

論文96-33B-6-20

## 홉필드 신경망을 이용한 다중 표적 추적의 데이터 결합 최적화에 대한 연구

(A Study on the Optimal Data Association in  
Multi-Target Tracking by Hopfield Neural  
Network)

李陽源 \*, 丁弘 \*\*

(Yang Weon Lee and Hong Jeong)

### 요약

다중 표적 추적 시스템은 레이더나 적외선 탐지 센서 등의 측정값을 이용하여 지상 혹은 공중에 있는 표적들의 상태를 추정하여 다수의 표적을 동시에 추적할 수 있는 시스템이다. 이 같은 다중표적 추적시스템의 문제는 센서의 측정값, 탐지 실패, 새로운 표적의 출현 등으로 인한 측정값 균원의 불확실성에서 기인된다. 본 논문에서는 다중표적 추적에 있어서 측정치 균원문제를 해결하기 위한 방법으로 흑필드 신경망을 이용하는 방법을 제안하였다. 제안한 알고리즘은 기존의 불확실성 문제를 에너지 함수화하여 표적과 측정값사이에 최적의 데이터 결합이 가능하도록 한 것이다. 실험결과 제안한 알고리즘은 기존의 JPDA 알고리즘보다 10%이상의 성능의 향상됨을 확인하였다.

### Abstract

A multiple target tracking(MTT) problem is to track a number of targets in cluttered environment, where measurements may contain uncertainties of measurement origin due to clutter, missed detection, or other targets, as well as measurement noise errors. Hence, an MTT filter should be introduced to resolve this problem. In this paper, a neural network is proposed as an MTT filter. After converting the uncertainty problem into an energy function, we describe a Hopfield network which has the

### I. 서 론

다중 표적 추적 시스템은 감시 영역 내에 존재하는 다수의 표적(target)을 측정하여 그 표적들에 대한 위치, 속도 등의 추정치를 제공하는 시스템이다. 이 같은 시스템이 갖고 있는 큰 난점은 센서 탐지 물표(plot)가 부정확하며 탐지 물표의 균원도 불확실하다는 점이다.

일반적으로 표적 추적 분야에서 이 같은 문제는 데이터 결합 문제(data association problem)로 정의하는데, 이 것을 크게 세 가지로 분류하면, 탐지 물표와 탐지 물표 사이의 데이터 결합 관계(추적 개시), 탐지 물표와 기존의 추적 표적 채적과의 결합(추적 유지 혹은 생성), 추적 채적들 사이의 결합(채적 융합)이다. 이 세 가지 중에서 다중 표적 추적(multi-target tracking)에 영향을 주는 것은 추적 필터에 표적 정보를 제공하기 위한 전처리 과정(preprocessing)인 첫 번째와 두 번째 문제가 되겠다. 추적 필터 출력 값들의 상관관계를 이용하는 후처리(postprocessing) 과정인 세 번째 분류는 추적 완료후 다중 센서를 사용시 한 개의 표적

\* 正會員, 湖南大學校 情報通信工學科

(Honam University)

\*\* 正會員, 浦港工科大學校 電子工學科

(Pohang University of science and technology)

接受日字:1996年1月10日, 수정완료일:1996年4月30日

에 대하여 두 개 이상의 표적이 대응되는 것을 방지함은 물론 추적 정확도를 향상시키기 위한 과정에 해당된다.

다중 표적의 데이터 결합 문제점을 해결하기 위한 방법으로서 지금까지 연구한 결과는 크게 세 가지로 나눌 수 있다. 첫째는 센서의 각 탐지 물표가 거짓이 되는 확률을 구해서 이 값이 칼만 필터(Kalman filter) 추정기에 포함되도록 구현한 베이시안(Bayesian) [1,2,10] 방법이다. 둘째는 공산 함수(likelihood function)를 기초로 해서 추적 궤적들을 유지할 것인가 삭제할 것인가를 결정하고, 이 결정을 이용하여 상태 추정을 하는 비베이시안(Nonbayesian)<sup>[13]</sup> 방법이다. 셋째로는 신경망 이론을 최적화 문제 해결에 적용하는 것으로서 데이터 결합 에너지 함수를 정의하여 추적을 구현한 방법<sup>[14,5,11]</sup>이다.

위 세 가지 방법 중에서 앞의 두 가지 방법은 데이터 결합을 구하기 위하여 탐지 물표와 표적간의 모든 조합(combination)을 구해야 하므로 센서에서 오는 탐지 물표의 수가 증가함에 따라 조합 개수는 지수 함수적으로 증가하고 실현 가능성에서 많은 문제를 내포하고 있다. 따라서 이를 해결하기 위하여 보다 효율적인 탐색 방법인 가지 제거(branch pruning)방법<sup>[16]</sup>들이 제안되었으나 실용적인 면에서는 그다지 사용되지 못하고 있는 실정이다. 그러나 신경망 이론을 적용한 접근은 이 같은 문제를 조합 방법이 아닌 계산 에너지 함수(computational energy function)로 문제를 풀며, 이 에너지 함수가 최소값(minimum)값을 가질 때를 적합한 데이터 결합으로 인식하므로 표적 수에 비례하여 계산 부하가 지수 함수적으로 증가하지 않는 장점이 있다. 따라서 표적 수가 많아도 계산이 급속히 증가하지 않으며 또한 병렬로 시스템 구성이 가능하므로 시간적인 면에서 많은 장점이 있다. 한편 이 방법의 단점은 전체 최소값(global minimum)이 아닌 국부 최소값(local minimum)에 빠질 수가 있다는 점이다. 따라서 이 같은 단점을 극복하기 위하여 에너지 함수를 정의함에 있어서 적절한 제한 사항(constraints)을 찾아 고려해 주어야만 한다.

본 논문은 위에서 언급한 다중 표적 추적 기법 중에서 세 번째 분류에 속하는 기법이다. 이 방법에 속하는 것중에서 Iltis<sup>[14]</sup>가 Bar-Shalom의 확률 데이터 결합 기법에 계산 에너지식을 추가로 정의하여 제시한 방법이 있는데 이 방법은 표적과 탐지 물표간의 일대일 대

응 관계가 형성되지 않음으로서 많은 평행 이동 표적 및 기동 표적에 취약함을 갖고 있다. 따라서 이 것을 개선하기 위하여 본 논문에서는 현재 가장 널리 이용하고 있는 최근접(nearest neighbour) 기법을 근간으로 계산 에너지 함수를 도출하여 효과적인 데이터 결합 관계를 풀 수 있는 새로운 알고리즘을 제시하였다. 본 논문의 II장에서는 다중 표적 추적을 위한 데이터 결합 함수의 유도 과정을 보였고, III장에서는 II장에서 유도한 에너지 함수를 흡필드 신경망 회로 방법을 이용하여 구현하는 과정을 서술하였고, IV장에서는 II장에서 설계한 흡필드 데이터 결합망의 성능을 평가하기 위한 컴퓨터 시뮬레이션 방법과 그 결과를 제시하였다.

## II. 데이터 결합(Data association) 함수

먼저 다중 표적 추적을 위한 데이터 결합 문제를 수식화한 후에 이 수식에 관련된 에너지 함수를 정의하고 그 물리적 의미를 관찰한다.

### 1. 데이터 결합 문제의 수식화

다중 표적 추적을 위한 데이터 결합 문제는 한 개의 추적 게이트 내에 다수의 탐지 물표가 나타나거나 혹은 서로 다른 추적 게이트들 간에 탐지 물표를 공유하는데서 문제가 발생한다. 그림 1에 다중 표적 추적시 추적 게이트들과 탐지 물표들과의 관계를 보였다. 여기서  $t_i$ 과  $t_j$ 는 각각 표적 추적 게이트의 중심을 나타내고  $m_1, m_2$  등은 게이트에 나타난 탐지 물표들을 나타내고 있다. 이 장에서는 그림 1에서와 같은 추적 게이트와 탐지 물표간의 결합 관계를 수식으로 표현하는 과정을 보이겠다.

먼저 탐지 물표  $j$ 가 ( $j=1, \dots, M$ )이고, 표적  $t_i$ 가 ( $i=1, \dots, T$ ) 일 때 탐지 물표  $j$ 가 표적  $t_i$ 로부터 기인했을 사건(event)을  $\chi_{it}$ 라 정의한다. 이때  $t_i$ 는 표적 추적 게이트  $t_i$ 가 탐지 물표  $j$ 와 결합 관계에 있는 표적임을 나타내는 색인 표시이다. 이 결합 사건  $\chi_{it}$ 를 이용하여 유효 행렬을 이진 표시 함수(binary indicator function)로 표현하면

$$\omega_{ji}(\chi) = \begin{cases} 1, & \chi_{it} \text{ 발생} \\ 0, & \text{기타.} \end{cases} \quad (1)$$

와 같이된다.

이 표시 함수를 이용하여 표적 추적 게이트와 탐지 물표들 간의 상호 결합 관계를 이진 값으로 갖는 행렬로

표시하면

$$\Omega = [ \omega_{jt} ] , \quad j=1, \dots, M, \quad t=0, 1, \dots, T \quad (2)$$

과 같이 되며, 이때  $j$ 는 탐지 물표의 수를 나타내며,  $t$ 는 표적 추적 게이트 수를 나타낸다. 특히  $t$ 의 값이 0 일 때는 표적이 존재하지 않거나 표적 이외의 클러터나 허위 경보 등으로 인한 탐지 물표를 나타내는데 사용하기 위함이다.

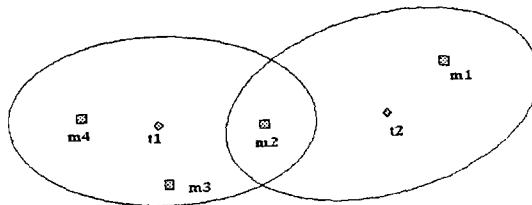


그림 1. 두 개의 표적 추적 게이트 안에 나타난 탐지 물표

Fig. 1. Measurement plots distribution within the two tracking gates.

그림 1에 나타난 상황의 데이터 결합 관계를 위에서 정의한 수식으로 표현하여 보면

$$\Omega = \begin{bmatrix} 1 & 0 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 0 \\ 1 & 1 & 0 \end{bmatrix} \quad j \quad (3)$$

이 된다. 위식에서 행렬의 행(column)  $t$ 는 표적 번호를 나타내고 열(row)  $j$ 는 탐지 물표 번호를 나타낸다. 여기서 첫 번째 행은 새로운 표적 혹은 클러터를 나타내는 것으로서, 모두 1로 되어 있는 것은 탐지된 모든 물표는 지금까지 추적되지 않은 새로운 표적이거나 혹은 클러터일 가능성이 있음을 나타내기 위함이다. 또한 두 번째 열이 모두 1이 되어 있는 것은 그림 1에서 보는 바와 같이 탐지 물표  $m_2$ 는 추적 게이트 1과 추적 게이트 2에 중첩되어 있기 때문이다.

그러나 실제 상황에서는 두 개의 표적이 레이더의 거리 분해능(Resolution) 보다 작지 않은 이상 하나의 탐지 물표는 두 개 이상의 표적으로부터 기인할 수 있으며, 또한 반대로 하나의 표적으로부터 두 개 이상의 탐지 물표는 발생하지 않는다. 따라서 식(3)의 행렬에서 실제 발생 가능한 사건의 유효 행렬 즉 제한 조건을 만족한 사건의 조합 가능한 경우의 수를 모두 찾아

서 각각의 유효 행렬에 대한 확률을 구하는 것이 Bar-Shalom 이 제안한 JPDA(Joint Probabilistic Data Association)<sup>[2]</sup> 방법이다. 그러나 이같은 유효 행렬의 수는 표적 및 탐지 물표의 수가 증가하면 그 수는 지수 함수적으로 증가함으로 실시간 측면에서 실용적이지 못한 점이 있다.

한 예로써 식(3)에서 정의한 행렬에서 제한 사항을 만족하는 행렬들을 일부 구해 보면 다음과 같다.

$$\begin{aligned} \bar{\Omega}_1 &= \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix} & \bar{\Omega}_2 &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} & \bar{\Omega}_3 &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \\ \bar{\Omega}_4 &= \begin{bmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} & \bar{\Omega}_5 &= \begin{bmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix} \end{aligned} \quad (4)$$

여기서  $\bar{\Omega}_1$  유효 행렬은 탐지 물표 1은 표적 2에, 탐지 물표 2는 표적 1에 결합되고 나머지 두개의 탐지 물표는 클러터나 새로운 표적으로 간주되는 상황을 의미한다.  $\bar{\Omega}_2$ 는 탐지 물표 1은 클러터이고 탐지 물표 2는 표적 2에, 탐지 물표 3은 표적 1에 탐지 물표 4는 클러터로 각각 결합되는 경우이다.  $\bar{\Omega}_3$ 는 탐지 물표 모두 클러터나 새로운 표적이 발생한 것으로 간주한 것이 되겠다. 이같은 유효 행렬들 중에서 실제 상황에서 일어날 수 있는 상황과 동일의 상황을 선택하여 탐지 물표와 표적과의 결합 관계를 찾는 것이 다중 표적 추적의 데이터 결합 문제를 해결하는 것이 되겠다.

이 문제는 여러 유효 행렬 집합 요소  $\bar{\Omega}$ 를 변수로 한 에너지 함수  $E$ (computational energy function)에 대한 최소값을 구하는 것과 같은 것으로서 다음과 같이 표현할 수 있다.

$$\bar{\Omega}^* = \min_{\bar{\Omega}} E(\Omega, \bar{\Omega}) \quad (5)$$

여기서 에너지 함수  $E$ 는 각각의 유효 행렬에 대하여 표적과 탐지 물표간의 결합 관계를 실수로 변환시켜 주는 함수로 생각할 수 있다. 즉 데이터의 결합 관계를 일차원의 실수 함수 위에 매핑(mapping) 하는 역할을 수행한다.

## 2. 에너지 함수

일반적으로 에너지 함수  $E$ 는 다음 식과 같이 두개 항의 합으로 구성할 수 있다.

$$E = (\text{가격 함수}) + (\text{제한 조건}) \quad (6)$$

이때 가격(cost)항은 표적 게이트 중심과 탐지 물표간의 거리  $d$ 를 판별자(measure)로 사용하여 구하고 전체 제한(global constraints)항은 다중 표적 추적 상황하에서 일어 날수 있는 모든 제한 사항을 이용하여 구하면 된다.

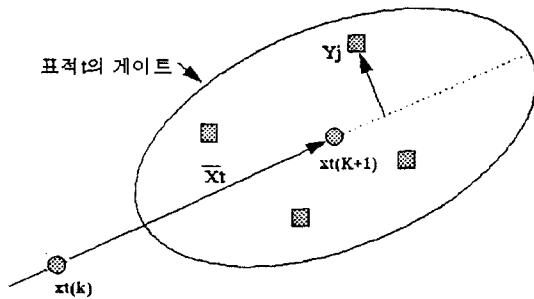


그림 2. 방향성을 고려한 표적 거리 계산 방법  
Fig. 2. Measurement of target distance based on target's course.

먼저 에너지식을 구성하는 요소 중에서 가격 함수에 대한 에너지식을 유도한다. 본 논문에서는 가격 함수의 거리 판별자(distance measure)를 정의함에 있어서 기존의 최근접 데이터 결합 기법(nearest neighbour data association)에서 사용한 표적과 탐지 물표간의 직선거리를 이용한 방법과는 다르게 측정 점에서 표적 방향에 수직한 거리 성분을 사용하도록 하였다. 즉 그림 2에서 보는바와같이 임의의 시간  $k$ 에서의 표적 위치  $x_t(k)$ 와 시간  $k+1$ 에서의 표적 예측 위치  $\bar{x}_t(k+1)$ 을 이용하여 하나의 표적 궤적의 침로를 계산 후에 이 침로 궤적을 기준으로한 탐지 물표와의 수직 거리를 계산하여 이 것을 거리 판별자로 이용한다. 이렇게 하면 많은 탐지 물표가 추적 게이트 내에 존재할 때 거리만이 아니라 방향 성분에도 가중치를 주게 되어 효과적인 데이터 결합이 이루어 질 수 있다. 이같은 방향 성분을 고려한 거리 판별자의 값은 그림 3에서와 같이 2차원의 x, y평면상에 표적  $t$ 의 침로 궤적식에 수직인 지점까지의 거리  $d_{jt}$ 를 다음과 같이 정의하여 사용한다.

$$d_{jt} = \|x_t - y_j\|^2 \equiv \frac{(x_t y_t - y_j \bar{x}_t)^2}{(x_t^2 + y_t^2)} \quad (7)$$

여기서  $x_t, y_t$ 은 벡터  $\bar{x}_t$ 의 x축과 y축의 투영 값이며  $x_t, y_t$ 는 물표의 위치를 나타낸다.

식(7)과 같이 정의된 거리 값을 이용하여 표적과 탐지

물표와의 결합 관계를 찾아내기 위하여

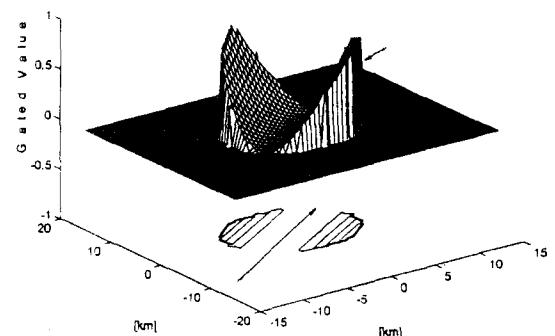


그림 3. 거리 판별자식을 적용했을 때 게이트 내에서 출력되는 값의 분포도  
Fig. 3. Distribution of distance measure value in the gate.

표적  $t$ 와 탐지 물표  $j$ 와의 결합 계수를  $\omega_{jt}$ 라했을 때 계수 분포에 따른 가격 항의 에너지 함수의 값은 다음과 같이된다.

$$E_1 = \sum_{t=1}^T \sum_{j=1}^M d_{jt}^2 \omega_{jt} \quad (8)$$

한편 식(8)에서  $\omega_{jt}$ 의 값은 최초에 그림 1에서 보인 표시 행렬  $\Omega$ 의 요소 값이 되겠으나 이 값은 식 (4)에서 보인 유효 행렬 중의 하나가 되어야만 실제 상황에서 일어날 가능성이 있는 결합 관계가 될 것이다. 따라서 식(8)에서 실제 상황에서 일어날 수 있는 두 가지 조건을 고려하면  $\omega_{jt}$ 의 값은  $\hat{\omega}_{jt}$ 가되어야 한다. 또한 수직 거리  $d_{jt}$ 는 탐지 물표들과 추적 게이트간의 상대적인 거리 값이므로 본 논문에서는 정규화(normalized)한 거리 값인  $r_{jt}$ 을 다음과 같이 구해서 사용한다.

$$r_{jt} = \frac{d_{jt}}{\sum_{j=1}^M d_{jt}} \quad (9)$$

식(9)을 이용하여 식(8)을 변경하면 에너지 함수  $E_1$ 은

$$E_1 = \sum_{t=1}^T \sum_{j=1}^M r_{jt}^2 \hat{\omega}_{jt} \quad (10)$$

이된다.

다음으로 에너지식 중에서 제한 사항을 고려한 부분을 유도한다. 먼저 한 개의 표적에서는 한 개의 물표밖에 나올 수 없다는 제한 조건은  $\Omega$  행렬의 행은 오직 1이 하나만 나와야 되므로 행의 합이 1이 될 때 에너지

가 최소로 되게 식을 구성하면 된다. 마찬가지로 하나의 탐지 물표는 오직 한 개의 표적 게이트에 결합될 수밖에 없으므로 그 행렬의 열의 합도 1이 되었을 때 최소가 되도록 식을 구성한다. 이 같이 구성한 식은

$$E_2 = \frac{1}{2} \sum_{t=1}^T \left( \sum_{j=1}^M \omega_{jt} - 1 \right)^2 + \frac{1}{2} \sum_{j=1}^M \left( \sum_{t=0}^T \omega_{jt} - 1 \right)^2 \quad (11)$$

가된다. 여기서 행에서는  $t$ 가 1부터 시작하는 것은 클러터나 새로운 표적은 기존 표적을 기준으로한 데이터 결합의 최적화에서는 제외하기 위함이다. 그러나 클러터나 새로운 표적도 직접적으로 추적 데이터 결합에 영향을 주기 때문에 이를 위해서 부가적으로 각 열의 요소 하나를 고정시킨 상태에서 다른 행의 요소들을 곱한 후 이들을 더함으로서 한 열에 하나의 1 값이 나올 때 에너지 값이 최소가 되도록 하나의 항을 추가하였다. 각 행에 대해서도 마찬가지로 이같은 사항을 고려하여 추가된 항을 식으로 나타내면

$$E_3 = \frac{1}{2} \sum_{j=1}^M \sum_{t=0}^T \sum_{r \neq t} \omega_{jt} \omega_{jr} + \frac{1}{2} \sum_{t=1}^T \sum_{j=1}^M \sum_{l \neq j} \omega_{jt} \omega_{lt} \quad (12)$$

이 된다.

지금까지 유도한 가격항  $E_1$ 과 제한 조건  $E_2$  와  $E_3$  을 더하여 최종적인 에너지식을 구하면

$$\begin{aligned} E = & \frac{A}{2} \sum_{j=1}^M \sum_{t=0}^T \sum_{r \neq t} \omega_{jt} \omega_{jr} + \frac{B}{2} \sum_{t=1}^T \sum_{j=1}^M \sum_{l \neq j} \omega_{jt} \omega_{lt} + \frac{C}{2} \sum_{t=1}^T \left( \sum_{j=1}^M \omega_{jt} - 1 \right)^2 \\ & + \frac{D}{2} \sum_{j=1}^M \left( \sum_{t=0}^T \omega_{jt} - 1 \right)^2 + \frac{F}{2} \sum_{t=1}^T \sum_{j=1}^M r_{jt}^2 \omega_{jt} \end{aligned} \quad (13)$$

이 된다. 위식 (13)에서  $A,B,C,D,E,F$  계수는 각 항에 대한 가중치 계수들이다.

일반적으로 에너지 함수는 유한한 값과 보장된 최소 값을 가지고 있어야 하므로 이 것들에 대한 검증이 필요하다. 먼저 안정성을 검증하기 위하여 하한값(low bound)  $E_{\min}$ 을 계산하자. (13)식의 각항은 음수가 될 수가 없으므로

$$0 < F \leq E_{\min} \quad (14)$$

인 양의수  $F$ 가 존재한다.

또한 상한 값(upper bound)  $E_{\max}$  은

$$E_{\max} = \frac{MA}{2} T(T+1) + \frac{BT}{2} M(M-1) + \frac{C}{2} T(M-1)^2 + \frac{D}{2} MT^2 \quad (15)$$

이므로 계수들과 추적 게이트 수 및 탐지 물표 수에 의존하므로 이 또한 유한한 값을 갖고 있다. 한편 에너

지  $E$ 는 또한 연속이고  $0 < E_{\min} < E < E_{\max}$  이므로 Lyapunov 함수의 성질을 만족한다. 따라서 유도된 에너지식 (13)은 안정하다.

### III. 데이터 결합 함수를 위한 흡필드망 (Hopfield Network) 설계

앞장에서 정의한 계산 에너지 함수의 해를 구하는 방법은 경험적 방법(Heuristic method), 시뮬레이티드 어닐링(Simulated annealing)<sup>[12]</sup>, 신경망<sup>[17]</sup> 등이 있다. 이 장에서는 이같은 방법 중에서 병렬 처리가 용이하고 표적 측정 수의 변화에 탄력적으로 대응이 가능한 흡필드망을 이용하여 다중 표적 추적을 위한 데이터 결합 알고리즘을 설계하였다. 이 장에서는 먼저 흡필드망의 특성을 고찰하고 이를 위한 에너지 함수의 흡필드망으로의 변환 과정 및 설계 예를 보이겠다.

#### 1. 흡필드망 구조

다중 표적 추적을 위해서 표적과 측정 데이터간의 결합 관계를 분류하는 것은 기존의 데이터 결합 문제를 풀기 위해서 적용한 신경망(Neural Net)은 그림 3과 같은 흡필드망을 응용하였다. 흡필드망의 특징은 단층 및 대칭 되는 구조에 비선형 출력 특성을 가지며 출력은 입력으로 재활되는(이때 자기 자신의 출력은 자기 자신의 입력으로 재활되지 않는다) 회귀적 특성을 가지고 있는 회로이다. 이 망은 뉴런(Neuron)의 상태가 변할 때마다 에너지 함수(Energy function)로 표현되는 값  $E$ 가 항상 감소하는 것이 흡필드와 탱크(Hopfield and Tank)<sup>[17]</sup>에 의해서 증명되었다. 흡필드 모델을 이용하여 다중 표적 추적 데이터 결합 에너지 함수를 최소화시키기 위하여 뉴런의 출력을  $X_i(t)$ 라 할 때 이 뉴런의 입력들의 가중치 합을  $S_i(t)$  표현하면 입출력 관계식은 ,

$$X_i = f(S_i) = \frac{1}{2}(1 + \tanh(S_i)) \quad (16)$$

와 같이 비선형 형태로 주어진다. 이때  $i$ 는 뉴런들의 집합들 중에 있는 어떤 것 하나를 나타낸다.

여기서 다중 표적 데이터 결합을 위한 뉴런들의 출력 분포  $X_i$ 를 기준으로 인위적으로 만든 에너지 함수  $E_h$ 를 최소로 하는 뉴런들의 분포가 되는  $X_i$ 를 찾을 수 있다는 것이 흡필드망이 갖고 있는 가능이라 할 수 있다.

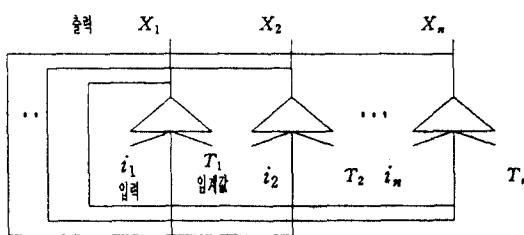


그림 4. 흡필드망(Hopfield Network) 구조  
Fig. 4. The structure of Hopfield network.

일반적으로 뉴런 출력 값에 따른 에너지 함수의 변화는 다음 식과 같이 나타낼 수 있다<sup>[8]</sup>.

$$\frac{dS_i(t)}{dt} = -\frac{\partial E_h}{\partial X_i} \quad (17)$$

이때 에너지 함수의 시간에 따른 변화는 다음 식과 같이 나타낼 수 있다,

$$\frac{dE_h}{dt} = \sum_{i=1}^N \frac{\partial S_i(t)}{\partial t} \frac{\partial X_i(t)}{\partial S_i(t)} \frac{\partial E_h(t)}{\partial X_i(t)} \quad (18)$$

식(17)의 모델이 에너지  $E_h$ 를 감소하는 방향으로 작용하는 기울기임을 보이기 위하여 식(17)을 식(18)에 대입하여 정리하면 다음 식과 같아지며

$$\frac{dE_h(t)}{dt} = - \sum_{i=1}^N \left( \frac{dS_i(t)}{dt} \right)^2 \frac{dX_i(t)}{dS_i(t)} \leq 0 \quad (19)$$

이때 에너지  $E_h$ 는  $X_i$  함수가 단순 증가 함수이므로 시간에 따라 항상 감소하는 것을 알 수 있다. 흡필드망의 에너지식을 다음과 같은 Lyapunov 함수로 정의하면,

$$E_h = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N W_{ij} X_i X_j - \sum_{i=1}^N I_i X_i + \sum_{i=1}^N \int_0^{X_i} f^{-1}(X) dX \quad (20)$$

흡필드망의 변화를 나타내는 미분 방정식은 다음과 같이 주어진다<sup>[8]</sup>.

$$\frac{dS_i}{dt} = -\frac{S_i}{\tau} + \sum_{j=1}^N W_{ij} X_j + I_i \quad (21)$$

여기서  $I_i$ 는 입력값,  $W_{ij}$ 는 신경망간 연결 가중치,  $\tau$ 는 시정수를 나타내며 보통 1로 주어진다. 식(21)에서 보면 어떤 상태에서 출발한 상태 벡터는 에너지 곡면을 따라 내려오다가 에너지 함수의 국부 최소값에 수렴하는 것임을 알 수 있고 이같은 수렴은 유한한 시간 내에 이루어짐을 알 수 있다. Iltis<sup>[4]</sup>의 논문에서

제안된 신경망에 의한 해법은 Hopfield와 Tank가 제안한 신경망식인 식(21)에 따르고 있다. 즉 Hopfield는 i번째 뉴런 동작식이 식(21)로서 주어진 것을 표시하고 있다. 그러나 식(21)의 우변 제1항에 있는 감쇄항 ( $-Si/\tau$ )은 시간으로서 에너지 함수  $E$ 을 증대시키는 해가 일어지지 않은 경우를 문헌 [13]에 밝히고 있으며 이같은 항을 안이하게 사용하는 것은 위험성이 크게 있다고 말하고 있다. 따라서 본 논문에서는 이 감쇄항을 사용하지 않고 안정상태에 도달하는 신경망을 제안한다. 이와같이 감쇄항을 사용하지 않는 신경망 표현법은 Iltis<sup>[4]</sup>의 논문에서 보다 항상 국부 최소값에 도달 할 수 있음을 보여주고 있다.

## 2. 에너지 함수의 흡필드망으로의 변환

흡필드망을 이용하여 II장에서 유도한 에너지식 식(13)을 풀기 위해서는 에너지식을 식(20)과 같은 형태로 변환을 해야 한다.

이 같은 형태로 변환하기 위해서 먼저 멸타 함수를

$$\delta_{ij} = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases} \quad (22)$$

라 할 때, 이 함수를 이용하여 에너지식을 다시 쓰면

$$\begin{aligned} E = & \frac{A}{2} \sum_i \sum_j \sum_r \delta_{ir} (1 - \delta_{jr}) X_i^r + \frac{B}{2} \sum_i \sum_j \sum_r \delta_{ir} (1 - \delta_{jr}) (1 - \delta_{nr}) X_i^r X_j^r + \frac{CT}{2} \\ & - C \sum_i \sum_j (1 - \delta_{ir}) X_i^r + \frac{C}{2} \sum_i \sum_j \sum_r \delta_{ir} (1 - \delta_{jr}) X_i^r X_j^r + \frac{DM}{2} - D \sum_i \sum_j X_i^r \\ & + \frac{D}{2} \sum_i \sum_j \sum_r \delta_{ir} X_i^r X_j^r + \frac{F}{2} \sum_i \sum_r \delta_{ir} (1 - \delta_{nr}) X_i^r \end{aligned} \quad (23)$$

와 같아된다. 이식에서는 원래 에너지식에서 표시 함수로 사용된  $\omega_{ji}$ 는 흡필드망에서는 각각의 뉴런들의 출력 값에 해당하므로  $\omega_{ji}$ 를  $X_j^r$ 로 치환하여 표현하였다. 뉴런 출력값  $X_j^r$ 는 j번째 열의 t번째 행에 해당되는 뉴런의 출력을 의미하며 그 값은 0과 1사이에 존재한다. 위식(23)을  $X_i^r$ 에 대해서 정리하면 아래와 같다.

$$\begin{aligned} E = & \frac{1}{2} \sum_i \sum_j \sum_r [ A \delta_{ir} (1 - \delta_{jr}) + B \delta_{ir} (1 - \delta_{jr}) (1 - \delta_{nr}) + C \delta_{ir} (1 - \delta_{jr}) + D \delta_{ir} ] X_i^r X_j^r \\ & + \frac{1}{2} (CT + DM) - \sum_i \sum_r [ C (1 - \delta_{nr}) + D - \frac{F}{2} \delta_{nr} (1 - \delta_{nr}) ] X_i^r \end{aligned} \quad (24)$$

한편 원래의 흡필드망의 에너지 함수는 식(20)과 같아지거나 식(20)의 마지막 항은 그 값이 매우 적은 관계로 신경회로망의 설계 과정에서는 일반적으로 생략하고 다음과 같이 간략한 에너지식을 은 사용한다<sup>[19]</sup>.

$$E_h = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N W_{ij} X_i X_j - \sum_{i=1}^N I_i X_i \quad (25)$$

식(24)를 식(25)와 같은 형태로 정의하여 고쳐쓰면 다음과 같다.

$$E = -\frac{1}{2} \sum_i \sum_j \sum_l \sum_r W_{ij}^r X_i^r X_j^l - \sum_i \sum_l I_i^l X_i^l \quad (26)$$

단, 여기서

$$W_{ij}^r = -[ \{A(1-\delta_{il})+D\} \delta_{jl} + \{B(1-\delta_{il})+C\} \delta_{rl}(1-\delta_{il}) ] \quad (27)$$

$$I_i^l = C(1-\delta_{il}) + D - \frac{F}{2} r_{il}^2 (1-\delta_{il}) \quad (28)$$

이다. 에너지식 (24)에서 상수항인  $\frac{CT+DM}{2}$ 은 뉴런의 출력과는 관계없이 에너지에서 바이어스 값에 해당하므로 생략한다. 이 같이 흡필드망의 연결 계수를 구했을 때 뉴런간의 연결 계수  $W$ 는  $M^4$ 개가 되나 대부분의 연결은 단절된 상태이고 일부만 연결이 된 성진 행렬(sparse matrix) 형태로 표현됨을 알 수 있다. 그럼 4에 탐지 물표가  $M=4$ 이고 추적 개이트 수가  $T=4$ 일 때 데이터 결합을 위한 흡필드망의 구조를 보였다. 각각의 뉴런 등은 가중치를 갖고서 연결되며 횡과 종으로는 영향을 주나 대각선 방향으로 영향은 없음을 알 수 있다. 특히 자기 케환 루프의 값에 있어서 첫 번째 행의 뉴런의 값이 계수  $D$ 에 의존하는 것은 이 항은 탐지 물표가 현재 추적하고 있는 표적이 아닌 새로운 표적이나 클러터임을 나타내기 위함이다.

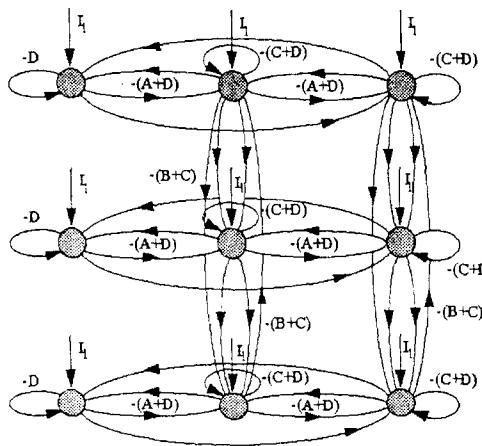


그림 5. 다중 표적 데이터 결합을 위한 흡필드망 (표적수:2, 물표수:3인 경우)

Fig. 5. Hopfield network for multi target data association(target No.:2, Plots:3)

앞에서 정의한 식(21)을 이용하여 흡필드망에 대한 시간에 따른 진화 과정식을 표현하면 아래와 같다.

$$\frac{dS'_i}{dt} = -\sum_j \sum_l [ \{A(1-\delta_{il})+D\} \delta_{jl} + \{B(1-\delta_{il})+C\} \delta_{rl}(1-\delta_{il}) ] X_j^l + C(1-\delta_{il}) + D - \frac{F}{2} r_{il}^2 (1-\delta_{il}) \quad (29)$$

이식을 정리하면 최종적인 식은

$$\frac{dS'_i}{dt} = -A \sum_{j \neq i} X_j^l - B(1-\delta_{il}) \sum_{j \neq i} X_j^l - C(1-\delta_{il}) (\sum_j X_j^l - 1) - D(\sum_j X_j^l - 1) - \frac{F}{2} r_{il}^2 (1-\delta_{il}) \quad (30)$$

이 된다.

#### IV. 실 험

본 논문에서 제안한 알고리즘의 타당성을 알아보기 위하여 실험을 실시하였다. 실험은 컴퓨터 시뮬레이션을 통하여 수행하였다. 특히 상대적인 성능 비교를 위하여 다중 표적 추적 기법 알고리즘의 비교의 기준이 되는 확률 데이터 결합 기법을 제안한 Bar-Shalom의 논문<sup>[2]</sup>를 이용한다.

##### 1. 시뮬레이션 방법

컴퓨터 시뮬레이션을 위하여 사용된 표적은 2차원의 직교좌표하에서 등속도로 운동하는 표적(표1 참조)모델에 가속도 성분을 고려한 공정 잡음을 첨가시킨 모델로서 상태 변수를  $x = [x \dot{x} y \dot{y}]$  라 하면 표적 운동 모델은

$$x'_{k+1} = F^t x_k + G^t \omega_k \quad (31)$$

이 된다. 여기서 위첨자  $t$ 는 각각의 표적에 대한 색인이고  $\omega_k$ 는 백색 가우시안 잡음으로서 평균이 영이고 분산값이  $E[\omega_k \omega_j] = Q \delta_{kj}$ 로 주어지며, 센서의 스캔률을  $\Delta$ 라 할 때  $F$ 와  $G$ 는 다음과 같다.

$$F^t(k) = \begin{pmatrix} 1 & \Delta & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (32)$$

$$G^t(k) = \begin{pmatrix} \Delta^2/2 & 0 \\ \Delta & 0 \\ 0 & \Delta^2/2 \\ 0 & \Delta \end{pmatrix} \quad (33)$$

한편 탐지 물표의 측정식은 오직 위치만을 측정 가능하게 하는 것으로서

$$z'_{k+1} = H x'_{k+1} + v_k \quad (34)$$

이고  $\nu_k$ 는 백색 가우시안 잡음으로서 평균이 영이고 분산값이  $E[\nu_k \nu_j] = R \delta_{kj}$ 로 주어지며,  $H$ 는 다음과 같이 된다.

$$H(k) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad (35)$$

클러터는 그 특성상 포아송(Poisson)함수로 나타나며, 그 분포는 탐지 영역 전체에서 균등하게 되도록 하였다. 식(30)의 미분 방정식은 가능한 계산 시간을 단축하기 위하여 오일라 방법(Euler's method)를 이용하였다. 시뮬레이션 시 클러터는 5 스캔(scan)까지는 클러터를 발생시키지 않고 실제 표적 정보만을 이용한 추적을 수행했는데 이 것은 초기 상태에서 추적 원도 우가 너무 큰 것을 방지하기 위함이었다. 실험을 위한 프로그램 구조는 그림 6과 같이 구성하였으며 사용된 프로그램 언어는 PC MATLAB 4.0 패키지를 이용하였다.

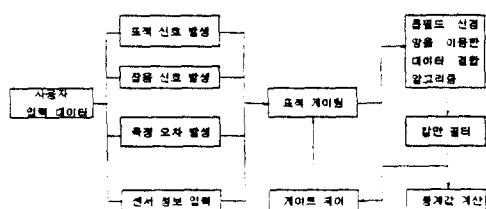


그림 6. 실험 프로그램 구조

Fig. 6. The structure of simulation program.

시뮬레이션 시 사용된 표적 및 필터의 계수들의 값은  $\triangle = 1$ ,  $R(k)=\text{diag}(0.09, 0.09)$ ,  $\sigma_i^s(k)^2 = 0.0036 km^2 s^{-4}$ ,  $\sigma_i^d(k)^2 = 0.0036 km^2 s^{-4}$ 이고, 클러터 밀도는  $0.2 km^{-2}$ 이다.

표 1. 표적 운동 세원

Table 1. Specifications of target trajectories.

표적	위치(m)		속도(m/s)		기동성
	X	Y	Vx	Vy	
1	4000	1000	200	50	
2	-4000	1000	200	50	
3	-6000	5000	0	300	
4	5500	5000	0	300	
5	8000	7000	-400	0	
6	8000	-8000	-400	0	
7	-5000	9000	250	0	
8	5000	8000	250	0	기동( $20m/sec^2$ )
9	500	3000	100	200	기동( $10m/sec^2$ )
10	9000	9000	10	200	

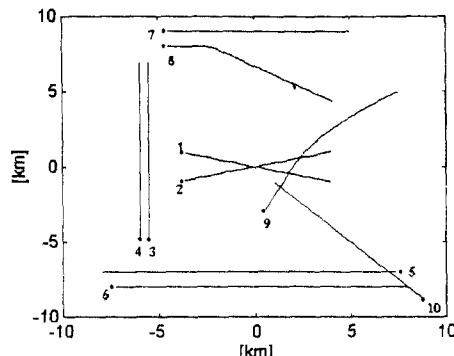


그림 7. 10개의 시험 표적 궤적

Fig. 7. Trajectories of 10 test targets.

실험은 각 스캔마다 센서로부터 들어오는 탐지 물표수를 이용하여 표적 캐이트를 통과하여 나온 탐지 물표수를 이용하여(그림 6 참조) 흡필드망에 입력된다.

## 2. 시뮬레이션 결과

다중 표적에 대한 제안된 필터의 추적 능력을 평가하기 위하여 표 1의 표적 정보를 이용하여 그림 7과 같은 시나리오를 발생하여 성능평가를 수행하였다. 추적오차는 추정오차값을 기준으로 평가하였다. X 및 Y 축에서 각각의 상태 변수에 대한 추정 오차는 다음식을 이용하여 구하였다.

$$\hat{x}_i = \frac{1}{\Delta} \sum_k \hat{x}_i(k) \quad i=1, 2, 3, 4. \quad (36)$$

위 식(36)에서

$$\hat{x}_i(k) = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{x}_i(k) - \hat{x}_i^j(k))^2} \quad (37)$$

이며,  $\Delta$ 는 샘플링간격이며, N은 몬테 카를로 반복 횟수를 나타내며(N=40),  $x_i(k)$ 는 시간 k에서 i 번째의 상태벡터를 나타내며,  $\hat{x}_i^j(k)$ 는 시간 k에서 몬테 카를로 시뮬레이션 반복 회수가 j일 때 필터가  $x_i(k)$ 를 추정한 값을 나타낸다.

### 1) 표적 유형별 추적 능력 평가

그림7에서 표적 1과 2는 서로 교차하는 표적으로서 표적이 서로 교차하는 지점을 경계로 하여 추적 궤적이 서로 교차되거나 합병되는 상황을 평가하기 위해서 제안된 시험 패턴으로서, 시뮬레이션 결과는 그림 8과 9에 나타냈다. 그림에 나타낸 값은 식(37)에 의하여 계산된 값중에서 X축의 상태변수에 대한 위치 및 속도

오차를 나타냈다. 제안한 알고리즘이 기존의 JPDA 알고리즘과 비교시 추적 성능 면에서 15%이상 더 정밀함을 알 수 있다. 그림7에서 표적 3과 4는 평행 이동하는 두 개의 표적이 다중 표적알고리즘에 미치는 영향을 보기 위해 제안된 시험 패턴으로서 시뮬레이션 결과를 그림 10과 11에 나타냈다.

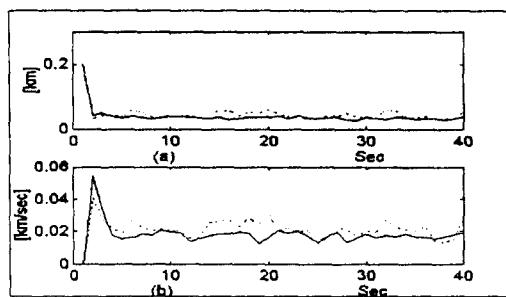


그림 8. 표적 1의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법  
Fig. 8. RMS error in X axis of target 1.  
— : Proposed —··· : JPDA

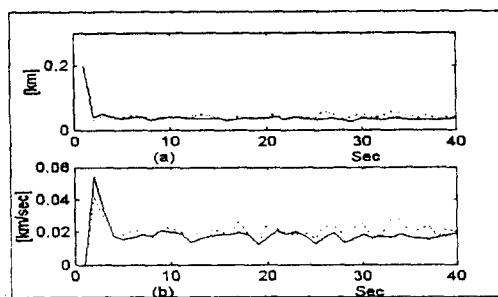


그림 9. 표적 2의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법  
Fig. 9. RMS error in X axis of target 2.  
— : Proposed —··· : JPDA

그림에서 보는 것과 같이 JPDA방법은 일정한 바이어스를 갖고서(그림 10) 추적하는 것이 되므로 제안한 알고리즘보다 오차가 커짐을 확인할 수 있다. 그림 7에서 표적 8은 DogLeg기동을 하는 표적으로서 기동 시작시간까지 등속 직선 운동하여, 기동시작시간에서부터 주어진 크기의 기동가속도로 원운동 형태의 회전기동을 하고 기동이 끝나면 다시 등속 직선 운동을 하는 방식의 시험 패턴이다(기동 시작시간 : 15초). 그림 15에 나타낸 시험 결과에서와 같이 JPDA방법은 기동이 시작되면 추적을 상실하나 제안한 알고리즘은 추적을

유지함을 볼 수 있다. 그림 7에서 표적 9는 등가속 기동을 하는 표적으로서 주어진 기동 시작 시간에서 기동 종료 시간까지 주어진 가속도로 등가속도 운동하는 표적이다. 그림 16에 나타난 시험 결과를 보면 JPDA 와 제안한 알고리즘 모두 추적을 유지함을 알 수 있으나 제안한 알고리즘이 JPDA방법보다 추적 정확도가 8%이상 높음을 알 수 있다.

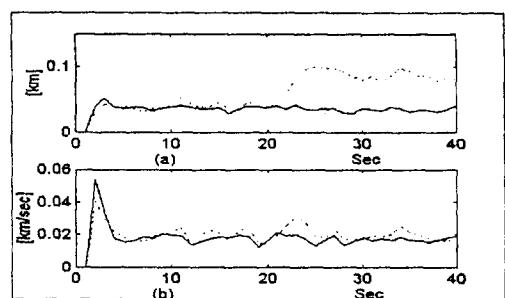


그림 10. 표적 3의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법  
Fig. 10. RMS error in X axis of target 3.  
— : Proposed —··· : JPDA

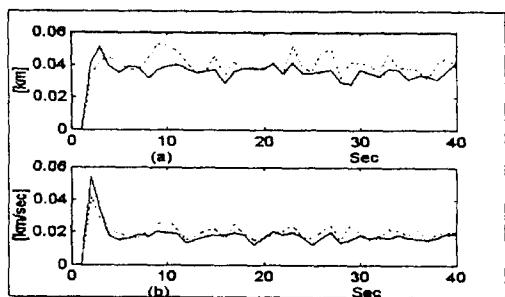


그림 11. 표적 4의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법  
Fig. 11. RMS error in X axis of target 4.  
— : Proposed —··· : JPDA

그림 7에서 5,6,10표적은 임의의 표적이 기존의 제안된 패턴에 영향을 주면서 추적 유지가 가능함을 알기 위해서 고안한 시험 패턴들로서 시험 결과를 그림 12,13,17에 나타냈다.

그림 18은 10개의 표적에 대한 JPDA와 제안한 알고리즘에 대한 샘플 실행(Sample Run)에 대한 표본 예를 보인 것이고, 표 2에 JPDA와 제안된 알고리즘에 대한 40회 몬테 카를로 시험 결과를 식(36)으로 계산한 값을 나타냈다.

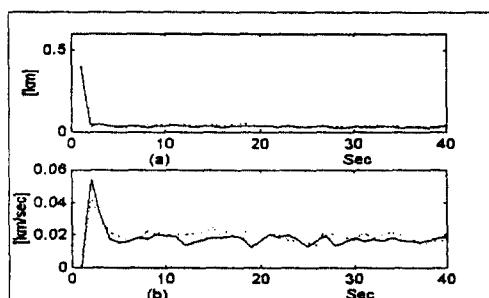


그림 12. 표적 5의 X축 RMS오차

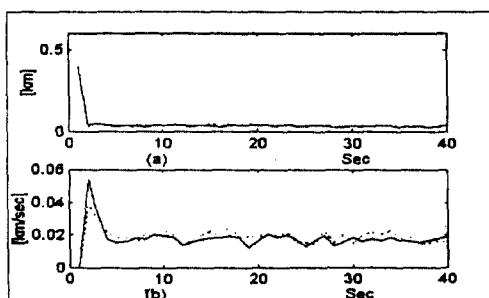
(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법Fig. 12. RMS error in X axis of target 5.  
— : Proposed —··· : JPDA

그림 13. 표적 6의 X축 RMS오차

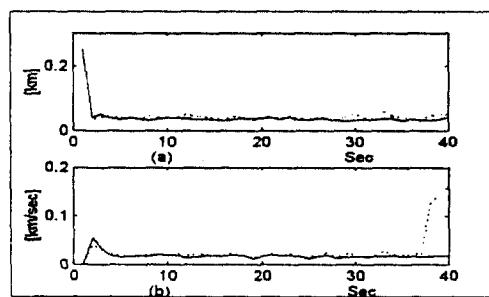
(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법Fig. 13. RMS error in X axis of target 6.  
— : Proposed —··· : JPDA

그림 14. 표적 7의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안한 방법 —··· : JPDA 방법Fig. 14. RMS error in X axis of target 7.  
— : Proposed —··· : JPDA

## V. 결 론

다중 표적 추적의 데이터 결합문제를 해결하기 위한

새로운 기술인 신경망(Neural Net)을 이용하여 다중 표적의 데이터 결합문제를 풀기 위한 시도를 하여 보았다.

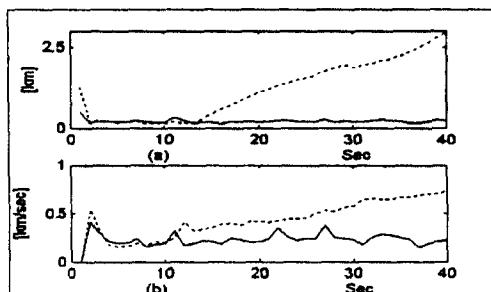


그림 15. 표적 8의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차

— : 제안한 방법 —··· : JPDA 방법

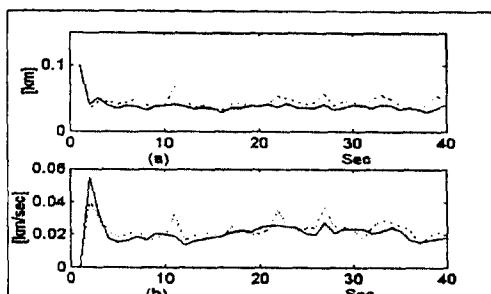
Fig. 15. RMS error in X axis of target 8.  
— : Proposed —··· : JPDA

그림 16. 표적 9의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차

— : 제안한 방법 —··· : JPDA 방법

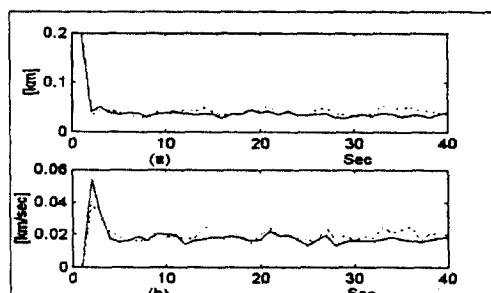
Fig. 16. RMS error in X axis of target 9.  
— : Proposed —··· : JPDA

그림 17. 표적 10의 X축 RMS오차

(a) X축 위치 오차 (b) X축 속도 오차

— : 제안한 방법 —··· : JPDA 방법

Fig. 17. RMS error in X axis of target 10.  
— : Proposed —··· : JPDA

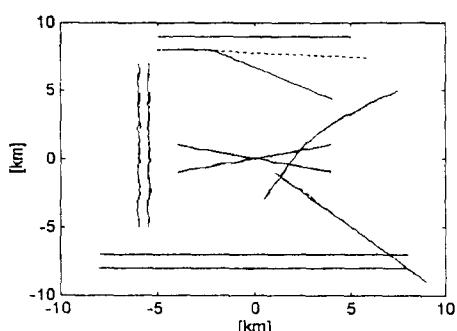


그림 18. 10개의 표적에 대한 다중 표적 추적 결과  
(a) X축 위치 오차 (b) X축 속도 오차  
— : 제안 필터의 추정값 - - - : JPDA 추정값

Fig. 18. Tracking performance against the 10 targets.

— : Estimation value of proposed algorithm  
- - - : JPDA

표 2. 제안 알고리즘과 JPDA 알고리즘과 성능 비교

Table 2. Performance comparison between JPDA algorithm and proposed one.

상호 표적	X 위치(km)		Y 위치(km)		X 속도(km/s)		Y 속도(km/s)		추적 성공률[%]	
	제안 알고리즘	JPDA	제안 알고리즘	JPDA	제안 알고리즘	JPDA	제안 알고리즘	JPDA	제안 알고리즘	JPDA
1	1.837	1.614	0.706	0.656	0.834	0.734	1.949	0.001	95	100
2	1.889	1.613	0.887	0.856	0.861	0.733	0.854	0.001	95	100
3	2.425	1.496	0.304	0.315	0.810	0.734	0.036	0.001	100	100
4	1.581	1.416	0.829	0.315	0.844	0.734	0.911	0.001	92.5	100
5	1.950	1.812	0.412	0.001	0.804	0.732	1.880	0.001	85	100
6	1.931	1.813	0.410	0.001	0.758	0.733	0.009	0.001	100	100
7	1.866	1.661	0.429	0.001	1.188	0.723	0.073	1.221	90	100
8	9.660		15.12		1.235	11.74	3.068		52.5	
9	1.255	1.646	0.688	0.210	0.919	0.561	0.189	0.001	80	95.5
10	1.751	1.611	0.635	0.208	0.791	0.735	0.227	0.001	100	95.5

본 논문에서 제안한 방법을 사용시 기존의 Bar-Shalom의 방법보다 다중 표적에 대한 추적 성공률은 기동 표적, 교차표적, 평행 표적에 대해 각각 50%, 5%, 4% 우수하였으며, 추적 정확도는 JPDA보다 10%이상 제안한 알고리즘이 우수함을 확인하였다. 또한 제안한 알고리즘의 구현시 병렬처리등의 용이함을 이용하면 표적 밀도가 높은 상황하에서 운용 가능한 실시간 다중 표적 추적 시스템 구성이 가능하리라 예상된다.

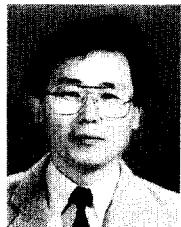
상된다.

## 참 고 문 헌

- [11] D. B. Reid, "An algorithm for tracking multiple targets," *IEEE Trans. on Automat. Contr.*, vol. 24, pp. 843-854, Dec. 1979.
- [12] 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.
- [13] D. L. Alspach, "A Gaussian sum approach to multi-target identification tracking problem," *Automatica*, vol. 11, pp. 285-296, May 1975.
- [14] Sengupta,D., and Iltis, R.A., "Neural solution to the multitarget tracking data association problem," *IEEE Trans. on AES*, AES 25, , pp. 96-108, Jan. 1989.
- [15] Kuczewski,R., "Neural network approaches to multitarget tracking," In proceedings of the IEEE ICNN conference, 1987.
- [16] P. Smith and G. Bucheler, "A Branching algorithm for discriminating and tracking multiple objects," *IEEE Trans. Automat. Contr.*, vol. AC-20, pp. 101-104, Feb. 1975.
- [17] Hopfield, J.J., and Tank, D.W., "Neural computation of decisions in optimization problems," *Biological Cybernetics*, pp. 141-152, 1985.
- [18] Hopfield, J.J., "Neural networks and physical systems with emergent collective computational abilities," In proceedings of the National Academy of Science, 79, pp. 2554-2558, 1982.
- [19] A. Cichocki and R. Unbenhauen, 'Neural networks for optimization and signal processing,' Wiley, New York, p. 526, 1993.
- [20] 이 양원, 서 진현, 이 장규, "다중 표적 추적을 위한 TWS 추적 필터에 관한 연구," 대한 전기학회 논문지, 제 41권, 4호, pp. 411-421, 1992
- [21] 이 양원, 정 흥, "다중 표적 추적을 위한 데이터 결합 에너지 함수의 최적화 방법 연구," 국방과

- 학연구소 제4차 유도 무기 학술회의 논문집, pp. 365-370, 1994
- [12] Emile Aarts and Jan Korst, 'Simulated annealing and Boltzmann Machines,' Wily, New York, pp. 275, 1989.
- [13] Y. Takefuji, and K.C. Lee, "Artifical Neural Networks for Four-coloring Map Problems and K-Colorability Problems," *IEEE Trans. on Circuits and Systems*, vol. 38, No. 3, pp. 326-333, Mar. 1991.

## 저자 소개



李陽源(正會員)

1958년 12월 12일생. 1982년 중앙대 공대 전자공학과 졸업. 1991년 서울대 공대 대학원 제어계측공학과 졸업(석사). 1996년 포항공대 전자공학과 대학원 박사과정 수료. 1982년 ~ 1995년 국방과학연구소 석ím연구원. 현재 호남대 공대 정보통신공학과 전임강사



丁弘(正會員)

1953년 5월 16일생. 1977년 서울대 공대 전기공학과 졸업. 1979년 한국과학원 전기 및 전자 공학과 졸업(석사). 1984년 M.I.T. 전기 전산학과 (S.M.) 1986년 M.I.T. 전기 전산학과(E.E.) 1988년 M.I.T. 전기 전산학과(Ph.D) 1988년 ~ 현재 포항공과대학교 전자전기공학과 부교수