

SVM을 이용한 교전영역 내 위협목록 획득방법

고혜승^{*,1)}

¹⁾ 국방과학연구소 제1기술연구본부

The Threat List Acquisition Method in an Engagement Area using the Support Vector Machines

Hyeseung Koh^{*,1)}

¹⁾ *The 1st Research and Development Institute, Agency for Defense Development, Korea*

(Received 28 August 2015 / Revised 22 December 2015 / Accepted 26 February 2016)

ABSTRACT

This paper presents a threat list acquisition method in an engagement area using the support vector machines (SVM). The proposed method consists of track creation, track estimation, track feature extraction, and threat list classification. To classify the threat track robustly, dynamic track estimation and pattern recognition algorithms are used. Dynamic tracks are estimated accurately by approximating a track movement using position, velocity and time. After track estimation, track features are extracted from the track information, and used to classify threat list. Experimental results showed that the threat list acquisition method in the engagement area achieved about 95 % accuracy rate for whole test tracks when using the SVM classifier. In case of improving the real-time process through further studies, it can be expected to apply the fire control systems.

Key Words : Threat List(위협목록), Classification(분류), Support Vector Machines(SVM)

1. 서론

통제콘솔은 무장의 발사제어를 수행하는 장비로서, 무기체계의 교전 및 발사를 위해서 필수적으로 개발되어야 하는 장비이다. 통제콘솔은 무장의 발사를 위하여 표적 관리, 위협목록 생성, 교전계획 생성 등과 같은 교전정보 및 발사절차 제어에 관한 알고리즘 개

발이 필요하다. 교전통제는 운용자가 특정 표적에 대하여 교전을 결심하고, 교전계획을 수립하여 무장이 발사되고 표적에 요격되는 순간까지의 과정을 의미한다. 이때, 표적격추에 적합한 교전계획 수립은 효과적인 교전통제를 수행하고, 이를 요격할 수 있는 정밀교전이 가능하도록 지원한다. 현대의 경우, 갈수록 복잡해지고 다양해지는 무장과 표적의 정보들로 인하여, 운용자의 빠르고 정확한 교전결심 및 발사제어가 필요하다. 통제콘솔은 다양한 표적의 정보를 획득하기 위하여, 상부/전투체계간의 상호 연동 네트워크인 전

* Corresponding author, E-mail: kohhs@add.re.kr
Copyright © The Korea Institute of Military Science and Technology

투정보망을 통하여 운용한다. 또한, 전투정보망으로부터 주기적으로 전달 받은 표적들에 대하여 위협목록을 생성하고, 표적의 위협정보 및 위협치를 운용자에게 제공함으로써 전투정보망으로부터 전달 받은 표적들 중 특정 표적에 대한 교전을 결심할 수 있도록 지원한다. 하지만 전투정보망으로부터 전송되는 표적정보는 여러 무기체계에 사용되기 때문에, 각 무기체계의 교전영역에는 적합하지 않은 표적정보를 포함하고 있다. 불필요한 표적정보들은 위협목록 및 위협치를 계산하는 알고리즘의 성능을 저하시키고 데이터의 연산량을 증가시킴으로써, 통제콘솔의 정밀교전통제 정확성 및 성능에 영향을 미칠 수 있다. 따라서 각 무기체계의 교전영역을 고려하여 불필요한 표적정보를 제거하고, 위협이 되는 표적을 선별하여 위협목록을 생성함으로써 운용자에게 정확한 표적정보를 제공하고, 교전결심에 도움을 줌으로써 신속한 교전이 가능하도록 하여야한다.

본 논문에서는 기계 학습 알고리즘 중 분류분야에서 일반화 능력이 높고, 널리 사용되어지는 Support Vector Machines(SVM)을 이용하여 동적표적의 특성을 고려한 무장의 교전영역 내의 위협목록 획득 방법을 제안한다. 또한, SVM을 이용하여 표적변화 및 이동성, 무기체계의 특성 등에 강인하며 높은 정확성과 인식률을 가지는 특정영역내의 위협목록 획득방법을 제안한다. 제안된 방법은 표적을 생성하고, 생성된 표적의 이동을 예측하여, 위협목록에 해당하는 표적에 대한 패턴을 획득한다. 획득된 패턴을 패턴인식 알고리즘인 SVM의 학습을 통하여 위협표적을 분류하는 모델을 만들고, 분류모델을 통해 전투정보망으로부터 전송되는 표적의 위협여부를 모델을 근거로 정확하면서도 빠르게 위협목록을 추정한다. 제안된 위협목록 획득 방법은 무기체계의 교전영역에 대한 위협목록 획득뿐만 아니라, 교전표적을 중심으로 하는 탐색패턴영역 내의 주변표적목록 획득이 가능함으로써, 교전계획 수립 시 표적 타격 확률을 높이는 효과가 기대된다.

2. 연구 배경

2.1 동적 표적의 특성

수많은 표적 중 불필요한 표적정보를 결정하여 제거하는 것은 동적표적의 특성을 고려하여야 하는 어려운 문제이다. 운용자가 교전을 결심하는 순간의

표적정보들은 Fig. 1과 같은 정적인 데이터이다. 하지만 표적은 과거에도 현재에도 미래에도 이동하는 동적인 정보로써, 교전계획이 생성되고 발사절차가 진행되어 특정표적에 격추되는 순간까지 위협표적은 Fig. 2와 같이 이동성을 갖는다.

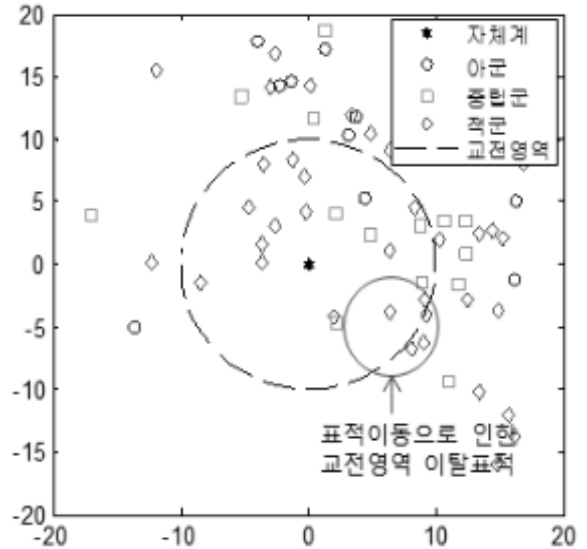


Fig. 1. Static track information at the engagement determination




Fig. 2. Static track information at the intercept engagement track

이처럼 Fig. 2의 표적격추 순간과 Fig. 1의 교전결심 순간을 비교하였을 때, 교전결심으로부터 표적격추까지 시간이 경과한 후에는 교전영역 안의 표적정보가 표적의 이동에 따라 교전영역 밖으로 벗어나는 것을 확인할 수 있다. 따라서 교전영역 내 위협표적정보추출은 통제콘솔의 교전통제시간과 표적의 이동성이 포함된 정보를 기준으로 선별하여야 한다.

2.2 Support Vector Machines 분류 알고리즘

표적정보가 전투정보망으로부터 주기적으로 전송되므로, 빠르고 정확한 주기적 위협표적 판별과정이 필요하다. 본 논문은 위협표적 판별방법으로 기계 학습 알고리즘을 적용하고자 한다. 신경망(Artificial Neural Network, ANN)을 포함하는 기존의 패턴인식 분류방법은 주어진 학습 데이터에 대하여 그룹별로 중심을 구한 후, 각 그룹의 가운데(center)에서 데이터 간의 동일한 분류 거리를 나타낼 수 있는 데이터 분류 기준을 선정함으로써 오류확률을 최소화 하려는 목적으로 설계한다^[1]. 또한 학습 데이터의 수행 정도를 최적화하기 위하여, 경험적인 위험 최소화 방법에 기초를 두고 있다. 하지만 일반적인 데이터 분류 방법은 데이터 그룹의 중심을 이용한 경험적인 방법으로 인해 새로운 데이터(new data)가 들어왔을 때, 잘못된 결과를 수행할 수 있다. 이러한 한계점을 극복하기 위하여 최근 패턴인식 응용분야에서는 각 그룹의 중심이 아닌 그룹들의 경계에 존재하는 데이터(support vector)에 초점을 맞추어 분류를 수행하는 SVM 분류 알고리즘이 널리 사용되고 있다^[2,3]. SVM은 각 그룹 경계에 존재하는 기존 데이터들 간의 최대거리가 동일한 분류 거리를 나타내는 구간을 데이터 분류 기준으로 정의함으로써, 가지고 있는 데이터들을 기반으로 앞으로 입력될 데이터(new data)에 대하여 오차가 가장 적을 것으로 예상되는 기준을 선정한다. 또한, 고정되어 있지만 알려지지 않은 확률 분포를 갖는 데이터에 대해 잘못 분류하는 확률을 최소화하는 구조적인 위험 최소화 방법에 기초를 하고 있기 때문에 일반적인 패턴 분류보다 높은 정확성을 지니고 있다^[4,5]. 뿐만 아니라, SVM은 패턴을 고차원 특징 공간으로 사상시킬 수 있다는 점과 최적의 대역적인 식별이 가능하다는 특징을 지니고 있다. Fig. 3은 2차원 특징을 가지는 A 데이터 그룹과 B 데이터 그룹에 대한 일반적인 선형 분류기를 나타낸다. 여기서 일반적인 선형 분류기의 데이터 분류 기준은 A 데이터 그룹 중심에 이르는 최소

거리와 B 데이터 그룹 중심에 이르는 거리가 같게 되는 최적의 초평면(optimal hyper-plane, OH)으로 표현된다. 반면에, Fig. 4는 2차원 특징을 가지는 데이터에 대한 기본적인 SVM 선형 분류기의 데이터 분류 기준을 설명한 것이다. SVM 선형 분류기의 분류 기준은 A 데이터 그룹의 경계(H_1)와 B 데이터 그룹의 경계(H_2)로부터 두 그룹간의 간격이 가장 크게 나타나는 최적 분류 초평면(optimal separating hyper-plane, OSH)으로 표현된다. 이때, SVM에서 분류 함수에 대한 일차직선이 각 그룹간의 경계 데이터와 만날 때까지 확장 폭을 선형 분류기의 마진(margin), 마진을 이루고 있는 영역을 떠받치고 있는 데이터 점들을 support vector라고 정의한다.

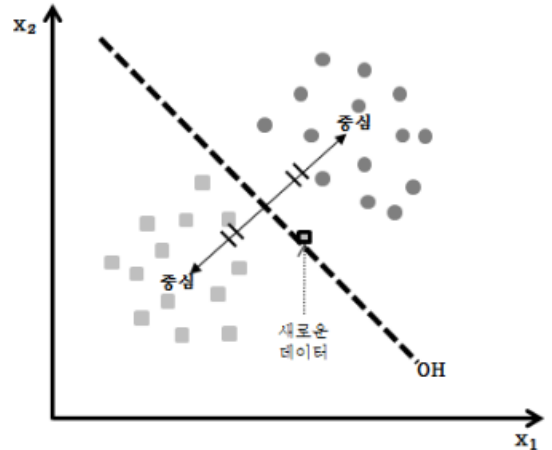


Fig. 3. Definition of general linear classifier




Fig. 4. Definition of support vector machine classifier

SVM의 선형분류기가 식 (1)과 같이 정의될 때, 선형분류기는 A와 B데이터 그룹을 식 (2)와 같이 (+1)과 (-1)의 클래스로 분류한다.

$$g(x,y) = \langle W, X \rangle + b = \sum_{i=1}^n w_i \cdot x_i + b \quad (1)$$

when, $W = (w_1, w_2, \dots, w_n)$

$$X = (x_1, x_2, \dots, x_n)$$

w_i : weight Vector, b : bise

$$W \cdot X + b > 0 : +1 \text{ class (data Set A)} \quad (2)$$

$$W \cdot X + b < 0 : -1 \text{ class (data Set B)}$$

이때, 마진을 이루고 있는 영역을 떠받치고 있는 데이터(support vector, X_{sv})의 분류결과 값과 최대 마진(maximal margin, M_{max})은 식 (3)과 식 (4)와 같다.

$$W \cdot X_{sv}^+ + b = 1 \quad (3)$$

$$W \cdot X_{sv}^- + b = -1$$

when, $X^+ \in +1 \text{ class}, X^- \in -1 \text{ class}$

$$M_{max} = \frac{|W \cdot X_{sv} + b - 1|}{\|W\|} = \frac{2}{\|W\|} \quad (4)$$

안정된 분류기는 식 (5)와 같이 최대 마진의 중심을 이동분하는 최적 분류 초평면을 가지고 있으며, 최대 마진으로 인하여 분류 경계 부근에서 발생하는 분류 오차가 최소화 될 수 있다⁵⁾.

$$W \cdot X + b = 0 : OSH \quad (5)$$

SVM은 각 데이터 그룹의 사이에 존재하는 마진(Margin)을 최대화하여 새로운 데이터에 대한 분류 능력인 일반화(Generalization) 능력을 극대화 시키는 개념으로써, 신경망과 같은 기존의 분류 알고리즘보다 향상된 결과를 보인다.

3. 교전영역 내 위협목록 획득방법

3.1 동적표적 학습분류 특징 추출

학습분류를 위한 동적표적데이터는 자체계의 표적탐색성능을 기반으로 생성한다. 자체계 표적탐색성능은 일반적인 장거리 레이더의 탐지거리를 기준으로 설정한다. 표적탐색성능이 Table 1과 같을 때, 표적데이터는 표적탐색성능을 정규분포의 랜덤 변수로 지니는 랜덤 함수를 이용하여 획득할 수 있다.

Table 1. Track scenario and characteristics

시나리오 속성	자체계 교전 영역	자체계 표적탐색성능 (랜덤변수범위)
표적 X좌표 (x)	자체계기준 ± 100 km	자체계기준 ± 300 km
표적 Y좌표 (y)	자체계기준 ± 100 km	자체계기준 ± 300 km
표적 속도 (v)	최대 60 km/h	최대 60 km/h
표적방위각 (θ)	360 degree	360 degree
표적 식별치 (ID)	1 ~ 3 1-아군 / 2-중립군 / 3-적군	

표적 데이터(T)의 특징으로 사용되는 n 개의 시나리오 데이터(T_n)는 운용자가 교전을 결심을 하는 순간의 정적인 표적정보이다. 하지만 본 논문의 분류 모델은 교전 결심 순간부터 표적이 격추되는 순간까지의 표적에 대한 이동성을 고려한 모델을 구축하여야 한다. 따라서 학습데이터로 사용되는 표적 데이터에 대한 수동분류 기준으로 식 (6)과 같이 통제콘솔의 교전 통제시간(Time)과 표적의 이동성이 포함된 정보를 기준으로 표적의 위치(T'_n)를 추정한 후, Fig. 5와 같이 데이터를 분류하여 이동성이 고려된 학습데이터를 획득한다.

$$T'_n = (x'_n, y'_n)$$

$$x'_n = x_n + (v_n \times Time \times \cos \theta_n) \quad (6)$$

$$y'_n = y_n + (v_n \times Time \times \sin \theta_n)$$

이때, 교전통제시간(*Time*)은 교전을 결심하는 순간부터 무장이 발사되는 시점까지의 시간(*Time To Go*, *TTG*)과 무장이 발사되어 표적을 격추시키는 시간(*Time Of Flight*, *TOF*)을 포함하며, 추정된 표적의 위치(T'_n)는 교전영역(E)과 표적의 식별값(ID_n)을 기준으로 아군 위협 표적과 아군 비위협 표적, 중립군 위협 표적과 중립군 비위협 표적, 적군 위협 표적과 적군 비위협 표적으로 분류할 수 있다. 위협과 비위협의 분류기준은 무장이 표적과 교우하는 시점에 표적이 교전영역 안에 존재하는지에 대한 존재유무로 판단한다.

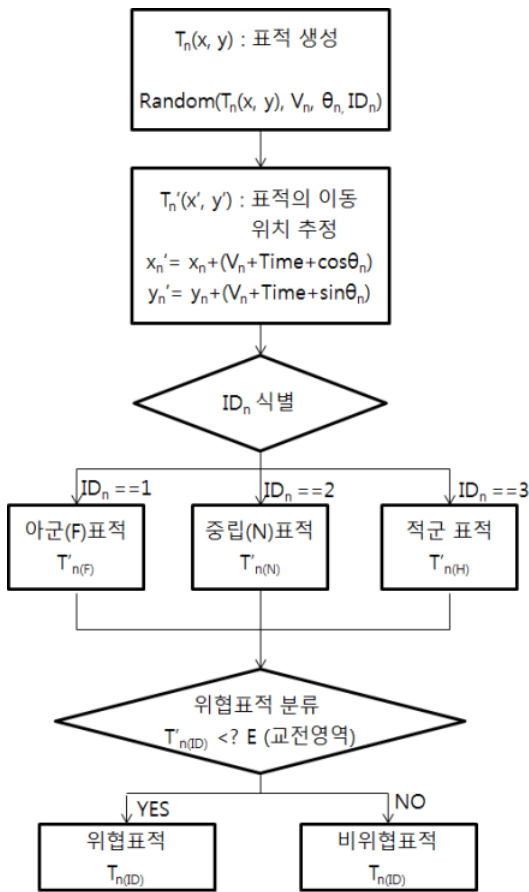


Fig. 5. Track acquisition process to get training data

3.2 SVM학습을 통한 위협표적분류 최적모델링

동적표적의 위협여부를 판별하는 분류모델 구축을 위하여 Table 1의 시나리오를 기준으로 6000개의 표적 데이터를 구성하고, Fig. 6과 같이 구성된 표적데이터에 대한 SVM 학습을 통해 분류모델을 획득한다.

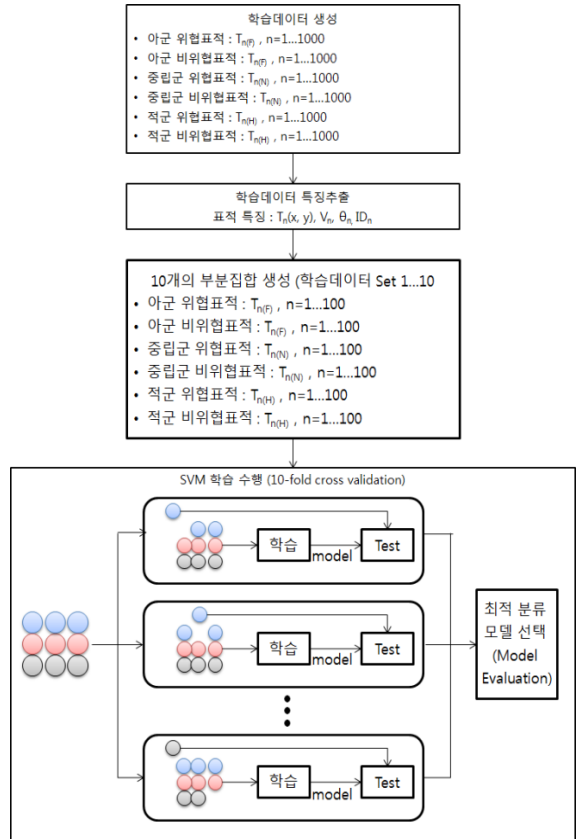


Fig. 6. Optimal classifier modeling process for support vector machine learning

학습데이터의 특징은 시나리오 속성을 이용하며, 학습데이터를 이용하여 분류모델을 생성할 때, 비선형적 분류를 위하여 커널(Kernel) 함수를 도입하여 표적데이터를 고차원 특징공간으로 사상시킨 후, 데이터를 선형적으로 분류한다. 본 논문에서는 식 (7)과 같은 다양한 데이터의 형태에 적용이 용이하여 주로 사용되는 radial basis function(RBF) 커널을 이용한다^[6].

$$K(\vec{x}_i, \vec{x}_j) = e^{-\frac{\|\vec{x}_i - \vec{x}_j\|^2}{2\sigma^2}} \tag{7}$$

이때, 필요한 커널모수(σ^2)와 정규화 모수(γ)는 데이터를 10개의 동일크기 데이터묶음으로 나누어 각 하나의 데이터 묶음을 테스트로 다른 9개의 데이터 묶음을 학습으로 이용하는 10-fold cross validation 방법을 이용하여 최적분류모델을 획득한다. 10-fold cross

validation은 각 데이터 묶음으로 학습된 10개의 학습 모델이 새로운 데이터에 대하여 어느 정도 일반화 (Generalization) 시켜 예측할 수 있는지를 효과적으로 측정 할 수 있는 방법으로써, 10개의 학습모델 중 분류오차가 최소화된 최적의 분류모델을 획득할 수 있다⁷⁾. 본 논문의 SVM 학습으로 생성된 최적분류 모델에 대한 파라미터는 $\sigma^2 = 0.360183$, $\gamma = 1.896747$ 로 정의된다. SVM 학습으로 생성된 최적분류 모델은 운용자가 교전을 결심하는 순간의 표적에 대한 수많은 정적데이터를 가지고 표적이 격추되는 순간의 위협 표적을 분류할 수 있다.

3.3 SVM을 이용한 교전영역 내 위협표적 분류

SVM을 이용한 교전영역 내 위협목록 획득방법의 유용성을 확인하기 위하여, Fig. 7과 같이 SVM의 학습에서 모델링된 최적분류모델을 사용하여 자체계의 교전영역 내 위협표적 분류성능을 검증한다.

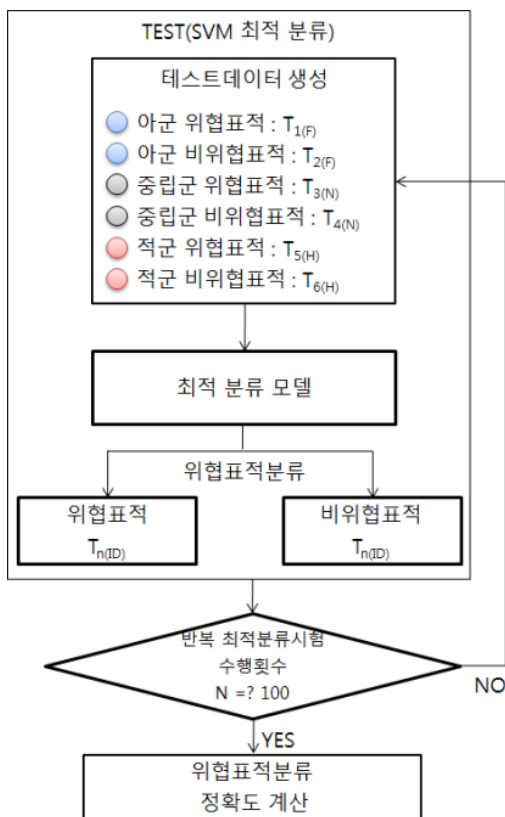


Fig. 7. Optimal classification test process using support vector machines

SVM을 이용한 표적분류능력을 확인하기 위하여, 3.2절에서 선택된 최적분류모델로 새로운 표적 데이터를 위협과 비위협으로 분류하는지 확인한다. 이때, 새로운 데이터는 Table 1의 시나리오를 기준으로 생성된 6개의 표적데이터이며, 시험결과와 신뢰성을 높이기 위하여 100번의 몬테카를로 시뮬레이션으로 표적분류를 반복 수행한다. 본 논문에서는 총 600개의 5가지의 패턴($T(x,y), v, \theta, ID$)을 지닌 새로운 표적데이터에 대하여 최적분류모델을 통해 미래 특정시점의 위협여부를 분류하고 위협목록을 생성한다.

4. 시뮬레이션 및 고찰

제안된 교전영역 내 위협목록 획득방법의 유용성과 정확성을 확인하기 위하여, 먼저, 제안된 표적분류방법에서 표적식별치 별 위협표적과 비위협표적의 혼동관계를 Table 2와 같이 confusion matrix를 사용하여 알아보았다. Table 2. (a)는 아군표적, 2. (b)는 중립군 표적, 2. (c)는 적군표적의 위협과 비위협 표적에 대한 confusion matrix이다. Confusion matrix 결과에 따르면, SVM을 이용한 표적분류방법은 표적 식별치에 관계없이 높은 성능의 위협표적분류기임을 확인하였다.

Table 2. Confusion matrix of proposed method in each identification

(a) Friend track(%)

		predicated class	
		위협	비위협
Actual class	위협	99.00	1.00
	비위협	6.00	94.00

(b) Neutral track(%)

		predicated class	
		위협	비위협
Actual class	위협	97.00	3.00
	비위협	6.00	94.00

(c) Hostile track(%)

		predicated class	
		위협	비위협
Actual class	위협	98.00	2.00
	비위협	10.00	90.00

표적식별치에 무관한 교전영역 내 위협표적에 대한 정확성은 Table 3과 같다. 교전영역 내 위협표적을 식별하는 정확성은 98.00 %, 교전영역 밖의 비위협 표적을 식별하는 정확성은 92.67 %로써, SVM을 이용한 교전영역 내 위협여부 분류결과는 95.33 %로 높은 분류 정확성을 보인다.

Table 3. Accurate rate of track classification

분류 결과	정확도 (%)
위협 표적	98.00
비위협 표적	92.67
총 정확도	95.33

본 논문에서는 SVM을 이용하여 교전영역 내 특정 미래시점의 표적위협성을 평가하여, 동적특성을 지닌 위협 표적 목록을 획득하는 방법이 유용함을 입증하였다.

5. 결 론

본 논문은 무장의 교전영역 내 위협목록 획득방법에 대한 연구로써, 기계학습 분야에서 널리 사용되고 있는 Support Vector Machines(SVM) 방법을 적용하여 표적의 위협여부를 판단하는 방법을 제안하였다. 제안된 위협목록 획득방법은 표적의 정적인 위치뿐 아니라, 표적의 속도와 방위각을 활용하여 동적표적의 특성까지 고려하여 무장의 교전영역 내 위협목록 획득방법을 제안한 것으로써, 표적의 이동성 및 무기체계의 교전영역 특성을 고려하여 위협표적을 분류하는 모델을 만들고, 분류모델을 통해 전투정보망으로부터 전송되는 표적들의 위협여부를 모델을 근거

로 정확하게 위협 여부를 판단하여 위협목록을 획득한다.

SVM을 이용한 교전영역 내 위협목록 획득방법은 시뮬레이션 결과를 통해 표적의 동적특성에 강인하며 위협분류에 대한 높은 정확성과 인식률을 가지는 것을 확인하였다. 또한 SVM을 이용하여 최적분류모델을 선정하는 학습소요시간은 1828.00초, 선정된 최적분류모델을 이용하여 새로운 데이터를 분류하는 분류소요시간은 1.88초로 확인되었다. 이때, 새로운 데이터의 위협여부를 분류하는 분류소요시간은 신뢰성을 높이기 위한 100번의 몬테카를로 시뮬레이션을 자동수행 후 확인한 소요시간이다. 이처럼 모델을 생성하는 학습시간에 비하여, 높은 정확성의 최적모델을 통한 분류시간이 빠름을 확인할 수 있다. 이는 모델을 이용한 적은 연산량으로 빠른 위협목록 획득이 가능하므로써, 전투정보망으로부터 주기적으로 전달 받은 표적들에 대하여 표적을 선별하여 위협목록을 생성하고, 특정 표적에 대한 교전을 신속하게 결심할 수 있도록 지원할 수 있을 것으로 예상된다. 뿐만 아니라, 본 논문을 통해 기계학습 알고리즘이 군사과학기술에 적용가능함을 확인하였다. 향후, 다양한 기계학습알고리즘과의 융합 연구를 통하여 보다 높은 정확성과 적은 소요시간으로 수행하는 표적분류가 가능할 것으로 기대된다.

References

- [1] 한학용, “패턴인식 개론: MATLAB 실습을 통한 입체적 학습”, 한빛미디어, pp. 482-504, 2009.
- [2] W. Chen, S. Hsu and H. Shen, “Application of SVM and ANN for Intrusion Detection,” Computers and Operation Research, Vol. 32, pp. 2617-2634, 2005.
- [3] F. Colas and P. Brazdil, “Comparison of SVM and Some Older Classification Algorithms in Text Classification Tasks,” Artificial Intelligence in Theory and Practice, Vol. 217, pp. 169-178, 2006.
- [4] J. A. K. Suykens, T. Van Gestel, J. De Brabanter, B. De Moor, J. Vandewalle, “Least Squares Support Vector Machines,” World Scientific, Singapore, 2002.
- [5] V. Vapnik, “The Nature of Statistical Learning Theory,” Springer, Inc. NewYork, 1995.

- [6] S. Chen, C. F. N. Cowan and P. M. Grant, "Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks," IEEE Transactions on Neural Networks, Vol. 2, No. 2, pp. 302-309, 1991.
- [7] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," Appears in the International Joint Conference on artificial Intelligence, Vol. 14, No. 2, pp. 1137-1145, 1995.