

표적 식별을 위한 방법론의 비교

Comparison of Methodologies for Target Identification

김 인택
Intaek Kim

명지대학교 정보제어공학과
Myongji University, School of Electrical, Information and Control Engineering

Abstract

본 논문은 전장에서의 표적 식별을 위해 다수의 센서가 사용되는 환경에서 요구되는 융합방법론에 대해 간단히 살펴보고 이에 대한 차이점을 비교한다. 다수의 센서를 사용함으로써 각각의 센서가 가진 중복성, 보완성을 활용하여 센서가 제공하는 정보의 불확실성을 줄일 수 있는 가능성을 기대할 수 있다. 본 논문에서는 베이지안 알고리즘, Dempster-Shafer 이론 그리고 퍼지 융합 방법 등에 대한 간단히 소개하고 임의의 표적과 특성값을 설정하여 융합 알고리즘간의 성능을 비교하였다.

I. 배경

전장에서는 매우 신속하고 정확한 표적 식별 (target identification)이 요구된다. 따라서 표적 식별의 신속성과 정확성을 향상시키기 위해서는 표적을 감지하는데 다수의 센서 (multiple sensors)를 사용하게 된다. 이는 센서가 적용되는 환경이 매우 열악한 경우가 많으므로 센서가 제공하는 정보는 많은 양의 불확실성 (uncertainty)을 수반하게 된다. 이러한 불확실성은 다수의 센서를 사용함으로써 감소시킬 수 있는데 이는 센서들 사이에 존재하는 중복성, 보완성을 활용함으로써 가능하다. 이와 같은 개념은 1980년 초 센서 융합 (sensor fusion)이라는 표현으로 주로 군사분야에서 많은 연구가 수행되었다[1]. 그러나 최근에는 군사분야뿐 만 아니라 민수용으로 그 기술이 이전되어 생산라인, 로봇 등에 적용되기도 한다.

다수의 센서를 운영하는데 각각의 센서에 의해 제공하는 정보가 효과적으로 융합되는 것은 매우 중요하다. 따라서 융합시키는 방법을 선택하는데 있어 표적 식별이 수행되는 환경의 여러 가지의 측면들이 고려되어야 한다. 특히 각각의 센서가 제공하는 정보들간에 모순 (conflict)이 있을 때는 융합 방법 선택에 더욱 신중을 기할 필요가 있다. 잘 알려진 방법론으로는 베이지안 (Bayesian) 알고리즘[2], Dempster-Shafer(DS) 이론[3], 그리고 퍼지 융합 방법[4]을 고려할 수 있다. 본 논문에서는 앞의 방법론에 대한 간단히 설명하고 예제를 통해 각각의 방법론의 차이를 고찰하고자 한다.

II 표적 식별을 위한 융합 알고리즘

군사 분야에서 적용되는 센서 융합의 예로 표적 식별을 들 수 있다. 표적 식별을 위해 정찰기가 탑재하고 있는 센서로는 SAR (Synthetic Aperture Radar), MTI (Moving Target

Indicator), EO (Electro-Optical), ELINT (Electronic Intelligence)등이 그 예이다. SAR, EO 등은 표적의 물리적인 형태에 대한 정보를 제공하며, MTI는 표적의 이동 속도, 그리고 ELINT는 표적에서 발생하는 전자파의 특성을 알려준다. 이와 같이 다수의 센서로부터 얻는 특성 (feature)은 매우 다양하므로 각 특성으로부터 표적에 대한 부정확한 정보를 융합하여 보다 나은 표적에 대한 추정이 가능하다.

II-1 베이저안 (Bayesian) 알고리즘

베이저안 알고리즘은 잘 알려진 바와 같이 아래의 Bayes 법칙을 이용한다.

$$P(A | x) = \frac{P(A \cap x)}{P(x)} = \frac{P(A)P(x | A)}{P(x)}$$

위에서 x 를 센서의 측정치, A 를 특정 표적이라 하면 위의 식은 센서가 x 를 측정했을 때 표적이 A 일 확률을 의미한다. 그런데 센서의 측정치가 x 가 나오는 것은 표적이 A 일 때 뿐만 아니라 2개의 표적 A 와 B 가 있다고 가정하면 위의 식을 다시 아래와 같이 쓸 수 있다.

$$P(A | x) = \frac{P(A)P(x | A)}{P(x)} = \frac{P(A)P(x | A)}{P(A)P(x | A) + P(B)P(x | B)}$$

따라서 위의 식에서 $P(A|x)$ 를 위해 구해야 하는 값은 $P(A)$, $P(B)$, $P(x|A)$, $P(x|B)$ 가 있다. 여기서 $P(A)$ 와 $P(B)$ 는 *priori* 확률로 주어진 환경 속에서 A 와 B 에 대한 확률을 의미한다. 또한 $P(x|A)$, $P(x|B)$ 는 표적 A 와 B 의 확률 분포를 의미한다. 따라서 $P(A|x)$, $P(B|x)$ 는 측정이 이루어진 후 $P(A)$, $P(B)$ 값이 변화가 일어나는 것이므로 *posterior* 확률이라고 한다. 여러 개의 측정치 (x_1, x_2, \dots, x_n)이 있는 경우는 위의 식이 아래와 같이 표현된다.

$$P(A_j | x_1, x_2, \dots, x_n) = \frac{P(A_j)P(x_1 | A_j)P(x_2 | A_j) \dots P(x_n | A_j)}{\sum_{i=1}^m P(A_i)P(x_1 | A_i)P(x_2 | A_i) \dots P(x_n | A_i)}$$

따라서 표적의 수가 m 개, 측정 데이터의 종류가 n 개일 경우 정보의 complexity는 $O(m \cdot 2^n)$ 이 된다.

베이저안 알고리즘의 장점은 대체로 두 가지를 고려할 수 있다. 첫째로 Bayes 법칙에 근거하여 수학적으로 증명된 기초에서 융합이 이루어진다. 다른 융합 알고리즘은 대부분의 경우, 논리적인 비약을 가지고 있는 취약점을 안고 있다. 다른 하나는 일반적으로 연산시간이 길지 않다라는 점을 들 수 있다. 연산 시간은 앞에서 설명한 바와 같이 $O(m \cdot 2^n)$ 와 연관되어 있다. 그러나 센서 융합의 경우 지수적으로 영향을 받는 특성의 개수(n)는 많지 않고 선형적으로 비례하는 표적의 수(m)도 별로 큰 문제가 되지 않는다.

베이저안 알고리즘의 단점으로는 사전 확률 (*a priori probability*)이 필요하다. *priori* 확률은 표본 집단에 대한 특성에서 나온다. 그러나 정확한 사전 확률에 대한 정보를 얻는 것은 쉽지 않을 뿐만 아니라 표본 집단에 대한 상당한 지식을 요구한다.

지상 표적 식별 융합에 경우, 대상 지역의 특성이 달라지면 (산악, 해안, 평야 지역, 또는 전방, 후방 등) 이에 따라 *priori* 확률이 달라져야 한다. 그러나 이와 같이 지역에 따라 *priori* 확률을 계속하여 바꾸어주는 것은 매우 어려운 일이므로 현실적으로 어려울 뿐만 아니라, 실제로 식별 융합에 있어 상당한 영향을 미치기 때문이다.

II-2 Dempster-Shafer 이론

Dempster-Shafer 이론에서는 확률 대신 basic probability assignment (bpa)를 사용하여 가

능성을 표현한다. 이러한 bpa가 부여되는 대상 (focal element)는 Bayesian의 경우는 단 한 개의 원소 (singleton)에 제한되었으나 Dempster-Shafer에서는 복수개의 원소를 포함하고 있다. bpa를 이용하여 belief(Bel)과 plausibility(Pl) 함수가 정의된다:

$$Bel(A) = \sum_{B \subseteq A} m(B) \quad Pl(A) = \sum_{A \cap B \neq \emptyset} m(B)$$

여기서 Bel(A)와 Pl(A)는 확률 구간의 최소와 최대의 표현으로 해석할 수 있다. 그러나 이렇게 가능성을 구간으로 나타내는 것은 Bayesian의 경우에 비해 합리적으로 보이지만 구간으로 표현된 확률이 가져다주는 정보는 오히려 혼란스럽다.

융합 알고리즘으로서의 Dempster-Shafer는 아래와 같은 공식(rule of combination)에 의해 두 가지 이상의 증거(evidence)가 융합(combining)된다.

$$m_1 \oplus m_2(A) = \frac{\sum_{X \cap Y = A} m_1(X) m_2(Y)}{1 - \sum_{X \cap Y = \emptyset} m_1(X) m_2(Y)}$$

위의 식은 두 개의 센서에서 측정된 bpa를 각각 m_1 , m_2 라고 할 때 표적 A에 대한 bpa를 구하는 식이다. 분모의 값 중 1에서 뺀 값에 해당되는 부분은 두 센서의 모순 (conflict)를 정량적으로 측정할 수 있는 부분이다. 위의 식은 교환 법칙, 결합 법칙을 만족하므로 두 개의 센서뿐만 아니라 그 이상의 센서에도 적용이 가능하다.

Dempster-Shafer 이론의 장점은 무엇보다도 융합 알고리즘, 즉 rule of combination은 직관적으로 잘 설명이 된다. 두 집단의 증거들을 융합시키는데 논리적으로 잘 맞는 융합 알고리즘으로 볼 수 있다. 특히 모순된 증거에 대한 정규화 (normalization)가 있어 수학적인 정의에 잘 부합한다. 그러나 단점으로는 bpa를 구하는 방법이 일반화에 대한 방법론의 부재와 계산량이 늘어날 가능성을 가지고 있는 것이다.

II-3 퍼지 융합 알고리즘

본 절에서 설명하고자 하는 방법은 퍼지 논리에 기반을 둔 융합 알고리즘을 의미한다. 퍼지 논리는 추론 과정에서 AND, OR 또는 MAX, MIN과 같은 매우 단순한 연산자의 사용에 의존하고 있어 장점이 되기도 한다. 퍼지 논리에 의한 식별 알고리즘은 아래와 같은 형태를 취할 수 있다.

If f1 is mf1_1 and f2 is mf2_1 and ..., fn is mfn_1 then target is T1

If f1 is mf1_2 and f2 is mf2_2 and fn is mfn_2 then target is T2

: : : : :

If f1 is mf1_m and f2 is mf2_m and fn is mfn_m then target is Tm

여기서 f1, f2, .. fn은 첫 번째, 두 번째 그리고 n 번째의 특성(feature)를 의미하고 T1, T2,...Tm은 각각 표적 1, 표적 2,.. 표적 m을 표시한다. mf1_1는 첫 번째 특성에 대한 퍼지 값으로 표적 1의 첫 번째 특성이 가지는 소속함수(membership function)를 가리킨다.

각 특성에 해당하는 센서의 입력이 (d1, d2, .. dn)이라고 가정하자. dj는 퍼지 규칙 전건부의 j번째에 적용되어 소속함수 값을 발생시킨다. 소속 함수는 0부터 1까지의 값을 가지며, 입력이 얼마나 퍼지 집합에 속하는 정도를 표현한다.

따라서 첫 번째 규칙에 입력을 넣고 벡터 형태의 소속함수를 구하면, (uf1_1(d1), uf2_1(d2), ... ufn_1(dn))을 얻게 된다. 그런데 입력이 첫 번째 규칙을 지지하는 경향, 즉 입력이 표적

T1에 가깝다는 정도는 여러 가지 방법에 의해 정할 수 있다. 예를 들면 (uf1_1(d1), uf2_1(d2), ... ufn_1(dn))의 값 중 최대값, 최소값, 평균값, 중간값 등이 존재할 수 있다.

만일 최소값을 규칙에 대한 지지도 (support)로 정한다면 k번째 규칙에 대한 지지도는 $\min(uf1_k(d1), uf2_k(d2), \dots, ufn_k(dn)) = \min(k)$ 로 표현된다. 따라서 m개의 규칙에 대한 이를 적용하면 (min(1), min(2), ... min(m))이 된다.

그러므로 센서의 입력 (d1, d2, .. dn)에 대해 어떠한 규칙의 적용이 가장 적절한가는 위에서 얻은 최소값중 최대값을 가지는 규칙을 선택한다. 예로 (min(1), min(2), ... min(m)) 중 min(p)의 값이 최대라면 p번째 규칙, 즉 표적이 Tp라는 결론에 도달하게 된다.

따라서 퍼지 규칙의 전건부는 여러 가지 조건을 융합할 수 있는 기능을 가지게 된다. 위에서 언급한 내용은 특성 수준의 융합이지만 판정 수준의 융합에도 동일한 접근이 가능하다.

III 시물레이션

본 장에서는 아래의 표와 같이 임의의 표적과 특성값을 설정하여 앞에서 설명하였던 융합 알고리즘의 차이점을 살펴본다.

Target	A	B	C	D
Feature				
f1 (size)	20	10	10	5
f2(length/width)	2	3	1.5	2
f3 (avg. speed)	20	30	40	20
f4 (freq. band)	400-500	200-300	300	100-400

표 1 임의의 표적과 특성값

a priori prob. 30% 40% 20% 10%

<실험 1>

입력으로 주어지는 값은 A의 값에서 B의 값으로 5단계에 걸쳐 변화시킨다.

마찬가지 방법으로 C에서 D로 변화시켜, 퍼지 융합 방법과 베이지안 알고리즘을 비교한다.

	A					B
f1	20	22	24	26	28	10
f2	2	2.2	2.4	2.6	2.8	3
f3	20	22	24	25	28	30
f4	450	410	370	330	290	250
결과	A	A	A	B	B	B

표 2. 퍼지 융합 방법 사용: 입력이 data A에서 B로 변할 때의 결과

	C					D
f1	10	11	12	13	14	5
f2	1.5	1.6	1.7	1.8	1.9	2
f3	40	36	32	28	24	20
f4	300	290	280	270	260	250
결과	C	C	B	B	D	D

표 3. 퍼지 융합 방법 사용: 입력이 data C에서 D로 변할 때의 결과

위의 표 5와 6은 입력을 초기에는 표적 A(C)의 값을 사용하면서 표적 B(D)로 변해 갈 때, 퍼지 융합 방법에 의한 융합 알고리즘의 성능을 살펴보았다. A에서 B로 변할 때는 매우 간단하게 전이가 일어났지만 C에서 D로 변할 때는 B의 결과가 나왔다.

	A					B
f1	20	22	24	26	28	10
f2	2	2.2	2.4	2.6	2.8	3
f3	20	22	24	25	28	30
f4	450	410	370	330	290	250
결과	A	A	A	B	B	B

표 4. 베이지안 알고리즘 사용:
입력이 data A에서 B로 변환
때의 결과 (A=30% B=40%
C=20% D=10%)

	C					D
f1	10	11	12	13	14	5
f2	1.5	1.6	1.7	1.8	1.9	2
f3	40	36	32	28	24	20
f4	300	290	280	270	260	250
결과	C	C	B	B	B	D

표 5. 베이지안 알고리즘 사용:
입력이 data C에서 D로 변환
때의 결과 (A=30% B=40%
C=20% D=10%)

위의 결과는 퍼지 융합 방법과 거의 유사한데 특히 C에서 D로 변환 때 D가 발생하는 횟수가 1회 줄어들었다. 이는 D에 대한 사전 확률이 적기 때문이다.

	A					B
f1	20	22	24	26	28	10
f2	2	2.2	2.4	2.6	2.8	3
f3	20	22	24	25	28	30
f4	450	410	370	330	290	250
결과	A	A	A	B	B	B

표 6. 베이지안 알고리즘 사용:
입력이 data A에서 B로 변환
때의 결과 (A=30% B=20%
C=20% D=30%)

	C					D
f1	10	11	12	13	14	5
f2	1.5	1.6	1.7	1.8	1.9	2
f3	40	36	32	28	24	20
f4	300	290	280	270	260	250
결과	C	C	B	B	D	D

표 7. 베이지안 알고리즘 사용:
입력이 data C에서 D로 변환
때의 결과 (A=30% B=20%
C=20% D=30%)

D에 대한 사전 확률을 증가시킨 후 같은 실험에 의해 D가 발생하는 횟수가 늘었다. 따라서 베이지안 알고리즘에 있어 사전 확률은 중요한 영향을 끼칠 수가 있다.

<실험 2>

표적 A와 D는 특성중 f2와 f3이 동일하므로 f1과 f4에 의해 식별이 가능하다. 본 실험에서는 f1을 5(D)에서 20(A)으로, f4를 100(D)에서 500(A)으로 변화시키어 그 사이에서 발생하는 두 가지 알고리즘의 융합 결과를 살펴본다.

위의 실험 결과를 통해 퍼지 융합 방법과 베이지안 알고리즘의 차이점을 명확하게 결론을 지을 수 없지만 일반적으로 다음과 같은 가능성을 제시할 수 있다.

첫째로 베이지안 알고리즘에서 사전 확률의 중요성을 확인할 수 있었다. 즉 B의 사전 확률을 적게 하고 D의 확률을 증가시켰을 때는 B가 표적이라고 판단한 경우는 전무하다. 따라서 베이지안 알고리즘의 사용에서 사전 확률에 대한 명확한 설정이 요구된다.

둘째는 퍼지 융합 방법에서 나타난 결과에 의하면 위의 두 베이지안 알고리즘 결과의 중간 정도로 판단된다. 이는 균등한 사전 확률을 설정한 경우와 유사하리라 생각된다. 따라서 퍼지 융합 방법은 Dempster-Shafer 이론과 마찬가지로 사전 확률을 같다고 판단한 경우가 된다. 그러므로 어떠한 알고리즘이 어떠한 환경에서 더 나은 성능을 발휘하는가 하는 문제는 계산의 복잡성과 함께 사전 확률의 적용이 적절한지 고려한 후 판단해야 한다.

		F4(Freq. band)의 변화 [증가율:20]	
		100	500
F1 (physical size) 의 변화 증가율 [0.75]	5	DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDAA	
		DDDDDDDDDDDDDDDDDDAAA	
		DDDDDBBBBBBDDDDDDAAAA	
		DDDDDBBBBBBDDDDDDAAAA	
		DDDDBBBBBBBBDAAAAAAAAA	
		DDDDBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
		DDDBBBBBBBBBBAAAAAAAAA	
20	DDDBBBBBBBBBBAAAAAAAAA		

표 10. 베이지안 알고리즘 사용:
A=30%, B=40%, C=20%, D=10%

		F4(Freq. band)의 변화 [증가율:20]	
		100	500
F1 (physical size) 의 변화 증가율 [0.75]	5	DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		DDDDDDDDDDDDDDDDDDDA	
		20	DDDDDDDDDDDDDDDDDDDA

표 11. 베이지안 알고리즘 사용:
A=30%, B=20%, C=20%, D=30%

Reference

[1] E.L. Waltz and J. Llinas, *Data Fusion with Military Applications*. Norwood, MA: Artech House, 1990.

[2] J.Jaffray, "Bayesian updating and belief functions," *IEEE Trans. Syst., Man, Cybern.*, vol. 22, pp.1144-1152, Sep./Oct. 1992.

[3] G. Shafer, *A Mathematical Theory of Evidence*. Princeton, NJ: Princeton University Press, 1976

[4] G.Klir, T.Folger, *Fuzzy Sets, Uncertainty, and Information*, Prentice Hall, 1988.