

기동표적 추적을 위한 유전 알고리즘 기반 상호작용 다중모델 기법

論 文

52D-1-3

A GA-Based IMM Method for Tracking a Maneuvering Target

李 範 植* · 周 永 焄** · 朴 珍 培***

(Bum-Jik Lee · Young-Hoon Joo · Jin-Bae Park)

Abstract - The accuracy in maneuvering target tracking using multiple models is resulted in by the suitability of each target motion model to be used. The interacting multiple model (IMM) method and the adaptive IMM (AIMM) method require the predefined sub-models and the predetermined acceleration intervals, respectively, in consideration of the properties of maneuvers in order to construct multiple models. In this paper, to solve these problems, a genetic algorithm (GA) based-IMM method using fuzzy logic is proposed. In the proposed method, the acceleration input is regarded as an additive noise and a sub-model is represented as a set of fuzzy rules to calculate the time-varying variances of the process noises of a new piecewise constant white acceleration model. The proposed method is compared with the AIMM algorithm in simulation.

Key Words : Maneuvering target tracking, IMM method, AIMM method, GA-based IMM method, Fuzzy logic,

1. 서 론

기동표적(maneuvering target)의 추적 문제는 상태추정(state estimation)의 분야에서 수십 년 간 연구되어 왔다. 칼만 필터(Kalman filter)는 표적의 상태를 추정하기 위해 널리 이용되어 왔으나, 기동(maneuver)이 발생하는 경우, 그 성능은 현저히 저하될 수 있다. 이러한 문제점을 해결하기 위해 여러 가지 기법들이 연구 및 적용되어 왔다. 먼저 1970년에 Singer는 표적의 기동 가속도를 시간 연관(time correlation)이 있는 1차 마코프 프로세스(first order Markov process)로 가정하여 기동을 표현할 수 있는 모델을 제안하였다[1]. Singer의 방법 이후, 기동표적 추적을 위한 최근의 연구는 크게 두 가지 접근 방법으로 구분된다. 첫 번째 접근 방법은 기동을 탐지하여 이에 적절히 대처하는 방법이다. 이러한 접근 방법에는 Bogler에 의해 제안된 입력추정(input estimation) 기법[2]과 Bar-Shalom에 의해 제안된 가변차원(VD : Variable Dimension) 필터[3] 등이 있다. 다른 하나의 접근 방법은 다중모델을 이용하여 표적의 운동을 표현하는 방법으로 Tugnait에 의해 제안된 일반화된 의사 베이시안(GPB : Generalized Pseudo-Bayesian) 기법[4]과 상호작용 다중모델(IMM : Interacting Multiple Model) 기법[5] 등이 있다. 본 논문에서는 주로 두 번째 접

근 방법을 다룬다.

다중모델을 이용한 기동표적 추적의 정확성은 기동에 대해 사용될 각각의 표적 운동모델의 적합성에 기인한다. 상호작용 다중모델(IMM : Interacting Multiple Model) 기법의 경우, 최종 추정치(estimate)는 각각의 모델이 유효할 확률에 따른 부-모델(sub-model)들의 추정치의 가중 합(weighted sum)으로 구해진다. 그러나 이 기법은 다중모델을 구성하기 위해, 기동의 특성을 고려하여 다양한 크기(dimension)나 다양한 수준의 프로세스 잡음(process noise)을 가지는 사전 설정된 부-모델들을 필요로 한다. 반면에 적응 상호작용 다중모델(AIMM : Adaptive Interacting Multiple Model) 기법[6]은 표적의 가속도를 적응적으로 추정하여, 추정된 가속도에 가속도 간격(acceleration interval)을 대칭적으로 가감하여 다중모델을 구성하므로, 사전 설정된 부-모델들을 필요로 하지 않는다. 그러나 다중모델을 구성하기 위해 필요한 가속도 간격은 마찬가지로 기동의 특성에 따라 결정되어야 한다.

본 논문에서는 기동표적을 효과적으로 추적하고, 위에서 언급한 이러한 문제점들을 해결하기 위해 퍼지논리(fuzzy logic)를 이용한 유전 알고리즘(GA : Genetic Algorithm) 기반 상호작용 다중모델기법을 제안한다. 제안된 방법에서, 기동입력은 추가적인 잡음으로 고려되고, 하나의 부-모델은 프로세스 잡음의 시변 분산(time-varying variance)을 계산하기 위한 퍼지규칙들로 표현된다, 또한 임의의 기동입력에 대하여 이러한 퍼지모델의 매개변수와 구조를 동시에 동정하기 위해 유전 알고리즘이 적용된다. 제안된 기법에서의 다중모델은 여러 기동입력에 대하여 동정된, 다양한 프로세스 잡음의 시변 분산을 가지는 퍼지모델들로 구성된다.

본 논문의 구성은 다음과 같다. 2절에서는 이론적 배경으

* 正 會 員 : 延世大學教 電氣電子工學科 博士課程

** 正 會 員 : 群山大學教 電子情報工學部 副教授 · 工博

*** 正 會 員 : 延世大學教 電氣電子工學科 教授 · 工博

接受日字 : 2002年 7月 3日

最終完了 : 2002年 9月 9日

로 기동표적 모델과 적응 상호작용 다중모델기법을 언급하고, 3절에서는 본 논문에서 제안한 기법을 언급한다. 4절에서는 모의실험을 통하여, 제안된 기법의 추적 성능이 적응 상호작용 다중모델기법과 비교되고, 마지막으로 5절에서는 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.

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

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

여기서, $x(k) = [p \dot{p}]^T = [p \ v]^T$ 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.

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

여기서, $H = [1 \ 0]$ 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 간의 상관관계(correlation)는 영으로 가정된다.

2.2 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. N 개의 부-모델을 가지는 경우, 다중모델의 집합 M 은 다음과 같이 표현된다.

$$M = \{m_1, m_2, \dots, m_N\} \\ = \{\hat{a}(k), \hat{a}(k) \pm \epsilon_1, \dots, \hat{a}(k) \pm \epsilon_{(N-1)/2}\} \quad (3)$$

여기서 $\hat{a}(k)$ 는 추정된 표적의 가속도를, $\epsilon_{(N-1)/2}$ 은 사전에 결정된 가속도 간격을 나타낸다. 적응 상호작용 다중모델기법에서 표적의 가속도는 바이어스(bias) 필터와 바이어스-프리(bias-free) 필터로 구성된 이단 칼만 추정기(two-stage Kalman estimator)에 의해 각각의 축에 대해 병렬로 추정된다[7].

적응 상호작용 다중모델 기법의 알고리즘은 다음과 같다[6]:

추정치의 상호작용(혼합)

$$\hat{x}_0(k-1|k-1) = \sum_{i=1}^I \mu_{ij}(k-1|k-1) \hat{x}_i(k-1|k-1) \quad (4)$$

$$P_{0j}(k-1|k-1) = \sum_{i=1}^I \mu_{ij}(k-1|k-1) \cdot \{P_i(k-1|k-1) \\ + [\hat{x}_i(k-1|k-1) - \hat{x}_0(k-1|k-1)] \cdot \\ [\hat{x}_i(k-1|k-1) - \hat{x}_0(k-1|k-1)]^T\} \quad (5)$$

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

$$\mu_{ij}(k-1|k-1) = p_{ij} \mu_i(k-1) / \sum_{i=1}^I p_{ij} \mu_i(k-1) \quad (6)$$

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

필터링 알고리즘

$$\hat{x}_j(k|k-1) = F \hat{x}_{0j}(k-1|k-1) + G \hat{a}_j(k-1) \quad (7-1)$$

$$P_j(k|k-1) = F P_{0j}(k-1|k-1) F^T + G q G^T \quad (7-2)$$

$$\hat{z}_j(k|k-1) = H \hat{x}_j(k|k-1) \quad (7-3)$$

$$S_j(k) = H P_j(k|k-1) H^T + R \quad (7-4)$$

$$K_j(k) = P_j(k|k-1) H^T S_j^{-1}(k) \quad (7-5)$$

$$\hat{x}_j(k|k) = \hat{x}_j(k|k-1) + K_j(k) [z(k) - \hat{z}_j(k|k-1)] \quad (7-6)$$

$$P_j(k|k) = P_j(k|k-1) - K_j(k) S_j(k) K_j^T(k) \quad (7-7)$$

모델 확률 갱신

$$\mu_j(k) = \Lambda_j(k) \sum_{i=1}^I p_{ij} \mu_i(k-1) / \sum_{i=1}^I \Lambda_i(k) \sum_{i=1}^I p_{ij} \mu_i(k-1) \quad (8)$$

여기서 공산함수(likelihood function), Λ_j 는 다음과 같다.

$$\Lambda_j(k) = \kappa[r_j(k); 0, S_j(k)] \\ = \frac{1}{\sqrt{(2\pi)^m |S_j(k)|}} \exp\left(-\frac{1}{2} r_j^T(k) S_j^{-1}(k) r_j(k)\right) \quad (9)$$

추정치 조합

$$\hat{x}(k|k) = \sum_{j=1}^I \mu_j(k) \hat{x}_j(k|k) \quad (10)$$

$$P(k|k) = \sum_{j=1}^I \mu_j(k) \{P_j(k|k) \\ + [\hat{x}_j(k|k) - \hat{x}(k|k)] \cdot [\hat{x}_j(k|k) - \hat{x}(k|k)]^T\} \quad (11)$$

3. 유전 알고리즘 기반 상호작용 다중모델 기법

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 표현된다.

$$x(k+1) = Fx(k) + Gw^*(k) \quad (12)$$

여기서 $w^*(k)$ 는 영 평균 백색 가우시안 프로세스 잡음으로 시변 분산, $q^*(k)$ 을 가진다.

그림 1은 제안된 기법의 전반적인 개요를 나타낸다. 제안된 방법에서 하나의 부-모델은 임의의 기동입력에 대하여, 잔차(residual)와 그 변화(variation) 및 프로세스 잡음의 시변 분산 사이의 관계를 이용하여 앞에서 언급한 새로운 모델의 프로세스 잡음의 시변 분산을 계산하기 위한 퍼지규칙들의 집합으로 표현된다. 또한 여러 기동입력에 대하여 이러한 퍼지모델의 매개변수와 구조를 동정하기 위해 유전 알고리즘이 적용된다.

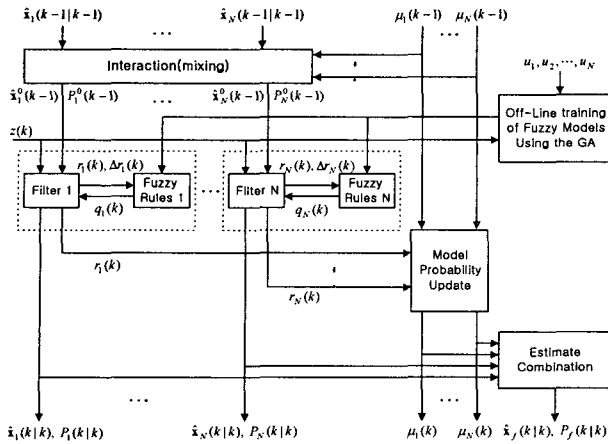


그림 1 유전 알고리즘 기반 상호작용 다중모델기법
Fig. 1 The GA based IMM method

3.1 유전 알고리즘을 이용한 퍼지모델 동정

본 논문에서 사용된 퍼지추론(fuzzy inference) 규칙은 입력 출력 공간 내에서 임의로 분할되는(scatter-partitioned) 구조를 가지며, 다음과 같이 표현된다.

$$\text{rule } l: \text{ If } x_1 \text{ is } A_1^l \text{ and } x_2 \text{ is } A_2^l, \text{ then } y \text{ is } w^l \quad (13)$$

여기서 두 입력변수, x_1 과 x_2 는 각각 새로운 모델의 잔차, $r(k)$ 와 그 변화, $\Delta r(k)$ 을 나타내고, 출력변수, y 는 l 번째 규칙에 대한 프로세스 잡음의 시변 분산, $q_i^*(k)$ 을 나타내며, w^l 는 실수 값이고, A_i^l 는 가우시안 소속함수(Gaussian membership function)로 다음과 같은 소속도(membership grade), $\mu_i^l(x_i)$ 를 가진다.

$$\mu_i^l(x_i) = \exp \left[-\frac{1}{2} \left(\frac{x_i - c_i^l}{\sigma_i^l} \right)^2 \right] \quad (14)$$

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

본 논문에서는 이러한 퍼지모델의 매개변수와 규칙수를 동정하기 위해 유전 알고리즘이 적용된다[9-11]. 유전암호화(genetic coding)는 하나의 퍼지규칙이 하나의 염색체(chromosome)로 표현되는 방식으로 유전 알고리즘을 이용한 퍼지 모델링은 유전암호화부터 시작된다. 또한 잠재적인 해들이 암호화되는 과정은 유전 알고리즘의 성능에 중요한 역할을 한다. 제안된 유전암호화 방법은 그림 2에서 묘사된다. 이 방법에서 매개변수 스트링과 규칙수 스트링은 각각 퍼지규칙의 전건부(premise)와 후건부(consequent) 매개변수 및 규칙수를 최적화시키기 위해 사용된다. 매개변수 스트링은 전건부 및 후건부 스트링으로 구성된다. 전건부 스트링은 가우시안 소속함수의 중심값, c_i^l 와 표준편차, σ_i^l 로 구성되고, 후건부 스트링은 프로세스 잡음의 시변 분산을 나타내는 실수치, w^l 로 선택된다. 또한 규칙수 스트링은 2진 스트링을 이용하여, 유효한 규칙에는 1을 유효하지 않은 규칙에는 0을 할당한다.

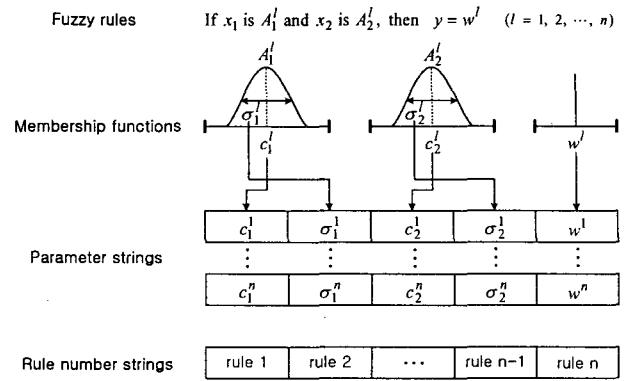


그림 2 제안된 유전 암호화 방법
Fig. 2 The proposed genetic coding method

초기 개체군(population)은 개체군의 크기만큼 초기 개체(individual)들로 구성된다. 각각의 초기 개체의 전건부 스트링은 잔차, $r(k)$ 와 그 변화, $\Delta r(k)$ 의 전체 범위 내에서 임의로 결정되고, 이에 따른 후건부 스트링은 프로세스 잡음의 표준편차의 가능한 범위 내에서 임의로 다음과 같이 결정된다[8].

$$0.5(a_M + \sqrt{q}) \leq \sigma^*(k) \leq (a_M + \sqrt{q}) \quad (15)$$

여기서 $\sigma^*(k)$ 는 프로세스 잡음의 표준편차를, a_M 는 가속도 입력의 최대 값을 나타낸다.

각각의 개체는 오차와 규칙수에 반비례하도록 설정된 다음과 같은 적합도함수(fitness function)에 의해 평가된다.

$$\text{fitness} = \lambda \frac{1}{\text{error} + 1} + (1 - \lambda) \frac{1}{\text{rule number} + 1} \quad (16)$$

여기서 λ 는 오차와 규칙수의 상관관계의 정도를 나타내며, 오차는 다음과 같이 정의된다.

$$\text{error} = \sqrt{(\Sigma \text{position error})^2 + (\Sigma \text{velocity error})^2} \quad (17)$$

3.2 유전 알고리즘 기반 상호작용 다중모델 기법

제안된 방법에서 각각의 부-모델은 임의의 기동입력에 대하여 유전 알고리즘에 의해 학습된 퍼지규칙들로 표현된다. N 개의 부-모델을 가지는 경우, 다중모델의 집합 M 은 다음과 같이 표현된다.

$$M = \{m_1, \dots, m_N\} = \{ \text{fuzzy rules } 1, \dots, \text{fuzzy rules } M \} \quad (18)$$

각각의 부-모델에서 동정된 퍼지 규칙을 이용한 필터링 알고리즘은 다음과 같다.

$$\hat{x}_j(k|k-1) = F \hat{x}_{0j}(k-1|k-1) \quad (19-1)$$

$$\hat{z}_j(k|k-1) = H \hat{x}_j(k|k-1) \quad (19-2)$$

$$x_1(k) = r_j(k) = z(k) - \hat{z}_j(k|k-1) \quad (19-3)$$

$$x_2(k) = \Delta r_j(k) = r_j(k) - r_j(k-1) \quad (19-4)$$

$$q_j(k) = \frac{\sum_{l=1}^M w^l (\prod_{i=1}^2 \mu_i^l(x_i(k)))}{\sum_{l=1}^M (\prod_{i=1}^2 \mu_i^l(x_i(k)))} \quad (19-5)$$

$$P_j(k|k-1) = F P_{0j}(k-1|k-1) F^T + G q_j(k) G^T \quad (19-6)$$

$$S_j(k) = HP_j(Mk-1)H^T + R \quad (19-7)$$

$$K_j(k) = P_j(Mk-1)H^T S_j^{-1}(k) \quad (19-8)$$

$$\hat{x}_j(Mk) = \hat{x}_j(Mk-1) + K_j(k)r_j(k) \quad (19-9)$$

$$P_j(Mk) = P_j(Mk-1) - K_j(k)S_j(k)K_j^T(k) \quad (19-10)$$

지금까지 언급한 것처럼, 제안된 기법의 목적은 기존의 기법들이 가지는 수학적 한계, 즉 상호작용 다중모델기법이 다중모델을 구성하기 위해 기동의 특성을 고려한 사전 설정된 부-모델들을 필요로 하고, 또한 적용 상호작용 다중모델 기법이 마찬가지로 다중모델을 구성하기 위해 기동 특성을 고려한 사전에 결정된 가속도 간격을 필요로 하는 등의 단점들을 보완하고, 동시에 표적의 추적성능을 향상시키는 것이다.

4. 모의실험 및 결과고찰

이 절에서는 모의실험을 통하여 제안된 방법의 성능이 적용 상호작용 다중모델기법과 비교된다. 모의실험은 두 부분으로 나뉘어 수행된다. 하나는 다중모델을 구성하기 위해 유전 알고리즘을 이용하여 오프라인(offline) 상에서 임의의 가속도 입력에 대해 최적의 퍼지규칙을 얻기 위한 모의실험이고, 다른 하나는 실제 온라인(online) 상에서 기동표적을 추적하기 위한 모의실험이다.

본 모의실험에서 사용된 유전 알고리즘의 초기 매개변수는 표 1과 같다.

표 1 유전 알고리즘의 초기 매개변수
Table 1 The initial parameters of the GA

매개변수	값
최대 세대수	100
최대 규칙수	50
개체군 크기	500
교차율	0.9
돌연변이율	0.01
λ	0.95

표적의 최대 가속도 입력은 0.1 km/s^2 로 가정되고, 부-모델들을 구성하기 위한 퍼지 규칙들의 집합들은 가속도 입력 $u_1=0.001 \text{ km/s}^2$, $u_2=0.01 \text{ km/s}^2$ 및 $u_3=0.1 \text{ km/s}^2$ 에 대하여 각각 학습되고, 학습된 결과를 보여주는 퍼지규칙들은 표 2.1, 표 2.2 및 표 2.3과 같다.

표적의 초기 상태는 $x-y$ 평면상에서 x 축에 대하여 45° 선상에서 22.4 km의 거리에서 0.015 km/s 의 일정한 속도로 이동한다. 표적의 기동을 위해, 40-60 스캔 동안 x 축에 대하여 0.01 km/s^2 , 80-90 스캔 동안 y 축에 대하여 0.06 km/s^2 , 및 120-140 스캔 동안 x 축에 대하여 -0.03 km/s^2 의 가속도 입력을 주어 그림 3과 같은 가상적 표적의 운동을 얻었다.

표 2.1 가속도 입력 $u_1=0.001 \text{ km/s}^2$ 에 대해 학습된 퍼지규칙들

Table 2.2 The fuzzy rules trained for acceleration input $u_1=0.001 \text{ km/s}^2$

규칙수	$u_1=0.001 \text{ km/s}^2$				
	c_1	σ_1	c_2	σ_2	w
1	2.330	0.376	0.254	2.591	0.215×10^{-5}
2	-0.934	3.615	-1.994	4.134	0.399×10^{-5}
3	1.273	1.904	-1.660	0.438	0.400×10^{-5}
4	2.453	2.436	-0.915	5.081	0.395×10^{-5}
5	2.626	2.264	-0.413	2.913	0.398×10^{-5}
6	2.445	0.937	2.659	5.467	0.388×10^{-5}
7	1.440	2.979	0.491	3.385	0.400×10^{-5}
8	0.541	1.400	-0.120	5.353	0.400×10^{-5}
9	1.281	3.035	-0.194	2.300	0.397×10^{-5}

표 2.2 가속도 입력 $u_2=0.01 \text{ km/s}^2$ 에 대해 학습된 퍼지 규칙들

Table 2.2 The fuzzy rules trained for acceleration input $u_2=0.01 \text{ km/s}^2$

규칙수	$u_2=0.01 \text{ km/s}^2$				
	c_1	σ_1	c_2	σ_2	w
1	0.290	2.588	-0.311	3.965	0.120×10^{-3}
2	-0.262	0.128	-0.007	0.732	0.055×10^{-3}
3	-0.246	0.188	1.302	2.340	0.056×10^{-3}
4	-1.330	0.634	-1.800	1.737	0.115×10^{-3}
5	0.464	0.568	-0.235	0.486	0.121×10^{-3}
6	-1.903	0.705	-0.399	3.820	0.100×10^{-3}
7	-1.891	0.140	-1.747	0.494	0.108×10^{-3}
8	-0.976	0.187	-1.366	4.191	0.039×10^{-3}

표 2.3 가속도 입력 $u_3=0.1 \text{ km/s}^2$ 에 대해 학습된 퍼지 규칙들

Table 2.3 The fuzzy rules trained for acceleration input $u_3=0.1 \text{ km/s}^2$

규칙수	$u_3=0.1 \text{ km/s}^2$				
	c_1	σ_1	c_2	σ_2	w
1	-2.533	0.568	-1.577	3.607	0.026×10^{-1}
2	0.302	1.327	0.806	0.039	0.100×10^{-1}
3	0.528	0.265	-0.381	2.963	0.096×10^{-1}
4	-0.895	0.350	0.722	2.050	0.040×10^{-1}
5	-0.084	0.204	0.241	2.091	0.083×10^{-1}
6	-1.883	0.293	-2.276	1.568	0.058×10^{-1}
7	-1.072	0.314	-2.166	0.692	0.057×10^{-1}
8	0.944	0.118	1.267	2.539	0.046×10^{-1}




그림 3 표적 운동
Fig. 3 The target motion

각각의 축에 대하여, 영 평균 백색 가우시안 측정 잡음의 표준 편차는 0.5 km 이고, 임의의 가속도 잡음, 즉 프로세스 잡음의 표준편차는 0.001 km/s^2 이다. 또한 이단 칼만 추정기를 위한 바이어스 필터 및 바이어스-프리 필터의 프로세스 잡음의 표준편차는 각각 0.01 km/s^2 와 0.001 km/s^2 과 같다 [6]. 각각의 부-모델에 대한 전환확률행렬 (switching probability matrix)과 초기모델확률 (initial model probability)은 다음과 같이 선택된다.

$$P_{ij} = \begin{cases} 0.97 & \text{if } i=j \\ \frac{1-0.97}{N-1} & \text{otherwise} \end{cases} \quad (20)$$

$$\mu_i(0) = \begin{cases} 0.6 & \text{if } i=1 \\ \frac{1-0.6}{N-1} & \text{otherwise} \end{cases} \quad (21)$$

적용 상호작용 다중모델기법에서 추정된 가속도에 가감되는 부-모델들의 가속도 간격은 AIMM3(3개의 다중모델)의 경우에 0.04이고, AIMM5(5개의 다중모델)의 경우 0.02와 0.04로 선택된다. 이러한 가속도 수준은 기동의 특성을 고려하여, 여러 번의 실험을 통하여 가장 우수한 값들로 결정되었다. 100번의 몬테카를로(Monte Carlo) 모의실험의 결과 및 수치적 결과 비교는 각각 그림 4와 표 3에 나타난다. 여기서, 각각의 기법에 대한 성능 비교는 다음의 식과 같은 위치 및 속도에 대한 표준 오차(normalized error)를 적용하였다.


$$P_e(k) = \frac{\sqrt{\sum_{s=1}^{N_s} (p_x^s(k) - \hat{p}_x^s(k))^2 + (p_y^s(k) - \hat{p}_y^s(k))^2}}{\sqrt{\sum_{s=1}^{N_s} (p_x^s(k) - z_x^s(k))^2 + (p_y^s(k) - z_y^s(k))^2}}$$

$$V_e(k) = \frac{\sqrt{\sum_{s=1}^{N_s} (v_x^s(k) - \hat{v}_x^s(k))^2 + (v_y^s(k) - \hat{v}_y^s(k))^2}}{\sqrt{\sum_{s=1}^{N_s} (v_x^s(k) - \bar{v}_x^s(k))^2 + (v_y^s(k) - \bar{v}_y^s(k))^2}}$$

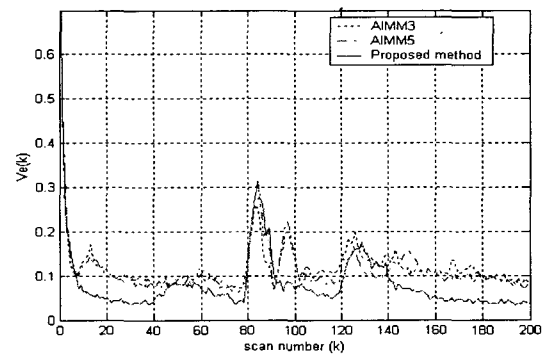
여기서 $p_x^s(k)$, $p_y^s(k)$ 와 $\hat{p}_x^s(k)$, $\hat{p}_y^s(k)$ 는 각각의 축에 대한 실제 및 추정위치이고, $z_x^s(k)$ 와 $z_y^s(k)$ 는 표적의 측정위치이다. $v_x^s(k)$, $v_y^s(k)$ 와 $\hat{v}_x^s(k)$, $\hat{v}_y^s(k)$ 는 각각의 축에 대한 실제 및 추정속도이고, $\bar{v}_x^s(k)$ 와 $\bar{v}_y^s(k)$ 는 표적의 측정속도이다. N_s 는 모의실험의 수행 횟수를 의미한다. 또한 각각의 기법들에 대한 수치적인 결과 비교 및 사용된 퍼지 규칙의 수는 표 6에서 보여준다. 수치적 결과는 표준오차의 합을 전체 스캔, S 로 나눈 다음 식을 이용하여 비교하였다.

$$\zeta_p = \frac{\sum_{k=1}^S P_e(k)}{S}$$

$$\zeta_v = \frac{\sum_{k=1}^S V_e(k)}{S}$$



(1) 표준 위치 오차



(2) 표준 속도 오차

그림 4 모의실험 결과

Fig. 4 The simulation results

표 3 수치적 결과 비교

Table 3 The comparison of the numerical results

Configuration	No. of sub-models	Numerical results	
		ζ_p	ζ_v
AIMM3	3	0.6089	0.1235
AIMM5	5	0.6003	0.1176
GA-based IMM	3	0.5138	0.0845

본 모의실험에서 적용 상호작용 다중모델기법은 다중모델을 구성하기 위해 가속도 입력에 가감되는 가속도 간격을 여러 번의 실험을 통하여 가장 성능이 우수한 것으로 선택하였다. 반면, 제안된 방법은 실제 상황에서 표적의 기동입력을 알지 못한다는 가정 하에, 여러 기동입력에 대해 학습을 통해 다중모델을 구성하였다. 따라서, 제안된 방법은 기존의 기법들이 가지는 단점들을 보완하였고, 표 3의 수치적 결과에서 보듯이 표적 추적성능을 동시에 향상시켰다.

5. 결 론

본 논문에서는 기동표적을 효과적으로 추적하기 위해 퍼지논리를 이용한 유전 알고리즘 기반 상호작용 다중모델기법을 제안하였다. 제안된 방법에서 기동입력은 추가적인 잡음으로 고려되고, 하나의 부-모델은 임의의 기동입력에 대하여, 잔차와 그 변화 및 프로세스 잡음의 시변 분산 사이의 관계를 이용하여 새로운 구간별 상수 백색 가속도 모델의 프로세스 잡음의 시변 분산을 계산하기 위한 퍼지규칙들의 집합으로 표현되었다. 또한 이러한 퍼지모델의 매개변수와 구조를 동정하기 위해 유전 알고리즘이 적용되었고, 여러 기동입력에 대하여 이들 퍼지모델들을 학습시킴으로써 다중모델을 구성하였다. 제안된 방법은 기존의 기법들이 가지는 수학적 한계를 보완하였고, 또한 모의실험 결과는 제안된 방법의 추적 성능이 적응 상호작용 다중모델기법과 비교하여 우수함을 보여주었다.

참 고 문 헌

[1] R. A. Singer, "Estimating optimal tracking filter performance for manned maneuvering targets," IEEE Trans. Aerosp. Electron. Syst., Vol. AES-6, No. 4, pp. 473-483, July, 1969.

[2] P. L. Bogler, "Tracking a maneuvering target using input estimation," IEEE Trans. Aerosp. Electron. Syst., Vol. AES-23, No. 3, pp. 298-310, May, 1987.

[3] Y. Bar-Shalom and K. Birmiwal, "Variable dimension filter for maneuvering target tracking," IEEE Trans. Aerosp. Electron. Syst., Vol. AES-18, No. 5, pp. 621-629, September, 1982.

[4] J. K. Tugnait, "Detection and estimation for abruptly changing systems," Automatica, Vol. 18, No. 5, pp. 607-615, 1982.

[5] H. A. P. Blom and Y. Bar-Shalom, "The interacting multiple model algorithm for systems with a jump-linear smoothing application," IEEE Trans. Automat. Contr., Vol. AC-33, No. 8, pp. 780-783, August, 1988.

[6] A. Munir and D. P. Atherton, "Adaptive interacting multiple model algorithm for tracking a maneuvering target," IEE Proc. of Radar, Sonar Navigation, Vol. 142, No. 1, pp. 11-17, 1995.

[7] A. T. Alouani, A. T. Xia, P. Price, and W. D. Blair, "A two-stage Kalman estimator for state estimation in the presence of random bias for tracking maneuvering targets," Proceedings of 30th IEEE Conference on Decision and Control, pp. 2059-2062, December, 1991.

[8] Y. Bar-Shalom and X. Li, Estimation and Tracking ; Principles, Techniques and Software, Norwood, MA : Artech House, 1993.

[9] D. E. Goldberg, Genetic algorithms in search, optimization, and machine learning, Addison-wesley

publishing company, inc., 1989.

[10] Y. H. Joo, H. S. Hwang, K. B. Kim, and K. B. Woo, "Linguistic model identification for fuzzy system," Electron. Letter, Vol. 31, pp. 330-331, 1995.

[11] Y. H. Joo, H. S. Hwang, K. B. Kim, and K. B. Woo, "Fuzzy system modeling by fuzzy partition and GA hybrid schemes," Fuzzy set and systems, Vol. 86, pp. 279-288, 1997.

저 자 소 개




이 범 직(李 範 植)

1970년 8월 15일생. 1993년 해군사관학교 기계공학과 졸업. 2000년 연세대학교 전기 및 컴퓨터 공학과 대학원 졸업(석사). 2001~현재 동 대학원 전기전자공학과 박사과정
 Tel : (02) 2123-2773
 Fax : (02) 362-4539
 E-mail : bumjik@control.yonsei.ac.kr



주 영 훈(周 永 焄)

1958년 6월 26일생. 1978년 연세대학교 전기공학과 졸업. 1995년 동 대학원 전기공학과 졸업(공학박). 1995년~현재 군산대학교 전자정보공학부 부교수
 Tel : (063) 469-4706
 Fax : (063) 466-2086
 E-mail : yhjoo@kunsan.ac.kr



박 진 배(朴 珍 培)

1954년 8월 7일생. 1977년 연세대학교 전기공학과 졸업. 1990년 Kansas State University 전기 및 컴퓨터 공학과 졸업(공학박). 1994년~현재 연세대학교 전기전자공학과 교수.
 Tel : (02) 2123-2773
 Fax : (02) 362-4539
 E-mail : jbpark@yonsei.ac.kr