

신경회로망을 이용한 전력계통 안정화에 관한 연구

A Study on the Power System Stabilization Using a Neural Network

정 형 환*, 안 병 철**, 주 석 민**, 김 상 효**
Hyeong-Hwan Chong*, Byung-Chul An**, Seok-Min Joo**, Sang-Hyo Kim**

본 논문은 1995년도 동아대학교 교내학술연구비 지원에 의하여 연구되었음

요 약

본 논문에서는 신경회로망 제어기의 한 설계기법을 제안하고 이를 전력계통 안정화에 적용하였다. 제안된 신경회로망 제어기는 오차와 오차변화량을 입력으로 하는 오차역전파 학습 알고리즘을 사용하고, 학습시간을 단축하여 실시간 제어가 가능한 모멘텀 방법을 사용하였다.

이를 전력계통에 적용한 결과 제안된 제어기법이 종래의 제어기법보다 응답특성이 우수함을 보였다.

ABSTRACT

In this paper, we propose a design technique for a neural network controller and apply it to power system stabilization. Using a learning algorithm of error back propagation that accepts error and change of error as inputs, the momentum learning technique is used by which reduction of learning time is possible for real time control.

The related simulation results show that the proposed control technique is more powerful than the conventional ones for dynamic responses.

I. 서 론

현재 대규모 복잡화 되고 있는 전력계통에 있어서, 전력의 안정화 공급이 중요한 문제로 부각되고 있다. 또한 전력시스템은 점차 연계된 계통으로 변화하고 있으나 안정도는 오히려 저하하기 때문에 안정적인 전력공급을 위해서 지속적인 대책수립이 요구된다.

따라서 고신뢰, 양질의 전기에너지는 전압과 주파수를 허용 범위내로 수렴시킬 수 있는지의 여부에 달려 있다고 볼 수 있다. 이러한 문제를 해결하기 위하여 전력계통의 안정화 장치(Power System Stabilizer: PSS)에 대한 연구가 활발하게 이루어져오고 있다.

Hanson[1]은 전력계통의 응답특성을 개선하기 위하여 조속기 및 전압조정기 등 발전기 제어부의 이득상수를 조정하여 계통의 안정도 향상에 기여하였으나 시행착오법으로 이득상수를 구하여 발전기를 제어하였기에 체계적인 접근방법을 제시하지 못하였다.

*동아대학교 전기공학과 교수·공학
**동아대학교 전기공학과 박사과정

Demello[2]은 전력계통 안정화 장치의 새로운 도입으로 안정도 문제의 체계적인 해를 구하는 방법을 제시하였다. 이후 Fleming[3], Gooi[4]에 의해 최적 파라미터 선정에 관한 연구가 활발히 진행되었고 Yu[5]는 위상보상회로를 구성하여 감쇠크기의 조정으로 PSS의 계수를 구하는 방법을 사용하였다.

그러나 전력계통은 비선형 시스템으로서 모델화가 어렵고 부하 및 발전기의 운전상태등이 다양하게 변화하므로 이에 대하여 광범위한 영역에서 동작되는 안정화 제어기를 설계한다는 것은 곤란하였다. 따라서 제어시스템을 설계하는데 있어서 중요한 점은 플랜트의 수학적 모델의 설계와 제어시스템의 강인성을 향상 시키는 것이다. 그러나 다양한 수학적 모델을 기반으로하여 설계되는 전력계통 플랜트는 부하 변동, 단락 및 지락등과 같은 예기치 못한 외란에 의해 운전상태가 상당히 변화 할 뿐만 아니라 복잡하고 예측하기 어려운 요소가 많기 때문에 모델링의 정확한 표현을 못하고 있는 실정이다. 오직 어느 정도 근사화하여 모델을 구할 뿐이다.

따라서 실제 시스템의 다양한 동적특성과 상태변이를 나타내는 가장 근접한 모델의 개발과 이 모델을 제어하는 한 분야로 비선형과 복잡성들을 학습하고 표현할 수 있는 인공신경회로망(Artificial Neural Network: ANN)이 제시되었다. 공학의 각 분야에 신경회로망을 적용하고자 하는 기본적인 목표는 생물의 신경계와 같은 복잡한 시스템을 비교적 단순한 소자의 집합으로 모델링하고 제시된 모델을 다양한 수학적 형식론과 컴퓨터 시뮬레이션에 의해서 검증하는 것이다[6].

그리고 이러한 연구는 항상 인간의 뇌와 같이 유연하고 고성능인 신경컴퓨터를 만들고자 하는 욕구 때문에 발전하여 왔다. 최근 수년 동안 신호처리, 패턴인식, 최적화, 로보틱스, 시스템 제어등 여러분야에 신경회로망 기술이 도입되었으며, 또한 비선형 동적 시스템의 제어에 응용하는 분야에 관한 연구도 활발히 진행되고 있다[7-8].

Y.Zhang[21]등은 신경회로망 이론을 이용하여 PSS 계인을 추적하는데, 최초 전력계통 안정화를 연구하였다.

따라서 본 논문에서는 신경회로망을 이용하여 오차와 오차변화량을 입력으로 하는 신경회로망 제

기를 구성하고, 오차최소화 학습방법중의 하나인 오차역전파(Error Back-Propagation) 학습 알고리즘을 이용하여 시스템을 학습하였다. 학습시간을 단축하기 위하여 모뎀 방법을 사용하였으며, 이를 전력계통 안정화 장치에 적용 하여 회전자각 편차의 초기치를 변화 시켰을 경우와 부하 조건의 변화로 무효전력과 유효전력을 변화 시켰을 경우에 있어서 회전자각 편차의 특성과 각속도 편차 특성을 고찰하였다. 또한 종래의 안정화 장치와 비교하여 신경회로망 제어기의 적용 가능성을 제시 하였다.

II. 계통방정식

동기발전기와 여자의 비선형모델을 실질적인 동작점에서 선형화한 1기 무한대모선의 모형은 그림1과 같고 이 계통모형은 기계적입력을 고정시킨후($\Delta T_m = 0$) 평형상태에서 선형화한 모형이다[9-14][20]. 여기서,

$\frac{K_3}{1+sT_{do}K_3}$ 는 계자회로 부분이고, $\frac{K_A}{1+sT_A}$ 는 여자기 모델이다.




그림 1. 선형화한 1기 무한대모선 모형
Fig. 1 A linearized one-machine infinite-bus model

그림1을 기초로 한 Noise 항을 추가시킨 Direct Lurie's Problem는 식(1)과 같은 상태방정식으로 표현된다.

$$\begin{aligned} \frac{d}{dt} X(t) &= AX(t) + BU(t) + Df(\sigma) \\ Y(t) &= CX(t) \end{aligned} \quad (1)$$

$$\sigma = C^T X$$

단, X: 상태벡터

U: 제어벡터

f(σ): Noise 항

$$A = \begin{bmatrix} -\frac{D}{M} & -\frac{K_1}{M} & -\frac{K_2}{M} & 0 \\ 2\pi f & 0 & 0 & 0 \\ 0 & -\frac{K_4}{T_{do'}} & -\frac{1}{T_{do'} K_3} & -\frac{1}{T_{do'}} \\ 0 & -\frac{K_A K_5}{T_A} & -\frac{K_A K_6}{T_A} & -\frac{1}{T_A} \end{bmatrix}$$

$$B = \begin{bmatrix} 0 & 0 & 0 & \frac{K_A}{T_A} \end{bmatrix}^T$$

$$U = [U_c]$$

$$C = [0 \ 1 \ 0 \ 0]$$

$$X(t) = [\Delta\omega, \Delta\delta, \Delta e_q', \Delta E_{FD}]^T$$

종래의 전력시스템 안정화장치(PSS)는 그림 2와 같다.




그림 2 기존 PSS 구조

Fig. 2 Block diagram of conventional PSS

여기서, $\frac{sT}{1+sT}$ 는 신호복귀 블록이고, Kc는 이득,

$\frac{Kc(1+sT_1)}{1+sT_2}$ 는 위상보상회로이다.

III. 신경회로망

1. 신경회로망 구조와 학습

신경회로망을 공학에 응용하기 위하여 신경모델을 구성한다[13-17]. 이 모델의 특징은 여러가지 주위환경에 적용할 수 있고, 학습을 통하여 스스로 지능을 축적 하여 다수의 뉴런들에 의하여 병렬 분산처리(Parallel Distributed Processing)를 수행할 수 있는 인공적인 신경회로망 모델이다.

인공 신경 회로망은 뉴런(Neuron)이라고 불리는

간단한 프로세싱 요소(Processing Element: PE)들의 다양한 집합으로 구성된다.

그림 3은 전형적인 뉴런의 구조를 블록 다이어그램으로 보여주고 있다.




그림. 3 신경회로망 내 뉴런의 구조

Fig. 3 Block diagram of a neuron

각 뉴런들은 다른 뉴런들의 출력에 가중치를 곱하고, 이들의 합이 활성화함수(Activation Function)를 지나면서 다른 뉴런의 입력값으로 이용된다. 이때 각 뉴런의 출력치 y는 식(2)와 같이 나타낼 수 있다.

$$y = f(x), \quad x = \sum_i W_i x_i \quad (2)$$

여기서 i번째 가중치 Wi와 입력치 xi의 총합 x가 얻어져 활성화함수 f에 의해 변형된 후 출력된다. 가중치는 흥분성 결합일 때에는 정(正)의 수를, 억제성 결합일 때에는 부(負)의 수를 취한다.

즉, 각 뉴런은 가중치의 연결 강도에 따라서 입력된 신호가 증폭 또는 감쇄되어 다른 뉴런들에게 전달한다. 활성화함수는 맥컬로-핏츠(McCulloh-Pitts)모델, 시그모이드 함수(Sigmoid Function) 하이퍼볼릭 탄젠트(Hyperbolic Tangent)등의 여러 종류가 사용되고 있다.

본 논문에서는 식(3)~식(4)와 같이 일종의 시그모이드 함수로써, 출력[-1, 1]의 범위내에서 미분 가능한 단조증가 Hyperbolic Tangent 함수를 사용하였다.

$$f(x) = \frac{(1 - \exp(-x))}{(1 + \exp(-x))} \quad (3)$$

$$f'(x) = \frac{1}{2} \{(1 - f(x)) \cdot (1 + f(x))\} \quad (4)$$

2. 오차 역전파 학습

다층 신경회로망의 중간층에서 구해지는 뉴런의 특성은 입력 신호 패턴뿐만 아니라 학습과정의 출력 신호의 영향도 받게 된다. 1986년 Rumelhart는 출력층에서의 오차를 이용하여 중간층의 뉴런특성을 바꾸는 역전파 학습 알고리즘을 제안하였다[7][16]. 본 논문에서 사용한 신경회로망 구조는 그림 4와 같다.




그림. 4 신경회로망 구조
Fig. 4 Neural Network Structure

역전파 학습방법은 임의의 시간 t에서 출력값과 교신호 사이의 오차에 중간층과 출력층의 가중치를 곱하고, 여기에 입력을 곱하여 가중치를 변화시키는 방법이다. 다층신경회로망의 각 뉴런이 그림 4와 같이 구성되었을 경우 이 신경회로망은 뉴런 i의 출력 I_i 와, 가중치 W_{ij} 를 곱한 다음 그 값들의 전체집합 뉴런 j의 입력으로 하고 그 출력을 규격화하는 함수 f에 의해 뉴런 j의 출력 O_j 가 결정되는 수식은 (5)와 같은 모델이다.

$$u_j = f(\sum_i W_{ij} \cdot I_i) \quad (5)$$

$$H_j = f(u_j)$$

여기서, 중간층 뉴런 j의 출력을 H_j , 출력층 뉴런 k의 출력을 O_k , 그리고 중간층 뉴런 j와 출력층 k와의 가중치를 W_{jk} 로 한다.

활성함수 f는 출력이 [-1, 1]의 범위내에서 단조 증가하는 식(3)과 같은 함수를 이용하였다. 이와 같은 경우 학습의 목표는 출력층에 있어서의 출력 O_k 와 교

신호 T_k 사이의 오차를 $\delta^k (= T_k - O_k)$ 로 두고 그 자승오차 E_p 를 최소화 시킨다. 이때 E_p 를 최소화 시키는 수식은 식(6)과 같고 오차 δ^k 는 식(7)과 같다.

$$E_p = \sum_k \frac{(T_k - O_k)^2}{2} \quad (6)$$

$$\frac{\delta E_p}{\delta O_k} = -(T_k - O_k) = -\delta^k \quad (7)$$

그래서, 출력층 뉴런 k의 내부 포텐셜 $S_k (= \sum W_{jk} \cdot H_j)$ 를 변환하면 그 출력은 $O_k = f(S_k)$ 로 되고, 가중치 W_{jk} 의 미소변화에 대한 출력 O_k 의 영향 $\frac{\delta O_k}{\delta W_{jk}}$ 는 식(4)로부터 식(8)과 같이 표현될 수 있다.

$$\frac{\delta O_k}{\delta W_{jk}} = f'(S_k) \cdot H_j$$

$$= \frac{1}{2} = \eta_1 \cdot (1 + O_k) \cdot (1 - O_k) \cdot H_j \quad (8)$$

여기서, η_1 은 정수이다. 따라서 가중치 W_{jk} 의 자승오차 E_p 에의 영향 $\frac{\delta E_p}{\delta W_{jk}}$ 는 식(6)과 식(8)로부터 식(9)와 같이 된다.

$$\frac{\delta E_p}{\delta W_{jk}} = \frac{\delta E_p}{\delta O_k} \cdot \frac{\delta O_k}{\delta W_{jk}}$$

$$= -\frac{1}{2} \eta_1 \cdot \delta^k \cdot (1 + O_k) \cdot (1 - O_k) \cdot H_j \quad (9)$$

자승오차 E_p 를 감소시키기 위한 가중치의 변화량 ΔW_{jk} 는 최급강하법(Steepest Descent Method)을 사용하면 식(10)과 같다.

$$\Delta W_{jk} = -\alpha_2 \frac{\delta E_p}{\delta W_{jk}}$$

$$= \eta_2 \cdot \delta^k \cdot (1 + O_k) \cdot (1 - O_k) \cdot H_j \quad (10)$$

여기서, η_2 는 정수이다. 또, 이 경우의 오차 δ_k 는 식(11)과 같다.

$$\delta_k = \frac{\delta E_p}{\delta S_k} = \delta^k \cdot (1 + O_k) \cdot (1 - O_k) \quad (11)$$

식(11)을 사용하면 식(10)은 식(12)와 같이 된다.

$$\Delta W_{jk} = \eta_2 \cdot \delta_k \cdot H_j \quad (12)$$

입력층과 중간층 사이의 가중치 W_{ij} 의 변화량 ΔW_{ij} 도 같은 방법으로 정의할 수 있다.

즉, 우선 중간층 뉴런 j 의 내부 포텐셜 $u_j (= \sum W_{ij} \cdot I_i)$ 로 하면 그 출력 H_j 는 $H_j = f(u_j)$ 로 나타낼 수 있고, 가중치 W_{ij} 의 미소 변화에 대한 자승오차 E_p 에의 영향을 식(13)과 같이 나타낼 수 있다.

$$\frac{\delta E_p}{\delta W_{ij}} = -\frac{1}{2} \sum \delta_k \cdot W_{kj} \cdot (1 + H_j) \cdot (1 - H_j) \cdot I_i \quad (13)$$

따라서, 식(10)과 같이 중간층 뉴런 j 의 오차를 σ_j 로 두면 식(13)은 식(14)와 같이 나타낼 수 있다.

$$\frac{\delta E_p}{\delta W_{ij}} = -\sigma_j \cdot I_i$$

따라서, 가중치의 변화량 ΔW_{ij} 는 식(14)로부터 식(15)와 같이 나타낼 수 있게 된다.

$$\Delta W_{ij} = -\eta_3 \cdot \frac{\delta E_p}{\delta W_{ij}} = \eta_3 \cdot \sigma_j \cdot I_i \quad (15)$$

단, η_3 은 정수이다.

오차 역전과 학습을 응용할 경우에는 학습이 수렴할 때까지는 많은 횟수의 반복학습을 필요로 하고, 극소점(Local Minimum)의 상태로 들어갈 가능성이 있고, 응용할 때마다 학습 파라미터의 조정이 필요하다.

본 논문에서는 이전 수정량도 고려하여서 수정량을 결정하는 방법으로써, 오차로부터 구해진 수정량에 의한 오버슈터를 억제하여 학습의 고속화에 유효한 것으로 알려져 있는 모멘텀법을 사용하여 학습 파라미터를 조정한다.

학습시간을 단축하여 실질적인 실시간 제어가 가능한 모멘텀법은 $(t-1)$ 시간에서 구하여진 오차의 변화량 $\Delta W(t-1)$ 에 일정한 모멘텀 (m)을 곱한 값을 현재 시간 t 에서 구해진 오차의 변화량 $\Delta W(t)$ 에 더하여 구할 수 있으며, 다음과 같이 가중치를 계산할 수 있다.

중간층과 출력층 사이의 가중치 변화량은 식(16)과 같다.

$$\Delta W_{jk}(t) = \eta_2 \cdot \delta_k \cdot H_j + m \cdot \Delta W_{jk}(t-1) \quad (16)$$

또, 입력층과 중간층 사이의 가중치 변화량은 식(17)과 같이 구해진다.

$$\Delta W_{ij}(t) = \eta_3 \cdot \sigma_j \cdot I_i + m \cdot \Delta W_{ij}(t-1) \quad (17)$$

여기서, $\Delta W(t-1)$ 은 전회의 가중치 변화량, $\Delta W(t)$ 는 현재의 가중치 변화량이고, m 은 모멘텀 계수이다.

IV. 시뮬레이션 결과 및 고찰

본 연구에서는 시스템의 오차와 오차의 변화량을 입력으로 하는 신경회로망 제어기를 구성하여 전력계통 안정화에 적용하였다. 이 제어기는 오차 최소화 학습법중의 하나인 오차 역전과 학습 알고리즘을 이용하여 시스템을 학습하게 된다. 본 연구에 사용한 신경회로망 제어기는 그림5와 같으며 각속도편차의 오차 e_i 및 오차변화률 \dot{e}_i 을 신경회로망 제어기 입력으로 사용한다. 시뮬레이션에 사용한 신경회로망은 입력층2개, 중간층10개, 출력층1개의 뉴런으로 구성하였다. 교사신호는 플랜트의 출력인 각속도 편차 $\Delta \omega$ 로 주었다. 제한한 신경회로망 제어기의 강인성을 검




그림 5 신경회로망 제어기에 의한 전력계통 안정화장치 구조
Fig. 5 Structure of Power System Stabilizer by Neural Network Controller.


표 1. 계통정수 및 초기설정값

Table 1. System parameter and initial values


계통정수	$M = 9.26$	$x_d = 0.973$
	$D = 0$	$x'_d = 0.19$
	$T'_{do} = 7.76$	$x_q = 0.55$
	$K_A = 50$	$T_A = 0.05$
선로정수	$R = -0.034$	$X = 0.997$
	$G = 0.249$	$B = 0.262$
초기설정값	$P_{e0} = 1.0$	$Q_{e0} = 0.015$
	$V_{t0} = 1.05$	

증하기 위해 회전자각 편차의 초기치를 변화시켰을 경우와 부하조건의 변화로 유효전력과 무효전력의 초기치를 변화시킨 경우에 있어 기존 PSS와 제안한 신경회로망 제어기의 동작특성을 비교·검토하였다. 여기에서 사용한 계통정수는 표1과 같다.

먼저, 회전자각 편차의 초기치를 0.1[rad]로 두고 유효전력과 무효전력의 초기치를 Case 1 ($P_{eo}=1.0$, $Q_{eo}=0.015$), Case 2 ($P_{eo}=0.7$, $Q_{eo}=0.4$)인 경우의 응답특성을 살펴보자. 그림 6은 Case 1인 경우의 회전자각 편차와 각속도 편차의 응답특성이고, 그림 7은 Case 2인 경우의 응답특성이다. 이때 기존 PSS보다 신경회로망 제어기가 최대편차량 및 수렴특성에서 양호한 응답특성을 나타내었다.




(a) 각속도 편차에 관한 응답
(a) Dynamic response for angular velocity deviation




(b) 회전자각 편차에 관한 응답
(b) Dynamic response for rotor angle deviation

그림 6. $\Delta\delta=0.1$, $P_{eo}=1.0$, $Q_{eo}=0.015$ 에 대한 동작응답
Fig. 6 Dynamic responses for $\Delta\delta=0.1$, $P_{eo}=1$, $Q_{eo}=0.015$



(a) 각속도 편차에 관한 응답
(a) Dynamic response for angular velocity deviation




(b) 회전자각 편차에 관한 응답
(b) Dynamic response for rotor angle deviation


그림 7. $\Delta\delta=0.1$, $P_{eo}=0.7$, $Q_{eo}=0.4$ 에 대한 동적응답
Fig. 7 Dynamic responses for $\Delta\delta=0.1$, $P_{eo}=0.7$, $Q_{eo}=0.4$

두번째로는 회전자각 편차를 0.5[rad]로 고정시킨 후 유효전력과 무효전력의 초기치를 Case 1과 Case 2로 둔 경우의 응답특성이다. 그림 8은 Case 1인 경우, 그림 9는 Case 2의 응답특성이다. 이 경우에 있어서도 제안한 신경회로망 제어기가 제어효과와 강인성에서 좋은 제어성능을 보였다.

세번째로 회전자각 편차를 0.5[rad]으로 고정시킨 후 유효전력과 무효전력의 초기치를 Case 1과 Case 2로 둔 경우에 있어서 Noise항을 추가시킨 경우의 응답특성이다. 그림 10은 Case 1인 경우, 그림 11은 Case 2의 응답 특성이다. 이 경우에 있어서도 제안한 신경회로망 제어기의 각속도 편차, 회전자각 편차의 제어효과와 강인성에서 좋은 제어성능을 보였다.




(a) 각속도 편차에 관한 응답
(a) Dynamic response for angular velocity deviation




(b) 회전자각 편차에 관한 응답
(b) Dynamic response for rotor angle deviation

그림 9. $\Delta\delta = 0.5$, $Peo = 0.7$, $Qeo = 0.4$ 에 대한 동적응답
Fig. 9 Dynamic responses for $\Delta\delta = 0.5$, $Peo = 0.7$, $Qeo = 0.4$




(b) 회전자각 편차에 관한 응답
(b) Dynamic response for rotor angle deviation


그림 8. $\Delta\delta = 0.5$, $Peo = 1.0$, $Qeo = 0.015$ 에 대한 동적응답
Fig. 8 Dynamic responses for $\Delta\delta = 0.5$, $Peo = 1.0$, $Qeo = 0.015$



(a) 각속도 편차에 관한 응답
(a) Dynamic response for angular velocity deviation




(a) 각속도 편차에 관한 응답
(a) Dynamic response for angular velocity deviation




(b) 회전자각 편차에 관한 응답
(b) Dynamic response for rotor angle deviation

그림 10. $\Delta\delta = 0.5$, $Peo = 1.0$, $Qeo = 0.015$ 에 있어서 noise 첨가에 대한 동적응답
Fig. 10 Dynamic responses on adding noise for $\Delta\delta = 0.5$, $Peo = 1.0$, $Qeo = 0.015$



(a) 각속도 편차에 관한 응답
(a) Dynamic response for angular velocity deviation



(b) 회전각 편차에 관한 응답
(b) Dynamic response for rotor angle deviation

그림 11. $\Delta\delta = 0.5$, $Pe_o = 0.7$, $Qe_o = 0.4$ 에 있어서 noise 첨가에 대한동적응답
Fig. 11 Dynamic responses on adding noise for $\Delta\delta = 0.5$, $Pe_o = 0.7$, $Qe_o = 0.4$

유효전력과 무효전력의 초기치를 변화시켜주면 선형화 모형계수($K_1 \sim K_6$)가 변화게 된다. 변화된 파라미터는 표 2에 나타내었으며, 기존 PSS와 제안한 신경회로망 제어기의 시뮬레이션 결과는 표 3과 같다.

표 2. $K_1 \sim K_6$ 의 파라미터

Table 2. Parameters of $K_1 \sim K_6$

	$Pe_o = 1.0$ $Qe_o = 0.015$	$Pe_o = 0.7$ $Qe_o = 0.4$
K_1	0.54427	0.47393
K_2	1.20675	0.83598
K_3	0.65845	0.65845
K_4	0.69819	0.69820
K_5	-0.09552	-0.12720
K_6	0.81593	0.85981

V. 결 론

본 연구에서는 전력계통 안정화 제어를 위한 신경회로망 제어기법을 제안하였다. 학습을 위해 신경회로망의 오차 최소화 학습 방법중의 하나인 오차 역전파 학습 알고리즘을 이용하였다. 학습 시간을 단축하여 실질적인 실시간 제어가 가능한 모델법 방법을 사용하였다. 이를 1기 무한대 모션 전력계통에 적용하

표 3. 시뮬레이션 결과

Table 3. Simulation results

			Control Method	Simulation result	
				Undershoot	Settling Time
$\Delta\omega = 0.1$	$\Delta\omega$	$Pe_o = 1.0$	PSS	-0.00108 [rad/s]	6.72 [sec]
		$Qe_o = 0.015$	NNC	-0.00112 [rad/s]	1.89 [sec]
		$Pe_o = 0.7$	PSS	-0.00109 [rad/s]	8.98 [sec]
		$Qe_o = 0.4$	NNC	-0.00123 [rad/s]	2.18 [sec]
	$\Delta\delta$	$Pe_o = 1.0$	PSS	-0.062 [rad]	6.51 [sec]
		$Qe_o = 0.015$	NCC	-0.034 [rad]	1.72 [sec]
		$Pe_o = 0.7$	PSS	-0.072 [rad]	6.51 [sec]
		$Qe_o = 0.4$	NNC	-0.031 [rad]	1.98 [sec]

$\Delta\delta = 0.5$	$\Delta\omega$	Peo = 1.0	PSS	-0.0052 [rad/s]	6.78 [sec]
		Qeo = 0.015	NNC	-0.0055 [rad/s]	3.38 [sec]
		Peo = 0.7	PSS	-0.0052 [rad/s]	9.38 [sec]
		Qeo = 0.4	NNC	-0.0048 [rad/s]	2.67 [sec]
	$\Delta\delta$	Peo = 1.0	PSS	-0.2983 [rad]	6.20 [sec]
		Qeo = 0.015	NNC	-0.1826 [rad]	2.73 [sec]
		Peo = 0.7	PSS	-0.3592 [rad]	9.13 [sec]
		Qeo = 0.4	NNC	-0.1479 [rad]	2.48 [sec]

여 각속도 및 회전자각 편차의 동특성에 대한 응답이 종래의 제어기법 PSS보다 제안한 신경회로망 제어기가 우수한 제어특성을 나타냄을 확인 하였다. 이상 본 논문의 연구 결과를 요약하면 다음과 같다.

첫째, 종래의 제어기법 PSS인 경우에 대해 각속도 및 회전자각 편차의 특성에서 장시간의 진동으로 수렴 특성이 좋지 못한다에 비해 신경회로망은 각각의 최대 편차량, 정정시간 등의 특성에서 우수함을 보였다.

둘째, 초기치를 변화시켰을 경우 및 부하조건을 변화 시켰을 경우에도 종래의 제어기법인 PSS보다 제안한 신경회로망이 보다 빠른 수렴을 나타내었으며, 또한 정상상태에서의 수렴특성도 우수함을 입증하였다.

참 고 문 헌


- O. W. Hanson, C. J. Goodwin, P. L. Dandeno, "Influence of Excitation and Speed Control Parameters in Stabilizing Intersystem Oscillations", IEE Trans on Power Apparatus and System, Vol PAS-87, No. 5, pp. 1306~1311, 1968.
- F. P. Demello, C. Concordia, "Concepts of Synchronous Machine Stability as Affected by Excitation Control", IEEE Trans. on Power Apparatus and System, Vol. PAS-88, No. 4, pp. 189~202, 1969.
- R. J. Fleming, M. A. Mohan, K. Parvatisam, "Selection Parameters of Stabilizers in Multimachine Power System", IEEE Trans. on Power Apparatus and System, Vol. PAS-100, No. 5, pp. 2329~2333, 1981.
- H. B. Gooi, E. F. Hill, M. A. Mobarak, D. H. Thorne, T. H. Lee, "Coordinate Multi-Machine Stabilizer Settings Without Eigenvalue Drift", IEEE Trans. on Power Apparatus and System, Vol. PAS-100, No. 8, pp. 3879~3887, 1981.
- Yao-Nan. Yu, "Electric Power System Dynamics", pp. 65-94, Academic, Press 1983.
- M. J. Willis, G. A. Momtague, C. D. Massimo, and M. T. Tham, "Artificial Neural Networks in process Estimation and Control", Automatica, Vol. 1, pp. 1181-1187, 1992.
- Panos J. Antsaklis, "Neural Networks in Control Systems", April, 1992.
- B. Bavarian, Guest Ed., "Special Issue on Neural Networks for Systems and Control", IEEE Control System Magazines, Vol. 8, No. 2, pp. 3-31, April, 1988.
- 정형환, 외 4명, "2 지역 전력계통의 부하주파수 제어를 위한 퍼지추론 기법의 적용", 한국퍼지시스템학회 논문지, Vol. 2, No. 4, pp. 67~73, 1992.
- A. Ishigame, H. Kaizu et al, "Power System Stabilizing Control Based on Simplification of Constructing Fuzzy Control Rules", IEE J., Vol. 113-B, No. 1, 1993.
- 정형환 외 4명, "최적 PID 제어기에 의한 2지역 전력계통의 부하주파수 제어 특성에 관한 연구", 대한전기학회 논문지, Vol. 43, No. 5, pp. 703~710, 1994.
- 정형환 외 4명, "의란적용 퍼지제어기를 이용한 전력계통의 부하주파수제어 특성에 관한연구",

대한전기학회 논문지, Vol. 43, No. 9, pp. 1393~1400, 1994.

13. 정형환 외 2명, "자기조정 퍼지제어기에 의한 전력계통 안정화에 관한 연구", 한국퍼지 및 지능 시스템학회 논문지, Vol. 5, No. 2, pp. 58~69. 1995.
14. 정형환 외 3명, "가중치 조정에 의한 교류-직류 병렬계통의 동특성 해석", 대한전기학회 논문지, Vol. 44, No. 10, pp. 1265~1273. 1995.
15. Bart Kosko, "Neural networks and Fuzzy systems", Prentice-Hall, 1992.
16. Simon Haykin, "Neural Networks", Macmillan College Publishing Company, 1994.
17. Takenori Kobayashi, Yasuo Morioka, Akihiko Yokoyama, "Synchronous Generator Control Using Neural Network Based Nonlinear Adaptive Regulator", IEE J., Vol. 114, No. 9, pp843~851, 1994.
18. 박민용, 최항식, "뉴로 컴퓨터", 대영사, 1991.
19. 정호선, 여진경, "뉴로 퍼지 카오스", 대광서림, 1994.
20. 박영문 외2명, "퍼지형 안정화제어기의 비선형특성에 관한연구", 대한전기학회 논문지, Vol. 42, No. 11, pp 61~66, 1993.
21. Y. Zhang, G. P. Chen, O. P. Malik, G. S. Hope, "An Artificial Network Based Adaptive Power System Stabilizer", IEEE Trans. on Energy Conversion, Vol. 8, No. 1, pp. 71~77, 1993.



안 병철(Byung-Chul An) 정회원
 1963년 6월 2일생
 1988년: 동아대학교 전기공학과 졸업
 1990년: 동대학원 전기공학과 졸업 (석사)
 현재: 동대학원 전기공학과 박사과정 수료



주 석민(Seok-Min Joo) 정회원
 1965년 5월 11일생
 1992년: 동아대학교 전기공학과 졸업
 1994년: 동대학원 전기공학과 졸업 (석사)
 현재: 동대학원 전기공학과 박사과정



김 상효(Sang-Hyo Kim) 정회원
 1965년 8월 29일생
 1992년: 동아대학교 전기공학과 졸업
 1994년: 동대학원 전기공학과 졸업 (석사)
 현재: 동대학원 전기공학과 박사과정



정 형 환(Hyeong-Hwan Chong) 정회원
 1941년 1월 19일생
 1964년: 연세대학교 전기공학과 졸업
 1984년: 동대학원 전기공학과 졸업(공학)
 현재: 동아대학교 전기공학과 교수