

# Rao-Blackwellized Multiple Model Particle Filter 자료융합 알고리즘

## Rao-Blackwellized Multiple Model Particle Filter Data Fusion algorithm

김도형\*

Do-Hyeung Kim\*

### 요 약

일반적으로 비선형 시스템에서 particle filter가 Kalman Filter보다 표적추적 성능이 뛰어나다고 알려져 있다. 그러나 particle filter는 많은 연산량을 요구하는 단점이 있다. 본 논문에서는 particle filter 보다 적은 particle의 수, 즉 적은 연산량으로 동일한 성능을 가지는 Rao-Blackwellized particle filter의 모델의 민감성을 줄인 Rao-Blackwellized Multiple Model Particle Filter(RBMMPF)의 알고리즘을 소개하고 이에 다중센서 정보를 융합하는 자료융합 기법을 적용하였다. 시뮬레이션을 통해 단일센서 정보를 이용한 RBMMPF 표적추적 성능과 다중센서정보를 융합한 RBMMPF의 표적추적 성능을 비교, 분석하였다.

### Abstract

It is generally known that particle filters can produce consistent target tracking performance in comparison to the Kalman filter for non-linear and non-Gaussian systems. In this paper, I propose a Rao-Blackwellized multiple model particle filter(RBMMPF) to enhance computational efficiency of the particle filters as well as to reduce sensitivity of modeling. Despite that the Rao-Blackwellized particle filter needs less particles than general particle filter, it has a similar tracking performance with a less computational load. Comparison results for performance is listed for the using single sensor information RBMMPF and using multisensor data fusion RBMMPF.

Key words : Rao-Blackwellized, Particle filter, Data fusion

### I. 서 론

동역학 필터는 센서를 통해 들어오는 잡음이 섞인 측정치를 이용하여 동역학 시스템의 상태변수의 추정치를 얻는데 쓰는 알고리즘이며 이는 표적추적 시스템의 고장진단, 다중센서 자료융합 등 여러 분야에

널리 사용되고 있다. 동역학 필터의 대명사로 되어 있는 KF(Kalman Filter)는 센서 시스템이 정확히 모델링 되고 선형시스템과 가우시안 잡음이라는 가정하에 최적의 필터가 된다. 그러나 잡음이 가우시안이 아닐 경우나 비선형 시스템일 경우는 조건부 확률밀도 함수인 posterior PDF(Probability Density Function :

---

\* 한양대학교

· 제1저자 (First Author) : 김도형

· 투고일자 : 2011년 8월 1일

· 심사(수정)일자 : 2011년 8월 2일 (수정일자 : 2011년 8월 24일)

· 게재일자 : 2011년 8월 30일

확률밀도함수)를 해석적으로 구하는 것이 불가능해지며 더 이상 KF는 최적의 필터가 아니다. 그래서 근사적인 방법으로 비선형 시스템의 상태변수 추정에서 사용하는 필터로 많이 알려진 EKF(Extended Kalman Filter), 반복적으로 선형화를 수행하는 Iterated EKF, 그리고 Modified Gain EKF가 사용되고 있다.

최근에는 해석적으로 구할 수 없는 비선형 시스템의 경우에 posterior PDF를 컴퓨터를 이용한 수치해석 방법으로 구하는 방법이 제안되었다. 이 방법은 particle이라 불리는 많은 수의 상태변수들을 생성하여 시스템의 동역학 모델에 따라 분포시켜 posterior PDF를 표현하는 것이다. 이러한 기법이 요즘 많이 알려진 SMC(Sequential Monte Carlo methods) 또는 PF(Particle Filter)로 소개 되었다. 1990년대 중반에는 Monte Carlo filters라는 이름 하에 SIS(Sequential Importance Sampling), SIR(Sequential Importance Resampling), Generic PF, Auxiliary SIR, MMPF 등 여러 가지 PF의 알고리즘들[1]이 소개 되었다. PF는 비선형 시스템과 잡음이 가우시안이 아닐 경우 posterior PDF를 직접구하는 장점이 있는 반면에 posterior PDF를 나타내기 위해서 많은 수의 particle이 필요하기 때문에 상태벡터의 변수가 많으면 particle filtering은 비효율적인 단점이 있다. 즉, 샘플링 시간이 짧은 필터링의 경우 real-time 수행이 불가능 하게 된다. 이러한 단점을 보완하기 위한 방법으로 analytic 상태변수들을 분리 시켜 particle의 상태변수 크기를 줄여 샘플링 기술의 효율성을 증가시키는 방법이다. 이를 Rao-Blackwellization이라 부른다(Casella and Robert 1996)[2]. 이것을 PF에 적용한 것이 RBPF이며 RBPF는 단일 모델로 시스템의 모델링에 따라 정확성에 민감한 특성을 보이게 된다. 모델링의 정확도가 추정성능에 미치는 영향을 감소시키기 위해 다수모델 필터를 사용할 수 있다. 그래서 다중모델을 사용한 PF인 MMPF(Multiple Model Particle Filter)[1]와 RBPF[3,4,5]를 결합하여 RBMMPF(Rao-Blackwellized Multiple Model Particle Filter)의 알고리즘을 본 논문에서 제안할 것이다.

최근 표적추적에 대한 문제에서 다수의 센서를 통해 얻어진 정보에 대하여 효율적인 정보융합 방법을 통해 정확한 상태변수를 추정하는 필터링 알고리즘

에 관심이 집중되고 있다. 이러한 표적을 추적하는 문제에 있어서 다수의 센서를 활용한 정보융합기법을 이용하는 경우[6,7]가 단일 센서를 사용하는 것보다 정확한 추정치를 얻을 수 있으며 표적의 트랙 유지성능 역시 뛰어난을 알 수 있다. 따라서 본 논문에서는 RBMMPF에 정보융합 기법을 적용한 알고리즘을 소개하며 시뮬레이션을 통해 단일센서 정보를 이용한 RBMMPF의 성능과 다중센서 정보를 융합한 RBMMPF의 성능을 비교하였고 다중센서 정보를 융합한 RBMMPF의 성능이 더 뛰어난을 보였다. 구성으로는 2장에서 시스템 모델과 알고리즘에 대해 기술 하였고, 3장에서는 시뮬레이션의 결과를 비교 분석하였으며, 마지막으로 4장에서는 결과를 도출하였다.

## II. RBMMPF 정보융합

### 2-1 시스템 모델

PF는 많은 범위의 상태변수를 가진 많은 particles 이 필요하다. particle의 개수를 줄이고 필터의 발산을 줄이기 위해 Rao-Blackwellization으로 알려진 방법을 적용할 수 있었다. 이 이론은 상태벡터에서 선형인 부분은 KF를 사용하고 나머지 부분은 PF를 사용하는 것이다. 표적을 추적하기 위한 필터 동역학의 상태변수는 위치, 속도로 상태변수를 사용한다. 보편적인 시스템의 동역학 모델을 식(1)과 같이 나타낼 수 있다.

$$\begin{aligned} x_k^p &= f^p(x_{k-1}^p) + F^p(x_{k-1}^p)x_{k-1}^a + G^p(x_{k-1}^p)W_{k-1}^p \\ x_k^a &= f^a(x_{k-1}^p) + F^a(x_{k-1}^p)x_{k-1}^a + G^a(x_{k-1}^p)W_{k-1}^a \\ z_k &= h(x_k^p) + H(x_k^p)x_k^a + V_k \end{aligned} \tag{1}$$

여기서  $x_k^p = [x_k^p, y_k^p, z_k^p]$ 는 비선형인 부분으로 PF를 이용하여 나타내는 상태변수,  $x_k^a = [\dot{x}_k^a, \dot{y}_k^a, \dot{z}_k^a]$ 는 선형 부분으로 KF를 이용하여 나타내는 상태변수이다.  $W_k^p \sim N(0, (\sigma_w^p)^2)$ 는 PF

부분의 공정잡음,  $W_k^a \sim N(0, (\sigma_w^a)^2)$ 는 KF 부분의 공정잡음 그리고  $V_k \sim N(0, (\sigma_v)^2)$  측정치 잡음을 표현하며,  $\sigma_w, \sigma_v$ 는 공정잡음과 측정잡음의 표준편차,  $z_k$ 는 측정치 벡터를 표현한다.

앞에서 언급한 MMPF는 다수모델 PF로  $r_k$ (모드 변수:regime)에 따라 각각 다른 동역학 모델을 가진다. 여기서  $r_k$ 값은 등속 직선운동 모드( $r_k=0$ ), 반시계 방향 회전운동 모드( $r_k=1$ ), 시계방향 회전운동 모드( $r_k=2$ ), 위쪽방향 회전운동 모드( $r_k=3$ ), 아래쪽방향 회전운동 모드( $r_k=4$ )로 5개의 값을 가지며, (k-1,k]의 시간 간격동안 표적의 시스템 모델에 영향을 미친다고 가정하였다[3]. 각 모드의 동역학 모델 행렬은 아래 식(2), (3), (4)와 같이 표현된다.

$r_k=0$ 일 경우,

$$\begin{bmatrix} f_k^{p,r_k} & F_k^{p,r_k} \\ f_k^{a,r_k} & F_k^{a,r_k} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & T & 0 & 0 \\ 0 & 1 & 0 & 0 & T & 0 \\ 0 & 0 & 1 & 0 & 0 & T \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\begin{bmatrix} G^{p,r_k} \\ G^{a,r_k} \end{bmatrix} = \begin{bmatrix} \frac{T^2}{2} & 0 & 0 \\ 0 & \frac{T^2}{2} & 0 \\ 0 & 0 & \frac{T^2}{2} \\ T & 0 & 0 \\ 0 & T & 0 \\ 0 & 0 & T \end{bmatrix}$$

(2)

$r_k=1,2$ 일 경우

$$\begin{bmatrix} f_k^{p,r_k} & F_k^{p,r_k} \\ f_k^{a,r_k} & F_k^{a,r_k} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & \frac{\sin(\omega_k^r \times T)}{\omega_k^r} & -\frac{1-\cos(\omega_k^r \times T)}{\omega_k^r} & 0 \\ 0 & 1 & 0 & \frac{1-\cos(\omega_k^r \times T)}{\omega_k^r} & \frac{\sin(\omega_k^r \times T)}{\omega_k^r} & 0 \\ 0 & 0 & 1 & 0 & 0 & T \\ 0 & 0 & 0 & \cos(\omega_k^r \times T) & -\sin(\omega_k^r \times T) & 0 \\ 0 & 0 & 0 & \sin(\omega_k^r \times T) & \cos(\omega_k^r \times T) & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\begin{bmatrix} G^{p,r_k} \\ G^{a,r_k} \end{bmatrix} = \begin{bmatrix} \frac{1-\cos(\omega_k^r \times T)}{(\omega_k^r)^2} & \frac{\sin(\omega_k^r \times T) - \omega_k^r \times T}{(\omega_k^r)^2} & 0 \\ -\frac{\sin(\omega_k^r \times T) - \omega_k^r \times T}{(\omega_k^r)^2} & \frac{1-\cos(\omega_k^r \times T)}{(\omega_k^r)^2} & 0 \\ 0 & 0 & \frac{T^2}{2} \\ \frac{\sin(\omega_k^r \times T)}{\omega_k^r} & \frac{\cos(\omega_k^r \times T) - 1}{\omega_k^r} & 0 \\ -\frac{\cos(\omega_k^r \times T) - 1}{\omega_k^r} & \frac{\sin(\omega_k^r \times T)}{\omega_k^r} & 0 \\ 0 & 0 & T \end{bmatrix}$$

(3)

$r_k=3,4$ 일 경우

$$\begin{bmatrix} f_k^{p,r_k} & F_k^{p,r_k} \\ f_k^{a,r_k} & F_k^{a,r_k} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & \frac{\sin(\omega_k^r \times T)}{\omega_k^r} & 0 & -\frac{1-\cos(\omega_k^r \times T)}{\omega_k^r} \\ 0 & 1 & 0 & 0 & T & 0 \\ 0 & 0 & 1 & \frac{1-\cos(\omega_k^r \times T)}{\omega_k^r} & 0 & \frac{\sin(\omega_k^r \times T)}{\omega_k^r} \\ 0 & 0 & 0 & \cos(\omega_k^r \times T) & 0 & -\sin(\omega_k^r \times T) \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & \sin(\omega_k^r \times T) & 0 & \cos(\omega_k^r \times T) \end{bmatrix}$$

$$\begin{bmatrix} G^{p,r_k} \\ G^{a,r_k} \end{bmatrix} = \begin{bmatrix} \frac{1-\cos(\omega_k^r \times T)}{(\omega_k^r)^2} & 0 & \frac{\sin(\omega_k^r \times T) - \omega_k^r \times T}{(\omega_k^r)^2} \\ 0 & \frac{T^2}{2} & 0 \\ -\frac{\sin(\omega_k^r \times T) - \omega_k^r \times T}{(\omega_k^r)^2} & 0 & \frac{1-\cos(\omega_k^r \times T)}{(\omega_k^r)^2} \\ \frac{\sin(\omega_k^r \times T)}{\omega_k^r} & 0 & \frac{\cos(\omega_k^r \times T) - 1}{\omega_k^r} \\ 0 & T & 0 \\ -\frac{\cos(\omega_k^r \times T) - 1}{\omega_k^r} & 0 & \frac{\sin(\omega_k^r \times T)}{\omega_k^r} \end{bmatrix}$$

(4)

여기서  $T$ 는 샘플링 주기이며  $\omega_k^r$ 는 모드에 따른 표적의 회전 각속도를 나타내며 이는 식(5)와 같이 표적의 속도와 구심 가속도( $a_k$ )로 표현된다.

$$\omega_k^r = \frac{(-1.0)^{r_k} \times a_k}{\sqrt{(\dot{x}_k^a)^2 + (\dot{y}_k^a)^2 + (\dot{z}_k^a)^2}} \tag{5}$$

### 2-2 RBMMPF 자료융합 알고리즘

이번 장에서는 1996년에 Casella와 Robert가 제시한 Rao-Blackwellised 방법[2]을 PF에 적용한 알고리즘을 소개한다. RBMMPF는 SIR의 변형된 형태인 RBPF에 MMPF[1]를 결합한 것이다. RBMMPF는 RBPF와 달리 각 particles마다 부여 받은 모드변수 (regime)에 따라 동역학 모델과 공정잡음 행렬이 다르기 때문에 RBPF와 달리 모든 particles의 analytic 상태변수의 공분산값을 구하여야 한다.

#### 1) Regime transition

k-1순간의 모드변수  $r_{k-1}$ 로 k순간의 모드변수를 Markov process로 가정한 상태전이 행렬에 의해 상태 전이를 하여 그때의 각각의 particle마다 부여받은 모드변수로 식(2, 3, 4)에서 정의된 동역학 모델 행렬을 부여 받은 부분[1]이다.

2) Computing the Proposal distribution

k-1순간에서 particle 상태변수와 측정치가 주어졌을 때 k순간의 particle 상태변수의 분포  $p(x_k^p | X_{0:k-1}^p, Z_{1:k-1})$ 를 알아내어 particles의 샘플을 취하는 부분이다. 이 분포는 marginal PDF로 표현하면 식(6)과 같다.

$$p(x_k^p | X_{0:k-1}^p, Z_{1:k-1}) = \int_{x_{k-1}^p} p(x_k^p | x_{k-1}^p, X_{0:k-1}^p) p(x_{k-1}^p | X_{0:k-1}^p, Z_{1:k-1}) dx_{k-1}^p \quad (6)$$

여기서  $p(x_k^p | x_{k-1}^p, X_{0:k-1}^p)$ 는 공정잡음이 가우시안 분포를 따른다는 가정을 하였기 때문에 가우시안 분포를 하며  $p(x_{k-1}^p | X_{0:k-1}^p, Z_{1:k-1})$ 는 KF부분의 상태변수의 분포를 나타내기 때문에 평균이  $\hat{x}_{k-1}^a$  이고 공분산이  $\hat{P}_{k-1}^a$ 인 가우시안 분포를 따른다. 따라서  $p(x_k^p | X_{0:k-1}^p, Z_{1:k-1})$ 는 평균이  $f^p(x_{k-1}^p) + F^p(x_{k-1}^p)\hat{x}_{k-1}^a$ , 공분산이  $F^p(x_{k-1}^p)\hat{P}_{k-1}^a F^{pT}(x_{k-1}^p) + G^p(x_{k-1}^p)Q_{k-1}^p G^{pT}(x_{k-1}^p)$ 인 가우시안 분포로서 k순간의 샘플들을 취한다.

3) Recursion for  $p(x_k^a | X_{0:k}^p, Z_{1:k})$

k순간에 particle의 상태변수와 측정치가 주어졌을 때 k순간의 analytic 상태변수의 분포  $p(x_k^a | X_{0:k}^p, Z_{1:k})$ 는 analytic posterior PDF로 평균이  $\hat{x}_k$ , 공분산이  $\hat{P}_k$ 인 가우시안 분포를 한다고 정의하고 k-1순간의 측정치와 k순간의 particle의 상태변수가 주어졌을 때 k순간의 analytic 상태변수의 분포  $p(x_k^a | X_{0:k-1}^p, Z_{1:k-1})$ 는 analytic prior PDF로 평균이  $\bar{x}_k$ , 공분산이  $\bar{P}_k$ 인 가우시안 분포를 한다고 정의하며 마지막으로 k-1순간의 측정치와 k순간의 particle의 상태변수가 주어졌을 때 k-1순간의 analytic 상태변수의 분포  $p(x_{k-1}^a | X_{0:k-1}^p, Z_{1:k-1})$ 는 analytic temporal PDF로 평균이  $\tilde{x}_{k-1}$ , 공분산이  $\tilde{P}_{k-1}$ 인 가우시안 분포를 한다고 정의한다.

우선 temporal PDF  $p(x_k^a | X_{0:k-1}^p, Z_{1:k-1})$ 를 Baye's rule에 의해 정리하면 식(7)과 같이 k-1순간의

posterior PDF  $p(x_{k-1}^a | X_{0:k-1}^p, Z_{1:k-1})$ 로 표현이 된다.

$$p(x_{k-1}^a | X_{0:k-1}^p, Z_{1:k-1}) = \frac{p(x_{k-1}^p | x_{k-1}^a, X_{0:k-1}^p, Z_{1:k-1}) p(x_{k-1}^a | X_{0:k-1}^p, Z_{1:k-1})}{p(x_{k-1}^p | X_{0:k-1}^p, Z_{1:k-1})} \quad (7)$$

이 PDF는 가우시안 가정에 따라 식(8)과 같이 평균과 공분산으로 표현할 수 있다.

$$\begin{cases} \tilde{x}_k^{a,i} = \hat{x}_{k-1}^{a,i} + K_2^i(x_{k-1}^{p,i} - f^{p,r_k}(x_{k-1}^{p,i}) - F^{p,r_k}(x_{k-1}^{p,i})\hat{x}_{k-1}^{a,i}) \\ \tilde{P}_k^{a,i} = \hat{P}_{k-1}^{a,i} - K_2^i S_2^i (K_2^i)^T \\ K_2^i = \hat{P}_{k-1}^{a,i} (F^{p,r_k}(x_{k-1}^{p,i}))^T (S_2^i)^{-1} \\ S_2^i = G^{p,r_k}(x_{k-1}^{p,i}) Q_{k-1}^p G^{p,r_kT}(x_{k-1}^{p,i}) + F^{p,r_k}(x_{k-1}^{p,i}) \hat{P}_{k-1}^{a,i} (F^{p,r_k}(x_{k-1}^{p,i}))^T \end{cases} \quad (8)$$

여기서 i는 i번째 particle을 나타내는 지정자 변수이며,  $r_k$ 는 위에서 정의된 모드변수를 나타낸다. 그 다음 prior PDF  $p(x_k^a | X_{0:k-1}^p, Z_{1:k-1})$ 는 marginal PDF에 의해 temporal PDF의 평균과 공분산으로 식(9)와 같이 표현된다.

$$\begin{cases} \bar{x}_k^{a,i} = F^{a,r_k}(x_{k-1}^{p,i}) \tilde{x}_k^{a,i} + f^{a,r_k}(x_{k-1}^{p,i}) \\ \bar{P}_k^{a,i} = F^{a,r_k}(x_{k-1}^{p,i}) \tilde{P}_k^{a,i} F^{a,r_kT}(x_{k-1}^{p,i}) + G^{a,r_k}(x_{k-1}^{p,i}) Q_{k-1}^a G^{a,r_kT}(x_{k-1}^{p,i}) \end{cases} \quad (9)$$

따라서 k-1순간 posterior PDF의 평균과 공분산으로 k순간 prior PDF의 평균과 공분산이 식(10)과 같이 표현된다.

$$\begin{cases} \bar{x}_k^{a,i} = F^{a,r_k}(x_{k-1}^{p,i}) [\hat{x}_{k-1}^{a,i} + K_2^i(x_{k-1}^{p,i} - f^{p,r_k}(x_{k-1}^{p,i}) - F^{p,r_k}(x_{k-1}^{p,i})\hat{x}_{k-1}^{a,i})] + f^{a,r_k}(x_{k-1}^{p,i}) \\ \bar{P}_k^{a,i} = F^{a,r_k}(x_{k-1}^{p,i}) [\hat{P}_{k-1}^{a,i} - K_2^i S_2^i (K_2^i)^T] (F^{a,r_k}(x_{k-1}^{p,i}))^T + G^{a,r_k}(x_{k-1}^{p,i}) Q_{k-1}^a (G^{a,r_k}(x_{k-1}^{p,i}))^T \\ K_2^i = \hat{P}_{k-1}^{a,i} (F^{p,r_k}(x_{k-1}^{p,i}))^T (S_2^i)^{-1} \\ S_2^i = G^{p,r_k}(x_{k-1}^{p,i}) Q_{k-1}^p (G^{p,r_k}(x_{k-1}^{p,i}))^T + F^{p,r_k}(x_{k-1}^{p,i}) \hat{P}_{k-1}^{a,i} (F^{p,r_k}(x_{k-1}^{p,i}))^T \end{cases} \quad (10)$$

마지막으로 k순간 측정치를 받았을 때 k순간의 posterior PDF의 평균과 공분산은 k순간의 prior PDF의 평균과 공분산으로 식(11)로 나타낼 수 있으며, 이

것은 k-1순간의 posterior PDF의 평균과 공분산으로 k 순간의 posterior PDF를 표현하는 recursion rule을 따르게 된다.

$$\begin{cases} \hat{x}_k^{a,i} = \bar{x}_k^{a,i} + K_1^i(z_k - h^p(x_k^{p,i}) - H^p(x_k^{p,i})\bar{x}_k^{a,i}) \\ \hat{P}_k^{a,i} = \bar{P}_k^{a,i} - K_1^i S_1^i (K_1^i)^T \\ K_1^i = \bar{P}_k^a H^p(x_k^{p,i})^T (S_1^i)^{-1} \\ S_1^i = H^p(x_k^{p,i})\bar{P}_k^a H^p(x_k^{p,i})^T + R_k \end{cases} \quad (11)$$

4) Compute weight and resampling

SIS와 동일하게 각각의 particle weight를 구하고 SIR과 같이 resampling 과정을 수행하는 부분[1]이다.

5) 자료융합

각 센서의  $p(x_k^a | X_{0:k}^a, Z_{1:k})$ 를 이용하여 상태들을 융합한다[6,7]. 융합된 상태를 피드백 시켜 수행한다. 융합은 식(12)와 같이 수행한다.

$$\begin{cases} x_k^f = \hat{x}_k^i + (\hat{P}_k^i - \hat{P}_k^{ij})(\hat{P}_{zz}^i)^{-1}(\hat{x}_k^j - \hat{x}_k^i) \\ P_k^f = \hat{P}_k^i + (\hat{P}_k^i - \hat{P}_k^{ij})(\hat{P}_{zz}^i)^{-1}(\hat{P}_k^j - \hat{P}_k^{ji}) \\ \hat{P}_k^{ij} = (I - K_k^i H_k^i)\Phi_{k-1} P_k^j (\Phi_{k-1})^T (I - K_k^j H_k^j)^T \\ \quad + (I - K_k^i H_k^i)\Gamma_{k-1} q_{k-1} (\Gamma_{k-1})^T (I - K_k^j H_k^j)^T \\ \hat{P}_{zz}^i = \hat{P}_k^i + \hat{P}_k^j - \hat{P}_k^{ij} - \hat{P}_k^{ji} \end{cases} \quad (12)$$

여기서  $x_k^f, P_k^f$ 는 융합된 상태의 평균과 분산이고,  $\Phi_{k-1}, \Gamma_{k-1}, q_{k-1}$ 는 시스템의 transition matrix와 공정잡음이며,  $K_k^i, H_k^i$ 는 Kalman filter의 Kalman gain과 H matrix를 나타낸다.

III. 시뮬레이션 결과

본 논문에서 제안한 RBMMPF로 정보융합 기법을 적용하여 시스템의 상태 추정 성능을 비교하기 위해 몬테칼로 100회를 수행한 시뮬레이션을 수행하였다. 2차원 시스템에서 위치, 속도, 가속도로 시뮬레이션을 구성하며 상태추정 필터는 비선형 부분을 위치로

particle filter를 이용하여 추정하였고, 선형부분인 속도와 가속도는 Kalman filter를 이용하여 시스템 상태를 추정하였다. 시나리오의 총 수행시간은 100초이며, 샘플링 주기가 0.1초로 시뮬레이션을 수행하였다. 표적의 초기위치는 XY좌표로 7000미터, 9000미터이며 표적이 10~30초, 70~80초 사이에 좌, 우 기동운동과 나머지 수행 시간 동안 등속 직선 운동을 하도록 하였다. 센서는 두 개를 이용하였으며 센서 1,2의 측정잡음 표준편차는 거리로 X축, Y축, 속도로 X축, Y축으로 센서1(80미터, 80미터, 20미터/초, 20미터/초), 센서2(60미터, 60미터, 10미터/초, 10미터/초)로 각각 설정하였다. 그림1은 시나리오에 따른 표적의 기동과 센서의 위치를 나타낸 것이다.

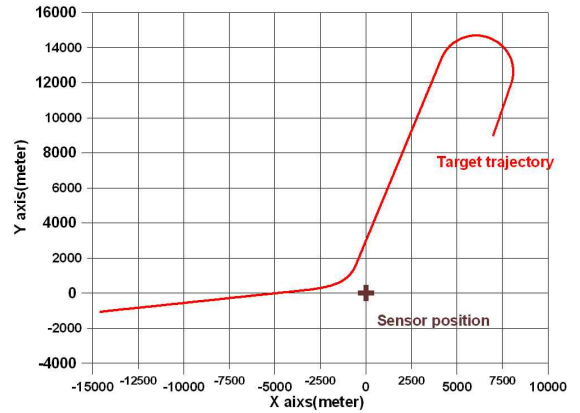


그림 1. 표적의 기동과 센서의 위치(XY 평면)  
Fig. 1. Target motion and sensor position(XY plan)

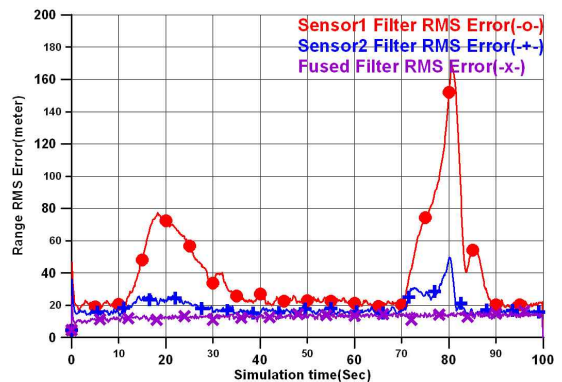


그림 2. 단일센서와 다중센서 RBMMPF의 RMS오차  
Fig. 2. RMS error of single sensor and multisensor RBMMPF

그림2는 단일센서1,2 각각의 정보를 이용하여 RBMMPF를 수행하였을 때 추정치의 거리 RMS 오차

와 센서1,2의 정보를 이용하여 RBMMPF를 수행하여 정보융합한 추정치의 거리 RMS 오차를 나타낸 것이다. 융합한 추정치의 RMS 오차가 가장 적은 것을 알 수 있다.

#### IV. 결 론

본 논문에서는 PF의 단점인 많은 연산시간 요구 때문에 아직까지 샘플링 주기가 짧은 시스템에 적용하는 것이 불가능하기 때문에 이를 극복하기 위한 상태추정 기법으로 RBPF와 MMPF를 결합한 RBMMPF의 알고리즘을 제안하고 RBMMPF의 성능을 개선하기 위하여 자료융합 기법을 적용한 알고리즘을 제안하였다. 시뮬레이션을 통하여 다중센서 정보융합 RBMMPF의 성능이 단일센서 정보를 이용한 RBMMPF보다 우수함을 보였다.

#### 참 고 문 헌

- [1] Branko Ristic, Sanjeev Arulampalam, and Neil Gordon, *Beyond the Kalman Filter*. Artech House Publishers, 2004.
- [2] Casella, G. and Robert, C.P. (1996). Rao-Blackwellisation of sampling scheme, *Biometrick* 83(1):81-94
- [3] Doucet, A., de Freitas, J. F. G., Murphy, K. and Russell, S. (2000). "Rao Blackwellised particle filtering for dynamic Bayesian networks.", *Uncertainty in Artificial Intelligence*.
- [4] A. Doucet, S. Godsill, and C. Andrieu, "On sequential monte Carlo sampling methods for Bayesian filtering," *Statistics and Computing*, vol. 10, no. 3, pp. 197-208, 2000
- [5] Doucet, A., de Freitas, and Gordon, N. Sequential Monte Carlo Methods in Practice. *Springer-Verlang* New York, 2001
- [6] DAVID L. HALL and JAMES LLINAS, "An Introduction to Multisensor Data Fusion", *Proceedings of the IEEE*, Vol, 85, No 1, January 1997
- [7] Ng Gee Wah, and Yang Rong, Comparison of Decentralized Tracking Algorithms", 2003 ISIF

#### 김 도 형 (金導亨)



2004년 2월 : 한양대학교 전기전자 제어계측공학과(공학사)

2006년 2월 : 한양대학교 전기전자 제어계측공학과(공학석사)

2006년 10월 ~ 2009년 4월 : LIG넥스원  
관심분야: 레이더/소나 표적 추적, 자료융합, 자료결합 등