

다중 표적 추적의 최적 데이터 결합을 위한 MAP 추정기 개발

A MAP Estimate of Optimal Data Association in Multi-Target Tracking

이 양원
(Yang-Weon Lee)

Abstract : We introduced a scheme for finding an optimal data association matrix that represents the relationships between the measurements and tracks in multi-target tracking (MTT). We considered the relationships between targets and measurements as Markov Random Field and assumed *a priori* of the associations as a Gibbs distribution. Based on these assumptions, it was possible to reduce the MAP estimate of the association matrix to the energy minimization problem. After then, we defined an energy function over the measurement space that may incorporate most of the important natural constraints. To find the minimizer of the energy function, we derived a new equation in closed form. By introducing Lagrange multiplier, we derived a compact equation for parameters updating. In this manner, a pair of equations that consist of tracking and parameters updating can track the targets adaptively in a very variable environments. For measurements and targets, this algorithm needs only multiplications for each radar scan. Through the experiments, we analyzed and compared this algorithm with other representative algorithm. The result shows that the proposed method is stable, robust, fast enough for real time computation, as well as more accurate than other method.

Keywords : multi-target tracking, estimation, data association

I. 서론

일반적으로 다중표적 추적 시스템은 감시 센서로부터 측정된 데이터가 여러 개의 표적에서 기인한 측정값 외에 표적과 인접하는 물체, 기상 상태, 전자기적 간섭 또는 허위 경보(false alarm) 등에 의해 발생하는 클러터들을 포함하는 상황을 고려하여야 한다. 이러한 클러터를 포함하는 수신 데이터의 처리는 표적 추적 알고리즘을 통하여 구현 될 수 있으나, 클러터가 많은 상황 하에서 탐지센서로부터 수신된 측정 데이터를 추적 필터에 그대로 입력하게 되면 많은 처리 시간을 요구하게 되기 때문에, 수신 데이터를 전처리(pre-processing)하여 수신 측정값의 수를 줄인 후에 추적 필터에 입력하게 된다. 다중 표적 추적 필터는 먼저 매 표본 간격마다 표적 및 클러터들에서 발생하는 측정값 집합을 구한다. 그리고 현재 추적하고 있는 각 궤적들과 측정값 집합들간에 결합관계를 구한다. 이 결합관계를 최종 측정값으로 하여 각 궤적들의 현재 상태를 추정하고 미래 상태를 예측함으로써 각 표적의 궤적을 유지 할 수 있도록 하는 개념으로 운영된다.

일반적으로 다중표적 추적을 위한 데이터 결합방법의 연구로는 공산 함수(likelihood function)에 기초한 비베이시안(non-Bayesian)기법[1], 베이시안(Bayesian) 기법[2,3] 그리고 신경망 기법[4,5] 등의 세가지 접근 방법이 연구되어지고 있다. 베이시안 기법과 비베이시안 기법의 주된 차이는 허위경보를 어떻게 다루느냐에 있다. 비베이시안 기법은 주어진 측정값들을 가지고 모든 가능한 공산함수를 계산한 후에 공산함수의 최대값을 주는 궤적을 선택하는 반면에, 베이시안 기법은 사후 확률(*a posteriori* probability)을 이용하여 관심 있는 위치를 예측하여서 그 곳의 측정값을 이용

한다. 이 두 가지 방법은 궤적 및 측정값의 수가 증가함에 따라 엄청난 계산을 요구하기 때문에 실시간 처리에는 부적합하다. 따라서 이를 해결하기 위한 대안으로 제시된 기법이 흡필드 신경망(Hopfield Neural Network)을 이용한 데이터 결합기법이다[4]. 이 방법은 바실룸이 제안한 JPDAF(Joint probability data association)[6]의 사후확률 값 β_j^t 를 한정된 최소화 문제로 변환시켜서 근사적으로 구하는 신경망을 제안하였다. 하지만 이 알고리즘은 두 가지 측면에서 문제가 있다. 첫째로 원래의 JPDAF의 β_j^t 의 값은 흡필드 신경망의 구성원인 X_j^t 와는 동질성이 없다는 점이다. 즉 이 논문에서 가정한 동일 표적으로부터 두 개의 측정값은 있을 수 없고, 두 개의 표적으로 부터는 하나의 측정값만은 올 수는 없다는 것이다. 이 같은 가정은 오직 가능한 데이터 결합 가설(feasible data association hypothesis)을 세우는 데만 사용해야 한다[7]. 둘째로 사용한 에너지 함수의 상수 계수 값들을 경험적으로 사용함으로써 최적데이터 결합 조건을 제공하지 못한다.

본 논문에서는 기존의 논문들이 가지고 있는 문제점을 해결하기 위하여 다중표적 추적 문제가 갖고 있는 자연적인 제한사항들을 반영하여 데이터 결합을 위한 새로운 모델을 유도하고 유도된 모델을 MAP 추정기[10]를 이용하여 에너지함수의 최소화 문제로 바꾸어서 계산하는 방법을 제안하였다. 또한 에너지 함수의 계수들은 Lagrange 멀티플라이어(multiplier)[9]와 국부 쌍대 이론(local dual theory)[8]을 이용하여 구하는 방법을 택했다.

본 논문의 구성은 서론에 이어 2장에서는 MTT 문제 정의와 제한된 최적화 문제를 설명하였으며, 3장에서는 문제해결을 위한 최적 접근방법을 기술하였고, 4장에서는 제안된 알고리즘의 시뮬레이션 결과를 보였으며 마지막으로 결론을 맺었다.

II. 문제 및 에너지 함수 정의

이 장에서는 데이터 결합에 관련된 주어진 환경에서 오

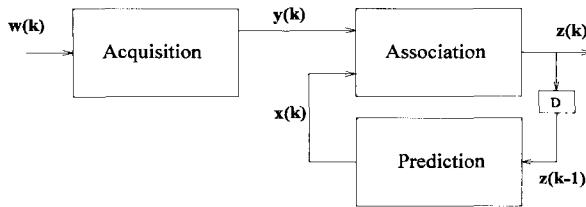


그림 1. 표적 추적 시스템의 전체 구조도.

Fig. 1. An overall scheme for target tracking.

는 제약사항의 철저 분석을 통하여 에너지 함수를 정의하고 정의된 에너지 함수의 최소값을 구하기 위한 최적 데이터 결합용 MAP 추정기를 유도한다.

1. 측정값과 표적과의 관계식

그림 1은 다중 표적 추적시스템의 전체 구성을 나타낸다. 이 시스템은 데이터 획득, 결합, 예측의 세 부분으로 나뉘어진다. 획득의 목적은 초기 추적을 위한 시작점을 결정하는 것이고, 다음 단계는 결합과 예측 작업이 상호 연관성을 가지면서 반복적으로 이루어진다. 본 논문에서 관심 있는 분야는 실제 측정값과 측정과의 결합을 판단하는 역할을 담당하는 결합(association)부분이다.

감시 센서의 탐지영역에서 m, n 을 각각 측정값과 표적의 수라고 하자. 그러면 표적과 측정값들 사이의 관계식은 유효행렬(validation matrix) ω 로 다음과 같이 표현이 가능하다[6]:

$$\omega = \{\omega_{jt} \mid j \in [1, m], t \in [0, n]\} \quad (1)$$

여기서 첫째 열은 클러터를 나타내고 그 값은 항상 $\omega_{j0} = 1$ 이 된다. 다른 열에 대해서는, 만일 표적 t 의 유효케이트가 측정값 j 를 포함하고 있다면 $\omega_{jt} = 1 (j \in [1, m], t \in [1, n])$ 이고, 그렇지 않으면 $\omega_{jt} = 0$ 이다.

유효행렬과 다음 (2)와 같은 데이터 결합 가설(feasible events[6])을 이용하여 가설 행렬(hypothesis matrix),

$$\hat{\omega} = \{\hat{\omega}_{jt} \mid j \in [1, m], t \in [0, n]\}$$
 를 발견해야만 한다.

$$\begin{cases} \sum_{j=1}^m \hat{\omega}_{jt} \leq 1 & \text{for } (t \in [1, n]), \\ \sum_{t=0}^n \hat{\omega}_{jt} = 1 & \text{for } (j \in [1, m]) \end{cases} \quad (2)$$

여기서 가설 행렬 $\hat{\omega}_{jt}$ 는 측정값 j 가 클러터 ($t=0$) 혹은 표적 ($t \neq 0$)과 결합을 이를 때 $\hat{\omega}_{jt}=1$ 이 된다. 모든 가설 행렬을 구하는 문제는 조합문제(combinatorial problem)가 되기 때문에 표적과 측정값의 수가 증가함에 따라 데이터 결합 가설의 수는 지수함수적으로 증가하게 된다.

2. 표적 운동궤적의 제한을 이용한 거리 기준자 정의

본 연구에서는 탐색 공간의 규모를 줄이기 위하여 추가적인 제한 사항을 고려한다. 그림 2와 같이 어떤 임의의 탐지센서의 한 스캔을 고려해 보자. 이 그림에서 시간 k 에

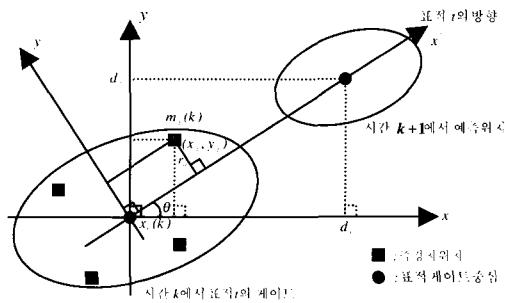


그림 2. 표적 케이트 및 측정값.

Fig. 2. Geometry of Track and Measurement.

서 표적 t 의 케이트 중심의 위치는 $x_t(k)$ 라고 하였으며, $m_j(k)$ 는 시간 k 에서 측정값 j 의 좌표를 나타낸다. 여기서 케이트 중심은 칼만필터[11]와 같은 추정기로 얻어진 실제 표적의 위치 추정값이다. 따라서 추적을 하기 위해서는 케이트 내의 측정값들 중에서 기껏해야 하나의 실제 표적 반환 값을 선택해야만 한다.

한편, 원거리 탐지센서에서 대상으로 하고 있는 표적은 그 방향을 한 스캔 사이에 갑자기 변하지 않으므로 표적궤적에서 실제 표적에서 오는 반환 값으로 선택하는 측정값을 측정값들 중에서 표적 케이트에 가장 가까이 위치한 것으로 선택하도록 하는 거리 기준자(distance measure)를 채택한다. 그러면 표적 t 의 궤적 방향을 기준 좌표로 한 $m_j(k)$ 의 위치값 r_{jt} 는 다음 (4)와 같이 표현 가능하다.

$$r_{jt}^2 \equiv \frac{(x_j d_{vt} - y_j d_{xt})^2}{(d_{xt}^2 + d_{vt}^2)} \quad (3)$$

여기서 d_{xt} 와 d_{vt} 는 예측 필터(prediction filter)에 의해서 추정된 시간 k 와 $k+1$ 에서의 각각 x, y 축의 방향으로 수직 거리이다. 따라서 관측된 지점으로부터 표적 궤적방향과는 항상 수직 거리 상태가 평가 기준의 초점이 된다.

3. 데이터 결합을 위한 MAP 추정기 유도

지금까지 논의된 문제의 궁극적인 목적은 측정값 y 와 x 가 주어지면 (2)를 만족하는 가설 행렬 $\hat{\omega} = \{\hat{\omega}_{jt} \mid j \in [1, m], t \in [0, n]\}$ 를 구하는 것이다. 지금부터는 케이트 센터 x , 측정값 y , 가설 행렬 ω 와 $\hat{\omega}$ 들을 랜덤 프로세스로 실현한 것을 X, Y, Ω , 그리고 $\hat{\Omega}$ 로 표시한다.

다음으로 $\hat{\Omega}$ 는 파라메터 공간(parameter space)이고, (X, Y, Ω) 는 관측 공간(observation space)이라고 생각하자. 그러면 베이시안 규칙에 의한 사후확률(a posteriori probability)은 다음과 같이 유도된다.

$$P(\hat{\omega} \mid \omega, y, x) = \frac{P(\omega \mid \hat{\omega}) P(y, x \mid \hat{\omega}) P(\hat{\omega})}{P(\omega, y, x)} \quad (4)$$

여기서 우리는 두 변수 $\hat{\omega}$ 와 (x, y) 는 서로 분리되어서 관측 되기 때문에

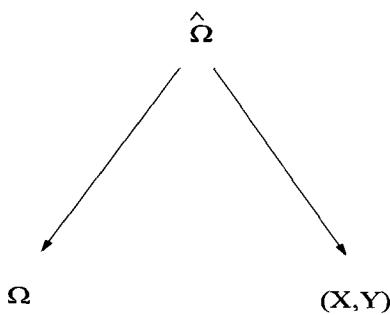


그림 3. 파라메터 공간 및 관측 공간.

Fig. 3. Parameter space and observation space.

$P(\hat{\omega} | \omega, y, x) = P(\omega | \hat{\omega})P(y, x | \hat{\omega})$ 와 같이 됨을 알 수 있다. 이 관계식은 그림 3과 같이 표현할 수 있다.

파라메터 $\hat{\Omega}$ 이 주어지면, Ω 와 (x, y) 가 관측되어진다. 만일 파라메터 공간과 관측 공간 사이에 관계식을 나타내는 조건 확률이 가능하다면 다음과 같은 MAP 추정기를 얻을 수 있다.

$$\hat{\omega}^* = \arg \max_{\hat{\omega}} P(\hat{\omega} | \omega, y, x) \quad (5)$$

4. 제한 사항을 고려한 에너지 함수 유도

다중표적 추적시스템에서 고려한 모델은 템지센서에서 가장 일반적으로 적용하는 깁스분포(Gibbs distribution)[14][15]을 이용하여 조건확률을 다음과 같이 나타낼 수 있다.

$$\begin{cases} P(y, x | \hat{\omega}) = \frac{1}{Z_1} \exp\{-E(y, x | \hat{\omega})\} \\ P(\omega | \hat{\omega}) = \frac{1}{Z_2} \exp\{-E(\omega | \hat{\omega})\} \\ P(\hat{\omega}) = \frac{1}{Z_3} \exp\{-E(\hat{\omega})\} \end{cases} \quad (6)$$

여기서 $Z_s (s \in [1, 2, 3])$ 은 파티션 함수(partition function)이고 그 값은 다음과 같이 표현된다.

$$Z_s = \int_{\hat{\omega} \in \epsilon} \exp\{-E(\hat{\omega})\} d\hat{\omega} \quad (7)$$

여기서 E 는 에너지 함수이다. (6)을 (4), (5)에 대입하여 다음 식을 얻는다.

$$\hat{\omega}^* = \arg \min_{\hat{\omega}} [E(y, x | \hat{\omega}) + E(\omega | \hat{\omega}) + E(\hat{\omega})] \quad (8)$$

여기서 에너지 함수는 표적 측정값과 표적 사이의 제한 사항들을 모두 고려하여 구현(realization)한 결과이다. 예를 들면 (9)에서 첫째 항은 측정값과 표적 사이에 거리를 나타낸다. 따라서 (3)에 의해서 주어진 제한사항을 고려하여 최소화 시켜야만 한다. 둘째 항은 유효 측정값들과 관련이 없는 측정값들을 억제하기 위한 의도로 삽입한 항이다. 셋째 항은 유효 행렬의 제한사항을 구현한 것으로서 (2)에서 보인 두 가지 제한 사항을 충실히 나타내도록 설계되었다. 각 항의 에너지 함수는 다음과 같이 각각 정의된다.

$$\begin{cases} E(y, x | \hat{\omega}) = \sum_{t=1}^n \sum_{j=1}^m \frac{(x_j d_{yt} - y_j d_{xt})^2}{(d_{xt}^2 + d_{yt}^2)} \hat{\omega}_{jt}, \\ E(\omega | \hat{\omega}) = \sum_{t=1}^n \sum_{j=1}^m (\hat{\omega}_{jt} - \omega_{jt})^2, \\ E(\hat{\omega}) = \sum_{t=1}^n \left(\sum_{j=1}^m \hat{\omega}_{jt} - 1 \right) + \sum_{j=1}^m \left(\sum_{t=0}^n \hat{\omega}_{jt} - 1 \right) \end{cases} \quad (9)$$

(9)를 (8)에 대입하면 다음과 같다.

$$\begin{aligned} \hat{\omega}^* = \arg \min_{\hat{\omega}} & \sum_{t=1}^n \sum_{j=1}^m r_{jt} \hat{\omega}_{jt} + \frac{\alpha}{2} \sum_{t=1}^n \sum_{j=1}^m (\hat{\omega}_{jt} - \omega_{jt})^2 \\ & + \sum_{t=1}^n \left(\sum_{j=1}^m \hat{\omega}_{jt} - 1 \right) + \sum_{j=1}^m \left(\sum_{t=0}^n \hat{\omega}_{jt} - 1 \right) \end{aligned} \quad (10)$$

여기서 $r_{jt} = \sqrt{\frac{(x_j d_{yt} - y_j d_{xt})^2}{(d_{xt}^2 + d_{yt}^2)}}$ 이고, α 와 β 는 각각 가중치가 적용된 거리 기준자와 매칭 항(matching term)들의 계수이다.

III. 최적해 구하기

앞장의 (10)의 최적해는 결정적인 방법(deterministic method)에 의해서 구하는 것은 매우 어려운 실정이다. 따라서 현재 제한된 최적화 문제를 제한이 없는 문제로 변환시켜서 푸는 방법을 이용한다. 이를 위하여 Lagrange 멀티플라이어 이론을 이용한다[8,9]. 이장에서는 (8)를 푸는 방법과 또한 관련 파라메터를 정하는 방법에 대해서 기술한다.

1. 에너지 함수의 최소화

해결해야 될 문제는 $\hat{\omega}^* = \arg \min_{\hat{\omega} \geq 0} L(\hat{\omega}, \lambda, \varepsilon)$ 가 되도록 $\hat{\omega}^*$ 을 구하는 것으로 표현할 수 있다. 여기서

$$\begin{aligned} L(\hat{\omega}, \lambda, \varepsilon) = & \alpha \sum_{t=1}^n \sum_{j=1}^m r_{jt} \hat{\omega}_{jt} + \frac{\beta}{2} \sum_{t=1}^n \sum_{j=1}^m (\hat{\omega}_{jt} - \omega_{jt})^2 \\ & + \sum_{t=1}^n \lambda_t \left(\sum_{j=1}^m \hat{\omega}_{jt} - 1 \right) + \sum_{j=1}^m \varepsilon_j \left(\sum_{t=0}^n \hat{\omega}_{jt} - 1 \right) \end{aligned} \quad (11)$$

이고, λ_t 와 ε_j 는 Lagrange 멀티플라이어들이다. (11)에는 결합 행렬의 첫째 열 즉 새로운 표적 혹은 클러티를 나타내는 부분을 반영하고 있다. 일반적으로 다중표적추적에서는 측정값의 수는 표적 궤적의 수 보다 많아서 원래 표적의 수보다 훨씬 넘는 측정값 때문에 많은 문제를 야기한다. 그러므로 본 논문에서는 $m > n$ 이라고 가정한다.

(11)의 각 항들이 똑같은 원소들을 갖도록 다음과 같이 변경한다.

$$\begin{aligned} L(\hat{\omega}, \lambda, \varepsilon) = & \alpha \sum_{t=0}^n \sum_{j=1}^m r_{jt} \hat{\omega}_{jt} (1 - \delta_t) + \frac{\beta}{2} \left(\sum_{t=0}^n \sum_{j=1}^m (\hat{\omega}_{jt} - \omega_{jt})^2 - d_{mn} - 1 \right) \\ & + \sum_{t=0}^n \lambda_t \left(\sum_{j=1}^m \hat{\omega}_{jt} - 1 - d_{mn} \delta_t \right) + \sum_{j=1}^m \varepsilon_j \left(\sum_{t=0}^n \hat{\omega}_{jt} - 1 \right) \end{aligned} \quad (12)$$

여기서 $d_{mn} \equiv m - n - 1$ 이다.

(12)는 극점을 갖는 컨벡스 함수(convex function)이다. 국부 쌍대성(local duality)[8]을 위해 컨벡스 해석 성질을 이용하여, 최적해는 다음과 같이 구할 수 있다.

$$(\hat{\omega}^*, \lambda^*, \varepsilon^*) = \arg \max_{\varepsilon} \max_{\lambda} \min_{\hat{\omega} \geq 0} L(\hat{\omega}, \lambda, \varepsilon) \quad (13)$$

(13)이 극점에 도달하기 위한 필요 조건[8]은 다음과 같다.

$$\begin{cases} \nabla_{\hat{\omega}_j} L(\hat{\omega}, \lambda, \varepsilon) = 0, \\ \nabla_{\lambda_i} L(\hat{\omega}, \lambda, \varepsilon) = 0, \\ \nabla_{\varepsilon_j} L(\hat{\omega}, \lambda, \varepsilon) = 0. \end{cases} \quad (14)$$

먼저 $\nabla_{\hat{\omega}_j} L(\hat{\omega}, \lambda, \varepsilon) = 0$ 으로 부터 다음을 얻을 수 있다.

$$\hat{\omega}_{jt}^* = -\frac{\lambda_i + f_{jt}(\varepsilon_j)}{\beta} \quad (15)$$

여기서 $f_{jt}(\varepsilon_j) = -\beta\omega_{jt} + \alpha r_{jt}(1 - \delta_t) + \varepsilon_j$ 이다. (15)를 (12)에 대입하여 다시 정리하면 다음과 같다.

$$\begin{aligned} L(\lambda, \varepsilon) &= -\frac{1}{2\beta} \sum_{i=0}^n \sum_{j=1}^m [\lambda_i^2 + 2\lambda_i f_{jt}(\varepsilon_j) \\ &\quad + \frac{2\beta\lambda_i}{m} (1 + d_{mn}\delta_t) \\ &\quad + f_{jt}(\varepsilon_j)^2 - \beta^2 \omega_{jt}^2 \\ &\quad + \frac{\beta^2(d_{mn}+1)}{mn} + 2\beta \frac{\varepsilon_j}{n+1}] \end{aligned} \quad (16)$$

다음으로 $\nabla_{\lambda_i} L(\lambda, \varepsilon) = 0$ 으로 부터 다음 해를 얻을 수 있다.

$$\lambda_i^* = -\frac{\beta}{m} (1 + d_{mn}\delta_t) - \frac{1}{m} \sum_{j=1}^m f_{jt}(\varepsilon_j) \quad (17)$$

(16)에 (17)을 대치하면 다음과 같다.

$$\begin{aligned} L(\varepsilon) &= -\frac{1}{2\beta} \sum_{i=0}^n \sum_{j=1}^m \left\{ \frac{1}{m} \sum_{l=1}^m f_{lt}(\varepsilon_l) - f_{jt}(\varepsilon_j) \right\}^2 \\ &\quad - \frac{2\beta\lambda_i}{m} (1 + d_{mn}\delta_t) \\ &\quad - f_{jt}(\varepsilon_j) + \frac{2\beta}{n+1} \varepsilon_j - \frac{\beta^2}{m^2} (1 + d_{mn}\delta_t)^2 \\ &\quad - \beta^2 \omega_{jt}^2 + \frac{\beta^2(d_{mn}+1)}{mn} \end{aligned} \quad (18)$$

마지막으로 $\nabla_{\varepsilon_j} L(\varepsilon) = 0$ 에서 다음을 얻을 수 있다.

$$\begin{aligned} \varepsilon_j^* &= \frac{m}{m-1} \tilde{\varepsilon}_j + \frac{m}{(n+1)(m-1)} \\ &\quad \sum_{t=0}^n \{\beta(\omega_{jt} - \bar{\omega}_t) - \alpha(1 - \delta_t)(r_{jt} - \bar{r}_t)\} \end{aligned} \quad (19)$$

여기서 $\bar{r}_t, \bar{\omega}_t$ 와 $\bar{\varepsilon}$ 는 t 열에서 평균값들이며, $\tilde{\varepsilon}_j$ 는 ε_j 의 요소를 제외한 평균값이다. 그러므로 ω_{jt} 와 r_{jt} 가 주어지면 ε^* 은 순차적으로 다음과 같이 구할 수 있다.

$$\begin{aligned} \varepsilon_j^{t+1} &= \frac{m}{(m-1)} \tilde{\varepsilon}_j^t + \mu \frac{m}{(n+1)(m-1)} \\ &\quad \sum_{t=0}^n \{\beta(\omega_{jt} - \bar{\omega}_t) - \alpha(1 - \delta_t)(r_{jt} - \bar{r}_t)\} \end{aligned} \quad (20)$$

여기서 μ 는 갱신 상수(updating constant)이고, t 는 반복 지수(iteration index)이다. 식(21)에서 ε_j 를 포함하여 ε 의 평균값을 구하면 $\frac{m}{m-1}$ 는 없어진다. 그 경우에는 다음 식을 얻을 수 있다.

$$\begin{aligned} \varepsilon_j^{t+1} &= \bar{\varepsilon}_j^t + \mu \frac{1}{n+1} \\ &\quad \sum_{t=0}^n \{\beta(\omega_{jt} - \bar{\omega}_t) - \alpha(1 - \delta_t)(r_{jt} - \bar{r}_t)\} \end{aligned} \quad (21)$$

지금까지 구한 (15), (17)과 (21)를 함께 모으면 다음과 같이 표현할 수 있다.

$$\begin{cases} \hat{\omega}_{jt} = \frac{\beta\omega_{jt} - \alpha r_{jt}(1 - \delta_t) - \lambda_i - \varepsilon_j}{\beta} \\ \lambda_i = -\frac{\beta}{m} (1 + d_{mn}\delta_t) - \frac{1}{m} \sum_{j=1}^m f_{jt}(\varepsilon_j) \\ \varepsilon_j = \bar{\varepsilon}_j^t + \mu \frac{1}{n+1} \sum_{t=0}^n \{\beta(\omega_{jt} - \bar{\omega}_t) - \alpha(1 - \delta_t)(r_{jt} - \bar{r}_t)\} \end{cases} \quad (22)$$

이 식들은 감시센서로부터 오는 스캔데이터의 각 프레임마다 오직 $O(mn)$ 의 곱하기 연산만이 필요하다.

2. 파라미터 추정

(22)에서는 두개의 파라미터 α, β 를 포함하고 있다. (10)에서 언급한바와 같이 α, β 는 비용함수(cost function)와 관계가 있다.

이 파라미터들을 구하기 위해서 본 논문에서는 최대공산 추정(Maximum Likelihood Estimation)을 고려한다. 즉 $(\omega, \mathbf{y}, \mathbf{x})$ 가 주어진 상황 하에서 Θ 는 다음과 같이 최대공산추정기로서 구할 수 있다.

$$\Theta = \underset{\Theta}{\operatorname{argmax}} P(\omega, \mathbf{y}, \mathbf{x} | \hat{\omega}, \Theta) \quad (23)$$

여기서 $\Theta \equiv [\alpha \ \beta]^T$ 이다. 만일 ML이 존재한다면 MLE은 유니크(unique)하지만[13] 불행하게도 ML 추정기의 계산량은 부분함수의 계산 때문에 엄청나다. 그러므로 MLE의 대안으로서 최대의사공산기법(MPL: maximum pseudo likelihood)을 고려한다. MPL 추정기에서 $P(\omega, \mathbf{y}, \mathbf{x} | \hat{\omega}, \Theta)$ 는 국부 부분 함수(local partition function)[13]의 곱으로 다음과 같이 표현 가능하다.

$$\begin{aligned} P(\omega, \mathbf{y}, \mathbf{x} | \hat{\omega}, \Theta) &= \frac{P(\mathbf{y}, \mathbf{x} | \omega, \hat{\omega}, \Theta) P(\hat{\omega} | \omega, \Theta) P(\omega | \Theta)}{P(\hat{\omega} | \Theta)} \\ &\approx \prod_{i=0}^n \prod_{j=1}^m \frac{1}{Z_{jt}} \exp\{-[\alpha r_{jt} \hat{\omega}_{jt} \delta_t + \frac{\beta}{2} (\hat{\omega}_{jt} - \omega_{jt})^2]\} \\ &= \prod_{i=0}^n \prod_{j=1}^m \frac{1}{Z_{jt}} \exp\{-\Theta^T \Phi(\hat{\omega}_{jt})\}, \end{aligned} \quad (24)$$

여기서 Z_{jt} 는 국부 부분함수이고 그 값은

$$Z_{jt} = \sum_{\hat{\omega}_{jt} \in \hat{\omega}} \exp\{-\alpha r_{jt} \hat{\omega}_{jt} \delta_t - \frac{\beta}{2} (\hat{\omega}_{jt} - \omega_{jt})^2\} \text{ 이고 } \Theta$$

용함수 $\Phi(\hat{\omega}_{jt})$ 은 다음과 같다.

$$\Phi(\hat{\omega}_{jt}) = \begin{bmatrix} r_{jt} \hat{\omega}_{jt} \delta_t \\ \frac{1}{2} (\hat{\omega}_{jt} - \omega_{jt})^2 \end{bmatrix} \quad (25)$$

(24)는 Θ 를 포함하는 파라미터가 서로 선형적으로 독립일 경우에만 Θ 의 관점에서 엄격한 오목꼴(concave)이 된다[13]. 그러므로 Θ 는 다음의 경사 탐색 방법(gradiant search method)로부터 구할 수 있다.

$$\frac{\partial \Theta}{\partial t} = -\mu \nabla_{\Theta} \ln P(\omega, \mathbf{y}, \mathbf{x} | \hat{\omega}, \Theta) \quad (26)$$

(24)를 (26)에 대입하면

$$\begin{aligned} \Theta^{t+1} &= \Theta^t - \mu \nabla_{\Theta} \ln P(\omega, \mathbf{y}, \mathbf{x} | \hat{\omega}, \Theta) |_{\Theta=\Theta^t} \\ &= \Theta^t - \mu \sum_{i=0}^n \sum_{j=1}^m \{ \Phi(\hat{\omega}_j) \\ &\quad - \frac{1}{Z_j} \sum_{\hat{\omega}_j \in \hat{\omega}} [\Phi(\hat{\omega}_j) \exp(-(\Theta^t)^T \Theta(\hat{\omega}_j))] \} \end{aligned} \quad (27)$$

이 된다. 여기서 μ 와 τ 는 각각 갱신 상수와 반복 횟수이다.

3. 전체 시스템 구조 및 요구 계산량 분석

지금까지 유도한 식들을 이용하여 전체 구성관련식과 계산 복잡성을 분석한다. (22)와 (27)을 이용하여 전체 구성식을 다시 정리하면 다음과 같다.

$$\begin{aligned} \hat{\omega}_j^* &= \frac{\beta \omega_j - \alpha r_j (1 - \delta_j) - \lambda_j - \varepsilon_j}{\beta} \\ \lambda_j^* &= -\frac{\beta}{m} (1 + d_{mn} \delta_j) - \frac{1}{m} \sum_{j=1}^n f_j(\varepsilon_j) \\ \varepsilon_j^* &= \bar{\varepsilon}_j^t + \mu \frac{1}{n+1} \sum_{i=0}^n \{ \beta (\omega_{ji} - \bar{\omega}_i) - \alpha (1 - \delta_i) (r_{ji} - \bar{r}_i) \} \\ \Theta^{t+1} &= \Theta^t - \mu \sum_{i=0}^n \sum_{j=1}^m \{ \Phi(\hat{\omega}_j) - \frac{1}{Z_j} \sum_{\hat{\omega}_j \in \hat{\omega}} [\Phi(\hat{\omega}_j) \exp(-(\Theta^t)^T \Theta(\hat{\omega}_j))] \} \end{aligned}$$

처음 세 개의 식들은 데이터 결합 부분을 나타내며, 마지막 식은 파라메터 갱신에 관한 식이다. 그럼 4에 전체 시스템의 계산 구조를 보였다. 이 시스템의 구조는 크게 데이터 결합 부분과 파라메터 갱신 부분으로 구성되어 있다. 데이터 결합 블록은 입력 데이터를 이용하여 가능한 행렬(feasible matrix)을 얻기 위하여 에너지 함수로 변형시킨다. 블록 내에서 먼저 ε 를 계산하고 그 다음에 λ 를 계산한다. 마지막으로 가능한 행렬(feasible matrix) $\hat{\omega}$ 가 계산되어 진다. 파라메터 갱신 블록은 앞 단계에서 입력과 가능한 행렬 데이터를 이용하여 파라메터를 갱신한다.

전체 시스템 계산 구성도에 의하여 데이터 결합 및 파라메터 갱신에 필요한 곱하기 연산 수를 가지고 계산 복잡성을 분석한다. 만일 n 개의 표적과 m 개의 측정값이 있다면 가정함과 동시에 ε_j 와 λ_j 의 평균 반복 횟수가 각각

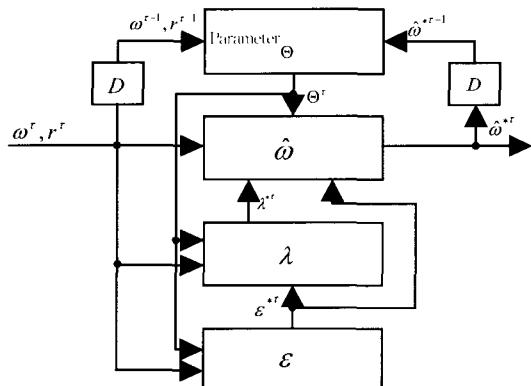


그림 4. 전체 시스템 계산 구조도.

Fig. 4. Overall calculation structure.

$\bar{\tau}_1$, $\bar{\tau}_2$ 라고 가정한다. 이 경우에 데이터 결합 단계에서 λ 와 ε 의 계산을 위해서는 $O(\bar{\tau}_1 mn)$ 과 $O(\bar{\tau}_2 mn)$ 의 계산이 요구된다. 가능한 가선행렬을 끌어내기 위해서 필요한 계산량은 $O(mn)$ 의 곱하기 연산이 필요하다. 그러므로 데이터 결합 부분에서 곱하기 연산의 수는 $O(\bar{\tau}_1 + \bar{\tau}_2 + 1)mn$ 이 된다. 파라메터 갱신을 위해서는 $O(\bar{\tau}_3 mn)$ 의 계산량이 요구된다. 여기서 $\bar{\tau}_3$ 는 수렴하는데 필요한 평균 반복 횟수이다. 예상했던 것과 같이 제안한 최적 적용 데이터 결합(optimal adaptive data association) 알고리즘의 계산 요구량은 표적 및 측정값의 증가에 지수함수 적으로 증가하지 않은 특성을 갖고 있다. 따라서 기존의 JPDAF(Joint Probabilistic Data Association Filter)[3]보다 실제 시스템 적용 시 유리할 것이다.

IV. 컴퓨터 시뮬레이션 및 고찰

최적데이터결합을 위한 MAP 추정기(MAPODA : MAP estimate optimal data association)의 성능 평가를 위하여 일디스(iltis)가 제안한 신경망 PDA(NPDA: neural probabilistic data association)[4] 알고리즘과 성능 비교를 수행하였다. 비록 MAPODA가 병렬구조의 하드웨어 구현에 용이하지만 본 시뮬레이션에서는 기본 알고리즘의 성능 평가를 위한 것이므로 실시간 개념이 아닌 표본간격을 이용하면 되므로 일반적인 범용 586급 퍼스널 컴퓨터를 사용하였다. 성능평가는 먼저 클러터 밀도에 따른 추적 유지 성능을 교차 표적과 평행 표적에 대해서 수행하였고, 다중표적 추적 성능 평가를 위해서는 <표 1>에 보인 모든 표적이 동시에 나타난 경우를 대상으로 시뮬레이션을 수행하였다.

<표 1>의 표적들의 운동 모델과 측정관계식은 2차원상에서 다음과 같이 주어졌다.

$$\mathbf{x}(k+1) = F\mathbf{x}(k) + G\mathbf{w}(k), \quad (28)$$

$$\mathbf{z}(k) = H\mathbf{x}(k) + \mathbf{v}(k), \quad (29)$$

여기서 표적의 위치($x(k)$, $y(k)$)와 표적의 속도($\dot{x}(k)$, $\dot{y}(k)$)의 상태변수 $\mathbf{x}(k)$ 의 값과 시스템 공정 잡음 $\mathbf{w}(k)$, 센서 측정잡음 $\mathbf{v}(k)$ 은

$$\left| \begin{array}{l} \mathbf{x}(k) = (x(k) \ \dot{x}(k) \ y(k) \ \dot{y}(k))^T \\ \mathbf{w}(k) = (w_1(k) \ w_2(k))^T \\ E\{w(k)\} = 0 \\ E\{w(k)w^T(j)\} = Q\delta(k-j) \\ E\{v(k)\} = 0 \\ E\{v(k)v^T(j)\} = R\delta(k-j) \end{array} \right. \quad (30)$$

이고, 시스템 천이 행렬 F 와 시스템 잡음 행렬 G , 측정행렬 H 는 표본 간격을 Δ 로 표현했을 때 다음과 같다.

$$F = \begin{pmatrix} 1 & \Delta & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta \\ 0 & 0 & 0 & 1 \end{pmatrix}, \quad G = \begin{pmatrix} \frac{\sqrt{2}}{2} & 0 \\ \Delta & 0 \\ 0 & \frac{\sqrt{2}}{2} \\ 0 & \Delta \end{pmatrix}, \quad H = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \quad (31)$$

그리고 측정값 잡음의 표준 편자는 X, Y 축이 동일하게 $\sqrt{R_u} = 0.15 \text{ km}$ 로 하였으며 탐지 확률은 $P_d = 0.7$ 로 하였다. 클러터는 전체 감시영역에 걸쳐서 균일하게 분포 시켰으며 관측된 전체 클러터의 수는 포아손 랜덤 변수(Poisson random number)를 이용하였다. 클러터의 밀도는 0.2에서부터 $0.8/\text{km}^2$ 으로 하였다. 필터 초기 안정화를 위하여 $k=5$ 이후부터 잡음을 첨가하였으며 성능 비교를 위하여 몬테카를로(Monte Carlo) 시뮬레이션을 수행하였으며 반복 횟수는 $N = 40$ 으로 하였다.

<표 1>에서 교차 표적 실험을 위하여 1,2번의 표적을, 평행 표적 실험을 위하여 3, 4번의 표적을 이용하였고 실험 결과 중 하나의 패턴을 그림 5와 7에 각각 보였다. 그리고 위치 및 속도에 대한 RMS(root mean square) 오차의 정량적인 값은 <표 3>과 같이 정리하였으며, 이것에 대한 도식적 표시는 그림 6과 8에 각각 보였다. 실험결과를 통하여 보면 제안한 알고리즘은 HNPDA 보다 추적 정확도 및 유지율(maintenance)에서 우수한 성능을 보인 것을 알 수 있다.

한편 기동표적에 대한 평가를 위해서는 싱어[12] 모델을 적용하여 시뮬레이션을 수행하였다. 그 결과 예상한 바와 같이 방향성 기동에서는 매우 취약한 점을 가지고 있었으

표 1. 표적 운동 제원.

Table 1. Target specification.

표적 i	초기위치(km)		초기속도(km/s)	
	x	y	x	y
1	-4.0	1.0	0.2	-0.05
2	-4.0	-1.0	0.2	0.05
3	-6.0	-5.0	0.0	0.3
4	-5.5	-5.0	0.0	0.3
5	8.0	-7.0	-0.4	0.0
6	-8.0	-8.0	0.4	0.0
7	-5.0	9.0	0.25	0.0
8	-5.0	8.9	0.25	0.0
9	0.5	-3.0	0.1	0.2
10	9.0	-9.0	0.01	0.2

표 2. 기동 표적 제원.

Table 2. Maneuvering target specification.

표적 i	기동 형태	가속도 (m/s^2)	회전 주기		회전각 (deg)
			(sec)	(sec)	
8	Dog-leg	20	10	10	30
9	일정 가속도	10	15-35	15-35	0

표 3. 교차 및 평행 추적 성능.

Table 3. Cross and parallel target tracking performance.

클러터 밀도 $C(\text{km}^2)$	위치 오차 (km)		속도 오차 (km/s)		추적 유지율 (%)	
	HNPDA	MAPODA	HNPDA	MAPODA	HNPDA	MAPODA
0.2	0.47	0.13	0.46	0.03	84	84
0.4	0.62	0.16	0.69	0.04	52	86
0.6	0.79	0.17	1.17	0.05	48	74
0.8	1.17	0.29	1.45	0.02	36	76
평균	0.76	0.19	0.94	0.04	55	80

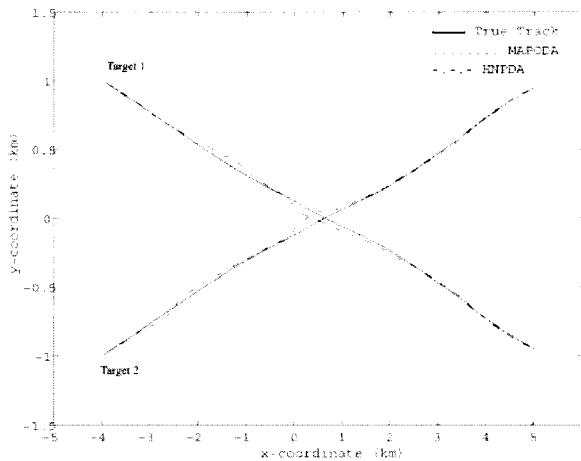


그림 5. HNPDA와 MAPODA의 교차 표적 성능.

Fig. 5. Cross target tracking performance of HNPDA and MAPODA.

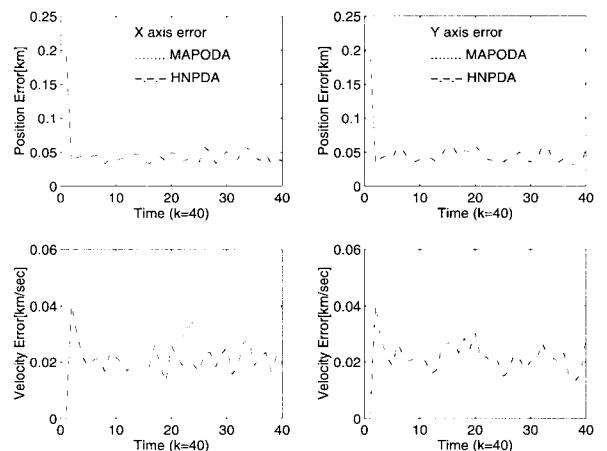


그림 6. 교차 표적에 대한 위치 및 속도 RMS 오차.

Fig. 6. RMS error of position and velocity about cross target.

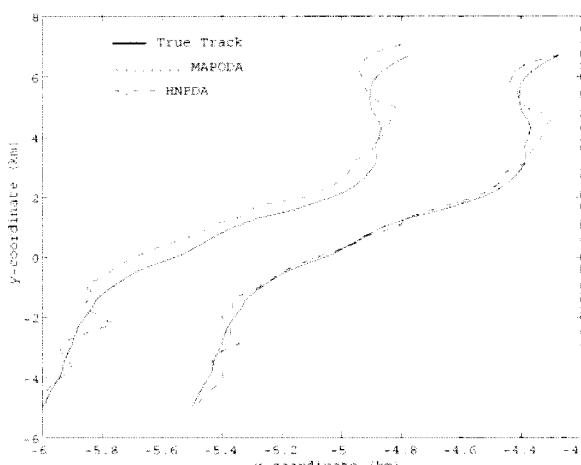


그림 7. 평행 표적에 대한 HNPDA와 MAPODA 성능비교.

Fig. 7. Parallel target tracking performance of HNPDA and MAPODA.

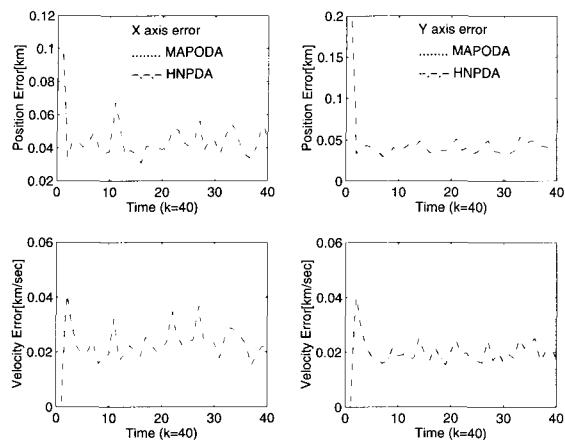


그림 8. 평행 표적에 대한 위치 및 속도에 대한 RMS 오차.
Fig. 8. RMS error of position and velocity about parallel targets.

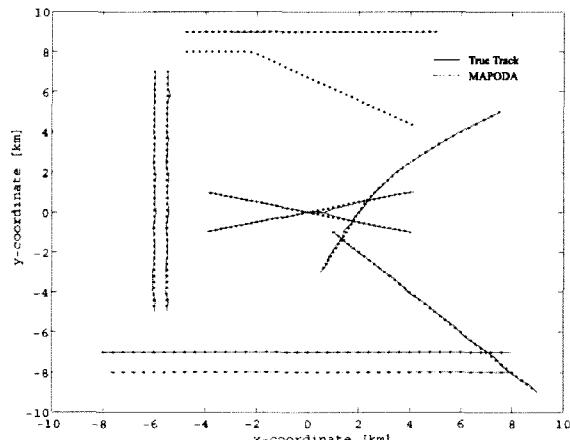


그림 9. MAPODA를 사용한 10개의 표적에 대한 추적 결과.
Fig. 9. Tracking results of 10 targets using MAPODA.

나 일정 가속도 기동에 대해서는 견실한 특성을 가지고 있음을 확인하였다. 기동 표적을 포함한 전체 표적에 대한 다중표적 추적능력을 측정하기 위해서는 클러터 밀도를 0.1로 고정시켜서 수행하였다. 그리고 그 결과 중 하나의 예를 그림 9에 보였다.

V. 결 론

본 논문의 목적은 다중표적추적시스템에 적용하기 위하여 MAP 추정기를 이용한 측정값과 표적 궤적사이의 최적 데이터 결합을 개발하는데 있다. 개발된 알고리즘은 흡필드망을 이용한 HNPDA에 비하여 일관된 데이터 결합 성능을 보여주고 있음을 컴퓨터 시뮬레이션을 통하여 확인하였다. 또한 HNPDA에서는 계수들을 시행착오 방법으로 구하고 있으나 본 알고리즘은 자동적으로 구하도록 함으로서 신뢰성을 높였다.

본 논문에서 제안한 알고리즘의 또 다른 특징은 하드웨어 구현 시 요구 메모리는 측정값의 수가 m 일 때 오직 $O(m)$ 만 필요하다는 것이다. 따라서 실제 구현 시 다른 알고리즘들이 시간이 경과함에 따라 메모리가 증가되는 단

점도 극복할 수 있다.

컴퓨터 시뮬레이션 결과 본 논문에서 제안한 MAPODA는 HNPDA에 비해서 약 5.2% 정도 오차율을 줄일 수 있는 것으로 나타났다.

본 논문에서 제안한 알고리즘은 레이더 표적 추적 시스템에서 사용시 매우 효과적일 것으로 기대된다.

참고문헌

- [1] D. L. Alspach, "A Gaussian sum approach to multi-target identification tracking problem", *Automatica*, vol. 11, pp. 285-296, May 1975.
- [2] D. B. Reid, "An algorithm for tracking multiple targets", *IEEE Trans. on Automat. Contr.*, vol. 24, pp. 843-854, Dec. 1979.
- [3] Y. Bar-Shalom, "Extension of probabilistic data association filter in multitarget tracking", in Proc. 5th Symp. Nonlinear Estimation Theory and its Application, pp. 16-21, Sept. 1974.
- [4] D. Sengupta and R. A. Iltis, "Neural solution to the multitarget tracking data association problem", *IEEE Trans. on AES*, AES-25, pp. 96-108, Jan. 1989.
- [5] R. Kuczewski, "Neural network approaches to multi-target tracking", in *proceedings of the IEEE ICNN conference*, 1987.
- [6] T. E. Fortmann, Y. Bar-Shalom and M. Scheffe, "Sonar Tracking of Multiple Targets Using Joint Probabilistic Data Association", *IEEE J. Oceanic Engineering*, vol. OE-8, pp.173-184, July 1983.
- [7] T. E. Fortmann, Y. Bar-Shalom, *Tracking and Data Association*. Orland Academic Press, Inc. p. 224, 1988.
- [8] J. B. Hiriart-Urruty and C. Lemarrecchal, *Convex Analysis and Minimization Algorithms I*, Springer-Verlag, 1993.
- [9] D. G. Luenberger, *Linear and Nonlinear Programming*, Addison-wesley Publishing Co., 1984.
- [10] Y. W. Lee and H. Jeong, "A Neural Network Approach to the Optimal Data Association in Multi-Target Tracking", *Proc. of WCNN'95*, INNS Press.
- [11] R. E. Kalman, "A new approach to linear filtering and prediction problems," *Trans. ASME, (J. Basic Eng.)* vol.82, pp. 34-45, Mar. 1960.
- [12] R. A. Singer, "Estimating optimal tracking filter performance for manned maneuvering targets", *IEEE Transactions on Aerospace and Electronic Systems*, vol. 6, pp. 473-483, July 1970.
- [13] C. S. Won and H. Derin "Unsupervised segmentation of noisy and textured images using Markov random fields", *CVGIP: Graphical Models and Image Processing*, vol. 54, No. 4, pp. 308-328, July, 1992.
- [14] J. Mousouris, "Gibbs and Markov systems with constraints". *Journal of statistical physics*, vol. 10, pp. 11-33, 1974.

- [15] D. Griffeath, *Introduction to random fields*. In J. G. Kemeny, J. L. Snell and A. W. Knapp, editors, *Denumerable Markov Chains*, chapter 12, pp. 425-458. Springer-Verlag, New York, 2nd edition, 1976.



이 양 원

1958년 12월 12일생. 1982년 중앙대학교 전자공학과 (공학사), 1989년 서울대학교 제어계측공학과(공학석사), 1996년 포항공과대학교 전자전기공학과(공학박사). 1982년 국방과학연구소 선임연구원. 1996년~현재 호남대학교 정보통신공학과 부교수. 관심분야는 레이더 신호처리, 표적 추적 필터, 인터넷 응용 제어.