

論文 2000-37CI-1-3

신경망 제어 시스템의 안정도에 관한 연구

(A Study on the Stability of Neural Network Control Systems)

金 殷 泰 * , 李 羲 振 * , 金 承 禹 ** , 朴 玫 用 ***

(Eun Tai Kim, Hee Jin Lee, Seung Woo Kim, and Mignon Park)

요 약

본 논문에서는 이산 시간 신경망 제어 시스템의 안정도에 대한 해석을 하도록 한다. 우선 리아프노프의 직접법을 이용하여 신경망제어기를 포함하고 있는 시스템의 안정조건을 체계적으로 유도하고 이 유도된 안정조건을 반영하여 수정된 수정 역전과 알고리즘을 제안한다. 이 수정된 역전과 알고리즘은 유도된 신경망 제어기 시스템의 안정조건을 반영한 학습 규칙이고 따라서 이를 이용하여 학습된 신경망 제어기의 경우 안정성을 보장하게 된다. 끝으로 컴퓨터 모의 실험에서는 제안한 신경망 제어 시스템의 안정조건과 이를 반영한 수정 역전과 알고리즘을 통하여 주어진 플랜트를 학습 제어하도록 한다.

Abstract

In this paper, an analysis of the stability for a class of discrete-time neural network control systems is presented. Based on Lyapunov's direct method, a sufficient stability condition for the neural network control systems is systematically derived and the modified back propagation algorithm which reflects the derived stability condition is suggested. The modified BP originates from the derived sufficient condition and guarantees the exponential stability of the resulting trained closed system. Finally, computer simulation is included to show an example where the derived stability condition and the BP modified by the condition is used to train the control plant.

I. 서 론

지난 수십 년간 신경망은 여러 분야에서 많은 관심을

끌었고 공학 및 과학분야에서 가장 유망한 분야 중에 하나가 되었다^[1-4]. 특히 제어분야에의 적용은 최근 부각되기 시작한 분야로 기존의 모델-기반 제어기법이 사용되기 부적절한 경우나 학습제어가 요구되는 경우에 성공적으로 사용되었다^[5-9]. 예컨대 Kawato는 [10]에서 로봇제어에 신경망 학습제어 기법을 사용하였고 Nguyen과 Widrow는 신경망 제어기를 이용하여 트럭-트레일러의 문제를 해결하였다^[11]. Gopal은 [12]에서 신경망 에뮬레이터의 역다이내믹스를 이용하여 로봇의 적응 궤적 추적을 구현하였다.

이 같은 실제적인 연구와 병행하여 신경망제어에 대한 이론적인 연구도 널리 진행되었다. 신경망 제어에 대한 이론적인 연구는 크게 다음의 두 방향으로 나눌 수 있다.

* 正會員, 國立大學校 制御計測工學科
(Dept. of Control and Instrumentation Engr Hankyog National University)

** 正會員, 順天鄉大學校 情報技術工學部
(Dept. of Information and Technology Engr Soonchunhyang University)

*** 正會員, 延世大學校 電子工學部
(Dept. of Electronic Engr Yonsei University)

接受日字: 1998年6月9日, 수정완료일: 1999年11月24日

- (1) 신경망 제어기의 연결강도 조정하는 방법에 대한 연구
- (2) 안정도나 강인성을 만족하는 신경망 제어기 설계 방법에 대한 연구

신경망의 연결강도의 조정에 관해서는 여러 가지 알고리즘이 알려져 있지만 가장 대표적인 방법이 기본 역전파 알고리즘이다(standard back propagation, SBP)^[4]. 또 기본 역전파 알고리즘에서 학습 속도를 가속화한 변형 고속화 알고리즘도 발표되어 있다^[19, 20]. Chen과 Mills은 지수 묘사 함수(exponential describing function)를 이용하여 신경망 제어기의 연결강도를 학습하는 알고리즘을 제안하였다^[21].

안정성을 만족하는 신경망 제어기의 설계에 대한 가장 주목할 만한 연구결과는 Sanner와 Slotine^[13], Narendra^[14], Camacho et al^[15], Teixer et al^[16], Polycarpou^[17]등에 의해 보고되었다. [13-17]에 제안된 방법들에서 사용된 기본적인 접근 방식은 신경망의 일반 근사력(universal approximation capability)를 이용하여 플랜트의 특성을 제거하고 나머지를 적응제어나 슬라이딩 제어로 접근하는 방식이다. 이들은 신경망의 설계에 모두 적응 알고리즘에 근거한 방법을 사용하므로 신경망 제어기의 설계 방법론을 제시하여 주기는 하지만 어떤 플랜트가 어떤 신경망 제어기와 페루프를 형성할 때 전체 시스템이 안정할 것인가에 대한 조건을 제시하여 주지는 않는다.

본 논문에서는 기존의 이론들과 달리 비적용 신경망 제어기를 이용하여 특정 플랜트와 페루프를 형성할 때 안정 조건을 제안한다. 제안된 조건은 신경망 제어기의 연결강도(synaptic weight)에 대한 조건으로 나타나게 된다. 끝으로 이 제안된 안정 조건을 반영하는 새로운 역전파 알고리즘을 제안한다. 제안된 역전파 알고리즘(Back Propagation which guarantees the Exponential Stability, BPES)은 유도된 안정 조건을 반영한 것으로 이 방법에 의해 신경망이 학습되면 전체 시스템은 지수적 안정성을 만족하게 된다.

본 논문의 구성은 다음과 같다. 2장에서는 신경망 제어기 간단히 설명하고 본 논문에서 다루게 되는 문제를 소개한다. 3장에서는 신경망 제어 시스템의 안정도를 보장하는 조건을 리아프노프 직접법을 이용하여 유도한다. 4장에서는 안정성을 보장하는 역전파 알고리즘을 제안하며 5장에서는 모의 실험을 통해 제안한 시스템의

타당성을 검증한다. 6장에서 본 논문의 결론이 주어진다.

II. 문제의 구성

제어의 영역에서 여러 형태의 전방향 신경망(feedforward neural networks)에 대한 연구가 널리 진행되고 있고 그 대표적인 예가 다층 신경망(multiple-layered perceptron, MLP), 레이디얼 기저 함수(radial basis function network, RBFN)과 두뇌 모델 제어기(cerebellar model articulation controller, CMAC)등이 있다. 본 논문에서는 이산시간 다층 신경망을 이용하며 이 구조는 그림 1과 같다.




그림 1. 다층 신경망 제어기

Fig. 1. The multilayer perceptron (MLP) neural network controller.




그림 2. 은닉층의 신경망 유닛

Fig. 2. The neuron unit in the hidden layer.

본 논문에서 사용되는 다층 신경망은 입력층 1층, 비선형 은닉층 1층, 선형 출력층 1층의 3층으로 구성된 것으로 한다. 여기서 입력층의 노드수는 n , 은닉층은 m , 출력층은 p 로 한다. Stone-Weistrass 정리에 의해 신경망은 충분히 많은 은닉층이 위의 3층 구조로도 사용된다면 대부분의 실함수를 표현할 수 있다는 정리에 의해 이 같은 제약은 크게 일반성을 잃지 않는 가정이다^[22-24]. 은닉층의 비선형 노드는 다음의 그림 2와 같이

비선형 활성화 함수 $\sigma(\cdot)$ 와 선형 조합기(a linear combiner)로 구성되어 있다.

2극 활성화 함수 $\sigma(\cdot)$ 의 예는 다음과 같다.

$$\begin{cases} \sigma_1(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \\ \sigma_2(x) = \frac{2}{1 + e^{-x}} - 1 = \frac{1 - e^{-x}}{1 + e^{-x}} \\ \sigma_3(x) = \frac{2}{\pi} \tan^{-1}\left(\frac{\pi}{2} x\right) \\ \sigma_4(x) = \frac{x^2}{1 + x^2} \text{sign}(x) \end{cases}$$

이 들 경우에서 $\sigma(\cdot)$ 는 다음의 조건을 만족한다.

$$0 \leq \sigma(h)\sigma(h) \leq \sigma(h)h \leq h^2 \text{ 이고 } \sigma(0)=0 \quad (1)$$

본 논문에서는 $\sigma_1(\cdot)$ 함수를 활성화함수로 사용하도록 한다. 그림 2의 신경망 제어기의 특성은 다음의 입출력 행렬 방정식으로 표현될 수 있다.

$$\mathbf{u}(k) = \mathbf{NN}(\mathbf{x}(k)) = \mathbf{W}_0 \boldsymbol{\Sigma}(\mathbf{h}(k)) \text{ 이고}$$

$$\mathbf{h}(k) = \mathbf{net}^H(k) = \mathbf{W}_H \mathbf{x}(k)$$

여기서 $\mathbf{x}(k)$ ($n \times 1$)는 상태벡터이고 $\mathbf{u}(k)$ ($p \times 1$)는 제어벡터이다. 그림 1에서 $\mathbf{W}_H = (w_{ji}^H)$ ($m \times n$, $i=1, \dots, n$, $j=1, \dots, m$)는 입력층과 은닉층사이를 연결하는 연결강도(synaptic weight)행렬이고 $\mathbf{W}_0 = (w_{ij}^0)$ ($p \times m$ matrix, $j=1, \dots, m$, $i=1, \dots, p$)는 은닉층과 출력층을 연결하는 연결강도 행렬이다.

$$\boldsymbol{\Sigma}(\mathbf{h}) \equiv (\sigma(h_1), \sigma(h_2), \dots, \sigma(h_m)) \text{ and}$$

$$\mathbf{h} = (h_1, h_2, \dots, h_m)^T;$$

$$(i=1, \dots, n, j=1, \dots, m)$$

(1)식에서 다음의 벡터 부등식이 성립한다.

$$0 \leq \boldsymbol{\Sigma}^T(\mathbf{h}) \boldsymbol{\Sigma}(\mathbf{h}) \leq \boldsymbol{\Sigma}^T(\mathbf{h}) \mathbf{h} \leq \mathbf{h}^T \mathbf{h} \text{ 여기서}$$

$$\mathbf{h} = \mathbf{W}_H \mathbf{x}. \quad (2)$$

이 논문의 시스템 구성은 그림 3과 같다.

본 논문에서는 평형점 주위의 안정도를 다루고 있으므로 레퍼런스 r 은 0으로 가정한다. 본 논문에서 다루는 플랜트는 식 3의 선형 플랜트를 생각한다.

$$\mathbf{x}(k+1) = \mathbf{A} \mathbf{x}(k) + \mathbf{B} \mathbf{u}(k), \quad (3)$$




그림 3. 신경망 시스템의 구성

Fig. 3. The configuration of neural network control system.

여기서 $\mathbf{x}, \mathbf{u}, \mathbf{A}, \mathbf{B}$ 는 각 $n \times 1, p \times 1, n \times n, n \times p$ 행렬이고 행렬 \mathbf{A} 는 이산 시간 Hurwitz 행렬이라 가정한다. 플랜트가 식 (4)와 같은 비선형 시스템인 경우, 식(3)은 식(4)의 평형점부근 선형화 식임을 알 수 있고 이 경우 다음 절에서 유도되는 안정조건은 전역 안정도를 보장하지 않고 지역 안정도만을 보장하게 된다.

$$\mathbf{x}(k+1) = \boldsymbol{\Phi}(\mathbf{x}(k), \mathbf{u}(k)) \quad (4)$$

플랜트와 신경망 제어기로 구성된 폐루프의 시스템은 다음의 식으로 표현된다.

$$\mathbf{x}(k+1) = \mathbf{A} \mathbf{x}(k) + \mathbf{B} \mathbf{u}(k)$$

$$\mathbf{u}(k) = \mathbf{NN}(\mathbf{x}(k)) = \mathbf{W}_0 \boldsymbol{\Sigma}(\mathbf{W}_H \mathbf{x}(k))$$

다음장에서 $\mathbf{x}(k)$ 을 0으로 끌어감을 보장하는 신경망 연결강도 \mathbf{W}_H 과 \mathbf{W}_0 에 대한 조건을 유도한다.

III. 신경회로망 시스템의 지수적 안정도를 보장하는 조건

본 장에서는 신경 회로망 제어기의 점근적 안정도를 보장하는 충분조건을 제시한다. 우선 다음과 같은 식으로 표현되는 신경망을 포함한 폐루프 시스템을 생각한다.

$$\mathbf{x}(k+1) = \mathbf{A} \mathbf{x}(k) + \mathbf{B} \mathbf{u}(k) \quad (5)$$

$$\mathbf{u}(k) = \mathbf{NN}(\mathbf{x}(k)) = \mathbf{W}_0 \boldsymbol{\Sigma}(\mathbf{h}(k)) \quad (6)$$

$$\text{and } \mathbf{h}(k) = \mathbf{net}^H(k) = \mathbf{W}_H \mathbf{x}(k)$$

정리 1.

다음의 조건을 만족하는 0이 아닌 $\xi \neq 0$ 가 존재한다고 가정한다.

$$-\lambda_{\min}(\mathbf{Q}) + \gamma\xi^2 + (\mu + \gamma\frac{1}{\xi^2})\rho < 0 \quad (7)$$

여기서 $\mathbf{A}^T\mathbf{P}\mathbf{A} - \mathbf{P} = -\mathbf{Q}$

$$\gamma \equiv \|\mathbf{A}^T\mathbf{P}\mathbf{B}\mathbf{W}_0\| = \gamma(\mathbf{W}_0) \quad (8)$$

$$\begin{aligned} \mu &\equiv \lambda_{\max}(\mathbf{W}_0^T\mathbf{B}^T\mathbf{P}\mathbf{B}\mathbf{W}_0) = \sigma_{\max}^2(\sqrt{\mathbf{P}}\mathbf{B}\mathbf{W}_0) \\ &= \mu(\mathbf{W}_0) \end{aligned} \quad (9)$$

$$\rho \equiv \lambda_{\max}(\mathbf{W}_H^T\mathbf{W}_H) = \|\mathbf{W}_H\|^2 = \rho(\mathbf{W}_H) \quad (10)$$

(여기서 모든 놈은 2-놈 또는 2-유도 놈(induced spectral norms)이다.

이 경우 식 (5)의 플랜트와 식 (6)의 신경망 제어기를 구성되는 신경망 제어 시스템은 평형점 주위에서 전역적으로 지수적으로 안정하다.

(증명)

\mathbf{A} 를 이산적 Hurwitz 행렬로 가정하면 어떤 양의 반한정 행렬 \mathbf{Q} 에 대하여 다음의 부등식을 만족하는 양의 한정 행렬 \mathbf{P} 가 존재한다.

$$\mathbf{A}^T\mathbf{P}\mathbf{A} - \mathbf{P} = -\mathbf{Q} \quad [26]$$

이제 다음의 $V(k)$ 을 리아프노프 후보함수로 채택한다.

$$V(k) = \mathbf{x}^T(k) \mathbf{P} \mathbf{x}(k)$$

이 경우,

$$\begin{aligned} \Delta V(k) &= V(k+1) - V(k) \\ &= \mathbf{x}^T(k+1) \mathbf{P} \mathbf{x}(k+1) - \mathbf{x}^T(k) \mathbf{P} \mathbf{x}(k) \\ &= (\mathbf{A} \mathbf{x}(k) + \mathbf{B} \mathbf{u}(k))^T \mathbf{P} (\mathbf{A} \mathbf{x}(k) + \mathbf{B} \mathbf{u}(k)) \\ &\quad - \mathbf{x}^T(k) \mathbf{P} \mathbf{x}(k) \\ &= \mathbf{x}^T(k) (\mathbf{A}^T\mathbf{P}\mathbf{A} - \mathbf{P}) \mathbf{x}(k) \\ &\quad + \mathbf{u}^T(k) (\mathbf{B}^T\mathbf{P}\mathbf{B}) \mathbf{u}(k) \\ &\quad + 2 \mathbf{u}^T(k) (\mathbf{B}^T\mathbf{P}\mathbf{A}) \mathbf{x}(k) \\ &\leq -\lambda_{\min}(\mathbf{Q}) \|\mathbf{x}(k)\|^2 \\ &\quad + \Sigma^T(\mathbf{h}(k)) \mathbf{W}_0^T \mathbf{B}^T \mathbf{P} \mathbf{B} \mathbf{W}_0 \Sigma(\mathbf{h}(k)) \\ &\quad + 2 \mathbf{x}^T(k) (\mathbf{A}^T\mathbf{P}\mathbf{B}) \mathbf{W}_0 \Sigma(\mathbf{h}(k)) \end{aligned}$$

이후로 편의상 시간을 나타내는 k 를 생략한다.

$$\begin{aligned} \Delta V(k) &\leq -\lambda_{\min}(\mathbf{Q}) \|\mathbf{x}\|^2 \\ &\quad + \lambda_{\max}(\mathbf{W}_0^T \mathbf{B}^T \mathbf{P} \mathbf{B} \mathbf{W}_0) \|\Sigma(\mathbf{h})\|^2 \\ &\quad + 2 \mathbf{x}^T (\mathbf{A}^T \mathbf{P} \mathbf{B}) \mathbf{W}_0 \Sigma(\mathbf{h}) \\ &\leq -\lambda_{\min}(\mathbf{Q}) \|\mathbf{x}\|^2 \\ &\quad + \lambda_{\max}(\mathbf{W}_0^T \mathbf{B}^T \mathbf{P} \mathbf{B} \mathbf{W}_0) \|\Sigma(\mathbf{h})\|^2 \\ &\quad + 2 \|(\mathbf{A}^T \mathbf{P} \mathbf{B}) \mathbf{W}_0\| \|\mathbf{x}\| \|\Sigma(\mathbf{h})\| \end{aligned}$$

여기서 다음의 수발츠 부등식을 이용한다^[26].

$$|\mathbf{x}^T \mathbf{y}| \leq \|\mathbf{x}\| \|\mathbf{y}\|$$

다음의 식 (8)과 식 (9)를 이용하면

$$\begin{aligned} \gamma &\equiv \|\mathbf{A}^T \mathbf{P} \mathbf{B} \mathbf{W}_0\| = \gamma(\mathbf{W}_0) \\ \mu &\equiv \lambda_{\max}(\mathbf{W}_0^T \mathbf{B}^T \mathbf{P} \mathbf{B} \mathbf{W}_0) \\ &= \sigma_{\max}^2(\sqrt{\mathbf{P}} \mathbf{B} \mathbf{W}_0) = \mu(\mathbf{W}_0) \end{aligned}$$

$\Delta V(k)$ 는 다음과 같이 상한(upper bounded)된다.

$$\begin{aligned} \Delta V(k) &\leq -\lambda_{\min}(\mathbf{Q}) \|\mathbf{x}\|^2 + \mu \|\Sigma(\mathbf{h})\|^2 \\ &\quad + 2 \gamma \|\mathbf{x}\| \|\Sigma(\mathbf{h})\| \end{aligned}$$

다음의 식을 고려하면

$$\begin{aligned} \gamma \|\mathbf{x}\| \|\Sigma(\mathbf{h})\| &= \gamma \left(\|\mathbf{x}\| \|\Sigma(\mathbf{h})\| - \frac{\xi^2}{2} \|\mathbf{x}\|^2 \right. \\ &\quad \left. - \frac{1}{2\xi^2} \|\Sigma(\mathbf{h})\|^2 + \frac{\xi^2}{2} \|\mathbf{x}\|^2 + \frac{1}{2\xi^2} \|\Sigma(\mathbf{h})\|^2 \right) \\ &= \gamma \left\{ -\frac{1}{2} \left(\xi \|\mathbf{x}\| - \frac{1}{\xi} \|\Sigma(\mathbf{h})\| \right)^2 \right. \\ &\quad \left. + \frac{\xi^2}{2} \|\mathbf{x}\|^2 + \frac{1}{2\xi^2} \|\Sigma(\mathbf{h})\|^2 \right\} \end{aligned}$$

따라서,

$$\begin{aligned} \Delta V(k) &\leq -\lambda_{\min}(\mathbf{Q}) \|\mathbf{x}\|^2 + \mu \|\Sigma(\mathbf{h})\|^2 \\ &\quad + 2 \gamma \left\{ -\frac{1}{2} \left(\xi \|\mathbf{x}\| - \frac{1}{\xi} \|\Sigma(\mathbf{h})\| \right)^2 \right. \\ &\quad \left. + \frac{\xi^2}{2} \|\mathbf{x}\|^2 + \frac{1}{2\xi^2} \|\Sigma(\mathbf{h})\|^2 \right\} \quad (11) \\ &\leq -\lambda_{\min}(\mathbf{Q}) \|\mathbf{x}\|^2 + \mu \|\Sigma(\mathbf{h})\|^2 \\ &\quad + \gamma \xi^2 \|\mathbf{x}\|^2 + \frac{\gamma}{\xi^2} \|\Sigma(\mathbf{h})\|^2 \end{aligned}$$

(2)식의 부등식에 의해, 위 부등식의 $\|\Sigma(\mathbf{h})\|^2$ 항은 다음의 식과 같이 상한된다.

$$\begin{aligned} \|\Sigma(\mathbf{h})\|^2 &= \Sigma^T(\mathbf{h})\Sigma(\mathbf{h}) \leq \mathbf{h}^T \mathbf{h} \\ &= \mathbf{x}^T \mathbf{W}_H^T \mathbf{W}_H \mathbf{x} \leq \lambda_{\max}(\mathbf{W}_H^T \mathbf{W}_H) \|\mathbf{x}\|^2 \quad (12) \\ &= \|\mathbf{W}_H\|^2 \|\mathbf{x}\|^2 = \rho \|\mathbf{x}\|^2 \end{aligned}$$

여기서 $\rho \equiv \lambda_{\max}(\mathbf{W}_H^T \mathbf{W}_H) = \|\mathbf{W}_H\|^2 = \rho(\mathbf{W}_H)$

(11)과 (12)를 이용하면 $\Delta V(k)$ 는 다음의 식으로 표현된다.

$$\Delta V(k) \leq \left\{ -\lambda_{\min}(\mathbf{Q}) + \gamma \xi^2 + (\mu + \gamma \frac{1}{\xi^2}) \rho \right\} \|\mathbf{x}\|^2 \quad (13)$$

따라서, 0이 아닌 $\xi \neq 0$ 에 대하여 신경회로망의 연결강도가 다음의 식을 만족하면 신경회로망은 이산적 차원에서 점근적으로 안정한다.

$$-\lambda_{\min}(\mathbf{Q}) + \gamma \xi^2 + (\mu + \gamma \frac{1}{\xi^2}) \rho < 0 \quad (14)$$

이때 리아프노프 후보함수가 2차 함수이므로 신경회로망 제어 시스템은 지수적으로 안정하다.

IV. 지수적 수렴을 보장하는 역전파 알고리즘

Rumelhart 와 McClland가 다층 신경망구조에 대한 학습 방법인 역전파 알고리즘을 개발한 이래 다층 신경망은 함수근사기로 널리 사용되게 되었다. 역전파의 기본 알고리즘은 다층 신경망의 연결강도를 목적함수를 줄이는 음의 그레디언트 방향으로 조절하여 원하는 함수의 근사화를 이루는 것을 의미한다. N 개의 학습 벡터에 대한 목적함수는 다음의 식으로 표현된다.

$$\begin{aligned} E(\mathbf{W}_H, \mathbf{W}_O) &= \frac{1}{2} \sum_{k=1}^n (u_k^{des}(\mathbf{x}) - NN_k(\mathbf{x}, \mathbf{W}_H, \mathbf{W}_O))^2 \\ &= \frac{1}{2} (\mathbf{u}^{des}(\mathbf{x}) - \mathbf{NN}(\mathbf{x}, \mathbf{W}_H, \mathbf{W}_O))^T \\ &\quad (\mathbf{u}^{des}(\mathbf{x}) - \mathbf{NN}(\mathbf{x}, \mathbf{W}_H, \mathbf{W}_O)) \end{aligned} \quad (15)$$

여기서 $\mathbf{u}^{des} = [u_1^{des}, u_2^{des}, \dots, u_p^{des}]^T$ 는 \mathbf{x} 의 원하는 출력값이며

$\mathbf{u}(k) = \mathbf{W}_O \Sigma(\mathbf{W}_H \mathbf{x}) = \mathbf{NN}(\mathbf{x}) = [NN_1, NN_2, \dots, NN_p]^T$ 는 신경망으로부터의 출력이다. 그러나 이같이 구축된 신경망 시스템에 대하여 역전파 알고리즘을 이용해 학습할 경우 이 신경망 제어 시스템 시스템의 안정도에 대한 어떤 보장할 수 없다^[28]. 본 절에서는 신경망 제어 시스템 시스템의 지수적 안정도를 보장하는 새로운 역전파 알고리즘을 제안한다. 본 장에서 제안되는 BPES는 3장에서 유도된 안정도 조건을 반영한 것으로 전체 신경망 제어 시스템 시스템의 지수적 안정도를 보장한다.

1. 수정된 지수적 안정도 조건

BPES를 유도하기 위하여 다음의 보조정리를 필요로 한다. 이의 증명은 매우 간단하므로 본 논문에서는 생략한다.

보조정리 1.

두 양수 $a > 0$ 와 $b > 0$ 에 대하여 다음의 부등식이 성립한다.

$$\frac{a+b}{2} \geq \sqrt{ab}$$

여기서 등호는 $a=b$ 인 경우 성립한다.

(13)식이 부등식을 생각하고 그 좌변을 다음과 같이 ξ 의 함수로 표현한다.

$$f(\xi) \equiv -\lambda_{\min}(\mathbf{Q}) + \gamma \xi^2 + (\mu + \gamma \frac{1}{\xi^2}) \rho$$

만약 $\min_{\xi \in R} f(\xi)$ 값을 구할 수 있다면 $f(\xi) < 0$ 인 0이 아닌 $\xi \neq 0$ 가 존재한다는 조건은 $\min_{\xi \in R} f(\xi) < 0$ 이라는 조건과 동치가 된다. $\xi^2 > 0$ 임을 고려하고 보조정리 1로부터, $\min_{\xi \in R} f(\xi)$ 은 다음과 같이 유도된다.

$$\begin{aligned} f(\xi) &= -\lambda_{\min}(\mathbf{Q}) + \gamma \xi^2 + (\mu + \gamma \frac{1}{\xi^2}) \rho \\ &= -\lambda_{\min}(\mathbf{Q}) + \mu \rho + (\gamma \xi^2 + \gamma \frac{1}{\xi^2}) \rho \\ &\geq -\lambda_{\min}(\mathbf{Q}) + \mu \rho + 2\sqrt{\gamma \xi^2 \cdot \gamma \frac{1}{\xi^2}} \rho \\ &\quad (\text{보조정리 1에 의해}) \\ &= -\lambda_{\min}(\mathbf{Q}) + \mu \rho + 2\gamma \sqrt{\rho} \\ &\equiv \min_{\xi \in R} f(\xi) \end{aligned}$$

따라서,

$$f(\xi) \equiv -\lambda_{\min}(\mathbf{Q}) + \gamma\xi^2 + (\mu + \gamma\frac{1}{\xi^2})\rho < 0$$

을 만족하는 0이 아닌 $\xi \neq 0$ 가 존재한다는 조건은 다음의 조건으로 변환될 수 있다.

$$\min_{\xi \in R} f(\xi) = -\lambda_{\min}(\mathbf{Q}) + \mu\rho + 2\gamma\sqrt{\rho} < 0 \quad (16)$$

이제 (16)의 부등식은 $\sqrt{\rho}$ 에 대한 2차 부등식으로 볼 수 있고 그 해는 다음과 같이 주어진다.

$$0 \leq \sqrt{\rho} < \frac{-\gamma + \sqrt{\gamma^2 + \mu\lambda_{\min}(\mathbf{Q})}}{\mu} \quad (17)$$




그림 4. 신경망 제어 시스템의 안정조건
Fig. 4. The stability condition of the neural network system.

주의 1.

- (1) $\sqrt{\rho} = \sqrt{\lambda_{\max}(\mathbf{W}_H^T \mathbf{W}_H)} = \|\mathbf{W}_H\|$ 는 은닉층의 연결강도 \mathbf{W}_H 에 의존하는 값이다.
- (2) \mathbf{Q} 를 항등행렬 \mathbf{I} 을 택하면 $\lambda_{\min}(\mathbf{Q})=1$ 이 된다. 또 시스템 행렬 \mathbf{A} 와 \mathbf{B} 가 주어지고 \mathbf{P} 는 $\mathbf{A}^T \mathbf{P} \mathbf{A} - \mathbf{P} = -\mathbf{I}$ 에 의해 결정되므로 $\gamma \equiv \|\mathbf{A}^T \mathbf{P} \mathbf{B} \mathbf{W}_0\|$ 와 $\mu \equiv \lambda_{\max}(\mathbf{W}_0^T \mathbf{B}^T \mathbf{P} \mathbf{B} \mathbf{W}_0) = \sigma_{\max}^2(\sqrt{\mathbf{P}} \mathbf{B} \mathbf{W}_0)$ 는 출력층의 연결강도 \mathbf{W}_0 에 의존하게 된다. 결과적으로 $\frac{-\gamma + \sqrt{\gamma^2 + \mu}}{\mu}$ 또한 출력층의 연결강도 \mathbf{W}_0 에 의존하게 된다.
- (3) $\frac{-\gamma + \sqrt{\gamma^2 + \mu}}{\mu}$ 를 $\chi(\mathbf{W}_0)$ 로 표시한다면 (17)

의 부등식은 다음의 식으로 표현된다.

$$\|\mathbf{W}_H\| < \chi(\mathbf{W}_0)$$

이는 그림 4와 같이 전체 신경망 제어 시스템 시스템의 안정도를 보장하기 위해서는 은닉층의 연결강도 \mathbf{W}_H 가 출력층의 연결강도 \mathbf{W}_0 에 의해 결정되는 $\chi(\mathbf{W}_0)$ 을 반지름으로 갖는 원의 내부에 들어와야 한다는 것을 의미한다.

2. 지수적 안정도를 보장하는 역전파 알고리즘 (BPES)

표준 역전파 알고리즘에서는 오차가 출력층에서 입력층으로 역방향으로 전해진다. 한편 전술한 바와 같이 신경망 제어 시스템의 안정도를 보장하기 위해서는 은닉층의 연결강도 \mathbf{W}_H 가 반지름이 $\chi(\mathbf{W}_0)$ 인 원안에 있어야 한다.

지수적 안정도가 보장되는 역전파 알고리즘인 BPES에서는 오차가 표준 역전파 알고리즘처럼 출력층에서 들어가지만 이 경우에도 항상 은닉층의 연결강도 \mathbf{W}_H 가 반지름 $\chi(\mathbf{W}_0)$ 인 원으로 들어오도록 유지한다. BPES의 자세한 알고리즘은 다음과 같다.

1단계 : $\Delta \mathbf{W}_0^{\text{SBP}}(k)$ 과 $\Delta \mathbf{W}_H^{\text{SBP}}(k)$ 가 표준 역전파 알고리즘에 의해 계산된다.

여기서 $\delta_i^O = u_i^{\text{des}} - u_i$ 과 $\delta_0 \equiv (\delta_1^O \ \delta_2^O \ \dots \ \delta_p^O)^T$ 로 정의하면

$$\begin{aligned} \Delta \mathbf{W}_0^{\text{SBP}}(k) &= -\eta \frac{\partial E}{\partial \mathbf{W}_0} \\ &\equiv \eta \begin{pmatrix} -\frac{\partial E}{\partial w_{11}^O} & -\frac{\partial E}{\partial w_{12}^O} & \dots & -\frac{\partial E}{\partial w_{1m}^O} \\ -\frac{\partial E}{\partial w_{21}^O} & -\frac{\partial E}{\partial w_{22}^O} & \dots & -\frac{\partial E}{\partial w_{2m}^O} \\ \vdots & \vdots & \ddots & \vdots \\ -\frac{\partial E}{\partial w_{p1}^O} & -\frac{\partial E}{\partial w_{p2}^O} & \dots & -\frac{\partial E}{\partial w_{pm}^O} \end{pmatrix} \\ &= \eta \begin{pmatrix} \delta_1^O \sigma(h_1) & \delta_1^O \sigma(h_2) & \dots & \delta_1^O \sigma(h_m) \\ \delta_2^O \sigma(h_1) & \delta_2^O \sigma(h_2) & \dots & \delta_2^O \sigma(h_m) \\ \vdots & \vdots & \ddots & \vdots \\ \delta_p^O \sigma(h_1) & \delta_p^O \sigma(h_2) & \dots & \delta_p^O \sigma(h_m) \end{pmatrix} \\ &= \eta \delta_0 \Sigma^T(\mathbf{h}) \end{aligned}$$

또 $\Delta \mathbf{W}_H^{SBP}(k) = -\eta \frac{\partial E}{\partial \mathbf{W}_H}$

$$\equiv \eta \begin{pmatrix} -\frac{\partial E}{\partial w_{11}^H} & -\frac{\partial E}{\partial w_{12}^H} & \dots & -\frac{\partial E}{\partial w_{1n}^H} \\ -\frac{\partial E}{\partial w_{21}^H} & -\frac{\partial E}{\partial w_{22}^H} & \dots & -\frac{\partial E}{\partial w_{2n}^H} \\ \vdots & \vdots & \ddots & \vdots \\ -\frac{\partial E}{\partial w_{m1}^H} & -\frac{\partial E}{\partial w_{m2}^H} & \dots & -\frac{\partial E}{\partial w_{mn}^H} \end{pmatrix}$$

$$= \eta \begin{pmatrix} \sum_{i=1}^n \delta_i^o w_{i1}^o \sigma'(h_1) x_1 & \sum_{i=1}^n \delta_i^o w_{i1}^o \sigma'(h_1) x_2 & \dots & \sum_{i=1}^n \delta_i^o w_{i1}^o \sigma'(h_1) x_n \\ \sum_{i=1}^n \delta_i^o w_{i2}^o \sigma'(h_2) x_1 & \sum_{i=1}^n \delta_i^o w_{i2}^o \sigma'(h_2) x_2 & \dots & \sum_{i=1}^n \delta_i^o w_{i2}^o \sigma'(h_2) x_n \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n \delta_i^o w_{im}^o \sigma'(h_m) x_1 & \sum_{i=1}^n \delta_i^o w_{im}^o \sigma'(h_m) x_2 & \dots & \sum_{i=1}^n \delta_i^o w_{im}^o \sigma'(h_m) x_n \end{pmatrix}$$

2 단계 :

$$\|\mathbf{W}_H(k) + \Delta \mathbf{W}_H^{SBP}(k)\| < \chi(\mathbf{W}_O(k) + \Delta \mathbf{W}_O^{SBP}(k))$$

라면

\mathbf{W}_O 과 \mathbf{W}_H 는 표준 역전파 알고리즘에 의해 조정된다.

$$\mathbf{W}_O(k+1) = \mathbf{W}_O(k) + \Delta \mathbf{W}_O^{SBP}(k)$$

$$\mathbf{W}_H(k+1) = \mathbf{W}_H(k) + \Delta \mathbf{W}_H^{SBP}(k)$$

그 외의 경우 연결강도는 다음과 같이 조정된다.

$$\mathbf{W}_O(k+1) = \mathbf{W}_O(k) + \Delta \mathbf{W}_O^{BPES}(k)$$

$$\mathbf{W}_H(k+1) = \mathbf{W}_H(k) + \Delta \mathbf{W}_H^{BPES}(k)$$

여기서

$$\Delta \mathbf{W}_O^{BPES}(k) \equiv -\eta_1 \frac{\partial E}{\partial \mathbf{W}_O} + \eta_2 \frac{\partial \chi(\mathbf{W}_O)}{\partial \mathbf{W}_O} \quad (18-1)$$

$$= \Delta \mathbf{W}_O^{SBP}(k) + \eta_2 \frac{\partial \chi(\mathbf{W}_O)}{\partial \mathbf{W}_O}$$

$$\Delta \mathbf{W}_H^{BPES}(k) \equiv -\eta_1 \frac{\partial E}{\partial \mathbf{W}_H} - \eta_2 \frac{\partial \|\mathbf{W}_H\|}{\partial \mathbf{W}_H} \quad (18-2)$$

$$= \Delta \mathbf{W}_H^{SBP}(k) - \eta_2 \frac{\partial \|\mathbf{W}_H\|}{\partial \mathbf{W}_H}$$

일반적으로 $\frac{\partial \chi(\mathbf{W}_O)}{\partial \mathbf{W}_O}$ 과 $\frac{\partial \|\mathbf{W}_H\|}{\partial \mathbf{W}_H}$ 를 해석적으로

구하는 것은 어려운 일이므로 수치적으로 구하도록 한다.

3 단계 : 1 단계와 2 단계를 조건이 만족할 때까지 반복한다.

여기서 주의할 것은 식 (18-1)과 (18-2)가 $\|\mathbf{W}_H\| < \chi(\mathbf{W}_O)$ 을 보장하지는 않는다는 것이다. 단지 두 공식은 $\chi(\mathbf{W}_O)$ 을 키우는 쪽으로 학습을 진행하여 SBP에 비하여 $\|\mathbf{W}_H\| < \chi(\mathbf{W}_O)$ 가 되도록 고안된 식이며 따라서 단계 3의 반복을 통하여 $\|\mathbf{W}_H\| < \chi(\mathbf{W}_O)$ 이 이루어지도록 하여야 한다.

V. 모의 실험

앞 장에서는 기존의 논문과 달리 과연 어떠한 신경 회로망 시스템이 어떤 플랜트와 결합할 때 안정성이 보장되는가를 다루었다. 본 장에서는 제안한 신경망 제어 시스템의 안정성에 대한 타당성을 확인하고 이를 반영한 BPES를 제어 문제에 적용한다. 제어할 시스템은 다음의 방정식으로 표현되는 Electrocraft Corporation 사의 E530 전동기 시스템이다.

$$\begin{pmatrix} \frac{di_a(t)}{dt} \\ \frac{d\omega_m(t)}{dt} \end{pmatrix} = \begin{pmatrix} -\frac{R_a}{L_a} & -\frac{K_b}{L_a} \\ \frac{K_i}{J_m} & -\frac{B_m}{J_m} \end{pmatrix} \begin{pmatrix} i_a(t) \\ \omega_m(t) \end{pmatrix} + \begin{pmatrix} \frac{1}{L_a} \\ 0 \end{pmatrix} e_a(t) \quad (19)$$

여기서 변수와 파라미터의 정의는 다음과 같다.

i_a (아마추어 전류)

ω_m (로우터의 각속도)

e_a (아마추어 전압)

K_i (토크 상수) = 10.02 oz-in/A

K_b (역 기전력 상수) = 7.41V/1000 rpm = 0.0708

V/rad/s

R_a (아마추어 저항) = 3.64 Ω

L_a (아마추어 인덕턴스) = 3.39 mH

B_m (비스코스 마찰 상수) = 0.1 oz-in./1000rpm =

9.55×10^{-4} oz-in./rad/s

J_m (로우터 관성) = 0.0038 oz-in.-s²

본 논문은 이산 시스템에 관심이 있으므로 플랜트는 샘플링 주파수 0.005초에 제로 오더 홀드로 다음과 같이 샘플링 된다.

$$\begin{pmatrix} i_a(k+1) \\ \omega_m(k+1) \end{pmatrix} = \begin{pmatrix} -0.0362 & -0.0164 \\ 2.0654 & 0.8047 \end{pmatrix} \begin{pmatrix} i_a(k) \\ \omega_m(k) \end{pmatrix} + \begin{pmatrix} 0.2313 \\ 2.7428 \end{pmatrix} e_a(k)$$

여기서 $\mathbf{x}(k) = \begin{pmatrix} x_1(k) \\ x_2(k) \end{pmatrix} = \begin{pmatrix} i_a(k) \\ \omega_m(k) \end{pmatrix}$ 또 $u(k) = e_a(k)$

이 경우 폐루프 시스템은 그림 3과 같이 신경망 제어 시스템으로 볼수 있고 제안한 BPES을 이용하여 신경망 제어기를 학습할 수 있다. 기준 모델은 제어이론에 널리 사용되는 LQR제어기를 사용하며 최소화하는 성능함수는

$$J = \sum (\mathbf{x}^T \mathbf{Q} \mathbf{x} + u^T \mathbf{R} u), \quad \mathbf{Q} = \mathbf{I}, \quad \mathbf{R} = 0.01 \mathbf{I}$$

으로 한다. 100 샘플을 원하는 기준모델로부터 만들어 BPES 200 주기 (epoches)로 돌려 성능 함수를 최소화 한다. 이 경우 신경망 부분이 플랜트와 피드백의 사이에 위치함으로 오차는 플랜트를 통과하여 신경망으로 가는 방식을 취한다^[28]. 신경망 시스템의 은닉층 노드수는 10개로 하고 따라서 결과적인 신경망 시스템은 2입력 노드 (x_1, x_2), 10 은닉 노드, 1출력 노드 (u)로 구성 되게 된다. BPES로 학습한 신경망의 연결강도는 다음과 같다.

$$\mathbf{W}_H = \begin{pmatrix} -0.0269 & -0.0165 \\ -0.0828 & -0.0255 \\ -0.0837 & -0.0258 \\ -0.1060 & -0.0313 \\ -0.0617 & 0.0332 \\ -0.0433 & 0.0031 \\ -0.0355 & 0.0166 \\ -0.0708 & -0.0445 \\ -0.0380 & 0.0199 \\ -0.0573 & -0.0357 \end{pmatrix}, \quad \mathbf{W}_O^T = \begin{pmatrix} 0.0067 \\ 0.0205 \\ 0.0251 \\ 0.0304 \\ 0.0109 \\ 0.0109 \\ 0.0080 \\ 0.0235 \\ 0.0048 \\ 0.0166 \end{pmatrix} \quad (20)$$


이 경우,

$$\begin{aligned} \|\mathbf{W}_H\| &= 0.2122 \\ \chi(\mathbf{W}_O) &= 0.5118 \end{aligned}$$


이고 이는 4장의 안정 조건을 만족하여 주어진 모터를 제어하는 신경망 제어 시스템 시스템은 지수적으로 안

정하다. 본 논문에서 제안된 방식에 의해 식 (19)의 플랜트와 식 (20)의 연결강도를 갖는 신경망으로 구성된 그 폐루프 시스템의 안정도를 보장할 수 있습니다. 이는 기존의 학습에 근거한 신경망 제어 기법으로는 안정도를 판정할 수 없는 상황이다.


그림 5는 3개의 다른 초기 값에 대하여 신경망 제어 시스템 시스템의 반응을 관찰한 것이다. 각 경우에 대하여 지수적으로 안정함을 볼 수 있다.



(a) $i_a(0) = 1$ and $\omega_m(0) = -1$



(b) $i_a(0) = 3$ and $\omega_m(0) = -2$



(c) $i_a(0) = -3$ and $\omega_m(0) = 1$

그림 5. 신경망 시스템의 응답

Fig. 5. The response of the neural-network system.

VI. 결 론


본 논문에서는 신경망 제어를 포함하고 있는 페루프 시스템이 지수적으로 안정하기 위한 조건을 제안하였다. 본 논문의 접근방식은 신경회로망 제어분야의 기존의 방법과 달리 특정 신경망 제어기가 특정 플랜트와 페루프를 형성할 때 안정 할 것인가를 판단하는 조건을 제시한 것이다. 또 지수적 안정도가 보장되는 경우 이 수렴속도를 예측하고 이 안정성을 획득할 수 있는 신경망 학습 방법을 제시하였다. 끝으로 제안한 학습방법을 신경망의 직류 진동기 제어에 적용하여 제안한 알고리즘의 타당성을 확인하였다. 그러나 본 논문에서는 비선형 신경회로망 제어 시스템의 안정도 해석을 간단히 하기 위하여 플랜트를 임의로 Hurwitz시스템으로 제약하였고 좀더 일반적 시스템을 포함한 경우에 대하여서는 Loop transform을 이용하여 추후 과제로서 연구를 진행하고 있다.

참 고 문 헌

- [1] J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proc. Nat. Acad. Sci. U.S.*, vol. 79, pp. 2554-2558, 1982.
- [2] T. Kohonen, *Self-Organization and Associative Memory*, New York: Springer-Verlag, 1984.
- [3] R. P. Lippmann, "An introduction to computing with neural nets," *IEEE ASSP Mag.*, pp. 4-22, 1987.
- [4] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing*, vol. 1. Cambridge, MA:MIT., 1986.
- [5] M. M. Gupta and D. H. Rao, Eds. *Neuro-Control Systems: Theory and Applications*. New York:IEEE, 1994.
- [6] W. T. Miller, R. S. Sutton and P. J. Werbos, Ed., *Neural Networks for Control*, Cambridge, MA: MIT Press, 1990.
- [7] K. J. Hunt, D. Sbarbaro, R. Zbikowski and P. J. Gawthrop, "Neural networks for control systems - A survey," *Automatica*, vol. 28, no. 6, pp. 1083-1112, 1992.
- [8] K. J. Hunt, G. W. Irwin and K. Warwick, Eds., *Neural Network Engineering in Dynamic Control Systems*, London: Springer-Verlag, 1995.
- [9] G. Lightbody and G. W. Irwin, "Nonlinear control structures based on embedded neural system models," *IEEE Trans. Neural Networks*, vol. 8, no. 3, pp. 553-567, 1997.
- [10] H. Miyamoto, M. Kawato, T. Setoyama and R. Suzuki, "Feedback error learning neural networks for trajectory control of a robotic manipulator," *Neural Networks*, vol. 1, pp. 251-265, 1988.
- [11] D. Nguyen and B. Widrow, "The truck backer-upper: An example of self-learning in neural networks," in *Proc. IEEE Int. Joint Conf. Neural Networks*, Washington, D.C., vol. 2, pp. 11357-11363, 1989.
- [12] L. Behera, M. Gopal and S. Chaudhury, "On adaptive trajectory tracking of a robot manipulator using inversion of its neural emulator," *IEEE Trans. Neural Networks*, vol. 7, no. 6, pp. 1401-1414, 1996.
- [13] R. M. Sanner and J. J. E. Slotine, "Gaussian network for direct adaptive control," *IEEE Trans. Neural Networks*, vol. 3, no. 6, pp. 837-863, 1992.
- [14] K. S. Narendra, "Adaptive of nonlinear multivariable systems using neural network," *Neural Networks*, vol. 7, pp. 737-752, 1994.
- [15] R. Carelli, E. F. Camacho and D. Patino, "A neural network based feedforward adaptive controller for robots," *IEEE Trans. Sys., Man, and Cyb.*, vol. 25, no. 9, pp. 1281-1288, 1995.
- [16] E. P. Teixeira, E. B. Faria and A. Breunig, "The use of feedforward neural networks to cancel nonlinearities of dynamic systems," in *Proc. IEEE Int. Joint Conf. Neural Networks*, vol. 2, pp. 767-772, 1997.
- [17] M. M. Polycarpou, "Stable adaptive neural

- control scheme for nonlinear systems," *IEEE Trans. Automatic Control*, vol. 41, no. 3, pp. 447-451, 1996.
- [18] K. Tanaka, "An approach to stability criteria of neural-network control systems," *IEEE Trans. Neural Networks*, vol. 7, no. 3, pp. 629-642, 1996.
- [19] D. B. Parker, "Optimal algorithms for adaptive networks: Second-order backpropagation, second-order direction propagation and second-order Hebbian learning," in *Proc. IEEE Int. Joint Conf. Neural Networks*, vol. 2, pp. 593-600, 1987.
- [20] Y. Iiguni, H. Sakai and H. Tokumaru, "A real-time learning algorithm for a multilayered neural network based on the extended Kalman filter," *IEEE Trans. Signal Processing*, vol. 40, no. 4, pp. 959-966, 1992.
- [21] P. C. Y. Chen and J. K. Mills, "Modeling of neural networks in feedback systems using describing functions," in *Proc. IEEE Int. Joint Conf. Neural Networks*, vol. 2, pp. 773-738, 1997.
- [22] M. E. Cotter, "The Stone-Weierstrass theorem and its applications to neural nets," *IEEE Trans. Neural Networks*, vol. 1, pp. 290-295, 1990.
- [23] K. Funahashi, "On the approximate realization of continuous mappings by neural networks," *Neural Networks*, vol. 2, pp. 183-192, 1989.
- [24] J. Villiers and E. Barnard, "Backpropagation neural nets with one and two hidden layers," *IEEE Trans. Neural Networks*, vol. 4, pp. 136-141, 1992.
- [25] S. Kuntanapreeda and R. R. Fullmer, "A training rule which guarantees finite-region stability for a class of closed-loop neural-network control systems," *IEEE Trans. Neural Networks*, vol. 7, no. 3, pp. 745-752, 1996.
- [26] C. T. Cheng, *Linear system theory and design*, 2nd ed., New York: Holt, Rinehart & Winston, 1970.
- [27] H. K. Khalil, *Nonlinear Systems*, Prentice-Hall, 1996.
- [28] D. Psaltis, A. Sideris, and A. A. Yamamura, "A multilayered neural network controller," *IEEE Control System Mag.*, vol. 8, no. 2, pp. 17-21, 1988.

 저 자 소 개



金 殷 泰(正會員)

1970년 3월 17일 생. 1992년 2월 연세 대학교 전자공학과 졸업(공학사, 전체수석). 1994년 2월 연세 대학교 대학원 전자 공학과 석사 과정 졸업 (공학석사). 1999년 2월 연세 대학교 대학원 전자공학과 박사 과정

졸업 (공학박사). 현재 국립 환경 대학교 제어계측 공학과 전임강사. 주관심분야는 지능 제어 및 모델링, 로보틱스, 비선형제어, 센서 공학 및 그 응용등임



李 義 振(正會員)

1964년 9월 10일생. 1987년 연세대학교 전자공학과 졸업. 1989년 연세대학교 대학원 전자공학과 석사과정 졸업. 1989년~1993년 (주) 대우통신 종합연구소 연구원. 1993년~1995년 (주) 에스원 종합연구소

연구원. 1998년 연세대학교 대학원 전자공학과 박사과정 졸업. 1998년~현재 국립 환경대학교 제어계측공학과 교수. 주관심분야는 로보틱스, 강인제어, 지능제어 등임



金承禹(正會員)

1961년 10월 15일 생. 1987년 연세대학교 전자공학과 졸업. 1989년 동대학원 전자공학과 졸업 (공학석사). 1989-1990년 삼성종합기술원 전임연구원. 1994년 동 대학원 전자공학과 졸업 (공학박사). 1994-1996

년 순천향 대학교 제어계측공학과 전임강사. 1998-1999년 미국 Case Western University 방문교수. 1996-현재 순천향 대학교 정보기술공학부 조교수. 주관심분야는 퍼지제어, 퍼지응용시스템, 로보틱스 및 자동화, 로봇협제어, Rapid Prototype Machine 설계

朴 玟 用(正會員) 第 32卷 B編 第 2號 參照

현재 연세대학교 전자공학과 교수