

## 신경회로망 PID 제어기를 이용한 전력계통의 부하주파수제어에 관한 연구

정형환\*, 김상효\*, 주석민\*, °김경훈\*, 유재엽\*\*

\*동아대학교 전기공학과 \*\*창원기술대학

### A Study on the Load Frequency Control of 2-Area Power System Using Neural Network PID Controller

H. H. Chong\*, S. H. Kim\*, S. M. Joo\*, °K. H. Kim\*, J. Y. Yoo\*\*

\* Dong-A University \*\*Changwon Polytechnique College

**Abstract** - This paper has presented a method for self-tuning the PID controller using a BP method of multilayered NNs. The proposed controller employ input signal as a learning signal of PID control. The proposed controller is applied to load-frequency control of power system and it is investigated a dynamic characteristic. The simulation results shows that proposed NN STPID controller has the good dynamics responses against load disturbances.

#### 1. 서 론

전력수요의 증가와 함께 계통간의 연계로 인해서 전력시스템의 규모도 복잡·대형화되어 가고 있으며 정밀산업의 발달에 따라 양질의 전력에 대한 필요성이 높아지고 있다. 전력의 신뢰도와 질적인 향상을 위해서 전기에너지의 품질을 나타내는 전압과 주파수를 혼용범위내로 수렴시키는 문제에 대해서 많은 연구가 진행되어 오고 있다. 전력계통은 일정 주파수 및 일정 전압을 유지할 수 있도록 운전되어야 하지만 항상 발생하는 부하변동에 대하여 전력계통에 외란이 발생하면 계통의 주파수와 유효전력조류가 변하게 된다. 이와 같은 이유로 주파수가 상승 또는 저하되어 전력계통의 안정이 무너지게 된다. 따라서, 부하변동에 대하여 주파수를 일정하게 유지시키기 위해서 필요한 전력계통의 주파수 제어는 고도의 제어기법이 요구된다. 그러나, 전력계통은 각 지역간의 연계선 등의 강한 비선형성으로 인해 계통의 해석 및 제어기 설계가 매우 어려운 실정이다. 따라서, 본 연구에서는 비례, 적분 그리고 미분요소로 구성된 신경망 자기동조 PID 제어기(NN STPID Controller)를 구성하고 오차최소화 학습법중의 하나인 오차 역전파법을 이용하여 제어기의 각 파라미터가 자동조정되도록 하였다. 그리고 이 제어기를 전력계통의 부하주파수 제어에 적용하여 각 지역 주파수의 동특성 및 전력 선연계조류편차를 고찰하고자 한다.

#### 2. Model 계통방정식

본 논문에서는 그림 1과 같은 2지역 전력계통의 모델을 사용한다. 그림 1은 2개의 지역으로 분할될 수 있는데 i지역 계통은 식(2-1)~식(2-6)과 같이 미분방정식으로 표현될 수 있다.

$$\frac{d}{dt} \Delta \delta_i = \Delta f_i \quad (2-1)$$

$$\begin{aligned} \frac{d}{dt} \Delta f_i = & \frac{1}{M_i} (-D_i \cdot \Delta f_i \\ & + \Delta P_{ti} - \Delta P_{tieij} - \Delta P_{di}) \end{aligned} \quad (2-2)$$

$$\frac{d}{dt} \Delta P_{ti} = \frac{1}{T_{ti}} (-\Delta P_{ti} + \Delta P_{gi}) \quad (2-3)$$

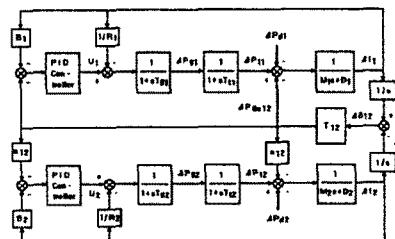


Fig 1. Block-diagram for LFC of nonlinear 2-area power system

$$\frac{d}{dt} \Delta P_{gi} = \frac{1}{T_{gi}} (-\frac{1}{R_i} \Delta f_i - \Delta P_{gi} + U_i) \quad (2-4)$$

$$\text{단, } \Delta \delta_{ij} = \Delta \delta_i - \Delta \delta_j \quad (2-5)$$

$$\Delta P_{tieij} = P_{tieij, max} (\sin(\delta_{ij}^* + \Delta \delta_{ij}) - \sin \delta_{ij}^*) \quad (2-6)$$

#### 3. 종래의 제어기법

##### 3.1 최적제어

전력계통의 선형 최적제어에서 가제어하며 관측 가능한 외란없는 시스템의 상태방정식은 식 (3-1)과 같이 쓸 수 있다.

$$\dot{X}(t) = AX(t) + BU(t) \quad (3-1)$$

단,  $X$  : 상태벡터 ( $n \times 1$ )

$U$  : 제어벡터 ( $m \times 1$ )

$A$  : 상태 계수행렬 ( $n \times n$ )

$B$  : 제어 계수행렬 ( $n \times m$ )

식(3-1)에 대한 최적제어 벡터  $U$ 는 다음에 의해 구해진다. 먼저, 2차 형식의 평가함수를 제어 시간  $t_f$ 에 대해 식 (3-2)로 정의한다.

$$J = \frac{1}{2} \int_{t_0}^{t_f} [X^T(t) Q X(t) + U^T(t) R U(t)] dt \quad (3-2)$$

단,  $Q$  : 상태가중행렬 ( $n \times n$ )

$R$  : 제어가중행렬 ( $m \times m$ )

따라서 식(3-2)의 평가함수를 최소화하는 최적 제어 입력  $U(t)$ 는 식(3-3)과 같이 주어진다.

$$U(t) = -K(t) X(t) \quad (3-3)$$

단,  $K(t) = R^{-1} B^T P(t)$

이때,  $P(t)$ 는 식(3-4)를 만족하는 정상 Riccati 방정식의 해이다.

$$P(t) A + A^T P(t) + Q - P(t) B R^{-1} B^T P(t) = 0 \quad (3-4)$$

### 3.2 PID 제어

일반적인 연속시간 PID 제어기의 전달함수는

$$G_c(s) = K_p + \frac{K_i}{s} + K_d \cdot s \quad (3-5)$$

이며, 제어기의 제어입력  $u(t)$ 는

$$u(t) = K_p [e(t) + \frac{1}{T_i} \int e(t) dt + T_d \frac{de(t)}{dt}] \quad (3-6)$$

이다. 여기서,  $e(t)$ 는 기준입력과 출력의 오차이고  $K_p$ ,  $K_i$  그리고  $K_d$ 는 각각 비례, 적분 및 미분 파라미터를 나타낸다. PID 제어기의 파라미터 결정법은 일반적으로 널리 이용되어 온 동조법으로 Ziegler - Nichols법이 있다. 이 방법은 시간영역속에서 제어 대상의 개회로 계단응답에 기초하여 임계이득( $K_c$ )과 임계주기( $T_c$ )를 구하여 비례, 적분 및 미분 파라미터를 결정하는 방법으로 식(3-7)과 같다.

$$K_p = 0.6 K_c, T_i = 0.5 T_c, T_d = 0.25 T_i$$

$$K_i = K_p / T_i \quad (3-7)$$

$$K_d = K_p * T_d$$

이상의 이론을 기초로 하여 2지역 계통의 부하 주파수모델에 적용하면, 임계이득  $K_c = 5.69$ , 임계 주기  $T_c = 1.60$ 로 구해진다. 이때, 임계이득과 임계 주기가 결정되므로 식(3-7)의 PID 파라미터는 식 (3-8)과 같다.

$$K_p = 3.417$$

$$K_i = 4.265 \quad (3-8)$$

$$K_d = 0.683$$

### 4. 신경망 제어기법

#### 4.1 오차 역전파 학습(Error Back-Propagation Learning)

역전파 학습알고리즘은 출력층에서 실제로 계산된 출력값과 목표출력값의 차이를 줄이는 방향으로 연결강도를 조절 하는 것으로서 1986년 Rumelhart 등에 의해서 제안된 학습알고리즘이다. 이 학습 방법은 구성하기가 용이하며, 학습계수의 선정에 따른 수렴성도 우수하기 때문에 신경회로망을 이용한 제어 시스템의 구현에 많이 이용되고 있다.

다중신경회로망의 각 뉴런이 그림 2와 같이 구성되었을 경우 이 신경회로망은 뉴런  $i$ 의 출력  $O_i$ 와, 연결강도  $w_{ji}$ 를 곱한 다음 그 값들의 전체집합 뉴런  $j$ 의 입력으로 하고 함수  $f$ 에 의해 뉴런  $j$ 의 출력  $O_j$ 가 결정되는 수식은 (4-1)과 같은 모델이다.

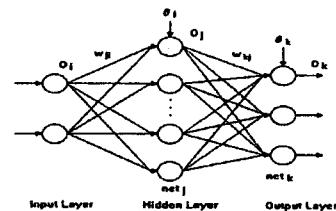


Fig 2. Multilayered Neural Network Structure

$$S_j = f(\sum_i w_{ji} \cdot O_i + \theta_j) \quad (4-1)$$

$$O_j = f(S_j)$$

여기서, 중간층  $j$ 의 출력을  $O_j$ , 출력층  $k$ 의 출력을  $O_k$ , 출력층  $k$ 의 읍세트를  $\theta_k$ , 중간층  $j$ 의 읍세트를  $\theta_j$ , 중간층과 출력층 간의 연결강도는  $w_{kj}$  그리고 입력층과 중간층간의 연결강도는  $w_{ji}$ 이다. 또한  $f(\cdot)$ 는 뉴런의 활성함수로써 -1과 1 사이의 값을 가지는 Hyperbolic Tangent 함수를 사용하였다.

학습의 목표는 출력층에 있어서의 출력과 교사신호 사이의 오차를  $\delta_k$ 로 두고 다음과 같은 오차함수  $E$ 를 최소화시키도록 연결강도를 계산한다. 이때  $E$ 를 최소화시키는 수식은 식(4-2)과 같고 오차  $\delta_k$ 는 식 (4-3)과 같다.

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (4-2)$$

$$\frac{\partial E}{\partial O_k} = -(T_k - O_k) = -\delta_k \quad (4-3)$$

여기서,  $T_k$ ,  $O_k$ 는 출력층  $k$ 에서의 목표출력, 실제 출력이다. 이때, 출력층에서의 오차  $\delta_k$ 는

$$\delta_k = (T_k - O_k) f'(net_k)$$

중간층에서의 오차  $\delta_j$ 는

$$\delta_j = f'(net_j) \sum \delta_k w_{kj}$$

와 같이 주어지고,  $f'(\cdot)$ 는  $f(\cdot)$ 의 미분함수를 나타낸다.

최급강하법(steepest descent Method)에 의해 중간 층과 출력층 사이의 가중치의 변화량은 식(4-4)와 같다.

$$\Delta w_{kj}(t) = \eta \cdot \delta_k \cdot O_j + m \cdot \Delta w_{kj}(t-1) \quad (4-4)$$

그리고 입력층과 중간층 사이의 가중치의 변화량은 식(4-5)과 같이 구해진다.

$$\Delta w_{ji}(t) = \eta \cdot \delta_j \cdot O_i + m \cdot \Delta w_{ji}(t-1) \quad (4-5)$$

여기서,  $\eta$ 는 학습률,  $m$ 은 모멘텀항을 나타낸다.

#### 4.2 신경망 자기동조 PID제어기(NN STPID)

그림 3은 신경회로망 PID 제어기를 전력계통의 부하주파수 제어에 적용시킨 것을 나타낸다. 여기서, 사용된 신경회로망은 그림 2와 같은 다중 신경회로망으로 PID이득을 조정하여 오차함수 식(4-2)를 최소화시킨다.

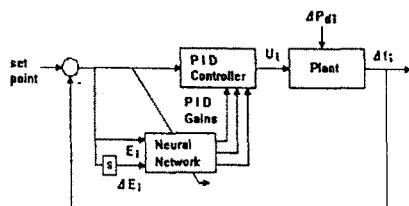


Fig 3. Neural Network Self - Tuning PID Controller for Area i

본 연구에서 사용한 신경망 STPID제어기는 PID 제어의 입·출력인 각 지역의 제어입력량  $U_i$ 와 오차  $E_i$  및 오차변화량  $\Delta E_i$ 을 신경망 학습알고리즘에 의해 학습시키고 제어기의 입력은 주파수편차  $\Delta f_i$ 의 오차와 오차변화량을 사용한다.

#### 5. 시뮬레이션 결과 및 고찰

본 연구에서는 시스템의 오차와 오차변화량을 입력으로 하는 신경망 STPID제어기를 구성하여 전력계통의 부하주파수 제어에 적용하였다. 이 제어기는 오차 역전파 학습알고리즘을 이용하여 시스템을 학습한다. 부하변동( $\Delta P_{dl} = 0.01[\text{p.u.MW}]$ )은 1지역에만 지속적으로 주어졌을 경우로 한다. 시뮬레이션에 사용된 신경망은 입력층 2개, 중간층 10개, 출력층 3개의 뉴런으로 구성하였다.

그림 4는 1지역과 2지역의 제어기가 학습하고 있는 과정을 나타낸 것이다.

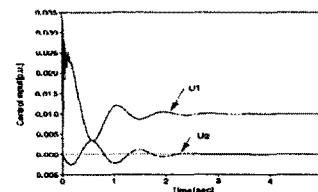


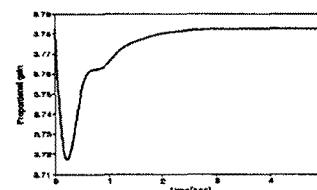
Fig 4. Learning Pattern of NN STPID Controller

표 1은 Z-N Method로 구한 PID 파라미터와 NN STPID에 의해 최종 수렴된 PID 제어기의 파라미터를 나타내고 있다.

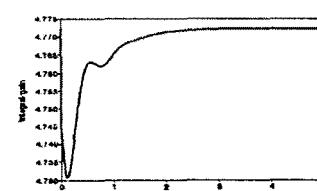
Parameter	Area 1		Area 2	
	Z-N	NN STPID	Z-N	NN STPID
$K_p$	3.417	3.783	3.417	4.051
$K_i$	4.265	4.772	4.265	4.758
$K_d$	0.683	1.133	0.683	1.236

Table 1. Converged PID Parameters by Z-N Method and NN STPID.

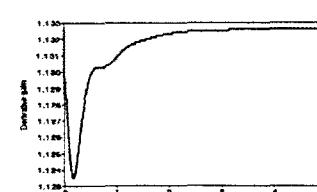
그림 5는 오차와 오차변화율에 대해 PID 제어기의 파라미터가 동조되는 과정을 나타낸 그림이다.



(a)  $K_{p1}$



(b)  $K_{i1}$



(c)  $K_{d1}$

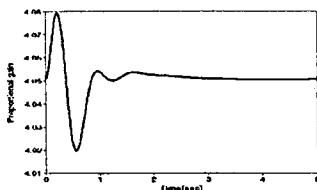
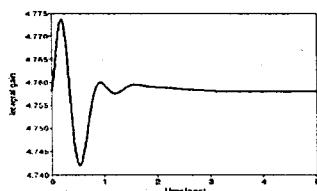
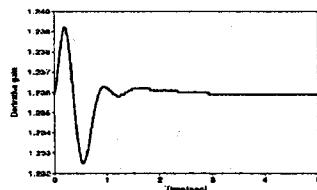
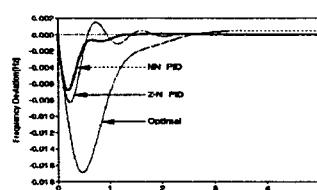
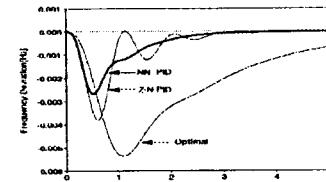
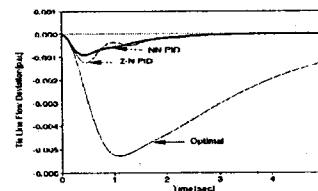
(d)  $K_{P2}$ (e)  $K_{I2}$ (f)  $K_{D2}$ 

Fig 5. Convergence procedures of PID parameters

그림 6은 NN STPID제어기와 종래의 제어기법의 1, 2지역에 대한 주파수 편차와 연계선 조류편차의 응답특성을 나타내고 있다.

제안한 방법에 의한 동특성 응답이 종래의 기법보다 주파수 편차량과 연계선 조류편차량을 경감시켰을 뿐만 아니라 정정시간(Settling time)을 줄일 수 있었다.

(a)  $\Delta f_1$ (a)  $\Delta f_2$ (c)  $\Delta P_{tie12}$ Fig 6. Dynamic Responses of power system by Optimal, PID and NN STPID Controller( $\Delta P_{d1} = 0.01$ ,  $\Delta P_{d2} = 0.0$ [p.u])

## 6. 결 론

본 논문에서는 2지역 전력계통의 부하주파수 제어를 위한 신경망 STPID제어기법을 제안하였다. 신경회로망의 오차 역전파 학습알고리즘을 이용하여 시스템을 학습한 후 부하 주파수 제어에 적용하여 PID 파라미터 자동등조 과정과 각 지역에 대한 주파수 최대편차량과 연계선 조류 편차량을 비교하였다.

종래의 제어기법을 이용한 것보다 응답 특성이 양호하였고 주파수 최대 편차량과 연계선 조류 편차량을 경감시킬 수 있었으며, 정정시간(Settling time)을 줄일 수 있었다.

## [참 고 문 헌]

- [1] Olle I. Elgerd, C. E. Fosha, "Optimum megawatt - frequency control of multiarea electric energy systems", IEEE Trans. on PAS, Vol. 89, No. 4, pp. 556-563, 1970.
- [2] A. J. Wood and B. F. Wollenberg, "Power Generation, Operation and Control", John Wiley & Sons, 1984.
- [3] M. Zhuang, D. P. Atherton, "Automatic tuning of optimum PID controllers", IEE Proc D, Vol. 140, No. 3, pp. 216-224, 1993
- [4] M. Saerens, A. Soquet, "A Neural Controller based on Backpropagation Algorithm", Proc. IEE, pp. 211-215, 1989.