

# 선박 자동접안 시스템 구축을 위한 인공신경망의 적용

이승건\* · 이경우\*\* · 이승재\*\*\* · 정성룡\*\*\*\*

The Application of Artificial Neural Network for Constructions of Automatic Berthing System of a Ship

Seung-Keon Lee\* · Gyoung-Woo Lee\*\* · Seong-Jae Lee\*\*\* · Sung-Ryong Jeong\*\*\*\*

Abstract	4. 접안시뮬레이션 결과 및 고찰
1. 서론	5. 결론
2. 저속시 조종운동 수학모델	참고문헌
3. 인공신경망의 적용	

## 요약

본 연구에서는 선박의 조종운동 중 중요한 과제인 접안운동을 자동화하기 위하여 현대 제어이론 중의 하나인 인공신경망(Artificial Neural Network, 이하 ANN으로 함)에 의한 제어를 수행하였다. 잘 알려진 바와 같이 ANN은 어떤 시스템의 입출력간의 연결상황과 요소들 내부의 처리방법을 정의하여 시스템을 표현하는 방법이다. 구체적으로는 시스템의 입출력에 대한 모범적인 교사(教師)데이터(Teaching data)를 준비하여 교사데이터와 실제 입출력간의 오차가 최소가 되도록 학습을 시키게 된다. 학습의 결과 ANN은 그 시스템의 비선형성을 충분히 표현할 수가 있어, 접안운동과 같은 비선형성이 강한 조종운동에 적합할 것으로 생각된다.

## Abstract

Along with the rapid growth of shipping and transportation, the size of a ship is with larger and larger. Low speed maneuverability of a full form's ship has been receiving a great

\* 부산대학교 공과대학 조선해양공학과  
\*\* 목포해양대학교 해양 및 조선공학부  
\*\*\* 부산대학교 기계기술연구소 연구원  
\*\*\*\* 부산대학교 대학원 조선해양공학과

deal of attention both concerning navigation safety, especially in the area of harbour area, waterway.

The Artificial Neural Network is applied to the automatic berthing control of a ship. The teaching data are made by the berthing simulation of a ship on the computer. And, the layer neural network is used and the 'Error Back-Propagation Algorithm' is used to teach the neural network.

Finally, it is shown that the berthing control is successfully done by the established neural network.

## 1. 서 론

선박의 조종운동 중 중요한 과제인 접안운동을 자동화하기 위하여 현대 제어이론 중의 하나인 인공신경망(Artificial Neural Network, 이하 ANN으로 함)에 의한 제어를 수행하였다. 이와 관련된 연구는 Hasegawa[1][2]와 Park[3][4] 등에 의해 행해진 바 있다. 잘 알려진 바와 같이 ANN은 어떤 시스템의 입출력간의 연결상황과 요소들 내부의 처리방법을 정의하여 시스템을 표현하는 방법이다. 구체적으로는 시스템의 입출력에 대한 모범적인 교사(教師)데이터(Teaching data)를 준비하여 교사데이터와 실제 입출력간의 오차가 최소화 되도록 학습을 시키게 된다. 학습의 결과 ANN은 그 시스템의 비선형성을 충분히 표현할 수가 있어, 접안운동과 같은 비선형성이 강한 조종운동에 적합할 것으로 생각된다.

대상선박은 304m의 Tanker로, 조종운동 수학모델은 Kose의 저속수학모델을 사용하였고, Propeller 역전에 의한 Hull 유체력은 Hasegawa 등[2]의 모형시험결과를 인용하였다.

## 2. 저속시 조종운동 수학모델

항만에서의 접안시, 선박은 저속으로 항행하게 되므로 이를 위해서는 저속수학모델을 사용해야 한다. 중고속에서의 조종수학모델과 저속수학모델의 가장 큰 차이는 Hull 유체력이다. 따라서 본 연구에서 사용된 Surge와 Sway-Yaw 방정식은 Hull 유체력성분인  $X_H$ ,  $Y_H$ ,  $N_H$ 는 Kose model[1]을 이용하고 타력은 다음과 같이 계산하였고, 식 중의  $f_\sigma$ 는 Fujii의 추정식을 사용하였다.

$$F_N = \frac{1}{2} \rho A_R f_\sigma U_R^2 \sin \delta \quad (1)$$

$$\text{단, } f_\sigma = \frac{6.13A}{2.25 + A}, \quad U_R = U \text{로 가정}$$

선박이 정지를 위해 프로펠러를 역전시킬 경우, 순전(順轉)할 때와는 달리 비대칭적인 Sway force와 Yaw moment가 Hull에 작용하게 된다. 이로 인한  $X_P$ ,  $Y_P$ ,  $N_P$ 는 Hasegawa[2]의 실험결과에서 인용하였다.

Table 1은 본 연구에서 사용된 선박의 주요제원을 나타낸다.

Table 1 Principal Dimension

Item	Symbol	Value
Ship length	$L$	304.0 m
Ship breadth	$B$	52.5 m
Mean draught	$d_m$	17.4 m
Block coefficient	$C_b$	0.827
Mass	$m$	$2.350 \times 10^6$ kg
Moment of inertia	$I_{zz}$	$1.018 \times 10^{12}$ kgm <sup>2</sup>
Wetted surface area	$S$	$2.259 \times 10^4$ m <sup>2</sup>
Propeller diameter	$D_P$	8.5 m
Rudder area	$A_R$	98.0 m <sup>2</sup>
Rudder height	$h$	12.94 m
Rudder aspect ratio	$\lambda_R$	1.709

이와 같이 Hull 유체력과 프로펠러 force를 고려하여, 본 연구에서 사용한 저속 조종운동 방정식은 식(2) ~ (4)와 같다.

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

$$(m + m_y)\dot{v} - Y_r \dot{r} = Y_v vU + Y_{vv}|v|v + Y_{vvv}v^3/U^3 + Y_r r + Y_{vr}vr + Y_{uvr}uv^2r/U^2 + Y_{vrr}vr^2/U + Y_P - (1 + a_H)F_N \cos \delta \quad (3)$$

$$(I_{zz} + J_{zz})\dot{r} - N_v \dot{v} = N_{uv}uv + N_r r + N_{rrr}r^3 + N_{vr}vr + N_{vvr}v^2r + N_P - (x_R + a_H x_H)F_N \cos \delta \quad (4)$$

이때 부가질량과 부가관성모멘트는 Motora 추정법[5]에 의해 구하였고, 그 밖의 유체력 미계수는 Table 2와 같다.

Table 2 Hydrodynamic derivatives

$X_{vr}^*$	$-0.310 \times 10^{-2}$	$N_{vvr}^*$	$-0.981 \times 10^{-2}$
$X_{uu}^*$	$-0.457 \times 10^{-3}$	$Y_v^*$	$-2.222 \times 10^{-2}$
$X_{uv}^*$	$2.927 \times 10^{-3}$	$Y_{vv}^*$	$-2.173 \times 10^{-2}$
$X_{vvr}^*$	$-0.558 \times 10^{-2}$	$Y_{vvvv}^*$	0.0
$N_{uv}^*$	$-7.910 \times 10^{-3}$	$Y_r^*$	$1.287 \times 10^{-3}$
$N_r^*$	$-1.632 \times 10^{-4}$	$Y_{vr}^*$	$0.510 \times 10^{-2}$
$N_{rrr}^*$	$-0.776 \times 10^{-2}$	$Y_{uvr}^*$	$-0.851 \times 10^{-2}$
$N_{vr}^*$	$-1.584 \times 10^{-3}$	$Y_{vrr}^*$	$-0.874 \times 10^{-2}$

### 3. 인공신경망의 적용

#### 3.1 인공신경망의 구조

인공신경망은 뇌의 신경세포를 단순화시켜 수학적으로 모델링한 인공신경세포(Artificial neuron)와 연결(Connection)들로 구성되어 있다. 인공신경세포는 처리단위(Processing unit)라고 하며 외부로부터 입력을 받아 다른 인공신경세포로 전파되는 출력신호를 계산한다. 그리고 인공신경세포는 가중치(Weight)를 조절하는 역할을 한다.

병렬적으로 배열된 한 무리의 인공신경세포들의 모임을 층(Layer)이라고 하며, 같은 층내의 신경세포들은 기능적으로 같은 작업을 수행하며 인공신경망은 근본적으로 같은 층내의 많은 신경세포들이 동시에 병렬적으로 동작한다. 이러한 층에는 신경세포들의 유형에 따라 외부로부터 입력을 받아들이는 입력층(Input layer), 외부로 출력을 내보내는 출력층(Output layer) 그리고 이들 입력층과 출력층 사이의 은닉층(Hidden layer)이 있다.

본 연구에서는 단층신경망의 한계를 극복하기 위해 제안된 입력층과 출력층 사이에 하나 이상의 중간층(은닉층)을 두는 다층신경망을 사용하였으며 이러한 다층신경망의 학습방법으로는 가장 널리 사용되고 있는 일반화된 학습규칙을 이용한 오류역전파 알고리즘을 이용하였다.

#### 3.2 오류역전파 알고리즘

##### 3.2.1 neuron 이론

신경세포의 인공적인 모델인 unit는 Fig.1과 같이 간략화 하여 나타낼 수 있다.




Fig.1 단순화된 신경모델

입력과 출력은 다음과 같은 관계가 있다.

$$X = \sum_i w_i \cdot x_i \quad (5)$$

$$y = f(X) \quad (6)$$

여기서  $x$ 는 입력,  $w_i$ 는 Unit로의 결합가중,  $f(X)$ 는 출력  $y$ 로의 응답계수로써 활성화치라고도 부른다.

이 응답계수는 신경세포가 어떤 흥분상태 이상이 되면 다음의 Neuron에 자극을 전달하는 것을 의미하며 이는 활성화함수에 의해 결정된다. 이 활성화함수는 때때로 계단함수나 선형함수를 사용하기도 하나 본 연구에서는 Fig.2와 같은 Sigmoid 형태의 것을 사용하였다.




Fig.2 Sigmoid Function

$$f(x) = \frac{1}{1 + e^{-2x/u_0}} = \frac{1 + \tanh(x/u_0)}{2} \quad (7)$$

$$f'(x) = 2f(x) \frac{1-f(x)}{u_0} \quad (8)$$

이와 같이 미분된 함수가 함수 자신의 형태로 표현 가능하므로 다음에서 보일 학습 알고리즘에서 취급하기 쉽다.

### 3.2.2 오류역전파 알고리즘

본 연구에서 사용된 오류역전파 알고리즘을 그림으로 나타내면 Fig.3과 같다.




Fig.3 오류역전파 알고리즘

Fig.3과 같이 어떤 상태에서 출력층의 활성화치가 Teaching Data(교사신호)와 같아지도록 결합가중들을 변화시키는 방법이 오차역전파법이다.

그 방법을 간단히 설명하면 다음과 같다.

$$U_j = \sum_i W_{ji} I_i + \theta_j \quad (9)$$

$$H_j = f(U_j) \quad (10)$$

$$K_l = \sum_j F_{lj} H_j + \epsilon_l \quad (11)$$

$$G_l = f(K_l) \quad (12)$$

$$S_k = \sum_l V_{kl} G_l + \gamma_k \quad (13)$$

$$O_k = f(S_k) \quad (14)$$

여기서

$I_i$  : 입력층 unit  $i$ 의 출력

$H_j$  : 1st은닉층 unit  $j$ 의 출력

$G_l$  : 2nd은닉층 unit  $l$ 의 출력

$O_k$  : 출력층 unit  $k$ 의 출력

- $U_j$  : 1st 은닉층 unit  $j$ 의 입력
- $K_l$  : 2nd 은닉층 unit  $l$ 의 입력
- $S_k$  : 출력층 unit  $k$ 의 입력
- $T_k$  : 출력층 unit  $k$ 에 대한 Teaching data
- $\theta_j$  : 1st 은닉층 unit  $j$ 의 offset
- $\varepsilon_l$  : 2nd 은닉층 unit  $l$ 의 offset
- $\gamma_k$  : 출력층 unit  $k$ 의 offset
- $W_{ji}$  : 입력층 unit  $i$ 와 1st 은닉층 unit  $j$ 의 연결가중치
- $F_{lj}$  : 1st 은닉층 unit  $j$ 와 2nd 은닉층 unit  $l$ 의 연결가중치
- $V_{kl}$  : 2nd 은닉층 unit  $l$ 과 출력층 unit  $k$ 의 연결가중치

이 때, 출력층  $k$ 에서 2nd 은닉층  $j$ 로는

$$(V_{kl})_{new} = (V_{kl})_{old} + \alpha \delta_{kk} G_l \quad (15)$$

$$(\gamma_k)_{new} = (\gamma_k)_{old} + \beta \delta_{kk} \quad (16)$$

$$\delta_{kk} = T_k - O_k \quad (17)$$

2nd 은닉층  $l$ 에서 1st 은닉층  $j$ 로는

$$(F_{lj})_{new} = (F_{lj})_{old} + \alpha \delta_{ll} H_j \quad (18)$$

$$(\varepsilon_l)_{new} = (\varepsilon_l)_{old} + \beta \delta_{ll} \quad (19)$$

$$\delta_{ll} = 2\delta_l G_l(1 - G_l)/u_0 \quad (20)$$

1st 은닉층  $j$ 에서 입력층  $i$ 로는

$$(W_{ji})_{new} = (W_{ji})_{old} + \alpha \delta_{jj} I_i \quad (21)$$

$$(\theta_j)_{new} = (\theta_j)_{old} + \beta \delta_{jj} \quad (22)$$

$$\delta_{jj} = 2\delta_j H_j(1 - H_j)/u_0 \quad (23)$$

단,

$$\delta_j = \sum_l \delta_l F_{lj} \quad (24)$$

$$\delta_l = \sum_k \delta_k V_{kl} \quad (25)$$

$$\delta_k = \delta_{kk} O_k(1 - O_k) \quad (26)$$

$\alpha, \beta$  는 학습율

하나의 Teaching data에 대한 오차를

$$E_p = (T_k - O_k)^2/2 \quad (27)$$

로 정의하면 복수개의 Teaching data에 대한 오차는

$$E = \sum_p \sum_k (T_{pk} - O_{pk})^2/2 = \sum_p E_p \quad (28)$$

와 같이 정의될 수 있다.

이 때 전체 Teaching data에 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 신경망의 학습

ANN의 학습에 영향을 미치는 요소들 중 가장 중요한 것은 은닉층의 개수와 Unit 개수, 그리고 적절한 활성화함수의 결정이다. 이러한 요소들이 부적절하게 결정될 경우, 학습 속도가 늘어날 수 있고, 심지어는 학습이 되지 않는 경우도 있다[6].

본 연구에서 선박의 접안운동 제어를 위해 사용한 ANN은 Fig.4와 같다.




Fig.4 Four Layer Neural Network




Fig.5 Coordinate system for berthing




Fig.7 Patterns of teaching data




Fig.6 Example of teaching data

입력층에서  $\xi$ ,  $\eta$ ,  $x$ ,  $y$ 는 Fig.5의 두 좌표계에 따른 선박의 질량중심의 좌표를 나타내고  $u$ ,  $v$ 는 각각  $x$ 와  $y$ 방향의 속도,  $\psi$ 는 회두각,  $r$ 는 회두각속도를 나타낸다. 또, 출력층에서의  $n$ 은 프로펠러 회전수(rps),  $\delta$ 는 타각을 나타낸다.

ANN을 학습시키기 위한 Teaching data는, Fig.6과 같이 선박의  $n$ 과  $\delta$ 를 수동으로 변화시켜가며 선박을 조종하여 접안시킨 하나의 경로에 대해 입출력층에 필요한 Data들을 Sampling하고, 이러한 과정을 Fig.7과 같은 6개의 경로들에 대하여 행한 것들을 사용하였다. Fig.6에서 보듯이 Sampling간격은 타각이나 회전수가 변화하기 전후에는 20초 간격으로 하여 Data를 많이 포함시켰고, 그 외의 통상적인 경우는 80초 간격으로 하였다. 즉, 임의 시간에서의  $\xi$ ,  $\eta$ ,  $\psi$ ,  $u$ ,  $v$ ,  $r$ ,  $x$ ,  $y$ ,  $n$ ,  $\delta$ 들이 하나의 Teaching data Group이 되고 이러한 Teaching data group들이 모두 198개가 사용되었다. 이러한 Data들을 학습시키기 위해서 은닉층의 개수와 Unit의 개수를 바꾸어 가며 시행착오를 거친 결과, 최종적으로 Fig.4와 같이 결정되었다. 단, 최적화 기법 등을 사용하지 않아 이 구조가 가장 효율적이라고 단정할 수는 없다.

ANN의 학습에 필요한 Teaching data는 일련의 'Knowledge-Base'에 따라 작성된 것일수록 학습되지 않은 경우에 대해서도 타당한 결과를 제공하게 된다. 그러나 본 연구의, 접안에 대한 Teaching data의 작성에 있어서는 프로펠러 역전에 의한 Sway force와 Yaw moment를 고려하였고, 접안에 대한 Knowledge-Base는 적용하지 않았다. 따라서, 정지를 위해 프로펠러가 역전을 하게 되고, 그에 따른 회두각의 변화가 상당히 크기 때문에 통상의 규칙에 따른 제어가 힘들었다. 그러나 정지를 위한 프로펠러 회전수나 타각 등은 가능한 한 일반적인 경향을 유지하도록 노력하였다.

#### 4. 접안시뮬레이션 결과 및 고찰

학습된 ANN을 이용한 접안 시뮬레이션은 Fig.8과 같은 과정에 의해 행해졌다.

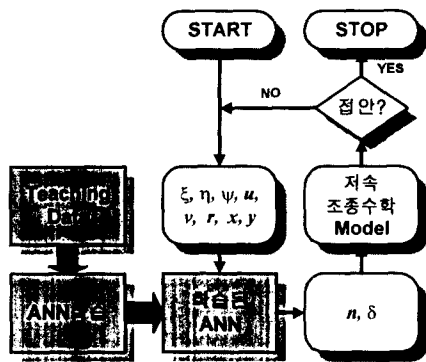


Fig.8 Flowchart for berthing simulation with ANN

학습된 ANN을 통한 접안 시뮬레이션 결과를 Fig.9-Fig.12에 나타내었다. 각 그림에서 ( $\xi$ ,  $\eta$ ,  $\psi$ )는 초기위치와 방위각을 나타낸다.

Fig.9-Fig.11에서 보듯이, 학습된 Pattern에 대해 접안이 잘 이루어지고 있다.

Fig.12은 학습되지 않은 경우에 대한 결과이다. Fig.11과 비교하여 약간의 초기회두각의 차이가 있음에도 불구하고, ANN이 Teaching data의 외삽(Extrapolation)에 해당하는 초기조건하에서는 바람직하게 작동하지 않는 경우도 있음을 보여주고 있다.




Fig.9 Simulation using ANN  
 ( $\xi$ ,  $\eta$ ,  $\psi$ ) = (3L, 5L, 120°)




Fig.10 Simulation using ANN  
 $(\xi, \eta, \psi) = (-7L, 12L, -45^\circ)$




Fig.12 Simulation using ANN  
 $(\xi, \eta, \psi) = (-11L, 4L, 10^\circ)$




Fig.11 Simulation using ANN  
 $(\xi, \eta, \psi) = (-12L, 2L, 0^\circ)$

이를 보완하기 위해서는 Teaching data를 보완하든지 ANN의 구조를 바꾸어 보는 것도 한 방법이라 할 수 있다.

## 5. 결론

대형유조선( $L_{pp}=304m$ )을 대상으로, 접안 제어를 인공신경망에 의해 자동으로 수행하였다. 그 결과를 요약하면 다음과 같다.

1. 학습된 인공신경망(ANN)에 의해 선박의 접안운동을 성공적으로 제어하였다.
2. 인공신경망의 설계나 학습과정에 있어 보다 효과적인 신경망구축을 위해 최적화 기법을 도입할 필요가 있다.



3. 더욱 현실적인 접안제어를 위해서는 바람, Tug 등의 외력을 고려할 필요가 있다.

#### 참고문헌

- [1] K. Hasegawa, K. Kitera., "Mathematical Model of Manoeuvrability at Low Advance Speed and its Application to Berthing Control", *Proc. of 2nd Japan-Korea Joint Workshop on Ship and Marine Hydrodynamics*, Vol.1, 1993.
- [2] 長谷川和彦, 木寺啓治., "ニューラルネットワークと知識ベースを併用した自動着棧システム" - *關西造船學會誌* 第220号, 1993
- [3] 곽문규, 서상현., "신경망을 이용한 선박용 자동조타장치의 제어시스템 설계(I)", *대한조선학회논문집* 제34권 2호, 1997.
- [4] 곽문규, 서상현., "신경망을 이용한 선박용 자동조타장치의 제어시스템 설계(II)", *대한조선학회논문집* 제34권 3호, 1997.
- [5] S. Motora., "On the Measurement of Added Mass and Added Moment of Inertia of ships in Steering Motion", *Proc. of First Symposium on Ship Maneuverability*, DTMB Report No. 1461, Washington, 1960.
- [6] 이상원., "학습하는 기계신경망", *Ohm사*.