

클러터 환경에서 Track Coalescence & Switch 감소를 위한 JPDA 기법연구

A Study of JPDA(Joint Probabilistic Data Association) to Decrease Track Coalescence & Switch in a Cluttered Environments

송 대 범*

Dae-Buem Song

Abstract

Data association is important technology which designate final destination in the target tracking. The joint probabilistic data association(JPDA) algorithm provides excellent ability to maintain track on multiple targets. Currently, it is not easily implemented in real time because of track coalescence & switch. The aim of this paper is to develop probabilistic filters that increase JPDA's sensitivity and decrease track coalescence & switch in a cluttered environments

Keywords : Joint Probabilistic Data Association(JPDA), Clutter Reduction(클러터 제거), Target Tracking(표적 추적), Multiple Target(다중 표적)

1. 서 론

표적이 단수가 아닌 다수 표적일 경우, 표적끼리 서로 겹치게 되는 현상이 발생되어 트랙(track)을 놓치게 되는 경우가 발생될 수 있다. 또한, 클러터(Clutter)정보를 탐지하는 과정에서 잘 처리한다 하더라도 완벽히 걸러지지 않기 때문에 자료결합(Data Association)기법을 필수적으로 사용해야 한다^[1~3]. 탐지된 표적들을 추적하기 위해서 필요한 자료결합의 형태는 크게 2가지 방법으로 나눌 수 있다. 첫 번째는 일대일로 자료결합

하는 형태로 'Nearest Neighbor', 'Strongest Neighbor' 방식과 같이 하나의 트랙에 하나의 측정치를 연관시키는 방법이 있다. 두 번째는 JPDA와 같은 'all-neighbor' 방식이 있다.

일대일 자료결합 방식의 장점은 계산량이 적고, 단순한 구조를 가지고 있다는 것이고, 단점은 클러터를 추정치로 단정할 경우 필터가 발산하는 현상이 일어날 수 있다는 것이다. 'all-neighbor' 방식은 계산량은 많지만 성능이 우수한 것으로 알려져 있다. 본 논문에서는 JPDA를 응용한 방법으로 추적기법에 적용할 새로운 자료결합 방법을 연구하였다.

JPDA를 사용하기 위해서는 몇 가지 문제점을 해결해야 한다. 첫 번째는 계산량이고^[4,5], 두 번째는 트랙이 서로 겹치는 'track coalescence'와 'track switch'

† 2012년 2월 3일 접수~2012년 4월 20일 게재승인

* 국방과학연구소(ADD)

책임저자 : 송대범(song@add.re.kr)

문제이다^[7~9]. 본 논문은 ‘track coalescence & switch’에 대해서 고찰하고 시뮬레이션을 통해 새로운 접근법을 제안한다. 또한, 기존의 방법과 비교하여 ‘track coalescence & switch’ 발생 확률을 낮추는데 연구의 초점을 두었다. JPDA 기법에서 VG(Validation Gate)을 판단하는 게이트의 사이즈 조절과 연관확률 값 조정으로 보다 안정적인 JPDA 방법을 제시한다. Adaptive JPDA라 지칭한 이 방법은 향후 복잡한 추적환경에서 사용될 예정이다.

2. JPDA(Joint Probabilistic Data Association)

가. JPDA 알고리즘

JPDA는 이미 제적이 개시된 ‘T’개의 기존의 제적이 존재한다고 가정하고 자료결합을 수행하게 되는데 이때 최근의 측정치는 기존의 제적과 연관될 확률을 계산하게 된다. JPDA의 핵심은 표적에 대한 상태추정은 동일하게 수행하면서 측정치의 표적에 대한 연관확률은 다른 방법으로 구하는 것이다. JPDA의 알고리즘을 요약하면 Fig. 1, Table 2, 3과 같다.

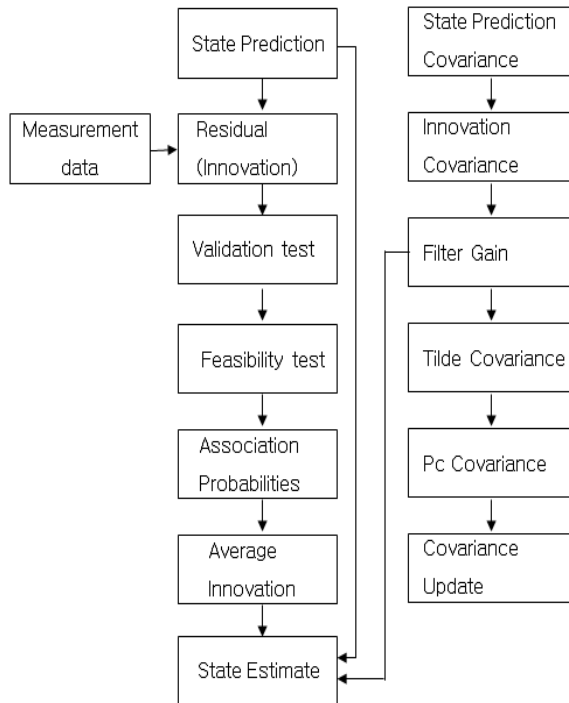


Fig. 1. JPDA Algorithm

Table 1. State estimation for JPDA

순서	내용	수식
1	State estimated at 'k'	$x_j(k k)$
2	State prediction for 'k+1'	$x_j(k+1 k) = F(k)x_j(k k)$
3	Measurement prediction	$z_j(k+1 k) = H(k+1)x_j(k+1 k)$
4	Innovation (residual)	$\nu_{jt}(k+1) = z_t(k+1) - z_j(k+1 k)$
5	Validation test	$z_{jv} = \{z_t(k+1) : \nu_{jt}(k+1)S^{-1}\nu_{jt}(k+1) \leq \gamma\}$
6	Validation matrix	$\Omega = [\omega_{jt}] \quad t = 1, \dots, M, \quad j = 0, 1, \dots, T$
7	Feasibility test	$\theta = \bigcap_{j=1}^{m_k} \theta_{jt}, \quad \hat{\Omega}(\theta) = [\hat{\omega}_{jt}(\theta)]$
8	Association probabilities	$\beta_{jt} = \sum_{\theta} P\{\theta Z^k\} \hat{\omega}_{jt}(\theta)$
9	Average Innovation	$\nu_j(k+1) = \sum_{t=1}^m \beta_{jt}(k+1)\nu_{jt}(k+1)$
10	State estimate	$x_j(k+1 k+1) = x_j(k+1 k) + W(k+1)\nu_j(k+1)$

Table 2. State covariance computation for JPDA

순서	내용	수식
1	State prediction covariance	$P(k+1 k) = F(k)P(k k)F'(k) + Q(k)$
2	Innovation covariance	$S(k+1) = H(k+1)P(k+1 k)H'(k+1) + R(k+1)$
3	Filter gain	$W(k+1) = P(k+1 k)H'(k+1)S^{-1}(k+1)$
4	Covariance update #1	$\tilde{P}(k+1 k+1) = W(k+1) \left[\sum_{t=1}^m \beta_{jt}(k+1)\nu_{jt}\nu'_{jt} - \nu_{jt}\nu'_{jt} \right] W'(k+1)$
5	Covariance update #2	$P_C(k+1 k+1) = [I - W(k+1)H(k+1)]P(k+1 k)$
6	Covariance update #3	$P(k+1 k+1) = \beta_0(k+1)P(k+1 k) + [I - \beta_0(k+1)]P_C(k+1 k+1) + \tilde{P}(k+1 k+1)$

나. JPDA 특징

1) 계산량증가

JPDA 알고리즘은 모든 측정데이터에 다중 표적들이 서로 결합되어 발생 가능한 모든 연관 가능성을 고려해야 하므로 표적과 클러터를 포함한 측정 데이터가 증가하면 할수록 계산량은 기하급수적으로 증가한다. 수식으로 표현하면 다음과 같다.

$$1 + \sum_{k=0}^{T-1} \binom{T}{k} \left[\prod_{i=0}^{T-1-k} (m-i) \right] = \sum_{k=0}^{T-1} \frac{T!m!}{k!(T-k)!(m-T+k)!} \quad (1)$$

여기서 m 은 측정치 수, T 는 표적수를 나타낸다.

2) track coalescence & switch

트랙이 서로 겹치는 track coalescence와 트랙이 서로 바뀌는 track switch는 근본적으로 동일한 문제로 취급한다. track coalescence & switch가 발생하는 이유는 JPDA의 핵심인 연관확률이 잘 반영되고 있다는 것을 역으로 증명하는 것이다. 즉, JPDA의 가장 큰 특징인 VG 내의 모든 측정치를 고려하여 all-neighbor 방식을 충실히 따른 결과이다.

3. JPDA 응용

JPDA의 우수한 성능에도 불구하고 앞에서 언급했듯이 계산량과 ‘track coalescence & switch’ 문제로 실제 시스템에 적용하기 위해서는 많은 최적화 작업이 필요하다. 본 논문에서는 ‘track coalescence & switch’ 문제에 국한하였기 때문에 ‘Cheap JPDA’, ‘Suboptimal JPDA’, ‘NNJPDA’, ‘JPDA*’에 대해서 알아본다.

가. Cheap JPDA

트랙이 2개 이상일 때 JPDA는 성능은 우수하지만 처리과정은 매우 복잡해진다. ‘Fitzgerald’는 JPDA 확률계산의 ‘ad hoc approximation’을 제안했는데, 이것을 Cheap JPDA라고 부른다^[9]. 자세한 과정은 다음과 같다.

트랙 ‘ t ’, 측정치 ‘ j ’와 연관될 확률 β_{tj} 는 Cheap JPDA에서 다음과 같이 개략화 될 수 있다.

$$\beta_{tj} = \frac{A_{tj}}{T_t + M_j - A_{tj} + B} \quad (2)$$

T_t 는 target ‘ t ’에 대한 likelihoods 합이다. $T_t = \sum_{j=1}^m A_{tj}$

M_j 는 측정치 ‘ j ’에 대한 likelihoods 합이다. $M_j = \sum_{t=1}^N A_{tj}$

B 는 bias 이다. 이것은 클러터가 존재하고 탐지확률 $P_D \neq 1$ 임을 의미한다.

식 (2)에서 트랙 ‘ t ’가 측정치 ‘ j ’와 더불어 다른 유효한 측정치를 동시에 가진다면 T_t 는 연관확률(β_{tj})을 줄이게 된다. 마찬가지로, 측정치 ‘ j ’가 트랙 ‘ t ’뿐만 아니라 다른 트랙에 의해서 유효화 될 때 M_j 는 연관확률(β_{tj})을 줄이게 된다.

식 (2)는 하나의 표적에 여러 개의 측정치, 하나의 측정치에 여러 개의 표적의 대칭 형태로 표현함으로써 연관확률을 간단하게 표현됨을 의미한다. 하나의 표적이 하나의 유효한 측정치일 때, 즉, 이 측정치가 다른 트랙에 기인한 것이 아닌 경우 Cheap JPDA에서 결합 확률은 매우 큰 값을 가지게 된다. 한편, ‘ B ’값이 분모에 있는 이유는 측정치가 클러터 이거나 원래의 트랙으로부터 기인한 것이 아닌 경우를 반영하기 위함이다. Cheap JPDA의 핵심은 트랙이 겹치는 부분이 발생하는 다중표적 추적의 경우, 결합 확률이 줄어들게 된다는 것이다. 이것은 증가된 측정치의 모호성을 반영한 것이라고 할 수 있다.

‘Fitzgerald’는 트랙 ‘ t ’로부터 어떤 측정치도 연관되지 않을 확률에 대해서는 언급하지 않았는데, [10]에서 ‘Blair’는 다음과 같이 β_{t0} 을 제시했다.

$$\beta_{t0} = \frac{B}{T_t + B} \quad (3)$$

‘ N ’ 개의 트랙, ‘ N ’ 개의 측정치가 존재할 때

incorrect answer : $\beta_{tj} = 1/(2N-1)$

correct answer : $\beta_{tj} = 1/N$

Fig. 2와 같이 트랙이 2개이고, 측정치가 3개인 경우를 예를 들어보자. 이때 2번째 측정치는 트랙 1, 2 둘 다 영향을 미친다.

측정치와 트랙에 대한 likelihood 함수로 표현하면 다음과 같다.




Fig. 2. 2-track, 3-measurement

$$M_1 = A_{11} \quad , \quad M_2 = A_{12} + A_{22} \quad , \quad M_3 = A_{23}$$

$$T_1 = A_{11} + A_{12} \quad , \quad T_2 = A_{22} + A_{23}$$

한편, ‘측정치3’과 ‘표적1’은 연관이 없으므로 다음과 같이 표현된다. $A_{13} = A_{21} = 0$.

‘표적1’에 대한 식 (2)과 (3)은 다음과 같이 구해진다.

$$\beta_{10} = \frac{B}{T_1 + B} = \frac{B}{A_{11} + A_{12} + B}$$

$$\beta_{11} = \frac{A_{11}}{T_1 + M_1 - A_{11} + B} = \frac{A_{11}}{A_{11} + A_{12} + B}$$

$$\beta_{12} = \frac{A_{12}}{T_1 + M_2 - A_{12} + B} = \frac{A_{12}}{A_{11} + A_{12} + A_{22} + B}$$

$$\beta_{13} = \frac{A_{13}}{T_1 + M_3 - A_{13} + B} = 0$$

β_{tj} 을 계산하는데 있어서 JPDA는 다음과 같은 4가지 경우를 고려한다.

- ① 측정치 ‘j’가 표적 ‘t’와 결합되는 경우
- ② 측정치 ‘j’가 표적 ‘t’를 제외하고 결합되는 경우
- ③ 표적 ‘t’가 측정치 ‘j’와 결합되는 경우
- ④ 표적 ‘t’가 측정치 ‘j’를 제외하고 결합되는 경우

그러나, Cheap JPDA는 4번째 경우를 제외하게 된다.

식 (2)에서 β_{tj} 의 물리적인 의미를 살펴보면, 분자는 표적 ‘t’가 측정치 ‘j’에 연관되는 likelihood 함수 A_{tj} 이다. 분모의 구성은 다음과 같다.

(T_t : target ‘t’에 대한 likelihoods 합) + (M_j : 측정치 ‘j’에 대한 likelihoods 합)

분모에 A_{tj} 가 두 번 계산되므로 한번 빼줘야 한다. ‘B’는 bias를 의미하는데, 클러스터를 중요하게 취급되는 환경에서 클러스터 density map에 따라서 ‘B’를 변동시

키는 것보다 고정시키는 것이 더 좋다고 언급되고 있다. 한편 false track을 제거하고 부정적인 영향을 미치는 요소를 감소시키기 위해서 다양한 환경에서 전산 모사 시험을 할 필요가 있고 이런 방법으로 ‘B’를 선정할 수 있다^[9].

Cheap JPDA와 JPDA는 비슷한 계산량을 가진다. 수식적으로 Cheap JPDA와 JPDAF와의 차이점은 weighted average updating을 제외하고 모두 동일하다.

나. Suboptimal JPDA

Cheap JPDA보다 계산량은 많지만 더 정확한 확률 계산을 제공하는 Suboptimal JPDA를 [6]에서 Roecker가 제안하였다. 두 가지 기본 가정이 필요하다.

- ① $P_D^t \approx 1$: 모든 표적은 탐지 된다.
- ② 모든 joint events는 클러스터에 할당되는 동일한 수의 측정치를 가진다.

위의 두 가지 가정을 바탕으로 Suboptimal JPDA는 ‘partial joint events’ 개념을 도입한다. ‘two-track-to-measurement pairings’하는 것으로 두개의 single events를 구성하게 된다. 그런 다음 아래 과정으로 계산된다.

- ① 각 트랙 ‘t’에 대해서 A_t 을 생성한다. 여기서 A_t 는 트랙 ‘t’에 대한 유효측정치 index들의 리스트를 의미한다.
- ② 각 측정치 ‘j’에 대해서 C_j 를 생성한다. 여기서 C_j 는 측정치 ‘j’를 유효화시키는 트랙 ‘t’ index들의 리스트이다.
- ③ 트랙 index 리스트 $L_t = \bigcup_{j \in A_t} C_j - \{t\}$.

각 트랙 ‘t’에 대해서 모든 측정치로부터 모든 트랙 index들의 합을 형성한다.

여기서, 측정치는 트랙 ‘t’의 index는 제외하고 트랙 ‘t’에 의해서 유효화 된 측정치를 의미한다.

- ④ 연관확률은 다음과 같다.

$$\beta_{tj} = \frac{D_{tj}}{B + \sum_{l \in A_t} D_{tl}} \tag{4}$$

여기서 ‘B’는 bias이며, Cheap JPDA의 B와 동일하다.

$$D_{tj} = \begin{cases} A_{tj} & \text{if } L_t = \phi \\ A_{tj} \sum_{s \in L_t} N_{sj} & \text{if } L_t \neq \phi \end{cases}$$

$N_{sj} = \max_{k \in A_s, k \neq j} \{A_{sk}\}$, ϕ 는 empty set을 의미함.

한편, 트랙 't'로부터 no measurement origin 확률은 수식 (5)와 같다.

$$\beta_{t0} = \frac{B}{B + \sum_{l \in A_t} D_{tl}} \quad (5)$$

Suboptimal JPDA의 특징은 다음과 같다.

- ① Cheap JPDA처럼 Suboptimal JPDA도 one target & multiple measurement 경우에 대해서 correct 확률을 제공한다.
- ② 2-표적 2-측정치의 경우, suboptimal JPDA는 correct probability를 제공한다.
- ③ N-표적 N-측정치의 경우, suboptimal JPDA의 연관 확률 $\beta_{jt} = \frac{1}{N}$ 임
- ④ Cheap JPDA는 “트랙 't'가 측정치 'j'를 제외하고 결합되는 경우”를 고려하지 않지만, Suboptimal JPDA는 위의 경우를 고려하게 된다.
- ⑤ 주어진 트랙에 대해서 $\sum_j \beta_{tj} = 1$ 을 만족함

Fig. 2의 예를 들어보면, 각 트랙에 대한 유효화 된 측정치 리스트는 아래와 같다.

$$A_1 = \{1, 2\}, A_2 = \{2, 3\}$$

각 측정치에 대한 트랙 유효화 리스트는 아래와 같다.

$$C_1 = \{1\}, C_2 = \{1, 2\}, C_3 = \{3\}$$

$$N_{21} = \max_{k \in A_2, k \neq 1} \{A_{2k}\} = \max\{A_{22}, A_{23}\}$$

$$N_{22} = \max_{k \in A_2, k \neq 2} \{A_{2k}\} = A_{23}$$

$$N_{23} = \max_{k \in A_2, k \neq 3} \{A_{2k}\} = A_{22}$$

$$D_{11} = A_{11} \sum_{s \in L_1} N_{s1} = A_{11} N_{21} = A_{11} \max\{A_{22}, A_{23}\}$$

$$D_{12} = A_{12} \sum_{s \in L_1} N_{s2} = A_{12} N_{22} = A_{12} A_{23}$$

$$D_{13} = A_{12} \sum_{s \in L_1} N_{s3} = A_{13} N_{23} = A_{12} A_{22} = 0$$

$$(\because A_{13} = 0, D_{13} = 0)$$

트랙 1에 대해서 β_{t0}, β_{tj} 는 다음과 같이 구해진다.

$$\beta_{10} = \frac{B}{B + \sum_{l \in A_1} D_{1l}} = \frac{B}{A_{11} \max\{A_{22}, A_{23}\} + A_{12} A_{23} + B}$$

$$\beta_{11} = \frac{D_{11}}{B + \sum_{l \in A_1} D_{1l}} = \frac{A_{11} \max\{A_{22}, A_{23}\}}{A_{11} \max\{A_{22}, A_{23}\} + A_{12} A_{23} + B}$$

$$\beta_{12} = \frac{D_{12}}{B + \sum_{l \in A_1} D_{1l}} = \frac{A_{12} A_{23}}{A_{11} \max\{A_{22}, A_{23}\} + A_{12} A_{23} + B}$$

$$\beta_{13} = \frac{D_{13}}{B + \sum_{l \in A_1} D_{1l}} = 0$$

다. NNJPDA

JPDAF, Cheap JPDA, suboptimal JPDA, 3개 모두다 트랙 VG 내에 있는 모든 측정치들의 weighted average를 사용한다. [8], [9]에서 ‘Fitzgerald’는 표적이 근접할 때, 표적이 다른 표적에 영향을 주어서, ‘track bias’나 ‘track coalescence’를 일으킨다고 적고 있다. 또한, 표적 트랙이 1.5 residual standard deviation보다 작은 거리일 때 표적들 중심이 합체될 수 있다고 언급하면서, 매우 복잡한 환경에서 JPDA와 같은 어려운 방법 대신에 간단한 방법을 제안하였다. 즉, weighted average updating을 버리고 ‘트랙-측정치’를 1대1로 매칭시키는 방법을 고안했다.

NNJPDA라 불리는 이방법은 연관확률(β_{tj})를 계산하는 복잡함을 제거하므로 알고리즘 단순화 시켰다. NN 방법과 차이점은 Table 3과 같다.

Table 3. The difference between NN and NNJPDA

DA 방법	판단 data
NN(Nearest Neighbor)	normalized distance 중 최소값
NNJPDA	association probabilities 중 최대값

JPDA와 차이점은 Table 1의 8번 수식에서 구한값을

$$\left(\beta_{jt} \cong p\{\theta_{jt}|Z^k\} = \sum_{\theta} p\{\theta|Z^k\} \hat{\omega}_{jt}(\theta), j=1, \dots, m_k, t=0, 1, \dots, T \right)$$

서로 비교하여 최대값을 찾아내는 것만 다르고 나머지는 JPDA와 동일한 알고리즘으로 계산된다. 연관될 확률이 큰 경우 상당한 계산절감 효과가 있지만 중첩되는 경우가 많이 없고 표적의 수가 적을 때는 JPDA와 크게 차이가 나지 않는다.

NNJPDA의 특징은 다음과 같다.

- ① β_{tj} 는 '1'보다 작기 때문에 β_{tj} 가 '0.5'보다 크면 무조건 그 값을 선택
- ② 문턱값 지정가능. $\beta_{tj} <$ 문턱값이면 측정치는 할당 안됨
- ③ 할당되지 않은 측정치는 임시 트랙을 형성하는데 사용 될 수 있다.

라. JPDA*

'Blom'은 'Hypothesis Pruning'을 통해서 추정신호의 조합 중 확률이 낮은 것들을 지우는 방법을 적용했다^[7]. 이 방법은 'track coalescence'의 확률을 낮추는데 효과는 있지만 $\sum_j \beta_{tj} = 1$ 이므로 겹치는 구간에서 한계가 있다. 이 기법에서 표적이 겹칠 때 표적의 상대속도에 영향이 많이 받는 것을 알 수 있다. $V^{norm} \approx 2$ 이면 일반적인 JPDA의 'track coalescence' 확률은 20~25 % 정도이다. 4장의 시뮬레이션에서 구한 JPDA*의 'track coalescence'는 'pruning' 확률을 0.1%~30 %까지 변화시키면서 구한 최적의 값이다. pruning 최적 문턱값 설정시 연관확률은 '0.2~0.3'이다.

마. Adaptive JPDA

기존 JPDA의 'track coalescence' 단점을 극복하기 위해서 4가지(Cheap JPDA, Suboptimal JPDA, NNJPDA, JPDA*) 방안에 대해서 살펴보았다. 본 논문에서는 제안한 방법은 표적이 겹치는 부분을 판단해서 게이트 사이즈를 조절하고 여기에 연관확률을 조절함으로써 'track coalescence & switch'를 낮추는 방법이다. 세부 알고리즘은 다음과 같다.

- ① 표적간 거리가 $9\sigma_m$ 이하가 되면 겹침으로 판단한다.
- ② 게이트 사이즈는 $\gamma = 0.2 \text{ mrad}^2 \times S^{-1/n}$ 으로 설정. 'n'값은 3으로 정함 ('n'값은 표적의 복잡성 유무와 관련이 있는데 3-표적 6-측정치 일 때 3으로 선정)
- ③ 연관확률값 β_{tj} 는 $\beta_{tj} = 1/N_c$ 로 설정된다. (여기서 N_c 는 특정시간에 트랙이 겹치는 경우의 수를 의미)
- ④ 표적간 거리가 $9\sigma_m$ 이상이면 게이트 사이즈와 연관확률값을 원래대로 복구시킨다.

Adaptive JPDA의 특징은 다음과 같다.

- ① Cheap JPDA와 틀리게 표적 't'가 측정치 'j'를 제외하고 결합되는 경우를 고려한다.
- ② Suboptimal JPDA와 차이는 $\sum_j \beta_{tj} \neq 1$ 와 VG를 변화시키는 것이다.
- ③ NNJPDA와 차이는 1대1 대응이 아닌 JPDA의 기본 알고리즘을 따른다.
- ④ JPDA*와 차이는 $\sum_j \beta_{tj} \neq 1$ 와 VG가 변화하는 것이다.

4. 시뮬레이션

가. 시뮬레이션 조건

JPDA의 다중탐지를 모사하기 위해서 다음과 같은 시뮬레이션 환경을 구축한다. 탐지 될 수 있는 실제 표적은 '3개'로 설정하고 클러스터를 포함했을 경우 최대 탐지 개수를 '6개'로 정하였다. 총 관찰시간은 '300 초'를 기준으로 했으며, 이 경우 '229개'의 feasibility 행렬을 생성해야 한다. 운동방정식과 측정방정식은 일반적인 등속도이고, 측정치 잡음은 '0.017 deg'로 설정했다. 탐지 확률은 '0.85', False alarm은 '0.3'으로 정했다^[1~3]. Monte Carlo 회수의 경우 JPDA는 100회, 나머지는 1000회 수행했는데 이는 'track coalescence & switch'를 좀 더 정확히 파악하기 위함이다. VG 값 설정은 자료결합의 최종 목표치를 반영하기 위해서 정했다. 근접판단 기준은 state estimated value값을 고려해서 약 '9 · σ_m '을 기준으로 만들었다. 여기서 ' σ_m '은 측정치의 표준편차 에러를 나타낸다. 상세한 시뮬레이션 변수는 Table 4와 같다.

Table 4. Simulation parameters

순번	제목	수치
1	표적수	3
2	최대 동시탐지 수	6
3	총 관찰시간	300 sec
4	자료결합 생성수	229
5	Motion matrix	$F = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}$
6	Motion noise matrix	$G = \begin{bmatrix} T^2/2 \\ T \end{bmatrix}$
7	Covariance of motion noise	$Q = \begin{bmatrix} T^4/4 & T^3/3 \\ T^3/3 & T^2 \end{bmatrix}$
8	Measurement matrix	$H = [1 \ 0]$
9	Measurement noise matrix	$K = 0.017$
10	Covariance of Measurement noises	$R = 0.017^2$
11	Detection probabilities	$Pd(1) = 0.85, Pd(2) = 0.85, Pd(3) = 0.85$
12	False alarm probability	$Pf = 0.3$
13	Monte Carlo	100~1000회
14	Validation test values	$\gamma = 0.2 \text{ mrad}^2 \times S^{-1}$
15	Validation test 값 변경	$\gamma = 0.2 \text{ mrad}^2 \times S^{-1}/n$
16	표적 1	$\begin{bmatrix} 6 \\ -0.02 \end{bmatrix} \begin{bmatrix} \text{deg} \\ \text{deg/s} \end{bmatrix}$
17	표적 2	$\begin{bmatrix} 0 \\ 0.02 \end{bmatrix} \begin{bmatrix} \text{deg} \\ \text{deg/s} \end{bmatrix}$
18	표적 3	$\begin{bmatrix} 3 \\ 0 \end{bmatrix} \begin{bmatrix} \text{deg} \\ \text{deg/s} \end{bmatrix}$
19	근접판단 기준	state estimated value를 비교

나. 시뮬레이션 결과

시간에 따른 고각의 방향이 등속으로 변화하는 표적을 예를 들어 JPDA 시뮬레이션을 수행하였다. 표적

은 3개이며, 클러터를 발생시키는 실제 JPDA 환경을 구축한 것이다. Fig. 3은 Target 1, 2, 3에 대한 true trajectory이고, Fig. 4는 클러터와 측정치를 함께 나타낸 그림이다. Fig. 3에서 ‘Target 1’은 -0.02 deg/sec의 속도로 하강한다. ‘Target 2’는 0.02 deg/sec의 속도로 상승한다. ‘Target 3’의 상승속도는 ‘0 deg/sec’이다.

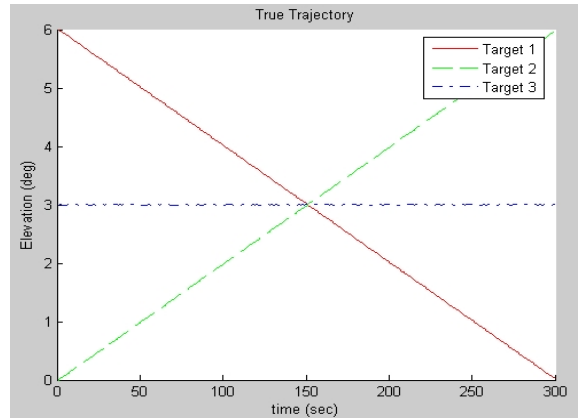


Fig. 3. True trajectory

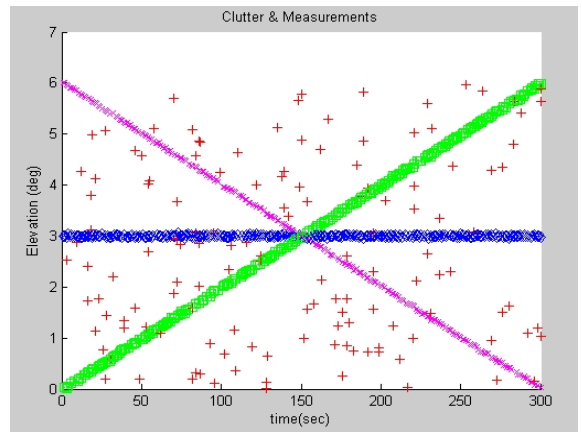


Fig. 4. Clutter and measurement

Fig. 5, 6, 7은 track coalescence가 발생될 때 고각/각속도/RMS error를 나타낸 그림이다.

Fig. 5에서 ‘Filtered 3’가 ‘True 3’과 자료결합 해야 하나 ‘True 2’를 추적하는 것을 알 수 있다. Fig. 6에서 ‘Velocity of True 3’을 ‘Filtered 3’이 추적해야 하나 ‘Velocity of True 2’값을 추종하게 되어 coalescence가 발생됨을 알 수 있다. Fig. 7은 coalescence 발생으로 ‘Target 3’의 RMS error가 증가함을 보여준다.




Fig. 5. Elevation in the event of coalescence

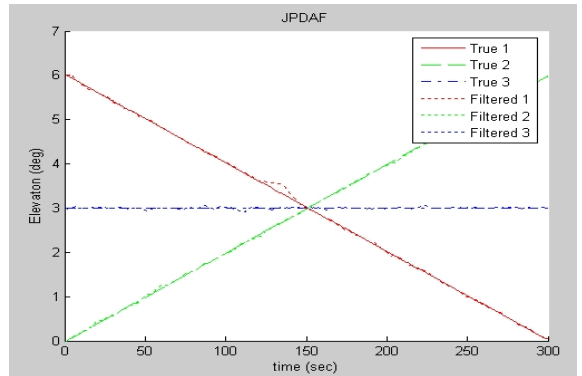


Fig. 8. Target elevation

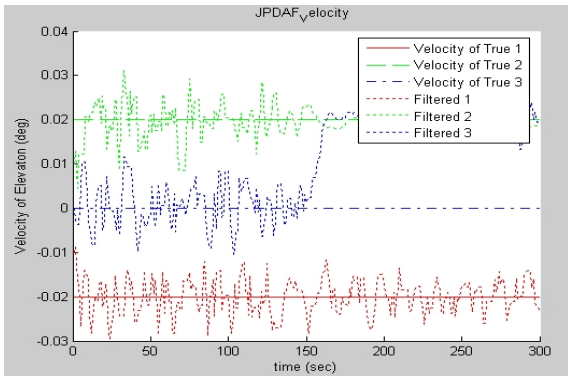


Fig. 6. Angular velocity in the event of coalescence

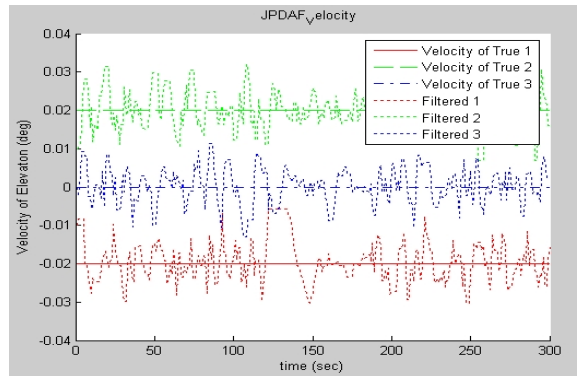


Fig. 9. Target angular velocity

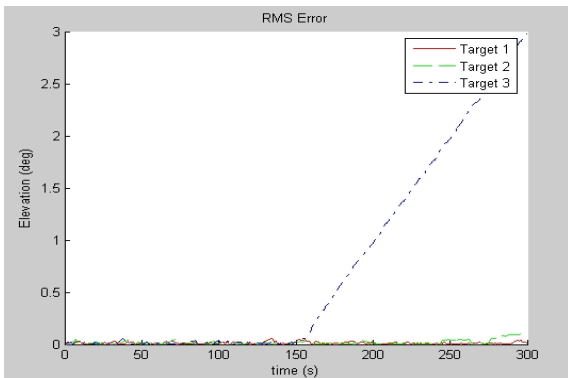


Fig. 7. RMS error in the event of coalescence




Fig. 10. RMS error

Fig. 8, 9, 10은 track coalescence가 발생되지 않고 JPDA가 잘 동작될 때의 예이다. Fig. 8에서 'Filtered 1'이 'True 1'을 추적할 때 130초 부근에서 에러가 조금 증대되는데 이는 Fig. 9 표적 가속도와 Fig. 10 RMS Error에서도 동일하게 증가하는 것을 확인할 수 있다.

문헌에 나온 JPDA 모의 시험중 근접하는 상황에서 트랙이 정상적으로 동작하는 비율이 낮은 것은 56 %의 성공률을 갖는다^[3]. [7]에서 'Blom'이 시험한 값은 75~80 % 정도이다 ($V^{norm} \approx 2$ 기준).

JPDA, JPDA(VG변화), NNJPDA, Adaptive NNJPDA,

JPDA*, Adaptive JPDA*, Adaptive JPDA자료결합 방법에 대한 ‘track coalescence’ 값의 비교는 Table 5와 같다. JPDA 기존 방식에서 VG를 변화시킴으로써 약 15 % 정도 향상됨을 알 수 있다. NNJPDA의 경우 클러터와 missed detections에 의해서 ‘track coalescence’ 확률이 높지만, Adaptive 방법을 이용하여 약 25 % 정도 향상됨을 알 수 있다. [7]에서 ‘Blom’이 제안한 JPDA* 방법도 우수한 편이지만 Adaptive JPDA* 방법 적용시 약 5 % 정도 더 향상되었다. 최종적으로 본 논문에서 제시한 Adaptive JPDA의 ‘track coalescence’ 확률이 5.1 % 수준으로 예측되었다. JPDA 기본성능(missed detections과 클러터에 강함)은 그대로 유지하면서 ‘track coalescence’를 줄일 수 있음을 확인할 수 있다.

Table 5. Comparison of Track coalescence & switch

순번	자료결합	Coalescence & switch 확률	normal-ization
1	JPDA	36.0 %	○
	JPDA (VG 변화)	20.6 %	○
2	NNJPDA	47.4 %	○
	Adaptive NNJPDA	12.8 %	×
3	JPDA*	13.0 %	○
	Adaptive JPDA*	8.0 %	×
4	Adaptive JPDA	5.1 %	×

5. 결론

기존 JPDA기법에서 VG의 크기 및 결합 확률을 조절하는 변형된 형태로서의 Adaptive JPDA방법을 제안하였다. 시뮬레이션에 의한 시험결과 시험조건에 따라 최소 5 %(JPDA* 기법) 최대 25 %(NNJPDA 기법)까지 ‘track coalescence’ 발생 확률을 줄였다. Adaptive JPDA를 이용한 ‘track coalescence’를 감소시키는 방안을 제안한다.

References

- [1] Y. Bar-Shalom, T. E. Formann, “Tracking and Data Association”, Orlando, FL : Academic Press, 1988.
- [2] S. Blackman, and R. Popoli, “Design and Analysis of Modern Tracking Systems”, Norwood, MA : Artech House, 1999.
- [3] Y. Bar-Shalom, “Multitarget Multisensor Tracking : Applications and Advances Volume II”, Artech House, 1992.
- [4] James L. Fisher and David P. Casasent, “Fast JPDA Multitarget Tracking Algorithm”, Applid Optics V28 pp. 371~376, 1988.
- [5] Ming-Hui Wangand Zhi-Sheng You “Improved Joint Probabilistic Data Association Algorithm”, ISIF pp. 1602~1604, 2002.
- [6] J. A.m, Roecker and G. L. Phillis, Suboptimal Joint Probabisistic Data Association, IEEE Trans. Aerospace and Electronic Systems, Vol. 29, No. 2, pp. 510~517, April. 1993.
- [7] Henk A. P. Blom and Edwin Aj. Bloem. “Probabilistic Data Association Avoiding Track Coalescence”, IEEE Trans. Auto. Con. V45, pp. 247~259, 2000.
- [8] R. J. Fitzgerald, “Track Biases and Coalescence with Probabilistic Data Association”, IEEE Trans. Aerospace and Electronic Systems, Vol. 21, No. 6, pp. 822~825, November, 1985.
- [9] R. J. Fitzgerald, “Development of Practical PDA Logic for Multitarget Tracking by Microprocessors”, Multitarget Multisensor Tracking : and Advances Applications Volume I , pp. 1~23, Artech House, 1990.
- [10] W. D. Blair, and M. Brandt-Pearce, “NNJPDA for Tracking Closely Spaced Rayleigh Target With Possibly Merged Measurements”, Proc. SPIE Conf. on Signal & Data Processing of Smalll Targets, Denver, CO, July 1999.