

비선형 신경회로망보상기를 이용한 시변파라미터 적응추정의 자동이득조정 알고리즘

0
서 보혁 권 순용
경북대학교 전기공학과

A gain self-tuning algorithm for adaptive estimating of time-varying
parameter using nonlinear neural network compensator

Bo-Hyeok Seo Soon-Yung Chun
Dept. of Electrical Eng. Kyung-Pook Nat. Univ.

Abstract

This paper proposes a new algorithm to estimate time-varying parameters by combining KFSM(Kalman Filter with Shift Matrix) with neural network compensator. While the time varying parameters are estimated from KFSM, the error coverage of system, $R(k)$ are compensated by neural network concurrently. The case study using computer simulation proves the usefulness and advantages of the proposed algorithm in this paper.

1. 서 론

시스템의 다이내믹(Dynamic) 모델에 대한 파라미터(Parameter) 추정 문제는 오랜동안 중요한 관심사로서 끊임 없는 연구가 계속 되어 왔으며, 선형인 시불변(Linear Time invariant) 시스템의 다이내믹 모델에 대해서는 RLS(Recursive Least Square) 기법을 이용하여 쉽게 그 해를 구할 수가 있게 되었다.¹⁾

그러나, 실제에 있어 파라미터 추정을 위해 사용되는 시스템의 입출력 정보들은 시스템잡음(System noise)이나 관측잡음(Measurement noise) 등에 의해 어느정도 더럽혀진 데이터들이기 때문에 이들로 부터 추정된 파라미터는 다소의 불확실성(Uncertainty)을 내재 하게 된다. 결국, 그 불확실성의 정도에 따라 제어 하고자 하는 시스템의 제어기 성능에 무관하게 제어의 목적을 상실 시킬 수도 있다. 따라서 최근에는 이와 관련된 연구로, 시스템 및 관측 오차 코베리언스(Covariance)를 정확히 추정하여 보상 하고자 하는 노력이 수반되어 왔다. 특히, 시불변인 시스템에 있어 여러 코베리언스를 보상하는 문제는 시스템의 추정 오차에 대한 정보로 부터 화이트니스(Whiteness) 검증 방법, χ^2 -검증법 등에 의해 모델링의 정확성 여부를 검증하여 보상할 수 있으나, 시변 혹은 비선형 시스템의 경우에는 이러한 방법으로 모델링의 정확성 여부를 검증하는 것이 어렵다. 시변 혹은 비선형 시스템을 추정하는 문제는 크게 2가지 관점에서 가능한데 첫째는, 직접 비선형 모델을 시스템 추정에 이용하는 방법이고, 다른 한가지 방법은 신경회로망이나 퍼지시스템과 같은 비선형 보상기를 이용하는 방법이다.

전자의 경우는 알고리즘 마다 여러가지 제약 조건을 수반할 뿐만 아니라, 방법이 복잡하고 시스템의 안정도 측면에서 그 해의 존재성 여부가 불투명 할 수 있기 때문에 최근에는 후자의 방법을 이용하여 시스템을 추정 하고 안정하게 제어

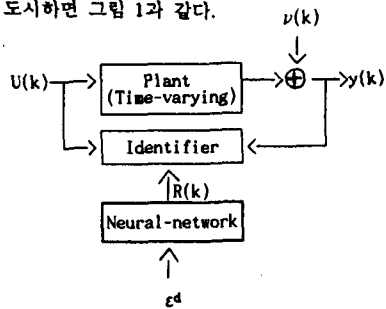
하려는 데에 보다 많은 관심이 집중되어 지고있다. 최근에 Narendra 와 Parthasarathy 등이 비선형 시스템의 추정과 제어를 위해 신경회로망을 사용 했으며⁵⁾, P. Burrascano, P.J Werbos 등이 신경회로망을 적용키위한 기법들을 최근 논문에서 제시 하였다.⁶⁾

본 논문에서도 이러한 기본 아이디어에 근거하여 시변 확률 시스템의 파라미터 추정을 위해 신경회로망 보상기를 이용하였다. ARMA 모델로 주어지는 선형인 시변확률시스템의 파라미터를 실시간(On line) 적응추정하기 위해 지연행렬을 갖는 칼만필터 알고리즘(KFSM)을 구성하여 적용하고, 시스템의 오차 코베리언스를 추정하는데 비선형 신경회로망보상기를 이용하여 안정하게 보상해 주는 자동 이득조정 알고리즘을 제시한다.

2. 적응추정기의 구성

2-1) 전체 계통도

시변확률시스템에 대한 파라미터의 적응추정을 위한 계통도를 도시하면 그림 1과 같다.



(Fig. 1) Block-diagram of adaptive identifier

이 구성에서는, 시스템에 가해지는 구동입력 $U(k)$ 와 시스템출력 $y(k)$ 로 부터 파라미터 $\theta_0(k)$ 를 추정하기 위해 지연행렬을 이용한 칼만필터 알고리즘을 적용하고, 이때 신경회로망을 통해 출력오차 ϵ 으로부터 매 스텝마다 시스템의 코베리언스 $R(k)$ 를 결정 함으로서 칼만필터 이득 $K(k)$ 를 적절히 보상할 수 있게 한다. 그림1의 적응추정기 전체 계통도에 포함되어 있는 시변확률시스템의 특성과 위에서 언급한 파라미터 추정 알고리즘, 그리고 추정기 구성에 관한 사항들을 2.2절에서 3절에 걸쳐 제시 하였다.

2-2) 시스템 모델(Model)

출력 $y(k)$ 가 다음과 같은 선형 차분방정식에 의해 생성된다고 가정한다.

$$y(k) + a_1(k)y(k-1) + \dots + a_n(k)y(k-n) = b_1(k)u(k-1) + \dots + b_m(k)u(k-m) + e(k) \quad (1)$$

여기서 $u(k)$ 는 입력벡터이고, $e(k)$ 는 평균이 0 인 가우시안 백색잡음 (Gaussian White noise)이다. 파라미터벡터 $\theta(k)$ 와 출력벡터 $\varphi(k)$ 를 식2와 같이 정의하면,

$$\theta(k) = [a_1(k), a_2(k), \dots, a_n(k), b_1(k), b_2(k), \dots, b_m(k)]^T$$

$$\varphi(k) = [-y(k-1), -y(k-2), \dots, -y(k-n), u(k-1), u(k-2), \dots, u(k-m)]^T \quad (2)$$

식 (1)은 다음과 같은 형태로 표시 할 수 있다.

$$y(k) = \varphi^T(k)\theta(k) + e(k) \quad (3)$$

2-3) 지연행렬을 갖는 칼만필터 알고리즘

시변확률시스템에서의 파라미터 변화 모델을 식4 로서 정의할때, 파라미터 벡터 θ 를 칼만필터 이노베이션 모델 (Innovation model)의 상태벡터(State vector)로 대응시키고, 상태전이행렬 A가 지연행렬(Shift matrix)로 정의되는 행렬 S를 갖는다고 보면 식4 와 식5는 칼만필터의 시스템모델(System model)과 관측모델(Measurement model) 이 된다.

$$\theta(k+1) = S\theta(k) + Z\omega(k) \quad (4)$$

$$y(k) = \varphi^T(k)\theta(k) + e(k) \quad (5)$$

이때, S는 n차인 시스템에 대해서 $2n \times 2n$ 인 정방 행렬이 되며, 만일 시스템이 2차라면 S는 다음과 같이 4차인 정방 행렬로서 주어진다.

$$S = \begin{bmatrix} s_1 & w_1 & 0 & 0 \\ 0 & s_2 & 0 & 0 \\ 0 & 0 & s_3 & w_2 \\ 0 & 0 & 0 & s_4 \end{bmatrix} \quad (6)$$

그리고 $\omega(k)$ 와 $e(k)$ 는 평균이 0이고 코베리언스가 각각 $Q(k)$ 와 $R(k)$ 로서 주어지는 서로 독립인 가우시안 백색잡음이며, 지연행렬의 요소 s 와 w는 파라미터의 시변 특성을 결정해 주는 요소들이다. 이때, $\theta(k) \in \mathbb{R}^n$ 인 상태벡터이며, S는 $n \times n$ 인 상태전이행렬(State transition matrix)로서 볼 수 있다. 또, $y(k) \in \mathbb{R}^m$, $Z \in \mathbb{R}^m$ 이며, $\varphi^T(k)$ 는 t_k 에서 출력벡터와 상태벡터를 잡음 없이 연결하는 $m \times n$ 인 행렬이다. 또, S, Z, φ^T 는 적당한 차수를 갖는 상수행렬(Constant matrix)로서, 이 문제는 결정적 접근추정(Deterministic asymptotic estimation) 문제이므로 $k \geq 0$ 에 대해서 다음과 같이 $\theta_*(k)$ 를 결정 할 수 있다.

$$\theta_*(k) = \theta_*(k-1) + K(k)[y(k) - \varphi^T(k)\theta_*(k-1)] \quad (7)$$

여기서 $\theta_*(k)$ 는 t_k 순간에서의 새로운 추정치(Updated estimate)이고 칼만이득 K(k)는 식(8) 로서 주어진다.

$$K(k) = P(k)\varphi^T(k)R^{-1}(k) \quad (8)$$

시스템 다이내믹스(System dynamics)로부터 $P^-(k+1)$ 를 결정하기 위해 추정오차를 다음과 같이 정의하면

$$e(k+1) = \theta(k+1) - \theta_*(k+1) \quad (9)$$

여러 코베리언스 행렬 $P^-(k+1)$ 은 식10과 같이 된다.

$$P^-(k+1) = E[e^-(k+1) e^{-(k+1)T}] = SP(k)S^T + ZQ(k)Z^T \quad (10)$$

이때, $\theta_*(k)$ 에 대한 식은 다음과 같으며,

$$\theta_*(k+1) = S\theta_*(k) \quad (11)$$

상태(State) 오차 코베리언스는 다음과 같이 주어진다.

$$P^-(k) = P^-(k-1) - K(k)\varphi^T(k)P^-(k-1) \quad (12)$$

이상과 같이, 시변 시스템의 파라미터 추정에 칼만필터를 이용 함으로서 실시간(Real time) 파라미터 추정이 가능케 된다.

3. 신경회로망을 이용한 보상기 설계

이 절에서는 앞에서 논의된 KFSM에 의해 시변 파라미터를 추정할때, 오차 코베리언스 R(k)를 추정 보상하기 위한 신경회로망 모델을 설계한다. 본 논문에서 구성된 신경회로망 모델은 그림2 와 같은 2층 구조를 가지며, 입력층은 n 개, 은닉층은 L 개, 그리고 출력층은 1개의 뉴런들로 구성이 되었다. 입력층은 단지 데이터 샘플들을 받아 들이는 버퍼로서 동작 하며, 은닉층으로 정보 변환은 다음에서 주어지는 자기동조 알고리즘에 의해 입력 데이터들을 트레이닝(Data training) 시킨다. 이때 입력층 각 뉴런에 인가되는 데이터 샘플들은 다음과 같이 정의 된다.

$$\Gamma = \{ \varepsilon(k-1), \varepsilon(k-2), \dots, \varepsilon(k-d-1), \varepsilon(k-d) \}$$

여기서, Γ 는 추정출력과 실제 플랜트의 출력간에 오차요소들로 구성된 집합이며, 이때 신경회로망 모델의 은닉층 각 뉴런에 대한 입,출력 관계는 다음과 같다.

$$G_j = f \left(\sum_{i=1}^d \beta_{1ij} \Gamma^d - T_j \right) \quad (13)$$

이때, Γ^d 는 d개의 신경회로망 보상기 입력샘플들로서 LVQ (Learning Vector Quantization) 혹은 K-means averaging 등과 같은 적절한 Clustering 방법을 이용하여 선택되어 질 수 있다.⁶⁾

여기서, T는 Threshold 이고, β_{1ij} 는 i 와 j번째 뉴런 상호간의 결합효율이다. $f(\cdot)$ 는 각 뉴런의 Activation 함수로서 다음과 같이 주어진다.

$$f(W) = \frac{1}{1 + \exp(-W)} \quad (14)$$


출력 뉴런의 Activation 함수는 추정 오차의 상태에 따라 오차를 최소화 할 수 있도록 선정되어 질 수 있으며, 출력 뉴런에 대한 입출력 관계는 다음과 같다.

$$\Delta = \sum_{j=1}^L \beta_{2j} G_j \quad (15)$$

$$= \sum_{j=1}^L \beta_{2j} f \left(\sum_{i=1}^d \beta_{1ij} \Gamma^d - T \right) \quad (16)$$

이때, 자기동조 보상알고리즘은 식17 과 식18로 주어진다.

$$R(k) = R(k-1) + \xi \operatorname{sgn}(\operatorname{Gradient}(\varepsilon)) \Delta \quad (17)$$



<Fig.2> Two layer neural networks

여기서, ξ 는 초기 R 값을 결정하기 위한 상수이며, 추정 출력의 오차 변화추이에 따라 신경회로망 보상기는 그 이전 스텝의 $R(k-1)$ 값에 적절한 변화 Δ 를 취하게 된다. 만일 추정오차가 0 이 되면 Δ 는 그 이전 스텝의 그레디언트로서 $R(k)$ 를 동조 시킨다. 만일 추정 오차가 어떤 한계치 이상으로 넘어서면 ξ 를 ξ_1, ξ_2 로 가감 함으로써 추정오차가 감소하는 방향으로 $R(k)$ 를 강제동조 시킨다.

$$\xi_1 = 0.8R(k-1), \xi_2 = 1.2R(k-1) \quad (19)$$

4. 사례연구 및 검토

4-1) 사례연구

본 논문에서 제시한 알고리즘에 의해 시변확률시스템에 대한 파라미터 적응추정기를 구성할 경우 그 유용성과 우수성을 검증하기 위해 다음과 같은 사례연구를 수행 하였다. 시뮬레이션 모델로서 다음과 같은 2차인 시변 확률 시스템 모델을 검토해 본다.

$$y(k) + a_1(k)y(k-1) + a_2(k)y(k-2) = b_1(k)u(k-1) + b_2(k)u(k-2) + e(k) \quad (19)$$


여기서, $e(k)$ 는 평균이 0 인 가우시안 잡음으로 코베리언스 $R(k)$ 을 0.2 로 두었다. 이때 시스템의 코베리언스 R을 모른다고 가정하고 임의의 초기코베리언스 R_0 에서 부터 파라미터를 추정하게 된다. 시변파라미터 $\theta(k)$ 를 19식과 같이 두고,

$$\theta(k)=[a_1(k), a_2(k), b_1(k), b_2(k)]^T \quad (19)$$


2.3 절 에서 정의된 시변 파라미터의 생성 모형에 대응되는 시뮬레이션 모델은 다음과 같이 두었다.

$$\theta(k+1) = \begin{bmatrix} s_1 & w_1 & 0 & 0 \\ 0 & s_2 & 0 & 0 \\ 0 & 0 & s_3 & w_2 \\ 0 & 0 & 0 & s_4 \end{bmatrix} \theta(k) + \begin{bmatrix} 1. \\ 1. \\ 1. \\ 1. \end{bmatrix} \omega(k) \quad (20)$$

단, 여기서 w_1 은 0.2 w_2 는 0.1 이고 s_1, s_3 는 각각 0.52 와 0.95로 주어지며, ω_k 는 평균이 0이고 코베리언스가 0.06 으로 주어진 가우시안 잡음으로 설정 하였다.



<Fig.3> Estimated parameter a1




<Fig.4> Estimated parameter b1

그림 3 과 4는 시뮬레이션을 통하여 파라미터를 추정한 것으로서, 실선은 실제 시스템의 파라미터를 나타내며 점선은 제시된 알고리즘에 의해 추정한 결과이다.

그림 5는 KFSM에 의해 파라미터를 실시간 추정시 비선형 신경회로망 보상기에 의해 시스템의 코베리언스 R을 추정한 결과를 보여준다.

시스템의 파라미터는 대개 -0.3에서 0.3까지 약 0.6정도의 변화를 취했으며, 추정결과는 매우 양호하였다. 시스템의 코베리언스는 400스텝 이후 부터 실제값 0.2에 접근하였다.



<Fig.5> Estimated error covariance R

5. 결 론

본 논문에서는 시변 시스템의 파라미터를 추정하기 위한 기법으로 KFSM을 제시 하였으며, 만일 시스템의 코베리언스 오차를 모를 경우에는 신경회로망 보상기를 이용하여 코베리언스 오차를 추정 보상함으로써 역시, 시변 시스템의 파라미터 추정을 가능케 하는 자기동조 알고리즘을 제시 하였다. 본 논문에서 제시한 자기동조 알고리즘은 최적화된 관점에서의 기법은 아니지만 시변 혹은 비선형 시스템의 파라미터 추정을 위한 경험적 접근 방법으로서 비교적 우수한 적용 특성을 얻을 수 있었다. 신경회로망의 파라미터들을 보다 최적화 한다면 본 알고리즘은 더욱 더 우수한 성능을 얻을 수 있을 것이다.

* 참고문헌

1. Graham C. Goodwin, "Adaptive filtering, Prediction, and control", Prentice-Hall Inc, pp.47-115, 1984.
2. Wittenmark b, "A two level estimator for time vrying parameters", Automatica Vol 15, pp 85-89, 1979.
3. Drago Matko, Bojan Newec, "Identification of fast time varying system - comparative characteristics of three algorithms", IFAC Vol 2, pp 720-725, 1988.
4. Robert Grove Brown, "Random signal analysis and Kalman Filtering", pp 195-200, 1983.
5. K.S.Narendra and K. Parthasarathy, " Identification and control of dynamical systems using neural networks", IEEE Trans, Neural networks, vol.1, pp.525-532, Mar 1990.
6. Amari, S "Statistical Neurodynamics of Associative Memory", Neural Networks, Vol1, pp.63-73, 1988.
7. Veljko Milutinovic, Paolo Antognetti, "Neural Networks", Prentice Hall, Vol. 1, pp.10-32, 1991.
8. P.J.Werbos, "Backpropagaton through time: What is does and how to do it", IEEE, Vol. 79, pp.1550-1560, Oct, 1990.