의하여 이루어졌다.

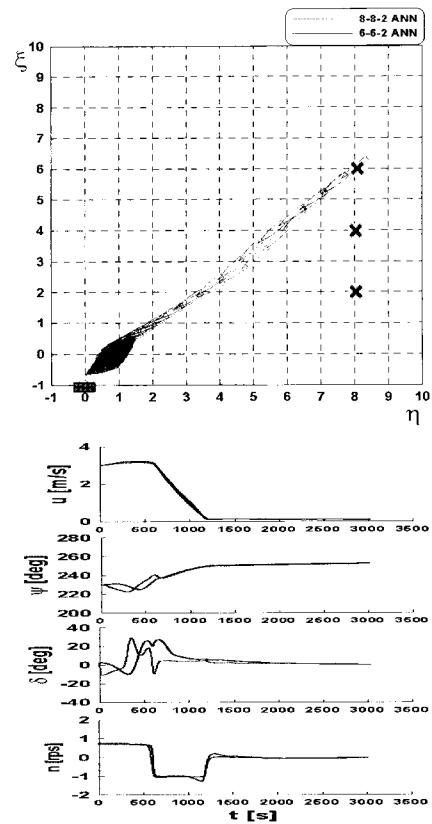


Fig. 8 Simulations using ANN, $[\eta, \xi, \psi] = [8, 6, 230^\circ]$

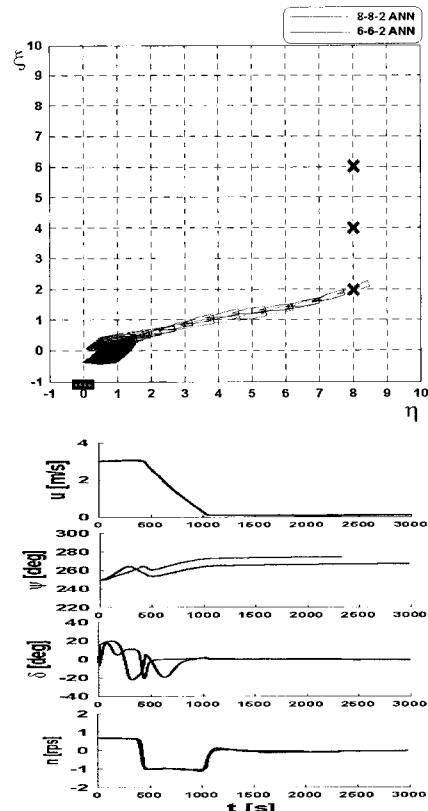


Fig. 9 Simulations using ANN, $[\eta, \xi, \psi] = [8, 2, 250^\circ]$

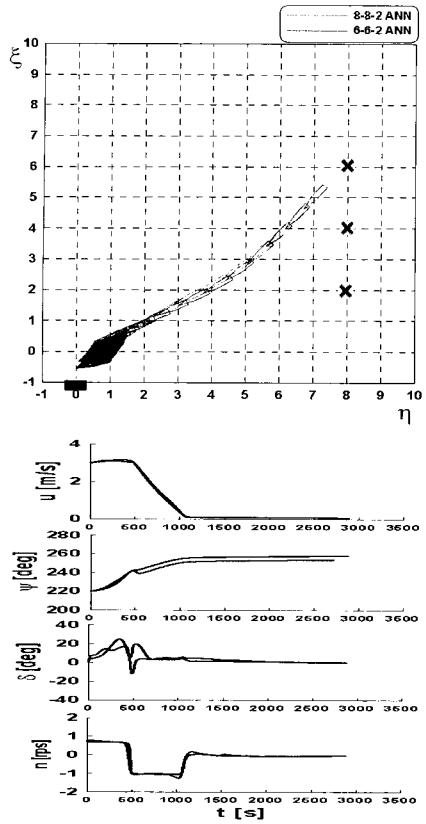


Fig. 10 Simulations using ANN, $[\eta, \xi, \psi] = [7, 5, 220^\circ]$

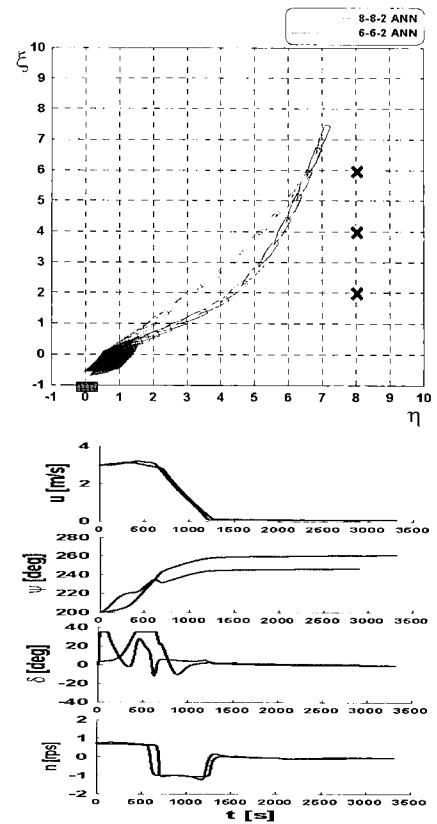


Fig. 12 Simulations using ANN, $[\eta, \xi, \psi] = [7, 7, 200^\circ]$

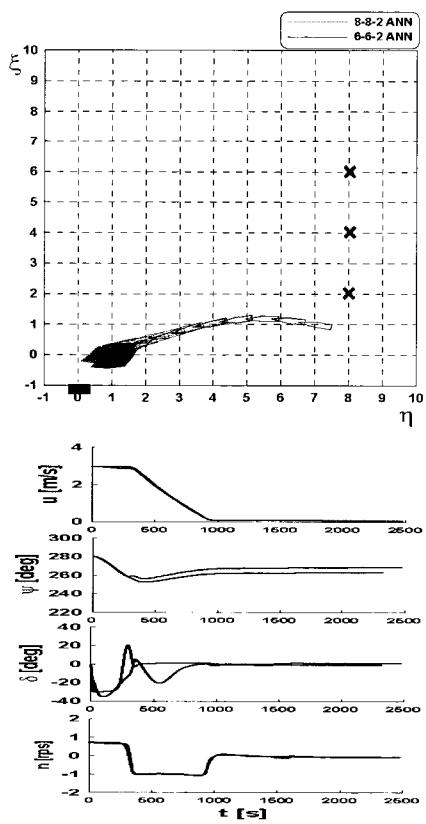


Fig. 11 Simulations using ANN, $[\eta, \xi, \psi] = [7, 1, 280^\circ]$

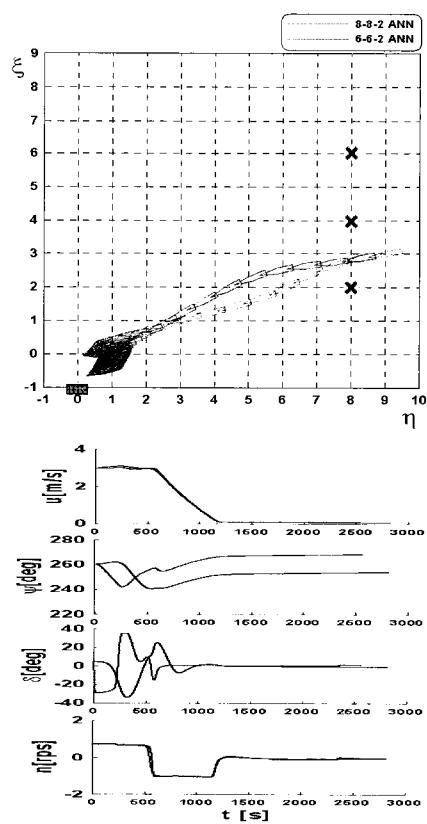


Fig. 13 Simulations using ANN, $[\eta, \xi, \psi] = [9, 3, 260^\circ]$

Fig. 14의 경우, 선박의 운동특성을 충분히 고려한 위치에서 선박이 어느 정도 접안 점을 향하도록 한 시뮬레이션 결과이다. ANN이 훈련되지 않은 영역에서는 선박의 타각이 약 $+5^\circ$ 정도 조타되어 있으나 선박의 운동 특성상 빠른 선회가 이루어지지 않으므로 큰 무리없이 선박이 ANN이 훈련된 영역으로 접근하였다. 훈련된 영역에서는 ANN에 의해 선박이 접안조건을 만족하여 시뮬레이션이 성공적으로 수행되었다.

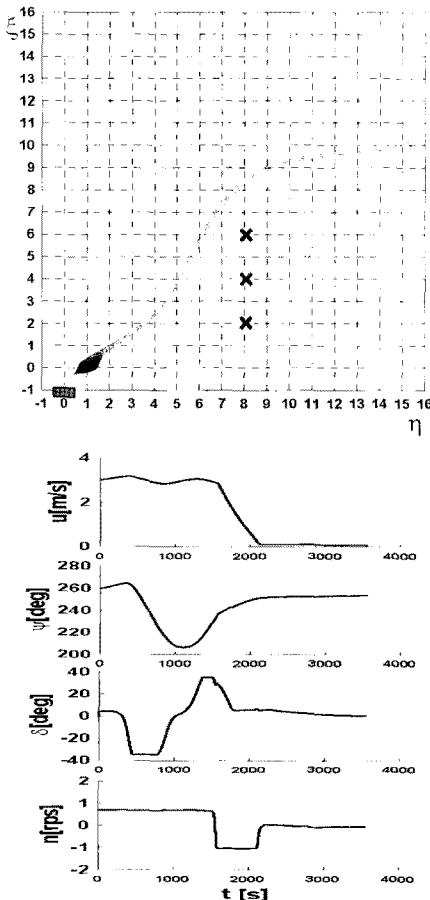


Fig. 14 Simulation using 6-6-2 ANN, $[\eta, \xi, \psi] = [15, 10, 260^\circ]$

Fig. 15에서는 선박이 ANN이 훈련된 영역에서 ANN에 의하여 접안점을 향해 급선회하였다. 따라서 급선회에 의한 전진 속도의 감소와 접안점에 근접하여 프로펠러의 역전에 의한 전진 속도의 감소가 중첩이 되어 선박이 접안점에서 멀리 떨어져 멈추었다.

Fig. 16은 선박이 접안점에서 접안조건을 만족할 수 없는 초기 조건으로 시뮬레이션 하였다. 다른 시뮬레이션과 다르게 ANN에 의하여 초기에 프로펠러가 역전하여 선박의 속도를 줄여 최대한 접안조건을 따르기 위한 제어가 되었다. 따라서 이러한 결과로 선박의 위치와 따라 선속을 다르게 제어함으로써, 좌표계 성분인 ξ 와 η 는 ANN의 출력층의 두 성분에 모두 크게 영향을 미치고 있다는 것을 알 수 있다.

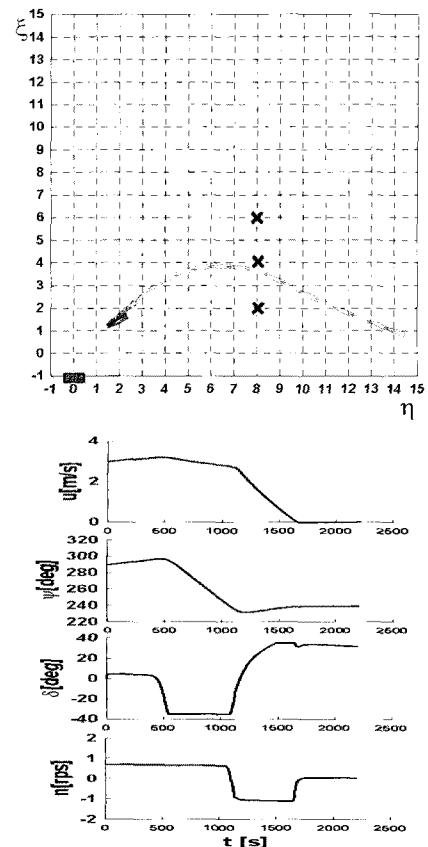


Fig. 15 Simulation using 6-6-2 ANN, $[\eta, \xi, \psi] = [14, 1, 290^\circ]$

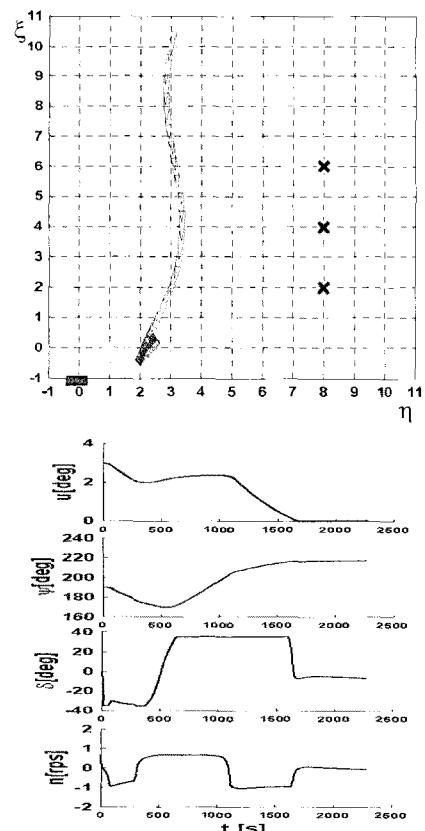


Fig. 16 Simulation using 6-6-2 ANN, $[\eta, \xi, \psi] = [3, 10, 190^\circ]$

5. 결 론

두 ANN에 의한 선박의 자동접안을 수행하였으며 그 결과를 요약하면 다음과 같다.

1. 입력총-은닉층-출력총의 8-8-2 구조의 ANN과 6-6-2 구조의 ANN의 제어 성능을 비교하였다. 8-8-2 ANN에서 입력총 성분 중 좌표계 성분 한 쌍(x, y)을 제거한 6-6-2 ANN을 구성하였다. 이로 인하여 조타 제어에 영향을 주었으며 두 ANN의 접안 경로의 선택이 선박의 초기 조건에 따라 차이가 나게 되었다.
2. 선박의 초기 위치에 따라, 8-8-2 ANN은 ξ 가 접안점에 가까울수록, 6-6-2 ANN은 ξ 가 접안점에서 멀어질수록 접안 점에 도착하였을 때 선박이 계류시설과 좀 더 평행하도록 제어를 하였다.
3. 두 ANN의 접안 경로의 선택에 차이가 나지만 접안 조건을 모두 만족을 하였다. 따라서 6-6-2 ANN에 의한 선박의 접안 제어가 가능였다.
4. 6-6-2 ANN에서 모든 입력총의 성분들이 ANN의 출력총 성분에 영향을 미치지만, 그 중 가장 많은 영향을 미치는 요소는 η 와 ξ 이다.

후 기

이 논문은 부산대학교 자유과제 학술연구비(2년)에 의하여 연구 되었다.

참 고 문 헌

- [1] 곽문규, 서상현(1997a), “신경망을 이용한 선박용 자동조타장치의 제어시스템 설계(I)”, 대한조선학회 논문집, 제 34권 2호.
- [2] 곽문규, 서상현(1997b), “신경망을 이용한 선박용 자동조타장치의 제어시스템 설계(II)”, 대한조선학회 논문집, 제 34권 3호.
- [3] 김대수(1992), “신경망 이론과 응용(1)”, 하이테크정보, pp.91-142.
- [4] 이승건(2004), “선박운동·조종론”, 부산대학교 출판부, pp.125-214.
- [5] 이승건, 이경우, 이승재, 정성룡(1998), “선박 자동접안 시스템 구축을 위한 인공신경망의 적용”, 한국항해항만학회:학술대회지, 춘계학술발표회 논문집, pp.111-119.
- [6] 임남균(2007), “인공신경망을 이용한 다방향 접근 시 선박 자동 접이안 제어기 연구”, 제어·자동화·시스템공학 논문지, 제 13권, 제 4호.
- [7] 한국항만협회(2005), “항만설계기준 - 제 2편 설계조건”, <http://www.koreaports.or.kr>, pp.24-30.
- [8] Hamamoto, M.(1997), “MMG Report II”, ibid., No.577.
- [9] Hasegawa, K. and Kitera, K.(1993), “Mathematical Model of Manoeuvrability at Low Advance Speed and its Application to Berthing Control”, ibid., Osak, Japan, pp.144-153.
- [10] Hasegawa, K. and Fukutomi, T.(1994), “On harbour manoeuvring and neural control system for berthing with tug operation”, Proc. of 3rd International Conference Manoeuvring and Control of Marine Craft(MCMC'94), pp.127-210.
- [11] Hasegawa, K., Nishino, M., Hachii, T., Kang, D. H., and Im, N. K. (2004), “Automatic Teaching Data Creation for Automatic Control System using Artificial Neural Network”, Proceedings of the 2nd Asia-Pacific Workshop on Marine Hydrodynamics Busan.
- [12] Im, N. K. and Hasegawa, K.(2002), “A Study on Automatic Ship Berthing Using Parallel Neural Controller(2nd Report)-Motion Identification Considering Lateral Speed and Angular Velocity to cope with Disturbances-”, J. Kansai Soc. N. A., Japan, No. 237.
- [13] Kasai(1997) “MMG Report III”, ibid., No.578. (all in Japanese)
- [14] Kose, K. (1984), “On a Mathematical Model of Maneuvering Motions of Ships in Low Speeds”, JSNA of Japan, Vol. 155, pp.132-138.
- [15] Motora, S.(1960), “On the Measurement of Added Mass and Added Moment of Inertia of ships in Steering Motion”, Proc. of First Symposium on Ship Maneuverability, Washington, DTMB Report No. 1461.
- [16] Michael, C.(1993), “NEURAL NETWORKS A Tutorial”, PTR Prentice-Hall, pp.1-65.
- [17] Newman, J. H.(1997), “Marine Hydrodynamics”, The MIT Press, pp.16-18.
- [18] Ogawa, A.(1997), “MMG Report I”, Bulletin of the Society of Naval Architects of Japan(SNAJ), No.575.

원고접수일 : 2008년 6월 30일

심사완료일 : 2008년 10월 15일

원고채택일 : 2008년 10월 27일