

기동표적 추적을 위한 퍼지 뉴럴 네트워크 기반 다중모델 기법

손현승*, 주영훈**, 박진배*

*연세대학교 전기전자공학과, **군산대학교 전자정보공학부

A Fuzzy-Neural network based IMM method for Tracking a Maneuvering Target

Hyun-Seung Son*, Young-Hoon Joo**, Jin-Bae Park*

*Electrical and Electronic Engineering of Yonsei Univ, **Electronic and Information Engineering of KunSan Univ

Abstract - This paper presents a new fuzzy-neural-network based interacting multiple model (FNNBIMM) algorithm for tracking a maneuvering target. To effectively handle the unknown target acceleration, this paper regards it as additional noise, time-varying variance to target model. Each sub model characterized by the variance of the overall process noise, which is obtained on the basis of each acceleration interval. Since it is hard to approximate this time-varying variance adaptively owing to the unknown acceleration, the FNN is utilized to precisely approximate this time-varying variance. The gradient descendant method is utilized to optimize each FNN. To show the feasibility of the proposed algorithm, a numerical example is provided.

1. 서 론

기동표적(maneuvering target)에 대한 문제는 각종 관제 시스템, 대공 방어 시스템, 조기 경보 시스템 등에 있어서 관심 높은 대상 중에 하나였다. 특히 레이다, 적외선 감지기 등의 발달과 함께 이들 센서에서 측정된 표적의 측정 데이터를 처리하고 이를 이용하여 표적의 위치 탐지 및 추적, 그리고 이를 이용하여 표적을 공격하는 자동 방어 시스템에서는 표적의 비선형적 운동에 대해 매우 민감한 반응을 하기 때문에 이제는 그 분야가 대공방어뿐만 아니라, 수중에서의 요격시스템에 이르기까지 그 범위는 점점 발전을 거듭하고 있다. 일반적으로, 항공기나 유도탄, 어뢰 등의 표적들은 비선형적 운동을 하는데 비해 이를 탐지 및 추적하는 감지센서들은 절대 표적의 위치만을 측정한다. 1960년대 칼만필터가 소개 된 이후 이를 이용하여 표적 추적 문제를 해결하려는 시도가 광범위하게 이루어져 왔다[1-3]. 이 경우 표적의 운동을 선형으로 근사화한 모델을 사용하여 칼만필터를 구성 하므로써 측정 오차와 표적 움직임의 비선형성을 어느 정도는 해결할 수 있었다. 그러나 표적의 방향 전환이나 탐지회피를 위하여 기동을 수행할 경우 가속도를 포함한 운동을 하게 되므로 기존의 등속도 운동모델은 상당한 오차를 유발하게 되며, 심지어는 표적을 놓치는 경우가 발생한다. 이러한 비선형 측정치의 문제해결을 위한 방법으로 확장 칼만필터(extended kalman filter)[4]가 개발되기도 하였으며, 근래에는 이러한 급격한 기동을 행하는 표적을 추적하기 위한 방법으로 가변차수 기법, 입력추정 기법, 다중모델 기법등의 다양한 모델이 제시되기도 하였다[5-7]. 기존의 수학적인 방법은 정확한 모델을 다른데 있어서 매우 성공적인 결과를 보여 오기는 하였으나 대상 시스템이 수학적으로 모델링하기 어렵거나 강한 비선형성을 가지는 경우, 원하는 목적을 얻을 수 없는 문제점을 가지고 있다. 이에 대한 대안으로서 여러 가지 지능체어 기법들이 제안되었다. 그 중 퍼지 이론과 칼만필터의 융합을 통한 추적 시스템의 성능 개선에 관한 연구들이 추적 시스템에 대한 응용 분야에 적용되었다[8-10]. 유전 알고리즘, 동장을 이용한 퍼지 규칙 기반의 추적 시스템은 칼만필터의 정확성과 유전 알고리즘을 이용한 퍼지 추적 방식의 전역 최적해 수렴의 장점을 모두 살릴 수 있는 방법이었으나, 온라인 기동이라는 실제 기동표적에 대한 추적 문제에 있어서 사전에 학습된 자료의 축적이 없이는 그 성능을 발휘할 수 없다는 단점을 지니고 있다. 본 논문에서는 실제 상황에서 자료의 수집과 함께 학습을 이루어 나가면서 동시에 추적의 효과를 나타낼 수 있는 모델을 제시하고자 한다. 제안된 방법은 먼저 수학적으로 증명된 칼만 필터를 사용한 표적 추적 시스템에 퍼지 신경망의 학습인 오차 역전파 학습법(error back-propagation method)을 이용하여 각종 파라미터를 조정하고 이렇게 이루어진 하나님의 시스템을 상호작용 다중모델 기법(IMM : interacting multiple model)의 부-모델(sub-model)로 설정한다. 이 기법은 최종 추정치(estimate) 값이 각각의 모델이 유효할 확률에 따른 부-모델 (sub-model)들의 추정치의 가중 합(weighted-sum)으로 구해진다. 여기에 표적의 가속도를 적용적으로 추정하여, 추정된 가속도에 가속도 간격(acceleration interval)을 대칭적으로 가감하여 다중모델을 구성한 적용 상호작용 다중모델(AIMM : adaptive interacting multiple model)기법[11]을 사용한다. 이 기법은 사전 설정된 부-모델이 필요하지 않으므로 다중모델 구성을 위한 가속도 간격은 기동의 특성에 따라 결정 되어진다. 본 논문의 구성은 다음과 같다. 2절에서는 기동표적 모델과 적용 상호작용 다중모델 기법을 소개하고, 3절에서는 본문에서 제안한 기법을 언급한다. 마지막으로 4절에서는 결론이 도출된다.

2. 이론적 배경

2.1 기동표적 모델

기동표적을 위한 선형 이산 시간 모델(linear discrete time model)은 각각의 축에 대하여 다음과 같다.

$$\begin{aligned} x(k+1) &= Fx(k) + G[u(k) + w(k)] \\ F &= \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad G = \begin{bmatrix} T^2/2 \\ T \end{bmatrix} \end{aligned} \quad (1)$$

여기서, $x(k)$ 는 상태 벡터, F 와 G 는 각각 시스템 행렬과 이득 행렬이고, $w(k)$ 는 프로세스 잡음, $u(k)$ 는 실제로 일지 못하는 결정적(deterministic) 가속도 입력이다. 또한 측정 방정식은 다음과 같다.

$$z(k) = Hx(k) + v(k) \quad (2)$$

여기서, $H=[1 \ 0]$ 은 측정 행렬이고, $v(k)$ 는 측정 잡음이다. $w(k)$ 와 $v(k)$ 는 각각 분산 q 와 r 을 가지는 영 평균 가우시안 백색 잡음이고, 두 잡음들 사이의 상관관계는 영으로 가정한다.

2.2 적용 상호작용 다중모델 기법

적용 상호작용 다중모델 기법은 각각의 축에 대해 제한된 수의 부-모델들을 가지고, 부-모델들은 추정된 가속도와 이러한 가속도에 대해 대칭적으로 분포하는 가속도 수준으로 표현된다. N 개의 부-모델을 가지는 경우, 다중모델 집합 M 은 다음과 같이 표현된다.

$$M = \{\hat{a}(k), \hat{a}(k) \pm \varepsilon_1, \dots, \hat{a}(k) \pm \varepsilon_{(N-1)/2}\} \quad (3)$$

여기서, $\hat{a}(k)$ 는 추정된 표적의 가속도를, $\varepsilon_{(N-1)/2}$ 는 사전에 결정된 가속도 간격을 나타낸다. 적용 상호작용 모델 기법에서 표적의 가속도는 바이어스(bias)필터와 바이어스-프리(bias-free) 필터로 구성된 이단 칼만 추정기(two-stage kalman filter)에 의해 각각의 축에 대해 별별로 추정된다. 적용 상호작용 모델 기법의 알고리즘[11]은 다음과 같다.

2.1.1 추정치의 상호작용(혼합)

$$\begin{aligned} p_{ij}(k-1|k-1) &= \sum_{i=1}^N \mu_{ij}(k-1|k-1)(p_n(k-1|k-1) \\ &\quad + [(\hat{x}_n(k-1|k-1) - \hat{x}_{ij}(k-1|k-1))] \\ &\quad \times (\hat{x}_n(k-1|k-1) - \hat{x}_{ij}(k-1|k-1))^T] \end{aligned} \quad (4)$$

여기서 혼합확률(mixing probability), μ_{ij} 은 다음과 같다.

$$\mu_{ij}(k-1|k-1) = p_y \mu_i(k-1) / \sum_{i=1}^N p_y \mu_i(k-1) \quad (5)$$

여기서 p_{ij} 는 알고 있는 모드 전환확률(mode transition probability)이다.

2.1.2 필터링 알고리즘

$$\hat{x}_j(k|k-1) = F \hat{x}_{0j}(k-1|k-1) + G \hat{a}_j(k-1) \quad (6)$$

$$p_j(k|k-1) = F p_{0j}(k-1|k-1) F^T + G G^T \quad (7)$$

$$\hat{z}_j(k|k-1) = H \hat{x}_j(k|k-1) \quad (8)$$

$$s_j(k) = H p_j(k|k-1) H^T + r \quad (9)$$

$$k_j(k) = p_j(k|k-1) H^T s_j^{-1}(k) \quad (10)$$

$$\hat{x}_j(k|k) = \hat{x}_j(k|k-1) + k_j(k) v_j(k) \quad (11)$$

$$p_j(k|k) = p_j(k|k-1) + k_j(k) s_j(k) s_j^T(k) \quad (12)$$

여기서, 변수 $s_j(k)$ 와 $k_j(k)$ 는 각각 이노베이션 공분산과 칼만 이득값을 나타낸다.

2.1.3 모델 확률 생성

$$\mu_{ij}(k) = \hat{\wedge}_j(k) \sum_{i=1}^r p_{ij} \mu_i(k-1) / \sum_{j=1}^r \hat{\wedge}_j(k) \sum_{i=1}^r p_{ij} \mu_i(k-1) \quad (13)$$

여기서, 공산함수(likelihood function), $\hat{\wedge}_j$ 는 다음과 같다.

$$\hat{\wedge}_j(k) = \frac{1}{\sqrt{2\pi|s_j(k)|}} \exp\left(-\frac{1}{2} v_j^T(k) s_j^{-1}(k) v_j(k)\right) \quad (14)$$

2.1.4 추정치 조합

추정치와 그 나머지 공분산에 대한 조합은 아래의 식과 같이 부-모델로부터 얻어지는 추정치와 그 나머지 공분산의 확률적 합에 의해 얻어진다.

$$\hat{x}(k|k) = \sum_{j=1}^r \mu_j(k) \hat{x}_j(k|k) \quad (15)$$

$$p(k|k) = \sum_{j=1}^r \mu_j(k) (p_j(k|k)) \quad (16)$$

$$+ [\hat{x}_j(k|k) - \hat{x}(k|k)] \cdot [\hat{x}_j(k|k) - \hat{x}(k|k)]^T$$

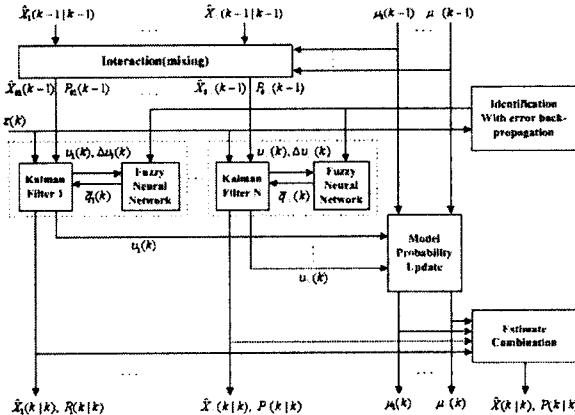
3. 퍼지 뉴럴 네트워크 기반의 상호작용 다중모델 기법

3.1 퍼지 뉴럴 네트워크를 이용한 상호작용 다중모델의 변형

기동표적 모델에서, 임의의 기간 동안 일정한 가속도 입력, $u(k)$ 는 추가적인 잡음으로 고려되고, 각각의 부-모델은 프로세스 잡음의 시변 분산을 가지는 새로운 구간별 상수 백색 가속도 모델(piecewise constant white acceleration model)로 다음과 같이 표현이 된다.

$$x(k+1) = Fx(k) + G\omega^*(k) \quad (17)$$

여기서, $\omega^*(k)$ 는 영 평균 백색 가우시안 프로세스 잡음으로 시변 분산, $q^*(k)$ 을 가진다. <그림 1>은 제안된 기법의 전반적인 개요를 나타낸다.

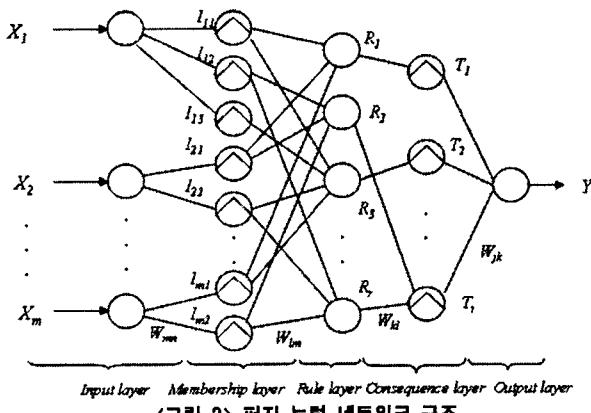


<그림 1> 퍼지 뉴럴 네트워크 기반의 상호작용 다중모델 기법

본 논문에서 사용된 퍼지 뉴럴 네트워크의 구조는 <그림. 2>와 같다. 그리고 입력단계에서 사용되는 입력값 x_1 과 x_2 는 각각 새로운 모델의 잔차 $r(k)$ 와 그 변화량 $\Delta r(k)$ 을 나타내고, 출력변수 프로세스 잡음의 시변 분산, $q^*(k)$ 를 나타내며, 소속함수층(membership layer)의 소속함수(membership function)는 가우시안 함수(gaussian function)를 사용하여 다음과 같은 소속도 $\mu_i(x_i)$ 를 가진다.

$$\mu_i(x_i) = \exp\left(-\frac{1}{2} \frac{(x_i - c_i)^2}{\sigma_i^2}\right) \quad (18)$$

여기서 c_i 와 σ_i 는 각각 i 번째 입력에 대한 가우시안 소속함수의 중심값과 표준편차(standard deviation)를 나타낸다.



<그림 2> 퍼지 뉴럴 네트워크 구조

3.2 퍼지 규칙을 이용한 파라미터 동정

제안된 방법에서 각각의 부-모델은 임의의 기동입력에 대해 퍼지규칙을 통하여 표현하고 동정된 입력값들에 의해 이루어진 필터링 알고리즘은 다음과 같다.

$$\hat{x}_j(k|k-1) = F \hat{x}_j(k-1|k-1) \quad (19)$$

$$\hat{z}_j(k|k-1) = H \hat{x}_j(k|k-1) \quad (20)$$

$$x_{ij}(k) = v_j(k) = z(k) - H \hat{x}_j(k|k-1) \quad (21)$$

$$x_{2j}(k) = \Delta v_j(k) = v_j(k) - v_j(k-1) \quad (22)$$

$$q_j(k) = \frac{\sum_{j=1}^r q_j^m \left(\prod_{i=1}^2 \theta_{A_i}^m(x_i^m(k)) \right)}{\sum_{j=1}^r \left(\prod_{i=1}^2 \theta_{A_i}^m(x_i^m(k)) \right)} \quad (23)$$

이후 식(23)의 값을 식 (7)의 q 에 입력하면 동정된 이후의 추정값과 그 공분산 \hat{x}, p 를 구할 수 있다.

4. 결 론

본 논문에서는 기동표적을 효과적으로 추적하기 위해 퍼지 뉴럴 네트워크를 이용한 상호작용 다중모델 기법을 제안하였다. 제안된 방법은 기존의 유전 알고리즘을 이용한 방법에 비해 사전학습 없이 실제 기동 중에 데이터를 형성하면서 학습과 반응을 도출할 수 있었으며, 기존의 상호작용 다중모델 기법과 칼만필터가 가지고 있는 장점을 그대로 실현할 수 있었다.

【참 고 문 헌】

- [1] Singer, R. A.: 'Estimating optimal tracking filter performance for manned maneuvering targets', IEEE Trans. Aero. Electron. Sys., AES-6, (4), pp. 473-483, 1970
- [2] Blom, H. A. P., and Bar-Shalom, Y.: 'The interacting multiple model algorithm for systems with a jump-linear smoothing application', IEEE Trans. Autom. Control, AC-33, (8), pp. 780-783, 1988
- [3] Bar-Shalom, Y., Chan, K. C., and Blom, H.A.P.: 'Tracking a maneuvering target using input estimation versus the interacting multiple model algorithm', IEEE Trans. Aero. Electron. Sys., AES-25, (2), pp. 296-300, 1989.
- [4] I. A. Gura, 'Extension of Linear Estimation Technique to Nonlinear Problem', Jour. of Astronomical Science, Vol. 4, pp. 194-205, 1968.
- [5] Y. T. Chan, A. G. C. Hu and J. B. Plant, 'A Kalman Filter Based Tracking Scheme with Input Estimation', IEEE Trans. on Aero. and Electro. sys., Vol. AES-15, No. 2, pp. 237-244, 1979.
- [6] Y. T. Chan, J. B. Plant, and J. R. T. Bottomley, 'A Kalman Tracker with a Simple Input Estimator', IEEE Trans. on Aero. and Electro. sys., Vol. AES-18, No. 2, pp. 235-241, 1992.
- [7] K. C. C. Chan, H. Leung, and V. Lee, 'Maneuvering Target Tracking Using Fuzzy Logic', IEEE Trans. on Aero. and Electro. sys., Vol. AES-28, No. 5, pp. 782-792, 1997.
- [8] T. H. S. Li, 'Estimation of one-Dimensional Radar Tracking via Fuzzy-Kalman Filter', IECON' 93, pp. 2384-2388, 1993.
- [9] C. G. Moore and C. J. Harris, 'Aspects of Fuzzy Control and Estimation', Advances in Intelligent Control, pp. 201-242, 1994.
- [10] B. J. Lee, J. B. Park, H. J. Lee and Y. H. Joo, 'Fuzzy-Logic-Based IMM Algorithm for Tracking a Maneuvering Target', IEE Proc. Radar, Sonar and Nav., Vol. 152 pp.16-22, 2005.
- [11] A. Munir and D. P. Atherton, 'Adaptive interacting multiple model algorithm for tracking a maneuvering target', IEE Proc. of Radar Sonar and Nav., Vol. 142, No.1, pp. 11-17, 1995.