

전력계통의 안정도 향상을 위한 적응 뉴로-퍼지 전 보상기 설계

(Design of Adaptive Neuro-Fuzzy Precompensator for
Enhancement of Power System Stability)

정형환* · 정문규** · 이정필** · 이준탁*

(Hyeng-Hwan Chung · Mun-Kyu Chung · Jeong-Phil Lee · Joon-Tark Lee)

요 약

본 논문에서는 전력계통의 저주파 진동 억제와 안정도 향상을 위해 적응 뉴로-퍼지 전 보상기(Adaptive Neuro-Fuzzy Precompensator, ANFP)를 설계하였다. 여기서 ANFP는 종래의 전력계통 안정화 장치(Power System Stabilizer, PSS)를 보상하도록 설계되며, 이 설계기법은 기존의 PSS 최적 파라미터를 구하는 방식과는 달리 현재 사용중인 PSS 파라미터를 고정시켜놓고, ANFP만을 추가하는 구조적인 장점을 나타낸다. 먼저, 학습 능력을 가지는 퍼지 전 보상기가 구성되며, 이는 발전 유니트의 입출력 데이터로부터 학습된다. ANFP는 학습의 특성을 가지기 때문에 보상기의 퍼지규칙과 소속함수는 학습 알고리즘에 의해 자동으로 동조될 수 있다. 학습은 ANFP와 목표 제어기(desired controller)의 출력을 비교하여 평가되는 오차를 최소화하도록 수행된다. 사례 연구 들에서 다양한 동작 조건들 상에서 전력계통의 우수한 제동을 제공할 수 있었으며, 시스템의 동특성을 향상시킬 수 있었다.

Abstract

In this paper, we design the Adaptive Neuro-Fuzzy Precompensator(ANFP) for the suppression of low-frequency oscillation and the improvement of system stability. Here, ANFP is designed to compensate the conventional Power System Stabilizer(PSS). This design technique has the structural merit that is easily implemented by adding ANFP to an existing PSS. Firstly, the Fuzzy Precompensator with learning ability is constructed and is directly learned from the input and output data of the generating unit. Because the ANFP has the property of learning, fuzzy rules and membership functions of the compensator can be automatically tuned by learning algorithm. Learning is based on the minimization of the error evaluated by comparing the output of the ANFP and a desired controller. Case studies show the proposed scheme can be provided the good damping of the power system over the wide range of operating conditions and improved the dynamic performance of the system.

* 정회원 : 동아대 전기·전자·컴퓨터공학부 교수·공학

** 정회원 : 동아대 대학원 전기공학과 박사과정

접수일자 : 2001년 3월 28일

1. 서 론

최근 전력수요의 증가와 더불어 전력계통의 규모는 대형화되고, 구조는 복잡해짐에 따라 계통의 안정 운용 및 안정성 유지에 어려움이 증대되고 있다. 특히 전력의 공급과 수요가 지역적으로 편재함에 따라 전력계통에 발생하는 저주파 동요의 감소는 안정성 유지 측면에서 매우 중요한 연구과제로 부각되어 왔다. 그러므로 전력계통의 안정도 문제를 개선하기 위한 전력계통 안정화 장치(Power System Stabilizer, PSS)에 관한 연구가 1960년대 후반부터 활발하게 진행되고 있으며, 그 결과 많은 종류의 제어기들이 제시되어 오고 있다[1-15].

한편, 인공 지능(Artificial Intelligence, AI)의 주요 분야인 퍼지논리제어(Fuzzy Logic Control, FLC)와 인공 신경회로망(Artificial Neural Network, ANN)은 각각의 많은 장점 때문에 고전적인 제어에 대한 대안책으로서 관심을 끌고 있다. 다른 고전적 제어방식과는 달리 FLC와 ANN은 제어대상의 정확한 수학적 모델을 요구하지 않으며, 이들의 신속성과 강인성은 고전적인 설계와 비교하여 우수한 특성을 나타낸다.

종래의 FLC를 이용한 전력계통 안정화 장치(Power System Stabilizer, PSS)의 설계는 복잡한 비선형 시스템에서 만족스러운 결과를 나타낸다 [5-6]. 그러나 FLC의 각 구성요소 선정시 전문가의 경험이나 시행착오법에 의존하므로 FLC 파라미터 동조에 대한 어려움이 있다. 따라서 출력오차나 평가 함수를 최소화하도록 소속함수나 제어규칙을 동조하기 위한 효과적인 방법이 필요하다. 또한, PSS의 설계에 ANN을 이용한 연구도 수행되었다[7-8]. ANN은 FLC에서 발견될 수 없는 장점인 학습과 적응능력을 가진다. 그러나 종래의 ANN을 이용한 시스템의 결점으로는 블랙박스(black box) 특성이다. 즉, 외부 관찰자가 ANN의 내부 의사결정 과정을 이해하거나 변경하는데 어려움을 가진다는 것이다. 이런 이유 때문에 ANN의 초기값은 랜덤하게 선택되어진다.

한편, 본 논문에서는 종래의 만족스럽게 설계된 PSS를 교체하지 않고, 제어기를 간단히 설치할 수 있는 전 보상의 형태를 제시한다. 이와 같은 전 보상형 제어기법은 퍼지와 종래의 PID 제어기의 장점을 이용하여 설계된 하이브리드형 제어기들에서 우수한 결과를 나타낸 바 있다[20-22].

따라서 본 논문에서는 FLC와 ANN을 적용 뉴로-퍼지 전 보상기(Adaptive Neuro-Fuzzy Precompensator, ANFP)를 설계하는데 함께 사용하고자 한다. 여기서 ANFP는 종래의 PSS를 보상하도록 설계하며, 이 설계기법은 기존의 PSS 최적 파라미터를 구하는 방식과는 달리 현재 사용중인 PSS 파라미터를 고정 시켜놓고, 간단히 ANFP만을 추가하는 구조적인 장점을 지닌다. 먼저, 학습능력을 가지는 퍼지 전 보상기가 구성되며, 이는 발전 유니트의 입출력 데이터로부터 학습된다. ANFP는 학습의 특성을 가지기 때문에 보상기의 퍼지규칙과 소속함수는 학습 알고리즘에 의해 자동으로 동조될 수 있다. 학습은 ANFP와 목표 제어기(desired controller)의 출력을 비교하여 평가되는 오차를 최소화하도록 수행된다. 본 논문에서는 H_∞ 최적화 방식에 의한 PSS[9]가 목표 제어기로 사용된다. 본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 사용한 모델계통을 제시하며, 3장에서는 적용 뉴로-퍼지(Adaptive Neuro-Fuzzy, ANF)에 대한 고찰로서 ANF의 구조와 하이브리드 학습에 대해 알아본다. 4장에서는 제안된 제어기법을 전력계통 모델에 적용한 것으로서 PSS의 보상을 위한 ANFP 설계를 다루고 있다. 5장에서는 이에 대한 실험으로 ANFP가 종래의 보상기 설계이론에 의한 PSS보다 다양한 동작 조건들 상에서 전력계통의 우수한 제동을 제공할 수 있으며, 시스템의 동특성을 향상시키고 있음을 보이고자 한다. 마지막으로 6장에서는 본 논문의 결론에 관하여 기술한다.

2. 계통 모델

발전기의 동적인 운동방정식은 식 (1), (2)와 같다.

$$M \frac{d\Delta\omega}{dt} + D\Delta\omega = \Delta T_m - \Delta T_e \quad (1)$$

$$\frac{d\Delta\delta}{dt} = \Delta\omega \quad (2)$$

여기서, $\Delta\omega$ 는 각속도 편차, $\Delta\delta$ 는 회전자각 편차, M 은 동기기의 관성상수, D 는 동기기의 제동상수, ΔT_m 과 ΔT_e 는 동기기의 기계적 및 전기적 토크이다.

또한, 여자기는 동기 발전기의 단자전압이 기준전

전력계통의 안정도 향상을 위한 적응 뉴로-퍼지 전 보상기 설계

압보다 강하할 때는 여자를 증가시키고 단자전압이 기준전압보다 상승할 때는 여자를 감소시키는 부كه 환 작용을 한다. 이로써 여자 시스템은 저주파 진동 시 시스템의 제동을 향상시킬 뿐만 아니라 외란시도 시스템의 안정도를 향상시키는 역할을 한다. 여자는 식 (3)과 같은 전달함수로 나타낸다.

$$\Delta E_{FD} = \frac{K_A}{1+sT_A} (u_E - \Delta V_t) \quad (3)$$

여기서, ΔE_{FD} 는 고정자 유기전력, K_A 와 T_A 는 여자기 이득상수 및 시정수, ΔV_t 는 단자전압, u_E 는 PSS의 출력신호이다.

그림 1은 이와 같은 동기기 및 여자기 모델을 종합한 블록선도이다. 이 모델은 기계적 입력을 고정시킨 후 ($\Delta T_m = 0$) 평형상태에서 선형화한 것으로서, 일반적으로 대기 시스템 안정도 해석에 사용되며, 특히 저주파수 진동을 해석하기 위한 모델이다.




그림 1. 1기 무한대 모선 전력계통의 선형화 모델
Fig. 1. Linearized model of one-machine infinite-bus power system

그림 1을 기초로 한 상태변수는 각속도 편차 $\Delta\omega$, 회전자각 편차 $\Delta\delta$, 발전기 유기전압 $\Delta E_q'$, 고정자 유기전력 ΔE_{FD} 이며, 상태 방정식은 식 (4)와 같이 쓸 수 있다.

$$\begin{aligned} \dot{\mathbf{x}} &= \mathbf{Ax} + \mathbf{Bu} \\ \mathbf{y} &= \mathbf{Cx} \end{aligned} \quad (4)$$

여기서,

$$\mathbf{A} = \begin{bmatrix} -\frac{D}{M} & -\frac{K_1}{M} & -\frac{K_2}{M} & 0 \\ \omega_b & 0 & 0 & 0 \\ 0 & -\frac{K_4}{T'_{d0}} & -\frac{1}{T'_{d0}K_3} & \frac{1}{T'_{d0}} \\ 0 & -\frac{K_A K_5}{T_A} & -\frac{K_A K_6}{T_A} & -\frac{1}{T_A} \end{bmatrix}$$

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

$$\mathbf{C} = [1 \quad 0 \quad 0 \quad 0]$$

$$\mathbf{x} = [\Delta\omega \quad \Delta\delta \quad \Delta E_q' \quad \Delta E_{FD}]^T$$

3. 적응 뉴로 퍼지 (ANF)

3.1 ANF의 구조

FLC와 ANN을 이용한 2입력 1출력 ANF의 구조는 그림 2와 같다[16-19].




그림 2. ANF의 구조
Fig. 2. Structure of ANF

그림 2의 ANF를 언어적 규칙으로 표현하면 식 (5)와 같다.

$$\begin{aligned} \text{Rule 1 : If } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 &= \alpha_1 x + \beta_1 y + \gamma_1 \\ \text{Rule 2 : If } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 &= \alpha_2 x + \beta_2 y + \gamma_2 \end{aligned} \quad (5)$$

여기서, x 와 y 는 입력, A_i 와 B_i 는 각 입력에 대한 소속함수, f_i 는 각 규칙에서의 출력, $\alpha_i, \beta_i, \gamma_i$ 는 각 규칙에서 입력에 대한 선형 파라미터를 의미한다. 그림 2의 ANF에서 Layer 1, 4는 동조될 파라미터를 갖고 있으며, Layer 2, 3, 5는 단지 규정된 연산만을 수행한다. Layer 1의 파라미터는 신호의 전방향 경로(forward pass)시 조정되며, Layer 4의 파라미터는 신호의 역방향 경로(backward pass)시 조정된다.

각 층의 각 노드에서 수행되는 계산은 다음과 같다.

1 층 : 각 노드 i 에 의한 출력은 식 (6)과 같다.

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x) \quad i = 1, 2 \\ O_i^1 &= \mu_{B_{i-2}}(y) \quad i = 3, 4 \end{aligned} \quad (6)$$

여기서, 소속함수 $\mu_{A_i}(x)$ 와 $\mu_{B_i}(y)$ 는 식 (7)과 같이 최대값 1, 최소값 0인 종형 소속함수를 사용한다.

$$\begin{aligned} \mu_{A_i}(x) &= \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \\ \mu_{B_i}(y) &= \frac{1}{1 + \left[\left(\frac{y - c_i}{a_i} \right)^2 \right]^{b_i}} \end{aligned} \quad (7)$$

여기서, $\{ a_i, b_i, c_i \}$ 는 동조되어야 할 조건부 파라미터 집합이다. 폭과 중심을 조정하기 위해 a_i 와 c_i , 교차점에서의 경사를 조정하도록 b_i 가 사용된다. 이 파라미터의 변화 때문에 소속함수는 A_i 와 B_i 에서 다양한 형태로 적절하게 변화하게 된다. 종형 소속함수 이외에도 사다리꼴, 삼각형 소속함수와 같은 연속적이고 이산적인 미분가능한 함수가 사용될 수 있다.

2 층 : 각 노드는 입력 신호들을 곱해서 식 (8)과 같이 출력된다. 이것은 각 퍼지규칙의 조건부 적합도를 계산하는 것을 의미한다.

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1, 2 \quad (8)$$

3 층 : 각 노드는 i 번째 규칙의 적합도와 모든 규칙의 적합도의 합과의 비율을 계산하는데 이 노드의 출력이 정규화된 적합도이다. 각 노드의 출력은 식 (9)와 같다.

$$O_i^3 = \overline{w}_i = \frac{w_i}{\sum_j w_j} \quad i = 1, 2 \quad (9)$$

4 층 : 각 노드에 대하여 결론부 변수를 곱한다. 각 노드의 출력은 식 (10)과 같다.

$$O_i^4 = \overline{w}_i f_i = \overline{w}_i (\alpha_i x + \beta_i y + \gamma_i) \quad (10)$$

여기서, \overline{w}_i 는 3층의 출력이고, $\{ \alpha_i, \beta_i, \gamma_i \}$ 는 동조되어야 할 결론부 파라미터 집합이다.

5 층 : 모든 입력신호들을 합하여 전체 출력을 식 (11)과 같이 계산한다.

$$O_1^5 = f = \sum_i \overline{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (11)$$

3.2 ANF의 학습

ANF의 특징은 하이브리드 학습 알고리즘에 있는데 결론부 파라미터는 먼저 최소자승법을 사용하여 수정되고 조건부 파라미터는 오차를 역전파법에 의해 수정된다. 이러한 하이브리드 알고리즘에 의한 접근은 최급강하법으로만 수행하는 것보다 학습속도가 매우 빠르다. 또한 조건부 및 결론부 파라미터의 최적화에서 조건부 및 결론부 파라미터를 따로따로 최적화하기 때문에 최적화해야 할 파라미터의 수를 줄일 수 있다. 이를 각 전달방향에 대하여 요약하면 표 1과 같다.

표 1. ANF의 하이브리드 학습
Table 1. Hybrid learning of ANF

	전방향 경로	역방향 경로
조건부 파라미터	고정	최급강하법
결론부 파라미터	최소자승법	고정
신호	노드 출력	오차 신호

ANF의 하이브리드 학습 특히, 최소자승법에 의한 학습과정을 설명하기 위해 먼저 식 (5)를 식 (12)와 같이 나타내었다.

$$\begin{aligned} \text{Rule } j : \text{ If } x_1 \text{ is } A_{j1} \text{ and } \dots x_k \text{ is } A_{jk} \text{ then} \\ y_j = a_{j0} + a_{j1}x_1 + \dots + a_{jk}x_k \end{aligned} \quad (12)$$

여기서, Rule j 는 $j(j=1, \dots, n)$ 번째 규칙, $x_l (l=1, \dots, k)$ 는 입력, A_{jl} 은 각 입력에 대한 소속함수, a_{jl} 은 결론부 파라미터이고 n 은 규칙수이다. 추론된 값

전력계통의 안정도 향상을 위한 적응 뉴로-퍼지 전 보상기 설계

y^* 는 식 (13)과 같다.

$$y_i^* = \frac{\sum_{j=1}^n w_{ji} y_j}{\sum_{j=1}^n w_{ji}} = \frac{\sum_{j=1}^n w_{ji} (a_{j0} + a_{j1} x_{1i} + \dots + a_{jk} x_{ki})}{\sum_{j=1}^n w_{ji}} \quad (13)$$

여기서, i 는 $i(i=1, \dots, m)$ 번째 데이터이다.

결론부 파라미터 동조는 조건부 입력변수 및 파라미터가 주어지면, 성능 평가지수 PI(Performance Index)를 최소화하는 결론부 파라미터 a_{ji} 을 결정할 수 있다. PI는 원 시스템의 출력 데이터 y_i 와 시스템의 출력 데이터 y_i^* 간의 차이를 의미하는 성능지수로 식 (14)로 정의된다.

$$PI = \frac{1}{m} \sum_{i=1}^m (y_i - y_i^*)^2 \quad (14)$$

결론부 파라미터는 입출력 데이터가 주어졌을 때 최소자승법에 의해 구해진다. 최소자승법에 의한 매개변수 추정은 식 (15)와 같다.

$$V(a, m) = \frac{1}{2} \sum_{i=1}^m \epsilon_i^2 = \frac{1}{2} \sum_{i=1}^m (y_i - y_i^*)^2 = \frac{1}{2} \sum_{i=1}^m [y_i - \sum_{j=1}^n a_{j0} w_{ji}]^2 \quad (15)$$

$$= \frac{1}{2} \sum_{i=1}^m [y_i - x_i^T a]^2 = \frac{1}{2} \cdot \|E\|^2$$

$$w_{ji} = \frac{(A_{j1}(x_{1i}) \wedge \dots \wedge A_{jk}(x_{ki}))}{\sum_{j=1}^n (A_{j1}(x_{1i}) \wedge \dots \wedge A_{jk}(x_{ki}))}$$

식 (15)에서 $E = Y - X_a$ 이므로 최소자승법에 의한 결론부 파라미터의 동조는 식 (16)에 의해 구해진다.

$$\hat{a} = (X^T X)^{-1} X^T Y \quad (16)$$

$$x_i^T = [w_{1i}, \dots, w_{ni}, x_{1i} w_{1i}, \dots, x_{1i} w_{ni}, \dots, x_{ki} w_{1i}, \dots, x_{ki} w_{ni}]$$

$$a^T = [a_{10}, \dots, a_{n0}, a_{11}, \dots, a_{n1}, \dots, a_{1k}, \dots, a_{nk}]$$

$$Y = [y_1, y_2, \dots, y_m]^T, \quad X = [x_1, x_2, \dots, x_m]^T$$

4. PSS 보상을 위한 ANFP의 설계

4.1 PSS 보상을 위한 ANFP의 구조

본 논문에서는 하이브리드 학습 알고리즘[16,17]에 의해 퍼지 전 보상기의 조건부 소속함수 파라미터와 결론부의 선형 파라미터를 동조하였다. 그림 3은 하이브리드 학습 알고리즘에 의해 퍼지 전 보상기의 조건부와 결론부 파라미터를 동조하기 위한 구성도를 나타낸다. 일반적으로 PSS의 입력으로 유효전력, 주파수 및 각속도가 많이 사용되고 있는데, 본 논문에서는 퍼지 전 보상기의 입력으로 발전기 각속도 편차 $\Delta\omega(e)$ 와 그 변화율 $\Delta\dot{\omega}(\Delta e)$ 를 사용하였다.




그림 3. PSS 보상을 위한 ANFP의 구조
Fig. 3. Structure of ANFP for compensation of PSS

본 논문에서 사용된 퍼지 전 보상기의 언어적 규칙은 식 (17)과 같다.

$$\begin{aligned} \text{Rule 1 : If } e \text{ is } A_1 \text{ and } \Delta e \text{ is } B_1, \text{ then} \\ y_{r1}' &= \alpha_1 e + \beta_1 \Delta e + \gamma_1 \\ \text{Rule 2 : If } e \text{ is } A_1 \text{ and } \Delta e \text{ is } B_2, \text{ then} \\ y_{r2}' &= \alpha_2 e + \beta_2 \Delta e + \gamma_2 \\ &\vdots \\ \text{Rule 9 : If } e \text{ is } A_3 \text{ and } \Delta e \text{ is } B_3, \text{ then} \\ y_{r9}' &= \alpha_9 e + \beta_9 \Delta e + \gamma_9 \end{aligned} \quad (17)$$

최종출력은 각각의 출력에 대한 가중치 평균으로 얻게되며, 식 (18)과 같은 후건부 파라미터의 선형조합으로 표현할 수 있다.

$$y_r' = \frac{w_1}{w_1 + \dots + w_9} y_{r1}' + \frac{w_2}{w_1 + \dots + w_9} y_{r2}'$$

$$\begin{aligned}
 & + \dots + \frac{w_9}{w_1 + \dots + w_9} y_{r'} \\
 = & \bar{w}_1 (a_1 e + \beta_1 \Delta e + \gamma_1) \\
 & + \bar{w}_2 (a_2 e + \beta_2 \Delta e + \gamma_2) \\
 & + \dots + \bar{w}_9 (a_9 e + \beta_9 \Delta e + \gamma_9) \\
 = & (\bar{w}_1 a_1 + \bar{w}_2 a_2 + \dots + \bar{w}_9 a_9) e \\
 & + (\bar{w}_1 \beta_1 + \bar{w}_2 \beta_2 + \dots + \bar{w}_9 \beta_9) \Delta e \\
 & + (\bar{w}_1 \gamma_1 + \bar{w}_2 \gamma_2 + \dots + \bar{w}_9 \gamma_9)
 \end{aligned} \tag{18}$$

그림 4는 본 논문에서 사용한 입출력 e , Δe 와 y_r' , 소속함수(Negative, Zero, Positive), 퍼지규칙 9개인 ANFP의 구조이다.




그림 4. ANFP의 구조
Fig. 4. Structure of ANFP

조건부 파라미터를 동조하기 위해서 식 (19)와 같이 오차를 근거로 하여 퍼지규칙의 조건부 파라미터를 동조한다.

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha} \tag{19}$$

여기서, η 는 학습율이고 식 (20)과 같이 계산된다.

$$\eta = \frac{k}{\sqrt{\sum_{\alpha} \left(\frac{\partial E}{\partial \alpha} \right)^2}} \tag{20}$$

그러므로 새로운 파라미터 α 는 식 (21)과 같이 주어진다.

$$\alpha_{n+1} = \alpha_n + \Delta \alpha \tag{21}$$

결론부 파라미터는 성능 평가지수 PI를 최소화하여 결정할 수 있다. PI는 시스템의 출력 데이터와 교사신호(teaching signal)간의 차이를 의미한다. 본 논문에서는 H_{∞} 최적화 방식에 의한 PSS의 입출력 데이터 쌍을 교사신호로서 선정하였다[9].

4.2 ANFP의 학습

종래의 퍼지 전 보상기에서 퍼지규칙 및 소속함수와 같은 파라미터는 시스템에 익숙한 전문가에 의해서 선정되었다[20,21]. 그러나 ANFP는 전문가의 이용이 필요없이 소속함수 파라미터의 초기값은 전영역에서 동일하게 설정되고, 퍼지규칙의 모든 후건부 파라미터는 영으로 설정된다. 여기서 ANFP는 영의 출력으로부터 시작해서 학습과정동안 목표 제어기에 가까워지도록 점차적으로 학습하게 된다.

5장에서 제시된 연구들에서 ANFP는 목표 제어기로서 H_{∞} 최적화 방식에 의한 H_{∞} PSS에 의해 학습된다. 그 학습은 발전 유니트에 대한 폭넓은 범위의 조건상에서 수행된다. 즉, 0.8[p.u.]로부터 1.2[p.u.]까지 범위의 발전기 유효전력 출력과 0.1[p.u.]로부터 0.4 [p.u.]까지 범위의 무효전력 출력을 학습범위로 선정하였다. 또한 가능한 외란의 폭넓은 범위가 학습되어지는데 -0.1[p.u.]로부터 0.1[p.u.]까지 범위의 기준전압과 -0.2[p.u.]로부터 0.2[p.u.]까지 범위의 조속기 입력 토오크 변화도 아울러 학습하도록 하였다. ANFP의 학습을 위해 사용된 입출력 데이터 쌍은 총 10,200개가 사용되었다.

각 입력변수에 대한 소속함수의 수는 학습데이터의 복잡성과 시행착오에 의해 결정된다. 그것은 ANN의 은닉층에서의 뉴런수를 선택하는 것과 유사하다. 너무 많은 뉴런은 컴퓨터의 메모리를 소모하게 되고, 또 너무 적은 뉴런을 사용한다면 적당한 제어 효과를 나타내지 못할 것이다. 본 논문에서는 경험에 바탕을 둔 각 입력변수에 대한 3개의 언어적 변수가 목적하는 제어성능을 가지도록 사용되었다. ANFP의 100회 학습후에 얻어진 e 와 Δe 의 조건부 파라미터는 표 2와 같다. 마찬가지로 결론부 파라미터는 표 3과 같다. 이득 파라미터는 입출력 공간을 기준으로 선택되어지는데 e 의 이득은 300, Δe 의 이득은 70 그리고 y_r' 의 이득은 0.1이다.

전력계통의 안정도 향상을 위한 적응 뉴로-퍼지 전 보상기 설계

표 2. 동조된 조건부 파라미터
Table 2. Tuned antecedent parameters

	e		
	a	b	c
Negative	0.5329	2.0000	-0.7716
Zero	0.3319	1.9320	0.0380
Positive	0.5176	2.0730	0.5566

Δe		
a	b	c
0.5007	2.0270	-1.5080
0.5763	2.0710	-0.0193
0.5963	2.0130	1.4540

표 3. 동조된 결론부 파라미터
Table 3. Tuned consequent parameters

	α	β	γ
MF 1	7.1830	4.2310	8.0690
MF 2	0.5753	1.1070	0.2345
MF 3	5.0070	-2.5390	6.2480
MF 4	4.6000	8.7860	13.2400
MF 5	2.2290	1.5410	-0.0560
MF 6	5.3430	-2.7800	5.9630
MF 7	28.2400	-23.6900	-36.0300
MF 8	0.4632	1.1530	-0.0334
MF 9	13.3400	6.1910	-13.6000

5. 시뮬레이션 결과 및 고찰

ANFP는 H_{∞} 최적화 방식에 의한 PSS의 입출력 인 각속도 편차와 그 변화율, 그리고 제어입력을 하이브리드 학습 알고리즘에 의해 학습시켜 설계하였다. 많은 사례연구들이 제안된 안정화 장치의 효과를 조사하기 위해 수행되었고, 그 결과들은 종래의 보상기 설계이론에 의한 PSS[10]와 ANFP PSS를 비교하여 동특성을 검토하였다.

5.1 종래의 PSS 파라미터 동조

유효전력 $P_{e0}=1.0$ [p.u.]와 무효전력 $Q_{e0}=0.2$ [p.u.]의 정상부하시 ΔV_{ref} 이 1초에서 0.1[p.u.]로 변한 경우로 운용조건을 설정한다. 또 5초에서 ΔV_{ref} 은 다시 제거

되고, 시스템은 이전 동작점으로 되돌아가게 된다. 이러한 조건상에서 보상기 설계이론에 의한 식 (22)와 같은 종래의 PSS는 우수한 응답특성을 나타내도록 동조되어진다. 그 결과, 오버슈터와 정정시간이 PSS의 최적 파라미터에 의해 최소화되어지도록 하는 $K_c=4.136$, $T=10.0$, $T_1=0.603$, $T_2=0.1$, $T_3=0.603$, $T_4=0.1$ 을 얻을 수 있었다. 이 파라미터는 5.2절의 실험에서도 변화시키지 않고 그대로 사용하였다.

$$PSS(s) = K_c \frac{sT}{1+sT} \frac{1+sT_1}{1+sT_2} \frac{1+sT_3}{1+sT_4} \quad (22)$$

여기서, K_c 는 PSS의 이득, T 는 washout 시정수, $T_1 \sim T_4$ 는 PSS의 파라미터를 결정하는 시정수이다.

정상부하시 종래의 PSS와 제안된 ANFP PSS에 대한 동특성 응답은 그림 5와 같다. 발전기 회전자각 편차 $\Delta\delta$ 의 응답특성에서 제안된 PSS가 저주파 진동을 매우 빨리 감쇠시킴을 볼 수 있다.




그림 5. 정상부하시 기준전압이 0.1 [p.u.]로 증가한 응답과 초기상태로 복귀한 경우의 응답 ($P_{e0}=1.0$ [p.u.], $Q_{e0}=0.2$ [p.u.], $\Delta V_{ref}=0.1$ [p.u.])

Fig. 5. Response to a 0.1 [p.u.] step increase in reference voltage and return to initial conditions in normal load ($P_{e0}=1.0$ [p.u.], $Q_{e0}=0.2$ [p.u.], $\Delta V_{ref}=0.1$ [p.u.])

5.2 중부하시, 무효전력 변화시 및 조속기 입력 토크를 변화시킨 경우

부하조건 변화로 유효전력이 $P_{e0}=1.0$ [p.u.]에서 $P_{e0}=1.2$ [p.u.]로 20% 증가한 중부하시 그리고 무효전력이 $Q_{e0}=0.2$ [p.u.]에서 $Q_{e0}=0.4$ [p.u.]로 증가시에 있어 ΔV_{ref} 의 초기치를 0.1[p.u.] 변화시킨 경우로 시스

템 운용조건을 설정하였다. 또한, ΔT_m 의 초기치를 0.1 [p.u.]로 변화시킨 경우도 고찰하였고 각 운전점에서 선형화된 모형을 이용하여 종래의 PSS와 ANFP PSS를 비교하여 동특성을 검토하였다. 각 시스템 조건에 의한 동특성은 응답은 그림 6, 7과 8에 나타내었다. 발전기 회전자각 편차 $\Delta\delta$ 의 응답 특성




그림 6. 중부하시 기준전압이 0.1 [p.u.]로 증가한 응답과 초기상태로 복귀한 경우의 응답 ($P_{e0}=1.2$ [p.u.], $Q_{e0}=0.2$ [p.u.], $\Delta V_{ref}=0.1$ [p.u.])

Fig. 6. Response to a 0.1 [p.u.] step increase in reference voltage and return to initial conditions in heavy load ($P_{e0}=1.2$ [p.u.], $Q_{e0}=0.2$ [p.u.], $\Delta V_{ref}=0.1$ [p.u.])




그림 7. 무효전력 변화시 기준전압이 0.1 [p.u.]로 증가한 응답과 초기상태로 복귀한 경우의 응답 ($P_{e0}=1.0$ [p.u.], $Q_{e0}=0.4$ [p.u.], $\Delta V_{ref}=0.1$ [p.u.])

Fig. 7. Response to a 0.1 [p.u.] step increase in reference voltage and return to initial conditions in change of reactive power ($P_{e0}=1.0$ [p.u.], $Q_{e0}=0.4$ [p.u.], $\Delta V_{ref}=0.1$ [p.u.])

에서 제안한 ANFP PSS가 종래의 PSS보다 성능이 우수한 동특성을 보이고 있다. 따라서 제안된 제어 장치는 폭넓은 범위상에서도 전력계통 안정화에 매우 효과적임을 알 수 있었다.




그림 8. 정상부하시 토오크가 0.1 [p.u.]로 증가한 응답과 초기상태로 복귀한 경우의 응답 ($P_{e0}=1.0$ [p.u.], $Q_{e0}=0.2$ [p.u.], $\Delta T_m=0.1$ [p.u.])

Fig. 8. Response to a 0.1 [p.u.] step increase in torque and return to initial conditions in normal load ($P_{e0}=1.0$ [p.u.], $Q_{e0}=0.2$ [p.u.], $\Delta T_m=0.1$ [p.u.])

6. 결 론

본 논문에서는 종래의 만족스럽게 설계된 PSS를 보상하기 위해 적응 뉴로 퍼지를 이용하는 새로운 설계방식과 이를 전력계통에 적용하는 문제를 다루었다. 전력계통 안정도 향상을 위한 ANFP PSS 설계의 주요 연구결과를 요약하면 다음과 같다.

첫째, ANN과 FLC의 장점인 구조적인 간소함, 적응성, 신속성 및 강인성을 이용하였다.

둘째, 퍼지 전 보상기의 설계과정에서 발생하는 최적의 제어규칙 선정과 정상상태의 오차를 최소화시키기 위해 하이브리드 학습 알고리즘에 의해 조건부 및 결론부 파라미터를 자동으로 동조하였다. 또한 전 보상형 제어기법이 현재 전력계통에 사용중인 PSS에 간단히 설치될 수 있는 제어구조를 가지고 있음을 보였다.

셋째, 비선형 특성을 가지는 전력계통의 안정화 성능을 검증하기 위하여 여러 가지 사례연구에서의 선형화 모형을 구축하였고, 종래의 보상기 설계이론에 의한 PSS와 ANFP PSS의 성능을 비교, 고찰하

였다. 정상부하시, 중부하시, 무효전력 변화시 및 토 오크 변화시의 사례연구를 통하여 제안된 제어 장치는 전력계통 안정화에 효과적임을 알 수 있었고, 또한 강인성을 검증하였다.

향후 본 논문의 기본기법을 바탕으로 비선형 시뮬레이션을 통해 전 보상기의 장점인, 선형 제어기에서 해결하지 못하는 비선형 성분을 만족스럽게 보상해주는 연구를 수행하여 인공지능형 보상기 연구의 우수성을 확인할 것이다. 아울러 신경회로망의 단점중 하나인 학습데이터 선정의 문제가 필요없이 단지 평가함수만으로 오차를 최소화시키며 최적화에 강인한 성능을 보이는 유전알고리즘을 이용한 연구도 수행할 계획이다.

본 연구는 한국전력공사의 지원에 의하여 기초전력공학공동연구소 주관으로 수행되었음. (과제관리번호 : 제 00-019 호)

참 고 문 헌

- [1] K. Bollinger, "Power System Stabilizer-Design using Root-Locus Method", IEEE Trans. on PAS, Vol. 94, No. 5, pp. 1484-1488, 1975.
- [2] R. J. Fleming, M. A. Mohan and K. Parvatisam, "Selection of Parameters of Stabilizers in Multimachine Power System", IEEE Trans. on PAS, Vol. 100, No. 5, pp. 2329-2333, 1981.
- [3] C. J. We and Y. Y. Hsu, "Design of Self-Tuning PID Power System Stabilizer of Multimachine Power System", IEEE Trans. on PWRS, Vol. 3, No. 3, 1988.
- [4] P. Kundur, M. Klein, G. J. Rogers and M. S. Zywno, "Application of Power System Stabilizers for Enhancement of Overall System Stability", IEEE Trans. on Power System, Vol. 4, No. 2, 1989.
- [5] T. Hiyama and T. Sameshima, "Fuzzy Logic Control Scheme for On-line Stabilization of Multi-machine Power System", Fuzzy Sets and Systems, Vol. 39, pp. 181-194, 1991.
- [6] M. A. M. Hassan, O. P. Malik and G. S. Hope, "A Fuzzy Logic based Stabilizer for a Synchronous Machine", IEEE Trans. on Energy Conversion, Vol. 6, No. 3, pp. 407-413, 1991.
- [7] Y. Zhang, G. P. Chen, O. P. Malik and G. S. Hope, "An Artificial Neural Network based Adaptive Power System Stabilizer", IEEE Trans. on Energy Conversion, Vol. 8, No. 1, pp. 71-77, 1993.
- [8] Y. Zhang, O. P. Malik, G. S. Hope and G. P. Chen, "Application of an Inverse Input-output Mapped ANN as a Power System Stabilizer", IEEE Trans. on Energy Conversion, Vol. 9, No. 3, pp. 433-441, 1994.
- [9] T. C. Yang, "Applying H_∞ Optimisation Method to Power System Stabiliser Design", Electrical Power & Energy Systems, Vol. 19, No. 1, pp. 29-35, 1997.

- [10] Y. N. Yu, "Electric Power System Dynamics", Academic Press, 1983.
- [11] A. J. Wood, B. F. Wollenberg, "Power Generation, Operation, and Control", John Wiley & Sons, 1984.
- [12] Kundur, "Power System Stability and Control", McGraw-Hill, Inc., pp. 581-626, 1993.
- [13] K. R. Padiyar, "Power System Dynamics, Stability and Control", John Wiley & Sons Pte Ltd, 1996.
- [14] 정형환, 왕용필, 정동필, 정문규, "유전 알고리즘을 이용한 전력시스템 안정화 장치의 최적 파라미터 선정", 전기학회논문지, 제48권, 제6호, pp. 683-691, 1999.
- [15] 정형환, 이준탁, 이정필, 한길만, "유전알고리즘을 이용한 전력계통 안정화 장치의 강인한 H_∞ 최적 튜닝", 전기학회논문지, 제49권, 제3호, pp. 85-94, 2000.
- [16] J.-S. R. Jang, "ANFIS : Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. Syst. Cyber., Vol. 23, No. 3, pp. 665-685, 1993.
- [17] J.-S. R. Jang and C.-T. Sun, "Neuro-Fuzzy Modeling and Control", IEEE Proceedings, Vol. 83, No. 3, pp. 378-406, 1995.
- [18] N. Gulley and J.-S. R. Jang, "Fuzzy Logic Toolbox for Use with MATLAB", The MathWorks, Inc., 1995.
- [19] 오성권, 박병준, 박춘성, "적응 퍼지-뉴럴 네트워크를 이용한 비선형 공정의 온-라인 모델링", 전기학회논문지, 제48권, 제10호, pp. 1293-1302, 1999.
- [20] J. H. Kim, K. C. Kim and E. K. P. Chong, "Fuzzy Precompensated PID Controllers", IEEE Trans. on Control Systems, vol. 2, no. 4, pp. 406-411, 1994.
- [21] S. W. Lee, M. J. Jeong and B. I. Jang, "Fuzzy Precompensated PI Controller for a Variable Capacity Heat Pump", IEEE Proceedings, 1998.
- [22] 정형환, 왕용필, 이정필, 정문규, "유전 알고리즘을 이용한 전력계통의 부하주파수 제어를 위한 퍼지 전 보상 PID 제어기 설계", 전기학회논문지, 제49권, 제2호, pp. 62-69, 2000.

◇ 저자소개 ◇

정 형 환 (鄭亨煥)

1941년 1월 19일생. 1964년 연세대 공대 전기공학과 졸업. 1984년 동 대학원 전기공학과 졸업(박사). 현재 동아대 공대 전기전자컴퓨터공학부 교수.

정 문 규 (鄭文圭)

1971년 11월 16일생. 1998년 동아대 공대 전기공학과 졸업. 2000년 동 대학원 전기공학과 졸업(석사). 현재 동 대학원 전기공학과 박사과정.

이 정 필 (李丁必)

1971년 8월 19일생. 1997년 동아대 공대 전기공학과 졸업. 1999년 동 대학원 전기공학과 졸업(석사). 현재 동 대학원 전기공학과 박사과정.

이 준 탁 (李浚柝)

1956년 11월 21일생. 1979년 동아대 공대 전기공학과 졸업. 1981년 동 대학원 전기공학과 졸업(석사). 1988년 중앙대 대학원 전기공학과 졸업(박사). 현재 동아대 공대 전기전자컴퓨터공학부 교수.