

Taylor 모델을 이용한 역동역학 뉴로제어기의 설계와 전력계통 안정화장치에 적용

김 문 찬* · 부 창 진** · 김 호 찬**

Taylor Model Based Inverse Dynamic Neuro Controller Design and Its Application to Power System Stabilization

Moon-Chan Kim* · Chang-Jin Boo** · Ho-Chan Kim**

ABSTRACT

This paper presents an implementation of power system stabilizer using inverse dynamic neuro controller. Traditionally, multilayer neural network is used for a universal approximator and applied to a system as a neuro-controller. In this case, at least two neural networks are used and continuous tuning of neuro-controller is required. Moreover, training of neural network is required considering all possible disturbances, which is impractical in real situation. In this paper, Taylor Model Based Inverse Dynamic Neuro Model (TMBIDNM) is introduced to avoid this problem. Inverse Dynamic Neuro Controller(IDNC) consists of TMBIDNM and Error Reduction Neuro Model(ERNM). Once the TMBIDNM is trained, it does not require retuning for cases with other types of disturbances. The controller is tested for one machine and infinite-bus power system for various operating conditions.

Key Words : Taylor model, Intelligent control, Power system stabilizer, Inverse dynamic neuro controller

1. 서 론

전력계통 제어의 주목적은 모든 소비자에게 전기를

공급하는데 있어 부하 변동에 관계없이 안정된 주파수와 전압을 제공하기 위함이다. 소비자들은 전력계통이 광범위한 라인, 케이블 그리고 변압기 네트워크로 구성되어 있고 전력은 먼 거리에 있는 발전소에서 공급된다는 사실에도 불구하고 믿을 수 있고 안전한 전기 에너지 공급을 기대한다. 전통적으로, 대부분 제어기들은 계통과 그 계통의 선형화 된 모델의 수학적 기술에 바탕을 두고 설계된다. 따라서 수학적 모델에 바탕을 둔 제어기들을 실제의 시스템, 특히 전력계통과 같은 복잡하고 비선형 시스템에 적용하기는

* 제주대학교 산업대학원 전자전기공학과
Department of Electronic & Electrical Eng., Graduate School of Industry, Cheju Nat'l Univ.

** 제주대학교 전기전자공학부, 첨단기술연구소
Faculty of Electrical & Electronic Eng., Cheju Nat'l Univ., Res. Inst. of Adv. Tech.

어렵다.

전력 플랜트의 특성은 조절기와 여자 시스템에 입력 변화에 의한 동작 조건의 조정, 그리고 전송선에서의 단락 등과 같은 조건 변화에 따라 다양하지만, 출력은 전력계통 동작에 필수조건을 만족해야만 한다. 전력 플랜트 제어의 궁극적 목표는 플랜트동작이 광대역임에도 불구하고 전력계통의 안정한 동작이다. 전력계통 안정화 장치(power system stabilizer, PSS)의 대부분은 deMello와 Concordia의 선구적인 연구에 기반을 두고 있는데[1,2], 그들은 선형화된 모델을 사용하여 고정된 구조의 PSS를 구하였다. 그리고 선형 최적제어와 현대제어 이론들을 적용하여 전력계통 모델에서 불확실성 아래 전력계통의 동적 성능을 개선하는 결과도 발표되었다[3-5]. 그러나 이러한 방법들은 모델의 정확성을 요구하는데, 전력 시스템의 규모가 점점 더 커져 가는 상황에서는 적용하기가 쉽지 않게 된다. 적응기법들을 사용하여 광역적인 동작점에서 PSS 설계하는 방법도 제안되었지만[5-13], 실제 응용에서 적응기법들은 매 샘플링 주기에서 거대한 계산량을 필요로 하는 단점을 가지고 있다.

최근에, 전력계통 분야에서 인공신경망(artificial neural networks, ANN)을 활용한 제어 시스템 설계에 관한 논문들이 발표되었다[14,16]. Park 등[14]이 제안된 역동역학 신경망(inverse dynamic neural network, IDNN)은 3개의 IDNN으로 구성되는 오차 감소망을 필요로 하고, Zhang 등[15]이 제안한 방법은 모든 가능한 조건에서 신경망 학습을 전제로 한다. Paggio와 Girossi는 ANN의 학습은 입력공간과 출력공간 사이의 조합 메모리를 종합화하는 것과 같다는 것을 밝혔다[17]. Nguyen과 Widrow는 비선형성이 많이 존재하는 시스템을 제어하는데 신경망이 쓰일 수 있다는 것을 보였다[18]. Iiguni와 Sakai는 제어 시스템에서 비선형성이 존재하는 것에 대해서 전통적인 LQ 제어기로 보상하는 것에 대해 보조 제어기로서 ANN을 사용했다. Hsu와 Chen[20]은 실시간 자기-튜닝 알고리즘을 제안했는데, 그들은 ANN을 사용해 전통적인 PI 형태의 PSS 매개변수들을 구하였다. 그러나, 이 방법은 정확한 수학적 모델을 요구하므로 대규모의 전력계통에 적용하기에는 한계가 있다. Wu 등[21]은 계층적인 구조를 가진 뉴로-PSS

를 제안하였는데, 이 뉴로-PSS는 두 개의 하위 망으로 구성되는데 하나는 입·출력 매핑을 위한 것이고, 다른 하나는 제어를 위한 것이다. Kennedy와 Quintana[22]는 ANN을 사용하는 역 제어기를 제안하였는데, 역동역학 관계는 상태 공간에서 주어지고 ANN에 의해 훈련되어 진다.

일반적으로 뉴로제어기의 입력은 제어대상 플랜트의 전 상태(full state) 벡터로 주어지는데 현실적으로 만족하기가 쉽지 않다. Zhang 등은 역 입-출력을 매핑한 PSS를 제안하였다[15]. 제시한 역 제어기는 다양하게 적용할 수 있으나, 플랜트가 비최소위상인 경우에는 큰 제어 입력에 대한 보호계획을 필요로 한다.

대부분의 제안된 뉴로 제어기 방법들은 시스템 식별과 제어기 구성을 위해 2개의 ANN을 사용한다. ANN 식별기는 먼저 입-출력 데이터를 이용하여 학습되고 난 후, ANN 제어기 학습에서 사용된다. 제어기의 학습은 목적함수를 최소화함에 의해 수행된다. 그러나 두개의 신경망 학습을 필요로 하는 방법은 뉴로 제어기 학습의 완료 후, 부가적인 뉴로-제어기의 학습이 필요하기 때문에 제어 성능을 변화시키기 어렵다.

본 논문에서는 제어대상 시스템의 역 입-출력 관계는 Taylor 모델[23,24]을 이용한 역동역학 뉴로모델(TMBIDNM)에 의해 표시되고 TMBIDNM의 학습 절차는 Levenberg-Marquardt 방법[25]을 사용하는 데, TMBIDNM의 원하는 출력은 시스템 출력이 아니라 제어입력이다. 학습 후에, TMBIDNM은 역동역학 제어기로써 사용되고 부가적인 제어기의 학습은 필요가 없다. 그리고 오차감소 뉴로모델(ERNM)은 TMBIDNM의 모델링 오차를 최소화하도록 사용된다.

II. Taylor 모델을 이용한 역동역학 뉴로제어기의 설계

본 논문에서는 Taylor 모델을 이용한 역동역학 뉴로제어기(TMBIDNC)를 새로운 형태의 전력계통 안정화 장치로 제안하는데 Taylor 모델을 이용한 역동역학 뉴로모델(TMBIDNM)과 오차감소 뉴로모델(EPNM)을 사용하여 PSS를 구성할 수 있다.

TMBIDNM은 시스템의 성능을 향상시키고 추종오차를 줄이는 피드포워드 제어기 역할을 하고, ERNM은 안정성을 만족하도록 하는 피드백 제어기로 동작하도록 한다.

2.1. Taylor 모델을 이용한 역동역학 뉴로모델

다음과 같은 단일입출력 비선형 시분변 이산시간 시스템을 고려하자.

$$y(k+1) = f(y(k), y(k-1), \dots, y(k-N), u(k), u(k-1), \dots, u(k-M)) \quad (1)$$

여기서 $y(k-i)$ 와 $u(k-j)$, $i=0, 1, \dots, N$, $j=0, 1, \dots, M$ 는 각각 지연된 입력과 출력 신호들을 나타낸다. 식 (1)에서 나타난 지연된 신호들을 다음과 같은 후진 차분 연산자 (backward difference operator)를 사용하여 나타내면 다음과 같다.

$$\begin{aligned} \Delta^n f(k) &= \Delta^{n-1} f(k) - \Delta^{n-1} f(k-1), n \geq 1 \\ \Delta^0 f(k) &= f(k) \end{aligned} \quad (2)$$

식 (2)의 차분 연산자를 이용하여 이산시간 시스템 (1)을 다시 나타내면 다음과 같다.

$$y(k+1) = f(y(k), \Delta y(k), \dots, \Delta^N y(k), u(k), u(k-1), \Delta u(k-1), \dots, \Delta^M u(k-1)) \quad (3)$$

식 (3)을 1차 Taylor 급수로 확장하여 나타내면 다음과 같다.

$$\begin{aligned} y(k+1) &= f(y(k), \Delta y(k), \dots, \Delta^N y(k), u(k), \\ &u(k-1), \Delta u(k-1), \dots, \Delta^M u(k-1)) \\ &= y(k) + \sum_{i=1}^N a_i \Delta^i y(k) + b_0 \Delta u(k) \\ &+ \sum_{i=1}^M b_i \Delta^i u(k-1) + O(k) \end{aligned} \quad (4)$$

여기서 $a_i = \frac{\partial f}{\partial \Delta^i y(k-1)}$, $b_0 = \frac{\partial f}{\partial u(k-1)}$, $b_i = \frac{\partial f}{\partial \Delta^i u(k-2)}$ 이고 $O(k)$ 는 고차항을 나타낸다. 식 (4)에서 $y(k)$ 를 좌변으로 이동하면, 위 식은 다음과 같이 표현된다.

$$\begin{aligned} \Delta y(k+1) &= \sum_{i=1}^N a_i \Delta^i y(k) + b_0 \Delta u(k) \\ &+ \sum_{i=1}^M b_i \Delta^i u(k-1) + O(k) \end{aligned}$$

여기서 고차항 $O(k)$ 을 무시하면, Taylor 모델은 다음과 같이 정의할 수 있다.

$$\begin{aligned} \Delta \hat{y}(k+1) &= \sum_{i=1}^N a_i \Delta^i \hat{y}(k) + b_0 \Delta u(k) \\ &+ \sum_{i=1}^M b_i \Delta^i u(k-1) \end{aligned} \quad (5a)$$

또는 Δ 으로 양변을 나누면

$$\begin{aligned} \hat{y}(k+1) &= \sum_{i=1}^N a_i \Delta^{i-1} \hat{y}(k) + b_0 u(k) \\ &+ \sum_{i=1}^M b_i \Delta^{i-1} u(k-1) \end{aligned} \quad (5b)$$

이다. 여기서 N 과 M 은 각각 입력과 출력을 위한 프리모델의 차수이다. 프리모델은 위의 두 가지 형태로 공식화할 수 있다.

일반적으로, 역동역학 뉴로모델 (IDNM)은 신경망으로 나타낼 수 있는데, Fig. 1은 IDNM의 학습모드를 나타내며, 여기서 Δ 는 식 (2)에서 차분 연산자의 벡터로서 정의된 것을 의미하며, 초기의 플랜트가 안정하지 않을 수 있기 때문에 페루프 식별 과정이 필요하다. 식 (3)를 참조하면 TMBIDNM을 적용하기 위해서는 제어입력을 다음과 같이 표현하도록 한다.

$$u(k) = g(y(k+1), y(k), \Delta y(k), \dots, \Delta^N y(k), u(k-1), \Delta u(k-1), \dots, \Delta^M u(k-1)) \quad (6)$$

일반적으로 제어의 목적이 주어진 기준입력을 잘 추종하도록 하는 것이므로 식 (6)에서 출력 $y(k+1)$ 를 기준입력 $y_c(k+1)$ 로 대체하고 제어기를 설계한다. 페루프 시스템식별은 학습 모드에서 사용한 입력과 출력 데이터를 수집하는데 적용된다. Fig. 2는 추가의 신호 $\hat{E}(k)$ 가 모델링 오차를 보상하기 위해 적용되어 지는 곳에 IDNM이 제어기로서 적용되어지는 방법을 보여준다.




Fig. 1. Training mode of IDNM




Fig. 2. Control mode of IDNM

IDNM의 학습에서, Fig. 3은 IDNM의 구조를 보여 주는데, 활성화 함수 f_i 는 \tanh 이고 F_0 는 1이다. 제어기 설계에서 주목적은 간단한 방법으로 시스템을 제어하는 것이다.




Fig. 3. The architecture of IDNM.

2.2. 오차감소 뉴로모델

제어기를 설계할 때 더 좋은 정확성을 위해서는 다양한 동작 조건과 외란을 고려하는 것이 필요하다. 하지만 실제 적용에서는 모든 동작 조건과 외란을 고

려하여 실행 할 수 없으므로 사전에 미리 주어진 데이터들에 대해 IDNM 학습이 완료되었다 할지라도 IDNM과 실제 에너지 사이에 오차는 불가피하게 존재한다.

IDNM이 단지 하나의 동작 조건에서 학습되었다고 가정하고 파라미터의 재조정 없이 어떤 다른 동작 조건에 적용된다면, Fig. 2에서 IDNM의 출력 $\hat{u}(k)$ 은 Fig. 1에서의 출력 $u(k)$ 과 더 이상 동일하지 않다. 즉 학습모드에서 $y_r(k+1)$ 과 $y(k+1)$ 이 항상 일치하지는 않으므로 Fig. 2의 IDNM의 출력 $\hat{u}(k)$ 은 다른 동작 조건에서의 올바른 값 $u(k)$ 로서 동일하지 않을 것이므로 시간 k 에서 모델링 에러 $E(k)$ 가 존재한다. 모델링 오차를 고려한 시스템 입력은 다음과 같다.

$$u(k) = \hat{u}(k) + \hat{E}(k) \quad (7)$$

여기서 $E(k-1)$ 는 모델링 오차 $E(k)$ 의 추정치이다. 오차는 다음과 같이 뉴턴 후진 차분 방정식(Newton backward difference formula, NBDF)을 사용해 이전의 오차를 추정할 수 있다.

$$\hat{E}(k) = \sum_{l=1}^l (-1)^l \binom{l}{l+1} \Delta^l E(k-1) \quad (8)$$

여기서

$$E(k-1) = u(k-1) - \hat{u}(k-1),$$

$$\Delta E(k-1) = E(k-1) - E(k-2)$$

이고 $E(k-1)$ 은 시간 $k-1$ 에서의 모델링 오차이다. Δ^l 은 식 (8)에서 정의한 후진 차분 연산자이고, l 은 추정순서이고 이항 계수 표시법은 다음과 같이 정의한다.

$$\binom{s}{k} = \frac{s(s-1)\cdots(s-k+1)}{k!}$$

Fig. 4는 IDNM과 NBDF를 사용한 오차감소 뉴로모델(ERNM)을 나타낸 것이다. Fig. 2에서 IDNM은 학습 후에 고정되고 피드포워드 제어기 같이 동작한다. 모델링 오차와 외란의 보상은 피드백 제어기같이 동작하는 ERNM에 의하여 보상된다.




Fig. 4. The Error Reduction Neuro Model

III. 컴퓨터 시뮬레이션

본 논문에서는 제안한 TMBIDNC의 타당성을 검증하기 위하여 선정된 계통전력은 일반적으로 많이 인용되고 있는 1기무한대모선(one machine infinite bus, OMIB) 계통에서의 전력계통 안정화 장치를 선정하였다(Appendix). 본 모델은 전형적인 비선형 시스템이며 외란이 존재하며 q 축 발전기 모델, 정적여자기(static excitation), 터빈과 거버너(governor) 모델로 구성된다.

제어기의 설계에서 주목적은 간단한 방법으로 시스템을 제어하는 것인데, 본 논문에서는 2차의 Taylor 모델을 사용한다고 가정하면 다음과 같이 주어지는 다섯 개의 입력은 TMBIDNM의 학습에서 쓰여진다.

$$y_r(k+1), y(k), \Delta y(k), u(k-1), \Delta u(k-1)$$

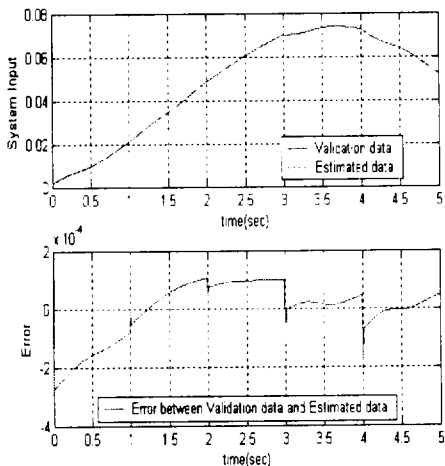


Fig. 5. TMBIDNM output and error(data n=500, order N=2).

Fig. 5는 일반적인 부하 조건하에서의 계통 출력과 Levenberg-Marquardt 방법에 의한 학습 후 TMBIDNM 출력의 차이를 보여준다. 샘플링 시간은 0.01[sec]이고 첫 번째 500개의 샘플을 사용하였는데 제안한 방법이 실제 계통출력을 거의 근사화시키는 것을 알 수 있었다. TMBIDNM이 실제 전력계통을 얼마나 정확하게 모델링 했는지를 살펴보기 위하여, 오차를 살펴보면 99%이상의 정확도를 나타냄을 알 수 있다.




Fig. 6. Outputs of the CPSS and TMBIDNC in the torque angle deviation.




Fig. 7. Outputs of the CPSS and TMBIDNC in the torque angle deviation and torque deviation.

또한 제안한 Taylor 모델을 이용한 역동역학 뉴로 제어기(TMBIDNC)를 두 가지 형태의 운전 조건이 변하여 외란으로 작용하는 경우를 시험하여 보았다. Fig. 6과 7은 제안한 TMBIDNC의 응답과 기존의

PSS(CPSS)의 응답을 나타내고 있다. Fig. 6는 초기 토오코각(torque angle) δ 이 0.7[p.u.]정도 증가하여 토크각 편차가 존재할 때 전력계통에 미치는 영향을 나타낸 결과이고, Fig. 7은 0초에서 7초 사이에서는 δ 이 0.5[p.u.]정도 증가하여 토크각 편차가 존재하는 경우고 그 후에는 토크 T_m 가 초기보다 20% 증가하여 외란으로 작용할 때 결과를 나타낸 것이다. 두 가지 경우 모두 제안한 TMBIDNC가 CPSS 보다 훨씬 우수한 성능을 보여주는 것을 알 수 있다.

IV. 결론

본 논문에서 새로운 형태의 역동역학 뉴로제어기(IDNC)가 제안하였다. 역동역학 뉴로모델(IDNM)은 Taylor 모델 개념을 사용해 유도했는데, 사용한 입출력 데이터들은 시스템이 초기에 불안한 과도상태 값을 나타낼 때 페루프에서 선택된다.

제안된 IDNM의 사용상에서 두 가지 장점이 있는데, 첫째는 학습된 인공신경망이 IDNM을 사용하므로 다른 외란들이 존재하는 경우에도 재학습을 할 필요가 없다는 것이고 둘째는 다양한 동작 조건에서 모델링오차를 감소시키는 오차감소 뉴로모델(ERNM)을 가지고 있다는 것이다. 기존의 IDNM 방법은 항상 잘 학습된 IDNM이 필요하지만 제안한 방법은 처음에 IDNM이 학습 모드에서 학습되어 주어지면 재학습 필요없이 제어 모드에서 계속 사용될 수 있다.

제안한 TMBIDNC는 1기 무한대 모선 전력계통에 적용하여 다양한 동작 조건에서 테스트되고 기존의 CPSS와도 비교하였는데, 모든 경우에 TMBIDNC는 CPSS보다 우수한 성능을 발휘하는 것을 알 수 있었다.

APPENDIX

One machine infinite bus(OMIB) power system³⁰⁾




Fig. A.1. One machine infinite bus power system.

Machine models(generator, turbine, governor and exciter):

$$\begin{aligned} \frac{d\delta_i}{dt} &= \omega_b(\omega_i - \omega_0) \\ M_i \frac{d\omega_i}{dt} &= (T_{Mi} - P_{ei} - D_i(\omega_i - \omega_0)) \\ T_{di} \frac{dE_{qi}}{dt} &= (E_{fdi} - E_{qi} - (X_{di} - X'_{di})I_{di}) \\ T_{Ai} \frac{dE_{fdi}}{dt} &= (K_{Ai}(V_{refi} - V_i + C_{pss}) - E_{fdi}) \\ T_{Ci} \frac{dT_{Mi}}{dt} &= (F_{hti} U_{gi} - T_{Mi} + T_{Mn}) \\ T_{gi} \frac{dU_{gi}}{dt} &= (K_{gi}(\omega_{refi} - \omega_i) - U_{gi}) \end{aligned}$$




Fig. A.2. Conventional power system stabilizer model.

Table A.1. The parameters of PSS

| T_1 | T_2 | T_w | K_{cs} |
|-------|-------|-------|----------|
| 0.685 | 0.1 | 3 | 7.091 |

Table A.2. The parameter of Generator, Turbine, and Governor(e_a Model)

| M | D | T_{do} | x_d |
|-------|--------|----------|----------|
| 9.26 | 0.01 | 7.76 | 0.937 |
| x_q | x'_d | T_c | F_{hp} |
| 0.55 | 0.19 | 0.1 | 1 |
| K_g | T_g | | |
| 10 | 0.1 | | |

| | | | |
|-------|-------|----------|----------|
| M | D | T_{do} | x_d |
| 9.26 | 0.01 | 7.76 | 0.937 |
| x_q | x_d | T_c | F_{hp} |
| 0.55 | 0.19 | 0.1 | 1 |
| K_g | T_g | | |
| 10 | 0.1 | | |

Table A.3. The operating points

| | | | |
|---|-----|-------------------------|------------------------------|
| P | Q | $V \angle \theta$ | $I \angle \theta$ |
| 1 | 0.2 | $1 \angle 29.602^\circ$ | $1.0198 \angle 18.292^\circ$ |

Table A.4. Transmission line data

| | |
|-------|-------|
| R_E | X_E |
| 0.03 | 0.5 |

Table A.5. Exciter data

| | |
|-------------|-------------|
| T_A (sec) | K_A (p.u) |
| 0.03 | 0.5 |

참고문헌

- 1) F.P. deMello and C.A. Concordia, "Concept of Synchronous Machine Stability as Affected by Excitation Control," IEEE Trans. on PAS, Vol. PAS-103, pp. 316-319, 1969.
- 2) F.P. deMello, P.J. Nolan, T.F. Laskowski, and J.M. Undrill, "Coordinate application of stabilizers in multimachine power system," IEEE Trans. on PAS, pp. 892-901, May/June 1980.
- 3) Doi, S. Abe, "Coordinated Synthesis of Power System Stabilizers in Multimachine Power Systems," IEEE Trans. on PAS, Vol 103, pp. 1473-1479, June 1984.
- 4) T.L. Hwang, T.Y. Hwang, and W.T. Yang, "Two-level Optimal Output Feedback Stabilizer Design," IEEE Trans. on PWRS, Vol. 6, No.3, pp. 1042-1047, August 1991.
- 5) M.R. Khaldi, A.K. Sarkar, K.Y. Lee, and Y.M. Park, "The Model Performance Measure for Parameter Optimization of Power System Stabilizers," IEEE Trans. on Energy Conversion, Vol. 8, No.4, pp. 660-666, December 1993.
- 6) K.T. Law, D.J. Hill, and N.R. Godfrey, "Robust Controller Structure for Coordinate Power System voltage Regulator and Stabilizer Design," IEEE Trans. on Control System Technology, Vol. 2, No. 3, pp. 220-232, September 1994.
- 7) A. Ghosh, G. Ledwich, O.P. Malik, and G.S. Hope, "Power System Stabilizer Based on Adaptive Control Techniques," IEEE Trans. on PAS, Vol. 103, pp. 1983-1989, August 1984.
- 8) S.J. Chang, Y.S. Chow, O.P. Malik, and G.S. Hope, "An Adaptive Synchronous Machine Stabilizer," IEEE Trans. on PWRS, Vol. 1, pp. 101-109, August 1986.
- 9) D.A. Pierre, "A Perspective on Adaptive Control of Power Systems," IEEE Trans. on PWRS, Vol. 2, pp. 387-396, May 1987.
- 10) W. Gu and K.E. Bollinger, "A Self-tuning Power System Stabilizer for Wide-range Synchronous Generator Operation," IEEE Trans. on PWRS, Vol. 4, No. 2, pp. 1191-1199, August 1989.
- 11) J.Y. Fan, T.H. Ortmeier, and R. Mukundan, "Power System Stability Improvement with Multivariable Self-tuning Control," IEEE Trans. on PWRS, Vol. 5, No. 5, pp. 227-234, February 1990.
- 12) A.A. Ghandakly and A.M. Farhoud, "A Parametrically Optimized Self-Tuning Regulator for Power System Stabilizer," IEEE Trans. on PWRS, Vol. 7, pp. 1245-1250, August 1992.
- 13) O.P. Malik and C. Mao, "An Adaptive Optimal Controller and Its Application to an Electric Generating Unit," International Journal of Elec-

- Mapped ANN as A Power System Stabilizer," IEEE Trans. on Energy Conversion, Vol. 9, No. 3, pp. 433 -441, September 1994.
- 16) Y.M. Park, M.S. Choi, and K.Y. Lee, "A Neural Network-Based Power System Stabilizer Using Power Flow Characteristics," IEEE Trans. on Energy Conversion, Vol. 11, No.2, pp. 435-441, June 1996.
 - 17) T. Poggio and F. Girosi, "Networks for Approximation and Learning," Proceeding of IEEE, pp. 1481-1497, September, 1990.
 - 18) D. Nguyen and B. Widrow, "The Truck Backer -Upper An Example of Self-Learning in Neural Networks," IEEE Control System Magazine, pp. 18-23, 1990.
 - 19) Y. Iiguni and H. Sakai, "A Nonlinear Regulator Design in the Presence of System Uncertainties Using Multilayered Neural Networks," IEEE Trans. on Neural Networks, Vol. 3, No.4, pp. 410- 417, July 1991.
 - 20) Y.Y. Hsu and C.R. Chen, "Tuning of Power System Stabilizers Using an ANN," IEEE Trans. on Energy Conversion, Vol. 6, pp. 612- 619, 1991.
 - 21) Q.H. Wu, B.W. Hogg, and G.W. Irwin, "A Neural Network Regulator for Turbogenerators," IEEE Trans. on Neural Networks, Vol. 3, No. 1, January 1992.
 - 22) D.C. Kennedy and V.H. Quintana, "Neural Network Regulators for Synchronous Machines," ACC, Vol. 5, pp. 131-136, 1993.
 - 23) K.Y. Lee, H.S. Ko, H.C. Kim, J.H. Lee, and Y.M. Park, "A free model based intelligent controller design and its applications to power system stabilization," IEEE Power Engineering Society Summer Meeting, Vol. 4, pp. 1985-1989, 2000.
 - 24) K.Y. Lee, H.S. Ko, H.C. Kim, J.H. Lee, and Y.M. Park, "A free model based power system stabilization," IEEE Power Engineering Society Winter Meeting, in proceeding, pp. 1191-1196, 2001.
 - 25) S. Haykin, Neural Networks: A Comprehensive Foundation, Prentice Hall, New Jersey, 1999.
 - 26) L. Ljung, System Identification: Theory for the user, Prentice-Hall, New Jersey, 1999.
 - 27) R.L. Burden and J.D. Faires, Numerical Analysis, PWS-KENT, 1989.
 - 28) P. Kunder, Power System Stability and Control, McGraw-Hill, New York, 1994.