

지능형 알고리즘을 이용한 랜덤 시간지연을 갖는 네트워크 기반 시스템의 비선형 제어

Nonlinear Control of Network based Systems with Random Time Delays using Intelligent Algorithms

Hyun Cheol Cho¹, Kwon Soon Lee²

조현철¹, 이권순²

¹ 부산시 사하구 하단2동 840번지 동아대학교 전기공학과 포닥연구원

² 부산시 사하구 하단2동 840번지 동아대학교 전기공학과 교수

요 약

본 논문은 확률특성을 갖는 네트워크 기반 제어시스템(NCS; Networked Control Systems)을 위하여 동적 베이시안 네트워크(DBN; Dynamic Bayesian Networks)와 신경회로망 기법을 이용한 지능제어기법을 제안한다. 신경회로망은 시변 시간지연을 갖는 비선형 시스템의 실시간 오차를 보상하기 위한 제어기의 최적화에 적용된다. 모듈화 신경회로망이 구성되며 이것은 제어기의 파라미터를 출력한다. 가장 간단한 DBN 구조인 마코브 체인(MC; Markov Chain)이 구성되며 NCS의 랜덤 관측값을 모델링에 적용되며 예측 제어기의 구성에 또한 사용된다. 제안한 제어기법은 위성시스템의 자세제어에 적용하여 컴퓨터 시뮬레이션을 통해 성능을 검증하였다.

Key Words : Networked Control Systems, Dynamic Bayesian Networks, Markov Chain, Neural Networks

1. 서 론

NCS는 현재 산업현장에서 활발히 적용되고 있는 제어시스템 중의 하나이다. 그 이유는 대부분의 시스템은 그 규모가 크며 이런 시스템의 경우 원격제어가 매우 경제적이기 때문이다. 하지만 원격제어와 통신시스템의 사용으로 인해 발생하는 시간지연성에 관한 연구는 아직까지 활발히 진행중에 있다. 일반적으로 NCS의 시간지연은 제어성능에 크게 영향을 끼치며 특히 시스템 안정성 문제에 매우 심각한 요인중 하나이다. 따라서 NCS 시스템의 설계시 이런 시간지연 특성을 충분히 고려하여 제어기를 구성하여야 한다. 최근 이런 제어시스템에 관한 연구가 활발히 보고되고 있는 실정이다 [1]-[3].

최근에 NCS의 제어 및 안정에 대한 개관논문이 출판되고 있으며, 대부분 선형시스템에 집중을 하고 있다. 가장 간단한 NCS의 제어시스템 구성은 augment 모델을 설정하여 선형 제어기를 적용하는 방법이다[4][5]. 또한 큐잉이론을 이용하여 확률 관측기를 개발하여 예측 NCS를 제안하였으며 [6][7], 최적 확률 제어기법을 적용한 NCS를 위한 제어기를 제안하기도 하였다[8]-[10]. 일반 제어기법과는 달리 샘플링 시간을 최적의 값으로 선정하여 NCS의 제어성능을 개선한 기법도 발표되었으며[11][12], 잘 알려진 PI 선형제어기도 NCS에 적용되었다[13]. 최근엔 더욱 복잡한 구조를 갖는

NCS에 대한 고급 제어이론이 적용되었다. [14]에서 Lyapunov 안정성 이론을 적용하여 다변수 NCS의 제어시스템을 구성하였으며, [15]과 [16]에서는 선형 궤환 제어가 적용되어 만족스러운 제어성능을 보였으며, 확률모델인 마코브 체인을 통해 시간지연을 추정하여 NCS의 제어성능을 향상시키는데 사용되었다[17].

이러한 대부분의 연구들은 NCS를 선형 시불변(time-invariant), 고정 시간지연 그리고 결정론적 동특성으로 간주하였으며 이런 시스템에 대하여 만족스러운 제어성능을 가졌다 할지라도 실시간 제어시 NCS의 비선형성 및 확률특성으로 인하여 제어성능이 저하될 수 있다. 따라서 오프라인 설계단계에서 구성한 제어기의 파라미터가 실시간에서 시스템 환경에 적합한 값으로 새롭게 수정되어야 하며 이것은 곧 NCS 제어기에 적용성을 부여함으로써 해결될 수 있다[2]. 하지만, NCS의 비선형성 및 확률에 대한 동특성을 해석적 방법으로 전체를 나타내기가 어려우며 특히 시스템 환경의 변화는 설계과정에서 충분히 예측할 수 없는 요인이기도 하다. 결론적으로 복잡한 NCS에 대해 이런 문제점을 잘 해결할 수 있는 신뢰성 높은 제어기의 설계가 시급한 실정이다.

본 논문은 시변(time-varying) 시간지연과 확률특성의 관측변수를 갖는 비선형 NCS의 정밀제어를 위한 지능형 제어기법을 제안한다. 구성하는 신경회로망은 선형 궤환 제어기의 최적의 파라미터를 산출하기 위하여 사용되며 제어기의 파라미터는 공칭과 보조값으로 구성된다. 공칭 파라미터는 고정 시간지연에 대한 선형모델을 이용하여 선형시스템 이론을 통해 해석적으로 산출된다. 그러나 이 제어기는 실시간의 비선형 NCS 시스템에 대하여 적절하지 못하며 부최적(sub-optimal) 상태로 저하된다. 신경회로망으로부터 산출되는 보조 제어파라미터는 실시간에서 발생하는 제어오차를 감

접수일자 : 2007년 8월 1일

완료일자 : 2007년 10월 4일

감사의 글 : 본 논문은 한국전력공사에서 지원한 전력 변환 시스템 신기술 연구센터 (과제번호2006-0273)의 사업으로 수행되었습니다.

소하기 위한 목적으로 사용된다. 신경회로망 보조 제어기는 시변 시간지연과 확률 특성을 갖는 비선형 시스템 모델을 통해 원하는 제어성능을 발휘할 수 있을 때까지 반복학습하게 된다. 신경회로망은 비선형 IIR 필터구조를 갖는 모델로 구성하였으며, 입력벡터는 현재 및 시간지연을 갖는 시스템 오차, 피드백 출력 그리고 바이어스로 하였으며 출력신호는 제어 파라미터 행렬의 요소들을 산출한다. 또한 DBN의 가장 간단한 구조인 MC 모델을 이용하여 확률 관측변수의 동특성을 모델링하여 예측 제어를 구성하는데 이용하였다. 이 시스템에서 DBN 예측기는 발생될 출력변수를 실시간으로 추정하며 이것은 최대 확률값을 갖는 변수를 설정함으로써 이루어진다. 제안한 제어기법의 타당성을 검증하기 위하여 인공 위성시스템의 자세제어에 적용하였으며 컴퓨터 시뮬레이션을 실시하여 그 결과를 분석하였다. 또한 예측기능의 여부에 관한 제어성능의 월등한 차이 또한 비교분석하여 그 성능을 입증하였다.

본 논문의 구성은 다음과 같다. 2절에서 랜덤 시간지연을 갖는 비선형 NCS의 모델을 제시하며, 3절에서 본 논문에서 제안하는 제어시스템을 서술하며, 4절과 5절에서 DBN 모델링과 예측 신경회로망 제어시스템을 각각 제안한다. 6절에서 컴퓨터 시뮬레이션 및 그 결과를 검토하였으며, 마지막으로 7절에서 결론과 향후 연구사항을 서술한다.

2. 확률 특성을 갖는 비선형 NCS

본 논문에서 다루는 NCS 시스템은 랜덤 시간지연을 가지며 확률 특성을 갖는 상태를 가진다고 고려한다. 이런 시스템에 대한 수학적 모델은 일반적으로 다음과 같이 표현된다.

$$\begin{cases} x(k+1) = f(x, u(k-\tau_u), k) \\ y(k) = g(x, \omega, k) \\ \zeta(k) = y(k-\tau_y) \end{cases} \quad (1)$$

여기서 τ_u 와 τ_y 는 입력과 출력에 대한 시간지연을 각각 나타내며, $x \in R^n$ 은 시스템 상태를, $u, y, \zeta \in R$ 는 시스템 입력, 출력 그리고 관측변수를, f 와 g 는 시스템 상태와 출력에 대한 비선형 함수를, ω 는 가우시안 확률변수를 나타내며, 비선형 시스템에 대하여 관측값은 비가우시안 분포를 갖는다. 제어시스템에 적용되는 실제 시스템 오차는 관측값과 설정치 r 의 편차로 정의되며 $e = r - \zeta$ 로 표현된다. 본 논문에서 다루는 비선형 NCS 제어시스템의 전형적인 블록선도가 그림 1에 주어진다. 여기서 두 시간지연 τ_u 와 τ_y 는 랜덤변수로서 다음의 경계치를 갖는다고 간주한다.

$$\tau_u \in [\tau_{u,\min}, \tau_{u,\max}], \tau_y \in [\tau_{y,\min}, \tau_{y,\max}] \quad (2)$$

여기서 시스템의 안정성은 최대값 이내에서 허용된다. 즉 최대 지연시간을 넘길 경우 시스템은 불안정하므로 두 시간지연은 이 범위를 벗어나지 않는다고 가정한다. 시간지연 τ_u 와 τ_y 에 대하여 식 (2)에 평균연산자를 적용하면 다음과 같이 표현된다.

$$\tau_u = T_u - \Delta\tau_u, \quad \tau_y = T_y - \Delta\tau_y \quad (3)$$

여기서

$$\begin{aligned} T_u &:= E(\tau_u), & T_y &:= E(\tau_y) \\ \Delta\tau_u &:= E(\tau_u) - \tau_u, & \Delta\tau_y &:= E(\tau_y) - \tau_y \end{aligned} \quad (4)$$

일반적으로 랜덤변수의 평균값은 시스템 및 제어기 설계 단계에서 어느 정도 예측할 수 있는 값이지만, 섭동 (perturbation)을 갖는 시간지연의 경우 정교한 제어성능을 저하시키는 요인이 된다.




그림 1. 네트워크 기반 제어시스템의 블록선도.

3. 제어기 설계

비선형 시스템의 상태 및 출력식을 나타내는 식 (1)에서 선형과 비선형 섭동 부분을 각각 분리해서 표현하면

$$\begin{cases} x(k+1) = x^*(k+1) + \Delta x(k+1) \\ y(k) = y^*(k) + \Delta y(k) \end{cases} \quad (5)$$

이며 여기서 x^* 와 y^* 는 공칭 선형모델, Δx 와 Δy 는 비선형 섭동을 각각 나타낸다. 선형 상태변수 x^* 는 식 (4)의 고정 시간지연 T_u , 그리고 섭동 상태변수 Δx 는 $\Delta\tau_u$ 와 연관된다. 따라서 식 (5)의 상태 방정식은 다음과 같다.

$$\begin{aligned} x(k+1) &= F(x^*, u^*(k-T_u), k) \\ &\quad + \Delta f(x, u(k-\tau_u)) \end{aligned} \quad (6)$$

여기서 F 와 ΔF 는 선형 및 비선형 섭동 함수를 각각 나타내며, 마찬가지로 출력에 대한 표현도

$$y(k) = G(x^*, \omega^*, k) + \Delta g(x, \omega, k) \quad (7)$$

와 같다. 여기서 G 와 Δg 또한 선형 그리고 비선형 함수를 나타낸다. 관측값도 다음과 같이 분리하여 표현할 수 있다.

$$\zeta(k) = \zeta^*(k) + \Delta\zeta(k) \quad (8)$$

식 (1)의 관측식에 대하여

$$\zeta(k) = y^*(k-\tau_y) + \Delta y(k-\tau_y) \quad (9)$$

와 같이 전개할 수 있으며 식 (4)에 정의한 수식을 식 (9)에 적용하면 최종적으로 관측 방정식은 다음과 같이 구할 수 있다.

$$\begin{aligned} \zeta(k) &= y^*(k-T_y + \Delta\tau_y) + \Delta y(k-\tau_y) \\ &= y^*(k-T_y) + \Delta y'(k-\tau_y) \end{aligned} \quad (10)$$

위의 관계로부터 실제 관측신호 또한 공칭과 섭동출력부분으로 구성됨을 알 수 있다. 요약하면, 비선형 NCS 모델은 고정 시간지연을 갖는 공칭 선형모델과 랜덤 시간지연과 확률 특성을 갖는 비선형 섭동모델의 조합으로 구성됨을 알 수 있다. 따라서 본 논문은 이 두 동특성에 대하여 두 제어기를 각각 설계한다. 우선, 상태 피드백 제어기법을 이용하여 공칭 선형시스템에 대한 제어기를 구성한 후 실시간에서 고려되는 실제 시스템 모델에 대하여 신경회로망 최적기법을 이용하여 제어기를 수정하는 알고리즘을 설계한다. 그러므로 전체 제어입력은 공칭값과 수정값의 조합으로 이루어진다. 그림 2는 이 알고리즘의 개념도를 보여준다.




그림 2. 신경회로망 최적화를 이용한 제어파라미터의 산출.

3.1 공칭 시간지연을 갖는 선형시스템의 제어

앞서 표현한 선형시스템 모델을 상태공간 표현법을 이용하여 나타내면 다음과 같다.

$$\begin{cases} x^*(k+1) = Ax^*(k) + Bu(k - T_u) \\ y^*(k) = Cx^*(k) \\ \zeta^*(k) = y^*(k - T_y) \end{cases} \quad (11)$$

이 선형모델에 대하여 극 배치기법(pole placement)을 이용하여 상태회환 제어를 구성하며, 시간지연 변수에 대하여 $T_y = 0$ 와 $T_u \neq 0$ 그리고 T_u 와 $T_y \neq 0$ 의 두 가지 경우를 고려한 제어를 구분하여 설계하며 그 후 두 제어파라미터가 만족하는 공통 범위를 찾아서 최종 파라미터의 값으로 선정한다.

먼저, 제어기의 시간지연만을 고려할 경우, 즉 $T_y = 0$, $T_u \neq 0$ 를 고려해 보자. 우선 식 (11)에 $T_y = 0$ 을 대입하면

$$\begin{cases} x^*(k+1) = Ax^*(k) + Bu^*(k - T_u) \\ \zeta^*(k) = Cx^*(k) \end{cases} \quad (12)$$

와 같으며 다음과 같은 새로운 상태공간 모델로 표현할 수 있다 [18].

$$\begin{cases} X_c(k+1) = \Pi_c X_c(k) + \Gamma_c U_c(k) \\ Z_c(k) = \Sigma_c X_c(k) \end{cases} \quad (13)$$

여기서

$$X_c(k) = \begin{bmatrix} x^*(k) & x_{n+1}(k) & \dots & x_{n+T_u}(k) \end{bmatrix}^T$$

$$\Pi_c = \begin{bmatrix} A & B & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 0 & 1 \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 \end{bmatrix}$$

$$\Gamma_c = [0 \dots 0 \ 1]^T$$

$$\Sigma_c = [C \ 0 \ \dots \ 0]$$

이 시스템에 대하여 선형 상태피드백 제어규칙을 적용하면

$$U_c(k) = -K_c X_c(k) \quad (14)$$

으로 간단하게 나타낼 수 있으며, 이득행렬은

$$K_c = [\kappa_c \ \kappa_{c,n+1} \ \dots \ \kappa_{c,n+T_u}] \in R^{1 \times (n+T_u)} \quad (15)$$

로 주어진다. 또한 식 (14)를 식 (13)에 대입하면 새로운 상태행렬은

$$\Pi^c = \Pi_c - \Gamma_c K_c \quad (1)$$

$$= \begin{bmatrix} A & B & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 0 & 1 \\ 0 & 0 & 0 & 0 & \dots & 0 & 1 \\ -\kappa_c & -\kappa_{c,n+1} & -\kappa_{c,n+2} & -\kappa_{c,n+3} & \dots & -\kappa_{c,n+T_u-1} & -\kappa_{c,n+T_u} \end{bmatrix} \quad (6)$$

이며 이에 대한 특성방정식은

$$zI - \Pi^c = 0 \quad (17)$$

이 된다. 선형 시스템이론을 통해 $|z| < 1$ 의 조건을 만족하는 이득행렬 K_c 를 선정할 수 있다.

다음으로, 출력 지연시간이 0이 경우 즉, $T_y \neq 0$ 과 $T_u = 0$ 인 경우의 시스템 모델을 고려해보자. 마찬가지로 $T_u = 0$ 에 대한 시스템 모델은 다음과 같으며

$$\begin{cases} x^*(k+1) = Ax^*(k) + Bu(k) \\ y^*(k) = Cx^*(k) \\ \zeta^*(k) = y^*(k - \tau_y) \end{cases} \quad (18)$$

또한 [18]에 의해

$$\begin{cases} X_0(k+1) = \Pi_0(k) + \Gamma_0 U_0(k) \\ Z_0(k) = \Sigma_0 X_0(k) \end{cases} \quad (19)$$

와 같이 표현할 수도 있다. 여기서

$$X_0(k) = [x^*(k), \zeta_{n+1}(k) \dots \zeta_{n+T_y}(k)]^T$$

$$\Pi_0 = \begin{bmatrix} A & 0 & 0 & \dots & 0 & 0 \\ C & 0 & 0 & \dots & 0 & 0 \\ 0 & 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

$$\Gamma_0 = [B \ 0 \ \dots \ 0]^T$$

$$\Sigma_0 = [0 \ 0 \ \dots \ 0 \ 1]$$

마찬가지로, 상태피드백 제어규칙을 적용하면

$$U_0(k) = -K_0 X_0(k) \quad (20)$$

이며 제어이득행렬은

$$K_0 = [\kappa_o \ \kappa_{0,n+1} \ \dots \ \kappa_{0,n+T_y}] \in R^{1 \times (n+T_y)} \quad (21)$$

로 주어진다. 이 제어파라미터를 포함한 상태행렬은 최종적으로 다음과 같다.

$$\Pi^0 = \Pi_0 - \Gamma_0 K_0$$

$$= \begin{bmatrix} A - B\kappa_o & -B\kappa_{0,n+1} & -B\kappa_{0,n+2} & \dots & -B\kappa_{0,n+T_y-1} & -B\kappa_{0,n+T_y} \\ C & 0 & 0 & \dots & 0 & 0 \\ 0 & 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (22)$$

같은 방법을 통해, 다음의 특성방정식을 통해 안정한 K_0 를 결정할 수 있다.

$$zI - \Pi^0 = 0 \quad (23)$$

이 두 설계과정을 통해 두 제어조건을 만족하는 파라미터의 범위를 결정할 수 있으며 위의 방법으로 구한 해의 공통값으로 선정한다. 즉

$$K \in \{K_c \cap K_0\} \quad (24)$$

와 같이 수식으로 표현할 수 있으며 여기서 K 는 제어기와 관측기의 고정지연을 갖는 공칭모델에 적용되는 실제 제어규칙을 나타낸다.

만약, 다음의 스칼라 값을 갖는 선형모델을 고려해보자.

$$\begin{cases} x(k+1) = ax(k) + bu(k) \\ y(k) = x(k) \end{cases} \quad (25)$$

여기서 $|a| < 1$, 시간지연을 $T_u = T_y = 2$ 로 간단히 정의한다. 우선 $T_y = 0$ 에 대하여 식 (16)의 결과를 이용하면

$$\Pi^c = \begin{bmatrix} a & b \\ -\kappa_c & \kappa_{c,1} \end{bmatrix} \quad (26)$$

으로 되며 특성방정식은 다음과 같은 2차방정식으로 표현된다.

$$z^2 + (\kappa_{c,1} - a)z - a\kappa_{c,1} + b\kappa_c = 0 \quad (27)$$

이산 시스템 이론의 안정성 조건[19]을 통해 다음과 같은 파라미터의 경계치를 구할 수 있다.

$$\begin{aligned} 0 < (1+a)(1-\kappa_{c,1}) + b\kappa_c \\ 0 < 1 + a\kappa_{c,1} - b\kappa_c \\ 0 < (1-a)(1+\kappa_{c,1}) + b\kappa_c \end{aligned} \quad (28)$$

또한 $T_u = 0$ 에 대하여 식 (22)의 상태행렬은

$$\Pi^0 = \begin{bmatrix} a - b\kappa_0 - b\kappa_{0,1} & \\ 1 & 0 \end{bmatrix} \quad (29)$$

이며 특성방정식은

$$z^2 + (a - b\kappa_0)z + b\kappa_{0,1} = 0 \quad (30)$$

로 전개되며 같은 방법을 통해 다음의 안정조건을 구할 수 있다.

$$\begin{aligned} 0 < (1-a) + b(\kappa_0 + \kappa_{0,1}) \\ 0 < 1 - b\kappa_{0,1} \\ 0 < (1+a) - b(\kappa_0 - \kappa_{0,1}) \end{aligned} \quad (31)$$

이 두 제어파라미터의 조건으로부터 실제 제어기 파라미터는

$$\kappa \in \{\kappa_c \cap \kappa_0\}, \quad \kappa_1 = \{\kappa_{c,1} \cap \kappa_{0,1}\}$$

으로 정의된다.

3.2 신경회로망을 이용한 제어파라미터의 수정

앞서 설계한 공칭시스템 모델에 대한 제어시스템은 실제 비선형 시스템에 대하여 부적절하며 바람직하지 못한 제어편차를 발생시킬 수도 있다. 이런 문제점을 해결하기 위하여 본 논문에서는 신경회로망 기술을 이용하며, 학습을 통해 최적의 파라미터값을 수정한다. 신경회로망은 그림 3과 같은 비선형 IIR 필터 모듈을 가지며 파라미터 최적 동조기로 이용된다. 이 신경망은 그림 4와 같이 출력신호가 입력단으로 피드백이 되는 재귀형 모델로 구성된다. 신경망의 입력으로 시

스템 오차와 지연을 갖는 오차 그리고 바이어스로 구성되며 제어파라미터의 수정값을 출력한다. 동적 구조를 갖는 재귀형 신경망은 안정한 제어기 구성을 보장하는 장점이 있다. 그림 4의 신경망의 출력은 다음과 같이 표현된다.

$$\Delta\kappa_i = \phi_i(\omega_i E + v_i \Omega_i + b_i) \quad (32)$$

여기서 $i = 1, \dots, (n+T)$, $T := T_u = T_y$ 이며 i 번째 신경회로망의 활성화함수는

$$\phi_i = \alpha_1 \tanh(\alpha_2 \Delta\kappa_i), \quad \alpha_1, \alpha_2 > 0 \quad (33)$$

이며, 가중치 행렬은

$$\omega_i = [\omega_{i0}, \dots, \omega_{il}], \quad v_i = [v_{i1}, \dots, v_{im}] \quad (34)$$

그리고 입력벡터는

$$\begin{aligned} E &= [e(k), \dots, e(k-l)]^T, \\ \Omega_i &= [\Delta\kappa_i(k-1), \dots, \Delta\kappa_i(k-m)]^T \end{aligned} \quad (35)$$

이며 여기서 b_i 는 i 번째 신경망의 바이어스이다. 제어목적은 신경망제어기를 이용하여 실시간 시스템 오차를 감소하는 것이며 이 설정을 위하여 신경회로망 제어기 학습이 실시된다. 우선, 목적함수를

$$J = \arg \min_{\theta_i} \frac{1}{2} e^2(k) = \frac{1}{2} (r(k) - \zeta(k))^2 \quad (36)$$

와 같이 정의한 후 최적강화법을 이용하여 신경회로망의 파라미터 수정규칙을 나타내면

$$\theta_1(k+1) = \theta_1(k) - \eta \frac{\partial J}{\partial \theta_i} \quad (37)$$

이며 여기서 $i = 1, \dots, n+T$, $\eta \in (0,1)$ 는 학습파라미터이다. 미분에 대한 연쇄법칙을 이용하여 식 (37)의 편미분항을 전개하면

$$\frac{\partial J}{\partial \theta_i} = \frac{\partial J}{\partial e} \frac{\partial e}{\partial \zeta} \frac{\partial \zeta}{\partial u} \frac{\partial u}{\partial \kappa_i} \frac{\partial \kappa_i}{\partial \Delta\kappa_i} \frac{\partial \Delta\kappa_i}{\partial \theta_i} \quad (38)$$

과 같으며 여기서 각각의 미분항은

$$\frac{\partial J}{\partial \theta_i} = e \frac{\partial \zeta}{\partial u} x_i \frac{\partial \Delta\kappa_i}{\partial \theta_i} \quad (39)$$

와 같이 된다. 여기서

$$\frac{\partial \Delta\kappa_i}{\partial \theta_i} = \begin{cases} \theta'_i(\cdot) E_i, & \text{if } \theta_i = \omega_i \\ \theta'_i(\cdot) \Omega_i, & \text{if } \theta_i = v_i \\ \theta'_i(\cdot), & \text{if } \theta_i = b_i \end{cases} \quad (40)$$

이다. 또한 시스템 자코비안(Jacobian)은 직접 전개하기가 어려우며 다음과 같이 근사화식을 이용한다[20].

$$\frac{\partial \zeta}{\partial u} = \frac{\zeta(k) - \zeta(k-1)}{u(k) - u(k-1)} \quad (41)$$

최종적으로 신경회로망의 파라미터 수정규칙은 다음과 같이 전개된다.

$$\omega_i(k+1) = \omega_i(k) + \eta e \left(\frac{z(k) - z(k-1)}{u(k) - u(k-1)} \right) \phi'_i(\cdot) \zeta_1 \quad (42)$$

$$\nu_i(k+1) = \nu_i(k) + \eta e \left(\frac{z(k) - z(k-1)}{u(k) - u(k-1)} \right) \phi'(\cdot) \zeta_2 \quad (43)$$

$$b(k+1) = b(k) + \eta e \left(\frac{z(k) - z(k-1)}{u(k) - u(k-1)} \right) \phi'(\cdot) \quad (44)$$




그림 3. 신경회로망 최적화 모듈.

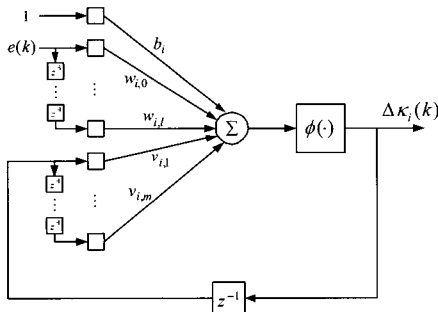


그림 4. 비선형 IIR 신경회로망 모델.

4. DBN을 이용한 시스템 모델링

이 절에서는 식 (1)의 랜덤 출력신호를 DBN 기법을 이용하여 모델링하며 예측 제어시스템의 구현에 적용된다. 2절에서 시스템 출력은 비가우시안 확률분포를 갖는다고 언급을 하였으며 DBN은 특히 이런 특성을 갖는 시스템의 모델링에 매우 적합한 알고리즘이다 [21]. DBN 모델링에 대한 이론은 [22]를 참고하였으며 특히 여러 가지 DBN 모델에서 본 논문은 가장 간단한 구조를 갖는 마코브 체인(MC; Markov Chain) 모델을 이용한다. MC 모델링에 앞서 식 (1)의 연속 시스템에 대하여 이산화(discretization)를 우선 실시한다. 즉, 시스템 관측변수에 대한 이산화는 다음과 같이 연속신호를 N 개의 이산변수로 정의하여 이루어진다.

$$\zeta(k) = \{\zeta_1(k), \zeta_2(k), \dots, \zeta_N(k)\} \quad (45)$$

이 변수에 대한 확률은

$$p(\zeta(k)) = \{p(\zeta_1(k)), p(\zeta_2(k)), \dots, p(\zeta_N(k))\} \quad (46)$$

이다. 확률공리(probability axiom)에 의해

$$\sum_{i=1}^N p(\zeta_i(k)) = 1 \quad (47)$$

의 제약조건을 가진다. 그림 5는 이 확률변수에 대한 MC 모델을 보여준다. 여기서 DBN 파라미터로서 주어지는 a_{ij} 는 $k-1$ 과 k 시간사이의 상태에 대한 조건부 확률로 정의되며

다음과 같이 표현된다.

$$a_{ij}(k) = p(\zeta_i(k) | \zeta_j(k-1)), i, j = 1, \dots, N \quad (48)$$

마찬가지로 확률공리에 의해 다음의 제약조건을 가진다.

$$\sum_{i=1}^N a_{ij}(k) = 1 \quad j = 1, \dots, N \quad (49)$$

이 DBN 파라미터 또한 학습을 통해 시스템 동특성을 충분히 표현할 수 있는 최적의 확률값을 선정해야한다[21]. 본 논문은 [22]의 DBN 파라미터 학습알고리즘을 이용하며 간단하게 이 알고리즘을 서술한다. 우선 식 (48)의 파라미터를 다음과 같은 선형조합으로 정의한다.

$$a_{ij}(k) = \alpha m_{ij}(k), \quad i, j = 1, \dots, N \quad (50)$$

여기서 m_{ij} 는 평균 가능성값, α 는 식 (49)의 제약조건을 만족하기 위한 정규화계수를 각각 나타낸다. 식 (50)은 다음의 재귀형으로 표현되며

$$m_{ij}(k) = \left(\frac{k-1}{k} \right) m_{ij}(k-1) + \left(\frac{1}{k} \right) \gamma_{ij}(k) \quad (51)$$

여기서 $i, j = 1, \dots, N$. 변수 γ_{ij} 는 다음의 수정규칙에 의해 선택된다.

$$\gamma_{ij}(k) = \begin{cases} c, & \text{if } \zeta(k) = i \text{ and } \zeta(k-1) = j \\ 0, & \text{그 외} \end{cases} \quad (52)$$

여기서 $c > 0$. 데이터의 효율적인 사용을 위해 슬라이딩 윈도우를 적용하면 식 (51)을 다음과 같이 최종적으로 표현한다.

$$m_{ij}(k) = \left(\frac{N_w - 1}{N_w} \right) m_{ij}(k-1) + \left(\frac{1}{N_w} \right) \zeta_{ij}(k) \quad (53)$$

여기서 $N_w > 0$ 이다.




그림 5. 랜덤 관측변수의 DBN 모델.

5. DBN 모델을 이용한 예측 제어시스템

그림 5의 DBN 모델로부터 확률변수는 다음과 같이 선형으로 표현할 수가 있다.

$$p(\zeta(k)) = A(k)p(\zeta(k-1)) \quad (54)$$

여기서 시변 확률행렬 $A = [a_{ij}]$, $i, j = 1, \dots, N$ 은 4절에서 서술한 학습알고리즘을 통해 결정된다. 이 상태확률은 이전의 확률벡터와 확률행렬과의 조합으로 구성된다. 이것은 초기 확률벡터 $p(z(k_0))$, $k_0 < k$ 가 주어지면 새로운 확률값은 새로운 관측데이터에 대하여 재귀적으로 산출할 수 있다. 더욱이, $A(k+i) = A(k)$, $i > 0$ 으로 가정하면 이전의 확률값을 재귀적으로 적용하여 i 번째후의 상태확률을 현재시간 k 에서 예측할 수 있다. 즉,

$$p(\zeta(k+i)) = A^{i+1} p(\zeta(k-1)), \quad i > 0 \quad (55)$$

확률의 정상상태이론[23]에 의하며, 충분히 큰 i 에 대하여, 즉 $i \rightarrow \infty$ 이면 행렬 A 의 각 요소들의 확률값은 정상상태 확률값으로 도달하며 이것은 고정값으로 된다. 본 논문은 이 이론을 시스템 상태의 예측기법에 적용한다. 즉, 식 (55)의 식을 이용하여 예측시간에 발생하는 시스템 상태를 확률적 기법을 통하여 구성한다. 이 알고리즘은 결국 다음에 정의되는 집합에서 최대 확률을 갖는 시스템 상태를 선택함으로써 얻을 수 있다.

$$s = \max \{p(\zeta_i(k+i), \dots, p(\zeta_N(k+i))\} \quad (56)$$

여기서 $i > 0$, $s \in [1, M]$, 예측 관측변수 $\hat{\zeta}$ 는 다음의 예측 시스템오차를 산출하는데 적용된다.

$$e_p(k) = r - \hat{\zeta}(k+i) \quad (57)$$

이 예측오차는 NCS의 제어성능을 향상시키는 매우 중요한 사항이 된다[2][3]. 그림 6은 본 논문에서 구성한 예측 제어시스템의 블록선도를 보여준다.




그림 6. DBN 모델을 이용한 예측 NCS의 구성.

6. 시뮬레이션 결과 및 검토

제안한 제어기법은 시간지연성을 갖는 인공위성시스템의 자세제어에 적용하였으며 컴퓨터 시뮬레이션을 통해 그 타당성 및 성능을 검증하였다. 인공 위성시스템은 지구에 대하여 최적의 신호전송을 위하여 위성자세가 매우 중요한 요인이 되며 따라서 우수한 제어성능이 절대적으로 요구된다. 또한 지구로부터의 원거리는 시간지연성을 충분히 내포하고 있어 기존의 제어방식으론 다소 힘든 점이 있었다. 본 논문은 [18]의 인공 위성시스템 모델을 이용하였으나 본 논문의 시뮬레이션 목적에 맞는 다음과 같이 수정하였다.

$$\begin{cases} x_1(k+1) = x_1(k) + T_s x_2(k) + c_1 \cos(k) \\ \quad + 0.5^2 u(k) \\ x_2(k+1) = x_2(k) + c_2 x_1(k)x_2(k) + T_s u(k) \\ y(k) = x_1(k) + c_3(k)\omega^3(k) \end{cases} \quad (58)$$

여기서 시스템 상태 x_1 과 x_2 는 위성시스템의 각도와 각속도를 각각 나타내며 T_s 는 샘플링 주기, c_1 과 c_2 는 상수, c_3 는 랜덤변수, 그리고 ω 는 가우시안 노이즈를 나타낸다. 식 (4)의 두 시간지연은 $T_u = T_y = 2$ 로 두었으며 따라서 다음의 공칭 모델을 가진다.

$$\begin{cases} \begin{bmatrix} x_1(k+1) \\ x_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & T_s \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} 0.5 T_s^2 \\ T_s \end{bmatrix} u(k-2) \\ y(k) = [1 \ 0] \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} \\ \zeta(k) = y(k-2) \end{cases} \quad (59)$$

이 시스템에 대한 제어목적은 주어진 시스템 초기상태로

부터 시스템 각도를 0으로 유지시키는 것이며 따라서 설정치는 $r=0$ 으로 정의된다. 3절에 서술한 선형제어기의 설계지침에 따라 공칭 제어행렬은 $K=[4.8, 2.1, 1.89, 0.5]$ 로 선정하였으며 신경회로망 동조기는 시변 시간지연을 갖는 비선형 시스템 모델을 이용하여 설계하였다.

우선, 결정론적(deterministic) 관측변수에 대하여 즉, 식 (58)의 $\omega=0$ 에 대하여 제어기를 구성한다. 제어행렬 K 는 1×4 의 크기를 가지므로 4개의 신경회로망 모듈이 요구되며 (그림 3 참조), 입력벡터는 다음과 같이 정의된다.

$$\begin{bmatrix} E_i(k) \\ \Omega_i(k) \end{bmatrix} = [1, e(k), e(k-1), e(k-2), \Delta \kappa_i(k-1), \Delta \kappa_i(k-2)]^T \quad (60)$$

여기서 $i=1, \dots, 4$. 신경회로망의 초기가중치는 $[-0.5, 0.5]$ 사이의 랜덤값으로 선정되며 학습률 η 는 0.75로 결정하였다. 이 초기상태로부터 신경회로망은 바람직한 제어성능을 가질 때까지 반복학습을 실시하게 된다.

그림 7은 초기상태 $x(0)=[1 \ 0]^T$ 에 대하여 신경회로망 제어를 적용하였을 경우와 그렇지 않은 경우 즉, 선형제어기만을 적용하였을 경우에 대한 시스템 응답파형을 보여준다. 이 결과로부터 신경회로망 제어기가 적용되었을 경우 월등히 제어성능이 개선되었음을 수치적으로 보여준다. 신경제어기의 경우 응답진폭이 시간에 따라서 천천히 감소함을 보여주며 신경회로망의 경우 오버슈트 등과 같은 진폭을 전혀 발생치 않음을 알 수 있다. 따라서 정상상태 도달시간 또한 선형제어기의 경우보다 훨씬 빠름을 알 수 있다. 신경회로망의 정상상태 구간에서의 무시할 만한 작은 리플은 시스템의 비선형성에 의해 발생하는 것으로 추정할 수 있다. 그림 7(b)는 두 제어기의 입력에 대한 파형을 보여주며 이 결과로부터 월등한 차이를 볼 수 있다. 즉, 초기 제어상태에서 큰 입력을 산출하며 이것은 바람직하지 못한 진동을 야기하며, 반면, 신경망 제어의 경우 아주 적합한 제어입력을 산출한다. 이것은 결국 실시간 제어의 구현에 있어 제어량의 관점에서 아주 효율적인 것으로 간주된다.

다음으로 식 (58)의 비선형 확률시스템에 대한 신경회로망 예측 제어시스템에 대한 시뮬레이션을 실시하였다. DBN 모델을 구성하기 위하여 다음과 같이 연속 관측변수를 이산화하였다.

$$\begin{cases} \zeta_1(k) = \{|\zeta(k)| > 0.2\} \\ \zeta_2(k) = \{|\zeta(k)| \in [0.2, 0.4)\} \\ \zeta_3(k) = \{|\zeta(k)| \in [0.4, 0.6)\} \\ \zeta_4(k) = \{|\zeta(k)| \in [0.6, 0.8)\} \\ \zeta_5(k) = \{|\zeta(k)| \geq 0.8\} \end{cases} \quad (61)$$

식 (58)의 출력 방정식에서 c_3 는 항등(uniform) 확률변수로 하였고 $\omega(k)$ 는 평균값 0과 랜덤하게 변하는 분산(variance)을 갖는 비정치(non-stationary) 가우시안으로 정의하였다. 이 시스템 환경하에 신경회로망 예측 제어기에 대한 시뮬레이션을 실시하였으며 예측기능이 없는 기존의 신경회로망 제어기와 성능을 비교하였다. 그 외의 것은 앞서 실시한 시뮬레이션의 환경과 동일한 조건으로 하였다.


그림 8은 두 제어기법에 대한 시스템 응답 파형을 보여준다. 예측기능이 없는 신경망의 경우 큰 제어편차가 발생됨을 알 수 있으며 이것은 시스템 출력의 비정치성 확률특성에 의한 것으로 추정된다. 반면 본 논문에서 제안한 예측 신경망 제어는 정상상태에서 거의 0에 가까운 시스템 응답을 보여준

다. 이 결과로부터 예측 신경망의 우수한 제어성을 자명하게 확인할 수 있으며 만족스럽게 동작함을 알 수 있다. 그림 8(b)는 제어입력을 각각 보여주며 예측제어의 경우 안정한 입력상태에 도달함을 알 수 있다.

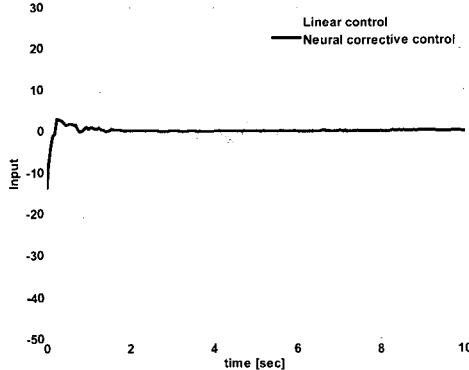
7. 결 론

본 논문은 시변 시간지연성을 갖는 네트워크 기반 확률 비선형 시스템에 대한 신경회로망 제어기법을 제안하였다. 재귀형 신경망 모듈이 상태 궤환 제어기의 파라미터 행렬의 최적화를 위하여 구성되었다. 제안한 제어기법은 비선형 인공위성 시스템의 자세제어에 적용되었으며 컴퓨터 시뮬레이션을 통해 성능을 검증하였고 그 타당성을 분석하였다.

향후 연구계획으로는 보다 복잡한 다변수 구조를 NCS 시스템에 적용할 예정이며 실시간 실험을 통하여 산업현장의 적용가능성을 제시하고자 한다. 또한 제안한 온라인 제어알고리즘에 대한 안정성 검증을 해석적 방법으로 실시하며, 기존의 비선형 제어시스템과의 비교분석을 통하여 성능의 우수성을 한층 더 입증하고자 한다.




(a) 시스템 응답.




(b) 제어입력

그림 7. 시뮬레이션 결과(신경회로망 및 선형제어기의 비교).



(a) 시스템 응답.



(b) 제어입력

그림 8. 시뮬레이션 결과(비예측 및 예측 신경회로망 제어기의 비교).

참 고 문 헌

- [1] T. C. Yang, "Networked control systems: a brief survey," *IEEE Proc.-Control Theory and Applications*, vol. 153, no. 4, pp. 403-412, 2006.
- [2] Y. Jianyong, Y. Shimin, and W. Haiqing, "Survey on the performance analysis of networked control systems," *IEEE Int. Conf. on System, Man & Cybernetics*, pp. 5068-5073, 2004.
- [3] Y. Tipsuwan and M.-Y. Chow, "Control methodologies in networked control systems," *Control Engineering Practice*, vol. 11, pp. 1099-1111, 2003.
- [4] Y. Halevi and A. Ray, "Integrated communication and control systems: Part I - analysis," *J. of Dynamic Systems, Measurement and Control*, vol. 110, pp. 367-373, 1988.
- [5] L.-W. Liou and A. Ray, "Integrated communication and control systems: Part III - nonidentical sensor and controller sampling," *J. of Dynamic Systems, Measurement and Control*, vol. 112, pp. 357-364, 1990.
- [6] R. Luck and A. Ray, "Experimental verification of a delay compensation algorithm for integrated

communication and control systems," *Int. J. of Control*, vol. 59, no. 6, pp. 1357-1372, 1994.

[7] H. Chan and U. Ozguner, "Closed-loop control of systems over a communications network with queues," *Int. J. of Control*, vol. 62, no. 3, pp. 493-510, 1995.

[8] J. Nilsson, *Real-time control systems with delays*, Ph.D. dissertation, Lund Institute of Technology, 1998.

[9] G. C. Walsh, O. Beldiman, and L. Bushnell, "Error encoding algorithms for networked control systems," *Proc. of the IEEE Conf. on Decision and Control*, vol. 5, pp. 4933-4938, 1996.

[10] F. Goktas, *Distributed control of systems over communication networks*, Ph.D. dissertation, University of Pennsylvania, 2000.

[11] S. H. Hong, "Scheduling algorithm of data sampling times in the integrated communication and control systems," *IEEE Trans. on Control Systems Technology*, vol. 3, no. 2, pp. 225-230, 1995.

[12] S. H. Hong and W.-H. Kim, "Bandwidth allocation scheme in CAN protocol," *IEEE Proc.-Control Theory and Applications*, vol. 147, no. 1, pp. 37-44, 2000.

[13] N. B. Almutairi, M.Y. Chow, and Y. Tipsuwan, "Network-based controlled DC motor with fuzzy compensation," *The 27th annual conf. of the IEEE Industrial Electronics Society*, vol. 3, pp. 1844-1849, 2001.

[14] G. C. Walsh, O. Beldiman, and L. Bushnell, "Asymptotic behavior of nonlinear networked control systems," *IEEE Trans. on Automatic Control*, vol. 46, no. 7, pp. 1093-1097, 2001.

[15] L. A. Montestruque and P. J. Antsaklis, "On the model-based control of networked systems," *Automatica*, vol. 39, pp. 1837-1843, 2003.

[16] D. Yue, Q.-L. Han, and C. Peng, "State feedback controller design of networked control systems," *IEEE Trans. on Circuits and Systems*, vol. 51, no. 11, pp. 640-644, 2004.

[17] L. Zhang, Y. Shi, T. Chen, and B. Huang, "A new method for stabilization of networked control systems with random delays," *IEEE Trans. on Automatic Control*, vol. 50, no. 8, pp. 1177-1181, 2005.

[18] G. F. Franklin, J. D. Powell, and M. L. Workman, *Digital Control of Dynamic Systems*, Prentice Hall, 1997.

[19] S. K. Mitra, *Digital signal processing*, New York, McGraw Hill, 2006.

[20] M. Saerens and A. Soquet, "Neural controller based on back-propagation algorithm," *IEE Proceedings - F*, vol. 138, no. 1, pp. 55-62, 1991.

[21] K. Murphy, *Dynamic Bayesian networks: Representation, Inference and Learning*, Ph. D. Dissertation, University of California-Berkeley, 2002.

[22] Hyun C. Cho and M. Sami Fadali, "Online estimation of dynamic Bayesian network parameter," *IEEE World Congress on Computational Intelligence*, pp. 6395-6402, 2006.

[23] A. Papoulis and S.U. Pillai, *Probability, Random variables and stochastic processes*, McGraw-Hill, 2002.

저 자 소 개



조현철(Cho, Hyun Cheol)

1997년 2월 : 부경대학교 제어계측공학과 졸업(공학사)

1999년 2월 : 동아대학교 전기공학과 졸업(공학석사)

2006년 8월 : 미국 네바다 대학교 전기공학과 졸업(Ph.D.)

2006년 8월~현재 : 동아대 전기공학과 제어 및 시스템 연구실 포닥연구원

관심분야 : 제어시스템, 신경회로망, 베이지안 네트워크, 확률 프로세스

Tel : 051) 200-6950

Fax : 051) 200-7743

E-mail : hyunccho@gmail.com



이권순(Lee, Kwon Soon)

1973년 : 충남대 졸업(공학사)

1997년 : 서울대 대학원 전기공학과 졸업(석사)

1990년 : 미국 오레곤 주립대 전기 및 컴퓨터공학과 졸업(Ph.D.)

1982년~현재 : 동아대학교 전기공학과 교수

관심분야 : 자동제어, 항만물류시스템, 의용생체시스템

Tel : 051) 200-7739

Fax : 051) 200-7743

E-mail : kslee@dau.ac.kr