

# 퍼지 뉴럴 네트워크 기반 다중모델 기법 추적 시스템

## A Fuzzy-Neural Network-Based IMM Method Tracking System

손현승\*, 주영훈\*\*, 박진배\*

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

\* 연세대학교 전기전자공학과

\*\* 군산대학교 전자정보공학부

### 요 약

본 논문에서는 기동표적의 추적에 대한 새로운 퍼지 뉴럴 네트워크 기반의 다중모델 기법을 소개한다. 표적의 가속도를 효과적으로 다루기 위하여, 이 논문에서는 표적의 가속도를 시변 변수인 표적의 추가적인 잡음으로 두고 각각의 가속도 간격의 정도에 따라 얻어지는 모든 잡음에 대한 변수에 의해 각각의 하부 모델들을 특성화시켰다. 모르는 가속도에 따른 시변 변수를 적응적으로 어릿잡기는 어렵기 때문에 정밀한 계산을 위하여 퍼지 뉴럴 네트워크가 이용되었다. 퍼지 뉴럴 네트워크의 동정을 위해서는 오차 역전파 학습법을 사용하였다. 그리고 제안된 알고리즘의 수행 가능성을 보여주기 위하여 몇 가지 예를 제시하였다.

키워드 : 기동표적 추적, 적응 다중 모델기법, 퍼지 뉴럴 네트워크

### 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 error back-propagation method is utilized to optimize each FNN. To show the feasibility of the proposed algorithm, a numerical example is provided.

Key words : Maneuvering target tracking, AIMM methods, Neuro fuzzy network

### 1. 서 론

기동표적(maneuvering target)에 대한 문제는 각종 관제 시스템, 대공 방어 시스템, 조기 경보 시스템 등에 있어서 관심 높은 대상 중에 하나였으며 현재에 있어서도 그 연구는 활발히 이루어지고 있다. 특히 군사적 시스템과 관련된 레이더, 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 소개된 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 표적

의 방향 전환이나 탐지회피를 위하여 표적이 강한 비선형 기동을 수행할 경우 가속도를 포함한 운동을 하게 되므로 기존의 등속도 운동 모델과는 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 가변 차수 기법, 입력추정 기법, 다중모델 기법등의 다양한 모델이 제시되기도 하였다[5-7]. 기존의 수학적 방법은 정확한 모델을 다루는데 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 지능 제어 기법들이 제안되었다. 그 중 퍼지 이론과 칼만필터의 융합을 통한 추적 시스템의 성능 개선에 관한 연구들이 추적 시스템에 대한 응용 분야에 활발히 적용되었다[8-10]. 이 방법은 유전 알고리즘 동정을 이용한 퍼지 규칙 기반의 추적 시스템은 칼만필터의 정확성과 유전 알고리즘을 이용한 퍼지 추론 방식의 전역 최적해 수렴 이라는 장점을 모두 살릴 수 있는 방법이었으나, 온라인 기동이라는 실제 기동중인 표적에 대한 추적 문제에 있어서 사전에 학습된 자료의 축적이 없다는 그 성능을 발휘할 수 없다는 단점을 지니고 있다.

본 논문에서는 실제 표적이 기동중인 상황에서 자료의

접수일자 : 2006년 6월 10일

완료일자 : 2006년 8월 5일

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 이러한 방법에 의해 이루어진 하나의 시스템을 적응 상호작용 다중모델 기법(AIMM : 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)의 추정치의 가중 합(weighted-sum)으로 구해진다. 여기에 표적의 가속도를 적응적으로 추정하여, 추정된 가속도에 가속도 간격(acceleration interval)을 대칭적으로 가감하여 다중모델을 구성한 적응 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 본 논문에 이용된 이론으로서 기동표적 모델과 적응 상호작용 다중모델기법을 소개하고, 3절에서는 본 논문에서 제안한 퍼지 뉴럴 네트워크 기반 적응 상호작용 다중모델을 소개한다. 4절에서는 가상표적을 설정하여 본 논문에서 제안하는 방법을 이용하여 기동표적을 추적해가는 과정을 모의실험을 통하여 보여줄 것이며, 마지막으로 5절에서는 본 논문의 결론을 도출한다.

## 2. 이론적 배경

### 2.1 기동표적 모델

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

$$x(k+1) = Fx(k) + G[u(k) + w(k)] \quad (1)$$

$$F = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad G = \begin{bmatrix} T^2/2 \\ T \end{bmatrix} \quad (2)$$

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

$$z(k) = Hx(k) + v(k) \quad (3)$$

여기서,  $H = [10]$ 는 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 칼만필터를 이용한 기동표적 추적

기동하는 표적을 추적하는 시스템은 레이터와 같은 센서로부터 얻어진 클러스터 또는 잡음이 섞여있는 측정 데이터를 이용하여 기동하는 표적의 상태를 추정하고 예측하여 표적의 궤적을 추적하는 시스템이다. 이러한 시스템의 설계시 표적 추정과정에서 생기는 여러 추정 잡음들을 고려해야 한다. 칼만필터 알고리즘은 이러한 추정 잡음들이 포함된 연속 측정값을 최소자승 알고리즘을 이용하여 시스템의 상태를 효과적으로 추정하는 알고리즘이다. 일반적으로 아래의 두 가

지 식으로 알고리즘은 시작하는데 그 하나가 잡음이 고려된 이산치 선형시스템의 상태 방정식이고, 하나는 그 상태방정식과 연관된 측정방정식이다.

$$x(k+1) = Fx(k) + Gu(k) + w(k) \quad (4)$$

여기서,  $x(k)$ 는 시간  $k$ 에서의 상태변수,  $u(k)$ 는 입력 값 또는 명령 신호(command signal),  $F(k)$ 는 시스템 행렬,  $v(k)$ 는 공분산 행렬  $Q(k)$ 를 갖는 영 평균 백색 프로세스 잡음이다.

또한, 측정 방정식은 아래 식(5)와 같으며 내용은 위의 식(3)에서 설명된 내용과 같다.

$$z(k) = Hx(k) + v(k) \quad (5)$$

칼만필터를 사용하여 가지는 주된 효과는 샘플링 타임을 기준으로 상태방정식과 측정방정식을 이용하여 순간의 상태값을 업데이트 된 상태값을 구하는 알고리즘으로 그 내용을 도식화 하면 아래 그림1.과 같다.

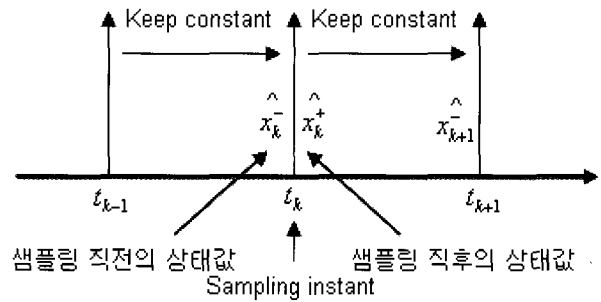


그림 1. 칼만필터의 상태값 갱신 알고리즘  
Fig. 1. Kalman filter state update algorithm

그림 1에서 나타나는 상태값의 변화는 아래 식(6)과 같이 시간에 따른  $k-1$ 과  $k$  시간에 관한 식에서부터 시작한다.

$$\hat{x}_k^+ = k_k \hat{x}_k^- + k_k z_k \quad (6)$$

여기서,  $k_k$ 는 측정치와 상태 값 사이의 관계를 연결해주는 칼만이득 이라고 부른다.

그리고 샘플링 직전과 직후의 상태 값  $\hat{x}_k^+$ ,  $\hat{x}_k^-$ 과 실제의 상태 값  $x(k)$ 와의 차이 값을  $e_k^+$ ,  $e_k^-$ 로 놓고 계산하면 칼만이득 값을 계산해 낼 수 있는데, 아래 식 (7)과 같이 정리 가 된다.

$$\hat{x}_k^+ = \hat{x}_k^- + k_k (z_k - H_k \hat{x}_k^-) \quad (7)$$

식 (7)에서는 아직 칼만이득인  $k_k$ 가 존재하기 때문에 칼만 이득을 정리하기 위하여 새로운 변수  $P_k$ 를 사용하였으며, 그 값은 식 (8)과 같이 표현된다.

$$P_k = E [e_k \cdot e_k^T] \quad (8)$$

$P_k$ 를 이용한 상태식의 변환은 갱신직전의 상태 값과 측정 값 그리고 차이값을 이용하여 칼만이득  $k_k$ 와 우리가 구하고자 하는 값  $\hat{x}_k^+$ 를 표현하고, 아래 식 (9)과 (10)은 이렇게 하여 계산된 칼만이득  $k_k$ 와 갱신된 상태값  $\hat{x}_k^+$ 를 나타낸다.

$$k_k = (H_k p_k^-)^T (H_k p_k^- + R_k)^{-1} \quad (9)$$

$$\hat{x}_k^+ = \hat{x}_k^- + (H_k p_k^-)^T (H_k p_k^- + R_k)^{-1} (z_k - H_k \hat{x}_k^-) \quad (10)$$

이상의 칼만필터에 의한 상태값 추정 과정을 도식화 하면 아래 그림 2와 같다.

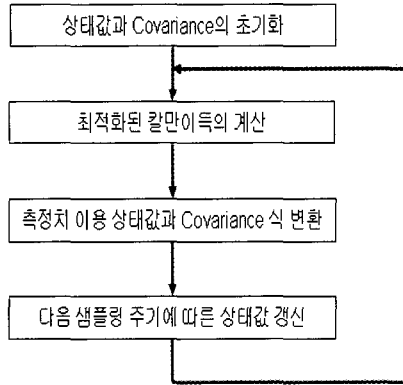


그림 2. 칼만필터의 순환과정 알고리즘  
Fig. 2. Kalman filter circulation algorithm

### 2.3 적응 상호작용 다중모델 기법

적응 상호작용 다중모델 기법은 각각의 축에 대해 제한된 수의 부-모델들을 가지고, 부-모델들은 추정된 가속도와 이러한 가속도에 대해 대칭적으로 분포하는 가속도 수준으로 표현된다. N개의 부-모델을 가지는 경우, 다중모델 집합 M은 다음과 같이 표현된다.

$$M = \{m_1, m_2, \dots, m_N\} \\ = \{\hat{a}(k), \hat{a}(k) \pm \varepsilon_1, \dots, \hat{a}(k) \pm \varepsilon_{(N-1)/2}\} \quad (11)$$

여기서,  $\hat{a}(k)$ 는 추정된 표적의 가속도를,  $\varepsilon_{(N-1)/2}$ 은 사선에 결정된 가속도 간격을 나타낸다. 적응 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 병렬로 추정된다. 적응 상호작용 모델 기법의 알고리즘[11]은 아래 4가지 내용을 주 내용으로 한다.

#### 2.3.1 추정치의 상호작용(혼합)

단 하나의 필터모델에서 벗어나 여러 개의 필터모델을 사용하여 각 모델을 간의 추정치를 어떠한 방법으로 혼합할 것인가에 대한 문제를 다음과 같은 방법에 의해 계산한다. 원하는 추정치는 각각의 추정치와 그 추정치가 지니는 확률의 가중합에 의한다.

$$\mu_{oj}(k-1|k-1) = \sum_{i=1}^N \mu_{ij}(k-1) \hat{x}_i(k-1|k-1) \quad (12)$$

$$p_{oj}(k-1|k-1) = \sum_{i=1}^N \mu_{ij}(k-1|k-1) (p_n(k-1|k-1) \\ + [(\hat{x}_n(k-1|k-1) - \hat{x}_{oj}(k-1|k-1)) \\ \times (\hat{x}_n(k-1|k-1) - \hat{x}_{oj}(k-1|k-1))^T]) \quad (13)$$

여기서, 혼합확률(mixing probability),  $\mu_{ij}$ 은 다음과 같다.

$$\mu_{ij}(k-1|k-1) = p_{ij} \mu_i(k-1) / \sum_{i=1}^N p_{ij} \mu_i(k-1) \quad (14)$$

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

#### 2.3.2 필터링 알고리즘

2.2절에서 소개했던 칼만필터 알고리즘은 본 절의 적응 상호작용 다중모델 기법에서 사용하는 부-모델(sub-model)로써 사용된다. 아래 식은 각각의 부-모델에서 사용되는 칼만 필터의 유도식이며, 각각의 부-모델에서의 추정값들은 다음 단계의 조합과정에서 그 비율에 의한 확률적 합에 의해 계산된다.

$$\hat{x}_j(k|k-1) = F \hat{x}_{oj}(k-1|k-1) + G \hat{a}_j(k-1) \quad (15)$$

$$p_j(k|k-1) = F p_{oj}(k-1|k-1) F^T + G G^T \quad (16)$$

$$\hat{z}_j(k|k-1) = H \hat{x}_j(k|k-1) \quad (17)$$

$$s_j(k) = H p_j(k|k-1) H^T + r \quad (18)$$

$$k_j(k) = p_j(k|k-1) H^T s_j^{-1}(k) \quad (19)$$

$$\hat{x}_j(k|k) = \hat{x}_j(k|k-1) + k_j(k) v_j(k) \quad (20)$$

$$p_j(k|k) = p_j(k|k-1) + k_j(k) s_j(k) s_j^T(k) \quad (21)$$

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

#### 2.3.3 모델 확률 갱신

각각의 부-모델(sub-model)이 전체에서 차지하는 값의 비율을 계산하면 아래와 같은 모델확률  $\mu_{ij}$ 에 관한 식으로 정리된다.

$$\mu_{ij}(k|k) = \wedge_j(k) \sum_{i=1}^n p_{ij} \mu_i(k-1) / \sum_{j=1}^N \wedge_j(k) \sum_{i=1}^n \wedge_j(k) p_{ij} \mu_i(k-1) \quad (22)$$

여기서, 공산함수(likelihood functions),  $\wedge_j$ 는 다음과 같다.

$$\wedge_j(k) = \frac{1}{\sqrt{2\pi |s_j(k)|}} \exp\left(-\frac{1}{2} v_j^T(k) s_j^{-1}(k) v_j(k)\right) \quad (23)$$

#### 2.3.4 추정치 조합

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

$$\hat{x}(k|k) = \sum_{j=1}^N \mu_j(k) \hat{x}_j(k|k) \quad (24)$$

$$p(k|k) = \sum_{j=1}^N \mu_j(k) (p_j(k|k) \\ + [\hat{x}_j(k|k) - \hat{x}(k|k)] \cdot [\hat{x}_j(k|k) - \hat{x}(k|k)]^T) \quad (25)$$

### 2.4 퍼지 뉴럴 네트워크 개요

본 논문에서 사용된 퍼지 뉴럴 네트워크의 구조는 그림. 3

과 같이 5단계의 계산과정을 가진다. 각 단계별 계산과정을 보면 다음과 같다.

**layer 1** : 이 층에서는 입력단계로써 계산에 사용되기 위한 입력값과 그 개수를 지정해주는 단계이다. 이곳에 사용되는 입력값  $X_1$ 과  $X_2$ 는 각각 새로운 모델의 잔차  $r(k)$ 와 그 변화량  $\Delta r(k)$ 를 사용하고, 다음 단계로 넘어가기 위한 입력값의 크기와 갯수를 지정한다.

**layer 2** : 이 층에서는 층 1에서 입력된 값을 이용하여 각 노드에서 언어적 함수화를 가지는 과정이다. 이 층에서의 모든 노드는 식(26)로 표현된다.

$$\begin{aligned} O_{1,j} &= A_{1,j}(I_1) \quad j = 1, 2, 3 \\ O_{2,j} &= A_{2,j}(I_2) \quad j = 1, 2, 3 \\ O_{3,j} &= A_{3,j}(I_3) \quad j = 1, 2, 3 \end{aligned} \quad (26)$$

여기서, 입력변수  $I_1, I_2, I_3$ 는 각각 노드의 입력값이며,  $A_{ij}$ 는 각 입력변수의 언어적 등급을 나타내는 가우시안 함수로 식 (27)로 표현된다.

$$\mu_i(x_i) = \exp\left(-\frac{1}{2}\left(\frac{x_i - c_i}{\sigma_i}\right)^2\right) \quad (27)$$

여기서,  $\mu_i(x_i)$ 는 소속도를 의미하고 사용된 변수  $C_i, \delta_i$ 는 각각  $i$ 번째 입력에 대한 가우시안 소속함수의 중심값과 표준편차(standard deviation)를 나타낸다.

**layer 3** : 이 층에서의 모든 노드는 층 2에서 계산된 값을 이용하여 식(28)과 같이 퍼지 곱(product)을 계산하는 층으로, 각 노드들의 출력은 규칙의 활성화 함수 강도로 표현이 된다.

$$O_{3,i} = \mu_i = A_{1,i}(I_1)A_{2,i}(I_2)A_{3,i}(I_3) \quad (i=1, \dots, 9) \quad (28)$$

**layer 4** : 이 층에서의 노드들은 다음의 두 가지 경우로 분리되어 계산과정을 가지는 층이다. 그 첫 번째 과정을 거치는 노드들은 규칙들의 활성화 강도를 합산하여  $i$ 번째 규칙들의 활성화 강도의 비율을 계산하는 노드들이다. 값을 수식으로 표현하면 다음과 같다.

$$O_{4,1,i} = \omega_i = \frac{\mu_i}{\sum \mu_i}, \quad (i = 1, \dots, 9) \quad (29)$$

두 번째 과정은 식(30)과 같이 계산되는 과정을 지니는 적응 노드이다.

$$O_{4,2,i} = \omega_i f_i = \omega_i (p_i I_1 + q_i I_2 + r_i I_3 + s_i) \quad (30)$$

여기서,  $\omega_i$ 는 앞의 계산  $O_{4,1,i}$ 에서 구한 정규화 된 활성화 강도이며,  $f_i$ 는 후반부의 퍼지화 된 값으로 Sugeno 모델에서와 같이 표현되며, 입력에 대한 선형적 결합으로 이루어져 있고,  $p_i, q_i, r_i, s_i$ 는  $i$ 번째 노드의 선형함수에 대한 매개 변수이다. 즉, 이 층에서의 매개변수들은 결론부 매개 변수들이다.

**layer 5** : 이 층에서는 층 4에서 출력된 모든 입력값들을 더하여 식 (31)과 같이 비퍼지화 과정이 이루어지는 부분이다.

$$O_{5,i} = \sum_i \omega_i f_i = \frac{\sum_i \mu_i f_i}{\sum_i \mu_i} \quad (31)$$

지금까지의 본 논문에서 제안하는 퍼지 뉴럴 네트워크의 전체적인 구조는 다음 그림 3.과 같다.

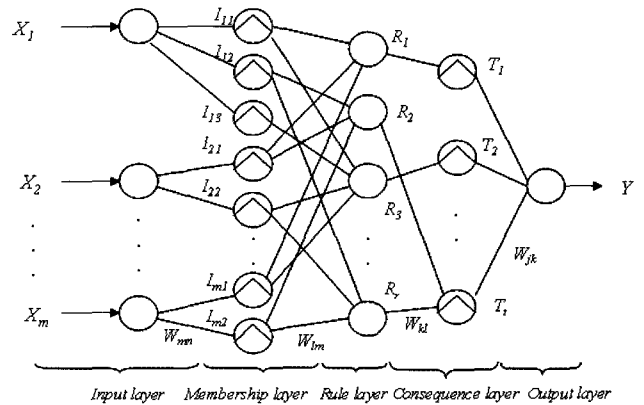


그림 3. 퍼지 뉴럴 네트워크 구조  
Fig 3. Fuzzy neural network structure

### 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 같다.

$$x(k+1) = Fx(k) + G\omega^*(k) \quad (32)$$

여기서,  $\omega^*(k)$ 는 영 평균 백색 가우시안 프로세스 잡음으로 입력가속도  $u(k)$ 를 잡음으로 포함시키고, 시변 분산,  $q^*(k)$ 을 가진다. 아래 그림 4.는 제안된 기법의 전반적인 개요를 나타낸다.

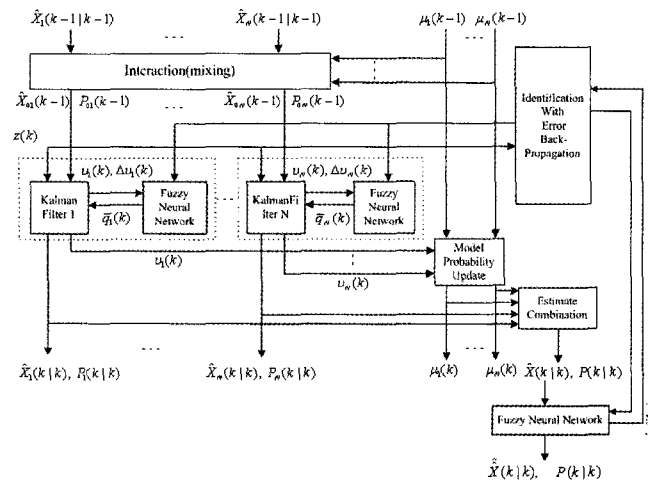


그림 4. 퍼지 뉴럴 네트워크 기반의 상호작용 다중모델 기법  
Fig. 4. Fuzzy neural network based AIMM method

제안된 방법에서 각각의 부-모델(sub-model)들은 임의의 기동입력에 대하여 잔차(residual)와 그 변화(variation)를 앞에서 언급한 새로운 모델의 데이터로 이용되고 새로운 시스템은 매 시간 적절한 프로세스의 시변 분산 값을 계산하여 각각의 부-모델(sub-model)이 추정하는 상태 값의 추정오차를 줄일 수 있도록 한다.

본 논문의 퍼지뉴럴 네트워크 과정에서 사용된 학습 알고리즘은 Error back-propagation 알고리즘으로 하나의 데이터가 입력될 때마다 앞에서 설명한 전 과정을 지나고 나서 시스템에서는 추정치와 실제 값을 비교 분석하면서 그 차이를 줄여 나가는 방법을 이용하였다.

제안된 방법에서 각각의 부-모델들은 임의의 기동입력에 대하여 퍼지규칙을 통해 표현하고 동정된 입력값들에 의해 이루어진 필터링 알고리즘을 형성한다. 동정된 퍼지화 과정을 통한 필터링 알고리즘은 다음과 같다. 상대값과 추정치의 퍼지화 계산에 의한 시변 분산값(식(37))은 기존의 분산값(식(16))을 대체하게 된다.

$$\hat{x}_j(k|k-1) = F \hat{x}_{oj}(k-1|k-1) + G \hat{a}_j(k-1) \quad (33)$$

$$\hat{z}_j(k|k-1) = H \hat{x}_j(k|k-1) \quad (34)$$

$$x_{1j}(k) = v_j(k) = z(k) - \hat{z}_j(k|k-1) \quad (35)$$

$$x_{2j}(k) = \Delta v_j(k) = v_j(k) - v_j(k-1) \quad (36)$$

$$q_j(k) = \frac{\sum_{i=1}^r \omega_j^m \left( \prod_{i=1}^2 \theta_{A_j^m}^m(x_i^m(k)) \right)}{\sum_{i=1}^r \left( \prod_{i=1}^2 \theta_{A_j^m}^m(x_i^m(k)) \right)} \quad (37)$$

$$p_j(k|k-1) = F p_{oj}(k-1|k-1) F^T + G q_j(k) G^T \quad (38)$$

$$s_j(k) = H p(k|k-1) H^T + R \quad (39)$$

$$K_j(k) = p_j(k|k-1) H^T s_j^{-1}(k) \quad (40)$$

$$\hat{x}_j(k|k) = \hat{x}_j(k|k-1) + K_j(k) \gamma_j(k) \quad (41)$$

$$p_j(k|k) = p_j(k|k-1) - K_j(k) s_j(k) K_j^T(k) \quad (42)$$

#### 4. 모의실험 및 결과고찰

이 절에서는 가상표적을 설정한 모의실험을 통하여 제안된 방법의 성능이 적절히 표현되는지를 확인하고 기존의 모델과 비교확인을 통하여 성능의 차이를 알아보려고 한다.

먼저 가상의 표적은 초기 등속도 운동을 하는 기동표적으로 초기 위치는 임의의 지점(관측점 기준 22.4km)에서 초기 속력 0.0106km/sec으로 기동을 시작한다. 40~80 샘플링 구간 동안 가속도 0.03km/sec<sup>2</sup>를 입력하여 그림 5.와 같은 가상의 기동표적 운동을 얻었다.




그림 5. 기동 표적 운동  
Fig. 5. Maneuvering target movement

표적을 추적할 제안된 알고리즘의 세부적인 조건은 다음과 같다. X축에 대한 영 평균 가우시안 측정 잡음의 표준 편차는 0.5km이고, 임의의 가속도 잡음, 즉 프로세스 잡음의 표준 편차는 0.001km/sec<sup>2</sup>이다. 그리고 이단 칼만 추정기(Two stage Kalman estimator)를 위한 바이어스 필터 및 바이어스-프리 필터의 프로세스 잡음의 표준편차는 각각 0.01km/sec<sup>2</sup>, 0.001km/sec<sup>2</sup>이다. 각각의 부-모델에 대한 전환확률행렬(switching probability matrix)과 초기모델확률(initial model probability)은 다음과 같이 결정된다.

$$p_{ij} = \begin{cases} 0.97 & \text{if } i = j \\ \frac{1-0.97}{N-1} & \text{otherwise} \end{cases} \quad (43)$$

$$\mu_i(0) = \begin{cases} 0.6 & \text{if } i = j \\ \frac{1-0.6}{N-1} & \text{otherwise} \end{cases} \quad (44)$$

기동표적 모델의 추적을 위한 속도 움직임을 살펴보면 그림 6.에서 볼 수 있듯이, 구간 40~80사이의 상승 구간은 0.03km/sec<sup>2</sup>의 가속도 입력에 의한 속도 상승 구간이다. 이렇게 실제 기동 표적과 기존에 알려져 있는 상호작용 다중모델 기법에 의한 추적, 제안된 퍼지뉴럴 네트워크 기반의 다중모델 기법의 추적 값을 비교하면서 본 논문에서 제안된 기법의 성능을 판단하고자 한다.

표적의 위치에 대한 비교결과인 그림 7.에서는 매우 미미한 차이를 보이기 때문에 구간 및 위치 값을 일부 구간을 확대하고 비교대상을 기동표적의 실제 값과 잡음을 동반한 측정 값, 그리고 제안된 기법에 의해 도출된 값을 비교하여 그림 8.에 도시하였다. 그림 8.에서 볼 수 있듯이 최초 큰 오차를 동반하지만 즉각적으로 반응하여 비교대상 방법보다 훨씬 더 실제 표적의 값과 유사한 값을 유지하면서 추적을 지속해 나갈 수 있다.

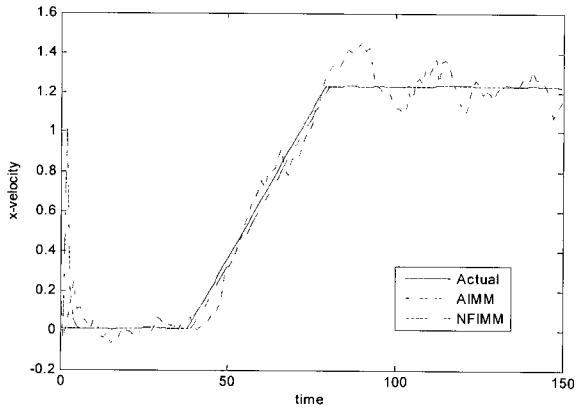


그림 6. 속도 추적 결과  
Fig. 6. Velocity tracking result

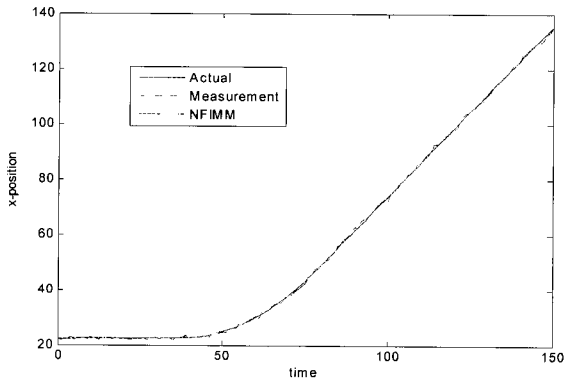


그림 7. 위치 추적 결과  
Fig. 7. Position tracking result




그림 8. 위치 추적 결과 일부구간  
Fig. 8. Parted position tracking result

위 그림에서 볼 수 있듯이 기존의 방법인 상호작용 다중 모델 기법에 의한 추적 방법은 실제 표적을 추적하는 효과는 있지만 그 차이가 제안된 방법에 비해 크며, 주어진 잡음의 처리에 있어서 그 성능이 훨씬 미미함을 알 수 있다.

제안된 기법은 위치 추적 결과 그래프 및 일부구간의 확대된 결과 그래프를 보면 기존의 방법에 비해 보다 완만하게

실 표적을 추적하는 모습과 시간의 흐름에 따라 점진적으로 실 표적과 근접함을 볼 수 있다.

다음으로 기존의 적응 상호작용 다중모델 기법과 제안된 기법과의 성능의 차이를 보이기 위해 실표적과의 차이인 RMSE를 계산하여 도시하였다.




그림 9. 표준 위치 오차  
Fig. 9. RMSE of position

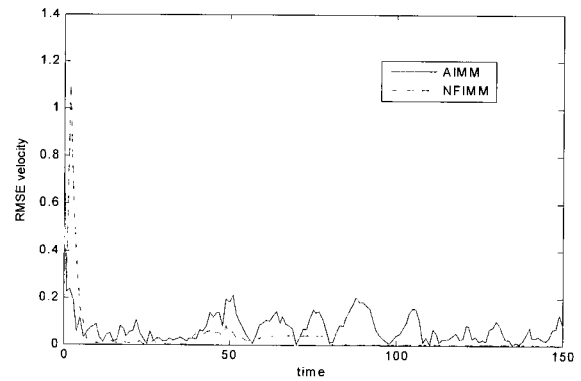


그림 10. 표준 속도 오차  
Fig. 10. RMSE of velocity

본 모의실험에서 적응 상호작용 모델기법은 다중모델을 구성한 값이 실험에 따라 적응적으로 변환하게 되므로 여러 번의 실험을 통해 그 성능이 우수한 결과를 채택하였으며, 제안된 방법 역시 초기치 및 반복실험에 의한 결과가 변환하는 점을 인식하여 여러 번의 실험에서 그 성능이 우수한 결과를 채택하였다.

#### 4. 결 론


본 논문에서는 기동표적을 효과적으로 추적하기 위해 퍼지 뉴럴 네트워크를 이용한 상호작용 다중모델 기법을 제안하였다. 본 논문이 제안한 가장 큰 원인은 실기동중 추적이라는 것에 그 의미가 있다. 최근 유전 알고리즘을 이용한 매개변수 동정을 통한 방법이 성능을 높이는 좋은 방법으로 제안되었으나 실제 표적의 위치 및 속도 값을 오프라인 동정을 통한 학습화라는 단계를 거치므로 실제 표적의 기동이 완료된 후에 다시 초기값부터 동정해 가는 과정을 반복하게 된

다. 이 방법은 사전의 학습화된 데이터가 없을 경우 추적 능력이 현저히 떨어진다는 단점을 지니고 있기 때문에 본 논문에서는 이점에 의미를 두고 새로운 기법을 유도하였다. 제안된 알고리즘은 표적이 기동하는 동안 빠른 학습을 실시하고 동시에 추적을 해 나가는 온라인(on-line) 기동추적기능을 우수한 성능으로 수행함을 실험을 통해 확인하였다.

### 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.

### 저 자 소 개



**손현승(Hyun Seung Son)**

2000년 : 해군사관학교(이학사)

2005~현재 : 연세대학교 전기전자공학과 석사과정

Tel : 02-2123-2773  
 Fax : 02-362-4539  
 E-mail : ssonhyung@control.yonsei.ac.kr



**주영훈(Young Hoon Joo)**

1995년 : 연세대학교 공과대학 (공학박사)

1986~1995 : 삼성전자(주) 자동화연구소 팀장

1995~현재 : 국립 군산대학교 정보전자공학부 교수

2006~현재 : 한국 퍼지 및 지능시스템 학회 부회장

2006~현재 : 제어 자동화 시스템 공학회 평의원, 지능시스템 연구회 회장, 국문논문지 담당이사

2000~현재 : 대한전기학회 D부문 총무이사

Tel : 063-469-4706  
 Fax : 063-466-2086  
 E-mail : yhjoo@kunsan.ac.kr



**박진배(Jin Bae Park)**

1990년 : 캔사스 주립대학교(미) (공학박사)

1992~현재 : 연세대학교 전기전자공학과 교수

1994~현재 : 산업자원부 기획평가위원

2001~현재 : 산업기술연구회 기획평가위원회 위원

2001~현재 : 연세대 자동화기술연구소 소장  
 2004~현재 : 제어 자동화 시스템 공학회 감사  
 2006~현재 : 연세대학교 연구처장

Tel : 02-2123-2773  
 Fax : 02-362-4539  
 E-mail : jbpark@yonsei.ac.kr