
기동표적 추적을 위한 OTSKE의 IMM 적용방법 연구

이호준* · 홍우영** · 고한석*

Investigation of tracking method for a manuevering target using IMM with OTSKE

Hojun Lee* · Wooyoung Hong** · Hanseok Ko*

요 약

본 논문에서는 다양한 기동표적에 대해 적은 연산량으로 효과적인 추적을 하기 위한 방법에 대해 기술한다. 일반적으로 사용되는 Kalman Filter (KF)는 비기동 표적의 추적에는 효과적인 반면 표적이 기동하는 경우에는 제한된 추적 성능을 보인다. 이에 대한 보완 방법으로는 표적의 여러 운동상태를 고려한 IMM이 적합한 대안으로 고려된다. 하지만 IMM은 모델의 수가 증가할수록 연산량이 증가한다는 제한사항을 가지고 있다. 따라서 기동표적 추적방법인 IMM의 제한사항을 보완하기 위해 KF를 Two-Stage로 나누어 각각 필터링을 수행하는 Optimal Two-Stage Kalman Estimator (OTSKE)를 IMM 구조에 적용하고 더 나아가 기존의 IAC 알고리즘에 적용하여 IMM과 유사한 추적성능을 발휘하면서도 연산량은 약 58% 감소시킬 수 있었다.

ABSTRACTt

In this paper, we propose a new tracking algorithm that achieves good tracking performance in manuevering targets while capping the computation load to "low". Kalman Filter (KF) is generally known to be poor in tracking maneuvering targets. IMM, on the other hand, compensates the weakness inherent in the mundane KF and is considered as a promising alternative for tracking maneuvering targets. However, IMM suffers from substantially increased computational load as the number of models increases. To remedy this problem, we propose a new method focused to reducing the computational load and attaining the desirable tracking performance at least as good that of IMM. It is achieved by essentially adopting the structure of IMM and injecting Optimal Two-Stage Kalman Estimator (OTSKE). The representative simulation shows a reduction in computational load with the proposed OTSKE but further reduction is shown achieved (by about 58%) with the Interacting Acceleration Compensation (IAC)-OTSKE approach.

키워드

Optimal Two-Stage Kalman Estimator, IAC 알고리즘, IMM-OTSKE, IAC-OTSKE

*고려대학교

** 해군사관학교

접수일자 : 2002. 5. 24

I. 서론

군사부분을 포함한 다양한 분야에서 해양환경상의 관제표적의 활동영역은 수중 및 수상뿐 아니라 공중까지 광범위하고 다양하며 이를 얼마나 정확하고 빠르게 추적하는가는 중요한 문제로 대두된다.

이러한 표적추적 분야에서 보편적으로 사용되는 필터로 Kalman Filter (KF)가 있다. KF는 운동모델에 의한 예측단계 단계와 관측값을 통한 갱신단계를 통해 최적의 추정값을 예측하여 오차값을 최소로 줄일 수 있다. 하지만 KF는 상태벡터의 차수가 증가함에 따라 계산량이 증가하는 문제가 있다. 또한 비기동 표적에는 최적의 추적성능을 발휘하나 기동하는 표적의 추적에는 제한된 성능을 발휘한다.

이의 해결을 위해 먼저 상태벡터를 두 부분으로 나누어 차수를 줄이는 Two-Stage Kalman Estiamtor (TSKE)가 제안되었다 [1]. 이것은 KF의 가속도 부분을 Bias 필터로 다른 부분을 Bias Free (BF) 필터로 나누는 방법으로 미지의 확정적인 Bias에 대해 최적의 추정값을 얻을 수 있다. 반면 랜덤 Bias에 대해서는 오차가 발생하게 되며 이를 해결하기 위해 BF 필터에 Bias의 랜덤 잡음을 반영하는 Optimal Two-Stage Kalman Estimator (OTSKE)가 제안되었다 [2].

기동표적의 추적에는 다중모델 (Multiple Model) 방법이 제안되었으며 연산량 및 추적성능을 고려한 Interacting Multiple Model (IMM)이 최적의 방법으로 고려된다. 하지만 모델의 수가 증가함에 따라 연산량이 증가한다는 문제점이 있어 실제 시스템의 적용에는 제한을 가진다. 이를 해결하기 위해 TSKE를 IMM에 적용한 IAC 알고리즘이 제안되었다 [3]. 이 방법은 계산량은 IMM에 비해 줄어드는 반면 성능은 IMM과 유사하다.

본 논문에서는 최근 제시된 OTSKE를 IMM에 적용하기 위한 기법에 대해 기술하고 더 나아가 IAC 알고리즘을 보완하여 이에 OTSKE를 적용함으로써 연산량은 감소시키면서 추적성능을 향상시킬 수 있음을 보이고자 한다.

II. 본론

1. 문제의 정의

일반적인 표적의 운동방정식은 다음과 같다.

$$X_{k+1} = F_k X_k + W_k \quad (1)$$

$$Z_k = H_k X_k + N_k \quad (2)$$

여기서 X_k 는 상태벡터로 $X_k = [x \ y \ \dot{x} \ \dot{y}]^T$ 로 구성된다. Z_k 는 관측값이고 W_k , N_k 는 평균이 0, 분산은 $E[W_k W_k^T] = Q_k \delta_{kk}$, $E[N_k N_k^T] = R_k \delta_{kk}$ 인 백색잡음으로 각각 동작잡음 및 관측잡음이다. 또한 $E[W_k N_k^T] = 0$ 이다. 여기서 δ_{kk} 는 Kronecker delta function을, $[\cdot]^T$ 는 Transpose를 나타낸다.

이때 상태벡터 및 관측값, 전이행렬들을 다음과 같이 Two-Stage로 표현 할 수 있다.

$$X_k = \begin{bmatrix} \bar{X}_k \\ \alpha_k \end{bmatrix}, \quad F_k = \begin{bmatrix} A_k & B_k \\ 0 & C_k \end{bmatrix}, \quad W_k = \begin{bmatrix} w_k^{\bar{x}} \\ w_k^{\alpha} \end{bmatrix},$$

$$H_k = [L_k \ M_k]$$

이 벡터들 및 행렬들의 차원은 $\bar{X}_k \in \mathbb{R}^{4 \times 1}$, $\alpha \in \mathbb{R}^{2 \times 1}$, $A_k \in \mathbb{R}^{4 \times 4}$, $B_k \in \mathbb{R}^{4 \times 2}$, $C_k \in \mathbb{R}^{2 \times 2}$, $w_k^{\bar{x}} \in \mathbb{R}^{4 \times 1}$, $w_k^{\alpha} \in \mathbb{R}^{2 \times 1}$, $L_k \in \mathbb{R}^{2 \times 4}$, $M_k \in \mathbb{R}^{2 \times 2}$ 이다.

따라서 (1), (2)는 다음과 같이 Two-Stage로 표현된다.

$$\bar{X}_{k+1} = A_k \bar{X}_k + B_k \alpha_k + w_k^{\bar{x}} \quad (3)$$

$$\alpha_{k+1} = C_k \alpha_k + w_k^{\alpha} \quad (4)$$

$$Z_k = L_k \bar{X}_k + M_k \alpha_k + N_k \quad (5)$$

추가적으로 KF에서의 오차 공분산 및 칼만이득은 다음과 같이 Two-Stage로 표현된다.

$$Q_k = \begin{bmatrix} \bar{Q}_k & \bar{Q}_k^{\alpha} \\ (\bar{Q}_k^{\alpha})^T & Q_k^{\alpha} \end{bmatrix}, \quad P_k = \begin{bmatrix} \bar{P}_k & \bar{P}_k^{\alpha} \\ (\bar{P}_k^{\alpha})^T & \Sigma_k \end{bmatrix}, \quad K_k = \begin{bmatrix} \bar{K}_k \\ K_k^{\alpha} \end{bmatrix}$$

KF는 상태벡터의 차수가 "m1+m2"일 때 보다 이를 각각 필터링 할 때인 "m1" + "m2"의 연산량이 더 적어진다. 또한 \bar{P}_k^{α} 가 중복 계산되어 여분의 계산량이 발생한다. 따라서 KF를 Two-Stage로 나누어 각각 필터링을 수행하면 상태벡

터의 차수를 줄이고 여분의 계산량을 감소시켜 전체적인 계산량이 감소하게 된다.

2. Optimal Two-Stage Kalman Estimator (OTSKE)

TSKE는 KF의 상태벡터를 Bias와 BF의 Two-Stage로 나누고 각각을 따로 필터링 하는 것으로 Bias는 표적의 상태를 변화시키는 요소로 가속도 성분으로 볼 수 있고 BF 성분은 가속도 이외의 성분, 즉 위치, 속도 성분으로 볼 수 있다. OTSKE는 TSKE와 같은 개념이나 Bias필터의 랜덤잡음에 대한 보상을 위해 BF필터에 Bias필터에서 계산된 입력값을 반영한다는 점이 다르다.

필터링 과정을 보면 먼저 BF필터의 필터링은 KF와 동일하나 아래와 같이 예측과정에서 Bias필터에서 계산된 u_k 와 $\bar{Q}_k^{\bar{x}}$ 를 반영한다.

$$\bar{X}_{k+1/k} = A_k \bar{X}_k + u_k \quad (6)$$

$$\bar{P}_{k+1/k} = A_k \bar{P}_k A_k^T + \bar{Q}_k^{\bar{x}} \quad (7)$$

$$\bar{X}_{k+1/k+1} = \bar{X}_{k+1/k} + \bar{K}_{k+1} \tilde{z}_{k+1} \quad (8)$$

$$\bar{P}_{k+1/k+1} = [I - \bar{K}_{k+1} H_k] \bar{P}_{k+1/k} \quad (9)$$

여기서 u_k 과 $\bar{Q}_k^{\bar{x}}$ 은 다음과 같다.

$$u_k = (\bar{U}_{k+1} - U_{k+1}) \alpha_{k+1/k} \quad (10)$$

$$\bar{Q}_k^{\bar{x}} = \bar{Q}_k - \bar{Q}_k^{\alpha} \bar{U}_{k+1} - U_{k+1} (\bar{Q}_k^{\alpha} - \bar{U}_{k+1} Q_k^{\alpha}) \quad (11)$$

Bias필터의 필터링도 예측 및 갱신과정이 KF와 동일하나 BF필터의 \tilde{z}_{k+1} , \bar{S}_{k+1} 이 반영된다.

$$T_{k+1} = L_k U_k + M_k \quad (12)$$

$$\tilde{z}_{k+1}^{\alpha} = \tilde{z}_{k+1} - T_{k+1} \alpha_{k+1/k} \quad (13)$$

$$S_{k+1}^{\alpha} = \bar{S}_{k+1} + T_{k+1} \Sigma_{k+1/k} T_{k+1}^T \quad (14)$$

$$K_{k+1}^{\alpha} = \Sigma_{k+1/k} T_{k+1}^T (S_{k+1}^{\alpha})^{-1} \quad (15)$$

마지막으로 BF필터와 Bias필터를 결합한다.

$$\hat{X}_{k+1/k+1} = \bar{X}_{k+1/k+1} + V_{k+1} \alpha_{k+1/k+1} \quad (16)$$

$$\hat{P}_{k+1/k+1} = \bar{P}_{k+1/k+1} + V_{k+1} P_{k+1/k+1}^{\alpha} V_{k+1}^T \quad (17)$$

여기서 결합행렬은 다음과 같다.

$$\bar{U}_{k+1} = (A_k V_k + B_k) C_k^{-1} \quad (18)$$

$$U_{k+1} = \bar{U}_{k+1} + (Q_k^{\bar{x}\alpha} - \bar{U}_{k+1} Q_k^{\alpha}) (\Sigma_{k+1/k}^{-1}) C_k^{-1} \quad (19)$$

$$V_{k+1} = U_{k+1} - \bar{K}_{k+1} T_{k+1} \quad (20)$$

3. Interacting Multiple Model (IMM)

IMM은 기동표적의 추적을 위해 표적이 가질 수 있는 다양한 운동상태 모델을 가정한 MM의 한 방법으로 모델 입력값 계산시 Markov 전이 확률을 반영하는 것으로 연산과정은 다음과 같다. 이때 모델의 수는 2개로 가정한다.

단계 1 인터랙팅 과정

$$X_{k/k}^{0t} = \sum_{s=1}^2 X_{k/k}^s \mu_{k/k}^{s/t} \quad (21)$$

$$P_{k/k}^{0t} = \sum_{s=1}^2 \mu_{k/k}^{s/t} \{P_{k/k}^s + [X_{k/k}^s - X_{k/k}^{0t}] [X_{k/k}^s - X_{k/k}^{0t}]^T\} \quad (22)$$

$$\text{여기서 } \mu_{k/k}^{s/t} = \frac{1}{\bar{c}_t} p_{st} \mu_k^s, \bar{c}_t = \sum_s p_{st} \mu_k^s, t, s = 1, 2$$

이다.

단계 2 필터링은 KF를 수행한다.

단계 3 모델 가능도 계산

$$\Lambda'_{k+1} = G[e'_{k+1}, 0, E'_{k+1}] \quad (23)$$

여기서 $G[\cdot]$: 가우시안 PDF, e'_k : t 모델에서의 예측 오차, E'_k : 예측오차의 공분산이다.

단계 4 모델확률 생성

$$\mu'_{k+1} = \frac{1}{c} \Lambda'_{k+1} \bar{c}_t \quad (24)$$

$$\text{여기서 } c = \sum_{t=1}^2 \Lambda'_{k+1} \bar{c}_t \text{ 이다.}$$

단계 5 결과값 융합

$$\hat{X}_{k+1/k+1} = \sum_{t=1}^2 X'_{k+1/k+1} \mu'_{k+1} \quad (25)$$

$$\hat{P}_{k+1/k+1} = \sum_{t=1}^2 \mu'_{k+1} \{P'_{k+1/k+1} + [X'_{k+1/k+1} - \hat{X}_{k+1/k+1}] \cdot [X'_{k+1/k+1} - \hat{X}_{k+1/k+1}]^T\} \quad (26)$$

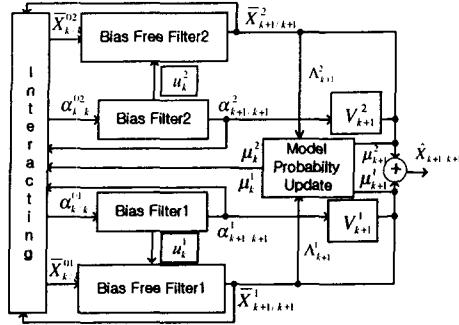


그림 1. IMM-OTSKE의 구조

3. OTSKE의 IMM 적용 (IMM-OTSKE)

OTSKE를 IMM에 적용방법은 [4]을 참조하여 그림 1과 같은 구조를 취한다. 2개의 모델로 구성되었다고 가정하면 상태벡터 및 공분산은 아래와 같다.

$$\bar{X}_{k/k}^t = \bar{X}_{k/k}^t + V_k^t \alpha_{k/k}^t \quad (27)$$

$$P_{k/k}^t = \bar{P}_{k/k}^t + V_k^t \Sigma_{k/k}^t V_k^{t T}, \quad t=1, 2 \quad (28)$$

단계 1. 인터렉팅 과정

Bias필터의 상태벡터 및 공분산과 BF필터에서 상태벡터는 IMM과 동일하나 BF필터의 공분산의 융합에 다른 Bias필터의 상태벡터가 반영된다.

$$\bar{X}_{k/k}^{0t} = \sum_{s=1}^2 \bar{X}_{k/k}^s \mu_{k/k}^{s/t} \quad (29)$$

$$\begin{aligned} \bar{P}_{k/k}^{ot} &= \sum_{s=1}^2 \mu_{k/k}^{s/t} \{ \bar{P}_{k/k}^s + [\bar{X}_{k/k}^s + V_k^s \alpha_{k/k}^s - \bar{B}_{k/k}^{ot}] \\ &\quad \times [\bar{X}_{k/k}^s + V_k^s \alpha_{k/k}^s - \bar{B}_{k/k}^{ot}]^T \} \end{aligned} \quad (30)$$

여기서 $\bar{B}_{k/k}^{ot} = \sum_{i=1}^2 \mu_{k/k}^{i/t} [\bar{X}_{k/k}^i + V_k^i \alpha_{k/k}^i]$ 이다.

단계 2. 필터링은 (6)~(9)와 동일하다.

단계 3. 모델 가능도 계산에서는 Bias필터의 예측오차 및 공분산을 반영한다.

$$\Lambda'_{k+1} = G[\tilde{z}_{k+1}^{a,t}, 0, S_{k+1}^{a,t}] \quad (31)$$

단계 4. 모델 확률 생성은 IMM과 동일하며 다음과 같다.

$$\mu'_{k+1} = \frac{1}{c} \Lambda'_{k+1} \bar{c}_t \quad (32)$$

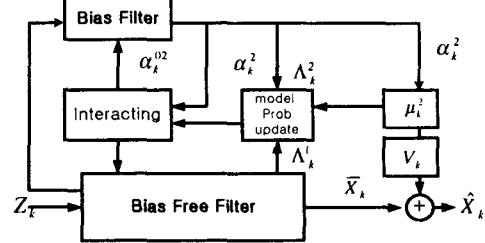


그림 2. IAC 알고리즘의 구조

단계 5. 결과값 융합은 다음과 같다.

$$\hat{X}_{k+1/k+1} = \sum_{i=1}^2 \mu'_{k+1} [\bar{X}_{k+1/k+1}^i + V_{k+1}^i \alpha'_{k+1/k+1}^i] \quad (33)$$

$$\begin{aligned} \hat{P}_{k+1/k+1} &= \sum_{i=1}^2 \mu'_{k+1} \{ \bar{P}_{k+1/k+1}^i + V_{k+1}^i \Sigma_{k+1/k+1}^i V_{k+1}^{i T} \\ &\quad + [\bar{X}_{k+1/k+1}^i + V_{k+1}^i \alpha'_{k+1/k+1}^i - \hat{X}_{k+1/k+1}] \\ &\quad \times [\bar{X}_{k+1/k+1}^i + V_{k+1}^i \alpha'_{k+1/k+1}^i - \hat{X}_{k+1/k+1}]^T \} \end{aligned} \quad (34)$$

4. IAC 알고리즘에의 적용 (IAC-OTSKE)

IMM-OTSKE는 그 자체로 차수의 감소로 인한 연산량의 감소가 있으나 더욱 연산량을 감소시킬 수 있는 IAC 알고리즘을 고려한다. IAC 알고리즘의 개념은 그림 2처럼 IMM-OTSKE에서 $\bar{X}_{k/k}^1 = \bar{X}_{k/k}^2 = \bar{X}_{k/k}$, $\bar{P}_{k/k}^1 = \bar{P}_{k/k}^2 = \bar{P}_{k/k}$, $\alpha_{k/k}^1 = 0$, $\alpha_{k/k}^{01} = 0$, $\Sigma_{k/k}^1 = 0$, $\Sigma_{k/k}^{01} = 0$ 로 하여 BF필터 1개, Bias필터 1개로 간략화 한 것이며 필터의 수가 IMM에 비해 절반으로 줄어들어 연산량을 감소시킨다. 본 논문에서는 [3]과 다르게 TSKE 대신 OTSKE를 사용하였으며 BF 필터의 예측과정에서 입력값 및 동작잡음에 모델화률을 반영하였다. [3]에서는 간략화 과정에서의 오차를 보상하기 위해 BF 필터에 큰 동작잡음을 부여하였으나 좀더 정확한 추적을 위해서는 동작잡음을 모델별로 다르게 부여하여야 하므로 BF 필터의 예측과정에서 입력값 및 동작잡음에 모델의 확률값을 반영하여야 한다. 모델은 동속도 모델(CV)과 등가속도 모델(CA)의 두 모델을 고려하고 모델별 상태방정식은 아래와 같으며 연산과정은 IMM-OTSKE와 동일하다.

$$X_{k/k}^1 = \bar{X}_{k/k}, \quad X_{k/k}^2 = \bar{X}_{k/k} + V_k \alpha_{k/k}^2 \quad (35)$$

$$P_{k/k}^1 = \bar{P}_{k/k}, \quad P_{k/k}^2 = \bar{P}_{k/k} + V_k \Sigma_{k/k}^2 V_k^T \quad (36)$$

단계 1. 인터렉팅 과정

IMM-OTSKE와 동일하며 간략히 하면 Bias필터는 다음과 같다.

$$\alpha_{k/k}^{02} = \mu_{k/k}^{1/2} \alpha_{k/k}^2 \quad (37)$$

$$\Sigma_{k/k}^{02} = \mu_{k/k}^{1/2} [\Sigma_{k/k}^2 + \mu_{k/k}^{1/2} (\alpha_{k/k}^2) (\alpha_{k/k}^2)^T] \quad (38)$$

BF필터의 상태벡터는 $\bar{X}_{k/k}^0 = \bar{X}_{k/k}$ 이며 공분산

은 $V_k^1 = 0, V_k^2 = V_k, \sum_{s=1}^2 \mu_{k/k}^{s/2} = 1$ 을 이용하면 다음과 같이 간략화 된다.

$$\bar{P}_{k/k}^0 = \bar{P}_{k/k} + \left[\sum_{s=1}^2 \mu_k^s \mu_{k/k}^{1/s} \mu_{k/k}^{2/s} \right] (V_k \alpha_{k/k}^2) (V_k \alpha_{k/k}^2)^T \quad (39)$$

단계 2. 필터링은 BF 필터의 예측과정이 다음과 같고 다른부분은 OTSKE와 동일하다.

$$\bar{X}_{k+1/k} = A_k \bar{X}_{k/k} + \mu_k^2 u_k^2 \quad (40)$$

$$\bar{P}_{k+1/k} = A_k \bar{P}_{k/k} A_k^T + [\mu_k^1 \bar{Q}_k^1 + \mu_k^2 \bar{Q}_k^2] \quad (41)$$

단계 3. 모델 가능성도 계산

1번모델은 BF필터의 모델 가능도를 계산한다.

$$\Lambda_{k+1}^1 = G[\tilde{z}_{k+1}, 0, S_{k+1}], \quad \Lambda_{k+1}^2 = G[\tilde{z}_{k+1}^{\alpha,2}, 0, S_{k+1}^{\alpha,2}] \quad (42)$$

단계 4. 모델화를 생신은 IMM-OTSKE와 동일하다.

단계 5. 결과값 유통

$$\hat{X}_{k+1} = \bar{X}_{k+1/k+1} + V_{k+1} \mu_{k+1}^2 \alpha_{k+1/k+1}^2 \quad (43)$$

$$\hat{P}_{k+1} = \bar{P}_{k+1/k+1} + V_{k+1} \{ \mu_{k+1}^2 [\Sigma_{k+1/k+1}^2 + \mu_{k+1}^1 \alpha_{k+1/k+1}^2 (\alpha_{k+1/k+1}^2)^T] \} V_{k+1}^T \quad (44)$$

III. 모의실험

1. 시나리오

수중표적이 최초 속도 50Knot, 위치는 X, Y축상 [20Km 10Km]이며 0초부터 30초간 등속도로 -X축 방향으로 진행하다 30초부터 36초간 반시계방향으로 $10.29m/s^2$ 의 가속도로 회전하고 37

초에서 60초간 등속도 진행후 60초에서 66초간 시계 방향으로 $5.145m/s^2$ 의 가속도로 회전하고 80초까지 등속도 진행한다.

탐지센서는 능동소나로 원점상에 위치하고 있으며 관측값은 방위각(θ_b), 고각(θ_e), 거리(r)정보이나 본 논문에서는 편의상 방위각 및 거리만 고려한다. 관측 오차는 방위각상으로 $\sigma_{\theta_b} = 0.1^\circ$, 거리상으로 $\sigma_r = 20m$ 이다.

2. 관측값 변환

방위각 및 거리를 X, Y좌표로 변환하였다 [4].

$$z_k = \begin{bmatrix} r \cos \theta_b \\ r \sin \theta_b \end{bmatrix}, \quad R_k = \begin{bmatrix} R_{11} & R_{12} \\ R_{21} & R_{22} \end{bmatrix}$$

$$R_{11} = r^2 \sigma_{\theta_b}^2 \sin^2 \theta_b + \sigma_r^2 \cos^2 \theta_b$$

$$R_{12} = R_{21} = (\sigma_r^2 - r^2 \sigma_{\theta_b}^2) \sin \theta_b \cos \theta_b$$

$$R_{22} = r^2 \sigma_{\theta_b}^2 \cos^2 \theta_b + \sigma_r^2 \sin^2 \theta_b$$

3. 실험 파라미터

IMM 모델은 등속도 모델 (Constant Velocity : CV)과 등 가속도 모델 (Constant Acceleration : CA)의 2개 모델로 구성한다. IMM-OTSKE는 CV, CA 모델을 BF 필터와 Bias 필터로 분할한다. IAC-OTSKE는 CV모델인 BF 필터 1개와 CA 모델에서의 Bias 필터 1개로 구성한다.

동작잡음과 모델 전이 확률은 모두 동일하게 적용한다.

$$\Pi = \begin{bmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{bmatrix}, \text{ 모델1: } \sigma_1 = 1m/s^2, \text{ 모델2: } \sigma_2 = 7m/s^2$$

4. 초기화

최초 두 샘플링 관측값을 가지고 위치 및 속도를 추정하여 초기값 $X_{0/0}$ 을 설정한다. 이 값을 바탕으로 OTSKE의 초기값은 아래와같다.

$$\bar{X}_{0/0} = X_{0/0}, \quad \alpha_{0/0}^1 = \alpha_{0/0}^2 = 0, \quad V_0 = 0, \quad \bar{Q}_k^{\bar{X},2} = \bar{Q}_k^2,$$

$$u_k^2 = [0 \ 0 \ 0 \ 0]^T, \quad \bar{P}_{0/0} = 10^3 \times I(4), \quad \Sigma_{0/0} = O(2)$$

여기서 $I(4): 4 \times 4$ Identity Matrix, $O(2): 2 \times 2$ Zero Matrix이다.

표 1. 한 샘플링 동안의 연산량

구분	IMM	IMM-OTSKE	IAC-OTSKE
연산량	470	362	1977
절감량	0%	24%	58%

표 2. RMSE 비교

구 분	RMSE	비 고
IMM	36/22/25	
IMM-OTSKE	39/20/24	최대/최소/평균(m)
IAC-OTSKE	33/23/26	

5. 실험결과

연산량을 측정하기 위해 MATLAB에서 덧셈과 곱셈의 회수를 반영하는 “flops” 명령을 사용하였다. 표 1은 한 샘플링동안의 곱셈 및 덧셈의 횟수를 “flops”으로 측정한 결과로 상태 벡터 차수의 감소로 인해 IMM-OTSKE의 연산량이 24% 감소하였으며 IAC-OTSKE 또한 필터수가 절반으로 감소하여 연산량이 58% 감소하였다.

그림 3, 그림 4는 IMM, IMM-OTSKE, IAC-OTSKE의 거리 및 속도 오차의 RMSE를 나타내며 1000번 실시 된 평균이다. 표 2 는 RMSE를 시간평균 낸 것으로 IMM-OTSKE가 가장 우수한 성능을 보이고 있다. IMM-OTSKE는 비기동구간에서는 IMM보다 오차가 적고 기동구간에서는 오차가 증가했다. 한편 IAC-OTSKE는 전체적인 성능이 IMM 보다 조금 떨어졌으나 큰 차이를 보이지는 않는다.

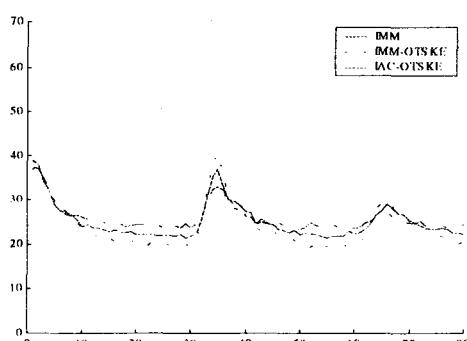


그림 3. RMSE 거리오차

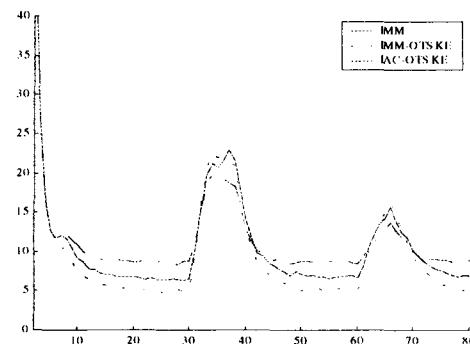


그림 4. RMSE 속도오차

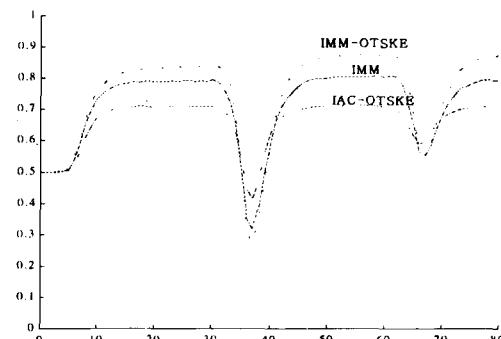


그림 5. 모델 확률의 변화

그림 5는 CV 모델의 시간에 따른 모델의 변화를 나타낸 것으로 1000번 실험의 평균값이다.

[3]의 결과와 그림 5를 비교하면 OTSKE를 적용하는 것이 좀 더 IMM과 유사한 모델전이를 하고 있다.

V. 결론

본 논문에서는 OTSKE를 IMM에 적용하여 기동표적에 대한 추적성능을 보장하고 연산량을 감소시킬 수 있는 기법을 제시 하였다. 상태 벡터의 차수를 감소 시켜 IMM에 비해 24%의 연산량을 감소 시켰으며 IAC 알고리즘을 적용하여 58%의 연산량을 감소시켰다. 또한 IMM과 유사한 추적성능을 발휘함을 알 수 있었다. 결과적으로 IMM-OTSKE나 IAC-OTSKE를 통해 IMM

보다는 적은 연산량을 가지고 이와 유사한 추적 성능을 가질 수 있다. 한편 기존의 TSKE에 비해 OTSKE가 좀더 IMM에 유사하고 최적인 성능을 발휘하였다.

차후로 잡음환경 및 다중표적으로 확장을 통해 실제 시스템에 적용하기 위한 연구를 진행시켜 나가기 위한 성능 향상 연구가 필요하다.

참 고 문 헌

- [1] B. Friedland, "Treatment of bias in recursive filtering", IEEE Trans on Automat Contr, V.AC-14, p.359~367, Aug 1969.
- [2] Chien-Shu and Fu-Chuang Chen, "Optimal Solution of the Two Stage Kalman Estimator", IEEE Tran on Automat Contr, V.44, p.194 ~ p.199, Jan 1999.
- [3] G.A.Watson , W.D. Blair, "Interacing Acceleration Compensation Algorithm For Tracking Maneuvering Targets", IEEE Tran on A&E Syst V.31, p.1152 ~ p.1158, July 1995.
- [4] G.A.Watson , W.D. Blair, "Interacting Multiple Bias Model Algorithm With Application To Tracking Maneuvering Targets", IEEE Proc of 31th Conf D&C, p.3790 ~ p.3795, Dec 1992.
- [5] Yaakov Bar-Shalom, XR Lee , Multitarget - Multisensor Tracking : Principle and Technique, YBS, p.38 ~ p.41 , 1995.

저 자 소 개



이호준(Hojun Lee)

1991년 3월~1995년 3월 육군사관학교 전산학 이학사
2001년 3월~현재 고려대학교 전자공학 석사과정

※관심분야 : 데이터 융합, 표적탐지/추정/추적



홍우영(Wooyoung Hong)

1978년 3월~1982년 3월 해군사관학교 전자공학과 공학사
1983년 3월~1985년 2월 연세대학교 전자공학과 공학석사
1987년 9월~1991년 10월 University of Minnesota 공학박사
1996년 1월~1997년 12월 : 국방과학연구소 위촉연구원
1997년 12월~2000년 1월 U.S. Naval Academy 교환교수
2001년 1월~2001년 12월 국방과학연구소 위촉연구원
1985년 3월~현재 해군사관학교 전자공학과 부교수
※관심분야 : 적용신호처리, 수중 음향신호처리 및 통신, 스마트 안테나



고한석(Hanseok Ko)

1978년 9월~1982년 5월 Carnegie-Mellon Univ. Electrical Engineering 공학사
1982년 9월~1986년 5월 Univ. of Maryland System Engineering 공학석사
1986년 9월~1988년 5월 Johns Hopkins Univ. Electrical Engineering 공학석사
1988년 9월~1992년 5월 Catholic Univ of America Electrical Engineering 공학박사
1993년 9월~1995년 2월 white Oak 연구소 Principal Engineer
1992년 9월~1995년 2월 Univ. of Maryland Part-time Asst. Professor
1995년 3월~현재 고려대학교 전기·전자·전파·공학부 부교수
※관심분야 : 이미지 데이터 융합, 표적신호 탐지/추정/추적, 음성신호처리