

기계학습을 이용한 Sentinel-2 산불피해등급 분류

Classification of Forest Fire Damage Grade Using Machine Learning and Sentinel-2

윤형진 Youn Hyoungjin**, 정종철 Jeong Jongchul**

Abstract

This study applies machine learning techniques to forest fire damage area. The study area was Sokcho, Gangwon-do, which occurred forest fire damage on April 4, 2019. We used Sentinel-2 images for detecting forest fire area. We adjusted four cases for train model based on the dNBR severity level classes. We used 4 SVM kernels, because the accuracy may vary depending on the structure of the data to learning. The training results showed that in all four cases, the SVM RBF model showed the highest accuracy. The SVM RBF model with the highest training accuracy was used in the test area classification process. During the verification process, we created 300 GTP using KOMPSAT-3 for verification. Verification results show that the test results using the SVM RBF model classified (82.67%) was more affected than dNBR classification result (80.67%). The results of the study suggested a direction to incorporate mechanical learning in the analysis process for detecting and classifying forest fire damage areas.

Keywords: Forest Fire, Machine Learning, SVM, Sentinel-2, KOMPSAT-3

I. 서론

국내 산불 피해지역 통계는 산불이 발생한 후 실측, 목측, 항공사진 및 1:2,500 지형도를 활용하고 있다. 하지만 실측 및 목측의 경우 산불 피해지역에 대한 인력이 다수 필요하며 항공사진도 산불 발생 이후 촬영허가 승인과 같은 부분에서 시간 및 비용이 소모된다. 통계과정에서 위성영상을 활용할 경우 산불 피해지역을 중심으로 넓은 면적을 다측면으로 분석 가능하며, 촬영 주기에 따른 시계열 변화탐지가 가능하다. 이러한 위성영상의 장점은 기존의 산불피해지역 통계

과정에 융합하게 될 경우보다 효과적인 분석으로 발전할 수 있다.

원격탐사 기반 산불 전후 피해면적은 식생의 감소를 기반으로 피해를 탐지하는 방법이 존재하며, 이는 정규식생지수(Normalized Difference Vegetation Index: NDVI)를 활용한 방법이 있다(원명수, 김경하, 이상우 2014). 또한 미국지질조사국(United States Geological Survey: USGS)은 NIR과 SWIR(Short Wave Infra-red) 기반의 정규탄화지수(Normalized Burned Ratio: NBR)을 활용하여 전후 시기 차영상 값과 실제 현장 조사결과와 융합해 산불 피해등급을 네 가지로 분류하는

* 남서울대학교 공간정보공학과 석사과정(제1저자) | M.S. Candidate, Dept. of Geographic Information Science, Namsseoul Univ. | Primary Author | popojj7@naver.com

** 남서울대학교 공간정보학과 교수(교신저자) | Prof., Dept. of Geographic Information Science, Namsseoul Univ. | Corresponding Author | jjc1017@gmail.com

dNBR 피해등급표를 제시하였다. 이러한 방법은 위성 영상을 활용하여 산불 피해를 분석하는 과정에서 사용되었다(Fransk, Masek and Turner 2013; Mira, Gunter and Thomas 2018; Ryu, Han, Hong and Park et al. 2018).

하지만 dNBR 피해등급표는 국외 산림을 기준으로 제작되었으며, 이를 국내 산림을 기준으로 산불피해 등급을 적용해 볼 필요성이 존재한다. 임룡혁(2020)은 위성영상을 활용해 2019년 4월 발생한 옥계지역의 산불 피해면적을 분류하였으며 피해면적을 실제 대외발표 면적과 비교해 약 2%의 오차 결과를 제시하여 국내 산불 피해지역 분석에 dNBR을 접합시키는 가능성을 제시하였다. 또한 이수진, 김광진, 김영호, 김지원 외(2017)에서는 국내 산림은 계절적 특징에 따라 변화하며, dNBR이 계절에 따른 민감성 문제가 있음을 제시하였고, 이를 개선하기 위한 FBI(Fire Burn Index)식을 Sentinel-2A 영상을 통해 제작한 바 있다.

산불에 대한 분석 과정에서 기계학습을 활용하는 방법 또한 현재 다양한 분석기법으로 진행 중에 있으나, 기존의 산불과 기계학습을 적용하는 과정에서는 산불이 발생할 수 있는 지역에 대한 예측 모델을 통한 연구, 즉 산불 발생 전에 산불을 예방하기 위한 방향의 연구로 진행된 바 있다(채경재, 이유리, 조용주, 박지현 2018). 하지만 국내 산불 피해지역을 분석하는 방법 중 기계학습을 접목하여 피해지역 통계를 산출하는 연구는 부족한 실정이다. 본 논문은 국내 산불 피해지역을 탐지하기 위해 기계학습을 접목해 국내 산불 피해지역을 분석하는 방법에 대한 연구를 진행하고자 하였으며, 본 논문에서 제안된 방법은 효과적으로 산불 피해지역 통계를 산출하기 위한 방안이 될 수 있다.

II. 연구 방법

1. 연구대상지

본 논문은 2019년 4월 4일 발생한 강원도 속초시와 강릉의 산불 피해지역을 대상으로 진행되었다. 강원도 고성-속초시 산불로 인해 전체적으로 약 1,757ha에 달하는 피해가 발생하였으며 산림뿐 아니라 주택, 시설물에 대한 2차적인 피해가 발생한 바 있다. 이처럼 연구지역은 단순 산림 피해뿐 아니라 주택과 같은 시가화 지역의 피해가 발생하였기 때문에 위성영상을 활용하여 단순 산림이 아닌 시가화와 산림이 공존하는 지역을 연구대상지로 선정하였다.

2. 사용 데이터

본 논문은 산불 피해등급을 분류하고 학습하는 과정에서 Sentinel-2 영상을 활용하였으며, 검증에 위해 고해상도 영상인 KOMSPAT-3 영상을 활용하였다(<Figure 1> 참조).

두 영상에 대한 분광 특성은 <Figure 2>와 같다. Sentinel-2 영상은 분광 밴드가 총 13개로 분류되며 그 중 적외선과 단파적외선이 세분화되어 식생과 같은 적외선에 민감한 대상을 분석하는 데 효과적이다. 산불피해 지역은 식생값 감소에 따른 피해탐지가 가능하기 때문에 Sentinel-2 영상을 활용하여 산불 지역을 분석하기 용이하며 이와 관련하여 다수의 선행연구에 사용되었다(Filipponi 2019; Roteta, Bastarrika, Padilla and Storm et al. 2019).

KOMPSAT-3 영상의 경우 70cm의 VHR(Very High-spatial Resolution)영상이며, Blue, Green, Red, NIR 밴드를 가진 광학 영상이다. 이러한 KOMPSAT-3 영상은 Sentinel-2 영상에 비해 육안 기반 검증자료를

Figure 1 _ Train and Test Area NIR-Red-Green Combination Images over Sokcho: Sentinel-2 (A, B, C) with dNBR and KOMSAT-3 (D)

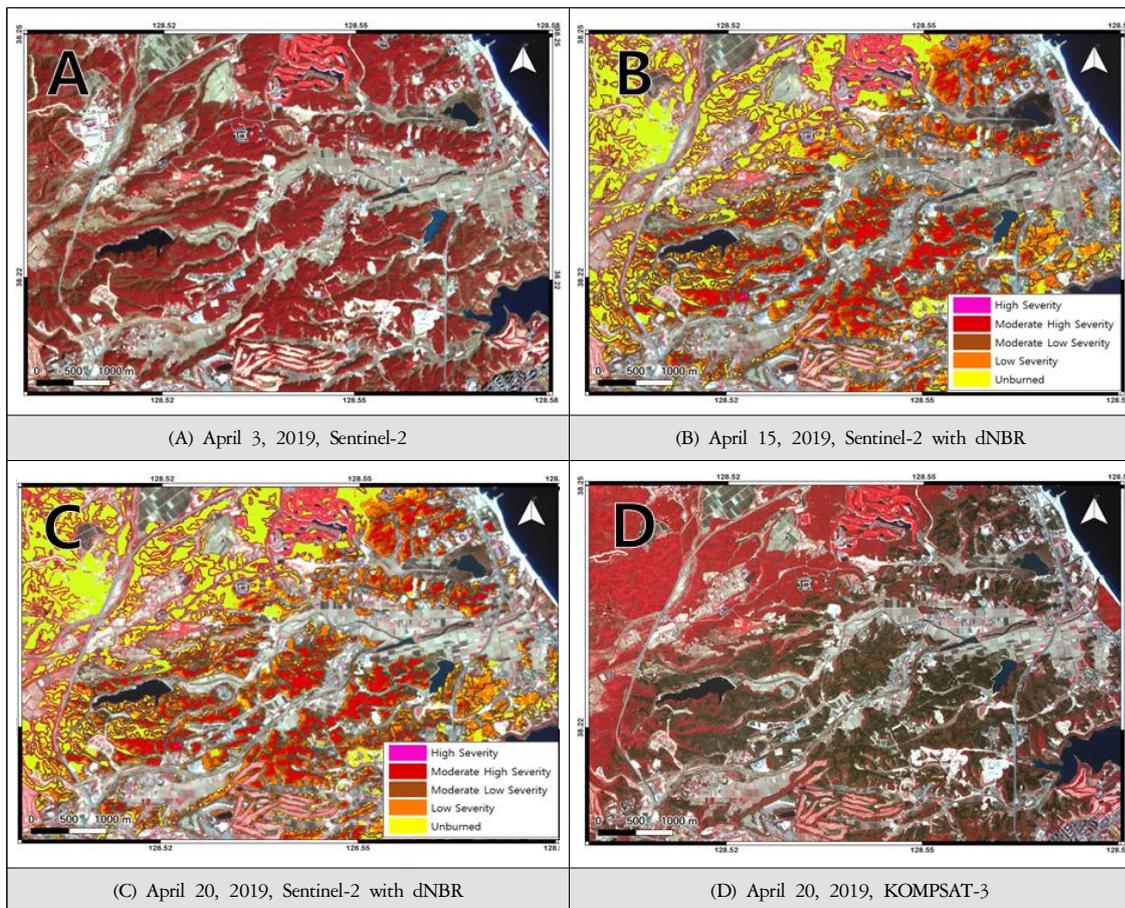
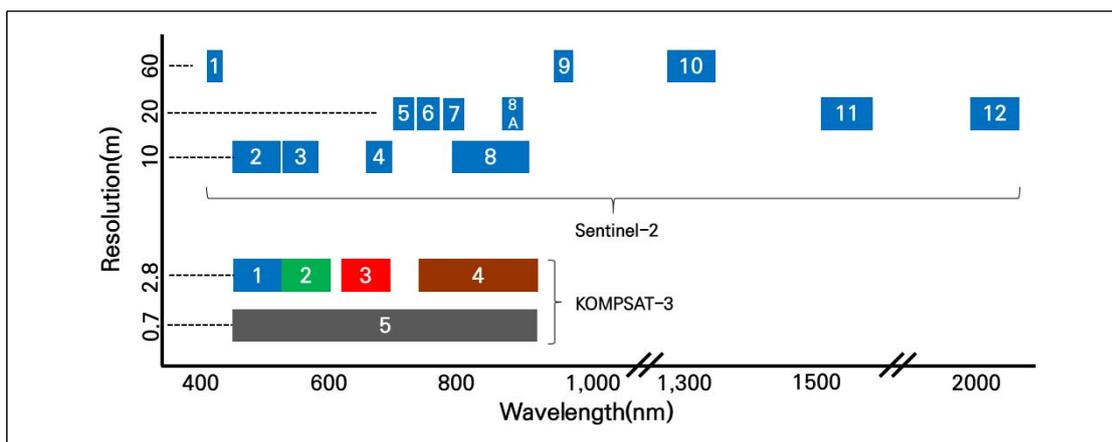


Figure 2 _ Comparison of Sentinel-2 and KOMSAT-3 Bands



제작하기 용이하며 본 논문에서는 이러한 고해상도 KOMPSAT-3를 기반으로 제작된 육안관독점 (Ground Truth Points, 이하 GTP)를 활용하여 연구 결과를 검증하는 방향으로 활용하였다.

3. 활용 알고리즘

1) NBR(Normalized Burn Ratio)

정규탄화지수(NBR)는 단파적외선과 근적외선의 합과 차를 이용하는 식으로 지역의 수분 함량에 따라 단파적외선 반사도에 차이를 보인다. 이러한 특성을 가지는 지수식은 산불의 전후 시기 차영상에서 급격한 식생 변화를 탐지할 수 있으며 이를 dNBR (difference Normalized burn Ratio)이라 한다. <식 1>은 NBR 밴드 분광식의 분광조합을 나타낸다.

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad \text{<식 1>}$$

$$dNBR = preNBR - postNBR \quad \text{<식 2>}$$

NBR은 근적외선 밴드와 단파적외선의 반사도 차이를 통해 산불 피해지역과 타지 않은 식생지역을 분류할 수 있다. 생성된 NBR은 산불탐지 등급 분류를 위해 산불 전시기와 후시기의 영상이 필요하다. NBR은 <식 2>와 같이 차영상 분석을 통해 dNBR로 표현된다. USGS에서 제시한 dNBR 산불 피해 등급표는 <Table 1>과 같다.

2) SVM(Support Vector Machine)

서포트 벡터 머신(SVM)은 기계학습 중 커널(Kernel)의 한 종류이며 바프닉(Vapnik)에 의해 1995년 제안되

었다. SVM은 n차원의 공간상에서 포함되어 있는 데이터를 구분하는 최적의 초평면을 생성하여 데이터를 분류하는 알고리즘이다(Vapnik 1995). n차원 공간에서 학습 데이터가 존재할 경우 두 개의 데이터 집합을 구분하는 최적의 초평면은 하나가 존재한다. 각 데이터 중 초평면에서 가장 가까운 데이터는 <식 3>과 같이 데이터 사이의 거리를 초기화할 수 있어야 한다. 데이터가 선형 분리가 가능할 경우 클래스를 정의하는 두 개의 초평면이 정의된다. 이때, 두 초평면상의 학습데이터를 서포트 벡터(Support Vector)라고 한다. 이러한 두 초평면은 사이의 마진을 최대화해야 하며 두 클래스의 초평면을 구하기 위해 <식 3>을 제약식으로 가지는 <식 4>와 같이 최솟값을 구해야 한다.

$$\begin{aligned} (\vec{w} \cdot \vec{x}) + b &= 0 & \text{<식 3>} \\ y_i(w \cdot x + b) - 1 &\geq 0 \end{aligned}$$

$$\min \frac{1}{2} \|\vec{w}\|^2 \quad \text{<식 4>}$$

하지만 대개의 데이터는 선형 분리가 가능하지 않다. 이는 기존에 제안된 SVM의 경우 선형 초평면을 기준으로 클래스를 분류하기 때문에 비선형 구조를 가지는 현실 데이터를 분류하기 위해서는 각각의 데

Table 1 _ Burn Severity Levels Obtained Calculating dNBR

| dNBR | Burn Severity |
|---------------|-------------------------|
| <-0.25 | High post-fire regrowth |
| -0.25 to -0.1 | Low post-fire regrowth |
| -0.1 to 0.1 | Unburned |
| 0.1 to 0.27 | Low severity |
| 0.27 to 0.44 | Moderate-low severity |
| 0.44 to 0.66 | Moderate-high severity |
| >0.66 | High severity |

Source: Key and Benson 2005.

이터에 맞는 임의의 커널 K를 적용하여 분류한다. 이러한 SVM은 안정성과 일반화 부분에서 강력한 성능을 보여주고 있으며, 커널을 활용한 비선형 분석이 가능하다(최재완, 변영기, 김용일, 유기운 2006).

SVM은 다양한 환경 분야 중 산불 관련 분야에서도 활용되었으며, 효과적인 결과를 도출할 수 있었다(Zhao, Jhang, Han and Qu et al. 2011; Bui, Le and Hoang 2018). 이러한 SVM 분류기법은 실용화 과정에서 적용하기 위해서 커널 함수와 매개변수 결과에 따른 실험이 필요하다(강남이, 고신영, 조기성 2013). 따라서 본 논문은 SVM의 4가지 커널을 활용하여 산불 피해지역에 대한 학습을 진행하였으며, <Table 2>는 SVM에서 사용되는 기본적인 선형 식과 비선형 식을 나열하였다.

4. 데이터 처리

본 논문의 흐름은 <Figure 3>과 같다. 학습 지역에 경우 2019년 4월 15일 영상 전체를 학습하였으며, 학습된 모델을 기반으로 2019년 4월 20일 영상을 테스트 하였다.

트 하였다. 기계학습 구축 환경의 경우 파이썬(Python) 기반의 아나콘다 환경을 구축하였다. 아나콘다는 콘다(conda), 파이썬 등과 같은 패키징을 포함하여 배포되는 소프트웨어다. 이러한 아나콘다(Anaconda)는 가상환경과 패키징 관리를 통해 프로젝트 개발 환경을 효과적으로 구성할 수 있는 장점이 존재한다. 본 논문에서는 아나콘다 환경에서 사이킷런(Scikit-learn) 라이브러리를 활용하였다. 사이킷런(Scikit-learn)은 넘파이(Numpy), 사이파이(Scipy) 및 매트플롯라이브러리(matplotlib)를 기반으로 데이터 마이닝, 데이터 분석에 효과적으로 활용 가능하며, 높은 접근성으로 다양한 상황에서 활용이 가능하다. 학습 데이터는 산불 발생 후의 피해지역에 대한 Sentinel-2

Table 2_SVM Kernel Formula

| Function | Formula |
|------------|---|
| Linear | $K(x_i, x_j) = x_i^T x_j$ |
| Polynomial | $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$ |
| RBF | $K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$ |
| Sigmoid | $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$ |

Source: Kang, Go and Jo 2013.

Figure 3_ Shows the Overall Methodology to Machine Learning of Forest Fire Damage Data

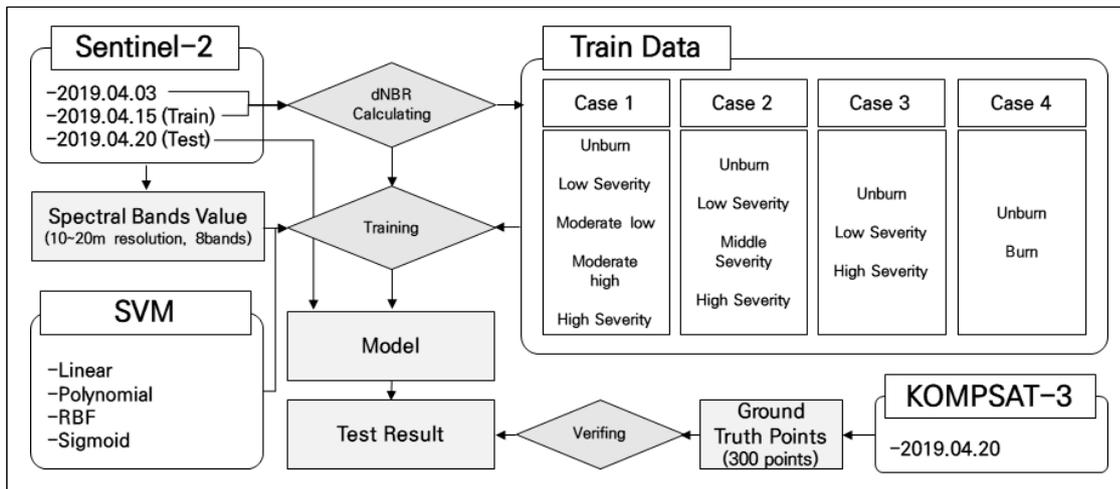


Table 3_dNBR Burn Severity Classification Term in This Study

| dNBR | Case 1 | | Case 2 | | Case 3 | | Case 4 | |
|--------------|---------------------------|-----------|-----------------|-----------|---------------|-----------|----------|-----------|
| | Class | Area (ha) | Class | Area (ha) | Class | Area (ha) | Class | Area (ha) |
| <0.1 | Unburned | 410.54 | Unburned | 410.54 | Unburned | 410.54 | Unburned | 410.54 |
| 0.1 to 0.27 | Low Severity | 240.11 | Low Severity | 240.11 | Low Severity | 387.14 | Burned | 546.28 |
| 0.27 to 0.44 | Moderate Low Severity | 147.03 | Middle Severity | 305.13 | | | | |
| 0.44 to 0.66 | Moderate High Severity | 158.10 | | | High Severity | 159.14 | | |
| 0.66> | High Severity | 1.04 | High Severity | 1.04 | | | | |

10~20m 해상도의 8개의 밴드값과 dNBR로 계산된 피해등급을 기준으로 네 가지의 케이스별로 학습하였다. 학습에 사용된 알고리즘은 SVM이며 4개의 커널 (Linear, Polynomial, RBF, Sigmoid)을 활용하였다. 이때 각 커널별 매개변수는 기본값을 활용하였다. 학습된 모델은 동일지역의 2019년 4월 20일 Sentinel-2 영상 분류 값을 통해 산불 피해지역 분류 결과를 제시하였다. 검증 단계에서는 기존의 dNBR과의 비교를 위해 테스트 영상과 동일한 촬영시기의 2019년 4월 20일 KOMPSAT-3 영상을 활용하여 제작된 300개의 GTP(Ground Truth Points)를 통해 정확도를 평가하였다.

III. 연구결과

1. 훈련지역 학습

학습에 사용된 영상은 2019년 4월 3일과 4월 15일을 통해 제작된 dNBR을 등급 조절을 통해 네 가지의 케이스로 구분하였다. <Table 3>은 본 논문에서 학습한 각 케이스별 dNBR분류 등급 및 학습 영역을 나타낸다. 케이스 구분에 따라 산불 피해등급을 한 단계씩 좁혀 가며 케이스 1은 dNBR과 같은 등급을 구분으로 학습하였으며, 케이스 4는 산불 피해가 발생했는지,

Table 4_Train Accuracy for Each Case

| Case | Train Acc(%) | | | |
|------|--------------|------------|-------|---------|
| | Linear | Polynomial | RBF | Sigmoid |
| 1 | 74.13 | 71.18 | 76.19 | 61.99 |
| 2 | 78.03 | 75.51 | 80.25 | 68.72 |
| 3 | 82.47 | 79.44 | 84.14 | 72.58 |
| 4 | 88.69 | 85.72 | 90.45 | 80.28 |

발생하지 않았는지에 대한 구분으로 실시하였다. 전체적으로 같은 영역을 기준으로 데이터 세트를 구축하였기 때문에 모든 케이스에 대해서 ‘연소되지 않음(Unburned)’은 동일한 면적이 학습되었다. 학습 데이터는 SVM의 네 가지 커널을 통해 각각의 케이스별 훈련을 진행하였으며, <Table 4>와 같은 학습 정확도로 나타났다. 모든 케이스에 대하여 SVM RBF 모델이 훈련지역을 학습한 결과에서 4개의 케이스 모두 가장 높은 학습정확도를 보여주는 것을 확인하였으며, 시그모이드(Sigmoid)는 가장 낮은 정확도를 보여주었다. 학습 데이터 훈련 결과에서는 산불 피해 등급을 세밀하게 구분할수록 낮은 정확도를 보여주는데 산불피해 유무만을 구분하는 케이스 4의 경우는 RBF에서 90.45%로 높은 정확도를 보여주지만 dNBR과 동일한 등급으로 구분하여 학습한 케이스 1의 경우에

는 동일한 RBF 기법에서 76.19%의 학습 정확도를 보여주었다.

2. 테스트 결과

훈련 데이터를 통해 학습된 모델 중 가장 높은 RBF 모델을 본 논문에서 사용하였다. 테스트를 위한 지역은 동일한 지역의 다른 시기의 산불 피해지역으로 전체적인 산불피해 양상은 비슷하지만 산불 피해면적이 감소한 지역이다. <Table 5>를 통해 2019년 4월 15일 훈련지역을 대상으로 dNBR과 SVM RBF에 대한 오차행렬을 제시하였으며, 모델을 통해 테스트한 각 케이스별 산불 피해 등급 분포도는 <Figure 4>와 같다.

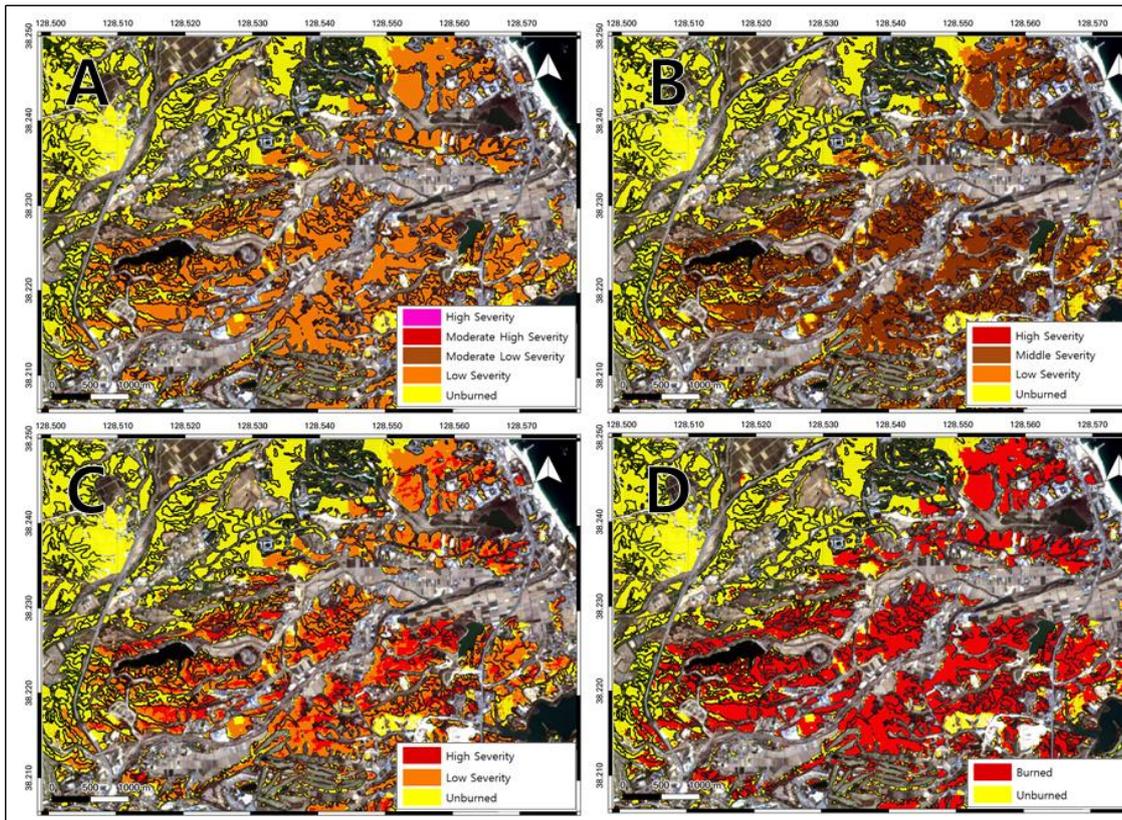
오차행렬에서 제시된 숫자는 훈련된 각각의 픽셀 수를 나타내며, 케이스 1의 경우 전체 등급분류 데이터 중 ‘심각한 피해(High Severity)’가 dNBR과의 비교

에서 생성되지 않은 것을 확인할 수 있다. ‘심각한 피해’ 등급의 경우 기존 학습단계에서 104개가 학습되었으며, 그 수가 다른 등급군에 비해 적어 모델상에서 상대적으로 분류에 대한 영향력이 크지 못한 경우로 판단된다. 케이스 2의 ‘심각한 피해’ 등급군 분류 결과에서도 동일한 결과로 나타나는데, 이는 케이스 1과 케이스 2에서 학습된 ‘심각한 피해’의 픽셀 수가 같기 때문이다 하지만 케이스 3과 같이 산불 피해 등급을 2가지로 구분한 경우에는 실제 모델을 통한 테스트 결과에서도 앞선 케이스들과는 다르게 모든 피해등급이 분류되는 것을 확인하였다. 이는 연구 대상지역에 대하여 네 가지 케이스들을 통한 모델 학습결과에서 dNBR 등급을 그대로 활용할 경우에 다른 지역에 적용하기 위해서는 기존의 등급을 조절해야 할 필요성을 나타내며 산불 등급을 2가지로 구분할 경우 dNBR과 유사한 등급으로 분류가 가능하다고 할 수 있다.

Table 5_Confusion Matrix between dNBR and SVM RBF Train Classification Results

| Case | dNBR(count of pixel) | | | | | |
|------|------------------------|---------------------|------------------------|------------------------|---------------|-----|
| | Unburned | Low Severity | Moderate low Severity | Moderate high Severity | High Severity | |
| 1 | Unburned | 35,470 | 4,626 | 201 | 1 | 0 |
| | Low Severity | 4,542 | 13,446 | 5,071 | 286 | 0 |
| | Moderate low Severity | 817 | 3,993 | 5,879 | 1,075 | 0 |
| | Moderate high Severity | 225 | 1,946 | 3,552 | 14,448 | 104 |
| | High Severity | 0 | 0 | 0 | 0 | 0 |
| | Unburned | Low Severity | Middle Severity | High Severity | | |
| 2 | Unburned | 35,468 | 4,623 | 2,204 | 0 | |
| | Low Severity | 3,905 | 11,625 | 3,424 | 0 | |
| | Middle Severity | 1,681 | 7,763 | 26,885 | 104 | |
| | High Severity | 0 | 0 | 0 | 0 | |
| | Unburned | Low Severity | High Severity | | | |
| 3 | Unburned | 34,637 | 4,274 | 0 | | |
| | Low Severity | 6,320 | 30,341 | 2,207 | | |
| | High Severity | 97 | 4,099 | 13,707 | | |
| | Unburned | Burned | | | | |
| 4 | Unburned | 34,615 | 4,251 | | | |
| | Burned | 6,439 | 50,377 | | | |

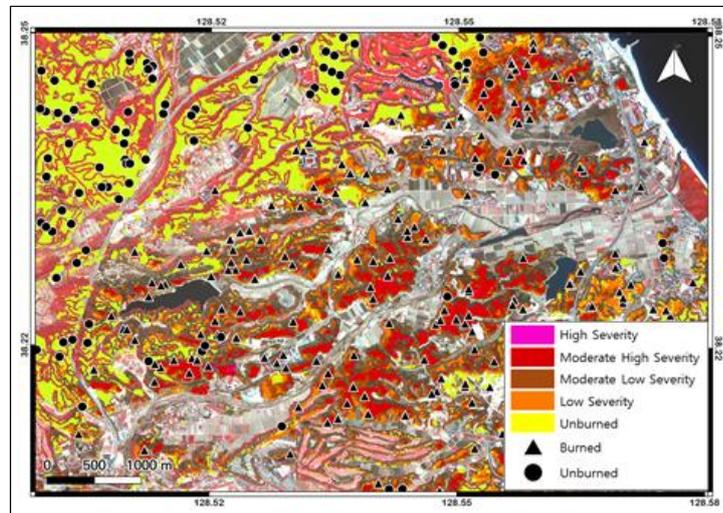
Figure 4 _ Test Image Results used SVM RBF Train Model Note: (A) Case1, (B) Case2, (C) Case3, (D) Case4



3. GTP 기반 검증 결과

연구 과정을 통해서 생성된 모델은 실제 dNBR의 분류 결과보다 산불 피해지역을 분류하는 과정에 있어서 개선된 부분에 대한 검증이 필요하며, 본 연구에서는 테스트 시기와 비슷한 촬영 일자인 KOMPSAT-3 영상을 기반으로 300개의 GTP를 제작하여 이를 비교하였다. GTP에 대한 공간적인 위치는 <Figure 5>와 같다.

Figure 5 _ Location of Ground Truth Points with KOMPSAT-3 Image and April 20th 2019 NBR Classification Result



GTP를 통해 2019년 4월 20일 Sentinel-2 dNBR 산불 피해지역 분류 결과와 SVM RBF 기반으로 테스트한 케이스 4에 대한 비교 검증을 진행하였으며 이는 <Table 6>과 같다. 제시된 검증 결과는 육안판독으로 제작된 GTP의 특성으로 인해 산불 피해지역을 구분하는 부분을 기준으로 검증을 진행하였다. 기존의 dNBR을 통한 산불 피해지역 분류 결과 전체적으로 80.67%로 준수한 분류 결과를 나타냈지만, SVM RBF를 기반으로 검증한 결과에서는 보다 향상된 82.67%의 전체 정확도가 나타났다. 또한 카파 계수 또한 dNBR보다 SVM RBF 테스트 결과에서 향상되었다. 오차행렬을 기반으로 생성된 정밀도, 재현율(=TPR, True Positive Rate), F 점수, FPR(False Positive Rate)의 경우에도 산불 비피해지역을 피해지역으로 분류하게 되는 FPR값을 제외하고 전체적으로 값이 상승되었음을 확인할 수 있었다. 이러한 통계 과정에서 산불 피해의 유무를 판단하는 분류의 경우에서 기존의 dNBR을 통한 분류보다 RBF 모델의 정확도 및 통계수치가

전반적으로 향상되었으며, 이를 통해 기계학습을 통해 제작된 모델이 산불 피해 분류 과정에서 효과적으로 활용될 수 있다.

IV. 결론 및 향후 과제

본 논문에서는 2019년 4월 4일 발생한 속초 산불을 대상으로 Sentinel-2 영상을 활용하여 산불 피해등급을 분류하고 이를 학습하여 피해면적을 재분류하는 연구를 진행하였다. 산불 피해지역은 산불 발생 후 민감한 근적외선과 단파적외선을 활용하여 산불 피해지역을 분류하지만 이는 단순 분광값 계산으로 오분류 지역이 존재할 수 있으며 이를 기계학습 중 SVM의 다양한 커널을 활용하여 진행하였다. 기계학습과 산불 등급을 접합시키는 과정에서 얻은 결론은 다음과 같다.

산불 피해등급을 기존에 USGS에서 제공된 dNBR을 기반으로 피해등급을 조절하여 네 가지 케이스별 학습을 진행하였다. 학습 과정에서 SVM RBF 모델이 가장 우수한 훈련 정확도를 보여주었으며, 피해등급 구분이 많아질수록 분류 정확도는 낮아지는 추세로 나타났다. 생성된 모델을 기반으로 KOMPSAT-3을 활용하여 만든 GTP를 통해 검증하였을 때, 단순 dNBR을 적용한 산불 피해지역보다 SVM RBF 테스트 결과가 향상된 정확도를 보여주는 것을 확인하였다.

현재 분광식을 기반으로 제시되는 산불피해등급 분류 및 피해지역 탐지의 경우 두 시기의 영상을 활용하는 과정에서의 화소값의 민감성 차이, 피해지역 탐지를 위한 전처리 작업이 동반된다. 이를 기계학습을 활용하여 훈련된 모델로 제시할 경우, 기존의 dNBR의 분류에서 전·후시기 영상을 모두 활용하는 과정을 간소화할 수 있으며, 추가되는 영상을 모델에 학습함으로써 개발된 모델을 제시할 수 있다. 따라서 본 논

Table 6 _ Confusion Matrix using GTP for comparing dNBR and SVM RBF Test Results

| Methods | | Ground Truth | | |
|----------------------------|----------|-----------------|------|-------|
| | | Unburn | Burn | Total |
| dNBR | Unburned | 85 | 43 | 128 |
| | Burned | 15 | 157 | 172 |
| | Total | 100 | 200 | 300 |
| Overall Accuracy: 80.67% | | kappa: 0.593457 | | |
| RBF | Unburned | 86 | 38 | 124 |
| | Burned | 14 | 162 | 176 |
| | Total | 100 | 200 | 300 |
| Overall Accuracy: 82.67% | | kappa: 0.632075 | | |
| Index | dNBR | SVM RBF | | |
| Precision | 0.66 | 0.69 | | |
| Recall | 0.85 | 0.86 | | |
| F-score | 0.75 | 0.77 | | |
| False Positive Rate | 0.22 | 0.19 | | |

문에서 진행된 연구의 경우 영상의 화소 값만을 활용하여 산불 피해등급 분류 모델을 구축하였지만, 화소 값과 더불어 산불 피해지역의 고도자료 및 피해 당시의 기상요인 등 다양한 공간적인 요인들과 같이 학습을 할 경우, 정확한 모델이 제시될 수 있다. 또한 본 논문에서 진행된 검증 자료는 육안판독 기준의 산불 피해지역 유무에 대한 정보를 가지고 있는 GTP로 모델 분류 결과에 대해 산불 유무에 대한 검증만 가능하였으며, 분류된 결과를 현장조사 결과와 더불어 피해 등급에 대한 검증을 진행해야 할 필요가 있다.

참고문헌

1. 강남이, 고신영, 조기성. 2013. KOMPSAT-2 영상의 토지 피복분류에 적합한 SVM 커널 함수 비교 연구. 한국지형공간정보학회지 21권, 2호: 17-23.
Kang Namyi, Go Sinyoung and Cho Gisung. 2013. A comparative study on suitable SVM kernel function of land cover classification using KOMPSAT-2 imagery. *Journal of Korean Society for Geospatial Information Science* 21, no.2: 17-23.
2. 이수진, 김광진, 김영호, 김지원, 이양원. 2017. Sentinel-2 영상 기반의 FBI(Fire Burn Index) 개발 및 우리나라 산불 피해지역 탐지 실험. 한국사진지리학회지 27권, 4호: 187-202. <http://doi.org/10.35149/jakpg.2017.27.4.012>
Lee Soojin, Kim Kwangjin, Kim Yeongho, Kim Jiwon and Lee Yangwon. 2017. Development of FBI(Fire Burn Index) for Sentinel-2 images and an experiment for detection of burned areas in Korea. *Journal of the association of Korean photo-geographers* 27, no.4: 187-202. <http://doi.org/10.35149/jakpg.2017.27.4.012>
3. 임륜혁. 2020. 재난지역 피해규모 산정을 위한 위성영상과 국토지표 활용방안. 세종: 국토연구원.
Im Ljunghyeok. 2020. *How to Use Satellite Images and National Land Indicators to Estimate the Amount of Damage in a Disaster Area*. Sejong: Korea Research Institute for Human Settlements.
4. 원명수, 김경하, 이상우. 2014. SPOT5 영상과 현장조사자료를 융합한 대형산불지역의 피해강도 분석. 한국농림기상학회지 16권, 2호: 114-124. <http://doi.org/10.5532/KJAFM.2014.16.2.114>
Won Myoungsoo, Kim Kyoungaha and Lee Sangwoo. 2014. Analysis of burn severity in large-fire area using SPOT5 images and field survey data. *Korean Journal of Agricultural and Forest Meteorology* 16, no.2: 114-124. <http://doi.org/10.5532/KJAFM.2014.16.2.114>
5. 채경재, 이유리, 조용주, 박지현. 2018. 머신러닝과 샘플링을 이용한 강원도 지역 산불발생예측모형 개발. 한국빅데이터학회지 3권, 2호: 71-78. <http://doi.org/10.36498/kbigdt.2018.3.2.71>
Chae Kyongjae, Lee Yur, Cho Yongju and Park Jihyun. 2018. Development of a Gangwon province forest fire prediction model using machine learning and sampling. *The Journal of Bigdata* 3, no.2: 71-78. <http://doi.org/10.36498/kbigdt.2018.3.2.71>
6. 최재완, 변영기, 김용일, 유기운. 2006. 분광 유사도 커널을 이용한 하이퍼스펙트럴 영상의 Support Vector Machine (SVM) 분류. 대한공간정보학회지 14권, 4호: 71-77.
Choi Jaewan, Byun Younggi, Kim Yongil and Yu Kiyun. 2006. Support vector machine classification of hyperspectral image using spectral similarity Kernel. *Korean Society for Geospatial Information Science* 14, no.4: 71-77.
7. Bui, D. T., Le, H. V. and Hoang, N. D. 2018. GIS-based spatial prediction of tropical forest fire danger using a new hybrid machine learning method. *Ecological Informatics* 48: 104-116. <https://doi.org/10.1016/j.ecoinf.2018.08.008>
8. Filippini, F. 2019. Exploitation of Sentinel-2 time series to map burned areas at the national level: A case study on the 2017 Italy wildfires. *Remote Sens* 11, no.6: 622. <https://doi.org/10.3390/rs11060622>
9. Fransk, S., Masek, J. G. and Turner, M. G. 2013. Monitoring forest regrowth following large scale fire using satellite data: A case study of Yellowstone National Park, USA. *European Journal of Remote Sensing* 46, no.1: 551-569. <https://doi.org/10.5721/EuJRS20134632>
10. Key, C. H. and Benson, N. C. 2005. Landscape assessment: ground measure of severity, the composite burn index; and remote sensing of severity, the normalized burn ratio. In *FIREMON: Fire Effects Monitoring and Inventory System*. eds Lutes, D. C., Keane, R. E., Caratti, J. F., Key, C. H., Benson, N. C. and Gangi, L. J. Fort Collins: USDA Forest

Service, Rocky Mountains Research Station General Technical Report in Press.

11. Mira, W., Gunter, Z. and Thomas, S. 2018. Automated delineation of wildfire areas using Sentinel-2 Satellite Imagery. *GI Forum* 1: 251-262. https://doi.org/10.1553/giscience2018_01_s251
12. Roteta, E., Bastarrika, A., Padilla, M., Storm, T. and Chuvieco, E. 2019. Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. *Remote Sensing of Environment* 222: 1-17. <https://doi.org/10.1016/j.rse.2018.12.011>
13. Ryu, J. H., Han, K. S., Hong, S. W., Park, N. W., Lee, Y. W. and Cho, J. I. 2018. Satellite-based evaluation of the post-fire recovery process from the worst forest fire case in South Korea. *Remote Sens* 10, no.6: 918. <https://doi.org/10.3390/rs10060918>
14. Vapnik, V. N. 1995. *The Nature of Statistical Learning Theory*. New York: Springer-Verlag.
15. Zhao, J., Jhang, Z., Han, S., Qu, C., Yuan, Z. and Zhang, D. 2011. SVM based forest fire detection using static and dynamic features. *Computer Science and Information Systems* 8, no.3: 821-841.

- 논문 접수일: 2020. 7. 9.
- 심사 시작일: 2020. 7. 29.
- 심사 완료일: 2020. 9. 23.

요약

주제어: 산불, 기계학습, SVM, Sentinel-2, KOMPSAT-3

본 논문은 산불 피해 발생 지역을 대상으로 머신러닝 기법을 적용한 연구이다. 연구 대상지로는 2019년 4월 4일 발생한 강원도 속초 지역의 산불피해지역을 대상으로 분석을 진행하였다. 산불 피해지역을 탐지하기 위해 Sentinel-2 영상을 활용하였다. 산불 피해 등급을 분류하는 dNBR을 기반으로 피해등급을 4가지 경우로 조정하여 학습하였다. 학습에 사용된 데이터의 경우 데이터의 구조에 따라 정확도가 다르게 나타날 수 있기 때문에 SVM 4가지 커널에 따른 학습 정확도를 도출하였다. 학습 결과 4가지 경우 모두에

서 SVM RBF 모델이 가장 높은 정확도를 보여주었다. 테스트 지역을 분류하는 과정에서는 훈련 정확도가 가장 높게 나타난 SVM RBF 모델을 활용하였다. 검증 과정에서는 KOMPSAT-3를 활용한 300개의 GTP를 구축하여 검증자료로 활용하였다. 검증결과에서 SVM RBF 모델을 통한 테스트 결과가 dNBR보다 높은 82.67%의 정확도로 피해지역을 분류한 것으로 나타났다. 연구 결과를 통해 산불 피해지역을 탐지하고 분류하는 분석과정에서 기계학습을 접목할 수 있는 방향성을 제시하였다.

