

네트워크 기반 시간지연 시스템을 위한 리셋 제어 및 확률론적 예측기법을 이용한 온라인 학습제어시스템

Online Learning Control for Network-induced Time Delay Systems using Reset Control and Probabilistic Prediction Method

조현철, 심광열, 이권순*

(Hyun Cheol Cho, Kwang Yeul Sim, and Kwon Soon Lee)

Abstract: This paper presents a novel control methodology for communication network based nonlinear systems with time delay nature. We construct a nominal nonlinear control law for representing a linear model and a reset control system which is aimed for corrective control strategy to compensate system error due to uncertain time delay through wireless communication network. Next, online neural control approach is proposed for overcoming nonstationary statistical nature in the network topology. Additionally, DBN (Dynamic Bayesian Network) technique is accomplished for modeling of its dynamics in terms of causality, which is then utilized for estimating prediction of system output. We evaluate superiority and reliability of the proposed control approach through numerical simulation example in which a nonlinear inverted pendulum model is employed as a networked control system.

Keywords: networked control systems, random time delay, dynamic Bayesian networks, reset control, inverted pendulum system

I. 서론

최근 무선 통신네트워크 기술이 급속히 발전하여 이러한 기술을 적용한 산업시스템들이 꾸준히 개발되고 있다. 그 대표적인 예가 네트워크 기반 제어시스템 (NCS: Networked Control Systems) 또는 모니터링 및 고장진단 시스템을 들 수가 있다[1]. 그 중 NCS는 원거리의 플랜트를 통신기술을 이용하여 시스템을 제어함으로서 복잡하게 구성되어 있는 산업시스템이 분산제어가 용이하며 시스템 관리가 매우 효율적인 장점이 있다[2].

일반적으로 NCS의 구현에서 고려하여야 할 중요한 사항은 통신 매체상의 문제로 인한 제어시스템 성능의 저하를 최소화하는 기술이다. 통신 네트워크로 인한 주된 문제는 통신채널의 협소한 대역폭, 데이터 패킷의 누락, 그리고 채플링 및 시간지연 등이 있으며[3], 최근 이러한 문제점들을 해결하기 위한 다양한 제어기술들이 발표되고 있다.

무선 네트워크로 인한 데이터 전송의 시간지연은 제어시스템의 안정성에 직접적인 영향을 미치므로 이에 대한 고급제어기술이 요구되고 있다. 현재까지 NCS를 위한 여러 가지 새로운 제어기법들이 발표되고 있으며, 최근에는 Lyapunov 이론, LMI (Linear Matrix Inequality) 또는 passivity와 같은 고급시스템이론을 이용한 방법론이 발표되고 있다 [4-7]. 이러한 연구는 시간지연을 갖는 시스템 모델에 대하여 강한 안정한 제어조건을 해석적 방법론을 적용하여 제어전략을 도출하는 기술들이다.

또한 신경회로망이나 퍼지이론과 같은 지능형 알고리즘을 이용하여 확률 및 시변 시간지연을 갖는 네트워크 기반 시스템의 새로운 제어기법도 발표되었다[8,9]. 이는 주로 시간지연 변수를 불확실성 요소로 간주하여 새로운 NCS의 동적 모델을 개발하거나, 소프트 연산기법을 통해 제어시스템을 설계 또는 파라미터 추정기로 구성하였다.

한편, 결정론적(deterministic) 방법이 아닌 확률 및 통계학적 기법을 이용한 제어방법론도 발표되고 있다[8,10-12]. 이는 주로 Markov 모델(MC)이나 은닉 Markov 모델(HMM)을 이용하여 NCS를 확률론적 방법으로 모델링하거나 시스템의 동특성을 해석하는데 사용하였다. 이와 같은 연구의 대부분은 시간지연 변수를 일정한 경계치를 갖는 확률변수로 정의하여, 기존의 확률론적 모델링 기법을 이용하여 해석적인 제어해법을 도출하는데 사용되었다.

이제까지의 NCS 연구는 선형 시스템을 고려하는 경우가 대부분이며, 비선형 시스템의 경우 선형화과정을 통해 시스템 모델을 근사화하여 선형시스템이론을 적용하는 경우가 많다. 한편, 통신네트워크 시스템은 비정치(nonstationary) 확률특성을 갖지만, 대부분의 경우 결정론적 방법으로 시스템을 모델링 및 제어기 설계를 하는 것이 대부분이다. 이러한 경우 시스템 설계에서 고려하지 못한 확률성분으로 인하여 실시간제어에서 시스템 오차가 발생하여 정밀한 제어시스템을 구현하기가 어렵다. 또한 확률론적 방법으로 NCS를 다루었다 할지라도 정치성(stationary)의 가우시안 신호로 간주하며, 비선형 시스템의 경우 그 확률특성이 변화하여 예상치 못한 동특성이 발생하여 시스템 전체 성능이 저하되는 경우가 발생한다.

본 논문은 비선형 및 비정치 확률특성을 갖는 네트워크 기반 시스템에 대한 새로운 제어시스템을 제안한다. 원거리의 비선형 플랜트는 상태 피드백 기법을 이용하여 공칭제

* 책임저자(Corresponding Author)

논문접수: 2009. 5. 20., 수정: 2009. 6. 30., 채택확정: 2009. 7. 7.

조현철: 울산과학대학 전기전자학부 조교수(hcjo@mail.uc.ac.kr)

심광열: 울산과학대학 전기전자학부 교수(kysim@mail.uc.ac.kr)

이권순: 동아대학교 전기공학과 교수(kslee@dau.ac.kr)

※ 본 논문은 2009학년도 동아대학교 학술연구비에 의하여 연구되었음

어기를 구성하며 보조제어기로서 리셋(reset) 제어기법을 설계한다. 리세트 보조제어기는 신경회로망 온라인 제어기법을 이용한 하이브리드 제어구조로 구성되며, 네트워크의 시간지연 특성으로 인해 발생하는 제어오차를 보상하기 위한 제어목적을 갖는다. 또한, 동적 베이시안 네트워크(DBN: Dynamic Bayesian Network) 기술을 이용하여 확률특성의 NCS를 모델링하며 이를 통해 예측 출력을 산출하여 예측제어시스템을 구성한다. 컴퓨터 시뮬레이션을 통해 본 논문의 제어기법에 대한 타당성을 검증하며 성능의 우수성을 입증하기 위하여 최근에 발표된 참고문헌 [4]의 제어시스템 또한 시뮬레이션을 실시하여 그 결과를 비교 분석하였다.

본 논문의 구성은 다음과 같다. II 장에서 비선형 NCS에 대한 수학적 모델링을 서술하며, III 장에는 제안하는 제어 시스템의 설계과정을 기술하며, IV 장에는 DBN 모델링과 예측제어시스템을 제안하며, V 장에는 컴퓨터 시뮬레이션 및 그 결과분석을, 그리고 마지막 VI 장에는 결론과 향후 연구내용을 각각 서술한다.

II. 비선형 NCS의 수학적 모델링

본 논문에서 고려하는 통신 네트워크 기반 시간지연 시스템의 제어시스템 블록선도는 그림 1과 같다. 여기서 제어 입력 $u(t)$ 는 제어기에서 산출되는 시스템 입력으로서 τ_u 의 지연시간 후에 원거리에 위치한 플랜트의 스칼라 입력 $u(t-\tau_u)$ 로 적용되며, 시스템 출력 $y(t)$ 는 플랜트의 센서로부터 τ_y 시간 후에 제어기에 전달된다. 이러한 두 시간지연은 무선통신 네트워크 매체로 인하여 발생되어지며, 일반적으로 τ_u 는 제어시간지연 그리고 τ_y 는 관측시간지연이라 한다. 본 논문은 원거리 플랜트를 비선형 시스템으로 간주하며, 그림 1에 대한 시스템 방정식은 다음과 같다.

$$\begin{cases} \dot{x}(t) = f(x, t) + g(x, t)u(t-\tau_u) \\ y(t) = Cx(t) + w_x(t) \\ z(t) = y(t-\tau_y) \end{cases} \quad (1)$$

여기서 $x \in R^N$ 은 시스템 상태, $y \in R$ 는 센서로부터 관측된 시스템 출력, 그리고 $z \in R$ 는 지연된 시스템 관측변수를 나타내며, $w_x \in R$ 은 비정치 가우시안 입력변수를 각각 나타낸다. 또한 $C \in R^{1 \times N}$ 는 관측행렬을, $f(\cdot), g(\cdot) \in R^N$ 은 비선형 함수를 각각 나타낸다.

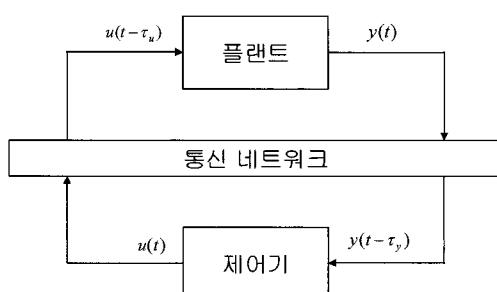


그림 1. 네트워크 기반 제어시스템의 블록선도.

Fig. 1. A block diagram of networked control systems.

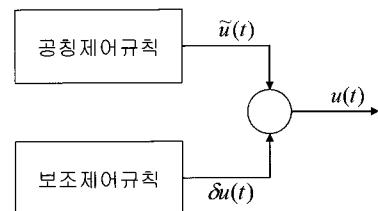


그림 2. 공칭 및 보조제어시스템의 개념도.

Fig. 2. Schematic diagram of nominal and auxiliary control.

그림 1에서, 시간 t 에서 생성된 제어입력 $u(t)$ 가 최적의 제어값으로 가정하고, 이 값은 원거리의 플랜트에 도달할 때는 $u(t-\tau_u)$ 가 되며, 만약 $\dot{u}(t) \neq 0$ 일 경우 $u(t) \neq u(t-\tau_u)$ 이므로 $u(t-\tau_u)$ 는 더 이상 최적의 값이 아니며 따라서 부최적(suboptimal)의 제어입력 값으로 된다. 한편, 플랜트 측면에서 고려한 지연된 입력변수를 $u_d(t) := u(t-\tau_u)$ 와 같이 정의하자. 현재시간 t 에서 플랜트에 인가되어야 하는 최적의 제어입력을 $u^*(t)$ 라고 가정한 후, 이 값은 부최적 제어입력 $u_d(t)$ 와 섭동 입력변수 $\delta u_d(t)$ 의 선형조합으로 표현하면 $u_d^*(t) = u_d(t) + \delta u_d(t)$ 와 같다. 이 관계식으로부터, 만약 u_d 가 최적의 제어입력이라면 $\delta u = 0$ 이 되며, 그렇지 않은 경우 섭동변수 $\delta u \neq 0$ 로서 최적의 입력과 실제 입력과의 편차로 표현된다는 것을 알 수 있으며 즉, $\delta u_d(t) = u^*(t) - u_d(t)$ 와 같이 주어진다. 따라서 현재 입력값 $u_d(t)$ 가 최적의 값이 아닐 경우 보조 입력값 $\delta u_d(t)$ 을 추가함으로서 최적값을 만들 수 있다는 것을 의미한다. 한편, 이러한 관계식으로부터 $u_d^*(t) = u(t-\tau_u) + \delta u(t-\tau_u)$ 와 같이 표현할 수 있으며 여기서 $u(t-\tau_u)$ 와 $\delta u(t-\tau_u)$ 는 제어시스템 측면에서 본 시간지연 이전의 입력변수 $\tilde{u}(t)$ 와 $\delta u(t)$ 에 대응된다. 따라서 제어기에서 생성되는 제어입력 $u(t)$ 또한 다음과 같이 선형조합의 형태로 표현된다.

$$u(t) = \tilde{u}(t) + \delta u(t) \quad (2)$$

두 제어변수 $\tilde{u}(t)$ 와 $\delta u(t)$ 는 각각의 독립된 제어규칙을 가지며, 두 입력값의 합으로서 최종 제어입력 $u(t)$ 가 산출된다. 한편, $\tilde{u}(t)$ 는 공칭(nominal) 제어변수로서, 시간지연을 고려하지 않은 시스템에 대하여 제어규칙을 가지며, 보조제어변수로서 $\delta u(t)$ 는 시간지연특성으로 인한 제어오차를 보상하기 위하여 구성된다(그림 2 참조).

III. 제어시스템 설계

1. 공칭 제어시스템

II 장에서 언급한 바와 같이 공칭제어시스템은 제어 및 관측 시간지연을 고려하지 않은 시스템 모델을 이용하여 제어규칙을 산출한다. 우선, 시간지연이 없는 시스템 상태 방정식을 표현하기 위하여 식 (2)의 제어변수를 식 (1)에 적용하여 나타내면 다음과 같다.

$$\dot{x}(t) = f(x, t) + g(x, t)\tilde{u}(t) + g(x, t)\delta u(t) \quad (3)$$

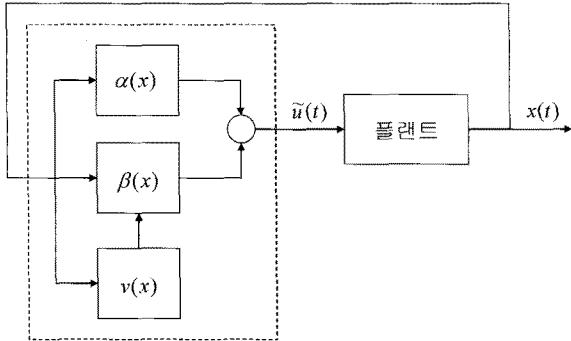


그림 3. 상태피드백기법을 이용한 공정제어시스템의 블록선도.
Fig. 3. A block diagram of the nominal control system with state feedback method.

한편 식 (3)의 주어진 비선형 상태방정식에 대하여 상태 피드백 기법[13]을 이용하여 제어변수 \tilde{u} 에 대한 제어규칙을 정의하면 $\tilde{u}(t) = \alpha(x, t) + \beta(x, t)v(x, t)$ 와 같으며 여기서 $\alpha(\cdot)$ 와 $\beta(\cdot)$ 는 상태변수 $x(t)$ 에 대한 비선형 함수를, v 는 선형함수로서 각각 주어진다. 이 제어규칙을 식 (3)에 대입하여 전개하면

$$\dot{x}(t) = f(x, t) + g(x, t)\alpha(x, t) + g(x, t)\beta(x, t)v(x, t) + g(x, t)\delta u(t) \quad (4)$$

가 된다. 피드백 선형화이론[13]에 의해 식 (4)의 제어함수 α, β, v 를 적절하게 설정하여 비선형 함수를 선형으로 나타낼 수 있다고 가정하면, 식 (4)는 $\dot{x}(t) = Fx(t) + g(x, t)\delta u(t)$ 와 같은 선형 미분방정식으로 나타낼 수 있다. 여기서 $F \in R^{N \times N}$ 는 선형 상태행렬을 나타낸다. 요약하면, 앞서 정의한 비선형 공정제어함수 \tilde{u} 는 식 (3)의 비선형 모델을 선형시스템 모델로 근사화하기 위하여 구성되어진다. 그림 3은 이러한 제어시스템에 대한 블록선도를 보여준다.

2. 리세트 제어시스템

식 (4)에서 보조제어변수 $\delta u(t)$ 는 리세트 제어기법을 적용하여 구성한다. 리세트 제어는 선형 미분방정식으로 정의되며 제어기 설계가 보다 간편한 특징이 있으며 또한 정상 상태응답에서 우수한 제어성능을 가지는 것으로 알려져 있다[14]. 본 논문에서 고려하는 리세트 제어시스템의 동적모델은 다음과 같다.

$$\begin{cases} \dot{\zeta}(t) = A\zeta(t) + e(t) \\ \delta u(t) = \begin{cases} \Gamma\zeta(t) + \Phi\gamma(t), & \text{if } e(t) \neq 0 \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (5)$$

여기서 $\zeta \in R^M, \gamma \in R^L$ 은 상태 및 입력벡터를, 그리고 $e \in R$ 는 시스템오차변수를 나타낸다. 또한 $A \in R^{M \times M}, \Gamma \in R^{1 \times M}, \Phi \in R^{1 \times L}$ 는 해당 행렬을 각각 나타내며, 주어진 제어사양에 맞도록 최적의 요소값을 제어기 설계과정에서 결정하여야 한다. 리세트 제어시스템의 주요 제어방식은 정상상태응답에서 제어오차가 0이면 제어입력 값을 0(또는 reset)으로 설정하며, 그렇지 않은 경우 즉 정상상태 오차가 발생하는 경우, 식 (5)의 두 번째 제어규칙에 의하여 제어입력을 산출하는 메커니즘으로 이루어져 있다. 식 (5)의 제

어규칙을 3.1절에 언급한 선형화 방정식에 적용하면 다음과 같은 augment 형태의 상태방정식으로 표현된다.

$$\begin{aligned} \dot{x}(t) &= Fx(t) + g(x, t)\Gamma\zeta(t) + g(x, t)\Phi\gamma(t) \\ \dot{\zeta}(t) &= A\zeta(t) + e(t) \end{aligned} \quad (6)$$

여기서 제어기의 동적 특성만을 다루기 위하여 리세트 상태인 $\delta u(t) = 0$ 인 경우는 고려하지 않는다. 한편, 식 (6)에서 제어오차 $e(t)$ 는 제어기 측면에서 고려한 시스템오차로서 기준값 r 과 지연된 시스템출력 $y(t - \tau_y)$ 에 대한 편차로서 정의되며, 즉 식 (1)로부터 $e(t) = r - y(t - \tau_y) = r - Cx(t - \tau_y)$ 와 같다. 여기서 결정론적 변수만 우선 다루기 위하여, $w_x = 0$ 으로 두었다. II 장에서 정의한 바와 같이, 마찬가지로 지연된 상태 $x(t - \tau_y)$ 를 제어기 측면에서 본 변수로 정의하면 $x_d(t) := x(t - \tau_x)$ 와 같으며, 또한 이 변수는 현재의 시스템 상태 $x(t)$ 와 섭동변수 $\delta x(t)$ 의 선형 합으로 주어진다고 가정하면 $x_d(t) = x(t) + \delta x(t)$ 와 같이 표현되어진다. 따라서 이 두 관계식을 이용하여 앞서 정의한 제어오차 $e(t)$ 를 다시 표현하면 $e(t) = r - Cx(t) - C\delta_x(t)$ 와 같다. 이 관계식으로부터 시간지연이 적용되지 않는 경우에는 $x_d = x$ 이므로 $\delta x = 0$ 이 되지만, NCS의 경우 $x_d \neq x$ 이므로 $|\delta x(t)| > 0$ 가 항상 발생하여 시스템 오차에 영향을 미치는 불확실성 변수로 작용한다. 다음으로, 이 제어오차변수를 식 (6)에 적용하여 상태방정식으로 표현하면

$$\begin{aligned} \dot{x}(t) &= Fx(t) + g(x, t)\Gamma\zeta(t) + g(x, t)\Phi\gamma(t) \\ \dot{\zeta}(t) &= A\zeta(t) - Cx(t) - C\delta_x(t) + r \end{aligned} \quad (7)$$

와 같다. 한편, 식 (7)의 첫 번째 방정식에서 행렬 Γ 와 Φ 를 적절히 선택하여 $g(x, t)\Gamma$ 와 $g(x, t)\Phi$ 의 연산결과를 선형행렬로 만들어질 수 있다고 가정하면 식 (7)은 다음과 같이 표현할 수 있다.

$$\begin{aligned} \dot{x}(t) &= Fx(t) + \tilde{\Gamma}\zeta(t) + \tilde{\Phi}\gamma(t) \\ \dot{\zeta}(t) &= A\zeta(t) - Cx(t) - C\delta_x(t) + r \end{aligned} \quad (8)$$

여기서 $\tilde{\Gamma} = g(x, t)\Gamma \in R^{N \times M}, \tilde{\Phi} = g(x, t)\Phi \in R^{N \times L}$ 은 각각 선형행렬을 나타낸다. 식 (8)의 미분방정식을 벡터형태로 나타내면

$$\begin{bmatrix} \dot{x}(t) \\ \dot{\zeta}(t) \end{bmatrix} = \begin{bmatrix} F & \tilde{\Gamma} \\ -C & A \end{bmatrix} \begin{bmatrix} x(t) \\ \zeta(t) \end{bmatrix} + \begin{bmatrix} \tilde{\Phi} \\ 0 \end{bmatrix} \gamma(t) + \begin{bmatrix} 0 \\ -C\delta_x(t) + r \end{bmatrix} \quad (9)$$

와 같다. 식 (9)에서 우선 $\delta x(t) = 0$ 으로 간주한 후 기존의 선형시스템 이론을 적용하여 안정한 상태행렬을 설정할 수 있으며, 따라서 $t \rightarrow \infty$ 일 때 상태 $x(t)$ 및 $\zeta(t)$ 가 평형점 (equilibrium point)으로 수렴하는 동특성을 기대할 수 있다. 다시 말해 안정한 상태행렬의 구성은 행렬의 고유치의 실수부가 모두 음수를 갖도록 행렬요소 $F, \tilde{\Gamma}, C, A$ 의 적절한 선택을 의미하며 수식으로 표현하면 다음과 같다.

$$Re\left\{\lambda\left(\begin{bmatrix} F & \tilde{\Gamma} \\ -C & A \end{bmatrix}\right)\right\} < 0 \quad (10)$$

여기서 λ 는 행렬의 고유치를 나타낸다. 한편, 식 (9)의

$\delta x(t)$ 는 불확실성의 시변 섭동변수로 정의할 수 있으며, 이는 실시간 시스템 구현에서 제어성능을 저하시킬 수 있는 요소이다. 이러한 문제를 해결하기 위하여 식 (9)의 보조제어변수 $\gamma(t)$ 를 온라인 제어시스템으로 구성하여 실시간을 통해 제어오차를 보상할 수 있다.

3. 신경회로망 온라인 제어시스템

식 (9)의 보조제어변수는 신경회로망 구조를 갖는 제어시스템으로 구성한다. 신경회로망 제어시스템은 온라인 학습이 가능하며 시스템 환경의 변화에도 적응제어능력이 탁월한 기능을 가지고 있다. 본 논문에서 구성하는 신경회로망 제어기는 단층 퍼셉트론(perceptron)의 구조를 가지며(그림 4 참조), 출력방정식은 $\gamma = \phi(W\sigma)$ 와 같다. 여기서 $\sigma = [1 \ e \ \dot{e}]^T \in R^3$ 은 신경회로망 입력벡터, $W = \{w_{ij}\} \in R^{L \times 3}$ 은 신경회로망 파라미터 행렬, 그리고 $\phi(\cdot) \in R^L$ 은 비선형 시그모이드 함수를 나타내며 $\phi_i = a \tanh(b\psi_i)$, $i = 1, \dots, L$ 으로 주어지며 여기서 a 와 b 는 scaling 상수이며 $\psi_i = w_i \sigma$ 로 표현되며 그리고 w_i 는 행렬 W 의 i 번째 열벡터로서 $w_i = \text{col}\{w_{i1}, \dots, w_{i3}\}$ 로 표현된다. 신경회로망 제어시스템이 최적의 제어성능을 발휘하기 위하여, 신경회로망 파라미터 행렬 W 의 요소들을 주어진 시스템 환경에 대하여 학습 알고리즘을 통해 최적의 값으로 선정하여야 한다. 본 논문은 최급강하(the steepest gradient descent) 기반 최적화 기법[15]을 통한 신경회로망 제어시스템의 학습알고리즘을 도출한다. 우선, 목적함수는 다음과 같은 자승오차로 정의되며, 신경망 제어기의 학습은 이 오차함수를 감소하는 목적으로 이루어진다.

$$J = \frac{1}{2}e^2 = \frac{1}{2}(r - z)^2 \quad (11)$$

잘 알려진 기존의 최급강하 알고리즘을 적용하면, 위의 신경회로망 파라미터의 수정규칙은

$$w_i(t_k) = w_i(t_k-1) - \eta \frac{\partial J}{\partial w_i}, \quad i = 1, \dots, L \quad (12)$$

와 같이 전개되며, 여기서 $\eta \in (0,1)$ 은 학습파라미터, t_k 는 학습시간을 나타낸다. 식 (12)에서 각각의 편미분항은 미분의 연쇄법칙을 이용하여 다음과 같이 전개할 수 있으며

$$\frac{\partial J}{\partial w_i} = \frac{\partial J}{\partial e} \frac{\partial e}{\partial z} \frac{\partial z}{\partial \gamma_i} \frac{\partial \gamma_i}{\partial \psi_i} \frac{\partial \psi_i}{\partial w_i} \quad (13)$$

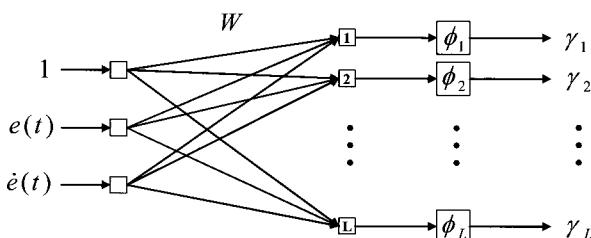


그림 4. 단층 퍼셉트론 구조의 신경회로망 제어시스템.

Fig. 4. A neural network control system with single-layer perceptron.

각각의 편미분항은

$$\begin{aligned} \frac{\partial J}{\partial e} &= r - z, \quad \frac{\partial e}{\partial z} = -1, \\ \frac{\partial z}{\partial \gamma_i} &\approx z(t_k) - z(t_k-1)/\gamma_i(t_k) - \gamma_i(t_k-1), \\ \frac{\partial \gamma_i}{\partial \psi_i} &= \partial \gamma_i / \partial \psi_i = ab(1 - \tanh^2(b\psi_i)), \quad \frac{\partial \psi_i}{\partial w_i} = \sigma \end{aligned}$$

와 같다. 여기서 $\frac{\partial z}{\partial \gamma_i}$ 는 시스템 Jacobian으로서 해석적 방법을 통해 쉽게 구할 수 없으므로, 신경회로망 제어입력의 변화분과 시스템 관측값의 변화분에 대한 비율로 이루어진 근사식으로 표현하였다[16]. 위의 결과식을 식 (12)에 대입하여 정리하면 신경회로망 파라미터의 수정규칙은 최종적으로 다음과 같다.

$$w_i(t_k) \approx w_i(t_k-1) + \eta ab(r-z)(1-\tanh^2(b\psi_i)) \times \left\{ \frac{z(t_k)-z(t_k-1)}{\gamma_i(t_k)-\gamma_i(t_k-1)} \right\} \sigma \quad (14)$$

한편, 온라인 학습알고리즘의 실현을 위하여 그리고 보다 빠른 수렴특성을 위하여 식 (14)의 학습파라미터 η 를 시스템 오차에 대한 함수로 정의하여 적응형 변수로 구성할 수 있으며 다음과 같다[17].

$$\eta(t_k) = \eta(t_k-1) - \epsilon(e) \eta(t_k-1)^2 \quad (15)$$

여기서 $\epsilon(e)$ 는 오차에 대한 사용자 함수를 나타낸다.

IV. DBN 기반 예측시스템

1. DBN 모델링

DBN은 그래프이론과 확률 및 통계이론을 이용하여 동적 시스템의 인과관계(causality)를 확률분포로서 나타내는 통계학적 모델링 기법이다. 본 논문은 그림 1의 네트워크 기반 제어시스템에서 시스템 입력 u 및 상태 x 그리고 관측 z 에 대하여 인과관계를 확률로서 나타낸다. 이러한 확률변수의 인과성을 표현하기 위하여, 시스템 상태는 입력에 인과관계를 가지므로 입력변수에 대한 함수관계로 표현할 수 있으며, 시스템 관측은 마찬가지로 시스템 상태에 대한 함수관계를 갖는다는 것을 알 수 있다. 한편, 시스템 상태는 원거리 플랜트에 대한 직접 변수로서 관측이 되지 않는 은너(hidden) 변수로 간주할 수 있으며, 시스템 입력 또는 관측값은 가관측 변수로서 정의할 수 있다. 이러한 확률변수에 대한 인과관계는 DBN의 일종인 input-output HMM[18]으로 표현할 수 있으며 그림 5와 같다. 여기서 $X(k)$, $Z(k)$, $U(k)$ 는 이산시간 변수를 나타내며, 연속시간 변수 $x(t)$,

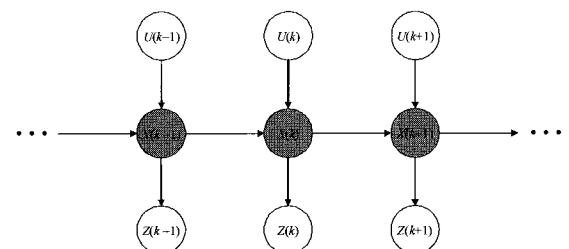


그림 5. Input-Output DBN 모델(○: 가관측변수, ●: 은너변수).

Fig. 5. A input-output DBN model(○: observation variables, ●: hidden variable).

$z(t)$, $u(t)$ 에 대한 이산화 변수로서 $X = \{x_1, x_2, \dots, x_{N_1}\}$, $Z = \{z_1, z_2, \dots, z_{N_2}\}$, $U = \{u_1, u_2, \dots, u_{N_3}\}$ 와 같이 정의된다. 이 변수들에 대한 확률은 $P(X(k) = x_i)$, $i = 1, \dots, N_1$, $P(Z(k) = z_i)$, $i = 1, \dots, N_2$, $P(U(k) = u_i)$, $i = 1, \dots, N_3$ 와 같으며 확률의 공리(axiom)에 의해 $\sum_{i=1}^{N_1} P(X(k) = x_i) = \sum_{i=1}^{N_2} P(Z(k) = z_i) = \sum_{i=1}^{N_3} P(U(k) = u_i) = 1$ 의 제약조건을 갖는다. 또 다른 확률분포로서 DBN의 파라미터로 주어지는 확률변수 사이의 조건부확률분포는 다음과 같다.

$$\theta(i, j, m) := P(X(k) = x_i | X(k-1) = x_j, U(k) = u_m), \quad i, j = 1, \dots, N_1, \quad m = 1, \dots, N_3 \quad (16a)$$

$$\phi(i, j) := P(Z(k) = z_i | X(k) = x_j), \quad i = 1, \dots, N_2, \quad j = 1, \dots, N_1 \quad (16b)$$

여기서 마찬가지로 $\sum_{i=1}^{N_1} \theta(i, j, m) = \sum_{i=1}^{N_2} \phi(i, j) = 1$ 이다. 식 (16)의 조건부확률 또는 DBN 파라미터는 시스템의 이산화변수들 사이의 인과관계를 확률론적으로 나타내는 것으로 그 확률값은 학습알고리즘을 통해 최적의 값으로 결정되어야 한다.

2. DBN의 하이브리드 학습

DBN 파라미터 학습은 식 (16)에 정의된 조건부 확률분포를 관측 데이터 집합을 이용하여 최적의 값으로 결정하는 과정이다. 일반적으로 신경회로망의 학습과 비슷한 과정을 거치지만 신경회로망의 오차역전파 학습의 경우처럼, 널리 사용되고 있는 학습 알고리즘은 현재까지는 없는 실정이다. 하지만, ML (Maximum Likelihood)나 EM (Expectation-Maximization)과 같은 확률론적 기반 추정알고리즘을 DBN의 파라미터 학습에 적용하는 사례가 늘고 있다[19]. 일반적으로 ML 및 EM 기반 DBN 학습은 최적값을 찾는 과정에서 국부해(local solution)에 빠질 수 있는 단점과 수학적 전개가 복잡하여 온라인 학습규칙으로 구성하는데 한계가 있는 것으로 알려져 있다[19].

한편, 참고문헌 [20]에서 비정치 및 비가우시안 통계 특성을 갖는 동적 시스템에 대한 온라인 학습알고리즘을 제안하였으며, 이는 수학적 전개가 보다 용이할 뿐만 아니라 연산량도 적어 실시간 구현에 매우 적합한 알고리즘으로 보고되고 있다. 본 논문은 4.1절에서 구성한 DBN 모델의

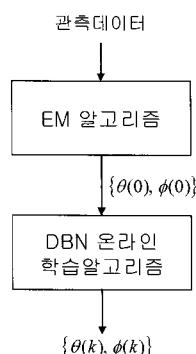


그림 6. DBN의 하이브리드 학습기법.

Fig. 6. A hybrid learning process for the DBN.

파라미터 학습을 위하여 기존의 EM 기법과 참고문헌 [20]에서 제안한 학습알고리즘을 사용한 하이브리드 형태의 학습과정을 이용한다. 즉, EM 알고리즘은 관측한 데이터 집합을 통해 오프라인 학습에 사용되고, 그 후 오프라인에서 추정한 파라미터 값을 초기값으로 하여 실시간 구현에서는 참고문헌 [20]의 온라인 학습기법을 적용하여 DBN의 파라미터를 수정한다. 이러한 하이브리드 형태의 학습기법에 대한 불록선도는 그림 6과 같다.

3. 평균 출력 추정

본 절은 4.1절에서 구성한 DBN 모델을 통해 시스템 관측값을 확률론적 방법을 이용하여 추정하는 수학적 과정을 서술한다. 우선 식 (16a)에 베이시안 이론[21]을 적용하여 전개하면 다음과 같다.

$$P(X_i(k) | X_j(k-1), U_m(k))$$

$$= \frac{P(X_j(k-1) | X_i(k), U_m(k)) P(X_i(k) | U_m(k))}{P(X_j(k-1) | U_m(k))} \quad (17)$$

여기서 보다 간편한 수학적 표현을 위하여 $X_i(k) := \{X(k) = x_i\}$, $Z_n(k) := \{Z(k) = z_n\}$, $U_m(k) := \{U(k) = u_m\}$ 와 같이 정의한다. 위의 제약조건을 만족하기 위하여 식 (17)의 분모를 정규화 계수 α 로 두면

$$\begin{aligned} & P(X_i(k) | X_j(k-1), U_m(k)) \\ &= \alpha P(X_j(k-1) | X_i(k), U_m(k)) P(X_i(k) | U_m(k)) \end{aligned} \quad (18)$$

와 같다. 한편, 확률변수 $X_j(k-1)$ 와 $U_m(k)$ 는 통계학적으로 독립이므로 식 (18)에서 $P(X_j(k-1) | X_i(k), U_m(k)) = P(X_j(k-1) | X_i(k))$ 와 같으며 마찬가지로 베이시안 이론을 적용하면 $P(X_j(k-1) | X_i(k)) = \alpha P(X_i(k) | X_j(k-1)) \times P(X_j(k-1))$ 와 같다. 이 결과식을 식 (18)에 적용하면 최종적으로 다음과 같다.

$$\begin{aligned} & P(X_i(k) | X_j(k-1), U_m(k)) \\ &= \alpha P(X_i(k) | X_j(k-1)) P(X_j(k-1)) P(X_i(k) | U_m(k)) \end{aligned} \quad (19)$$

한편 확률이론에 의하여 상태 X 에 대한 확률식은

$$\begin{aligned} P(X_i(k)) &= \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} P(X_i(k) | X_j(k-1), U_m(k)) \\ &\quad \times P(X_j(k-1), U_m(k)), \quad i = 1, \dots, N_1 \end{aligned} \quad (20)$$

와 같이 연산되어진다. 마찬가지로 $X_j(k-1)$ 와 $U_m(k)$ 는 통계학적으로 상호독립이므로 최종적으로 다음과 같다.

$$\begin{aligned} P(X_i(k)) &= \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \alpha P(X_i(k) | X_j(k-1)) P(X_j(k-1))^2 \\ &\quad \times P(X_i(k) | U_m(k)) P(U_m(k)), \quad i = 1, \dots, N_1 \end{aligned} \quad (21)$$

다음으로, 식 (16b)로부터 관측변수 Z 에 대한 확률식은

$$P(Z_i(k)) = \sum_{j=1}^{N_1} P(Z_i(k) | X_j(k)) P(X_j(k)), \quad i = 1, \dots, N_2 \quad (22)$$

와 같으며 식 (21)의 결과식을 대입하여 전개하면 이산출력 Z_n 에 대한 확률은 다음과 같이 전개된다.

$$\begin{aligned} P(Z_n(k)) &= \sum_{l=1}^{N_1} P(Z_n(k)|X_l(k)) \\ &\times \left\{ \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \alpha P(X_l(k)|X_j(k-1)) P(X_l(k)|U_m(k)) \right. \\ &\quad \left. \times P(X_j(k-1))^2 P(U_m(k)) \right\}, \\ n &= 1, \dots, N_2 \end{aligned} \quad (23)$$

이 결과로부터 출력변수 $Z(k)$ 의 평균치는 다음과 같다.

$$\begin{aligned} \bar{Z}(k) &= \sum_{n=1}^{N_2} z_n P(Z_n(k)) \\ &= \sum_{n=1}^{N_2} z_n \left\{ \sum_{l=1}^{N_1} P(Z_n(k)|X_l(k)) \right. \\ &\quad \left. \left\{ \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \alpha P(X_l(k)|X_j(k-1)) \right. \right. \\ &\quad \left. \left. \times P(X_l(k)|U_m(k)) \right. \right. \\ &\quad \left. \left. \times P(X_j(k-1))^2 P(U_m(k)) \right\} \right\} \end{aligned} \quad (24)$$

여기서 z_i 는 이산화 과정에서 정의되는 연속 출력변수 $z(t)$ 에 대한 이산값으로 주어진다.

4. 예측 제어시스템

식 (21)의 현재 시간 k 에서 상태 X 의 확률식은 두 조건부 확률분포 $P(X(k)|X(k-1))$ 와 $P(X(k)|U(k))$ 그리고 이전의 상태확률 $P(X(k-1))$ 및 현재의 입력확률 $P(U(k))$ 로 표현됨을 알 수 있다. 이 두 조건부 확률분포가 일정하다고 가정하면 상태확률은 재귀형(recursive) 형태로 연산이 이루어질 수 있다. 예를 들어, 식 (21)로부터 $P(X(k))$ 의 결과식을 이용하여, 예측시간 $k+1$ 의 상태 X 의 확률 $P(X(k+1))$ 의 추정식은

$$\begin{aligned} \hat{P}(X_i(k+1)) &= \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \alpha P(X_i(k)|X_j(k-1)) \\ &\times P(X_i(k)|U_m(k)) P(X_j(k))^2 P(U_m(k)) \end{aligned} \quad (25)$$

와 같이 나타낼 수 있으며 또한 $k+2$ 에서의 추정확률은 식 (25)를 통해 다음과 같이 전개할 수 있다.

$$\begin{aligned} \hat{P}(X_i(k+2)) &= \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \alpha P(X_i(k)|X_j(k-1)) P(X_i(k)|U_m(k)) \\ &\times \hat{P}(X_j(k+1))^2 P(U_m(k)) \\ &= \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \left\{ \alpha P(X_i(k)|X_j(k-1)) \right. \\ &\quad \left. \times P(X_i(k)|U_m(k)) P(U_m(k)) \right\} \\ &\quad \left\{ \sum_{l=1}^{N_1} \sum_{n=1}^{N_3} \alpha P(X_i(k)|X_l(k-1)) \right. \\ &\quad \left. \times P(X_i(k))^2 P(X_l(k)|U_n(k)) \right\} \end{aligned} \quad (26)$$

이러한 재귀형 관계식을 일반화 식으로 나타내기 위하여 식 (21)의 오른쪽 항을

$$\begin{aligned} F_{k-1}(P(X_i(k-1)))^2 &:= \sum_{j=1}^{N_1} \sum_{m=1}^{N_3} \alpha P(X_i(k)|X_j(k-1)) \\ &\times P(X_j(k-1))^2 P(U_m(k)) P(U_m(k)) \end{aligned} \quad (27)$$

와 같이 두면, $k+h$ ($h > 0$)에서의 상태 X 에 대한 추정 확률식은 다음과 같이 표현된다.

$$\hat{P}(X_i(k+h)) = F_{k+h-1}(F_{k+h-2} \cdots (F_k(P(X_i(k))^h))) \quad (28)$$

한편, 식 (28)을 식 (22)에 대입하여 h 단계 이후의 예측 출력확률을 추정할 수 있으며 다음과 같다.

$$\begin{aligned} \hat{P}(Z_i(k+h)) &= \sum_{j=1}^{N_1} P(Z_i(k)|X_j(k)) \hat{P}(X_j(k+h)) \\ &= \sum_{j=1}^{N_1} \left\{ P(Z_i(k)|X_j(k)) \times F_{k+h-1} \right. \\ &\quad \left. \times (F_{k+h-2} \cdots (F_k(P(X_i(k))^h))) \right\} \end{aligned} \quad (29)$$

따라서 예측 평균 출력은 마찬가지로 다음과 같이 나타낼 수 있으며

$$\begin{aligned} \hat{\bar{Z}}(k+h) &= \sum_{i=1}^{N_2} z_i \hat{P}(Z_i(k+h)) \\ &= \sum_{i=1}^{N_2} z_i \left\{ \sum_{j=1}^{N_1} \left\{ P(Z_i(k)|X_j(k)) \times F_{k+h-1} \right. \right. \\ &\quad \left. \left. \times (F_{k+h-2} \cdots (F_k(P(X_i(k))^h))) \right\} \right\} \end{aligned} \quad (30)$$

이 결과식은 기준값 r 에 대한 예측 오차를 정의할 수 있으며 다음과 같다.

$$e_p = r - \hat{\bar{Z}}(k+h) \quad (31)$$

이 예측오차는 III 장의 신경회로망 제어기의 입력신호로 적용하여 예측제어시스템으로 구성할 수 있다. 그림 7은 DBN 모델을 통해 확률론적 기법을 이용하여 산출하는 시스템의 예측오차의 평균값 추정에 대한 알고리즘을 보여준다.

한편, 그림 8은 본 논문에서 제안하는 제어시스템에 대한 전체 블록선도를 나타낸다. 앞서 도출한 공청 및 리세트 제어기 그리고 DBN 기반 온라인 신경회로망 제어입력이 각각 독립적으로 산출된 후 그 조합이 전체 제어입력으로 인가된다. 요약하면, 공청제어시스템은 시간지연성을 고려하지 않은 모델에 대한 제어규칙이며, 리세트 제어기법은 시간지연성을 보상하기 위한 제어시스템이며, 신경회로망은

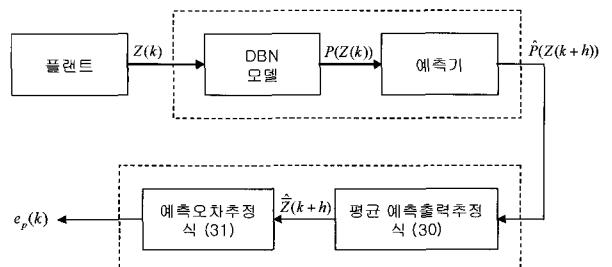


그림 7. DBN 모델기반 예측제어시스템.

Fig. 7. Predictive control system with the DBN model.

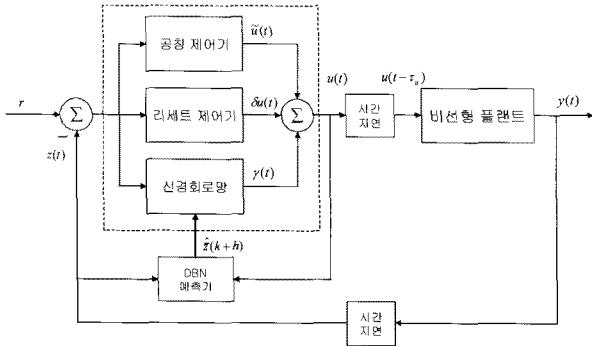


그림 8. 본 논문에서 제안한 제어시스템의 전체 블록선도.
Fig. 8. A block diagram of the proposed NCS.

실시간 제어오차를 보상하기 위한 제어기로 각각 구성된다. 또한 리세트와 신경망 제어는 보조제어기로서 정밀제어성능을 달성하기 위해 부가적으로 추가되어 진다.

V. 컴퓨터 시뮬레이션

본 논문에서 제안한 제어시스템의 성능평가를 위하여 컴퓨터 시뮬레이션을 실시하였다. 시뮬레이션에 이용한 플랜트는 비선형성이 매우 강한 역진자 시스템으로 하였으며 제어 및 관측지연을 적용하기 위하여 각각의 변수에 시간지연 변수를 적용하였으며, 시스템 모델은 다음과 같다.

$$\begin{cases} \dot{x}_1(t) = x_2 \\ \dot{x}_2(t) = -\sin(x_1 + 0.05) + \sin(0.05) - x_2 + u(t - \tau_u) \\ y(t) = x_1 + w_x \\ z(t) = y(t - \tau_y) \end{cases} \quad (32)$$

여기서 시스템의 초기상태는 $x_1(0) = \pi$, $x_2(0) = 0$ 으로 설정하였으며, 노이즈 신호는 비정치 가우시안으로서 $w_x \sim N(0, \mu(t))$ 와 같으며 여기서 분산 μ 는 0.01과 0.05 사이의 항등분포(uniformly distributed)를 갖는 확률변수로 하였다. 또한 시변 시간지연을 구현하기 위하여 시간지연 변수 τ_u 와 τ_y 를 0.01초와 0.3초 사이의 항등분포의 확률변수로 설정하였다. 여기서 최대 시간지연 0.3초는 MATI (Maximum Allowable Transfer Interval)[22]의 조건을 만족하는 값으로서 시스템이 안정하기 위한 경계치를 의미한다.

우선 3.1절의 공정제어기 설계에 따라 주어진 시스템 모델에 대하여 공정제어규칙을 다음과 같이 정의하였다.

$$\tilde{u} = \sin(x_1 + 0.05) - \sin(0.05) - 50x_1 - x_2 \quad (33)$$

한편 II 장에서 언급한 바와 같이 $u(t - \tau_u) = \tilde{u}(t) - \delta u(t)$ 이므로 식 (33)의 제어식을 식 (2)에 적용하면 다음의 선형모델로 표현된다.

$$\begin{cases} \dot{x}_1(t) = x_2 \\ \dot{x}_2(t) = -50x_1 - 2x_2 + \delta u(t) \\ y(t) = x_1 + w_x \\ z(t) = y(t - \tau_y) \end{cases} \quad (34)$$

이 상태방정식에 대한 리세트 제어시스템 모델은 다음과 같다.

$$\begin{cases} \dot{\zeta}(t) = -0.5\zeta(t) - z(t) \\ \delta u(t) = \begin{cases} \zeta(t) + \gamma(t), & \text{if } z(t) \neq 0 \\ 0, & \text{otherwise} \end{cases} \end{cases} \quad (35)$$

여기서 상태행렬은 1행 1열의 스칼라로 정의하였으며 행렬 요소는 식 (10)의 조건을 만족하는 값으로 설정하였다. 마지막으로 3.3절의 신경회로망 제어기는 다입력(multi-input) 및 단출력(single-output)의 단층 퍼셉트론으로 구성하였으며 출력방정식은 $\gamma = \phi(w_1 + ew_2 + ew_3)$ 와 같으며 여기서 신경망 파라미터의 초기값은 $\{w_1(0), w_2(0), w_3(0)\} \in [-1, 1]$ 으로서 항등분포의 확률변수 값으로 설정하였다. 또한 DBN 모델링을 위하여 연속시간 출력변수를 다음의 이산화 변수로 정의하였다.

$$Z(k) = \{z_1, z_2, z_3, z_4\} \quad (36)$$

여기서 각 변수에 대한 정의는 다음과 같다.

$$\begin{cases} z_1 = \{z : |z| \in [0, 0.5]\} \\ z_2 = \{z : |z| \in [0.5, 1]\} \\ z_3 = \{z : |z| \in [1, 2]\} \\ z_4 = \{z : |z| \in [2, \infty]\} \end{cases} \quad (37)$$

앞서 언급한 바와 같이 DBN의 파라미터 학습법은 기존의 EM 알고리즘과 참고문헌 [20]에서 제안한 기법을 이용한 하이브리드 형태로 실시하였다.

시뮬레이션의 전체 제어시간은 20초로 하였으며 12초에 임펄스 외란을 인가하여 제어기의 강인성 또한 분석하였다. 제어시스템의 목적은 역진자의 각도를 설정한 초기상태에서 0으로 하는 것으로서, 본 논문에서 제안하는 제어시스템 외에 기존의 상태궤환 제어기법 또한 시뮬레이션을 실시하여 성능을 비교분석하였다. 한편, 비교 시뮬레이션에 적용한 상태궤환 제어시스템의 구성을 참고문헌 [4]의 설계지침을 이용하였다.

그림 9는 두 제어시스템에 대한 시스템 응답을 동시에 보여준다. 우선 기존의 상태궤환 제어의 경우 약 4초까지 과도응답을 가지며 초기에 최대 오버슈트가 발생하여 그 진동이 감소하는 것을 볼 수 있다. 제안한 제어시스템의 경우도 마찬가지로 초기에 최대 오버슈트가 발생하지만 상대적으로 그 진폭이 작은 것을 관측할 수 있다. 즉, 오버슈트

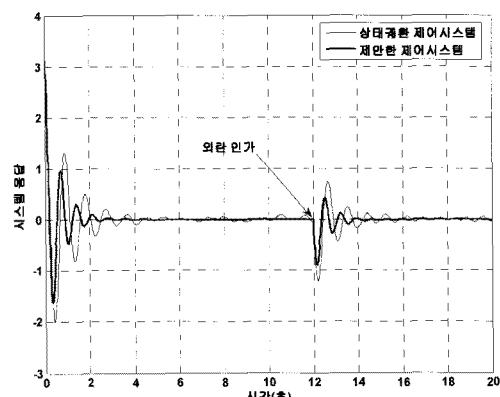


그림 9. 두 제어시스템에 대한 시스템 응답파형.

Fig. 9. System response waveform for the two control methods.

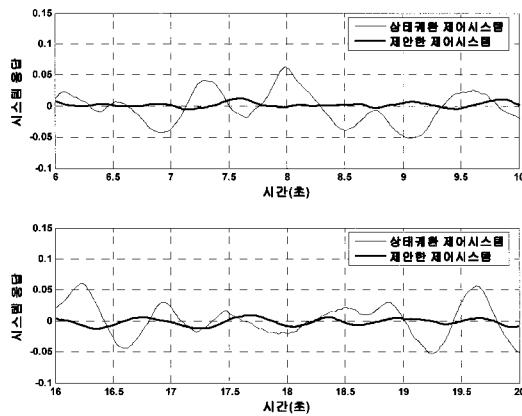


그림 10. 제어시간 [6, 10]초와 [16, 20]초의 시스템 응답.

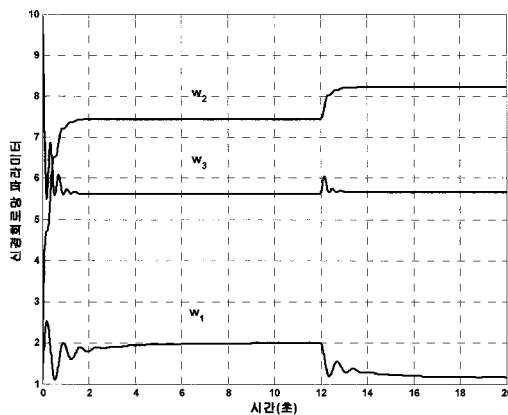
Fig. 10. System response during $t=[6, 10]$ and $[16, 20]$.

그림 11. 신경회로망 파라미터 수정과정.

Fig. 11. Update of the neural network parameters.

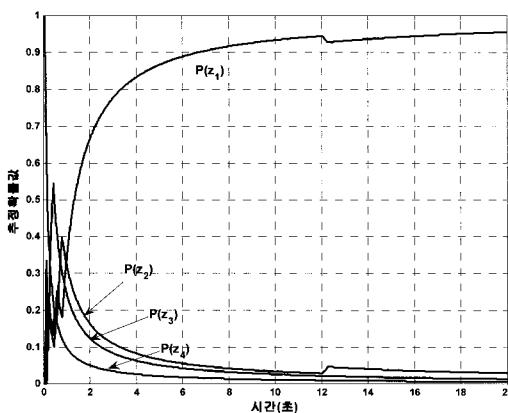


그림 12. DBN 모델 기반 시스템 출력의 확률분포 추정과정.

Fig. 12. Probability distribution estimation of system output by the DBN.

의 크기가 상태궤환 제어기의 보다 약 40% 정도 감소하였으며 정상상태 도달시간도 약 2.4초로서 60% 정도 개선되었다. 한편 정상상태 응답면에서도 상태궤환의 경우 0에 완전히 수렴하지 못하고 어느 정도의 크기를 갖는 리플현상을 보이고 있다(그림 10 참조). 제안하는 제어의 경우도 리

플현상은 있지만 상태궤환의 경우보다 현저히 작은 진폭을 갖는 것을 명백히 알 수 있다. 이러한 리플은 시스템의 노이즈에 의한 자연적인 현상으로 간주된다.

12초에 임펄스 외란을 인가한 경우의 두 제어성능 또한 현저한 차이가 있음을 알 수 있다. 제안한 제어기의 경우 외란이 인가된 초기에 큰 오차진폭을 가지지만 상태궤환의 경우 보다는 작은 것을 알 수 있으며 정상상태로 복귀하는 시간도 약 2초 후로서 약 14초인 상태궤환 제어의 경우보다 성능이 우수함을 알 수 있다. 상태궤환의 경우는 외란이 없는 경우 보다 오히려 정상상태 도달시간이 3배 정도 늘어났으며 이는 외란에 대한 제어성능이 매우 떨어진다는 것을 의미하며, 반면 본 논문의 제어성능은 외란에 대한 강인성이 우수함을 알 수 있다.

그림 11은 신경회로망 제어기의 파라미터 수정파형을 보여준다. 제어 초기시간과 외란이 인가된 제어구간에서는 파라미터 값의 수정이 크게 이루어졌으며 이는 시스템 환경에 대한 제어기의 적응성을 잘 보여준다. 한편 w_2 와 w_3 의 경우는 제어초기상태 및 외란인가 후 약 2초 내에 정상상태 값으로 수렴하지만 w_1 의 경우 5초 가량에서 수렴함을 알 수 있다. 이러한 현상은 정밀한 제어성능을 위하여 파라미터 학습이 계속 이루어진다는 것으로 분석된다.

그림 12는 DBN 모델로부터 추정된 식 (37)의 이산출력 변수의 확률값을 보여준다. 여기서 시스템의 절대값 출력이 0.5보다 작은 확률인 $P(z_1)$ 의 값은 과도응답에서 서서히 증가하여 약 7초에서부터 확률값이 0.9에 도달함을 알 수 있다. 이는 시스템 출력이 이 시간이후에는 설정치 0의 값에 가까운 정도를 나타내며, 외란이 인가한 12초에 확률값이 약간 감소되었지만 그 후에는 다시 증가함을 알 수 있다. 반대로 나머지 확률분포는 초기에 가장 큰 값을 가지지만 정상상태 응답으로 진입할수록 확률값들이 서서히 감소함을 알 수 있다.

VI. 결론

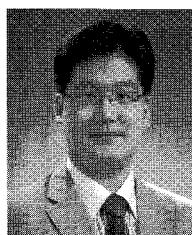
본 논문은 확률론적 모델링 및 신경회로망 기법을 이용하여 네트워크 기반 제어시스템을 위한 새로운 제어방식을 제안하였다. 본 논문에서 제안한 제어시스템은 공칭제어, 리세트 제어 그리고 신경회로망 제어시스템의 3개의 독립된 제어규칙을 가지며 각 제어시스템 입력의 선형조합은 전체 시스템의 제어입력으로 인가된다. 또한 DBN 기술을 이용하여 시스템을 확률 모델링을 실시하여 예측 제어기를 구성하였다. 컴퓨터 시뮬레이션을 통해 제어시스템의 타당성을 검증하였으며 기존의 제어시스템과 비교분석하여 성능의 우수성을 입증하였다. 시뮬레이션 실험을 통해 본 논문은 과도응답에서 보다 작은 오버슈트와 빠른 정상상태 도달시간을 확인할 수 있었으며 외란의 입력에 대해서도 월등히 우수한 제어성능을 발휘하였으며, 전체적으로 제안한 제어시스템의 우수성을 입증하였다.

향후 연구계획은 제안한 제어시스템의 실적용 가능성 및 그 타당성을 검증하기 위하여 실시간 실험을 위한 test-bed을 이용하여 성능을 분석하고자 한다. 또한 본 논문에서 제안한 DBN 모델링은 원거리 시스템의 고장검출 및 모니터

링 시스템 구현에 적용하여 고신뢰성의 시스템 진단기법을 개발하고자 한다.

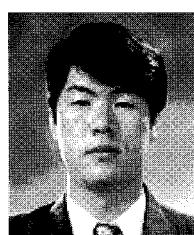
참고문헌

- [1] 조현철, 여대연, 이권순, 이오경, “무선통신네트워크 기반 산업설비의 모니터링 시스템 구축에 관한 고찰,” 대한전기학회 전기설비전문위원회 춘계학술대회, pp. 142-148, 2009.
- [2] T. C. Yang, “Networked control system: a brief survey,” *IEEE Proc.-Control Theory Appl.*, vol. 153, no. 4, pp. 403-412, 2006.
- [3] J. P. Hespanha, P. Naghshtabrizi, and Y. Xu, “A survey of recent results in networked control systems,” *Proc. of the IEEE*, vol. 95, no. 1, pp. 138-162, 2007.
- [4] B. Tang, G-P. Liu, and W.-H. Gui, “Improvement of state feedback controller design for networked control systems,” *IEEE Trans. on Circuits and Systems-II: Express briefs*, vol. 55, no. 5, pp. 464-468, 2008.
- [5] D. Yue, Q.-L. Han, and C. Peng, “State feedback controller design of networked control systems,” *IEEE Trans. on Circuits and Systems-II: Express briefs*, vol. 51, no. 11, pp. 640-644, 2004.
- [6] N. Kottenstette, X. Koutsoukos, and P. Antsaklis, “Passivity-based design of wireless networked control systems for robustness to time-varying delays,” *Real-Time Systems Symposium*, pp. 15-24, 2008.
- [7] H. Gao, T. Chen, and T. Chai, “Passivity and passification for networked control systems,” *SIAM J. Control Optimization*, vol. 46, no. 4, pp. 1299-1322, 2007.
- [8] H. C. Cho and K. S. Lee, “Nonlinear networked control systems with random nature using neural approach and dynamic Bayesian networks,” *Int. J. of Control, Automation, and Systems*, vol. 6, no. 3, pp. 444-452, 2008.
- [9] Y.-C. Cao and W.-D. Zhang, “Modified fuzzy PID control for networked control systems with random delays,” *Proc. of World Academy of Science, Engineering and Technology*, vol. 12, pp. 313-316, 2006.
- [10] F.-C. Liu and Y. Yao, “Modeling and analysis of networked control systems using hidden Markov models,” *Proc. of the 4th Int. Conf. on Machine Learning and Cybernetics*, pp. 928-931, 2005.
- [11] W. Pan, P. Han, L. Zhang, and T. Wang, “On stochastic control of networked control systems based on hidden Markov models,” *Int. Conf. Wireless Communications, Networking & Mobile Computing*, pp. 1-4, 2008.
- [12] 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.
- [13] H. K. Khalil, *Nonlinear Systems*, Prentice Hall, Upper Saddle River, New Jersey, 2002.
- [14] O. Beker, “Analysis of reset control systems,” Ph.D. Dissertation, Univ. of Massachusetts Amherst, 2001.
- [15] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, Upper Saddle River, New Jersey, 1999.
- [16] M. Saerens and A. Soquet, “Neural controller based on back-propagation algorithm,” *IEE Proceedings-F*, vol. 138, no. 1, pp. 55-62, 1991.
- [17] A. Rubaai and R. Kotaru, “Online identification and control of a dc motor using learning adaptation of neural networks,” *IEEE Trans. on Industry Applications*, vol. 36, no. 3, pp. 935-942, 2000.
- [18] Y. Bengio and P. Frasconi, “Input/output HMMs for sequence processing,” *IEEE Trans. on Neural Networks*, vol. 7, no. 5, pp. 1231-1249, 1996.
- [19] K. Murphy, “Dynamic Bayesian networks: Representation, Inference and Learning,” Ph.D. Dissertation, UC Berkeley, 2002.
- [20] H. C. Cho, “Dynamic Bayesian networks for online stochastic modeling,” Ph.D. Dissertation, Univ. of Nevada-Reno, 2006.
- [21] F. V. Jensen, *Bayesian Networks and Decision Graphs*, Springer, New York, 2001.
- [22] W. Zhang, M. S. Branicky, and S. M. Phillips, “Stability of networked control systems,” *IEEE Control Systems Magazine*, vol. 21, no. 1, pp. 84-99, 2001.



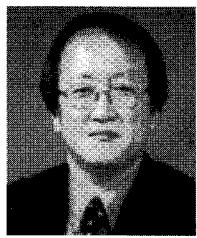
조 현 철

1971년 9월 1일생. 1997년 2월 부경대학교 제어계측공학과 졸업(공학사). 1999년 2월 동아대학교 전기공학과 졸업(공학석사). 2006년 8월 미국 네바다대학교 전기공학과 졸업(Ph.D.). 2006년 9월~2009년 2월 동아대학교 전기공학과 포닥연구원. 2009년 3월~현재 울산과학대학 전기전자학부 조교수. 관심분야는 네트워크 기반 제어시스템, 신경회로망, 학률제어.



심 광 일

1961년 5월 27일생. 1983년 2월 경남대학교 전기공학과 졸업(공학사). 1985년 2월 영남대학교 전기공학과 졸업(공학석사). 1995년 2월 동대학교 전기공학과 졸업(공학박사). 1985년~1991년 현대중공업 기전연구소 선임연구원. 현재 울산과학대학 전기전자학부 교수. 관심분야는 신재생에너지, 전력전자, 자동제어.



이 권 순

1955년 1월 18일생. 1977년 2월 충남 대학교 공업교육과 졸업(공학사). 1981년 2월 서울대학교 전기공학과 졸업(공학석사). 1990년 7월 미국 오레곤 주립대학교 전기 및 컴퓨터공학과 (Ph.D.). 현재 동아대학교 전기공학과 교수. 관심분야는 제어공학, 첨단 항만장비, 녹색물류시스템, 차세대 운송시스템.