

碩士學位論文

Taylor 모델을 이용한 역동역학 뉴로제어기의  
설계와 전력계통의 안정화에 적용



濟州大學校 産業大學院

電子電氣工學科

金 文 燦

2004

# Taylor 모델을 이용한 역동역학 뉴로제어기의 설계와 전력계통의 안정화에 적용

指導教授 金 豪 贊

이 論文을 工學碩士學位 論文으로 提出함.

2004年 6月 日

濟州大學校 産業大學院  
電子電氣工學科 電氣工學專攻



金文燦의 工學碩士學位 論文을 認准함.

2004年 6月 日

委員長 印

委 員 印

委 員 印

# 목 차

LIST OF FIGURES .....	ii
LIST OF TABLES .....	iii
SUMMARY .....	iv
I. 서 론 .....	1
II. Taylor 모델을 이용한 역동역학 뉴로제어기의 설계 .....	4
1. Taylor 모델을 이용한 역동역학 뉴로모델 .....	4
2. 오차감소 뉴로모델 .....	7
III. 전력계통 안정화 장치의 설계와 컴퓨터 시뮬레이션 .....	9
1. 전력계통 안정화 장치의 설계를 위한 동기발전기 모델의 선정 .....	9
2. 컴퓨터 시뮬레이션 .....	16
IV. 결 론 .....	19
참고문헌 .....	20

## LIST OF FIGURES

Fig. 1 Training mode of IDNM .....	6
Fig. 2 Control mode of IDNM .....	6
Fig. 3 The architecture of IDNM .....	7
Fig. 4 The error reduction neuro model .....	8
Fig. 5 One machine infinite bus power system .....	9
Fig. 6 Governor model .....	11
Fig. 7 Turbine model .....	11
Fig. 8 The block diagram of static exciter .....	14
Fig. 9 The block diagram of AVR .....	14
Fig. 10 Conventional power system stabilizer model .....	14
Fig. 11 Synchronous machine control scheme with PSS .....	15
Fig. 12 TMBIDNM output and error (data n=500, order N=2) .....	17
Fig. 13 Output of the CPSS and TMBIDNC in the torque angle deviation ...	18
Fig. 14 Output of the CPSS and TMBIDNC in the torque angle deviation and torque deviation .....	18

# LIST OF TABLES

Table 1 Transmission line data .....	10
Table 2 Parameter of generator .....	12
Table 3 Parameters of PSS .....	15
Table 4 Parameters of synchronous machine control scheme with PSS .....	16



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

Moon-Chan Kim

DEPARTMENT OF ELECTRONIC AND ELECTRICAL ENGINEERING  
GRADUATE SCHOOL OF INDUSTRY  
CHEJU NATIONAL UNIVERSITY

Supervised by professor Ho-Chan Kim



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 infinite-bus power system for various operating conditions.



# I. 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, 대부분의 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 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(deMello and Concordia, 1969), 그들은 선형화된 모델을 사용하여 고정된 구조의 PSS를 구하였다. 그리고 선형최적제어와 현대제어 이론들을 적용하여 전력계통 모델에서 불확실성 아래 전력계통의 동적 성능을 개선하는 결과도 발표되었다(Abe, 1984; Hwang et al. 1991) 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(Khaldi et al. 1993; Law et al. 1994; Ghosh et al. 1984), 실제 응용에서 적응기법들은 매 샘플링 주기에서 거대한 계산량을 필요로 하는 단점을 가지고 있다.

최근에, 전력계통 분야에서 인공신경망(artificial neural networks, ANN)을 활

용한 제어 시스템 설계에 관한 논문들이 발표되었다(Park et al. 1996; Zhang et al. 1994). Park 등 (Park et al. 1996)이 제안된 역동역학 신경망(inverse dynamic neural network, IDNN)은 3개의 IDNN으로 구성되는 오차감소망을 필요로 하고, Zhang 등(Zhang et al. 1994)이 제안한 방법은 모든 가능한 조건에서 신경망 학습을 전제로 한다. Poggio와 Girossi는 ANN의 학습은 입력공간과 출력공간 사이의 조합 메모리를 종합화하는 것과 같다는 것을 밝혔다(Poggio and Girossi, 1990). Nguyen과 Widrow는 비선형성이 많이 존재하는 시스템을 제어하는데 신경망이 쓰일 수 있다는 것을 보였다(Nguyen & Widrow, 1990). Iiguni와 Sakai는 제어 시스템에서 비선형성이 존재하는 것에 대해서 전통적인 LQ 제어기로 보상하는 것에 대해 보조 제어기로서 ANN을 사용했다(Iiguni & Sakai, 1991). Hsu와 Chen(Hsu & Chen, 1991)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(Wu et al. 1992)은 계층적인 구조를 가진 뉴로-PSS를 제안하였는데, 이 뉴로-PSS는 두 개의 하위 망으로 구성되는데 하나는 입·출력 매핑을 위한 것이고, 다른 하나는 제어를 위한 것이다. Kennedy와 Quintana(Kennedy and Quintana, 1993)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(Zhang et al. 1994). 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, 추가적인 뉴로-제어기의 학습이 필요하기 때문에 제어 성능을 변화시키기가 어렵다.

본 논문에서는 제어대상 시스템의 역 입-출력 관계는 Taylor 모델(Lee et al. 2000; Lee et al. 2001)을 이용한 역동역학 뉴로모델(TMBIDNM)에 의해 표시되고 TMBIDNM의 학습절차는 Levenberg-Marquardt 방법(Haykin, 1999)을 사용하는데, TMBIDNM의 원하는 출력은 시스템 출력이 아니라 제어입력이다. 학습 후에, TMBIDNM은 역동역학 제어기로써 사용되고 추가적인 제어기의 학습은 필요가 없다. 그리고 오차감소 뉴로모델(ERNM)은 TMBIDNM의 모델링 오차를 최소화하도록 사용된다.



## II. Taylor 모델을 이용한 역동역학 뉴로 제어기의 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 (ERNM)을 사용하여 PSS를 구성할 수 있다. TMBIDNM은 시스템의 성능을 향상시키고 추종오차를 줄이는 피드포워드 제어기 역할을 하고, ERNM은 안정성을 만족하도록 하는 피드백 제어기로 동작하도록 한다.

### 1. Taylor 모델을 이용한 역동역학 뉴로모델

다음과 같은 단일입출력 비선형 시불변 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 출력과 입력 신호들을 나타낸다. 식 (1)에서 나타난 지연된 신호들은 다음과 같은 후진 차분 연산자 (backward difference operator) (Phillips & Nagle, 1997; Ogata, 1995)를 사용하여 나타내면 다음과 같다.

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

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.

$$y(k+1) = y(k) + \sum_{i=1}^N a_i \Delta^i y(k) + b_0 \Delta u(k) + \sum_{i=1}^M b_i \Delta^i u(k-1) + O(k) \quad (4)$$

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, 위식은 다음과 같이 표현된다.

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

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

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

또는  $\Delta$ 로 양변을 나누면 다음과 같다.

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

여기서  $M$ 과  $N$ 은 각각 입력과 출력을 위한 Taylor 모델의 차수이다. Taylor 모델은 위의 두 가지 형태로 공식화할 수 있다.

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

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

일반적으로 제어의 목적이 주어진 기준입력을 잘 추종하도록 하는 것이므로 식 (6)에서 출력  $y(k)$ 를 기준입력  $y_r(k)$ 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.

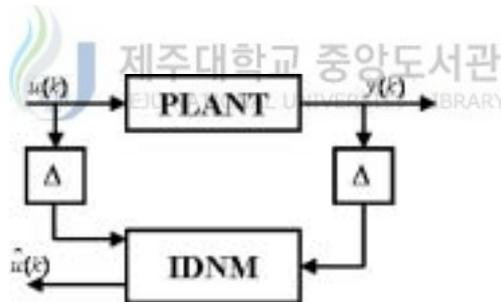


Fig. 1. Training mode of IDNM

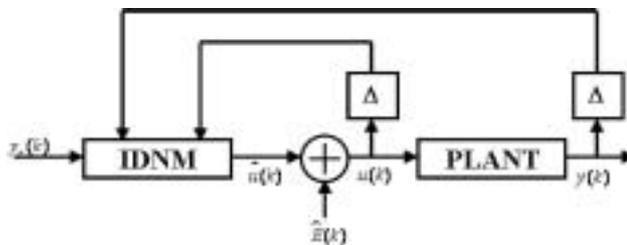


Fig. 2. Control mode of IDNM

IDNM의 학습에서, Fig. 3은 IDNM의 구조를 보여주는데, 활성화 함수  $f_j$ 는 tanh 이고  $F_0$ 는 1이다. 제이기 설계에서 주목적은 간단한 방법으로 시스템을 제어하는 것이다.

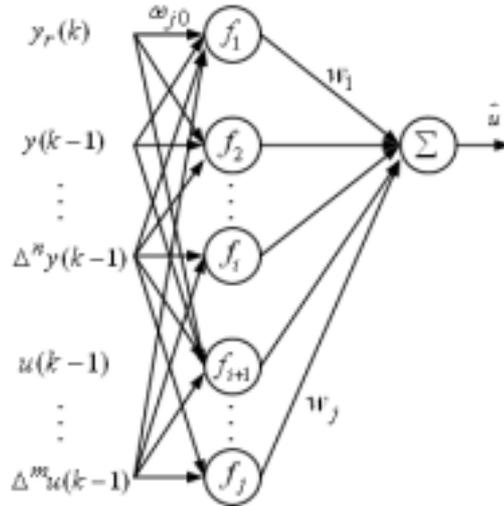


Fig. 3. The architecture of IDNM

## 2. 오차감소 뉴로모델



제어를 설계할 때 더 좋은 정확성을 위해서는 다양한 동작 조건과 외란을 고려하는 것이 필요하다. 하지만 실제 적용에서는 모든 동작 조건과 외란을 고려하여 실행 할 수 없으므로 사전에 미리 주어진 데이터들에 대해 IDNM 학습이 완료 되었다 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  $\hat{u}_r(k)$ 은 Fig. 1에서의 출력  $u(k)$ 과 더 이상 동일하지 않다. 즉 학습모드에서  $y_r(k)$ 과  $y(k)$ 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.

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

여기서  $\hat{E}(k)$  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.

$$\hat{E}(k) = \sum_{r=0}^l (-1)^r \binom{r}{l+1} \Delta^r E(k-1) \quad (8)$$

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.  $\Delta^r$  은 식 (8)에서 정의한 후진 차분 연산자이고,  $l$  은 추정순서이며 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.

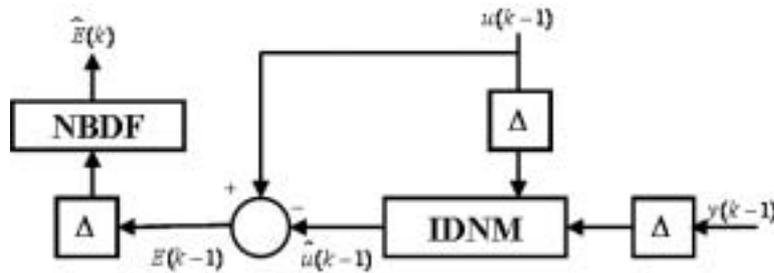


Fig. 4.. The Error Reduction Neuro Model

### Ⅲ. 전력계통 안정화 장치 설계와 컴퓨터 시뮬레이션

#### 1. 전력계통 안정화 장치의 설계를 위한 동기발전기 모델의 선정

본 논문에서는 제안한 Taylor 모델 제어를 이용한 전력계통 안정화 장치(FMBPSS)의 타당성을 검증하기 위하여 선정된 계통전력은 일반적으로 많이 이용되고 있는 1기-무한대모선 (one machine infinite bus, OMIB) 계통으로 비선형 시스템이며 외란이 존재하는 시스템이다. 먼저 계통에 대한 설명을 하기 위하여 대형 전력계통에 송전선로를 통하여 연결되어 동작하는 발전기를 살펴볼 때, 전체 전력계통의 규모가 발전시스템의 규모에 비하여 매우 크다고 가정하면 해당 발전시스템의 동작에 의해 전체 전력시스템이 거의 영향을 받지 않는다고 가정하여 Fig. 5와 같은 1기-무한대모선의 간략한 시스템으로 표현할 수 있다 (Kunder, 1994; Sauer and Pai, 1998).

Fig. 5와 같은 1기-무한대모선의 전력계통 모델은 전력계통 안정화 장치의 설계를 위해 널리 사용되어 온 모델로써 본 논문에서는 선로 정수들이 Table 1과 같이 주어져 있다고 가정한다.

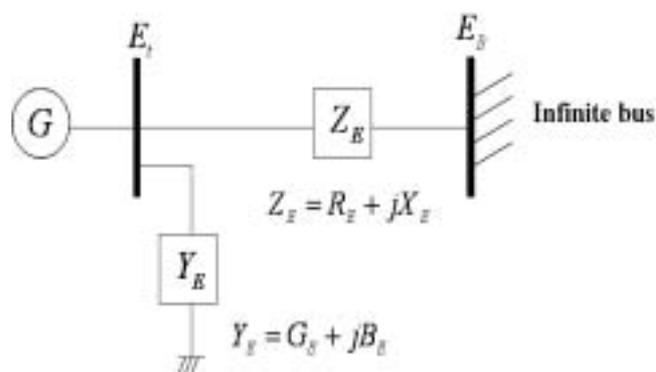


Fig. 5 One machine infinite bus power system

Table 1 Transmission line data

	Variable	Parameter
Impedance	$R_E$	0.03
	$X_E$	0.5
Admittance	$G_E$	0.249
	$B_E$	0.262

Fig. 5의 전력계통을 표현하는 수학적 모델은 그 사용목적에 따라 매우 다양하게 존재하는데 (Kunder, 1994), 본 논문에서는 일반적으로  $e'_q$  모델이라고 불리는 다음과 같은 비선형 3차모델을 선정하였다.

$$\dot{w} = \frac{1}{M} \{ T_m - T_e(\delta, e'_q) - T_D \} [pu/s] \quad (9)$$

$$\dot{\delta} = w_b(w - 1) [rad/s] \quad (10)$$



제주대학교 중앙도서관  
JEJU NATIONAL UNIVERSITY LIBRARY

$$\dot{e}'_q = \frac{1}{T_{do}'} \{ e_{fd} - (x_d - x'_d) i_d(\delta, e'_q) - e'_q \} \quad (11)$$

$$\dot{e}'_d = \frac{1}{T_{do}'} \{ e_{fd} - (x_d - x'_d) i_d(\delta, e'_q) - e'_d \} \quad (12)$$

식 (9)과 (10)은 발전소의 토크의 평형상태를 표현하는 동요방정식이고, 식 (11)는 발전기 회전자의 계자 전압의 동특성을 표현하는 식이다. 각 식에서 사용된 상태변수들,  $w, \delta, e'_q$  이 의미하는 바는 다음과 같다.  $w$ 는 발전기 회전자의 각속도를 의미하고  $\delta$ 는  $q$ 축과 무한대모선 사이의 토크각의 차이 [rad]를 나타내며  $e'_q$ 는 과도 리액턴스 배후전압의  $q$ 축 성분을 나타낸다. 그리고 위 식들에서 사용된 각종 상수들  $M, T_{do}', x_d, x'_d$ 의 의미와 본 논문에서 사용된 값들은 Table 2에 나타나 있

으며  $w_b$ 는 기준 각속도로 그 값은  $120\pi$  [rad/s]이다. 식 (9)에서  $T_m$ 은 기계적 토오크 입력이며 터어빈에서 공급된다. 하나의 발전시스템 내에는 식 (9)~(11) 이외에도 Fig. 6과 Fig. 7같이 주어지는 조속기와 터어빈 등은 다음과 같은 동특성을 만족한다.

$$\dot{T}_m = \frac{1}{T_c} (F_{hp}u_g - T_m) \quad (13)$$

$$\dot{u}_g = \frac{1}{T_g} [K_g(w_r - w) - u_g] \quad (14)$$

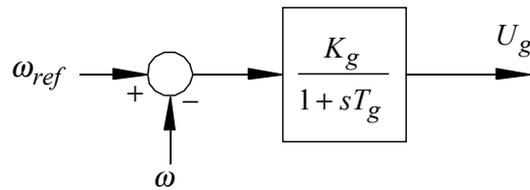


Fig. 6 Governor model

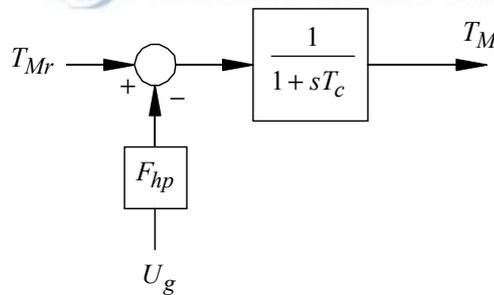


Fig. 7 Turbine model

식 (9)에서  $T_e$ 는 전기적 토오크 출력이며  $p.u.$  단위를 사용할 경우  $T_e = P_e/w$ 의 관계식이 성립하지만,  $w \approx 1$ 이라는 가정하에  $T_e = P_e$ 로 간략화 하였고  $P_e$ 의 값은 다음과 같이 결정된다.

$$T_e \approx P_e = v_d i_d + v_q i_q \quad (15)$$

여기서  $v_d, v_q, i_d, i_q$ 는 각각 단자전압  $v_t$  및 단자 전류의  $d$ 축 및  $q$ 축 성분을 나타내고, 이들을 식으로 나타내면 다음과 같다.

$$i_d = Y_d e_q - \frac{v_o}{Z_e^2} (R_2 \sin \delta + X_1 \cos \delta)$$

$$i_q = Y_q e_q - \frac{v_o}{Z_e^2} (-X_2 \sin \delta + R_1 \cos \delta)$$

$$v_d = x_q i_q$$

$$v_q = e_q' - x_d' i_d$$

$$v_t = \sqrt{v_d^2 + v_q^2}$$

위 식들에서 사용된 각종 상수들은 다음과 같이 정의된다.



$$1 + ZY = C_1 + jC_2$$

Table 2 Parameters of Generator

	Variable	Parameter
Moment constant	$M$	9.26
Damping coefficient	$D$	0.01
d-axis transient open-circuit time constant	$T_{do}'$	7.76
d-axis component of machine reactance	$x_d$	0.973
q-axis component of machine reactance	$x_q$	0.55
q-axis transient reactance	$x_d'$	0.19

$$\begin{aligned}
Z_e^2 &= R_1 R_2 + X_1 X_2 \\
Y_d &= (C_1 X_1 - C_2 R_2) / Z_e^2 \\
Y_q &= (C_1 R_1 + C_2 X_2) / Z_e^2 \\
R_1 &= R - C_2 x_d' \\
R_2 &= R - C_2 x_q \\
X_1 &= X + C_1 x_q \\
X_2 &= X + C_1 x_d'
\end{aligned}$$

그리고,  $Z$ 와  $Y$ 는 Fig. 5의  $Z_E$ 와  $Y_E$ 를 의미하며, 마찬가지로  $R$ 와  $X$ 는 각각  $R_E$ 와  $X_E$ ,  $G$ 와  $B$ 는 각각  $G_E$ 와  $B_E$ 를 나타낸다.

식 (9)에서  $T_D$ 는 감쇄토크를 나타내고 이는  $D(w-1)$  ( $D$ 는 감쇄상수)로 주어지며, 식 (11)에서 사용된  $e_{fd}$ 는 AVR 및 여자기의 출력인데, 앞에서 사용한 식 (9)~(11)는 거의 대부분의 동기발전기에 공통적으로 적용되는 식인데 반하여  $e_{fd}$ 의 동특성을 표현하는 식은 발전소에 설치된 AVR 및 여자기의 종류에 따라 각각 다른 형태의 식을 가지게 된다. 본 논문에서는 Fig. 8과 같이 표현되는 가장 간단한 형태의 사이리스터 (thyristor) 타입의 여자시스템인 IEEE type 1의 여자시스템 (IEEE Standard Board, 1990)을 사용한다고 가정하였다. Fig. 8에서는 여자시스템의 출력단에 제한기 (limiter)가 부착되어 있으며, 출력이 제한기의 범위안에 있는 경우에는 다음과 같은 동특성으로 표현된다. 식 (12)과 Fig. 8에서  $u_{pss}$ 는 전력계통 안정화 장치의 출력을 의미한다.

$$\dot{e}_{fd} = \frac{1}{T_e} \{ K_e (v_{ref} - v_t - u_{pss}) - e_{fd} \} \quad (16)$$

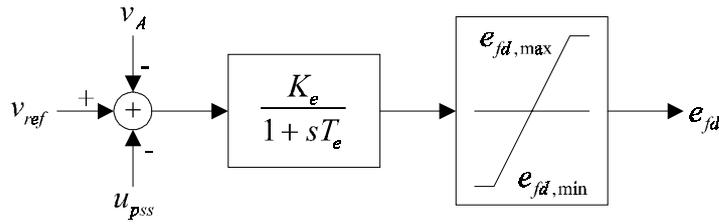


Fig. 8 The block diagram of static exciter

Fig. 9와 같은 형태의 AVR을 시뮬레이션에서 사용하였다.

$$u_A = \frac{1 + T_A s}{1 + T_B s} (v_r - v_t) \quad (17)$$

일반적으로 많이 사용되는 PSS는 Fig. 10과 같이 주어지는 진-지상 보상기 (lead-lag compensator)이고 사용된 매개변수들은 Table 3과 같다. Fig. 11은 시뮬레이션을 위하여 사용된 동기발전기의 제어시스템의 구조를 나타내고 사용된 각종 정수들은 Table 4에 주어진다.

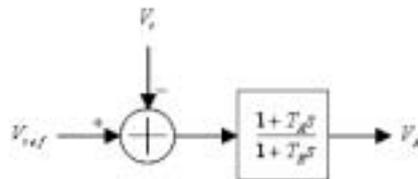


Fig. 9 The block diagram of AVR

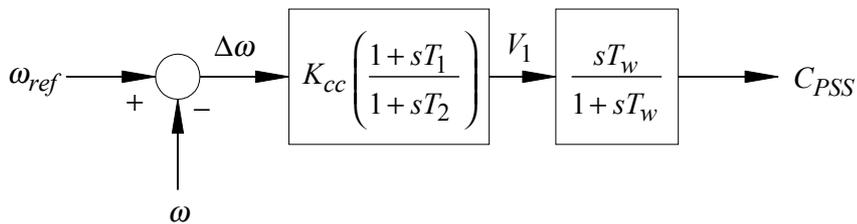


Fig. 10 Conventional power system stabilizer model

Table 3 Parameters of PSS

	Variable	Parameter
Time constant (sec)	$T_1$	0.685
Time constant (sec)	$T_2$	0.1
Wash-out Time constant (sec)	$T_w$	3
Gain	$K_{cc}$	7.091

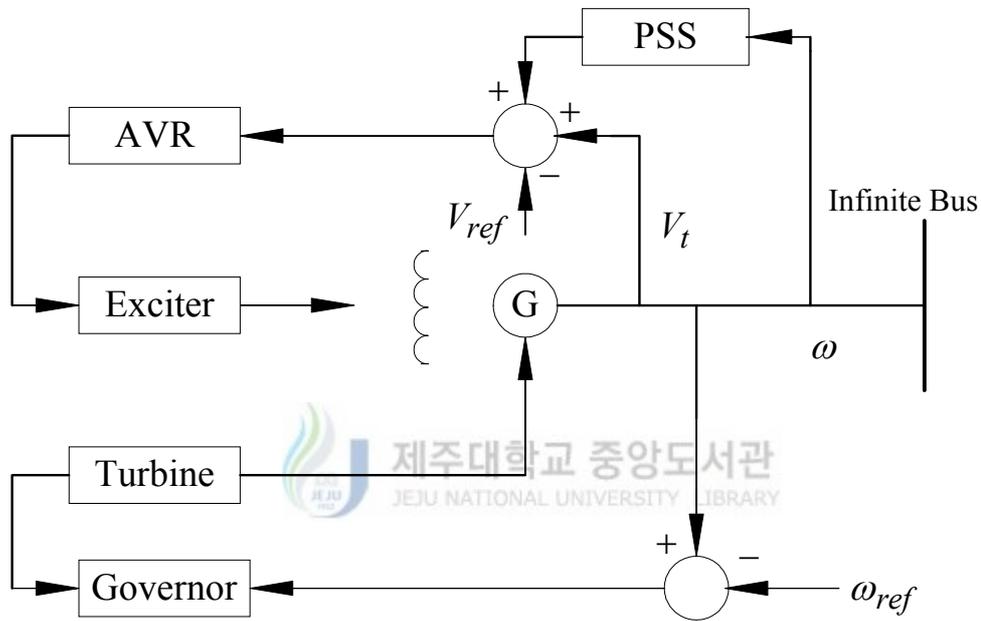


Fig. 11 Synchronous machine control scheme with PSS

Table 4 Parameters of synchronous machine control scheme with PSS

Control scheme		Variable	Parameter
Exciter	Exciter time constant	$T_e$	0.05
	Exciter gain	$K_e$	25.0
	Output upper bound	$e_{fd,max}$	4.0
	Output lower bound	$e_{fd,min} T_1$	-4.0
Turbine	Turbine time constant	$T_c$	0.1
	Turbine gain	$F_{hp}$	1.0
Governor	Governor time constant	$T_g$	0.1
	Governor gain	$K_g$	10.0
AVR	AVR time constant	$T_A$	0.1
	AVR time constant	$T_B$	0.2
PSS	Output upper bound	$u_{max}$	0.2
	Output lower bound	$u_{min}$	-0.2



## 2. 컴퓨터 시뮬레이션

본 논문에서는 제안한 TMBIDNC의 타당성을 검증하기 위하여 선정된 계통 전력은 일반적으로 많이 인용되고 있는 1기무한대모선 (OMIB) 계통에서의 전력계통 안정화 장치를 선정하였다. 본 모델은 전형적인 비선형 시스템이며 외란이 존재하며 q축 발전기 모델, 정적여자기, 터빈과 거버너 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.

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

Fig. 12는 일반적인 부하 조건하에서의 계통 출력과 Levenberg-Marquardt 방법에 의한 학습 후 TMBIDNM 출력의 차이를 보여준다. 샘플링 시간은 0.01[sec]이고 첫 번째 500 개의 샘플을 사용하였는데 제안한 방법이 실제 계통출력을 거의 근사화시키는 것을 알 수 있었다.

또한 제안한 Taylor 모델을 이용한 역동역학 뉴로제어기 (TMBIDNC)를 두가지 형태의 운전 조건이 변화하여 외란으로 작용하는 경우를 시험하여 보았다. Fig. 13과 14는 제안한 TMBIDNC의 응답과 기존의 PSS (CPSS)의 응답을 나타내고 있다. Fig. 13은 초기 토오크각 (torque angle)  $\delta$ 이 0.7 p.u.정도 증가하여 토오크각 편차가 존재할 때 전력계통에 미치는 영향을 나타낸 결과이고, Fig. 14는 0초에서 7초 사이에서는  $\delta$ 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.

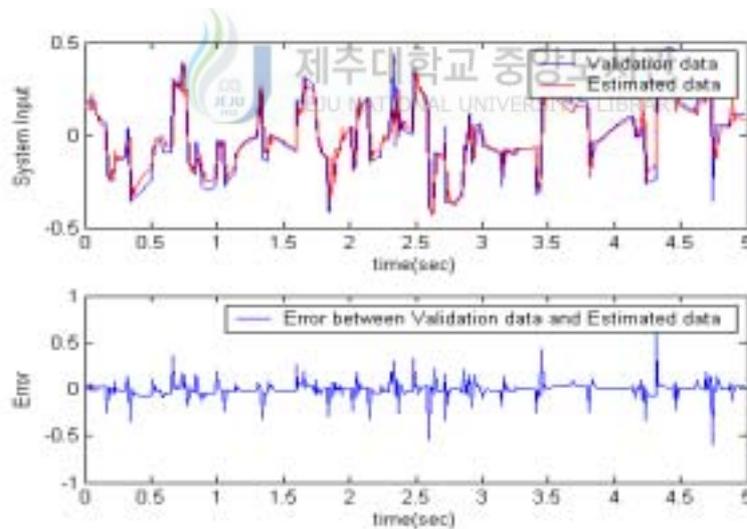


Fig. 12 TMBIDNM output and error (data n=500, order N=2)

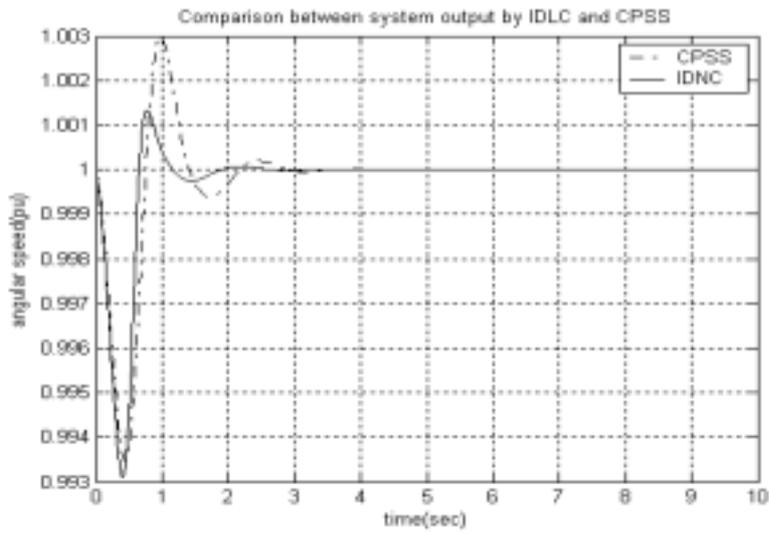


Fig. 13 Outputs of the CPSS and TMBIDNC in the torque angle deviation

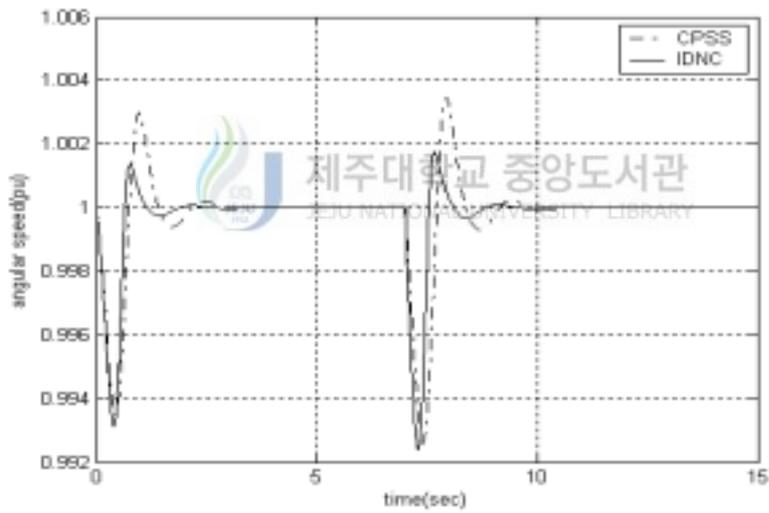


Fig. 14 Outputs of the CPSS and TMBIDNC in the torque angle deviation and torque deviation

## IV. 결 론

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

제안된 IDNM의 사용상에서 두가지 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 모션 전력계통에 적용하여 다양한 동작 조건에서 테스트되고 기존의 CPSS와도 비교하였는데, 모든 경우에 TMBIDNC는 CPSS보다 우수한 성능을 발휘하는 것을 알 수 있었다.

## 참고문헌

- Abe D. S., "Coordinated Synthesis of Power System Stabilizers in Multimachine Power Systems," *IEEE Trans. on PAS*, Vol 103, pp. 1473-1479, June 1984.
- DeMello F. P. 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.
- Ghosh A., 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.
- Haykin S., *Neural Networks: A Comprehensive Foundation*, Prentice Hall, New Jersey, 1999.
- Hsu Y. Y. and C. R. Chen, "Tuning of Power System Stabilizers Using an ANN," *IEEE Trans. on Energy Conversion*, Vol. 6, pp. 612-619, 1991.
- Hwang T. L., 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.
- IEEE Standard Board, 1990. *IEEE Guide for Identification, Testing, and Evaluation of the Dynamic Performance of Extation Control Systems*, IEEE Press.
- Kennedy D. C. and V. H. Quintana, "Neural Network Regulators for Synchronous Machines," *ACC*, Vol. 5, pp. 131-136, 1993.
- Khaldi M. R., 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.
- Kundur P., 1994. *Power System Stability and Control*, McGraw-Hill, New York.
- Law K. T., 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.
- Lee K. Y., 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.
- Lee K. Y., 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.
- Liguni Y. 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.
- Nguyen D. and B. Widrow, "The Truck Backer-Upper An Example of Self-Learning in Neural Networks," *IEEE Control System Magazine*, pp. 18-23, 1990.
- Ogata K., 1995. *Discrete-time Control System*, Prentice Hall.
- Park Y. M., S. H. Hyun, and J. H. Lee, "A synchronous Generator Stabilizer Design Using Neuro Inverse Controller and Error Reduction Network," *IEEE Trans. on Power System*, Vol. 11, No. 4, pp. 1969 -1975, November 1996.
- Phillips C. and H.T. Nagle, 1997. *Digital Control System Analysis and Design*, Prentice Hall.

- Poggio T. and F. Girosi, "Networks for Approximation and Learning," *Proceeding of IEEE*, pp. 1481-1497, September, 1990.
- Sauer P. W. and M.A. Pai, 1998. *Power System Dynamics and Stability*, Prentice Hall, New Jersey.
- Wu Q. H., B. W. Hogg, and G. W. Irwin, "A Neural Network Regulator for Turbogenerators," *IEEE Trans. on Neural Networks*, Vol. 3, No. 1, January 1992.
- Zhang Y., 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, September 1994.



## 感謝의 글

본 논문이 결실을 맺기까지 여러 가지로 부족한 저를 위하여 세심한 지도와 자상한 가르침을 주신 김호찬 지도교수님께 진심으로 존경과 깊은 감사를 드립니다.

논문의 심사와 많은 조언을 주셨던 좌종근교수님, 김세호교수님, 그리고 평소 아낌없는 가르침과 격려를 주신 오성보교수님, 이개명교수님, 현재 미국에 연구차가 계신 김일환교수님께 깊은 감사를 드립니다.

또한 본 논문이 완성되기까지 관련자료 및 원고정리에 많은 도움을 주신 제어계측 연구실의 부창진, 부찬혁 원생들에게도 고마움을 전합니다.

아울러 늦깎이에 시작한 저의 대학원 생활에 용기와 세심한 관심을 가지고 등을 다독겨 주신 이효성 지사장님을 비롯한 한전 가족 여러분과 주변의 지인들에게도 감사의 마음을 전합니다.

그리고 나의 대학원 생활을 헌신적인 사랑으로 내조를 해준 영원한 나의 반려자 박영숙에게 고맙다는 말을 전하고 싶고, 사랑하는 나의 두 아들 강호, 철호에게도 이 작은 선물로 아빠의 부족함을 채워주면서 귀감이 되었으면 하는 바램입니다. 감사합니다.

2004년 6월 일

김문찬 드림