

## 신경회로망 제어기와 동적 베이시안 네트워크를 이용한 시변 및 비정치 확률시스템의 제어

### Control of Time-varying and Nonstationary Stochastic Systems using a Neural Network Controller and Dynamic Bayesian Network Modeling

조현철\* · 이진우\* · 이영진\*\* · 이권순\*

Hyun Cheol Cho\* · Jin Woo Lee\* · Young Jin Lee\*\* · Kwon Soon Lee\*

\* 부산시 사하구 하단2동 840 동아대학교 전기공학과

\*\* 경남 사천시 이금동 438 한국폴리텍 항공대학 항공전기과

#### 요약

본 논문은 비정치(nonstationary) 통계특성 및 시변 동특성을 갖는 확률 프로세서의 정밀제어를 위한 신경회로망 제어기와 동적 베이시안 네트워크(DBN; Dynamic Bayesian Networks) 기반 모델링 기법을 제안한다. 신경망 제어기는 재귀형 구조의 일종인 Multilayer Perceptron-Infinite Impulse Response(MLP-IIR) 신경회로망으로 하였으며 실시간 시스템 오차를 보상하기 위한 온라인 학습법 또한 제안한다. DBN은 확률 프로세서의 확률모델링을 위하여 설계되며 또한 예측 제어기를 구성하는 보조시스템으로 이용된다. 제안한 제어기법의 타당성을 검증하기 위하여 컴퓨터 시뮬레이션이 실시되었으며 성능의 우수성을 입증하기 위하여 기존의 제어기법과 비교검토하였다.

키워드 : 신경회로망 제어기, 동적 베이시안 네트워크, 확률프로세서, 비정치 통계특성, 시변 동특성

#### Abstract

This paper presents a novel control approach for stochastic processes with nonstationary statistics and time-varying dynamics by using neural network control and dynamic Bayesian network modeling. We design a MLP-IIR neural network as a controller and propose online learning algorithm for compensating real-time system error due to such natures. We statistically represent relationship of input and output of a stochastic system by using a DBN model, which is technically used in constructing of a predictive control system. We evaluate our control method through computer simulation and demonstrate its superiority by comparing with the traditional control.

Key Words : Neural network control, Dynamic Bayesian networks, Stochastic process, Nonstationary statistics, Time-varying dynamics

#### 1. 서 론

확률시스템은 시스템의 통계특성을 미리 파악한 후 확률 및 통계학을 적용하여 제어시스템을 구성하는 것이 일반적이다. 이러한 경우 결정론적 기법에 확률론적 이론을 접목하여 제어기를 설계 또는 해석하여 결정론적 제어기법에서 만족시키지 못한 제어성능을 구현하고 있다. 하지만 대부분의 확률시스템 제어는 그 통계특성을 가우시안(Gaussian)으로 간주하여 시스템 설계가 이루어지고 있으며 특히 정치성(stationary) 통계성

을 갖는 확률시스템을 대부분 다룬다[1]-[5]. 하지만, 최근의 시스템은 그 구성이 매우 복잡하고 특히, 네트워크와 연결되는 제어시스템의 경우 네트워크의 토플로지(topology) 변화로 인하여 비정치성을 갖는 경우가 대부분이므로 종래의 제어기법으로 제어기에 대한 신뢰성이 감소되어 진다.

본 논문은 신경회로망과 동적 베이시안 네트워크(DBN; Dynamic Bayesian Networks) 기법을 이용하여 시변(time-varying) 파라미터 및 비정치 통계특성을 갖는 확률시스템을 위한 제어시스템을 제안한다. 시스템 제어기로서 구성되어지는 신경회로망은 안정한 제어기를 구성하기 위하여 재귀형 구조인 Multilayer Perceptron-Infinite Impulse Response(MLP-IIR) 신경회로망을 설계하였다. 또한 확률시스템의 확률적 모델링을 위한 DBN이 사용되었으며 시스템이 입력과 출력에 대하여 그 확률을 추정하였으며 예측 제어시스템을 구성하기 위하여 보조시스템으로 사용되었다. 신경회로망 제

접수일자 : 2007년 11월 10일

완료일자 : 2007년 12월 5일

일본 논문은 정부(과학기술부)의 재원으로 한국과학재단의 국가지정연구실사업으로 수행된 연구임(R0A-2003-000-10 303-0).

어기는 우선 정치성 및 가우시안 확률분포를 갖는 시스템에 대하여 바람직한 제어성능을 갖기 위하여 오프라인 학습이 이루어지며, 비정치성 및 시변 특성의 확률시스템에 대하여 실시간 제어오차를 보상하기 위하여 온라인 학습이 이루어진다. DBN에서 시스템 상태의 확률은 온라인 파라미터 추정법을 통하여 실시되며 시스템의 예측 출력값을 산출하는데 사용되어진다. 제안한 제어기의 성능의 우수성과 타당성을 검증하기 위하여 컴퓨터 시뮬레이션을 실시하였으며 기준의 확률시스템에 주로 사용되는 제어기법과 비교하여 제어기의 신뢰성을 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서 신경회로망 제어기 및 학습알고리즘을 서술하며 3장에서 신경회로망 제어기의 온라인 학습에 대하여 논하며 4장에서 DBN 모델링과 파라미터 추정알고리즘을 5장에서는 DBN 모델을 이용한 예측 제어시스템에 대하여 서술한다. 6장에서는 컴퓨터 시뮬레이션에 대하여 논하며 마지막으로 7장에서는 결론과 향후 연구에 대하여 서술한다.

## 2. 재귀형 신경회로망 제어기

신경회로망 제어시스템의 일반적인 블록선도는 그림 1과 같다. 신경망 제어기는 시스템 오차  $e(k)$ 를 입력으로 하며 적절한 학습알고리즘을 통하여 주어진 제어목적에 대하여 최적의 제어입력  $u(k)$ 를 산출한다. 여기서 시스템 오차  $e(k)$ 는 기준입력값  $r(k)$ 와 시스템 출력  $y(k)$ 의 차이, 즉  $e(k) = r(k) - y(k)$ 로 정의된다. 본 절에서는 제어기로 구성되는 신경회로망의 구조와 그 학습알고리즘에 대하여 서술한다.

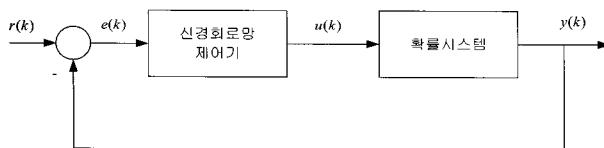


그림 1. 신경회로망 확률 제어시스템.

Fig. 1. Neural network control for stochastic systems.

### 2.1 MLP-IIR 신경회로망

과거 수년 동안 여러 형태의 신경회로망 구조가 발표되었으며 신호처리, 패턴인식, 시스템 모델링과 같은 다양한 응용에 적용되어 왔다. 그 중 역전파 학습알고리즘의 다층 신경망은 구조가 간단할 뿐만 아니라 학습과정과 해석이 용이하며 성능 또한 우수하여 공학적 응용분야에 가장 널리 사용되고 있다[6].

최근엔 동적 또는 재귀형 신경회로망 모델이 시스템 제어 및 시계열 모델링에 각광을 받고 있다. 이러한 신경회로망의 구조는 신경회로망 출력신호가 신경회로망의 입력패턴으로 피드백되는 것이 가장 큰 특징이며, 차분 또는 미분방정식으로 신경망의 동특성을 표현할 수 있다. 이러한 재귀형 구조로 인하여 동적 신경회로망의 파라미터(또는 가중치)들은 네트워크의 안정성을 보장하기 위하여 그 값들이 어느 범위 내에 한정되어 있어야 한다.

본 논문은 비교적 구성하기 용이한 구조와 안정성 해석이 용이한 MLP-IIR 신경회로망을 제어기로 설계한다. 그림 2는 본 논문에서 구성한 MLP-IIR 신경회로망의 블록선도를 보여준다. 여기서, MLP 신경망과 IIR 필터가 직렬로 연결되어

있으며 IIR의 출력이 비선형 활성화함수에 적용되어 신경회로망의 최종 출력으로 산출되며 제어입력으로 인가된다. 그럼 2에서 MLP는 다층 퍼셉트론으로 구성되며 그림 3과 같은 3 층 구조를 갖는다. MLP의 입력벡터  $\gamma(k) = [\gamma_1, \gamma_2, \dots, \gamma_{N_1}]^T$ 는 시스템 오차신호와 바이어스 입력을 포함하며 출력으로는 스칼라 값인  $x(k)$ 를 산출하며 다음과 같이 표현된다.

$$x(k) = v^T W\gamma + \beta \quad (1)$$

여기서  $W = [w_{ij}], i=1, \dots, N_2, j=1, \dots, N_1$ 는 가중치 행렬,  $v = [v_1, \dots, v_{N_2}]^T$ 는 MLP의 첫 번째와 두 번째 층사이의 가중치 벡터를, 그리고  $\beta$ 는 바이어스를 각각 나타낸다. 그림 2의 IIR 신경망은 그림 4의 고차 IIR 필터의 구조를 가진다. 이 필터의 스칼라 출력  $\Gamma(k)$ 는 입력패턴으로 피드백되며 출력식은 다음과 같다.

$$\Gamma(k) = a^T \Psi + b^T X \quad (2)$$

여기서 가중치 벡터  $a$ 와  $b$  그리고 입력과 출력벡터  $X$ 와  $\Psi$ 는 각각 다음과 같다.

$$a = [a_1, \dots, a_{M_1}]^T, \quad b = [b_0, \dots, b_{M_2+1}]^T$$

$$X = [x(k), \dots, x(k-M_2-1)]^T, \quad \Psi = [\Gamma(k-1), \dots, \Gamma(k-M_1)]^T$$

IIR 신경망 출력은 비선형 활성화 함수  $\phi(\cdot)$ 에 적용되어 최종값을 산출하며 또한 시스템의 제어입력  $u(k)$ 로서 다음과 같이 표현된다.

$$u(k) = \phi(\Gamma(k)) \\ = [1 + \exp(-\alpha\Gamma(k))]^{-1}, \quad \alpha > 0 \quad (3)$$

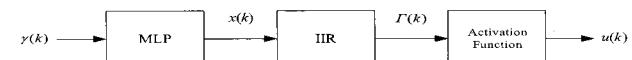


그림 2. MLP-IIR 신경회로망의 블록선도.

Fig. 2. A block diagram of MLP-IIR neural networks.

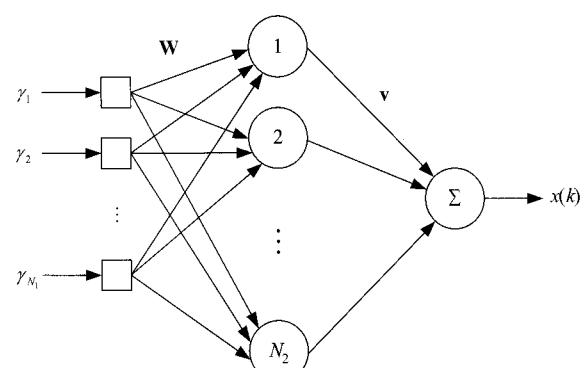


그림 3. 다층 퍼셉트론 신경회로망.

Fig. 3. A multilayer perceptron neural network.

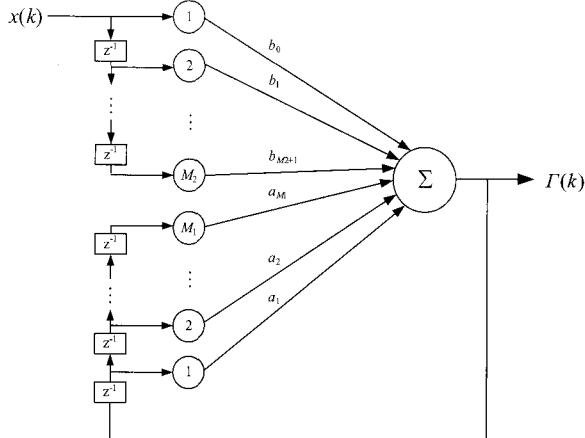


그림 4. IIR 신경회로망.  
Fig. 4. An IIR neural network.

## 2.2 신경회로망 안정성 해석

그림 2의 신경회로망 구조에서 시스템의 동특성은 IIR 신경망과 관계가 있으며, 기존의 선형시스템의 안정성이론을 적용하여, 신경회로망의 안정성 해석을 실시한다. 우선, 식 (2)의 IIR 신경망의 동특성을 차분방정식으로 전개하면

$$\begin{aligned} \Gamma(k) - a_1 \Gamma(k-1) - \cdots - a_{M_1} \Gamma(k-M_1) \\ = b_0 x(k) + b_1 x(k-1) + \cdots + b_{M_2+1} x(k-M_2-1) \end{aligned} \quad (4)$$

와 같으며  $z$  변환을 적용하여 IIR 신경망의 폐루프 전달함수를 다음과 같이 표현할 수 있다.

$$\frac{\Psi(z)}{X(z)} = \frac{b_0 + b_1 z^{-1} + \cdots + b_{M_2+1} z^{-(M_2+1)}}{1 - a_1 z^{-1} - \cdots - a_{M_1} z^{-M_1}} \quad (5)$$

여기서 폐루프의 특성방정식은

$$z^{M_1} - a_1 z^{M_1-1} - \cdots - a_{M_1} = 0 \quad (6)$$

이며 기존의 안정성 이론을 바탕으로 다음의 세 가지 안정성 및 동특성을 분석할 수 있다.

- 1) 위의 신경회로망의 동특성이 안정하기 위하여 식 (5)의 전달함수의 극점이나 식 (6)의 특성방정식의 근이  $z$  평면상의 단위원(unit circle) 내부에 위치하여야 한다.
- 2) 다수의 시스템 극점 중 어느 하나의 극점이 단위원 상에 위치하면 임계안정(marginally stable)이 되며 중복근(repeated poles) 중의 어느 하나가 단위원 상에 위치하면 시스템이 불안정함을 의미한다.
- 3) 폐루프 전달함수의 영점은 오버슈트나 정상상태시간 또는 상승시간 등과 같은 시스템의 동특성에 관계되며 시스템의 안정성에는 직접적으로 미치지 않는다.

예를 들면, 식 (4)에서  $M_1 = 2$  일 때 특성방정식은

$$z^2 - a_1 z - a_0 = 0$$

이 되며, 이 때 안정하기 위한 파라미터  $a_0$ 와  $a_1$ 의 필요충분 조건의 범위는

$$0 < 1 + a_1 - a_0, \quad 0 < 1 + a_0, \quad 0 < 1 - a_1 - a_0 \quad (7)$$

가 된다[7]. 이러한 조건은 본 논문에서 안정한 신경회로망 제어기를 구성하는데 있어 제약조건으로 적용된다. 3차 이상의 차수를 갖는 IIR 신경망의 경우 그 동특성 및 안정성이 해석적으로 다소 복잡하기 때문에 본 논문은 2차 IIR 신경회로망을 구성한다. 또한, 위의 3)에서도 언급한 바와 같이, 영점의 위치는 IIR 필터의 시간응답에 관계되며 실시간에서 바람직한 제어성능을 갖기 위하여, 제어기의 온라인 학습을 통하여 영점 또는 네트워크의 가중치가 재조정되어진다.

## 2.3 신경회로망 제어기의 학습

주어진 시스템 환경에 대하여 바람직한 제어기의 성능을 갖기 위하여 적합한 최적화 알고리즘을 이용하여 신경회로망을 학습한다. 이 과정은 사용자가 정의한 목적함수에 대하여 최적의 신경회로망 파라미터 값을 결정하는 과정이다. 신경회로망 학습을 위한 목적함수는 확률시스템의 출력에 대한 시스템 오차, 랜덤 출력값의 분산, 그리고 시스템입력으로 구성하며 다음과 같다.

$$J = \frac{1}{2} [J_1 + J_2 + J_3] \quad (8)$$

여기서

$$J_1 = \alpha_1 [\bar{y}(k) - r(k)]^2, \quad \alpha_1 > 0 \quad (9)$$

$$J_2 = \alpha_2 \{E[(y(k) - \bar{y}(k))^2]\}, \quad \alpha_2 > 0 \quad (10)$$

$$J_3 = \alpha_3 \bar{u}^2, \quad \alpha_3 > 0 \quad (11)$$

로 각각 정의되며,  $\bar{y}(k)$ 과  $\bar{u}(k)$ 는 평균출력과 입력을 각각 나타내며 다음과 같이 정의된다.

$$\bar{y}(k) = \epsilon_y \bar{y}(k-1) + (1 - \epsilon_y) y(k) \quad (12)$$

$$\bar{u}(k) = \epsilon_u \bar{u}(k-1) + (1 - \epsilon_u) u(k) \quad (13)$$

여기서  $\epsilon_y, \epsilon_u \in (0,1)$ 이다. 본 논문의 신경회로망 제어기의 학습목적은 식 (8)의 목적함수를 신경회로망 파라미터 벡터를 이용하여 최소화하는 것으로서, 최적의 신경망 파라미터 값을 선정하는 것과 같다. 즉,

$$\theta^* = \arg \min_{\theta} J \quad (14)$$

와 같이 표현되며, 여기서 파라미터  $\theta$ 는 MLP와 IIR 네트워크의 가중치 행렬 및 벡터 그리고 바이어스를 포함하여 다음과 같다.

$$\theta = \{W, v, \beta, a, b\} \quad (15)$$

신경회로망 파라미터의 학습알고리즘은 최급경사강하(the steepest gradient descent) 최적화기법[6]을 적용하여 전개하였으며 파라미터 수정규칙은 다음과 같다.

$$\theta(k+1) = \theta(k) - \eta \frac{\partial J(k)}{\partial \theta} \quad (16)$$

여기서 학습률  $\eta \in (0,1)$ 이다. 식 (16)의 미분항은 미분의 연쇄법칙을 적용하여 다음과 같이 전개한다.

$$\frac{\partial J}{\partial \theta} = \frac{1}{2} \left[ \left( \frac{\partial J_1}{\partial y} + \frac{\partial J_2}{\partial \theta} \right) \frac{\partial \bar{y}}{\partial y} \frac{\partial y}{\partial u} + \frac{\partial J_3}{\partial u} \frac{\partial \bar{u}}{\partial u} \right] \frac{\partial u}{\partial \theta} \quad (17)$$

여기서 식 (9)의 각각의 목적함수를 식 (17)에 대입하여 각각

의 편미분항을 다음과 같이 전개할 수 있다.

$$\frac{\partial J_1}{\partial \bar{y}} = 2\alpha_1 (\bar{y} - y) \quad (18)$$

$$\frac{\partial J_2}{\partial \bar{y}} = 2\alpha_2 (\bar{y} - y) \quad (19)$$

$$\frac{\partial J_3}{\partial \bar{u}} = 2\alpha_3 \bar{u} \quad (20)$$

$$\frac{\partial \bar{y}}{\partial y} = (1 - \epsilon_y) \quad (21)$$

$$\frac{\partial \bar{u}}{\partial u} = (1 - \epsilon_u) \quad (22)$$

또한 식 (18) – 식 (22)를 식 (17)에 대입하면

$$\frac{\partial J}{\partial \theta} = \left[ (\alpha_1 + \alpha_2)(\bar{y} - y)(1 - \epsilon_y) \frac{\partial y}{\partial u} + \alpha_3 \bar{u}(1 - \epsilon_u) \right] \frac{\partial u}{\partial \theta} \quad (23)$$

와 같이 구해진다. 따라서 식 (16)의 파라미터 수정규칙은 최종적으로 다음과 같다.

$$\begin{aligned} \theta(k+1) &= \theta(k) \\ &- \eta \left[ (\alpha_1 + \alpha_2)(\bar{y} - y)(1 - \epsilon_y) \frac{\partial y}{\partial u} + \alpha_3 \bar{u}(1 - \epsilon_u) \right] \frac{\partial u}{\partial \theta} \end{aligned} \quad (24)$$

여기서

$$\frac{\partial u}{\partial \theta} = \left[ \frac{\partial u}{\partial W} \frac{\partial u}{\partial v} \frac{\partial u}{\partial \beta} \frac{\partial u}{\partial a} \frac{\partial u}{\partial b} \right]^T \quad (25)$$

이며 각각의 편미분항은 다음과 같이 전개된다.

$$\frac{\partial u}{\partial W} = \frac{\partial u}{\partial \Gamma} \frac{\partial \Gamma}{\partial x} \frac{\partial x}{\partial W} = \phi'(\Gamma) b_1 v \gamma^T \quad (26)$$

$$\frac{\partial u}{\partial v} = \frac{\partial u}{\partial \Gamma} \frac{\partial \Gamma}{\partial x} \frac{\partial x}{\partial v} = \phi'(\Gamma) b_1 W \gamma \quad (27)$$

$$\frac{\partial u}{\partial \beta} = \frac{\partial u}{\partial \Gamma} \frac{\partial \Gamma}{\partial x} \frac{\partial x}{\partial \beta} = \phi'(\Gamma) b_1 \quad (28)$$

$$\frac{\partial u}{\partial a} = \frac{\partial u}{\partial \Gamma} \frac{\partial \Gamma}{\partial a} = \phi'(\Gamma) \Psi \quad (29)$$

$$\frac{\partial u}{\partial b} = \frac{\partial u}{\partial \Gamma} \frac{\partial \Gamma}{\partial b} = \phi'(\Gamma) X \quad (30)$$

여기서  $\phi'(\Gamma)$ 는 활성화함수에 대한 미분식을 나타내며

$$\phi'(\Gamma) = \frac{\alpha \exp(-\alpha \Gamma(k))}{[1 + \exp(-\alpha \Gamma(k))]^2} \quad (31)$$

이다. 식 (24)의 시스템 자코비안(Jacobian)  $\frac{\partial y}{\partial u}$ 는 시스템 입력에 대한 출력의 미분식으로서, 주어진 시스템 방정식을 통해 해석적으로 구할 수 있다. 하지만, 시스템 방정식을 정확히 알기 힘든 확률프로세서의 경우 이러한 자코비안 식을 산출하기 어려우며 근사화 과정을 통하여 추정한다[8]. 본 논문은 Simultaneous Perturbation Stochastic Approximation(SPSA) 알고리즘[9]을 이용하여 식 (24)의 자코비안을 추정한다.

## 2.4 SPSA 알고리즘

Stochastic Approximation(SA)[10]는 수치적 방법을 이용하여 랜덤 노이즈를 포함하는 미분함수의 값을 산출하는 기법으로서, 주로 미분식을 해석적인 방법으로 구하기 어려운 경우 널리 사용되는 수치적 알고리즘이다. 본 논문은 몇 가지 SA 방법 중 수렴속도가 비교적 빠르며 정밀도가 높은

SPSA 알고리즘을 적용한다.

식 (24)에서의 시스템 자코비안  $\frac{\partial y}{\partial u}$ 에서 출력  $y(k)$ 는 시스템 입력  $u(k)$ 의 함수이며 따라서 다음과 같이 표현할 수 있다.

$$\frac{\partial y(u(k))}{\partial u(k)} \quad (32)$$

SPSA 알고리즘에 의하여 스칼라  $u(k)$ 에 대하여 시스템 자코비안은

$$\frac{\partial y(u(k))}{\partial u(k)} = \frac{y(u(k) + c(k)\delta(k)) - y(u(k) - c(k)\delta(k))}{2c(k)\delta(k)} \quad (33)$$

와 같이 근사화되며 여기서  $\delta(k) \in [-1, 1]$ 는 대칭형 베르누이(Bernoulli) 확률분포를 갖는 랜덤변수이며,  $c(k)$ 는 [10]에 의하여

$$c(k) = \alpha k^{-\gamma}, \quad \alpha, \gamma > 0 \quad (34)$$

로 정의된다. 또한 벡터  $u(k) = [u_1, \dots, u_N]^T$ 에 대해서도 자코비안은 다음과 같다.

$$\frac{\partial y(u(k))}{\partial u(k)} = \left[ \frac{\partial y(u)}{\partial u_1(k)}, \dots, \frac{\partial y(u)}{\partial u_N(k)} \right]^T \quad (35)$$

마찬가지로, 벡터값을 갖는 자코비안은 다음과 같다.

$$\begin{aligned} \frac{\partial y(u)}{\partial u(k)} &= \frac{y(u(k) + c(k)\Delta(k)) - y(u(k) - c(k)\Delta(k))}{2c(k)} \\ &\cdot [\Delta_1(k), \dots, \Delta_N(k)]^{-T} \end{aligned} \quad (36)$$

여기서 랜덤벡터  $\Delta(k) = [\Delta_1(k), \dots, \Delta_N(k)]^T$ 는 식 (33)의 동일한 확률분포를 갖는다.

## 3. 신경회로망 제어기의 온라인 학습

제어기의 온라인 학습은 시스템 환경의 변화에 의하여 발생되는 실시간 제어오차를 보상하기 위하여 실시간으로 제어기 파라미터 값을 수정하는 것을 의미한다. 본 논문에서 고려하는 확률시스템의 파라미터는 랜덤변수로 주어지며 실시간에서 그 확률분포가 비정치 특성을 갖는 것으로 간주한다. 이러한 시변 및 비정치성으로 인하여 오프라인 설계단계에서 구성한 제어시스템은 실시간에서 부최적(sub-optimal) 상태가 되어 제어오차를 발생하게 된다.

신경회로망 제어기의 온라인 학습은 공학적 문제에 있어 일반적으로 다루기가 다소 어려운 문제이며, 특히 온라인 학습이 만족스럽지 못할 경우 전체 제어시스템이 불안정한 상태로 될 수가 있기 때문이다. 이러한 과제는 신경회로망 연구에 있어 아직 완전하게 해결치 못한 과제로 남아 있다[11]. 현재까지 발표된 온라인 학습의 주된 기법은 다음과 같은 두 가지 방법이 널리 사용되고 있다. 첫째로, 학습율을 적응형 형태로 정의하여 실시간에서 제어오차가 발생하게 되면 학습율을 수정하여 수렴속도를 증가시키는 방법이다. 두 번째 방법은 오차보상을 위하여 신경회로망의 가중치의 일부분을 실시간으로 수정하는 방법으로서 주로 재귀형 구조의 신경회로망에 사용이 용이하다. 이 때 수정되는 가중치는 네트워크의 동적 안정성에 영향을 주지 않는 것을 선택하여야 한다.

본 논문은 두 번째 온라인 학습방법을 채택하며, 즉, IIR

신경회로망에서 시스템의 동특성에는 연관되나 안정성에는 직접적인 영향을 미치지 않는 가중치를 수정함으로서 신경회로망 제어기의 온라인 학습알고리즘을 구현한다. 즉, 그림 4에서 IIR 신경회로망에서 안정성에는 무관한 신경회로망 가중치  $b$ 에 대한 온라인 학습규칙을 산출하면 다음과 같다.

$$\begin{aligned} b(k+1) = b(k) - \eta [(\alpha_1 + \alpha_2)(\bar{y} - y)(1 - \epsilon_y) \frac{\partial y}{\partial u}] \\ + \alpha_3 \bar{u}(1 - \alpha_u)\phi(\Gamma)X \end{aligned} \quad (37)$$

#### 4. 확률프로세서의 DBN 모델링

DBN은 시스템의 상태(state)를 확률분포로 나타내는 통계학적 모델링기법으로, 결정론적(deterministic) 모델링기법에서 표현하지 못하는 가능성(feasibility) 정도를 나타낼 수 있는 특징이 있다. 현재 고장진단[12], 패턴인식[13], 시계열 예측시스템[14] 등과 같은 다양한 공학적 및 과학적 문제를 다루는데 사용되고 있으며, 특히 불확실성 요소를 확률적 기법을 통하여 추정하는데 적용되고 있다[15][16]. 본 논문은 비정치 확률특성을 갖는 확률시스템의 모델링에 DBN 기법이 적용되며 신경회로망의 제어성능을 향상시키기 위한 보조 시스템으로 구성된다.

##### 4.1 DBN 모델링

본 논문에서 확률프로세서의 DBN 모델링은 시스템의 입력과 출력을 확률관계로 표현한다. 제어시스템의 구성에서 일 반적으로 현재시간  $k$ 에서의 시스템 출력  $y(k)$ 는 이전시간  $k-1$ 에서의 시스템입력  $u(k-1)$ 의 인과관계이며 또한 제어입력은 이전의 출력값을 근거로 계산되어진다. 이러한 입출력은 서로 함수관계를 가지며 수식으로 나타내면 다음과 같다.

$$y(k+1) = f(y(k), u(k), k) \quad (38)$$

$$u(k+1) = g(u(k), y(k), k) \quad (39)$$

여기서  $f$ 와  $g$ 는 비선형 함수를 각각 나타낸다. 위의 두 관계식을 그림 5와 같은 DBN 모델로 나타낼 수 있으며, 확률변수  $u$ 와  $y$ 는 각각  $N$ 과  $M$ 개의 이산상태(discrete state)를 갖는다고 가정한다. 즉,

$$u = \{u_1, u_2, \dots, u_N\}, \quad y = \{y_1, y_2, \dots, y_M\}$$

이다. 또한 DBN 파라미터로 주어지는  $a_{ij}$ ,  $b_{ij}$ ,  $c_{ij}$ ,  $d_{ij}$ 는 입력과 출력변수에 상응하는 조건부확률 또는 천이확률로서 다음과 같이 정의된다.

$$a_{ij} = p(u(k+1) = i | u(k) = j), \quad i, j = 1, \dots, N \quad (40)$$

$$b_{ij} = p(y(k+1) = i | y(k) = j), \quad i = 1, \dots, N, \quad j = 1, \dots, M \quad (41)$$

$$c_{ij} = p(y(k+1) = i | u(k) = j), \quad i = 1, \dots, M, \quad j = 1, \dots, N \quad (42)$$

$$d_{ij} = p(y(k+1) = i | u(k) = j), \quad i, j = 1, \dots, M \quad (43)$$

여기서 확률공리(probability axiom)에 의하여 다음의 제약 조건(constraint conditions)를 갖는다.

$$\sum_{i=1}^N a_{ij} = \sum_{i=1}^N b_{ij} = 1, \quad \sum_{i=1}^M c_{ij} = \sum_{i=1}^M d_{ij} = 1 \quad (44)$$

시스템의 입출력 확률은 이전의 상태확률에 의하여 결정되어

지며 이러한 관계는 마코브(Markov) 특성[17]에 기반하여 다음의 조건부 확률식으로 나타내어진다.

$$p(u_i(k+1)|u_j(k), y_n(k)), \quad i, j = 1, \dots, N, \quad n = 1, \dots, M \quad (45)$$

$$p(y_i(k+1)|y_j(k), u_n(k)), \quad i, j = 1, \dots, M, \quad n = 1, \dots, N \quad (46)$$

여기서  $u_i(k) \equiv \{u(k) = i\}$ ,  $y_i(k) \equiv \{y(k) = i\}$ 이다. Bayes 확률법칙[17]에 의하여 식 (45)와 식 (46)은 각각 다음과 같이 전개된다.

$$\begin{aligned} & p(u_i(k+1)|u_j(k), y_n(k)) \\ &= \frac{p(u_j(k)|u_i(k+1), y_n(k))p(u_i(k+1)|y_n(k))}{p(u_j(k)|y_n(k))} \\ &= \alpha p(u_j(k)|u_i(k+1), y_n(k))p(u_i(k+1)|y_n(k)) \end{aligned} \quad (47)$$

$$\begin{aligned} & p(y_i(k+1)|y_j(k), u_n(k)) \\ &= \frac{p(y_j(k)|y_i(k+1), u_n(k))p(y_i(k+1)|u_n(k))}{p(y_j(k)|u_n(k))} \\ &= \alpha p(y_j(k)|y_i(k+1), u_n(k))p(y_i(k+1)|u_n(k)) \end{aligned} \quad (48)$$

여기서  $\alpha$ 는 식 (44)의 제약조건을 만족하기 위한 정규화 계수를 나타낸다. 제어입력  $u(k)$ 와 시스템 출력  $y(k)$ 는 모든 이산상태에서 통계학적으로 독립(independent) 관계이므로 확률이론에 의하여 식 (47)과 식 (48)은

$$p(u_i(k+1)|u_j(k), y_n(k)) = \alpha p(u_j(k)|u_i(k+1))p(u_i(k+1)|y_n(k)) \quad (49)$$

$$p(y_i(k+1)|y_j(k), u_n(k)) = \alpha p(y_j(k)|y_i(k+1))p(y_i(k+1)|u_n(k)) \quad (50)$$

으로 간략화되며 여기서 조건부확률은

$$\begin{aligned} p(u_j(k)|u_i(k+1)) &= \frac{p(u_i(k+1)|u_j(k))p(u_i(k))}{p(u_i(k+1))} \\ &= \alpha p(u_i(k+1)|u_j(k))p(u_j(k)) \end{aligned} \quad (51)$$

$$\begin{aligned} p(y_j(k)|y_i(k+1)) &= \frac{p(y_i(k+1)|y_j(k))p(y_i(k))}{p(y_i(k+1))} \\ &= \alpha p(y_i(k+1)|y_j(k))p(y_j(k)) \end{aligned} \quad (52)$$

와 같이 된다. 최종적으로 식 (45)와 식 (46)은

$$p(u_i(k+1)|u_j(k), y_n(k)) = \alpha p(u_i(k+1)|u_j(k))p(u_j(k))p(u_i(k+1)|y_n(k)) \quad (53)$$

$$p(y_i(k+1)|y_j(k), u_n(k)) = \alpha p(y_i(k+1)|y_j(k))p(y_j(k))p(y_i(k+1)|u_n(k)) \quad (54)$$

와 같이 표현된다. 여기서  $u(k)$ 와  $y(k)$ 의 독립관계임을 이용하여 식 (53)을 적용하면 이산시간  $k+1$ 에서의 시스템 입력  $u(k+1)$ 에 대한 확률은 다음과 같이 전개되며

$$p(u_i(k+1))$$

$$= \sum_{j=1}^N \sum_{n=1}^M p(u_i(k+1)|u_j(k), y_n(k))p(u_j(k), y_n(k)) \quad (55-1)$$

$$= \sum_{j=1}^N \sum_{n=1}^M p(u_i(k+1)|u_j(k), y_n(k))p(u_j(k))p(y_n(k)) \quad (55-2)$$

$$= \sum_{j=1}^N \sum_{n=1}^M \alpha p(u_i(k+1)|u_j(k))p(u_i(k))|y_n(k))p(u_j(k))^2 p(y_n(k)) \quad (55-3)$$

$$= \sum_{j=1}^N \sum_{n=1}^M \alpha a_{ij} b_{in} p(u_i(k))^2 p(y_n(k)) \quad (55-4)$$

마찬가지로, 시스템 출력에 대해서도

$$p(y_i(k+1))$$

$$= \sum_{j=1}^N \sum_{n=1}^M p(y_i(k+1)|y_j(k), u_n(k)) p(y_j(k), u_n(k)) \quad (56-1)$$

$$= \sum_{j=1}^N \sum_{n=1}^M p(y_i(k+1)|y_j(k), u_n(k)) p(y_j(k)) p(u_n(k)) \quad (56-2)$$

$$= \sum_{j=1}^N \sum_{n=1}^M \alpha p(y_i(k+1)|y_j(k)) p(y_i(k)) |u_n(k) p(y_j(k))^2 p(u_n(k)) \quad (56-3)$$

$$= \sum_{j=1}^N \sum_{n=1}^M \alpha c_{ij} d_{in} p(y_i(k))^2 p(u_n(k)) \quad (56-4)$$

와 같이 구해진다. 위의 두 결과식은 재귀형 구조를 갖는 연산식으로서, 이산시간  $k+1$ 에서의 시스템 입력과 출력에 대한 확률값은 이전시간에서의 입출력 확률값과 상태천이확률에 의하여 결정됨을 알 수가 있다.

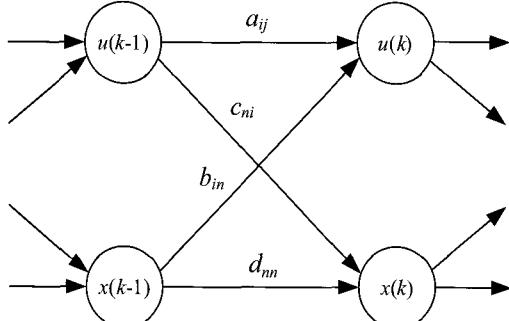


그림 5. 확률시스템의 DBN 모델.

Fig. 5. A DBN model of stochastic systems.

#### 4.2 DBN 파라미터 학습

식 (55-4)와 식 (56-4)의 결과식을 이용하기 위하여 우선 식 (40)-식 (43)의 천이확률  $a_{ij}$ ,  $b_{ij}$ ,  $c_{ij}$ ,  $d_{ij}$ 를 파라미터 학습 알고리즘을 이용하여 최적의 값으로 추정하여야 한다. 본 논문은 참고문헌 [18]에서 발표한 DBN의 온라인 파라미터 학습알고리즘을 이용하며,  $a_{ij}$ 에 대한 파라미터 추정을 예를 들어 간략히 알고리즘을 서술한다. 우선, 파라미터  $a_{ij}$ 를 다음과 같이 정의하며

$$a_{ij}(k) = \rho m_{ij}(k), \quad i, j = 1, \dots, N \quad (57)$$

여기서  $\rho$ 는 식 (44)를 만족하기 위한 정규화 계수이며  $m_{ij}$ 는 평균 가능성으로서 다음과 같이 정의한다.

$$\begin{aligned} m_{ij}(k) &= \frac{1}{k} \sum_{n=1}^k \zeta_{ij}(n) \\ &= \left( \frac{k-1}{k} \right) m_{ij}(k-1) + \left( \frac{1}{k} \right) \zeta_{ij}(k) \end{aligned} \quad (58)$$

식 (58)은 평균값을 산출하는 재귀적 형태로서  $\zeta_{ij}$ 의 값에 의하여 수정되며,  $\zeta_{ij}$ 는 시스템의 관측값에 의하여 0 또는

$c > 0$ 의 값으로 선택된다. 예를 들어, 관측값이 이산시간  $k-1$ 에서  $u=j$ 이고  $k$ 에서  $u=i$ 라고 가정하면(즉,  $u(k) = i | u(k-1) = j$ ) 일 때  $\zeta_{ij}(k)$ 는  $c$ 로 선택되어지며 그렇지 않은 경우는 0으로 선택된다. 수식으로 표현하면

$$\zeta_{ij}(k) = \begin{cases} c, & \text{if } x(k) = i \text{ given } x(k-1) = j \\ 0, & \text{otherwise} \end{cases} \quad (59)$$

와 같다. 그림 6은 식 (59)의 예를 그래프로 도시한 것이다. 그림 6에서 회색으로 그려진 두개의 원은 이산시간  $k$ 와  $k-1$ 에서 관측된 시스템 상태를 나타내며 점선은 관련 파라미터  $a_{ij}$ 를 가리킨다. 그림에서 보는 바와 같이  $\zeta_{ij} = c > 0$ 이 되면 평균가능성  $m_{ij}$ 는 증가하며, 반면 다른 가능성값은 상대적으로 감소하게 된다. 파라미터  $\zeta_{ij}$ 는 관측값에 따라서 매 시간마다 0 또는  $c$ 로 설정되며 이에 대하여 가능성값 또한 수정되어진다. 최종적으로 정규화 계수  $\rho$ 가 가능성값에 적용되어 파라미터  $a_{ij}$ 의 확률값을 산출하게 된다. 이러한 파라미터 추정과정은 실제 구현에 있어 실현하기가 매우 용이하며 계산량도 상당히 작은 것이 특징이다. 또한 관측값에 의하여 DBN파라미터의 온라인 학습이 가능한 장점이 있다[18].

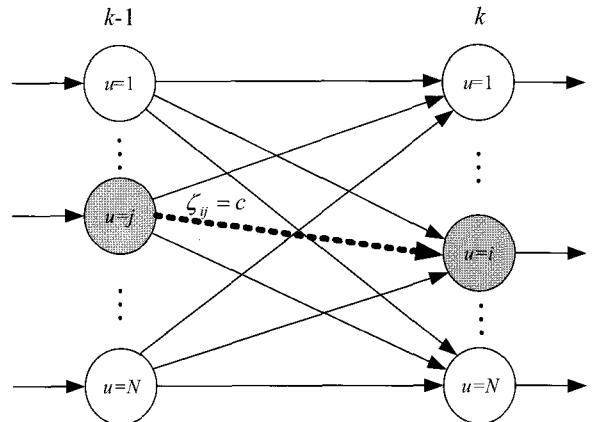


그림 6. DBN 파라미터  $a_{ij}$ 의 수정.

Fig. 6. Update of the DBN parameter  $a_{ij}$ .

#### 5. DBN 기반 예측 제어시스템

본 절은 4절에서 구성한 DBN 모델을 신경회로망 예측제어시스템을 구성하기 위한 보조시스템으로 이용한다. 우선, 식 (55-4)와 식 (56-4)를 다시 표현하자.

$$p(u_i(k+1)) = \sum_{j=1}^N \sum_{n=1}^M \alpha a_{ij}(k) b_{in}(k) p(u_j(k))^2 p(y_n(k)) \quad (60)$$

$$p(y_i(k+1)) = \sum_{j=1}^N \sum_{n=1}^M \alpha c_{ij}(k) d_{in}(k) p(y_j(k))^2 p(u_n(k)) \quad (61)$$

여기서 파라미터는 앞서 서술한 바와 같이 온라인 학습을 통하여 실시간으로 추정되며 따라서 시변특성을 갖는다. 식 (60)과 식 (61)의 확률식을 이용하여 각각의 변수에 대한 기대값(expectation)을 다음과 같이 표현할 수 있다.

$$\begin{aligned} \bar{u}(k+1) &= \sum_{h=1}^N u_h(k) p(u_i(k+1)) \\ &= \sum_{h=1}^N u_h(k) \left( \sum_{j=1}^M \sum_{n=1}^N \alpha a_{ij}(k) b_{in}(k) p(y_j(k))^2 p(u_n(k)) \right) \end{aligned} \quad (62)$$

$$\begin{aligned} \bar{y}(k+1) &= \sum_{h=1}^M y_h(k) p(y_i(k+1)) \\ &= \sum_{h=1}^M y_h(k) \left( \sum_{j=1}^M \sum_{n=1}^N \alpha c_{ij}(k) d_{in}(k) p(y_j(k))^2 p(u_n(k)) \right) \end{aligned} \quad (63)$$

여기서

$$u_h(k+1) \equiv \{u(k+1)\}, h = 1, \dots, N$$

$$y_h(k+1) \equiv \{y(k+1)\}, h = 1, \dots, M$$

이다. 마찬가지로, 식 (60)과 식 (61)은 이전의 확률값에 대하여 재귀적으로 계산되어지는 형태이며, 이러한 재귀적 연산을  $T > 0$  단계의 예측 확률값을 다음과 같이 표현할 수 있다.

$$\begin{aligned} \hat{p}(u_i(k+T)) &= \sum_{j=1}^N \sum_{n=1}^M \{\alpha a_{ij}(k) b_{in}(k) \hat{p}(u_j(k+T-1))^2 \hat{p}(q_n(k+T-1))\} \end{aligned} \quad (64)$$

$$\begin{aligned} \hat{p}(y_i(k+T)) &= \sum_{j=1}^M \sum_{n=1}^N \{\alpha c_{ij}(k) d_{in}(k) \hat{p}(y_j(k+T-1))^2 \hat{p}(u_n(k+T-1))\} \end{aligned} \quad (65)$$

또한 두 변수에 대한 예측 평균값은

$$\hat{u}(k+T) = \sum_{h=1}^N u_h(k) \hat{p}(u_i(k+T)) \quad (66)$$

$$\hat{y}(k+T) = \sum_{h=1}^M q_h(k) \hat{p}(q_i(k+T)) \quad (67)$$

로 주어진다. 본 논문은 식 (67)의 결과식을 이용하여 그림 7과 같은 예측 제어시스템을 구성할 수 있다. 확률시스템의 입출력은 DBN에 의해 확률적으로 모델링되어지며 예측기를 거쳐 예측출력확률이 추정되어 예측출력의 평균값을 산출된다. 이 예측값은 기준값과 비교되어 신경회로망의 제어기에 인가되어 예측출력을 산출하게 된다.

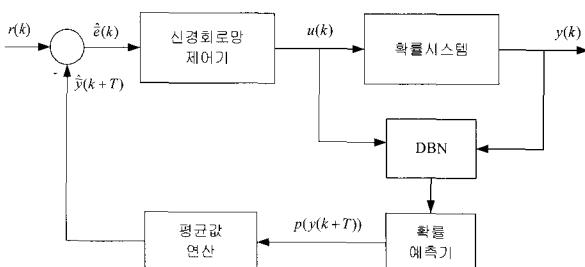


그림 7. DBN 모델을 이용한 신경망 예측제어시스템.  
Fig. 7. A neural predictive control system with a DBN model.

## 6. 컴퓨터 시뮬레이션

본 논문에서 제안한 제어시스템의 타당성을 입증하기 위하여 컴퓨터 시뮬레이션을 실시하였으며 기존의 제어방식과 비교분석하여 성능의 우수성 또한 검증하였다. 시뮬레이션에 사용된 확률시스템은 참고문헌 [19]에서 참조를 하였으며 다음과 같다.

$$y(k) - a(k)y(k-1) = u(k-1) + w(k) + c(k)w(k-1) \quad (68)$$

여기서  $a(k)$ 와  $c(k)$ 는 시변 및 비정치 확률 파라미터로서 주어지며,  $a(k), c(k) \in (0.5, 1]$ 의 항등분포(uniform distribution)의 범위를 갖는다. 또한  $w(k)$ 는 시스템에 적용되는 랜덤 노이즈(noise)로서 평균값 0과  $(0, 1]$ 의 항등분포의 분산값을 갖는 가우시안(Gaussian) 확률변수로 주어진다.

이 시스템에 대하여 본 논문에서 제안한 제어기법을 적용하여 시스템 응답을 파악하였으며, 기존의 확률제어시스템으로 널리 사용되고 있는 최소분산제어(MVC: Minimal Variance Control) 기법[19]과 비교 검토하였다. MVC의 시스템 구성은 참고문헌 [19]에 서술한 설계법을 참조하였다. 본 논문의 신경회로망 제어기 학습에 대한 시스템 설정은 식 (68)에 대하여 파라미터 시불변 및 결정론적 시스템 변수로 고려하였으며 즉,  $a=c=1$ 로 두었으며 시스템 노이즈는 정규화 가우이산 변수, 즉  $w \sim N(0, 1)$ 으로 설정하였다. 제어목적은 시스템의 단위계단응답에서 오버슈트가 발생하지 않도록 하며, 기준값에 대하여 정상상태 시간이 전체 제어시간에 10% 내에 도달하도록 하며, 또한 기준값에 대하여 분산정도가 낮은 응답을 가지도록 하였다. 이러한 제어사양에 대하여 최적의 제어성능을 가질 수 있도록, 여러 번의 반복 학습을 통하여 신경회로망 제어기의 파라미터 값을 선정하였다. 또한 DBN 모델을 구성하기 위하여 우선 다음과 같이 이산상태를 정의하였다.

$$\begin{aligned} y_1 &= \{y \mid y \in [0, 0.75]\} \\ y_2 &= \{y \mid y \in (0.75, 1.25]\} \\ y_3 &= \{y \mid y \in (1.25, \infty]\} \end{aligned} \quad (69)$$

그림 8은 식 (68)의 시스템에 대한 신경회로망 제어기를 적용하였을 때의 시스템 응답과 기존의 MVC 제어기법을 적용한 경우의 응답을 각각 보여준다. MVC의 경우 과도응답에서 최대 오버슈트를 가지며 정상상태부근에서도 기준값에 대하여 비교적 큰 분산값을 가지는 것을 볼 수가 있다. 반면, 제안한 제어기법의 경우, 보다 개선되었음을 알 수 있으며, 비교적 만족스러운 제어성능을 보이고 있다. 초기응답구간에서 오버슈트 동특성이 전혀 나타나지 않고 있으며, 정상상태 구간에서도 분산정도가 비교적 낮은 응답을 보여준다.

그림 9와 10은 DBN 모델링에 의해 추정된 시스템 출력에 대한 확률분포를 시간축에 대하여 나타낸 것이다. 그림 9는 MVC에 대한 시스템 출력의 확률분포를 나타내며,  $p(y_2)$ 의 경우, 즉 시스템 응답이 기준값에 가장 근접할 확률로서, 정상상태에서 약 0.8을 갖는 반면, 그림 10의 제안한 제어기법의 경우, 거의 1에 가까운 확률분포를 갖는다. 이러한 결과로부터 제안한 제어기법의 경우 정상상태에서 기준값에 근접할 확률이 기존의 MVC 제어보다 높은 것을 의미하여, 따라서 제안한 제어기법의 신뢰성이 보다 더 높음을 알 수 있다.

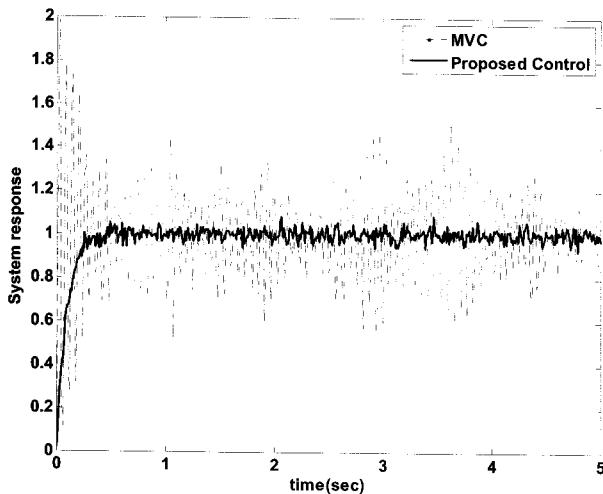


그림 8. 시스템 응답.

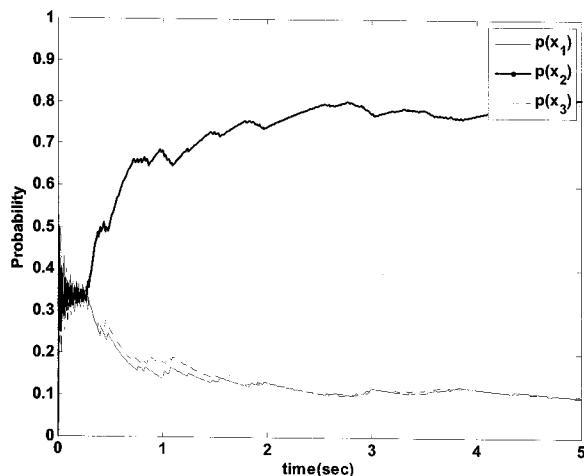


그림 9. 시스템 출력의 확률분포(MVC 적용).

Fig. 9. Probability distributions of the system output(applying MVC).

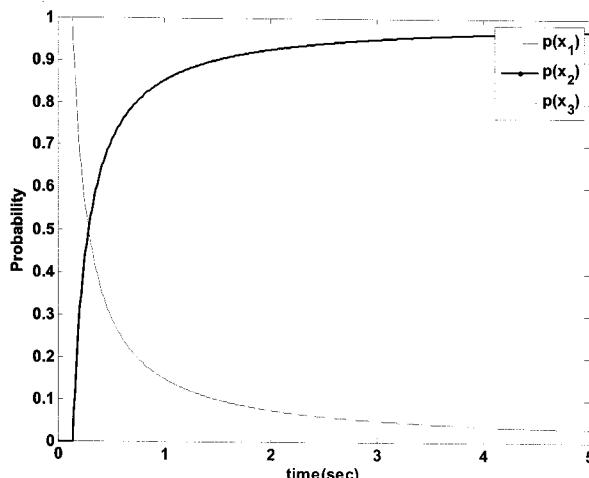


그림 10. 시스템 출력의 확률분포(제안한 제어기 적용).

Fig. 10. Probability distributions of the system output(applying the proposed control).

## 7. 결 론

본 논문은 신경회로망 제어기와 DBN 모델링을 이용하여 확률시스템의 새로운 제어기법을 제안하였다. 제어기로 구성된 신경회로망은 재귀형 구조를 갖는 MLP-IIR 모델을 이용하였으며, 온라인 학습알고리즘을 제안하여 시스템의 비정치 및 시변특성으로 인하여 발생되는 실시간 제어오차를 보상하였다. DBN은 확률시스템의 입출력 변수에 대한 확률적 모델로서 예측 출력값을 산출하는데 보조시스템의 구성되었다. 제안한 제어시스템의 타당성을 검증하기 위하여 컴퓨터 시뮬레이션을 실시하였으며 기존의 제어기법인 MVC와 비교분석하여 성능의 우수성을 입증하였다. 향후 연구로는 실제 확률시스템을 구성하여 실시간 실험을 통하여 제안한 제어기의 실현 가능성을 검토하고자 한다.

## 참 고 문 헌

- [1] M. Basin, A. Ferreira, and L. Fridman, "Sliding mode identification and control for linear uncertain stochastic systems," *Int. J. of Systems Science*, vol. 38, no. 11, pp. 861-869, 2007.
- [2] Y. Liu, Z. Wang, and X. Liu, "Robust H infinity control for a class of nonlinear stochastic systems with mixed time delay," *Int. J. of Robust and Nonlinear Control*, vol. 17, no. 16, pp. 1525-1551, 2007.
- [3] N. S. Demin and S. V. Rozhkova, "Optimal control of stochastic systems in the case of continuous-discrete observation channels with memory," *Automatic Control and Computer Sciences*, vol. 40, no. 6, pp. 1-10, 2006.
- [4] H. Bauer and U. Rieder, "Stochastic control problems with delay," *Mathematical Methods of Operations Research*, vol. 62, no. 3, pp. 411-427, 2005.
- [5] C.-C. Lin, H. Peng, and J. W. Grizzle, "A stochastic control strategy for hybrid electric vehicles," *American Control Conference*, vol. 5, no. 30, pp. 4710-4715, 2004.
- [6] S. Haykin, *Neural networks: A comprehensive foundation*, Upper Saddle River, New Jersey, Prentice Hall, 1999.
- [7] S. K. Mitra, *Digital signal processing*, New York, McGraw Hill, 2006.
- [8] M. Saerens and A. Soquet, "Neural controller based on back-propagation algorithm," *IEE Proceedings-F*, vol. 138, no. 1, pp. 55-62, 1991.
- [9] P. Sadegh and J. C. Spall, "Optimal random perturbations for stochastic approximation using a simultaneous perturbation gradient approximation," *IEEE Trans. on Automatics Control*, vol. 43, no. 10, pp. 1480-1484, 1998.
- [10] J. C. Spall, *Introduction to stochastic search optimization*, Wiley-Interscience, 2003.
- [11] S. Ablameyko, M. Gori, L. Goras, and V. Piuri, editors, *Impact of neural networks on signal*

- processing and communications, of Limitations and Future Trends in Neural Computation, NATO Science Series, 2003.
- [12] K. Patan and T. Parisini, "Identification of neural dynamic models for fault detection and isolation: the case of a real sugar evaporation process," *J. of Process Control*, vol. 15, no. 1, pp. 67-79, 2005.
- [13] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*, Wiley-Interscience Publication, New York, 2001.
- [14] L. Gyorfi and G. Ottucsak, "Sequential prediction of unbounded stationary time series," *IEEE Trans. on Information Theory*, vol. 53, no. 5, pp. 1866-1872, 2007.
- [15] K. Murphy, *Dynamic Bayesian networks: Representation, Inference and Learning Ph. D. Dissertation*, UC Berkeley, 2002.
- [16] F. Tian, H. Zhang, and Y. Lu, "Research on modeling with dynamics Bayesian networks," *Proc. of the IEEE/WIC International Conference on Web Intelligence*, pp. 606-609, 2003.
- [17] J. R. Norris, *Markov chains*, Cambridge University Press, 1998.
- [18] H. Cho and M. Sami Fadali, "Online estimation of dynamic Bayesian network parameter," *IEEE WCCI*, Vancouver, Canada, pp. 6395-6402, 2006.
- [19] Z. Li and R. J. Evans, "Generalised minimum variance control of linear time-varying systems," *IEE Proc.-Control Theory and Applications*, vol. 149, no. 1, pp. 111-116, 2002.



이진우(Lee, Jin Woo)

1998년 : 경남대학교 전기공학과 졸업(공학사)  
2000년 : 동아대학교 전기공학과 졸업(공학석사)  
2006년 : 동 대학교 전기공학과 졸업(공학박사)  
2006년~현재 : 동아대학교 전기공학과 포닥연구원

관심분야 : 영상처리, 적응제어, 항만자동화, 지능제어

Phone : 051) 200-6954  
Fax : 051) 200-7743  
E-mail : tojwlee@hanmail.net



이영진(Lee, Young Jin)

1992년 : 동아대학교 전기공학과 졸업(공학사)  
1994년 : 동 대학교 전기공학과 졸업(공학석사)  
2000년 : 동 대학교 전기공학과 졸업(공학박사)  
2001년~현재 : 한국폴리텍 항공대학 항공전기과 부교수

관심분야 : 제어시스템, 면역알고리즘, 항만자동화

Phone : 055) 830-3482  
Fax : 055) 830-3489  
E-mail : airlee011@hanmail.net



이권순(Lee, Kwon Soon)

1977년 : 충남대학교 공업교육과 졸업(공학사)  
1981년 : 서울대학교 전기공학과 졸업(공학석사)  
1990년 : 미국 오래곤 주립대학교 전기 및 컴퓨터공학과 졸업(Ph.D.)  
1982년 ~ 현재 : 동아대학교 전기공학과 교수

관심분야 : 항만자동화, 지능제어, 최적화, 영상처리, 의용공학

Phone : 051) 200-7739  
Fax : 051) 200-7743  
E-mail : kslee@dau.ac.kr

## 저자 소개



조현철(Cho, Hyun Cheol)  
1997년 : 부경대학교 제어계측공학과 졸업(공학사)  
1999년 : 동아대학교 전기공학과 졸업(공학석사)  
2006년 : 미국 네바다 대학교 전기공학과 졸업(Ph.D.)  
2006년~현재 : 동아대학교 전기공학과 포닥연구원

관심분야 : 제어시스템, 신경회로망, 확률프로세서, 임베디드 시스템

Phone : 051) 200-6950  
Fax : 051) 200-7743  
E-mail : hyunccho@gmail.com