

자기 회귀 웨이블릿 신경 회로망을 이용한 자율 수중 운동체의 방향제어에 관한 연구

김병수*, 박상수*, 최윤호*, 박진배**

*경기대학교 전자공학부, **연세대학교 전기전자공학부

A Study on Steering Control of Autonomous Underwater Vehicle Using Self-Recurrent Wavelet Neural Network

Byung Soo Kim*, Sang Su Park*, Yoon Ho Choi*, Jin Bae Park**

*School of Electronic Eng, Kyonggi Univ. **Dept. of Electrical & Electronic Eng, Yonsei Univ.

Abstract - In this paper, we propose a new method for designing the steering controller of Autonomous Underwater Vehicle(AUV) using a Self-Recurrent Wavelet Neural Network(SRWNN). The proposed control method is based on a direct adaptive control technique, and a SRWNN is used for the controller of horizontal motion of AUV. A SRWNN is tuned to minimize errors between the SRWNN outputs and the outputs of AUV via the gradient descent(GD) method. Finally, through the computer simulations, we compare the performance of the propose controller with that of the MLP based controller to verify the superiority and effectiveness of the propose controller.

1. 서 론

자율 수중 운동체(Autonomous Underwater Vehicle: AUV)란 컴퓨터와 동력원을 내장, 여러 가지 각종 항해용 센서의 정보를 근거로 외부 상태를 판단하는 등 인간의 조정 없이 수중에서 자율적으로 주어진 임무를 수행하면서 활동하는 수중 운동체이다. AUV의 활용으로는 민간 목적으로 인간을 대신하여 심해저 조사를 통해 다양한 정보를 취득하고 해양 자원의 개발 및 해양 과학 조사를 할 수 있고 군사 목적으로는 해상에서의 각종 무기 탐지 및 공격 무기로써 전술적, 전략적으로 다목적 임무 수행이 가능하다. 이렇듯 다양한 방법에서 응용이 가능하지만 이러한 임무를 수행하기 위해서는 각종 센서와 자율 제어 및 여러 시스템에 맞는 기술이 필요하다. 그 중에서도 AUV의 자율 운동을 제어하는 조정 장치는 중요한 기능을 가진다. AUV는 해양이라는 특수한 환경에서 제어판에 비해 물체가 크고 운항속도가 느려 제어력이 약하다. 이러한 여러 외관에 능동적으로 대처하기 위해 슬라이딩 모드 제어나 신경회로망 이론을 응용하여 시스템을 학습시킨 퍼지-뉴랄 제어기 및 많은 연구가 진행되어 왔다[1].

본 논문에서는 AUV 방향 제어 시스템의 지능 제어를 위해 직접 적용 제어 기법에 기반한 자기 회귀 웨이블릿 신경 회로망(Self-Recurrent Wavelet Neural Network) 기반 제어기 설계 방법을 제안하였다. 제안한 시스템에서 AUV 모델의 실제 출력과 SRWNN 모델의 출력에 대한 오차를 비교하여 제어 오차가 최소화가 되도록 SRWNN의 파라미터 값들을 변화시키며 각각의 파라미터 값들은 경사하강법을 통해 학습시킨다. 마지막으로 제안한 SRWNN 기반 제어기의 우수성과 효용성을 검증하고자 한다.

2. AUV의 운동 방정식 및 SRWNN 신경 회로망

2.1 AUV의 운동 방정식

AUV는 수중의 3차원 공간에서 존재하므로 각각의 직진운동과 회전 운동에 의한 6자유도 운동 방정식으로 비선형 형으로 전개 된다. 본 논문에서 제안한 제어 대상은 한국과학기술원과 한국해양연구원 해양시스템 안전 연구소에서 공동 제작한 ASUM으로 2개의 수직타와 2개의 수평타를 가진 어뢰의 형태를 가졌으며 수직과 수평 두 제어 모드를 분리하여 제어기를 설계 할 수 있다. 본 논문에서는 [2]을 이용하여 AUV의 동역학을 표현한다.

2.1.1 수평면 운동 방정식

모델링의 단순화를 위해 AUV가 대칭이고 선체 고정 좌표계에서 무게 중심이 AUV 운동 좌표계와 일치한다고 가정한다. 또한 AUV가 수중에서 운동할 때 외부로 받는 힘과 모멘트에 대해서도 간략화를 한다면, AUV 운동의 6자유도 운동 방정식은 식(1)과 같이 간략하게 표현할 수 있다.

$$u = U_0$$

$$m[\dot{v} + ur] = Y_f \quad (1)$$

$$I_{zz}\dot{r} = N_f$$

$$\dot{\psi} = r$$

여기서 U_0 은 AUV의 속도, m 은 질량, I_{zz} 는 z 축 관성모멘트, r 과 \dot{r} 은 각각 z 축에 대한 각속도 및 각속도 변화율, Y_f 와 N_f 는 Y 축에 대한 유체 역학적 힘 및 Z 축에 대한 유체 역학적 힘, $\dot{\psi}$ 는 z 축에 대한 오일러(Euler) 각을 의미한다. 이 때, 식 (1)에서 무게중심에서 X, Y 는 0이므로 분리 할 수 있고, 또한 움직임이 매우 적다고 가정하면 좌우 동요 속도(sway velocity) v 는 무시 할 수 있다. 결국 수평 운동에 대한 유체 역학적 힘과 모멘트 성분에 대해 테일러(Taylor)급수를 통해 선형화 할 수 있다. AUV 방향 제어에 필요한 힘을 선형화 시키고 행렬 형태로 나타내면 식 (2)와 같이 된다.

$$\begin{bmatrix} \dot{r} \\ \dot{\psi} \end{bmatrix} = \begin{bmatrix} \frac{N_r}{I_{zz} - N_r} & 0 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} r \\ \psi \end{bmatrix} + \begin{bmatrix} \frac{N_{\delta_R}}{I_{zz} - N_r} \\ 0 \end{bmatrix} \delta_R \quad (2)$$

2.2 자기 회귀 웨이블릿 신경 회로망

2.2.1 SRWNN의 구조

SRWNN은 웨이블릿 신경 회로망의 각각의 모체 웨이블릿에 자기 회귀(self-feedback)고리를 달아주어 기존 정보를 가지고 다시 학습을 통해 성능을 향상시킨 회로망이다[3].

SRWNN의 구조는 <그림 1>에서처럼 N_i 개의 입력과 하나의 출력, 그리고 $N_i \times N_w$ 개의 모체 웨이블릿으로 되어 있고, 4개의 층으로 구성되어 있다.

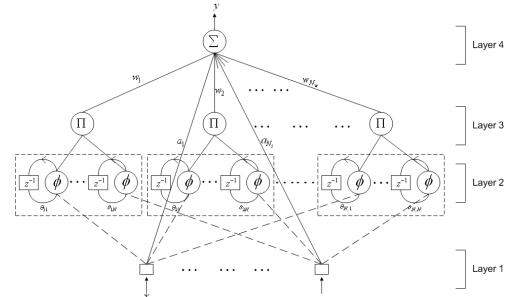


그림 1> SRWNN의 구조

첫 번째 층은 신경 회로망의 입력 층이고, 두 번째 층은 모체 웨이블릿 층이고 세 번째 층은 모체 웨이블릿의 곱을 나타내고, 네 번째 층은 출력 층이다. 여기서 사용한 모체 웨이블릿은 식 (3)과 같은 가우시안(Gaussian) 함수의 1차 미분형을 사용한다.

$$\phi(z) = -z \exp\left(-\frac{1}{2} z^2\right) \quad (3)$$

각 마디의 모체 웨이블릿 ϕ_{jk} 는 모체 웨이블릿 ϕ 로부터 나타낼 수 있고 식 (4)와 같다.

$$\phi_{jk}(z_{jk}) = \phi\left(\frac{u_{jk} - m_{jk}}{d_{jk}}\right) \quad (4)$$

여기서, m_{jk} 와 d_{jk} 는 각각 웨이블릿 노드의 변형인자 및 확장 인자를 나타내고 jk 는 j 번째 웨이블릿의 k 번째 입력의 항을 가리킨다.

두 번째 층에서 n 개로 분리된 입력은 식 (5)와 같이 표시 된다.

$$u_{jk}(n) = x_k(n) + \phi_{jk}(n-1) \cdot \theta_{jk} \quad (5)$$

여기서, θ_{jk} 는 자기 귀환(self-feedback)의 가중치를 나타낸다.

세 번째 층의 노드에 각 웨이블릿은 식 (6)과 같이 각 입력에 대한 모체 웨이블릿의 곱으로 표현된다.

$$\Phi_{jk}(X) = \prod_{k=1}^{N_i} \phi(z_{jk}) = \prod_{k=1}^{N_i} \left[-\left(\frac{u_{jk} - m_{jk}}{d_{jk}} \right) \exp\left(-\frac{1}{2}\left(\frac{u_{jk} - m_{jk}}{d_{jk}}\right)^2\right) \right] \quad (6)$$

네 번째 층은 출력 층으로써 세 번째 층의 출력으로 얻어진 결과의 선형 조합을 나타낸다. 그리고 입력 층으로부터 직접 입력 값을 받아들인다. 따라서, SRWNN의 출력은 자기 회귀 웨이블릿과 각각의 파라미터 값을 조합으로 표현 할 수 있고, 식 (7)과 같다.

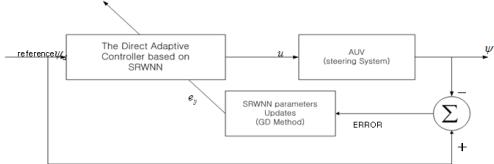
$$y(n) = \sum_{j=1}^{N_w} w_j \Phi_j(X) + \sum_{k=1}^{N_i} a_k x_k \quad (7)$$

여기서 w_j 는 세 번째 층과 네 번째 층 사이의 가중치를 a_j 는 입력층 출력 사이의 가중치이다. 학습을 통하여 생성되는 SRWNN의 파라미터 집합은 W 로 표현하고 식 (8)과 같다.

$$W = [a_k \ m_{jk} \ d_{jk} \ \theta_{jk} \ w_j]^T \quad (8)$$

2.2.2 SRWNN의 학습 방법 및 직접 적용 제어기의 구조

본 논문에서는 SRWNN에 기반을 둔 직접 적용 제어기를 사용하며, 제어기의 구조는 <그림 2>와 같다.



<그림 2> 직접 적용 제어기의 구조

SRWNN의 학습 방법은 식 (9)와 같은 비용 함수를 최소화 하는 파라미터 W 를 구하는 것이다.

$$J(n) = \frac{1}{2} [y_d(n) - y(n)]^2 = \frac{1}{2} e^2(n) \quad (9)$$

여기서, $y(n)$ 은 n 번째 SRWNN의 출력, $y_d(n)$ 은 원하는 출력값이다. 비용함수의 최소화 과정은 파라미터 집합 W 를 식 (10)과 같이 경사 하강법(gradient descent)을 이용하여 반복적으로 학습하여 구하는 것이다.

$$W(n+1) = W(n) + \Delta W(n) = W(n) + \bar{\eta} \left(-\frac{\partial J(n)}{\partial W(n)} \right) \quad (10)$$

이때, $\bar{\eta} = [\eta^a, \eta^m, \eta^d, \eta^\theta, \eta^w]$ 는 SRWNN의 모델 예측에 사용되는 학습률을 나타낸다. $W(n)$ 은 n 번째 파라미터 집합을 나타내고 $\frac{\partial J(\theta(n))}{\partial W(n)}$ 은 $W(n)$ 에 대한 비용 함수의 기울기로서 식 (11)에 의해 계산된다.

$$\frac{\partial J(n)}{\partial W(n)} = e(n) \frac{\partial e(n)}{\partial W(n)} = -e(n) \frac{\partial y(n)}{\partial W(n)} \quad (11)$$

식 (11)에서 $W(n)$ 에 대한 $y(n)$ 의 기울기 $\frac{\partial y(n)}{\partial W(n)}$ 는 출력을 각각의 파라미터에 대해 미분하여 식 (12)와 같이 구해진다.

$$\frac{\partial y(n)}{\partial a_k} = x_k \quad (12-a)$$

$$\frac{\partial y(n)}{\partial m_{jk}} = -\frac{w_j}{d_{jk}} \frac{\partial \Phi_j(X)}{\partial z_{jk}} \quad (12-b)$$

$$\frac{\partial y(n)}{\partial d_{jk}} = -\frac{w_j}{d_{jk}} z_{jk} \frac{\partial \Phi_j(X)}{\partial z_{jk}} \quad (12-c)$$

$$\frac{\partial y(n)}{\partial \theta_{jk}} = \frac{w_j}{d_{jk}} \phi_{jk}(n-1) \frac{\partial \Phi_j(X)}{\partial z_{jk}} \quad (12-d)$$

$$\frac{\partial y(n)}{\partial \theta_{jk}} = \frac{w_j}{d_{jk}} \phi_{jk}(n-1) \frac{\partial \Phi_j(X)}{\partial z_{jk}} \quad (12-d)$$

$$\frac{\partial y(n)}{\partial w_j} = \Phi_j(X) \quad (12-e)$$

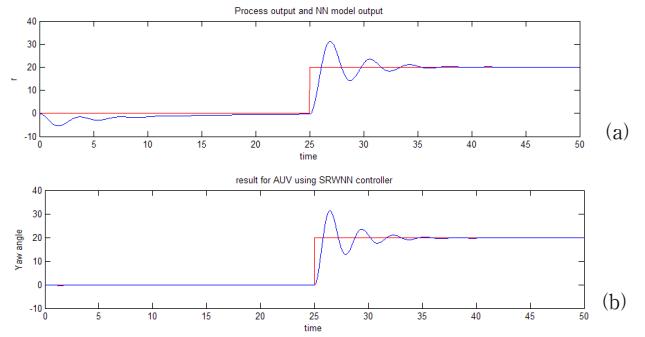
여기서, $\frac{\partial \Phi_j(X)}{\partial z_{jk}}$ 는 다음과 같다.

$$\frac{\partial \Phi_j(X)}{\partial z_{jk}} = \phi(z_{j1}) \phi(z_{j2}) \cdots \phi(z_{jk}) \cdots \phi(z_{jN_i}) \quad (13)$$

$$\dot{\phi}(z_{jk}) = \frac{\partial \phi_j}{\partial z_{jk}} = (z_{jk}^2 - 1) \exp\left(-\frac{1}{2} z_{jk}^2\right) \quad (14)$$

2.3 모의 실험 및 결과 고찰

본 논문의 모의 실험은 MATLAB으로 수행 하였고, 실험에서 제어 입력으로는 각 속도 r 과 오일러 각 ψ 를 가지고, 제어 대상으로는 위치 좌표 값과 진행 방향에 대하여 출력으로 하는 AUV 시스템에 대해 모의 실험을 하였다. 비교 실험을 위해 MLP 기반 제어기와 비교 하였으며, 그림 3은 현재 요각 0°에서 명령 요각 20°로 회전하는 경우에 대한 요각 추종 성능을 나타내고 있다. MLP 기반 제어기와 비교 했을 때 약 3초 정도 더 빠르고 안정적으로 수렴하는 것을 확인할 수 있었고, 평균제곱오차(MSE)의 경우 0.0028에서 0.0018로 약 30% 향상 된 것을 알 수 있었다. 이 결과로 부터 SRWNN 기반 제어기의 우수성을 확인하는 계기가 되었다. 본 논문에서 사용된 웨이블릿 신경 회로망의 제어기에 의한 제어 결과는 <표 1>과 같다.



<그림 3> 요각 추종 성능 (a)MLP (b)SRWNN

<표 1> 모의 실험 환경 및 제어 결과

	MLP	SRWNN
Number of Hidden neuron & Mother Wavelet	10	10
Sampling time	50sec	50sec
Learning rate	0.001	0.001
Control Result(MSE)	0.0028	0.0018

3. 결 론

본 논문에서는 수중에서의 주어진 임무를 수행하는 AUV의 방향 제어를 위하여 직접 적용 제어 기법에 기반한 SRWNN 기반 제어기 설계 방법을 제안하였고 학습 방법으로는 시스템의 출력과 원하는 출력 값을 이용하여 비용함수를 최소화 하는 경사 하강법을 이용하였다. 본 논문에서 제안된 방법의 우수성과 성능 평가를 위해 MLP 기반 제어기와 비교 및 모의 실험을 수행 하였다. 일반적인 MLP 기반 제어기와 SRWNN 기반 제어기의 성능을 비교 하였을 때 수렴 속도 면에서 더 빠른 수렴을 보였으며, 평균제곱오차(MSE) 역시 줄어든 것을 확인 할 수 있었다. 모의실험 결과로부터, AUV의 방향 제어를 위해 본 논문에서 제안한 SRWNN 기반 제어기의 우수성을 확인 하였다.

[참 고 문 헌]

- [1] 서경철, 박진배, 최윤호, “웨이블릿 신경 회로망을 이용한 자율 수중 운동체 방향 제어기 설계”, 대한 전기학회 하계 학술대회 논문집, pp. 1182-1183, 2006.
- [2] 박진영, “소형 무인 잠수정의 자세 제어 구현에 관한 연구”, 석사학위논문, KAIST, 2005.
- [3] Sung Jin Yoo, Jin Bae Park, Yoon Ho Choi, “Stable Predictive Control of Chaotic Systems Using Self-Recurrent Wavelet Neural Network”, International Journal of Control, Automation, and Systems, vol. 3, no. 1, pp. 43-55, 2005.