

자기회귀 웨이블릿 신경망을 이용한 풍력 발전 시스템의 적응 속도 제어기 설계

송승관*, 최윤호**, 박진배*
연세대학교*, 경기대학교**

Design of Adaptive Velocity Controller for Wind Turbines Using Self Recurrent Wavelet Neural Network


Seung Kwan Song*, Yoon Ho Choi** Jin Bae Park*
Yonsei University*, Kyonggi University**

Abstract - In this paper, the adaptive neural network technique is proposed to control the speed of wind power generation system. For maximizing generated power effectively, adaptive neural algorithm based on SRWMM(Self Recurrent Wavelet Neural Network) is derived to on-line adjust the excitation winding voltage of the generator. Through computer simulations, it is shown that the proposed method can achieve smooth and asymptotic rotor speed tracking.

크기 같은 시스템의 예기치 않은 변화에 쉽게 대처할 수 있다[4].


1. 서 론

풍력 발전기는 대기의 이동에 의한 운동 에너지를 터빈을 이용해 동력에너지로 전환하고 이를 다시 발전기를 이용해 전기에너지로 전환하는 장치이다. 이러한 풍력 에너지 변환 장치는 바람의 속력과 방향의 불규칙성으로 인해 입력 변수의 불규칙성이 강하며, 풍속의 변화에 따른 역학적 모델의 비선형성, 즉 터빈의 질량 및 회전 모멘트의 측정의 한계성과 풍속마찰과 같은 정확한 모델링이 불가능함으로 인해 제어 입력을 설계하는데 많은 어려움이 따른다. 이러한 문제점을 해결하기 위해 적응 제어 기법, 퍼지 이론 및 신경망 회로망 등을 이용한 지능 제어 기법과 같은 다양한 제어 방법들이 연구되고 있다[1][2].



<그림 1> 전력 생산계수와 TSR의 관계 그래프

본 논문에서 자기 회귀 웨이블릿 신경망(Self Recurrent Wavelet Neural Network: SRWNN)에 기반한 적응 제어 기법을 이용하여 풍력 발전 시스템의 속도 제어 방법을 제안한다. 비선형적인 풍력 발전시스템의 속도 제어를 위해 발전기의 계자 권선 전압으로 조정한다. 이때 자기 회귀 웨이블릿 신경망은 웨이블릿 신경망(Wavelet Neural Network: WNN)과는 달리 과거의 정보를 저장할 수 있는 성질을 가지기 때문에 불규칙한 바람의 변화에 빠르게 대처할 수는 장점을 가진다[4]. 마지막으로, 컴퓨터 모의 실험을 통해 제안된 제어 알고리즘의 타당성 및 효율성을 검증하고자 한다.



Aeroturbine

<그림 2> 풍력발전시스템의 일반적인 구조


2. 본 론

2.1 풍력발전 시스템의 모델링

풍력발전시스템에서 발생하는 전력은 식 (1)과 같이 결정된다.

$$P_m(w) = k_w w^3 \quad \text{with } k_w = \frac{1}{2} C_p \rho \pi \frac{R^5}{\lambda^3} \quad (1)$$

여기서 λ (TSR: tip speed ratio)는 발전 효율을 결정하는 변수로서 그림 1과 같이 특성 곡선에 의해 전력 생산 계수(power coefficient)를 결정하게 된다. 따라서 전력 생산 계수가 최대가 되는 TSR에 따라 발전 터빈의 회전 속력이 결정된다[2].



<그림 3> 자기 회귀 웨이블릿 신경망의 구조

일반적으로 많이 사용되는 수평축 풍차 구조는 그림 2와 같이 터빈날개, 기어박스 및 발전기의 세 부분으로 구성된다[3].

그림 2의 발전 시스템의 동특성(dynamics)과 계자전류 동특성으로부터 제어 입력의 설계를 위한 식 (2)를 구할 수 있다.

$$\begin{aligned} \dot{w} &= a_1 w^2 + a_2 w + a_3 \int_0^t w d\tau + b_1 I_f \\ \dot{I}_f &= b_2 I_f + b_3 u_f \end{aligned} \quad (2)$$

2.2 자기 회귀 웨이블릿 신경망의 구조

자기회귀 웨이블릿 신경망의 구조는 그림 3과 같다. 자기회귀 웨이블릿 신경 회로망의 모체(mother) 웨이블릿 층은 자기 회귀 뉴런들로 구성되어 과거의 정보를 저장할 수 있는 성질을 가지기 때문에 풍력의 방향과

이 신경망 구조를 이용하여 미지의 함수 $f(x)$ 를 입력 x 에 대해 $\hat{f}(x)$ 로 추정할 수 있다.

$$f(x) = \hat{f}(x) + \delta(x) = \theta^* \zeta(x) + \delta(x) \quad (3)$$

여기서 $\theta^* \in R^n$ 는 미지의 파라미터이며 $\zeta: R \rightarrow R^n$ 는 주어진 smooth 자기 회귀 함수 벡터이며, $\delta(x)$ 는 신경망 함수 재구성에 따른 오차이다. $f(x)$ 에 가장 근접한 적응 신경망을 구성하기 위해서는 $\delta(x)$ 를 최소화하기 위한 θ^* 최적화 하는 작업이 필요하다. 이는 $|\delta(x)| \leq \psi^*$ 을 설정하고 이를 최소한으로 국한시킴으로써 $\delta(x)$ 의 범위를 최소한으로 수렴시킬 수 있다.

2.3 리아프노프 함수를 이용한 제어기 설계

그림 2의 발전 시스템의 동특성(dynamics)의 식에서 a_1, a_2, a_3 를 포함한 부분을 미지의 함수라 가정하면 식 (2)를 식 (4)와 같이 변환할 수 있다[5].

$$\begin{aligned} \dot{w} &= f(w) + I_f \\ \dot{I}_f &= v \end{aligned} \quad (4)$$

여기서, $f(x_1)$ 은 미지의 함수이며, 제어 입력의 미분값을 v 로 정의하여 적응 신경망의 적용이 용이하게 변환한다. 제어 목적은 출력 w 가 $w_r \in R$ 의 기준 신호를 점근적(asymptotically)으로 추종(tracking)하고, 전체 시스템의 안정성을 보장 해주는 피드백 제어기 v 를 설계하는 것이다. w 와 u 의 변수 치환을 통해 식 (5)와 같은 리아프노프 함수를 설정할 수 있다.

$$z_1 = w - w_r \quad (5)$$

$$z_2 = I_f + w + \theta^T \zeta(w) + \psi \tanh\left(\frac{z_1}{\epsilon}\right)$$

$$V = \frac{1}{2}(z_1^2 + z_2^2 + \tilde{\theta}^T \Gamma^{-1} \tilde{\theta} + \gamma^{-1} \tilde{\psi}^2) \quad (6)$$

식 (5)와 (6)을 이용한 리아프노프 함수의 시간에 대한 미분 함수는 식 (7)과 같이 전개될 수 있다.

$$\begin{aligned} \dot{V} &= z_1 [I_f + \theta^* \zeta + \delta] + z_2 \left[v - \frac{\delta \alpha}{\delta w} - \frac{\delta \alpha}{\delta \theta} \dot{\theta} - \frac{\delta \alpha}{\delta \psi} \dot{\psi} \right. \\ &\quad \left. + \tilde{\theta}^T \Gamma^{-1} \dot{\tilde{\theta}} + \gamma^{-1} \dot{\tilde{\psi}} \right] \\ &\leq -cV + \lambda \end{aligned} \quad (7)$$

식 (7)의 해는 식(8)과 같이 주어진다.

$$0 \leq V(t) \leq \frac{\lambda}{c} + (V(0) - \frac{\lambda}{c}) \exp(-ct) \quad (8)$$

한편, 식 (9)는 식 (7)의 부등호 관계가 성립하기 위한 제어 입력이다.


$$\begin{aligned} \dot{I}_f &= -z_1 - z_2 - (I_f + \theta^T \zeta) - \dot{\theta}^T \zeta \\ &\quad - \dot{\psi} \tanh\left(\frac{z_1}{\epsilon}\right) + \psi \tanh\left(\frac{I_f}{\epsilon}\right) \\ \dot{\theta} &= \Gamma(\zeta(z_1 + z_2)) \\ \dot{\psi} &= \gamma(z_1 \tanh\left(\frac{z_1}{\epsilon}\right) + z_2 \tanh\left(\frac{z_2}{\epsilon}\right)) \end{aligned} \quad (9)$$

식 (8)의 부등 관계에 의해 식 (5)는 uniform bound하게 되므로 제어 입력인 식 (9)에 의해 w 는 w_r 을 오차 범위 안으로 추종할 수 있게 된다. uniform bound의 원인은 미지 함수의 재구성에 따른 구성 오차로서, 이 구성 오차는 ϵ 의 값에 비례한다. 따라서 ϵ 의 값을 작게 설정하여 w 와 w_r 사이의 오차를 줄일 수 있다.


2.4 컴퓨터 모의 실험 및 결과 고찰

본 논문의 모의 실험에서는 제시된 적응 신경망 기법의 타당성을 입증하기 위해 MATLAB으로 컴퓨터 모의 실험을 수행하였다. 그림 5는 $\epsilon = 0.001$ 경우의 모의 실험 결과이다. 기준 모델과 출력 속도와의 추종 오차는 추종이 안정된 이후 ± 10 [rpm]이내의 오차를 보여준다. 그림 4는

$\epsilon = 0.1$ 경우의 모의실험 결과로 ϵ 가 작아짐에 따라 성능이 개선됨을 확인할 수 있었다.



〈그림 4〉기준모델(w_r)과 출력속도(w)[rpm] 속도추종오차($z_1 = w - w_1$)[rpm]



〈그림 5〉기준모델(w_r)과 출력속도(w)[rpm] 속도추종오차($z_1 = w - w_1$)[rpm]

3. 결 론

본 논문에서는 자기 회귀 신경망을 이용한 적응 제어 기법을 이용하여 풍력 발전 시스템의 속도 제어 방법을 제안하였으며, 비선형적인 풍력 발전 시스템의 속도 제어를 발전기의 계자 권선 전압으로 조정하였다. 이를 구현하기 위해 자기 회귀 신경망 기반의 적응 제어기의 구조를 사용하였고, 풍력 발전 시스템의 기계 및 전기적인 동특성을 고려하여 제어 알고리즘을 유도하였다. 또한 컴퓨터 모의 실험 결과들로부터, 본 논문에서 제안된 제어 알고리즘의 타당성 및 효용성을 확인하였다.

[참 고 문 헌]

- [1] J. Chang, Y. Peng, "Movable Propeller Turbine Neural Network Model and Nonlinear Simulation", in *Proc. Conf. Machine learning and Cybernetics*, pp. 1220-1225, Aug 2005.
- [2] Y. D. Song, B. Dhinakaran and X. Bao, "Control of Wind Turbines using Nonlinear Adaptive Field Excitation Algorithms", in *Proc. Conf. American Control Conference*, Vol. 3, pp. 1551-1555, June, 2000.
- [3] X. F. Zhang, D. P. Xu and Y. B. Liu, "Adaptive Optimal Fuzzy Control for Variable Speed Fixed Pitch Wind Turbines", in *Proc. Conf. 5th World Congress on Intelligent Control and Automation*, Vol. 3, pp. 2481-2485, June 2004.
- [4] Sung Jin Yoo, Jin Bae Park, and Yoon Ho Choi, "Indirect Adaptive Control of Nonlinear Dynamic Systems Using Self Recurrent Wavelet Neural Network via Adaptive Learning Rates", *Information Sciences*, Vol. 177, No. 15, pp. 3074-3098, 2007.
- [5] Marios M. Polycarpou, "Stable Adaptive Neural Control Scheme for Nonlinear Systems", *IEEE Transactions on Automatic Control*, Vol. 41, No. 3, pp. 447-451, March 1996.