

적외선 영상에서의 시계열 특징 추출을 이용한 Gunnery 분류 기법 연구

김재협*, 조태욱*, 천승우*, 이종민**, 문영식**

Gunnery Classification Method Using Profile Feature Extraction in Infrared Images

Jae-Hyup Kim *, Tae-Wook Cho *, Seung-Woo Chun *, Jong-Min Lee **, Young-Shik Moon **

요약

Gunnery 표적으로부터 발생하는 영상특징은 장비의 위치를 탐지하고 종류를 판별하는 주요 정보로 활용될 수 있다. 본 논문에서는 Gunnery 영상에서 표적 영역의 밝기값을 획득하여 특징을 추출하고 분류하는 기법을 제안한다. 제안하는 기법에서는 38~40개의 신호 기반 특징과 2개의 모델 기반 특징을 추출하여 분석하고 분류모델에 적용한다. 다중 클래스 분류를 위하여 트리(tree) 기반의 분류 모델을 설계하였으며, 시스템에서 요구하는 Gunnery의 종류와 특성에 따라 유사도를 정의하여 트리 구조를 설계하였다. 트리 구성 단계에서는 각 레벨마다 SVM(Support Vector Machine)을 이용하여 분류 하였으며 시스템에서 요구하는 분류 성능을 만족함을 확인하였다.

▶ Keywords : Gunnery 분류, 트리 구조, SVM(Support Vector Machine)

Abstract

Gunnery has been used to detect and classify artilleries. In this paper, we used electro-optical data to get the information of muzzle flash from the artilleries. Feature based approach was applied; we first defined features and sub-features. The number of sub-features was 38~40 generic sub-features, and 2 model-based sub-features. To classify multiclass data, we introduced tree structure with clustering the classes according to the similarity of them. SVM was used for each non-leaf nodes in the tree, as a sub-classifier. From the data, we extracted features and sub-features and classified them by the tree structure SVM classifier. The results showed that the performance of our classifier was good for our muzzle flash classification problem.

▶ Keywords : Gunnery Classification, Tree Structure, SVM(Support Vector Machine)

•제1저자 : 김재협 •교신저자 : 문영식

•투고일 : 2014. 6. 19, 심사일 : 2014. 8. 28, 게재확정일 : 2014. 9. 19.

* 삼성탈레스(Samsung Thales Co.)

** 한양대학교 컴퓨터공학과(Dept. of CSE, Hanyang University)

I. 서 론

유현대의 전장에서는 탱크의 포탄을 비롯해서 105-mm, 155-mm 등 총탄이나 TNT, RDX 등 폭발물, 지대공 미사일과 공대공 미사일, 로켓 등 여러 가지 포가 사용된다. 이러한 공격을 탐지하는 방법 중 하나가 Gunnery 표적의 밝기값을 이용한 탐지 방법이다. 폭발물이나 미사일 등에서 발생하는 각종 빛 에너지는 Gunnery의 종류별로 미세한 차이가 있기 때문에, 빛 에너지를 이용한 분류는 탐지와 Gunnery의 타입, 크기 등의 분류 면에서 상당히 좋은 효과를 얻을 수 있다.

Gunnery 표적으로부터 발생하는 밝기값이란 순간적으로 강렬히 번쩍이는 빛을 의미하며, 밝기값의 방사량 측정 수치는 폭발 이벤트 후 나오는 빛의 흐름의 밀도(M), 광학 통로를 따라 전파되는 빛의 특성(τ_{atm}), 범위(z)와 광원의 크기(A_{source}), 측정기와 광원과의 각도, 측정기의 검출능력 등에 의해 결정된다. 이러한 밝기값은 적외선 영상 센서를 이용해서 수집이 가능하다. 하지만 밝기값은 포탄의 종류마다 매우 다양하며, 총구 밝기값의 경우 밝기값의 지속시간이 200ms에 불과하기 때문에, 정확한 측정을 위해서는 여러 가지 복잡한 요구사항들을 만족시킬 수 있는 고성능 센서가 사용되어야 한다. 뿐만 아니라 측정 거리에 따른 대기 감쇠(atmospheric attenuation) 효과나 잡음 등 여러 요소들도 중점을 두어야 한다.

Gunnery 표적 분류란 적외선 영상 센서를 이용해서 발생 시 생성되는 밝기값을 탐지하여 고유한 특징을 이용해 종류를 구분하는 것이다. 그렇지만 포탄에 대한 신속한 대응과 피해를 예측하기 위해서는 높은 정확도와 실시간으로 Gunnery에 대한 탐지 및 분류가 완료 되어야 한다. Gunnery 표적 분류에 관한 연구는 대상이 되는 분류 목표가 지극히 군사적이기 때문에, 공개적인 연구는 거의 진행 되어온 바가 없다. 지금까지의 연구는 미국의 군 관련 연구에서 대부분 진행이 되어 왔으며, 최근 국내의 군 관련 연구에서 대두되고 있다.

대표적으로 1990년대 초반에 'The United States Air Force'에서 포탄의 타입, 밝기값 강도, 변화 등으로 분류할 수 있는 가능성을 보였으며, 그 이후 더 빠르고 정확한 분류를 위해 각 포탄 밝기값의 신호값과 새로운 분류 방법을 찾아내는 연구가 진행되고 있다[1]. Ritter 등[2]이 제한한 TEC(Transient Event Characterization) 알고리즘은 단계적으로 필터를 배치해서 여러 가지 지속시간이 짧은 밝기값 이벤트들을 단시간에 분류해냈다. 보통 포 밝기값 이벤트는 10초안에 모든 과정이 이루어지며, 각종 포탄에 따라 그 시간

에 따른 밝기값 강도 분포가 다르다. 저자는 이 점을 이용해서 Gunnery를 분류했으며, 또한 Gunnery 밝기값의 파장이나 폭약의 양 등의 특징으로 일정 수준의 분류가 가능함을 보여 주었다. Ritter 등[3]은 [2]에서 분류해 낸 포탄 종류에 artillery, high explosive detonations, SBRM (Short-Burn Rocket Motors) 등을 추가로 분류해냈다.

Hagerty 등[4]은 PCA(Principal Component Analysis)를 이용한 특징기반 알고리즘으로 접근하여 실시간으로 broad / fine 카테고리의 Gunnery를 분류해냈다. PCA 기반의 알고리즘은 기존의 단순 밝기값 특징 벡터 기반의 알고리즘과 비슷한 수준의 분류 성공률을 보임과 동시에, 고정된 차원을 사용하기 때문에 알고리즘을 더욱 단순화 할 수 있고, 잡음에 강하다는 장점을 가지고 있다. 분류기는 베이저안 분류 모델(bayes classifier)을 사용했으며, 'unknown event'에 대해서는 일단 가장 비슷한 이벤트의 클래스로 분류해놓고 마할라노비스 거리(mahalanobis distance)를 이용해 초타원체의 경계를 만들어 그 이벤트가 경계의 바깥쪽에 있을 경우 unknown으로 분류할 수 있게 했다.

국내의 연구로는, Kim 등[5]이 Gunnery의 단순 밝기값 특징 벡터의 형태 정보를 이용한 FLD(Fisher's Linear Discriminant) 기반의 특징공간을 이용하여 분류하였다. 분류 모델은 혼합가우시안 모델(mixture-gaussian model)을 사용하였으며, 클래스의 영역에 따라 단계적으로 확률 모델을 적용하여 broad, fine 클래스의 분류를 수행하였다.

이와같이 기존의 Gunnery 분류 연구는 Gunnery로부터 발생하는 밝기값의 특징 벡터를 기반으로 분류모델을 설계 하였다. 그러나 다양한 분야의 표적 분류 연구 동향을 보았을 때 특징 기반의 분류가 잡음에 강건하며 분류 성능 또한 뛰어나다[6].

본 논문에서는 위의 연구들에서 기본적으로 활용한 밝기값 표적의 밝기값의 시계열 정보, 즉 밝기값 특징 벡터의 분석을 통해 다양한 부특징(sub-feature)을 추출하고, 단계적인 분류 모델을 구축하는 기법에 대하여 설명한다. 제안하는 기법에서 분류 목표로 하는 표적은 Gunnery 클래스이며, broad 클래스로 A, R, fine 클래스로 1, 2, 3으로 구분된다. 즉, 후보 클래스는 A1, A2, A3, R1, R2, R3의 6개로 표시된다. 제안하는 기법을 설명하는데 있어 분류 시간 목표, 시계열 정보의 기본 특성 등 시스템의 세부 요구사항과 표적에 대한 세부 정보는 군사 보안 사항이므로 생략하였다. 본 논문에서는 2장에서는 밝기값 분류를 위한 부특징 추출에 관해 설명하고, 3장에서는 표적 분류 모델 설계에 대하여 설명한다. 4장에서

는 특징과 분류 모델에 따른 실험 결과에 대해 분석하고, 5장에서는 결론을 설명한다.

II. Gunnery 표적의 특징(feature) 및 부특징(sub-feature) 추출

1. 표적 특징

연속적으로 획득되는 적외선 영상으로부터 얻을 수 있는 Gunnery 표적은 시야의 가로, 세로, 그리고 시간의 3차원 공간에 digital level(밝기)의 값으로 주어진다. 밝기값의 3차원 데이터는 그 크기가 매우 크며, 분류에 불필요한 데이터가 포함되어 있으므로 분류에 적합한 특징을 추출해 내어 사용하면 분류 시간을 줄일 뿐만 아니라 분류 성능을 향상시킬 수 있다. 그림 1은 제안하는 기법의 목표가 되는 Gunnery 표적의 밝기값 에너지의 예를 보여주고 있다. 표적 정보의 가로축과 세로축의 상세 수치는 보안상의 이유로 생략하였다.

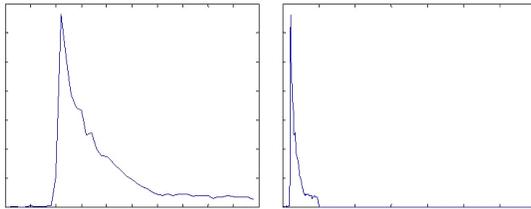


그림 1. 밝기값 표적 profile 예
Fig. 1. The example of flash target

제안하는 기법의 목표가 되는 밝기값 표적은 크게 A 클래스와 R 클래스가 있다. 일반적으로 A 클래스 밝기값이 지속 시간이 짧으며, 발사된 시점 이후로 digital level이 감소하는 특성이 있으며, R 클래스는 지속 시간이 길며 digital level이 A 클래스에 비해 일정하고, 표적의 위치에 따라 밝기값의 위치가 계속 변하는 특성이 있다. 또한 표적의 크기에 따라 탐지되는 동안의 digital level 특성이 다르며, 이 또한 분류의 대상이 된다. 위와 같은 밝기값의 digital level의 차이는 한 장의 영상에서 나타나기 보다는 시간에 따른 변화에서 주로 비롯된다. 즉, 매 순간마다 한 장의 영상, 즉 시야의 가로와 세로에서의 중요한 특징을 적은 수의 값으로 축소하여 시간에 따라 변화하는 양을 측정하는 것이 효과적이다.

Digital level의 값을 추출하는 방법으로는 한 장의 영상 내에서 탐지된 부분의 밝기값의 digital level의 최대값, 평

균, 혹은 digital level을 모두 더한 에너지를 추출하는 방법이 있으며, 이외에도 밝기값의 분산 정도를 추출하는 방법(radius), 처음 밝기값을 탐지한 부분으로부터 이동한 거리(motion)을 특징으로 할 수 있다. 이 중 가장 빨리 추출할 수 있으며 그 변화가 커 분류에 용이하게 사용할 수 있는 특징은 최대값이며, 부특징 추출에는 최대값을 사용하였다.

이렇게 얻은 특징들은 시간에 따라 변하는 1차원 배열로 이루어지며, 그 길이는 표적에 대한 탐지와 추적의 기간에 따라 달라진다. 기준이 되는 길이를 탐지 시간으로 할 경우 추적이 끝난 시점부터 탐지가 끝나는 시점 사이는 zero-padding을 통해 특징 벡터를 완성하였다. 기준이 되는 길이의 실제 수치는 보안상의 이유로 생략하며, 해당 길이는 전체 시스템의 수행 시간, 탐지/분류 성능 요구사항에 따라 결정된다.

기준 길이의 정의에 따라 같은 방법으로 구한 특징이라도 그 값이 달라지는 경우가 있으며, 이 경우 서로 다른 특징으로 간주하였다.

2. 부특징

1차원의 time-series 형태로 나타나는 밝기값 특징 벡터는 3차원 데이터에 비해 작은 크기이지만, 여전히 분류기를 만들고 분류를 하기에는 크기가 크며, 또한 분류에 필요한 중요한 특성이 반영되었다고 볼 수 없다. 따라서, 밝기값 특징 벡터로부터 분류에 사용할 부특징을 추출해야 한다.

제안하는 기법에서는 generic approach 혹은 model-based approach로 부특징을 추출하였다. Generic approach의 부특징에는 모멘트, 밝기값의 그래프 형태를 일종의 PDF(Probability Distribution Function)으로 생각하여 구하는 유클리드 모멘트, 밝기값의 최대값, 유효한 값을 가지는 지속시간(duration), 밝기값의 감소시간(decrease), 밝기값의 추적 길이 등이 있다. 모델링을 통하여 추출한 특징에는 밝기값 특징의 감소부분에 대한 지수형 커브피팅(exponential curve fitting) 특징이 있다.

2.1 모멘트

밝기값 표적의 특징 벡터를 일정 확률에 따라 값이 결정되는 랜덤 변수 들로 생각했을 때 이 랜덤 변수의 PDF의 특성을 나타내는 값들이다. PDF는 식 (1)과 같이 정의된다.

$$p(x) = \text{Prob}(X=x) = \frac{\text{값이 } x \text{인 특징 배열 개수}}{\text{샘플 특징 배열의 길이}} \quad (1)$$

제안하는 기법에서는 최대 4차 모멘트를 계산하여 특징으로 활용 하였다. 모멘트 특징의 경우 밝기값 표적의 기준 길이를 탐지 시간 또는 추적 시간으로 하면 다르게 된다. 예를 들어 A 클래스의 표적의 밝기값은 추적 시간이 짧기 때문에 추적 시간으로 구한 1차 모멘트는 탐지 시간으로 구한 1차 모멘트에 비해 큰 값을 가진다.

2.2 형태 모멘트

밝기값 특징 벡터를 PDF로 생각하였을 때 이것의 특성을 나타내는 값들이다. PDF는 식 (2)와 같이 정의된다.

$$p(t) = Prob(X=t) = \frac{\text{특징 배열 } t \text{ 번째 값}}{\text{특징 배열 값들의 합}} \quad (2)$$

형태 모멘트는 밝기값 특징 벡터의 곱형을 그대로 PDF로 해석한 데에 의미가 있다. 즉, 각 형태 모멘트가 곱형의 형태의 특성을 나타내며, 형태 모멘트를 조합하여 밝기값 특징 벡터를 복원할 수 있다.

2.3 최대값

밝기값 특징 배열 중에서 가장 큰 값이다. 이 부특징은 빠르게 구할 수 있으면서도 대체로 표적의 크기에 비례하여 달라지기 때문에 좋은 분류 성능을 가진다.

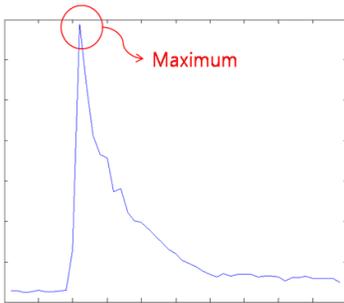


그림 2. 밝기값 특징 배열의 최대값
Fig. 2. The maximum of flash feature vector

2.4 지속 시간

추적 시간 중 밝기값이 유효한 값을 가지는 시간을 나타낸다. 표적이 사라진 뒤에도 표적이 발생한 열로 인해 주변의 digital level의 크기는 다른 부분에 비해 높다. 이를 보정하여 일정 문턱치를 넘는 부분을 유효하다고 판단할 수 있으며,

이 시간을 바로 지속 시간 특징으로 간주하였다. 문턱치는 최대값을 일정 비로 나누어 정할 수 있으며, 여기에 노이즈를 고려하여 약간의 변화량을 더한다. 지속 시간 비율은 지속 시간을 추적 시간으로 나눈 것으로, 추적 도중 유효한 값을 가지는 비율을 나타낸다.

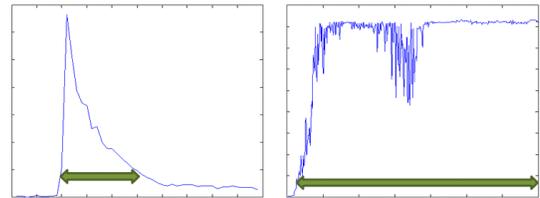


그림 3. 지속시간 특징
Fig. 3. The duration feature

2.5 감쇠 시간

추적시간 중 밝기값의 값이 감소하는 구간의 길이를 나타낸다. 노이즈로 인해 감소하는 구간을 제외하기 위해 노이즈의 크기를 추정하거나 가정하여 일정 문턱치 크기 이상 감소하는 구간만을 이용하였다. 감쇠 시간 비율은 감쇠 시간을 추적 시간으로 나눈 것으로, 추적 도중 감쇠하는 시간의 비율을 나타낸다.

2.6 추적 시간

탐지 시간 중 추적 시간의 부분을 나타내며, 추적이 탐지 시간 동안 끝나지 않으면 탐지 시간을 곧 추적 시간으로 이용하였다.

2.7 지수형 커브 피팅

A 클래스의 일반적인 특성으로 digital level이 최대값에 도달한 이후 계속 감쇠한다. 따라서, 감쇠 구간의 밝기값 특징 배열을 지수 함수와 피팅하여 파라미터를 구한다면 좋은 분류 특징으로 활용할 수 있다. 그러나, 지수 함수의 피팅과정은 많은 수행 시간을 소요하기 때문에 목표가 되는 각각의 클래스에 대한 이상적인 지수 모델을 만든 후, 각 모델과의 차이를 구하여 분류 특징으로 활용하였다. 이상적인 지수 모델은 식 (3)과 같이 계산된다.

$$x(t) = a \exp(-bt) + c \quad (3)$$

여기서 x 는 시간에 따라 결정되는 digital level, t 는 시

간, a 는 최대값, b 는 감쇠비율, c 는 표적이 아닌 영역의 digital level이 되며, 감쇠 비율 b 가 감쇠구간의 형태 혹은 감소 비율을 결정한다.

분류 특징은 감쇠 비율만을 가지는 부분의 지수 모델과 정규화된 밝기값 특징 배열의 MSE(Mean Squared Error)를 계산하여 얻어진다. 정규화된 밝기값 특징 배열 $y(t)$ 는 식 (4)와 같이 계산된다. MSE의 계산은 식 (5)와 같다

$$y(t) = \frac{x(t) - c}{a} = \exp(-bt) \quad (4)$$

$$MSE = \sum_{t=1}^n (\hat{y}(t) - y(t))^2 \quad (5)$$

여기서 \hat{y} 는 어떤 표적으로부터 얻은 정규화된 밝기값 표적 배열, y 는 지수 모델이다. 지수 모델은 각 클래스 별로 데이터베이스를 이용하여 MSE를 최소화 하는 모델을 생성하였다.

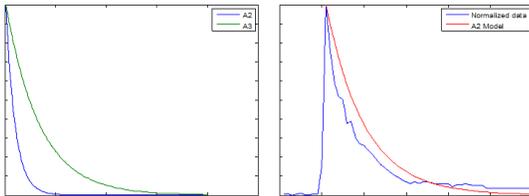


그림 4. (a) 지수 모델 (b) 밝기값 특징 벡터와 모델의 비교 예
Fig. 4. (a) The exponential model (b) The example of comparison between flash feature vector and exponential model

3. 부특징의 적용성

각 부특징은 물리적 혹은 수학적인 의미를 가지고 추출되었다. 이중 유용한 부특징들은 밝기값 분류를 위한 유용한 정보를 가지는데, 이는 부특징 공간에서 같은 클래스의 밝기값들이 잘 모여 있고, 서로 다른 클래스의 밝기값들은 멀리 떨어져있음을 의미한다. 여러 부특징들을 함께 사용하여 단일 부특징 만으로는 얻을 수 없는 분류 성능을 얻을 수 있는데, 가령 같은 클래스의 표적이라도 연료가 많이 들어가면 부특징 중 최대값이 커질 것이나, 동시에 지속 시간도 커질 것으로 예측할 수 있기 때문에 두 부특징을 같이 사용하여 어떤 최대값을 가질 때 어느 정도의 지속 시간이 표적의 클래스를 결정할 것이라고 추정하는 것이 더 분류 성능이 좋을 수 있다. 따라서 부특징의 유용성은 단일 부특징 만으로 판단하기 보다는 다른 부특징과의 관계를 고려하여 선택해야 한다. 이때 다수의 부특징 간의 관계를 하나하나 파악하기 보다는 직접 분류

모델에서 부특징을 활용한 후, 필요한 부특징을 선택적으로 사용하는 방법이 모델 구축에 필요한 수행 시간이 빠르고, 또 직접 선택을 할 때 놓칠 수 있는 정보를 잡아줄 수 있다. 따라서, 부특징의 적용성은 분류 단에서 판단한다.

III. 분류 모델 설계

1. 분류 모델 설계 개요

분류기는 부특징 공간에서 밝기값 표적의 클래스를 분류한다. 기 확보된 밝기값 특징 벡터를 이용하여 감독(supervised) 학습형태의 분류 모델로 설계 하였으며, 알려지지 않은 밝기값 특징 배열 데이터에 대해 새로운 클래스라고 판별 할 수 있도록 하는 분류기가 필요하다.

또한, 시스템의 요구사항에 따라 분류 모델은 unknown 영역을 설정하여 미지의 표적과 노이즈로 인한 잘못된 분류 결과에 대처할 수 있어야 한다. 분류기의 입력 단에 들어갈 데이터는 앞서 설명한 부특징들을 모은 배열과 분류기에 사용할 몇 가지 파라미터이며, 분류기의 출력 단에서 나올 데이터는 분류 결정에 사용될 하나의 숫자이다.

분류기에 대해서는 다양한 선택 가능성이 존재한다. 다중 클래스의 분류와 성능을 보장하는 신경망 계열의 분류기가 가장 일반적이며[6][7], 이진 분류에 특화되고 가장 우수한 분류 성능을 보장하는 SVM(Support Vector Machine)[8], 약한 분류기의 가치치 융합을 통해 강인한 분류 성능을 내는 강한 분류기를 생성하는 Adaboost(Adaptive-Boosting)[9], 등 다양한 모델이 존재한다. 제안하는 기법에서는 'unknown' 영역을 위한 boundary 설정, 단계별 클래스 구분, 우수한 분류 성능 보장 등의 기본 요구조건을 고려하여 SVM을 분류기 모델로 선정하였다.

2. SVM(Support Vector Machine)

SVM은 데이터를 특징 공간에 두고 학습데이터가 나타내는 서로 다른 두 클래스의 경계 중간에 결정 경계(decision boundary)를 정하는 기법이며, 이때 각 클래스의 경계와의 마진(margin)을 최대화하는 방향으로 결정 경계를 정한다. 결정 경계를 정하는 방법은 아래 식 (5)와 같이 최적화 문제를 푸는 것으로 해결된다.

$$\min_{w, b} \frac{1}{2} \|w\|^2 \quad (5)$$

$$\text{subject to } y_i(w^T x_i + b) \geq 1, i = 1, \dots, n$$

여기서 x, y 는 각각 분류기 $y = \text{sign}(w^T x_i + b)$ 의 입출력 데이터이며, x_i 는 i 번째 학습데이터, y_i 는 i 번째 학습데이터의 클래스, w, b 는 분류기의 파라미터를 나타낸다. 위의 목적식을 만족하는 특정 데이터를 SV(Support Vector)로 간주하며, 결정 경계로부터의 마진을 최대화 하는 직선을 이루는 벡터이다. 그림 5는 결정 경계와 SV의 예를 나타낸다.

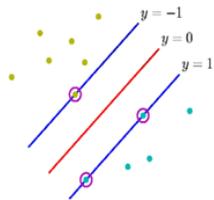


그림 5. Decision boundary 예
Fig. 5. The example of decision boundary

마진은 분류기가 새로운 데이터에 대해서도 안정적인 성능을 내는데 결정적인 역할을 하며, 일부의 노이즈가 포함된 데이터를 무시하는 리스크를 감수해서라도 크게 확보하는 것이 전체적인 분류 성능 향상을 위해 필요하다. 따라서 어느 정도의 학습데이터가 결정 경계를 넘어 다른 클래스의 영역에 속하는 것을 허용하는 대신 여기에 페널티(penalty) ξ 을 주는 유연한 마진 SVM(soft margin SVM)을 사용한다.

데이터의 분포가 선형 분류가 되지 않는 분포인 경우를 위하여 데이터를 선형 분류가 가능한 공간으로의 매핑(mapping) 과정이 필요하다. 그림 6은 커널 함수를 이용한 데이터 매핑의 예를 나타낸다.

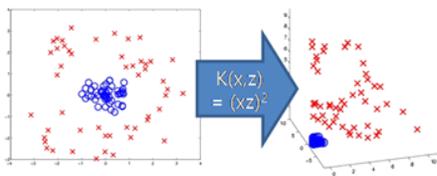


그림 6. 커널 함수 매핑의 예
Fig. 6. The example of data mapping using kernel function

최적화 문제의 쌍대문제(dual problem)를 푸는 방법을 사용하여 커널(kernel)이라 부르는 매핑 공간에서의 내적 함수로 분류기를 생성할 수 있으며, 이를 커널 SVM(kernel SVM)이라 한다. 식 (6)은 유연한 마진 커널 SVM(soft margin kernel SVM)의 쌍대문제를 나타내며, 분류기를 만

들 때 실질적으로 이 문제를 풀게 된다.

$$\begin{aligned} & \max_{\alpha} \sum_{i=1}^n \alpha_i - \sum_{j=1}^n \sum_{k=1}^n \alpha_j \alpha_k y_j y_k K(x_j, x_k) \quad (6) \\ & \text{subject to } \sum_{i=1}^n \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, i = 1, \dots, n \end{aligned}$$

여기서 α 들은 쌍대 문제의 파라미터이며, K 는 커널 함수이다. 이 때 분류기는 식 (7)과 같이 α 와 K 로 구할 수 있다.

$$y = \text{sign}\left(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b\right) \quad (7)$$

‘Unknown’ 영역은 상수 Υ 를 기준으로 SVM 목적함수의 결과 값에 따라 결정 경계를 정하는 방식으로 만들 수 있다. 식 (8)은 이러한 개념을 적용한 SVM 분류기를 나타낸다.

$$\begin{aligned} x \text{ is 'Unknown', if } & \left| \sum_{i=1}^n \alpha_i y_i K(x_i, x) + b \right| < \Upsilon \quad (8) \\ \text{otherwise, } & y = \text{sign}\left(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b\right) \end{aligned}$$

그림 7은 unknown 영역과 클래스 영역을 구분한 SVM 결정 경계의 예를 나타낸다.

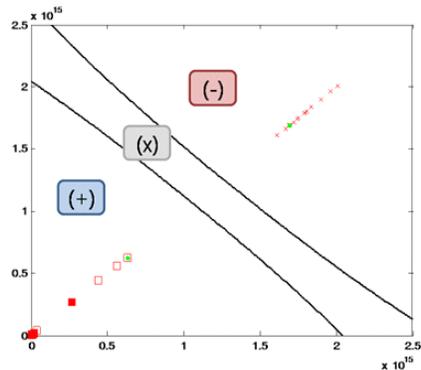


그림 7. Unknown 영역 예((x)영역)
Fig. 7. The example of ‘Unknown’ region((x) region)

이와 같은 분류기 모델에서 결정해야 할 사항은 마진의 유연성을 결정하는 파라미터와 커널함수이다. 마진의 유연성은 너무 크거나 작지 않는 한 큰 변화가 없이 일정 상수를 사용하는 경우가 대부분이며, 커널함수는 무한 차원의 공간으로

매핑하는 RBF(radial basis function) 적용하였다. 식 (9)는 RBF 커널 함수를 나타낸다. x 와 z 는 입력 벡터이며, σ 는 주요 커널 파라미터로써 데이터 공간에서 SV로 채택된 샘플과 결정 경계와의 너비에 비례한다.

$$K(x, z) = -\frac{1}{2\sigma^2} \|x - z\|^2 \quad (9)$$

3. 밝기값 표적 분류기 구조

앞서 소개한 SVM은 이진 분류모델로써, 다중 표적 클래스의 분류 문제로 확장시킬 필요가 있다. 가장 손쉬운 접근 방법으로는 표적의 클래스를 한번에 분류하도록 하나의 부특징공간에서 여러개의 이진 분류기를 적용하는 방법으로 다중 클래스 분류를 수행할 수 있다. 그러나, 표적의 종류와 크기에 따라 분류 성능에 영향을 미치는 서로 다른 부특징이 존재하므로, 트리 구조(tree structure)를 적용하여 층(layer)별로 부분분류기(sub-classifier)를 거쳐 최종적으로 표적을 분류하도록 설계하였다. 트리 구조에서 하나의 노드는 자체에서 판별된 클래스의 이름을 가지며, 하위 노드가 있을 경우 데이터를 아래로 보내기 위한 하나의 SVM을 적용한 부분분류기를 가진다. 그림 8은 제안하는 기법에서 설계한 트리 분류기의 구조를 나타낸다. 제 1 계층은 Broad A, R 층을 의미하며, 색이 부여된 블록이 최종 결과를 의미한다.

이 구조를 적용하면 사용자가 필요한 만큼의 분류만을 빠르게 하는 것도 가능하다. 또한 필요한 만큼만 연산을 행하게 하여 연산 시간을 줄일 수 있는데, 예를 들어 사용자가 표적에 대해 대처하는데 필요한 정보가 A 또는 R로 구분되는 broad 클래스와 fine 클래스 레벨뿐이라면 위 트리구조에서 2 계층 까지만 분류과정을 수행한 뒤 결과를 취하면 된다. 각각의 명칭에 대해서는 4장에서 자세히 설명한다.

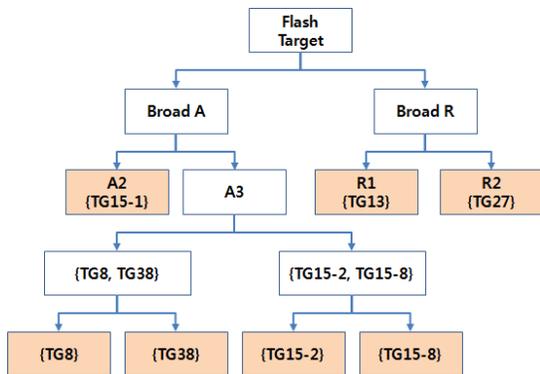


그림 8. 제안하는 트리형 분류 모델 구조
Fig. 8. The proposed tree-structural classifier model

4. 부특징 선별 방법

앞서 설명한 부특징은 최대 40 크기의 벡터가 생성된다. 모든 부특징의 조합을 탐색하면 2^{40} 의 조합에 대해 분류기 성능을 계산해보아야 하며 이는 지수 복잡도(exponential complexity) $O(2^n)$ 을 의미한다. 따라서 빠른 연산을 위해 이미 선별된 부특징 조합에서 선별되지 않은 부특징을 하나씩 추가해보고 가장 결과가 좋은 결과를 택하는 SBFA(sequential brute force approach)를 사용하였으며, 계산 복잡도(computational complexity)는 $O(n^2)$ 이다. 이러한 방법을 SBFA1이라 하며, 이 방법은 매 시기에 주어진 부분분류기 조합에 한해서 최적(optimal)의 결과를 보장하나 전체 부분분류기 조합에 대해서는 최적의 결과를 보장하지는 못한다. 이를 조금 더 보정하기 위해 처음 두 개의 부특징은 모든 조합을 고려하고, 나머지 부특징은 위의 SBFA1 방법을 적용하였다. 이 방법을 SBFA2라 하며, $O(n^2)$ 의 계산을 두 번 하므로 SBFA1 방법에 비해 약 두 배의 시간이 소요된다.

IV. 실험 및 성능 분석

1. 분류 설정

본 논문에서 분류하고자 하는 것은 표적 밝기값의 클래스이며, 각 표적의 종류는 broad 카테고리 A, R, fine 카테고리 1, 2, 3으로 구분된다. 따라서 전체 후보 클래스는 A1, A2, A3, R1, R2, R3의 6개이다. 이 중 자체 구분상의 A1, R3에 해당하는 표적 데이터는 현존하지 않기 때문에 실제 분류를 위해 보유한 후보 클래스 데이터는 A2, A3, R1, R2의 4개이다.

추가하여, 세분화 단계에 대한 실험을 목적으로 A3에 속한 서로 다른 4 종류의 표적을 구분하는 단계를 3, 4번째 계층으로 추가하였다. TG155-1, TG8, 등의 기호는 최종 분류단에서 나오는 결과의 레이블을 나타내며, 표적과 레이블의 정식 명칭은 보안상의 이유로 변경하여 표기하였다.

분류 모델에서 밝기값 특징 배열의 기준 길이는 실험적으로 0000 프레임으로 결정하였으며, 따라서 최대 탐지 시간이 기준 길이에 한하여 적용되어 추출된 부분분류기의 종류에 따라 최대 0000 프레임 만큼의 길이를 가지도록 설계하였다. 분류는 선택된 특징 공간을 (+) 영역, (-) 영역, (x) unknown 영역으로 나눈 뒤 각 표적의 부특징이 어느 영역에 있는지를 판별하는 과정을 단계적으로 수행한다. 연속적인 단계를 거치면서 트리 구조의 마지막에 도착한 노드가 해당 표적의 클래스

스가 된다.

표 1. 표적 클래스와 데이터 수
Table 1. Target classes and flash data

Broad 클래스	Fine 클래스	레이블	표적 개수
A	A2	TG155-1	90
			115
	A3	TG8	51
			13
		TG155-2	28
		TG155-8	17
R	R1	TG13	48
	R2	TG27	71

표 1은 클래스의 구분과 표적 데이터 수를 나타낸다. 1차 계층에서는 broad 카테고리, 2차 계층에서는 fine 카테고리가 분류되며, 레이블은 4차 계층까지 수행했을 때 분류가 완료된다.

2. 파라미터 및 기타 실험 설계

제안하는 기법에서 설계한 밝기값 분류기의 기본 모델에 SBFA1과 2를 사용하였다. SVM의 유연한 마진 계수는 너무 크거나 작지 않은 이상 성능에 큰 영향이 없기 때문에 클수록 계산이 오래 걸리므로 너무 작아 성능이 나빠지지 않을 정도의 수준으로 판단되는 50으로 고정하였다. RBF 커널 파라미터 σ 는 0.5와 2 두 가지를 사용하여 복잡한 ($\sigma=0.5$), 그리고 완만한 ($\sigma=2$) 결정 경계를 모두 사용한 밝기값분류기를 각각 구현하여 총 4개의 모델(SBFA1 vs SBFA2, $\sigma = 0.5$ vs $\sigma = 2.0$ 에 따른 4가지)을 만들었다. 이 중 각각에 대한 분류 성능 검증을 거쳐 최종 모델과 특징 선택을 수행하였다. Unknown 영역은 SVM의 목적함수의 크기가 0.2 이하일 경우로 하였다.

분류 성능 검증은 다수의 교차검증(cross validation) 실험방법을 통하여 행하였다. 교차검증은 데이터를 여러 개의 그룹으로 나누어 하나의 그룹을 제외한 나머지 그룹들을 학습에 사용하고, 학습에 사용하지 않은 하나의 그룹을 분류 테스트에 사용하는 방법이다. 신속한 검증을 위해 두 개의 그룹으로 나누었으며, 다양한 그룹에 대해 검증하기 위해 각 분류 모델별로 100번 반복하였다.

3. 분류 실험 결과

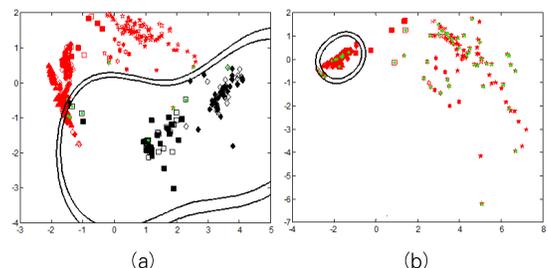
본 논문에서는 표적 데이터의 표기의 통일을 위하여 그림 9와 같이 표적의 종류에 따른 기호를 자체 규정하였다. 표적의 broad 카테고리에 따라 A형은 붉은색, R형은 검은색으로 규정하였으며, SV(Support Vector)는 별도로 녹색으로 규정하였다.

- ◇ TG155-1
- ☆ TG8
- TG13
- ◇ TG27
- △ TG155-1
- TG155-2
- × TG155-8
- ☆ TG8
- ☆ TG38
- ◆ SV(Support Vector)

그림 9. 특징 공간에서의 클래스 기호
Fig. 9. The class symbols in feature space

그림 10은 각각의 부분분류기의 학습 결과를 2차원 PCA 공간에 투영하여 보여주고 있다. 대부분의 부분분류기 공간은 2차원 이상이므로, PCA(principle component analysis)를 사용하여 주축(major axis) 2 개를 찾아 투영하여 표적 데이터의 분포와 결정 경계를 표현하였다.

그림 10에서 결정 경계가 복잡하고 마진이 작은 것이 정답률의 표준 편차가 크며, 이는 해당 단위 분류기가 잘 분류가 되지 않는 어려운 문제를 풀고 있다는 것을 의미한다. 전체적으로 단위 별 분류에서는 그림 10. (e)의 경우 외에는 결정 경계가 명확하여 잘 분류되고 있다. 그림 10. (e)는 TG8과 TG38의 세부분류기의 경우인데, 두 표적의 데이터가 유사도가 매우 높아 상대적으로 결정 경계의 구분성이 낮게 나타난다. A/R 분류기에서 A 클래스 표적의 일부가 분류되지 않은 것처럼 보이는데, 결정 경계가 곡면의 형태를 하기 때문에 투영 과정에서 중복 표현 되는 현상일 뿐 실제로는 잘 구분되어 있다.



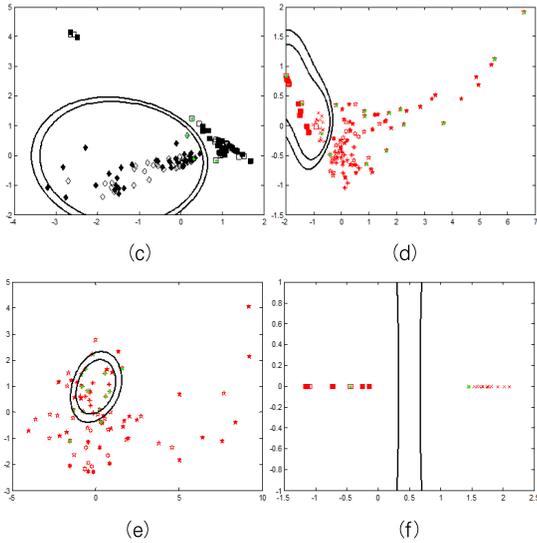


그림 10. 부분류기의 결정 경계. (a) A/R (b) A2/A3 (c) R1/R2 (d) {TG8, TG38}/{TG155-2, TG155-8} (e) TG8/TG38 (f) TG155-2/TG155-8
 Fig. 10. The decision boundary of each sub-classifiers. (a) A/R (b) A2/A3 (c) R1/R2 (d) {TG8, TG38}/{TG155-2, TG155-8} (e) TG8/TG38 (f) TG155-2/TG155-8

표 2. 4중 클래스 분류 실험 결과
 Table 2. The experimental result of 4 classes classification

True \ Test	A2	A3	R1	R2	Unknown
A2	96.99 ±1.79	1.75 ±1.31			1.25 ±1.33
A3	0.85 ±0.84	97.35 ±2.26		0.87 ±0.98	0.92 ±1.47
R1	0.13 ±0.71	0.46 ±2.21	98.25 ±3.80		1.17 ±2.37
R2		0.17 ±0.79	0.03 ±0.29	99.17 ±1.74	0.63 ±1.32

표 3. 7중 클래스 상세 분류 실험 결과
 Table 3. The experimental result of specific 7 classes classification

True \ Test	TG155	TG8	TG38	TG 155-2
TG155	96.99 ±1.79	0.61 ±0.82		1.15 ±0.96
TG8		91.32 ±5.76	3.03 ±2.86	
TG38		3.33 ±7.66	90.33 ±13.92	
TG155-2	3.79 ±3.72			94.00 ±6.86
TG155-8				
TG13	0.13 ±0.71	0.42 ±2.01		
TG27		0.17 ±0.79		

True \ Test	TG 155-8	TG13	TG27	Unknown
TG155				1.25 ±1.33
TG8			1.74 ±1.97	3.90 ±3.82
TG38				6.33 ±9.89
TG155-2				2.21 ±5.05
TG155-8	100.00 ±0			
TG13		98.25 ±3.80		1.21 ±2.46
TG27		0.03 ±0.29	99.17 ±1.74	0.63 ±1.32

표 2는 최종적으로 완성된 분류 모델에 테스트 데이터를 이용하여 분류 실험 한 결과를 나타낸다. 분류 결과는 2단계 레이어, 즉 broad / fine 카테고리의 분류에 대해서 정리하였다.

표 2에서 true는 입력 데이터의 실제 클래스, test는 분류 결과로 계산된 클래스이다. 따라서, 대각 수치가 정답률이 되며, 각각의 분류 성능은 (평균)±(표준편차)의 형태로 나타내었다. 전체 정답률은 97.57%이며, 표준 편차는 1.00%이다 (전체 정답률은 표4의 대각선 성분 4개의 평균이므로 분산은 1/4 표준 편차는 1/2 정도로 감소한다.). 단순 계산으로는 전체적으로 정답률이 매우 우수하다. 그러나, 편차가 2% 내

외로 크게 발생하기 때문에 서로 다른 클래스 간의 마진이 크지 않음을 알 수 있다.

표 3은 4단계 레이어, 즉 세부 분류를 모두 수행했을 때의 결과를 나타낸다(작성의 편의상 표의 좌/우를 나누어 표현하였다.). 전체 정답률은 96.33%이며, 표준 편차는 1.39%이다. 4중 클래스의 broad, fine 카테고리만 분류할 때에 비해 정답률이 약간 떨어지며, 편차 또한 크다. 특히, TG38 표적 클래스는 편차가 매우 크며, TG8 클래스와 쉽게 구별되지 않음을 알 수 있다. 이는 그림 10. (e)의 부특징 공간의 분포에서도 확인할 수 있다.

4. Unknown 영역

Unknown 영역의 기준은 분류기 함수의 크기가 0.2 이하인 경우로 하였다. 주어진 데이터는 모두 클래스를 가지므로 unknown은 정답률을 계산할 때는 오답과 같다. 따라서, unknown 영역을 구분하는 문턱치를 더 크게 하면 정답률이 떨어진다. 대신 잘못 분류할 확률도 줄어들기 때문에 실제로는 더 안정적이라 할 수 있다. Unknown 영역 문턱치를 0.2에서 0.5, 0.8로 바꾸었을 때 broad / fine 카테고리에 대한 분류기의 정답률은 각각 $97.57\% \pm 1.00\%$ 에서 $95.69\% \pm 1.29\%$, $89.72\% \pm 2.25\%$ 으로 감소하였으며, unknown 영역을 제외한 A2의 오답률은 1.75%에서 0.82%, 0.56%로, A3의 오답률이 1.73%에서 1.61%, 1.48%으로 감소하는 것을 확인할 수 있다.

단, 모델 선택에서 unknown 영역 문턱치를 0.2로 사용하였기 때문에 문턱치를 바꿀 경우의 정답률이 최적 값이라는 보장은 없으며, 실험을 통해 상관관계를 분석해야 한다. 그림 11은 unknown 영역 문턱치 변화에 따른 결정 경계의 예를 나타낸다.

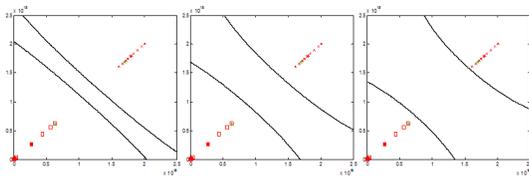


그림 11. Unknown 영역 문턱치에 따른 결정 경계 변화 예
Fig. 11. The example of decision boundary according to unknown region threshold

IV. 결론

본 논문에서는 밝기값 표적 영상을 사용하여 효과적으로

위협 표적의 종류를 분류할 수 있음을 확인하였다. 즉 실전에서 적어 소지한 무기의 화력과 위협 정도를 신속하고 정확하게 판단하여 적절한 대응 수준을 결정하는 데 도움을 주도록 전체 알고리즘과 시스템의 성능을 안정화하고 분류기의 분류 결과를 보다 유용하게 하는 연구의 가능성을 확인하였다.

그러나, 연구 결과에서 상당히 높은 분류 성능을 거두었지만 분류기의 마진이 크지는 않으므로 표적 데이터의 특성이 달라지거나 실전 상황에서 새로운 클래스의 밝기값 표적을 접하게 되었을 때 여전히 안정적인 성능을 달성할 수 있는지에 대한 추가 연구가 필요하다. 다양한 부특징들을 추가로 발굴하고 분류 성능을 향상시키는 동시에 오분류, unknown 등에 대비하여 분류 성능의 안정도를 향상시킬 수 있는 방안도 함께 연구되어야 한다. 또한, 제안하는 기법의 분류 모델은 어느 한 클래스로 분류를 하거나 unknown으로 분류를 하고 있는데, 여기서 더 나아가서 분류 결과를 얼마나 믿을 수 있는지를 수치화함으로써 화력, 위협의 정도를 보다 더 정확히 파악하고 적절히 대응할 수 있도록 설계되어야 실용성을 높일 수 있다. 예를 들어 A2라고 분류할 뿐만 아니라 A2일 확률은 95%이고 A3일 확률이 5%이다 와 같은 수치화된 정보를 제공하는 것이 군장비의 측면에서 더욱 효율적일 수 있다.

참고문헌

- [1] Anthony N. Dills, "Classification of battlespace detonations from temporally resolved multi-band imagery and mid-infrared spectra," Air Force Institute of Technology, 2005.
- [2] A. B. Ritter, A. Y. Weisberg, T. J. Slusarchyk, J. J. Lisowski, and B. A. Hibbeln, "Transient Event Characterization," 1999 IEEE Aerospace Conference Proceedings, Vol. 4, pp. 273-280, March 1999.
- [3] A. B. Ritter, T. J. Slusarchyk, and J. J. Lisowski, "Enhancement and Assessment of a Transient Event Characterization Algorithm," 2000 IEEE Aerospace Conference Proceedings, Vol. 3, pp. 343-349, March 2000.
- [4] S. Hagerty, C. Hilliard and A. Haralson, "Real-time Discrimination of Battlefield Ordnance Using Remote Sensing Data," 2000 IEEE Aerospace Conference Proceedings, Vol. 3, pp. 329-342, March 2000.

- [5] J. H. Kim, G. H. Park, J. H. Jung, and Y. S. Moon, "Gunnery Classification Method using Shape 시계열 정보 of Profile and GMM," Journal of IEEK, Vol. 48 CI, No. 5, pp. 16-23, Sept. 2011.
- [6] Young-Gu Lee and Woo-Seung Choi, "Learning Networks for Learning the Pattern Vectors Causing Classification Error," Journal of KSCI, Vol. 10, No. 5, pp. 77-86, Nov. 2005.
- [7] S. K. Kang, Y. U. Kim, I. M. So, and S. T. Jung, "Enhancement of the Correctness of Marker Detection and Marker Recognition based on Artificial Neural Networks," Journal of KSCI, Vol. 13, No. 1, pp. 89-97, Jan. 2008.
- [8] Kwang Seong Kim and Doosung Hwang, "Support Vector Machine Algorithm for Imbalanced Data learning," Journal of KSCI, Vol. 15, No. 7, pp. 11-17, July 2010.
- [9] J. H. Kim, K. H. Jang, J. H. Lee, and Y. S. Moon, "Multi-target Classification Method Based on Adaboost and Radial Basis Function," Journal of IEEK, Vol. 47 CI, No. 3, pp. 22-28, May 2010.



조 태 옥
 2006: 충남대학교
 전기전자공학부 공학사
 2008: 충남대학교
 컴퓨터공학과 공학석사.
 현 재: 삼성탈레스 선임연구원
 관심분야: 컴퓨터공학
 Email : tw08.jo@samsung.com



천 승 우
 2002: 영남대학교
 전기전자공학부 공학사.
 2005: 도우호쿠대학
 응용정보과학 공학석사.
 2008: 도우호쿠대학
 응용정보과학 공학박사
 현 재: 삼성탈레스 전문연구원
 관심분야: 신경망회로, 패턴인식
 Email : sw45.chun@samsung.com



이 종 민
 2007: 한양대학교
 컴퓨터공학과 공학사.
 2009: 한양대학교
 컴퓨터공학과 공학석사.
 현 재: 한양대학교
 컴퓨터공학과 박사과정
 관심분야: 영상처리, 영상개선
 Email : jmlee@visionlab.or.kr

저 자 소 개



김 재 협
 2001: 한양대학교
 전자계산학과 공학사.
 2003: 한양대학교
 컴퓨터공학과 공학석사.
 2008: 한양대학교
 컴퓨터공학과 공학박사
 2008: 한양대학교
 엠비언트 인텔리전스
 SW연구팀 박사후연구원
 현 재: 삼성탈레스 책임연구원
 관심분야: 지능형 영상처리, 패턴인식
 Email : jaehyup.kim@samsung.com



문 영 식
 1980: 서울대학교
 전자공학과 공학사.
 1982: 한국과학기술원
 전기 및 전자공학과 공학석사.
 1990: University of California at Irvine
 컴퓨터공학과 공학박사
 현 재: 한양대학교 컴퓨터공학 교수
 관심분야: 컴퓨터비전, 영상처리,
 패턴인식
 Email : ysmoon@hanyang.ac.kr