

Article

초분광 표적 탐지를 위한 $L_{2,1}$ -norm Regression 기반 밴드 선택 기법

김주창*†, 양유경**, 김준형**, 김준모*

*한국과학기술원 전기 및 전자공학부, **국방과학연구소

Band Selection Using $L_{2,1}$ -norm Regression for Hyperspectral Target Detection

Joochang Kim*†, Yukyung Yang**, Jun-Hyung Kim** and Junmo Kim*

*School of Electrical Engineering, KAIST

**Agency for Defense Development

Abstract : When performing target detection using hyperspectral imagery, a feature extraction process is necessary to solve the problem of redundancy of adjacent spectral bands and the problem of a large amount of calculation due to high dimensional data. This study proposes a new band selection method using the $L_{2,1}$ -norm regression model to apply the feature selection technique in the machine learning field to the hyperspectral band selection. In order to analyze the performance of the proposed band selection technique, we collected the hyperspectral imagery and these were used to analyze the performance of target detection with band selection. The Adaptive Cosine Estimator (ACE) detection performance is maintained or improved when the number of bands is reduced from 164 to about 30 to 40 bands in the 350 nm to 2500 nm wavelength band. Experimental results show that the proposed band selection technique extracts bands that are effective for detection in hyperspectral images and can reduce the size of the data without reducing the performance, which can help improve the processing speed of real-time target detection system in the future.

Key Words : Hyperspectral Target Detection, Band Selection, $L_{2,1}$ -norm regression

요약 : 초분광 영상을 이용한 표적 탐지를 수행할 때에는 인접한 분광 밴드의 중복성의 문제 및 고차원 데이터로 인해 발생하는 방대한 계산량의 문제점을 해결하기 위한 특징 추출 과정이 필수적이다. 본 연구는 기계 학습 분야의 특징 선택 기법을 초분광 밴드 선택에 적용하기 위해 $L_{2,1}$ -norm regression 모델을 이용한 새로운 밴드 선택 기법을 제안하였으며, 제안한 밴드 선택 기법의 성능 분석을 위해 표적이 존재하는 초분광 영상을 직접 촬영하고 이를 바탕으로 표적 탐지를 수행한 결과를 분석하였다. 350 nm~2500 nm 파장 대역에서 밴드 수를 164개에서 약 30~40개로 감소시켰을 때 Adaptive Cosine Estimator(ACE) 탐지 성능이 유지되거나 향상되는 결과를 보였다. 실험 결과를 통해 제안한 밴드 선택 기법이 초분광 영상에서 탐지에 효율적인 밴드를 추출해 내며, 이를 통해 성능의 감소 없이 데이터의 차원 감소를 수행할 수 있어 향후 실시간 표적 탐지 시스템의 처리 속도 향상에 도움을 줄 수 있을 것으로 보인다.

Received February 22, 2017; Revised March 28, 2017; Accepted August 7, 2017; Published online September 15, 2017.

† Corresponding Author: Joochang Kim (kjc0419@kaist.ac.kr)

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

초분광 영상을 이용한 표적 탐지에 관련된 연구는 현재까지 국내외로 꾸준히 이루어져 왔다. 초분광 센서는 가시광선에 해당하는 파장부터 적외선 파장까지의 대역을 일정한 파장 간격으로 잘게 나누어 계속하게 되며, 이렇게 계속된 초분광 데이터는 공간적 정보와 스펙트럼 정보를 가지는 3차원 큐브(cube) 형태를 가진다. 이러한 초분광 영상의 풍부한 스펙트럼 정보를 이용하면, 물체의 파장 대역 별 특성 분석을 통해 보다 정밀한 표적 탐지를 수행할 수 있다.

계측된 초분광 영상 내 모든 분광 정보를 이용하는 표적 탐지 과정은 몇 가지 문제점을 가진다. 우선 초분광 영상의 인접한 분광 밴드간의 정보 중복이 존재할 수 있고, 일부 파장 대역 내 잡음으로 인한 표적 탐지율 감소의 가능성이 있으며, 수많은 분광 정보 처리를 위한 방대한 계산량으로 인한 탐지 속도 저하가 발생할 수 있다. 이러한 문제점들을 해결하기 위해 초분광 정보의 차원을 효과적으로 줄이면서 유용한 정보를 추출해 내는 기법을 초분광 특징 추출 기법이라고 하며, 여기에는 크게 초분광 데이터 내 일부 분광 밴드를 선택하는 밴드 선택 기법과, 초분광 데이터를 변환하는 함수를 이용한 특징 변환 기법이 있다. 본 연구는 초분광 데이터가 가지는 물리적 특성을 그대로 보존하며 앞서 언급한 문제점을 보완할 수 있는 밴드 선택 기법을 다루고 있다.

표적 탐지를 위한 초분광 밴드 선택 기법은 크게 표적의 분광 정보를 이용하는 supervised 밴드 선택 기법과, 표적의 분광 정보 없이 데이터의 분포 분석을 이용한 unsupervised 밴드 선택 기법이 있다. Keshava(2004)는 밴드 간의 유사성을 비교하여 Spectral Angle Mapper (SAM), Euclidean Distance(ED) 등의 유사도를 최대화하는 밴드를 순차적으로 선택하는 과정을 통해 최적의 밴드 집합을 도출하는 Band Add ON(BAO) 기법을 제안하였으며, Du and Yang(2008)과 Zhang *et al.*(2015)의 연구에서도 Linear Prediction(LP), Orthogonal Subspace Projection(OSP), 그리고 Spectral Information Divergence-Spectral Angle Mapper(SID-SAM) 등의 다양한 유사도 측정 방식을 이용한 순차적 밴드 선택 방식을 제안하였다. 하지만 이러한 방식들은 순차적인 밴드 추가에 앞서 초

기 밴드 선택 과정이 존재하는데, 이 초기 밴드 선택 방식에 따라 최종적으로 선택된 밴드 집합의 결과가 크게 달라진다는 단점이 있다. 또한 탐지하고자 하는 표적의 분광 특성을 반영하지 않는 unsupervised 밴드 선택 기법들이기 때문에, 특정 표적 탐지에 적합한 밴드 선택이 어렵다. Yang *et al.*(2010)은 이러한 초기 밴드 선택 과정의 문제를 해결하기 위한 알고리즘을 및 새로운 밴드 추가 방식을 제안하였지만, 이 연구는 supervised classification을 다루고 있어 각 class에 해당하는 물체의 endmember를 이용한 밴드 선택을 수행하기 때문에 표적 탐지에 그대로 적용하기 어렵다. 최근 이루어진 Sun *et al.*(2015)의 연구의 경우, 밴드 선택 없이 수행한 탐지 결과와 L_1 regression 모델(Tibshirani, 1996)을 이용하여 특정 표적 탐지를 위한 모든 밴드의 중요도를 도출한 후 최적의 밴드 집합을 선택할 수 있는 기법을 제안하였다. 기계 학습(machine learning)의 sparsity를 도입한 밴드 선택 기법을 개발한 데에 의의가 있지만, 밴드 선택 없이 수행한 탐지 결과를 모방하는 방식을 사용하기 때문에 밴드 선택 후 성능이 보장되지 않으며, 탐지 결과 내 픽셀 수가 많을 경우 그 계산량 또한 많아진다.

본 연구는 탐지하고자 하는 표적의 분광 정보와 초분광 데이터로부터 추출된 샘플 분광 정보를 바탕으로 밴드의 중요도를 추정하는 과정에 $L_{2,1}$ regression 모델(Nie *et al.*, 2010)을 도입한 새로운 supervised 밴드 선택 기법을 제안하였다. 제안한 밴드 선택 기법의 성능 분석을 위해 표적이 존재하는 초분광 영상을 직접 계측하고, 이를 바탕으로 표적 탐지를 수행한 결과를 분석하였다. 실험 결과를 통해 제안한 밴드 선택 기법이 탐지 성능을 최대한 유지하며 효율적으로 데이터의 차원 감소를 수행함을 확인하였다.

2. 초분광 영상을 이용한 표적 탐지

1) 물체의 초분광 반사 특성

일반적으로 초분광 영상을 이용한 군사 표적 탐지 연구에서는 가시광선/근적외선/중간파장 적외선 대역(360 nm~3 μ m)을 주로 사용한다(Keshava, 2004; Sun *et al.*, 2015; Yang *et al.*, 2010; Zhang *et al.*, 2015). 이 파장 대

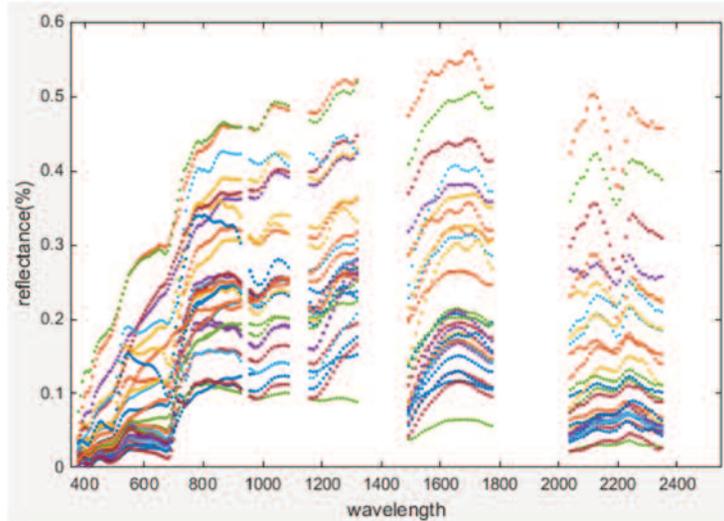


Fig. 1. Spectral variability of vegetative background sampled from Imsil dataset.

역 내에는 대기 내 성분들에 의해 전자기파의 특정 파장대역의 에너지가 흡수되는 구간이 존재하기 때문에 초분광 데이터를 이용한 표적 탐지에 사용할 수 없는 파장 대역이 존재한다. 360 nm~3 um 대역의 초분광 영상을 이용한 표적 탐지를 위해서는 표적 탐지 상황에서 배경 성분이 되는 수풀, 도로, 강, 건물 등이 가지는 초분광 반사 특성 분석이 필요하다.

물체의 가장 중요한 초분광 반사 특성은 같은 종류의 물체라도 물체의 재질 및 색상 변화, 촬영 시의 날씨 및 온도, 그리고 촬영 각도 등의 환경 요인에 의해 초분광 데이터의 변화가 존재한다는 점이다. Winkelmann(2015)의 연구에서는 표적 탐지 시 배경 성분으로 가장 많이 존재하는 초목 성분의 반사 특성을 분석하였는데, 초목의 종류에 따라 초분광 반사 특성이 서로 다른 분포를 보이지만 같은 종류의 초목의 경우에도 서로 다른 샘플을 계측하였을 때 진폭 변동(amplitude variability)가 있음을 확인하였다. Fig. 1은 본 연구에서 획득한 데이터셋의 수풀 위치에서 추출한 30개의 초분광 반사 특성 곡선을 보여준다. 같은 초목 성분이기 때문에 전체적인 곡선의 굴곡의 경향이 비슷한 특성을 가지지만, 대역 별로 조금씩 다른 특성을 보이며 특히 진폭 변동이 매우 크게 일어남을 확인할 수 있다. 그러므로 초분광 데이터에서 나타나는 물체의 진폭 변동 특성을 고려한 탐지 알고리즘이 실전에서의 군사 표적 탐지 시 유리하다.

2) 표적 탐지 알고리즘

초분광 표적 탐지를 위한 다양한 기법들이 존재하는데, 그 중 성능이 안정적이어서 가장 널리 사용되는 두 기법은 matched filter와 Adaptive Cosine Estimator(ACE)이다. 특히, 표적의 분광 스펙트럼이 하나밖에 존재하지 않아 표적의 subspace를 구성할 수 없는 상황에서도 유용한 탐지 기법들이며, 본 연구에서는 이렇게 표적의 분광 스펙트럼이 하나인 제한적인 상황에서의 밴드 선택 및 표적 탐지를 가정하였다. Matched filter는 표적의 분광 스펙트럼과 탐지하고자 하는 픽셀의 분광 스펙트럼 간의 Mahalanobis distance를 이용해 정의된다. 행렬을 이용한 matched filter의 계산식은 식 (1)과 같다.

$$D_{MF} = (d - \mu)^T \Sigma^{-1} (x - \mu) \quad (1)$$

식 (1)에서 d 는 표적의 분광 스펙트럼, μ 와 Σ 는 각각 배경 분포의 평균과 공분산(covariance), x 는 초분광 영상 내 탐지하고자 하는 픽셀의 분광 스펙트럼을 의미한다. 탐지 수치 D_{MF} 를 살펴보면, 표적의 스펙트럼 d 와 테스트 스펙트럼 x 를 배경 분포의 평균을 빼고 공분산으로 나누어 주는 whitening 과정을 거친 후 내적하는 형태를 가지므로, 테스트 스펙트럼이 얼마나 표적 스펙트럼 방향의 성분을 가지는지를 판별하는 distance threshold를 이용해 탐지를 수행하게 된다.

ACE의 탐지 수치 D_{ACE} 는 식 (2)와 같이 나타내어진다.

$$D_{ACE} = \frac{\{(d-\mu)^T \Sigma^{-1} (x-\mu)\}^2}{\{(d-\mu)^T \Sigma^{-1} (d-\mu)\} \{(x-\mu)^T \Sigma^{-1} (x-\mu)\}} = \cos^2 \theta \quad (2)$$

식 (2)의 d, μ, Σ, x 는 식 (1)에서의 정의와 같다. 탐지 수치 D_{ACE} 는 whitening된 두 스펙트럼 d 와 x 의 내적을 각각의 크기로 나눈 $\cos \theta$ 의 제곱 형태를 가지므로, 테스트 스펙트럼과 표적 스펙트럼이 나타내는 스펙트럼 공간 상 두 벡터의 각도를 비교하는 angular threshold를 바탕으로 탐지를 수행한다. Manolakis *et al.* (2003)의 연구에 의하면 실제 표적 탐지에서 ACE가 matched filter보다 대체적으로 좋은 성능을 보이고 있으며, Kraut *et al.* (2005)는 ACE가 이론적으로 분광 변동에 가장 강인한 적응성을 가지는 탐지 기법이라고 주장하고 있다. 이는 ACE 기법이 앞서 언급한 초분광 스펙트럼의 진폭 변동 특성 문제를 잘 처리한다는 것인데, ACE가 식 (2)와 같이 초분광 벡터의 크기에 상관 없이 공간상의 각도만을 비교하기 때문에 비슷한 굴곡을 가지며 스케일만 다른 데이터들을 하나의 물체로 분류해 낼 수 있기 때문이다. 본 연구에서는 이 같은 선행 연구를 토대로, ACE 탐지 기법을 기반으로 밴드 선택 알고리즘을 개발하고 성능 분석을 수행하였다.

3. $L_{2,1}$ Regularization 기반 초분광 밴드 선택 기법

본 연구는 초분광 데이터로부터 특정 표적의 탐지에 유용한 밴드를 선택하기 위해, 각 밴드가 표적 탐지에 미치는 중요도를 추정하여 값이 큰 순서대로 밴드를 선택하는 방식을 사용하였다. 각 분광 밴드의 중요도를 추정하기 위해 기계 학습 분야에서 많이 연구된 특징 선택(feature selection) 기법을 적용하였다. 즉, 초분광 데이터의 각 밴드를 하나의 특징으로 간주하여 밴드 선택 문제를 기계 학습 분야의 특징 선택 문제로 전환하여 좋은 특징을 찾듯이 밴드를 선택하게 하는 것이다. 초분광 탐지의 경우 표적과 배경에 해당하는 label 정보가 주어지므로, 이를 이용한 supervised 특징 선택 기법 중 가장 성능이 우수한 $L_{2,1}$ -norm regression 기법을 적용한 밴드 선택 기법을 개발하였다.

행렬 W 의 $L_{2,1}$ -norm은 각 행의 2-norm의 합으로 정의

되며, 이는 식 (3)으로 나타내어 진다.

$$\|W\|_{2,1} = \sum_{i=1}^n \|w^i\|_2 \quad (3)$$

식 (3)에서 w^i 는 행렬 W 의 i 번째 행 벡터이며 n 은 행렬 W 내 행의 개수이다. 초분광 데이터가 d 개의 분광 밴드를 가지고, 하나의 표적 스펙트럼 $s \in R^d$ 와 n 개의 샘플 배경 스펙트럼 $\{b_1, b_2, \dots, b_n\} \in R^d$ 이 주어졌을 때 각 분광 밴드의 중요도 추정을 위한 $L_{2,1}$ -norm regression의 수식은 식 (4)와 같다.

$$\min_W J(W) = \|X^T W - Y\|_{2,1} + \gamma \|W\|_{2,1} \quad (4)$$

식 (4)에서 $X = \{s, b_1, b_2, \dots, b_n\} \in R^d$, $Y = \left\{ \underbrace{y_1, y_2, y_3, \dots, y_n}_n \right\} \in R^d$, γ 는 sparsity 상수이다. 즉, X 는 표적과 배경의 초분광 스펙트럼 데이터이고 Y 는 이에 해당하는 label 값을 가진다. $J(W)$ 를 최소화 하는 W 를 추정하기 위해 Nie *et al.*(2010)가 제안한 $L_{2,1}$ -norm minimization 알고리즘을 사용하였으며, 본 기법을 통해 loss function과 행렬의 sparsity regularization에 모두 $L_{2,1}$ -norm을 적용하여 예외 데이터 및 잡음에 강인하게 수렴하도록 하였다. 추정된 W 는 초분광 데이터 X 를 각각의 데이터에 해당하는 label Y 로 변환하는 행렬인데 이 때 sparsity regularization에 의해 $\|w^i\|_2$ 이 작은 값을 갖는 경우 그에 해당하는 i 번째 분광 밴드가 초분광 데이터의 분류에 미치는 영향이 작다고 볼 수 있으며, 반대로 $\|w^i\|_2$ 이 큰 값을 갖는 경우 이에 해당하는 i 번째 분광 밴드가 분류에 미치는 영향이 크다고 볼 수 있다. 그러므로 본 연구에서는 $\|w^i\|_2$ 를 초분광 데이터의 i 번째 밴드의 중요도의 추정 값으로 사용하였다. $L_{2,1}$ -norm regression을 이용해 각 분광 밴드의 중요도가 추정된 후에는 최종적으로 $\|w^i\|_2$ 의 값이 큰 순서대로 k 개의 밴드를 선택하게 된다.

한편, $L_{2,1}$ -norm regression 과정에서 전체 배경 샘플을 사용하는 것은 많은 계산량을 요구하기 때문에 배경 데이터의 분포를 잘 표현하는 일부 배경 샘플을 추출할 필요가 있다. 본 연구에서는 초분광 데이터 내 고유 성분을 분리하는 분광혼합분석 과정인 endmember 추출 기법을 사용하여 배경 샘플을 추출하였으며, 이를 통해 초분광 데이터 내에서 고유의 분광 반사 특성을 가지는 배경 샘플 픽셀을 추출할 수 있다. 최근까지 연구된 endmember 추출 기법은 다양한데, 본 연구에서는 Ren

et al.(2003)이 제안한 automatic target generation procedure (ATGP) 방식을 이용해 endmember를 추출하였다. ATGP는 표적 분광 스펙트럼을 시작으로 이에 대한 orthogonal projection의 크기가 가장 큰 벡터를 찾는 과정을 반복적으로 수행하여 endmember를 찾아 나가는 방식으로, 다른 endmember 추출 기법에 비해 그 성능이 우수함이 알려져 있다(Gerg, 2010).

4. 실험 결과 및 분석

Fig. 2는 계측한 초분광 영상으로부터 전처리 과정을 거쳐 밴드 선택을 수행하여 최종적으로 표적 탐지를 수행하는 과정을 보여준다. 밴드 선택을 위해 endmember 추출 과정을 거치고, 전처리를 거친 데이터와 endmember를 바탕으로 $L_{2,1}$ -norm 기반 밴드 선택을 수행한 후 선택된 밴드만을 이용한 ACE 탐지를 수행하여 최종적으로 탐지 스코어를 계산한다.

1) 초분광 데이터 계측 및 전처리

본 연구에서는 초분광 밴드 선택 기법의 성능 분석을 위해 초분광 영상을 직접 계측하였다. 촬영에 사용된 장비는 Specim사의 AisaFENIX로 380 nm~2500 nm 대역의 초분광 영상을 약 5 nm 간격으로 448개의 초분광 밴드를 가지도록 계측하였으며, 본 기기를 항공기에 탑재 후 약 1 km 상공에서 임실과 창원 두 지역에 배치된 표적 일대를 촬영하여 초분광 데이터를 획득하였다. Table 1은 본 연구에서 계측한 두 초분광 데이터셋의 밴드 수 및 표적 정보를 보여준다.

임실 데이터셋은 총 10개의 표적, 창원 데이터셋은 총 6개의 표적이 존재하며, 비슷한 재질 및 색상을 가지는 전투 차량들을 묶어 Battlecar 표적으로 분류하였다. Fig. 3는 임실 데이터셋의 RGB 채널 분광 영상을 이용한 이미지와 영상 내 존재하는 표적의 종류 및 위치를 보여준다.

추가적으로, 표적 탐지 성능 분석을 위한 ground truth map의 정의가 필요하다. 이를 위해 초분광 영상과 동시에 고해상도의 RGB 영상을 함께 촬영하고, 고해상도

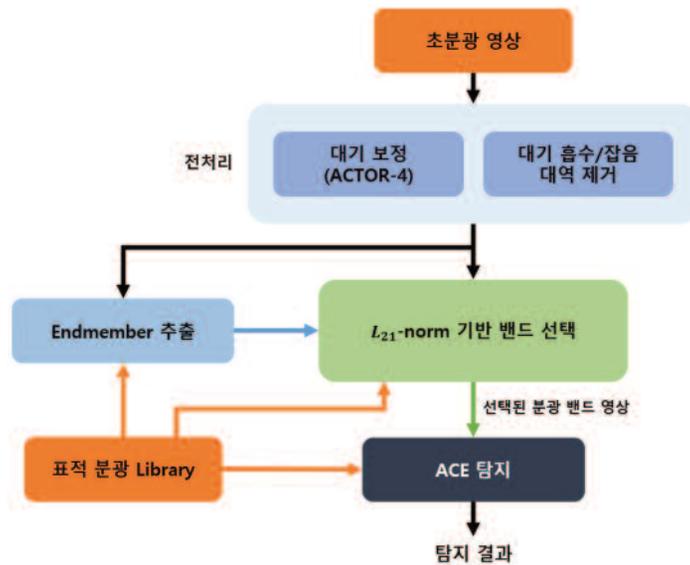


Fig. 2. Overview of hyperspectral target detection system with $L_{2,1}$ -norm based band selection.

Table 1. Specifications of the measured hyperspectral image

| Region | # of pixels | # of Bands | Targets(# of targets) |
|----------|-------------|------------|--|
| Imsil | 253,450 | 448 | Battlecar(6), M548(2), NIKE(1), F-86F(1) |
| Changwon | 200,000 | | Battlecar(3), Camouflaged(1), Decoy(2) |

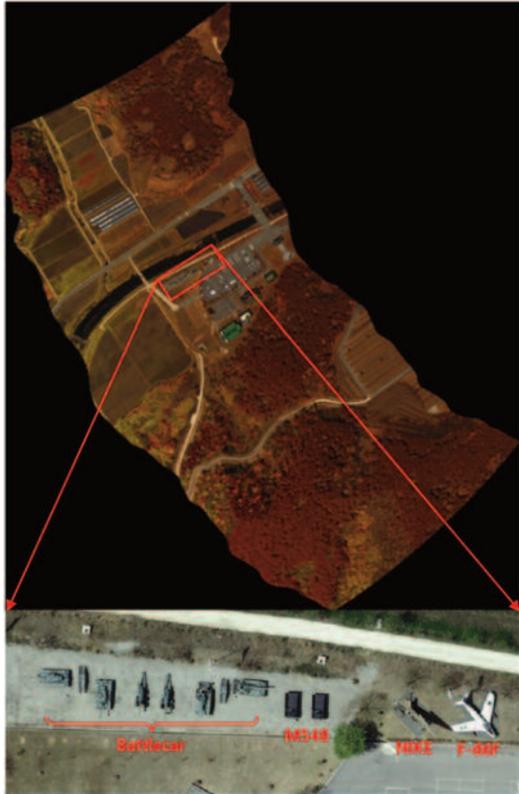


Fig. 3. RGB image of Imsil dataset(top) and detailed target locations(bottom).

RGB에서 생성한 표적 마스크를 초분광 영상에 포개는 방식으로 ground truth map을 생성하였다(Fig. 4).

촬영한 초분광 영상을 ACTOR-4 대기 보정 프로그램을 이용해 처리하였으며, 기하 보정도 수행한 후 표적 탐지에 사용하였다. 최초 448개의 분광 밴드 데이터 중 대기 흡수 파장 대역인 930 nm~950 nm, 1100 nm~1160 nm, 1320-1500 nm, 1780-2030 nm 대역의 밴드 93개를 제외하고(Shaw *et al.*, 2003), 계측된 분광 데이터 중 끝부분 대역(2360 nm~2500 nm)이 신호 대 잡음비(SNR)가 높은 것을 실험적으로 찾아 이에 해당하는 27개의 밴드를 추가적으로 제거하였다. 잡음이 심한 배경을 제거하는 이유는 잡음으로 인해 분광 스펙트럼에 크게 왜곡이 된 픽셀의 경우 배경 샘플링을 위한 endmember 추출 과정에서 이를 endmember로 인식하여 전체적인 밴드 선택 알고리즘의 성능 저하를 가져오기 때문이다. 대기 흡수 파장 밴드 및 잡음 밴드 120개를 제외한 328개의 밴드를 빠른 처리 속도를 위해 1/2로 downsampling 하여 최종적으로 164개의 분광 밴드를 가지는 데이터셋을 기반으로 밴드 선택을 수행하였다. Fig. 5는 대기 흡수 대역 및 잡음 대역을 제외한 164개의 밴드에 대한 초분광 데이터를 보여준다.

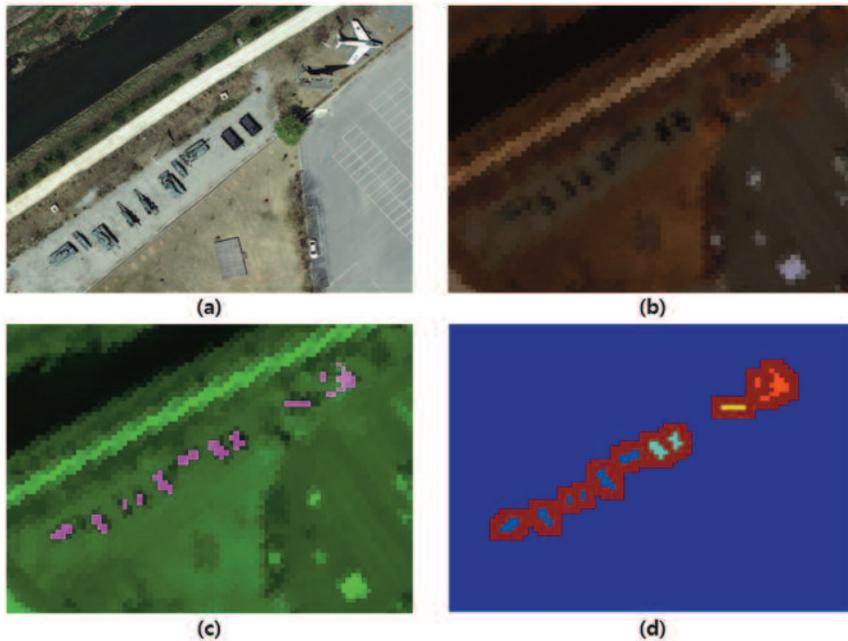


Fig. 4. (a) High-resolution RGB image, (b) RGB image from hyperspectral imagery, (c) target mask in hyperspectral imagery and (d) ground-truth map (red area for guard pixels).

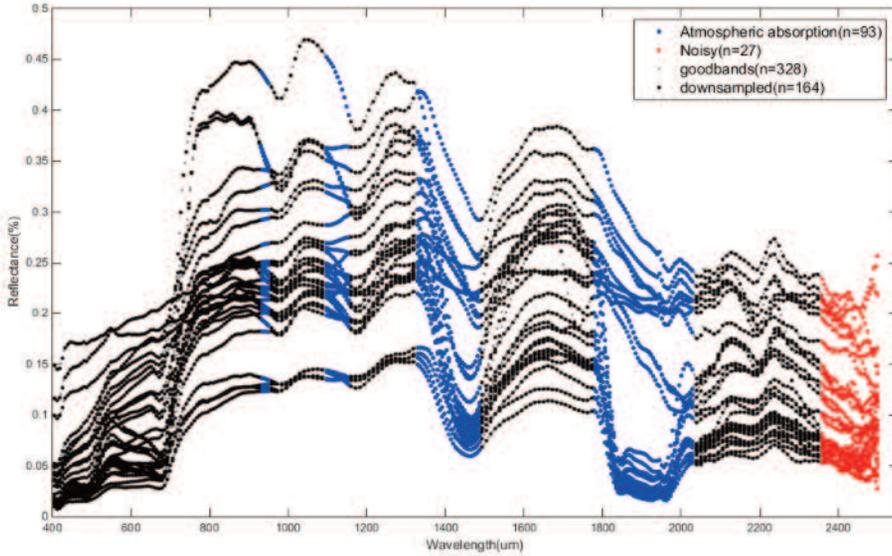


Fig. 5. Atmospheric absorption/noisy band rejection and downsampling for measured hyperspectral dataset.

2) 초분광 탐지 성능을 이용한 밴드 선택 기법 성능 분석

본 연구에서 개발한 L_{21} -norm regression 기반 초분광 밴드 선택 기법의 성능 평가를 위해, 밴드 선택 기법을 적용한 후 ACE 기법을 이용한 초분광 탐지 성능을 분석하였다. Fig. 6는 개발한 L_{21} -norm regression 기반 밴드 선택을 위해 임실 데이터셋에서 50개의 endmember를 추출한 결과이다. 추출된 50개의 배경 스펙트럼과 하나의 표적 스펙트럼으로 X 행렬을 생성한 후 L_{21} -norm regression을 통해 각 밴드의 중요도를 계산 후 중요도

순서대로 밴드 선택을 수행하였다. 촬영한 초분광 영상 내 표적들의 경우 대부분 영상에서 한 픽셀 이상을 차지하기 때문에 full-pixel 표적으로 정의하고, 탐지 성능 분석을 수행하였다.

Fig. 7은 임실 데이터셋의 “battlecar” 표적에 대해 L_{21} -norm regression 기반 밴드 선택 후 ACE 탐지를 수행한 detection map을 보여준다. 선택된 밴드 수가 10개인 경우(Fig. 7(a)), 표적 위치에 탐지 수치가 약간 높은 값을 가지긴 하지만 배경에서도 높은 값들이 많이 분포하여 대체적으로 오경보가 높을 것으로 예상할 수 있다. 밴

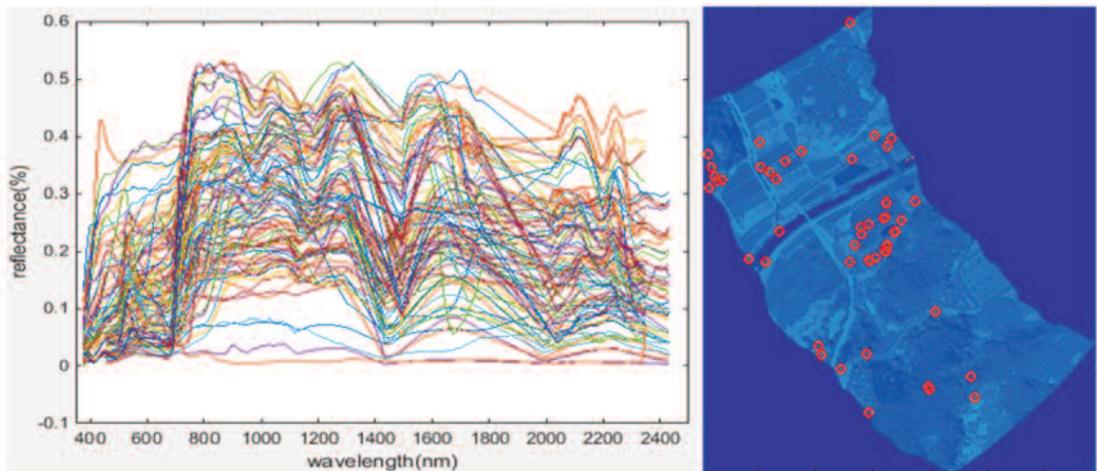


Fig. 6. Spectrums of 50 endmember extracted from Imsil dataset(left) and extracted locations(right).

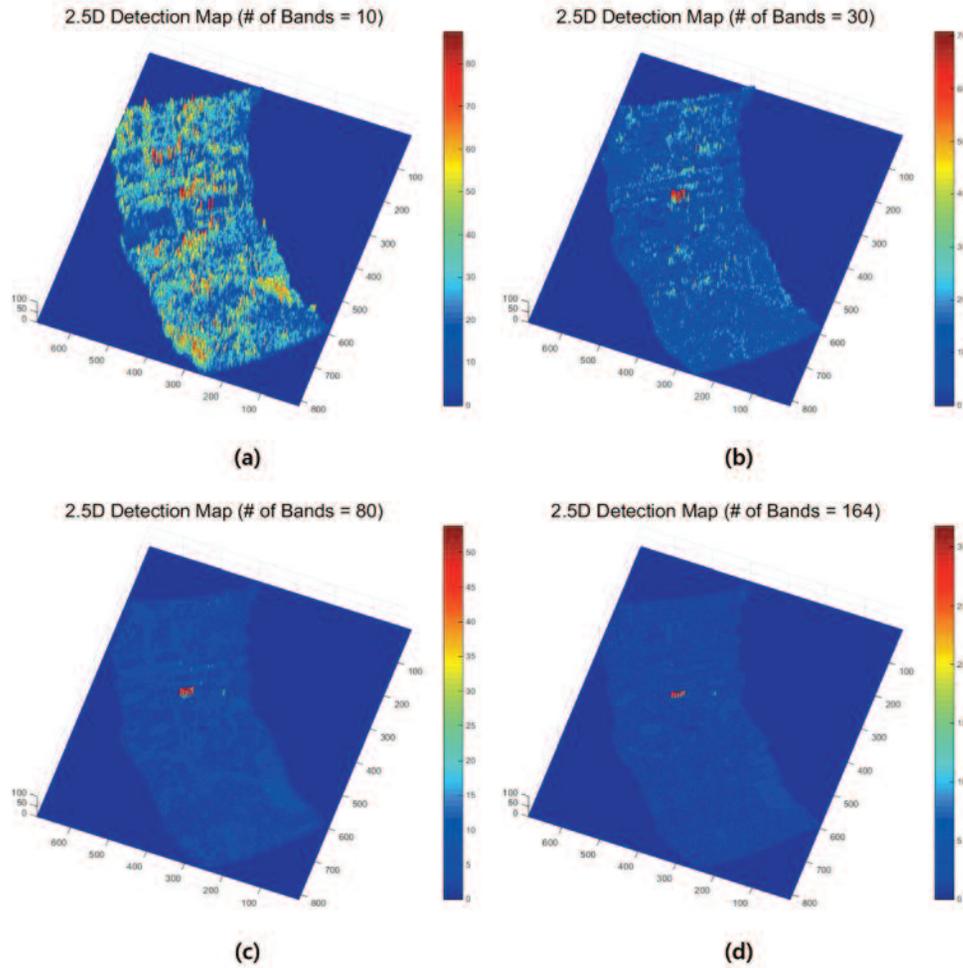


Fig. 7. Detection map for "battlecar" target in Imsil dataset using L_{21} -norm regression based band selection. Every detection maps were scaled by 200 for visibility.

드를 30개 선택하였을 때에는(Fig. 7(b)) 모든 밴드를 사용하였을 때(Fig. 7(d))보다 배경 픽셀에서 탐지 수치가 약간 높게 발생하지만 표적에서의 값을 넘지 못하므로 여전히 탐지가 잘 수행됨을 확인할 수 있다. 하지만, 이러한 Detection map으로는 정량적인 성능 분석이 어렵기 때문에, 정량적 성능 평가 지표로 오경보 픽셀 수와 Target/Background Difference(TBD)를 이용하였다. 주어진 표적을 모두 탐지할 때의 탐지 수치 임계값(threshold)에 대해, 오경보 픽셀 수는 임계값을 넘는 배경 픽셀 수가 되며, 탐지 임계값에서 배경 픽셀에 대한 탐지 수치의 최대값을 뺀 값을 TBD로 정의하였다(Fig. 8).

즉, 오경보 값이 클수록 성능이 좋지 않으며, 임계값과 배경의 최대값의 차이인 TBD가 클수록 표적과 배경

을 더 잘 분리하여 오경보가 발생할 확률이 낮다고 가정하고, 이를 이용하여 탐지 성능 분석을 수행하였다. 오경보 외에 TBD를 추가적인 성능 측정 지표로 정의한 이유는 실험에 쓰인 임실 및 창원 데이터셋 내 표적이 오경보 없이 잘 탐지되는 경우에, 밴드 선택을 하여도 오경보 수가 0으로 변화가 없는 상황에서 좀 더 세밀한 성능 변화를 분석하기 위함이다.

Fig. 9은 임실 데이터셋에 대하여 L_{21} -norm regression 기반 밴드 선택을 수행한 후 ACE 탐지의 오경보수와 TBD를 선택된 밴드 수에 따라 보여주는 그래프이다. Fig. 9(a)는 전차(battlecar) 표적에 대한 탐지 결과를 보여주는데, 오경보 수는 선택 밴드 수를 30까지 낮추어도 0을 유지하다가 20개와 10개에서 오경보가 발생하였다.

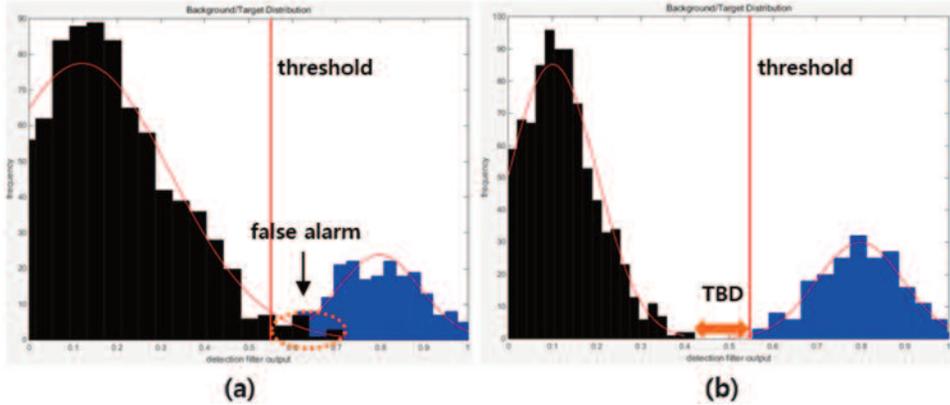


Fig. 8. (a) False alarm, (b) Target-Background Difference(TBD) in detection statistic distribution.

이 때 TBD는 모든 밴드를 사용하였을 때 0.06의 값을 가지지만 밴드를 선택할수록 값이 증가하는 경향을 보였다. 이는 밴드 선택 알고리즘 후에 배경과 표적을 더 잘 분리하여 오경보가 발생할 확률이 더 낮아진다고 볼 수 있으므로 밴드 선택이 탐지 성능의 향상을 가져왔다고 할 수 있다. Fig. 9(c)의 NIKE 표적과 Fig. 9(d)의 F-86F 표적의 경우에도 전차 표적과 비슷하게 일정수의 밴드를 선택하였을 때 TBD지표의 성능이 향상되었으며, 선택 밴드 수가 매우 적을 때에는 오경보가 발생하며 성

능이 악화됨을 확인할 수 있다. Fig. 9(b)의 M548 장갑차 표적의 경우, Fig. 3의 아래쪽 사진에서 볼 수 있듯이 표적의 색상이 매우 어두우며 분광 스펙트럼이 모든 대역에 걸쳐 낮고 일정한 값을 가져, 영상 내 존재하는 강물에서 오경보가 많이 발생하여 탐지가 어려웠다. 이렇게 표적의 분광 특성 상 탐지가 어려운 경우는 밴드 선택 후에도 큰 성능 향상을 기대할 수 없었다.

Fig. 10은 창원 데이터셋에 대하여 $L_{2,1}$ -norm regression 기반 밴드 선택을 수행한 후 ACE 탐지의 오경보수와

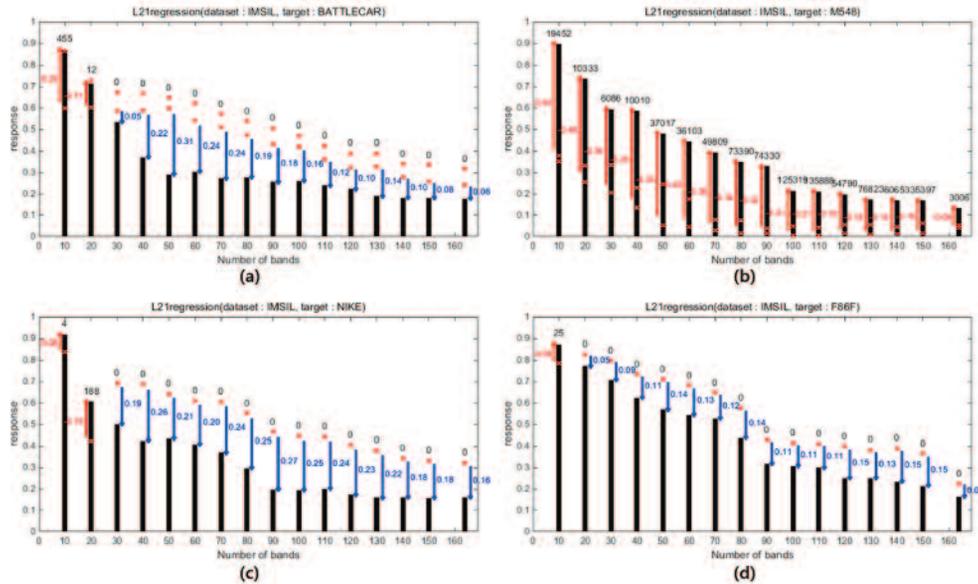


Fig. 9. False alarm and TBD of detection results using $L_{2,1}$ -norm regression based band selection on **Imsil dataset**. (a): battlecar, (b): M548, (c): NIKE, and (d): F-86F. (black bar : background statistics min/max, red x mark : target statistics min/max. Number of false alarm pixels are written on top of each bar, and TBDs are written in red/blue depending on the sign of its value).

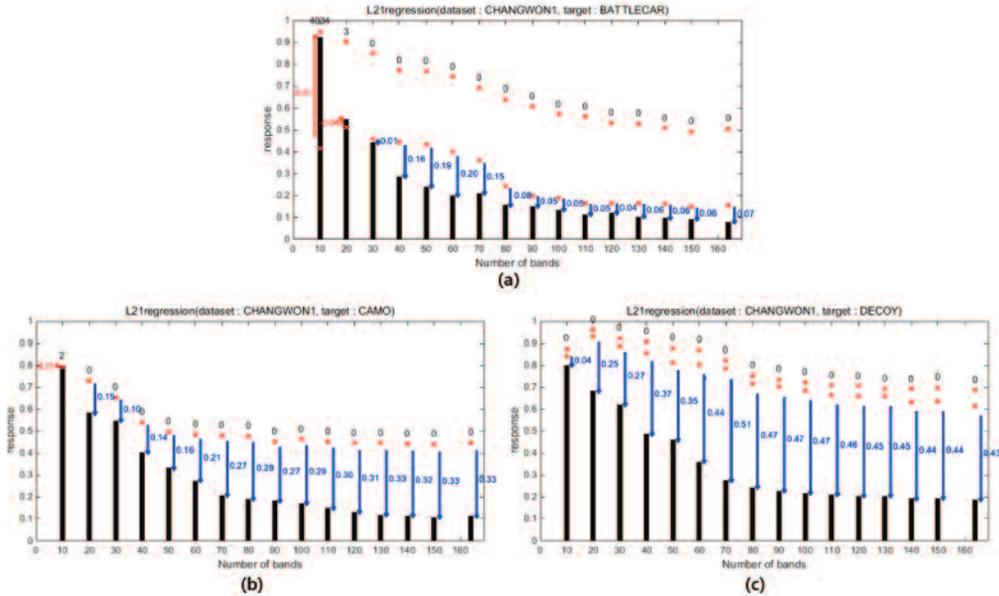


Fig. 10. False alarm and TBD of detection results using L_{21} -norm regression based band selection on **Changwon dataset**. (a): battlecar, (b): camouflage, and (c): decoy. (**black bar** : background statistics min/max, **red x mark** : target statistics min/max. Number of false alarm pixels are written on top of each bar, and TBDs are written in red/blue depending on the sign of its value).

TBD를 선택된 밴드 수에 따라 보여주는 그래프이다. 앞선 임실 데이터셋에 대한 실험 결과와 비슷하게 선택되는 밴드 수가 줄어들 때 성능이 약간 향상 되거나 유지되다가 적은 수의 밴드로 갈수록 성능이 감소하는 경향성을 보였다. 선택되는 밴드 수가 변할 때 탐지 성능 변화의 경향성은 탐지하고자 하는 표적의 분광 특성에 따라 조금씩 차이가 있음을 확인할 수 있지만, 총 밴드 수 164개를 기준으로 약 절반 정도의 수까지 밴드를 선택하여 차원을 감소시켜도 그 성능이 유지되거나 오히려 향상되는 경향을 보였으며 30개까지 밴드를 줄였을 때에도 오경보 없이 표적을 탐지하는 것을 확인하였다.

제안한 밴드 선택 기법 알고리즘의 성능 검증을 위해 Sun *et al.*(2015)가 제안한 sparsity 기반 밴드 선택을 이용한 탐지를 계속된 데이터에 대해 수행하였다.

Fig. 11은 창원 데이터셋에 대하여 Sun *et al.*(2015)의 기법을 이용한 밴드 선택 및 Constrained Energy Minimization(CEM)(Harsanyi, 1993) 탐지 결과를 보여 준다. 위장 표적(CAMO)와 가짜 표적(DECOY)에 대해서는 밴드를 약 30개까지 줄였을 때 오경보가 발생하지 않았지만 battlecar 표적에 대해서는 전체적으로 오경보가 발생하였으며, 모든 밴드를 사용하였을 때의 15 pixel

의 오경보가 발생하였을 때, 밴드 수를 줄여나감에 따라 오경보 수가 점점 늘어나는 것을 확인하였다. Sun *et al.*(2015)의 연구에서도 제안한 밴드 선택 알고리즘은 밴드를 줄여나갈수록 성능이 감소할 수밖에 없음을 증명하였으며, 이는 본 연구에서 계속한 창원 데이터셋에 대한 결과에서도 확인할 수 있었다. 비록 Sun *et al.*(2015)의 연구는 ACE 탐지가 아닌 CEM 탐지를 수행하였지만, 밴드를 줄여나갔을 때 성능을 비교하였을 때 제안한 알고리즘이 더 우월하다는 것을 확인할 수 있다.

Fig. 12는 임실 데이터셋의 4가지 표적에 대해, L_{21} -norm regression기반으로 선택된 30개의 밴드 집합을 50개의 endmember와 함께 보여준 결과이다. 각 표적에 따라 선택되는 밴드 분포가 다르며, 각 표적의 분광 곡선 정보를 반영한 결과를 확인할 수 있다. Fig. 12의 (a)와 (c)의 경우, 표적 곡선에 굴곡이 존재하는 곳에서 밴드가 선택되는 경향을 보이는 데 이는 선택된 분광 밴드에서 표적과 배경(endmember)의 분리가 유리하도록 선택되었기 때문이다. (d)의 경우에도, 표적 곡선의 분포가 배경과 확연히 다르기 때문에 배경 분포와 표적 곡선의 차이가 큰 밴드에서 선택되었다. (b) 표적의 경우, 앞서 설명한 것처럼 표적 반사 곡선이 전체적으로 낮고 일정한

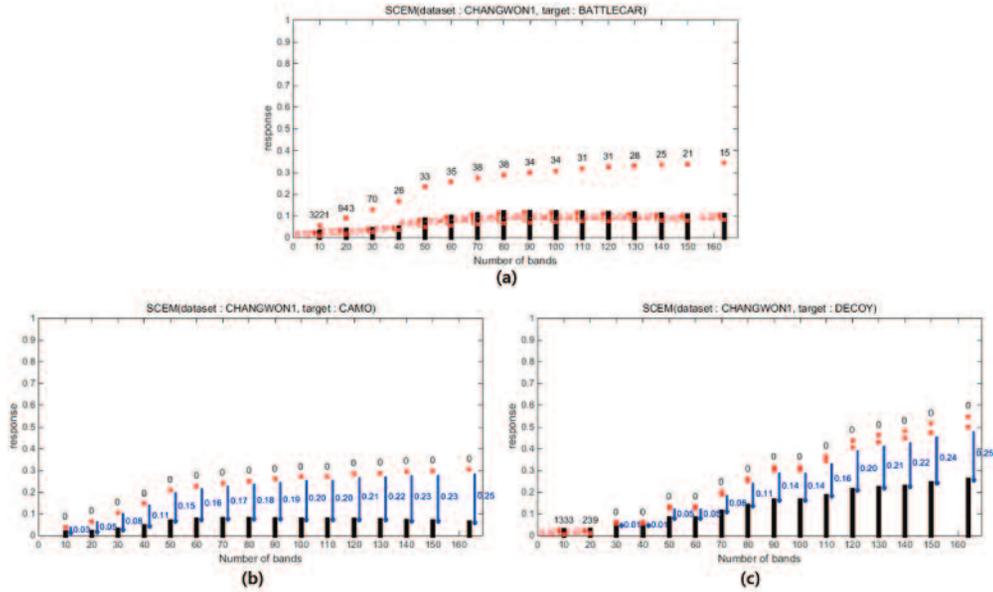


Fig. 11. False alarm and TBD of detection results of Sun et al.(2015) on **Changwon dataset**. (a): battlecar, (b): camouflage, and (c): decoy. (**black bar** : background statistics min/max, **red x mark** : target statistics min/max. Number of false alarm pixels are written on top of each bar, and TBDs are written in red/blue depending on the sign of its value).

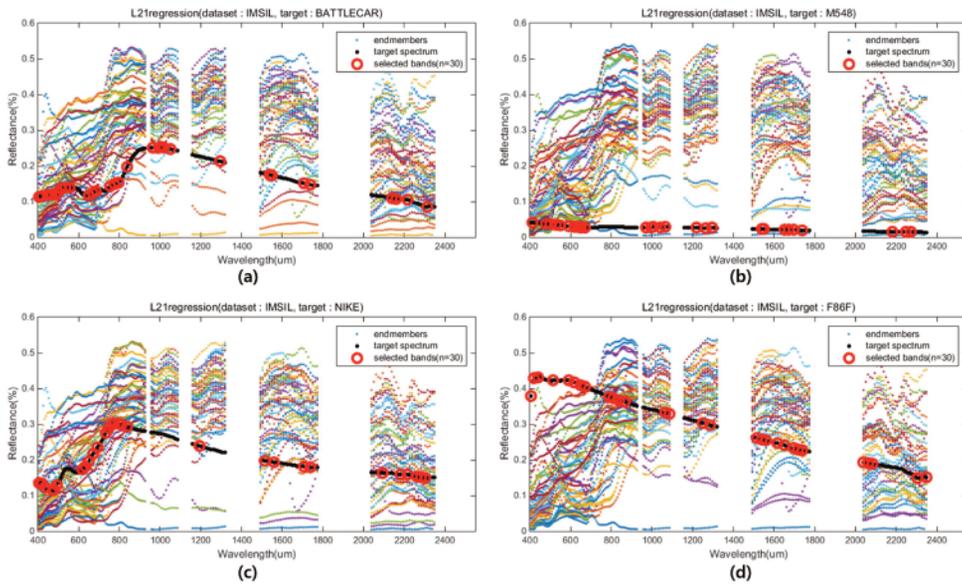


Fig. 12. Selected band set using L_{21} -norm regression based band selection on Imsil dataset.

값을 가지므로 비록 선택된 밴드 분포가 다른 표적과 비슷한 경향을 보이지만 탐지 시에 오경보가 많이 발생하였다.

Table 2는 밴드 선택 및 표적 탐지까지 수행하는데 각

알고리즘의 계산 수행 시간을 보여준다. 밴드 선택으로 차원이 감소함에 따라 ACE 탐지의 계산량은 선형적으로 감소하게 되므로 탐지에 걸리는 시간을 약 절반 정도로 단축할 수 있다. 또한 Nie *et al.*(2010)의 L_{21} -norm

Table 2. Computation time analysis for band selection and target detection on Imsil dataset (Environment: i7-4790 CPU, 32GB RAM, MATLAB 64bit)

| Algorithm | Endmember extraction | $L_{2,1}$ -norm regression | Sun <i>et al.</i> (2015) | ACE detector | | | | | | | |
|----------------------|----------------------|----------------------------|--------------------------|--------------|------|-----|-----|------|------|------|------|
| | | | | Band # | Full | 140 | 120 | 100 | 80 | 60 | 40 |
| Computation time (s) | 87.5 | 0.06 | 7.5 | Time | 4.47 | 4.1 | 3.6 | 3.43 | 2.63 | 2.21 | 1.95 |

regression 기법은 매우 빠르게 수렴하기 때문에 밴드 선택에 걸리는 시간이 탐지 수행시간에 비해 무시할 수 있었지만, 배경 샘플 추출을 위한 endmember extraction 과정에서 매우 많은 시간이 소요되었다. 그 이유는, ATGP 알고리즘이 모든 배경 샘플들을 projection 시키는 과정을 반복적으로 수행하는 과정에서 계산량이 많기 때문이다. 하지만, Endmember가 추출된 후에는 매우 빠르게 밴드를 선택할 수 있으며, 이는 Sun *et al.*(2015)에 비해 100배 이상 빠른 속도이다. 실제 표적 탐지 수행 시에는 인근 지역의 배경 샘플을 미리 추출하여 밴드를 선택한 후 선택된 밴드로 탐지를 수행할 수 있기 때문에 배경 샘플 추출 과정이 큰 영향을 미치지 않을 수 있지만 새로운 환경에 빠르게 적응하는 탐지 시스템을 위해서는 속도 개선을 위한 추후 연구가 필요할 것으로 예상된다.

5. 결론

본 연구는 초분광 영상을 이용한 표적 탐지 과정에서 필수적인 특징 추출을 위한 $L_{2,1}$ -norm regression 기반 밴드 선택 기법을 제안하였으며, 제안된 기법의 성능 평가를 위해 AisaFENIX 센서를 이용해 초분광 데이터셋을 구축하고 이를 이용해 실제 표적에 대한 밴드 선택 후의 탐지 성능을 분석하였다. 두 개의 데이터셋에 대한 실험 결과, 일정 수의 밴드 선택 후에도 ACE 기법의 탐지 성능이 유지되지만 너무 적은 수의 밴드를 선택하였을 때는 ACE 기법의 탐지 성능이 저하되는 것을 확인하였다. 350 nm~2500 nm 파장 대역에서 전체 164개의 분광 밴드 수를 기준으로 약 30~40개의 밴드만을 이용해 표적 탐지를 수행할 수 있었으며, 밴드 선택 후 ACE 탐지의 성능이 유지되거나 향상되는 경향을 보였다. 본 연구를 통해 표적 탐지 시에 배경 샘플 추출 및 제안된 $L_{2,1}$ -norm regression을 이용한 사전 밴드 선택을 거친 후

ACE 탐지를 수행할 시 차원 감소로 인한 탐지 속도 개선 및 탐지 성능의 향상까지 기대할 수 있을 것으로 예상된다.

References

Du, Q. and H. Yang, 2008. Similarity-based unsupervised band selection for hyperspectral image analysis, *IEEE Geoscience and Remote Sensing Letters*, 5(4): 564-568.

Gerg, I., 2010. An evaluation of three endmember extraction algorithms: ATGP, ICA-EEA & VCA, *Proc. of 2010 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, Reykjavik, Iceland, Jun.14-16, pp. 1-4.

Harsanyi, J. C., 1993. Detection and classification of subpixel spectral signatures in hyperspectral image sequences, *Diss. University of Maryland Baltimore County*, 6372

Kraut, S., L. L. Scharf, and R. W. Butler, 2005. The adaptive coherence estimator: A uniformly most-powerful-invariant adaptive detection statistic, *IEEE Transactions on Signal Processing*, 53(2): 427-438.

Manolakis, D., D. Marden, and G. A. Shaw, 2003. Hyperspectral image processing for automatic target detection applications, *Lincoln Laboratory Journal*, 14(1): 79-116.

Nie, F., H. Huang, X. Cai, and C. H. Ding, 2010. Efficient and robust feature selection via joint $L_{2,1}$ -norms minimization, *In Advances in neural information processing systems*, 1813-1821.

- Ren, H. and C. Chang, 2003. Automatic spectral target recognition in hyperspectral imagery, *IEEE Transactions on Aerospace and Electronic Systems*, 39(4): 1232-1249.
- Shaw, G. A. and H. K. Burke, 2003. Spectral imaging for remote sensing, *Lincoln Laboratory Journal*, 14(1): 3-28.
- Sun, K., X. Geng, and L. Ji, 2015. A new sparsity-based band selection method for target detection of hyperspectral image, *IEEE Geoscience and Remote Sensing Letters*, 12(2): 329-333.
- Tibshirani, R., 1996. Regression shrinkage and selection via the lasso, *Journal of the Royal Statistical Society. Series B (Methodological)*, 267-288.
- Keshava, N., 2004. Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries, *IEEE Transactions on Geoscience and Remote Sensing*, 42(7): 1552-1565.
- Winkelmann, M., 2015. Spectral analysis of the vegetative background in the NIR and SWIR spectral range, *Proc. of SPIE Security+ Defence. International Society for Optics and Photonics*, Toulouse, France, Sep. 11-14, vol. 9653, pp. 96530D-96530D.
- Yang, H., Q. Du, H. Su, and Y. Sheng, 2011. An efficient method for supervised hyperspectral band selection, *IEEE Geoscience and Remote Sensing Letters*, 8(1): 138-142.
- Zhang, J., Y. Cao, L. Zhuo, C. Wang, and Q. Zhou, 2015. Improved band similarity-based hyperspectral imagery band selection for target detection, *Journal of Applied Remote Sensing*, 9(1): 095091-095091.