

GOCI 영상과 기계학습 기법을 이용한 *Cochlodinium polykrikoides* 적조 탐지 기법 연구

앵호자리갈 운자야* · 박수호* · 황도현* · 정민지* · 김나경* · 윤홍주**

Study on Detection for *Cochlodinium polykrikoides* Red Tide using the GOCI image and Machine Learning Technique

Enkhjargal Unuzaya* · Su-Ho Bak* · Do-Hyun Hwang* · Min-Ji Jeong* · Na-Kyeong Kim* · Hong-Joo Yoon

요약

본 연구에서는 적조 *Cochlodinium Polykrikoide*를 기계학습 방법과 정지궤도 해상위성 영상을 활용하여 탐지하는 방법을 제안한다. 기계학습 모형을 학습시키기 위해 GOCI Level2 자료를 활용하였으며, 국립수산물품질관리원의 적조 속보 자료를 활용하였다. 기계학습 모델은 로지스틱 회귀모형, 의사결정나무 모형, 랜덤포레스트 모형을 사용하였다. 성능 평가 결과 기계학습을 사용하지 않은 전통적인 GOCI 영상 기반 적조 탐지 알고리즘 (Son et al., 2012) (75%)과 비교해보았을 때 약 13~22%p (88~98%)의 정확도 향상을 확인할 수 있었다. 또한 기계학습 모형 간 탐지 성능을 비교 분석해본 결과 랜덤 포레스트 모형(98%)이 가장 높은 탐지 정확도를 보였다. 이러한 기계학습 기반 적조 탐지 알고리즘은 향후 적조를 조기에 탐지하고 그 이동과 확산을 추적 모니터링하는데 활용될 수 있을 것이라고 판단된다.

ABSTRACT

In this study, we propose a method to detect red tide *Cochlodinium Polykrikoide* using by machine learning and geostationary marine satellite images. To learn the machine learning model, GOCI Level 2 data were used, and the red tide location data of the National Fisheries Research and Development Institute was used. The machine learning model used logistic regression model, decision tree model, and random forest model. As a result of the performance evaluation, compared to the traditional GOCI image-based red tide detection algorithm without machine learning (Son et al., 2012) (75%), it was confirmed that the accuracy was improved by about 13~22%p (88~98%). In addition, as a result of comparing and analyzing the detection performance between machine learning models, the random forest model (98%) showed the highest detection accuracy. It is believed that this machine learning-based red tide detection algorithm can be used to detect red tide early in the future and track and monitor its movement and spread.

키워드

Red Tide, Ocean Color Remote Sensing, COMS/GOCI, Decision Tree, Machine Learning
적조, 해수색 원격 탐사, 정지 궤도 해상 위성, 로지스틱 회귀 모형, 의사 결정 나무, 기계 학습

* 부경대학교 지구환경시스템과학부
(unuzaya.e@gmail.com, rupine725@hanmail.net,
shbak91@pukyong.ac.kr, hming34@pukyong.ac.kr,
gnknk8852@gmail.com)

** 교신저자 : 부경대학교 공간정보시스템공학과

• 접수일 : 2020. 10. 30
• 수정완료일 : 2020. 11. 23
• 게재확정일 : 2020. 12. 15

• Received : Oct. 30, 2020, Revised : Nov. 23, 2020, Accepted : Dec. 15, 2020

• Corresponding Author : Hong-Joo Yoon

Division of Earth Environmental System Science Major of Spatial Information
Engineering, Pukyong National University,

Email : yoonhj@pknu.ac.kr

1. 서론

적조 현상은 식물 플랑크톤이 특정 환경조건에서 대량 증식함으로써 해수가 붉게 변색되는 현상으로 알려져 있다. 그러나 적조 원인 생물인 식물 플랑크톤의 종류에 따라 붉은색 이외의 변색 형태도 존재하며, 해수의 색을 변화시키지 않는 낮은 생물밀도에서 어패류를 독화시키는 현상이 지속적으로 보고되고 있다. 따라서 2001년부터 적조현상의 피해에 초점을 두어 해양에서 식물 플랑크톤 대량증식이 생물에게 물리적 피해를 야기하는 현상을 통틀어 유해적조(HAB; Harmful Algal Bloom)라는 용어로 정의하고 있다[1].

한국의 경우 고려사, 조선왕조실록 등 과거 문헌에도 적조 현상이 기록된 바 있으며, 과학적인 보고로는 1967년이 최초이다[2]. 한국에서는 *Cochlodinium polykrikoides*(이후 *C. polykrikoides*)로 인해 매년 여름과 가을철(7~10월)에 발생하고 있다. 1995년에는 *C. polykrikoides*로 인해 약 750억원의 경제적 손실이 발생한 사례가 있다. 한국의 적조 발생사를 되짚어볼 때, 1980년대까지는 주로 규조류(Diatoms)에 의한 적조가 남해 연안 일부 해역에서 일시적으로 발생하였으나[2], 1990년대에 들어 비교적 유해성이 높은 와편모조류(Dinoflagellates)에 의한 적조 발생 비율이 급격히 증가하고 있다.

와편모조류는 편모조류(Phytoplankton)의 일종으로 두 개의 편모를 가지고 운동력을 지니고 있어 한번 대발생을 일으키면 저층의 높은 영양조건에서 지속적으로 영양분을 공급받아 장기간, 넓은 해역에서 적조 현상을 지속시킬 수 있다[3]. *C. polykrikoides*는 무독성 와편모조류로 알려져 있으나, 대량발생을 일으켰을 경우 어류의 아가미에 달라붙어 질식사시킴으로써 양식업에 큰 경제적 손실을 입하고 있다.

적조 원인생물의 대량증식 메커니즘에 대해서 이미 많은 연구들이 진행되었으나, *C. polykrikoides*의 경우 대량증식에 유리한 환경 조건의 일부만 파악되어 있는 상황이다. 해양화학, 해양생태학, 해양물리학적 요인들이 복합적으로 상호작용한 결과로 발생하는 현상이거나 적조의 발생을 예측하는 것은 현재의 연구결과들만으로는 어렵다[4]. 따라서 이러한 적조의 특성상 적조발생의 사전예측보다는 조기식별 및 지속적인 추적 모니터링을 통한 신속대응이 효율적이다[4, 5].

그러나 기존의 적조 탐지 및 모니터링 방법은 주로 현장에서 직접 채수한 시료를 실험실에서 분석하여 식별하는 방법으로 적조의 발생여부 및 원인 종 파악에 상당한 시간이 소요된다. 또한 이러한 관별법은 해당분야의 숙련된 전문 인력이 필요한 작업으로 광범위한 해역에 적용하기에는 시간적, 경제적으로 비효율적이다. 따라서 발생 범위가 공간적으로 광범위한 *C. polykrikoides* 적조를 모니터링하기에는 인공위성을 이용한 원격탐사가 효율적이다[6].

인공위성 원격탐사를 이용할 경우 광범위한 해역을 단시간에 탐지 및 모니터링 할 수 있으며, 적은 인력과 비용으로 시각적인 결과물을 얻을 수 있다는 장점이 있다. 또한 COMS(Communication, Ocean and Meteorological Satellite)와 같은 정지궤도 위성을 이용할 경우 하루 8회 촬영을 통한 준 연속 모니터링이 가능하여 적조방제 능력을 향상시킬 수 있다.

초기의 인공위성 원격탐사를 이용한 적조 탐지 기법 연구는 주로 해색위성 영상이나 고해상도 육상관측 위성을 통해 추정된 Chlorophyll-*a* 농도와 Chlorophyll-*a* 농도 anomaly를 이용하여 시도되었다[7-10]. 이러한 방법은 적조가 발생하지 않은 일정기간의 Chlorophyll-*a* 농도 평균값을 기준으로 anomaly를 계산하여 특이값을 가지는 픽셀을 추출하는 기법으로 현재 NOAA(: National Oceanic and Atmospheric Administration)에서 공식적인 적조탐지 기법으로 사용되고 있다. 그러나 이 방법은 단순히 식물 플랑크톤의 증식으로 인한 Chlorophyll-*a* 농도 변화를 이용한 것으로 대량발생을 일으킨 식물 플랑크톤이 유해성인지 무해성인지 구분하지 못한다는 단점을 가지고 있다. 또한 대부분의 해색위성 산출물에 적용되는 Chlorophyll-*a* 산출 알고리즘들은 해수의 색이 식물 플랑크톤에 의해서만 결정되는 맑은 해수(Case-1)에 중점을 두고 개발되어 용존 유기물 및 부유물질의 농도가 높은 우리나라 연안 해역에서는 그 정확도가 낮다는 단점이 있다[11-13]. 한국의 연안에서 발생한 적조는 용존 유기물 및 부유물질의 영향으로 짧은 파장의 가시광선에서 흡광이 증가하여 위성에서 추정된 Chlorophyll-*a* 농도가 과대추정된다[12].

최근에는 이러한 Chlorophyll-*a* 농도 기반 탐지 기법의 단점을 개선하고자 해수의 광학적 특성인 IOP(: Inherent Optical Properties)와 AOP(: Apparent

Optical Properties)를 이용하여 시도하고 있다[4, 11, 14, 15]. IOP란 해수의 고유한 광특성으로 외부의 광학적 환경에 관계없이 일정한 값을 가지는 흡광계수(Absorption coefficient; a), 산란계수(Scattering coefficients; b), 감쇠계수(Attenuation coefficient; c) 등이 있다. AOP는 해수면의 광학적 환경 특성에 따라 그 값이 변할 수 있는 외형적 광특성으로 수출광량(Water leaving radiance; L_w), 원격반사도(Remote sensing reflectance; R_{rs}) 등이 있다. 이러한 광특성을 파악함으로써 해수 중의 물질 종류와 양을 추정할 수 있다[6, 16, 17]. 그러나 이 방법은 배경이 되는 해양의 가시광선 스펙트럼과 적조의 스펙트럼 형태 차이를 이용한 것으로 탐지 대상이 되는 식물 플랑크톤의 광학적 특성을 미리 알고 있다는 가정 하에서 제한적으로 사용이 가능하다. 또한 용존 유기물 및 부유물질의 농도가 높은 해수(Case-2)의 광학적 특성은 식물 플랑크톤 외의 다른 물질(용존 유기물, 부유물질)의 농도에 따라서 크게 변화하기 때문에 실험실에서 얻어진 광학적 특성과 실제 관측되는 광학적 특성 간에 차이가 발생할 수 있다. 뿐만 아니라 충분히 많은 상황에서 얻어진 탐지 대상의 스펙트럼을 얻어낸 다 하더라도 배경 해수의 본래 스펙트럼 형태에 따라 변색 패턴이 상이하기 때문에 모든 상황에 대처 가능한 탐지 식을 생산하는 것은 어렵다. 따라서 이런 복잡한 배경 해수에서 발생한 적조를 탐지하고 해결하기 위해 기계학습 기반 적조 탐지 알고리즘 개발 연구가 이루어지고 있다. 기계학습 모형은 인과관계 대신 데이터와 자연현상 간의 상관관계를 활용하기 때문에 인과관계를 모르는 상태에서 모델 개발이 가능하다[18]. 그러나 기계학습 기반 분류 알고리즘을 개발할 경우 학습 데이터셋의 불균형 데이터 문제가 발생할 수 있다[19]. 따라서 본 연구에서는 이런 문제를 해결하기 위해 회귀모형 또는 회귀모형이 포함된 모형들을 이용해서 적조를 탐지하는 방법을 제안했다.

II. 자료 및 방법

2.1 연구지역

국립수산과학원의 적조 데이터를 바탕으로 적조가 발생한 가장 넓은 곳 또는 탁수가 가장 많다고 알려

져 있는 남해 연안을 연구 지역으로 선택하였다 (그림 1).

또한 남해안 유해성 적조의 중요한 특성 중 하나는 지역적으로 국한되지 않고 남해 연안 및 동해 및 서해 연안 해역까지 확산되면서 많은 피해를 주는 것이다.




그림 1 한국의 남해 연안
Fig. 1 South sea of South Korea

그래서 지역적으로 국한된 조사만으로는 유해성 적조의 조기 탐지 및 모니터링에 한계가 있기 때문에 위성을 활용한 자료 제공이 필수적이다[11].

연구 자료는 GOCI (Geostationary Ocean Color Imager) 영상을 활용하였으며 GOCI는 가시광선 영역의 6개 채널과 근적외 영역의 2개 채널을 가지고 있다(표1). 그리고 해양 환경은 세계 최초의 정지궤도 위성으로 한반도 주변 2500km x 2500km 해양 수역을 500m x 500m의 공간 정확도로 관측하고, 정지궤도에서 하루 8번 한반도를 공전한다. 또한 적조 발생 위치를 얻기 위해 국립수산과학원에서 제공하는 적조속보 자료를 사용했다.

표 1. GOCI 밴드 구성
Table 1. Band Composition of GOCI

| Band | Centroid Wavelength (nm) | Bandwidth (nm) |
|------|--------------------------|----------------|
| 1 | 412 | 20 |
| 2 | 443 | 20 |
| 3 | 490 | 20 |
| 4 | 555 | 20 |
| 5 | 660 | 20 |
| 6 | 680 | 10 |
| 7 | 745 | 20 |
| 8 | 865 | 40 |

2.2 기계학습 모형

본 연구에서는 *C.polykrikoides*를 기계학습 방법과 정지레도 해석 위성 영상을 활용하여 탐지하는 방법을 제안하고자 하며 기계학습 모형을 시키기 위해 GOCI Level 2 자료를 활용하였다. 그리고 국립수산과학원의 적조 속보 자료를 사용하였다. 기계학습 모델은 회귀 모형, 의사결정 나무 모형, 랜덤 포레스트 모형을 이용했다.

회귀모형은 독립 변수의 선형 결합을 이용하여 사건의 발생 가능성을 예측하는데 사용되는 통계 기법이다. 목적은 일반적인 회귀 분석의 목표와 동일하게 종속 변수와 독립 변수간의 관계를 구체적인 함수로 나타내어 향후 예측 모델에 사용하는 것이다. 본 연구에서는 회귀모형을 포함한 후진 소거법 및 전진 선택법 및 단계적 선택법을 이용하여 기계학습 모형을 각각 만들었다. 이런 회귀모형을 포함한 회귀모형들은 설명 변수의 선택 방법에 따라 모형의 성능에 영향을 받을 수 있다.

의사결정나무 모형은 어떤 항목에 대한 관측값과 목표값을 연결시켜주는 예측 모델로서 결정 트리를 사용한다. 또한 트리 모델 중 목표 변수가 유한한 수의 값을 가지는 것을 분류 트리라고 한다. 결정 트리 중 목표 변수가 연속하는 값, 일반적으로 실수를 가지는 것은 회귀 트리라고 한다. 의사결정 분석에서 결정 트리는 시각적으로 명시적인 방법으로 의사 결정 과정과 결정된 의사를 보여주는 데 사용된다. 또는 데이터 마이닝 분야에서 결정 트리는 결정된 의사보다는 자료 자체를 표현하는데 사용된다.

랜덤 포레스트는 분류, 회귀 분석 등에 사용되는 앙상블 학습 방법의 일종으로, 훈련 과정에서 구성한 다수의 결정 트리로부터 분류 또는 평균 예측치를 출력함으로써 동작한다.

랜덤 포레스트의 가장 큰 특징은 랜덤성(randomness)에 의해 서로 조금씩 다른 특성을 갖는다는 점이다. 이 특성은 각 트리의 예측들이 decorrelation 되게 하며, 결과적으로 일반화 성능을 향상시킨다. 또한 랜덤화는 노이즈가 포함된 데이터에 대해서도 강인하게 만들어 준다. 랜덤화는 각 트리의 훈련 과정에서 진행되며, 랜덤 학습 데이터 추출 방법을 이용한 앙상블 학습법은 bagging과 랜덤 노드 최적화가 자주 사용된다. 이 두 가지 방법은 서로 동시에 사용되어 랜덤화 특성을 더욱 증진 시킬 수 있다.

2.3 적조탐지 모형 생성

본 연구에서는 국립수산과학원에서 제공하는 적조 발생 해역도를 지오레퍼런싱한 결과 자료 위도 및 경도값을 위치 정보로 활용하였다. 또한 적조가 발생한 해역의 GOCI Level 2 수출광량 분광 프로파일을 속성값으로 이용해서 진행하였다.

HABs 및 nonHABs 데이터에 imbalance 환경이 조성되어서 이 문제를 해소하기 위해 샘플 수가 적은 적조는 오버샘플링 (HABs 2,412개에서 100,000개까지)을 수행하였고 적조가 아닌 데이터는 언더샘플링(청수의 경우 906,001개에서 50,000개까지, 탁수의 경우 915,372개에서 50,000개까지)을 수행하여 데이터의 불균형 문제를 해결하였다. 이를 기반으로 학습 자료량 검증 자료를 산출했다. 따라서 전체 200,000개 데이터셋(HABs과 nonHABs 각각 100,000개)의 80%를 학습 자료로, 20%를 검증 자료 및 모형 평가 자료로 사용하였다. 그 다음으로 기계학습 모형에 적용하였다. 결과 정확도 평가는 오차행렬(Confusion Matrix, 표 2)을 이용해서 확인하였다(그림 2).

2.4 정확도 평가

본 연구에서는 분류 정확도를 평가하기 위해 오차행렬(Confusion Matrix, 표 2)을 이용한 전체 정확도를 평가 측도로 사용하였다.

이 때, 전체 정확도(Accuracy)는 식 (1)과 같이 정의된다.

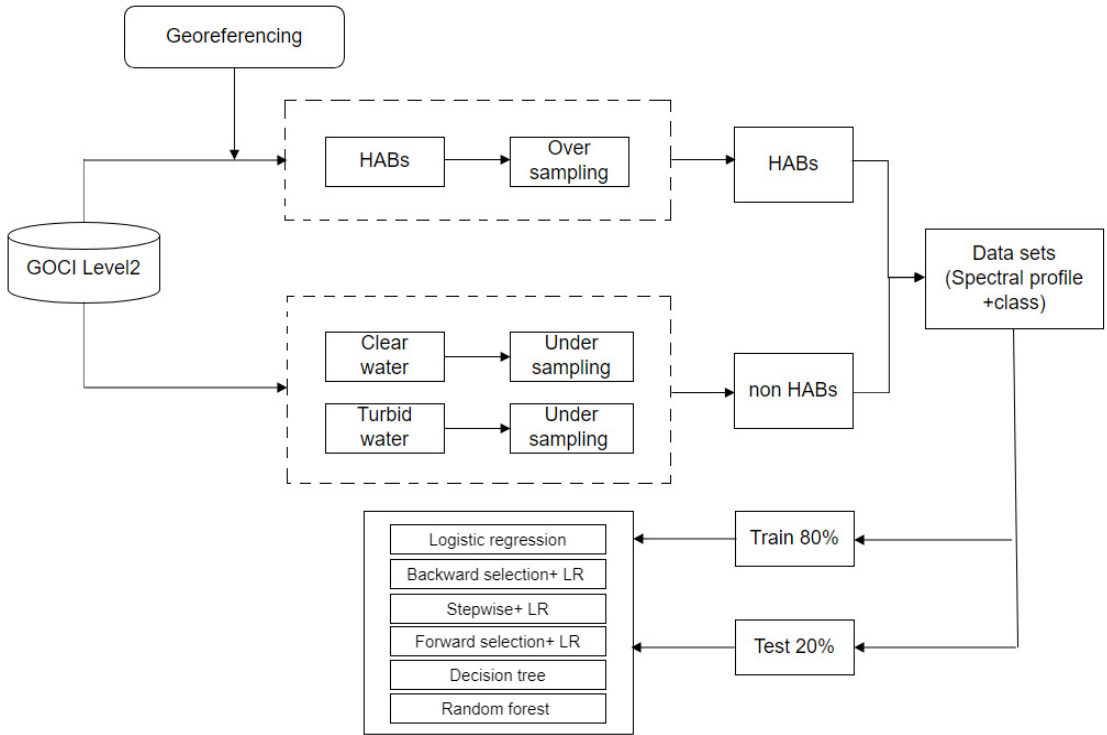


그림 2. 연구 흐름도
Fig. 2 Flow chart of research

표 2. 오차행렬
Table 2. Confusion Matrix

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN}$$

(i)

| | | Prediction | |
|-----------|-------|------------|-------|
| | | True | False |
| Reference | True | TP | FN |
| | False | FP | TN |

※ TP : True Positive / FP : False Positive
FN : False Negative / TN : True Negative

TP와 TN는 모델이 실제 클래스로 정확하게 분류한 사례 수이며, FP와 FN는 모델이 클래스를 혼동한 사례의 수이다. 따라서 정확도는 모델이 검증 데이터셋을 분류한 결과 중 정확하게 맞춘 사례의 비율을 뜻하게 된다.

기계학습 모형의 경우 일반적으로 데이터셋을 특정 비율로 나누어 그 일부를 학습용 데이터로 사용하며, 나머지를 검증용 데이터로 사용한다.

III. 결과 및 고찰

본 연구의 연구지역은 남해 연안으로 한국에서 적조가 많이 발생하고 해수가 case 2로 적조 탐지가 가장 어렵고 복잡하다. 연구 자료로 GOCI Level 2 자료와 국립 수산과학원의 적조 속보 자료를 사용하였다. 기계학습 모델은 회귀 모형, 의사결정나무 모형, 랜덤포레스트 모형을 이용했다. 회귀 모형에서는 후진 소거법 및 전진 선택법 및 단계적 선택법을 이용하여 기계학습 모형을 각각 만들어보았다. (표 3) 계산을 R 스튜디오로 하였다.

표3에 나와 있는 결과를 비교해보면 랜덤 포레스트 모형을 빼고 나머지 모형들의 정확도가 전체적으로 유사하고(89, 90, 89, 88%) TP(17548, 17802, 17696, 17548, 18183,) 및 FP 값도 (2501, 2381, 2487, 2501, 1866,) 큰 차이를 보이지 않았다. 그러나 TN(18375, 1589, 1519, 18375, 17243) 및 FN(1594, 18228, 18298, 1594, 2708) 값들의 큰 차이를 보여주는 것을 확인할 수 있었다.

가. 변수 선택법을 적용하지 않은 회귀모형과 전진 선택법을 활용한 회귀모형을 비교해 보았을 때, 정확도 결과가 크게 다르지 않은 것을 확인할 수 있었고 전진 선택법을 적용한 회귀 모형인 경우에 TP 및 FN의 관측값이 더 높고 변수 선택법을 적용하지 않은 회귀모형의 경우에는 FP 및 TN의 값이 높게 나타났다.

나. 변수 선택법을 적용하지 않은 회귀모형과 후진 소거법을 활용한 회귀모형을 비교해 보았을 때 정확도 값이 회귀모형의 경우 0.8976 이었으며 후진 소거법을 활용한 회귀모형의 경우에는 0.8998이다. 두 모

형은 큰 차이가 없는 것을 보여주지만 FN 값이 후진 소거법을 활용한 회귀모형에 18298이라는 값이 나왔고 변수 선택법을 적용하지 않은 회귀모형 경우에는 1594로 훨씬 더 낮게 나타난 것을 확인할 수 있었다. 그러나 TN 값은 반대로 후진 소거법을 활용한 회귀모형은 변수선택법을 적용하지 않은 회귀모형보다 낮게 나타났다.

다. 변수선택법을 적용하지 않은 회귀모형과 단계적 선택법을 활용한 회귀 모형의 결과는 모두 동일하였다.

라. 전진 선택법을 활용한 회귀모형과 후진 소거법을 활용한 회귀모형의 ACC 값은 전진 선택법을 활용한 회귀모형의 경우에 0.9008 이었으며, 후진 소거법을 활용한 회귀모형의 경우에는 0.8998로 나타났다. 그러나 오차행렬값에는 큰 차이가 없는 것으로 나타났다.

마. 전진 선택법을 활용한 회귀모형과 단계적 선택법을 활용한 회귀모형을 비교해 봤을 때 ACC 값은 큰 차이가 없었던 것을 확인할 수 있었고 TN과 FP 값들을 보면 전진 선택법을 활용한 회귀모형이 더 높게 나타났다. 그러나 FN과 TP 값은 단계적 선택법을 활용한 회귀모형의 결과가 상대적으로 높게 나타난 것을 확인할 수 있었다.

바. 후진 소거법을 활용한 회귀 모형과 단계적 선택법을 활용한 회귀모형을 비교해보면 ACC 값은 거의 동일하지만 TN과 FN 값들이 많은 차이를 보였다.

사. 의사결정나무 모형의 경우 ACC 값은 0.8856으로 나타났고 TP 값은 회귀모형 보다 높게 나타난 것을 볼 수 있었다. 의사결정나무 모형의 경우 complexity parameter 값을 따라 결과의 효율적인지를 확인할 수 있다. 본 논문에서는 0, 0.005, 0.01, 0.02, 0.03, 0.04, 0.05으로 계산해 봤을 때 CP=0.005 경우에 가장 타당한 결과를 보였다 (88.56%).

아. 랜덤 포레스트의 특징을 따라 ntree 값을 1로 선택해서 랜덤 포레스트 모델을 만들었다. 랜덤 포레스트 정확도가 가장 높은 0.9863값을 보여준 것을 확인할 수 있었다.

표 3. 정확도 결과
Table 3. Result of accuracy

| | model | CP | ntree | TP | TN | FP | FN | ACC |
|---|--|-------|-------|-------|-------|------|-------|--------|
| 1 | Regression model | 0.005 | | 17548 | 18375 | 2501 | 1594 | 0.8976 |
| 2 | Regression model using forward selection method | | | 17802 | 1589 | 2381 | 18228 | 0.9008 |
| 3 | Regression model using backward elimination method | | | 17696 | 1519 | 2487 | 18298 | 0.8998 |
| 4 | Regression model using stepwise selection method | | | 17548 | 18375 | 2501 | 1594 | 0.8976 |
| 5 | Decision tree | | | 18183 | 17243 | 1866 | 2708 | 0.8856 |
| 6 | Random forest | | 1 | 78942 | 78860 | 1009 | 1189 | 0.9863 |

CP : Complexity parameter
ACC : Accuracy
ntree : number of trees

IV. 결 론

본 연구에서는 위성 자료로 GOCI Level 2 자료를 활용하였으며 적조의 발생한 위치를 얻기 위해서 국립수산과학원의 적조 속보 자료를 사용해서 적조 탐지 기계학습 모형을 제안했다. 기계학습 모형으로 6가지 모형을 생성해서 확인했으며 (표 3) 성능 평가 결과 기계학습을 사용하지 않은 전통적인 GOCI 영상 기반 적조 탐지 알고리즘(75%)과 비교해보았을 때 약 13~22%p (88~98%)의 정확도 향상을 확인할 수 있었다. 또한 기계학습 모형 간 탐지 성능을 비교 분석해 본 결과 랜덤 포레스트 모형(98%)이 가장 높은 탐지 정확도를 보였다. 회귀모형과 의사결정 나무 모형은 정확도가 대부분 88~90% 사이로 나타났다.

이러한 기계학습 기반 적조 탐지 알고리즘은 향후 적조를 조기에 탐지하고 그 이동과 확산을 추적 모니터링에 활용될 수 있을 것이라고 판단된다.

감사의 글

이 연구는 기상청 「미래유망 민간기상서비스 성장기술개발」(KMI2019-00510)의 지원으로 수행되었습니다.

References

- [1] D. Anderson, P. Anderson, V. Bricelj, J. Cullen, and J. Rensel, *Monitoring and Management Strategies for Harmful Algal Blooms in Coastal Waters*. Paris: Intergovernmental Oceanographic Commission Technical Series, 2001.
- [2] H. Kim, *Harmful Algal Blooms in the Sea*. Busan: Dasom, 2005.
- [3] Y. Yoon, *Sea rebellion, Red tide*. Paju: Jipmoondang, 2012.
- [4] Y. Kim, Y. Byun, Y. Huh, and Y. Yu, "Detection of *Cochlodinium polykrikoides* Red Tide Using MODIS Level 2 Data in Coastal Waters," *Korean Society of Civil*

- Engineers Journal of Civil Engineering*, vol. 27, no. 4D, 2007, pp. 535-540.
- [5] S. Oh, J. Park, and H. Yoon, "Prediction of Red Tide Occurrence by using Oceanic and Atmospheric Data by Satellite," *J. of the Korean institute of Electronic Communication Sciences*, vol. 10, no. 2, 2015, pp. 311-318.
- [6] Y. Ahn, J. Moon, W. Seo, and H. Yoon, "Inherent Optical Properties of Red Tide Algal for Ocean Color Remote Sensing Application," *J. of the Korean Society for Marine Environmental Engineering*, vol. 12, no. 1, 2009, pp. 47-54.
- [7] R. Stumpf, M. Culver, P. Tester, M. Tomlinson, G. Kirkpatrick, B. Pederson, E. Truby, V. Ransibrahmanakul, and M. Soracco, "Monitoring *Karenia brevis* blooms in the Gulf of Mexico using satellite ocean color imagery and other data," *Harmful Algae*, vol. 2, no. 2, 2003, pp. 147-160.
- [8] M. Tomlinson, R. Stumpf, V. Ransibrahmanakul, E. Truby, G. Kirkpatrick, B. Pederson, G. Vargo, and C. Heil, "Evaluation of the use of SeaWiFS imagery for detecting *Karenia brevis* harmful algal blooms in the eastern Gulf of Mexico," *Remote Sensing of Environment*, vol. 91, no. 3, 2004, pp. 293-303.
- [9] Y. Suh, L. Jang, N. Lee, and J. Ishizaka, "Feasibility of Red Tide Detection Around Korean Waters Using Satellite Remote Sensing," *J. of Fisheries Science and Technology*, vol. 7, no. 3, 2004, pp. 148-162.
- [10] J. Ishizaka, Y. Kitaura, Y. Touke, H. Sasaki, A. Tanaka, H. Murakami, T. Suzuki, K. Matsuoka, and H. Nakata, "Satellite Detection of Red Tide in Ariake Sound, 1998-2001," *J. of Oceanography*, vol. 62, no. 1, 2006, pp. 37-45.
- [11] Y. Son, Y. Kang, and J. Ryu, "Monitoring Red Tide in South Sea of Korea(SSK) Using the Geostationary Ocean Color Imager(GOCI)," *Korean J. of Remote Sensing*, vol. 26, no. 5, 2012, pp. 531-548.
- [12] Y. Ahn and P. Shanmugam, "Detecting the red tide algal bloom from satellite ocean color observations in optically complex Northeast-Asia Coastal waters," *Remote Sensing of Environment*, vol. 103, no. 4, 2006, pp. 419-437.
- [13] Y. Son, J. Ishizaka, J. Jeong, H. Kim, and T. Lee, "Cochlodinium polykrikoides red tide detection in the South Sea of Korea using spectral classification of MODIS data," *Ocean Science Journal*, vol. 46, no. 4, 2011, pp. 239-263.
- [14] S. Bak, H. Kim, D. Hwang, H. Yoon, and W. Seo, "Detection technique of Red tide Using GOCI Level 2 Data," *Korean J. Remote Sensing*, vol. 32, no. 6, 2016, pp. 673-679.
- [15] S. Bak, H. Kim, D. Hwang, S. Oh, and H. Yoon, "Red Tide Detection Technique by Using Multi-temporal GOCI Level 2 Data," *Internation J. of Grid and Distributed Computing*, vol. 10, no. 10, 2017, pp. 45-56.
- [16] H. Kim, S. Jang, and H. Yoon, "Utilization of Unmanned Aerial Vehicle(UAV) Image for Detection of Algal Bloom in Nakdong River," *J. of the Korean institute of Electronic Communication Sciences*, vol. 12, no. 3, 2017, pp. 457-464.
- [17] S. Bak and H. Yoon, "Analysis on optical property in the South Sea of Korea by using Satellite Image : Study of Case on red tide occurrence in August 2013," *J. of the Korean institute of Electronic Communication Sciences*, vol. 11, no. 7, 2016, pp. 723-728.
- [18] S. Bak, M. Jeong, D. Hwang, U. Enkhjargal, N. Kim, and H. Yoon, "Study on *Cochlodinium polykrikoides* Red tide Prediction using Deep Neural Network under Imbalanced Data," *J. of the Korean Institute of Electronic Communication Sciences*, vol. 14, no. 6, 2019, pp. 1161-1170.
- [19] S. Bak, H. Kim, D. Hwang, U. Enkhjargal, B. Kim, and H. Yoon, "Study on Detection Technique for *Cochlodinium polykrikoides* Red tide using Logistic Regression Model under Imbalanced Data," *J. of the Korean Institute of Electronic Communication Sciences*, vol. 13, no. 6, 2018, pp. 1353-1363.

저자 소개



**앵흐자리갈 운자야
(Enkhjargal Unuzaya)**

2014년 몽골 과학기술대학교 정보 및 전기통신기술학과 졸업(공학사)

2020년 현재 부경대학교 대학원 지구환경시스템과학부(석사과정)

※ 관심분야 : 무선 통신, 해양원격탐사, GIS



김나경(Na-Kyeong Kim)

2020년 부경대학교 공간정보시스템공학과 졸업(공학사)

2020년 현재 부경대학교 대학원 지구환경시스템과학부(석사과정)

※ 관심분야 : 해양 원격탐사, Deep Learning



박수호(Su-Ho Bak)

2013년 부경대학교 공간정보시스템공학과 졸업(공학사)

2017년 부경대학교 공간정보시스템공학과 졸업(공학석사)

2020년 현재 부경대학교 대학원 지구환경시스템과학부(박사수료)

※ 관심분야 : 해양 원격탐사, GIS



윤홍주(Hong-Joo Yoon)

1983년 부경대학교 해양공학과 졸업(공학사)

1985년 부경대학교 대학원 해양학과 졸업(공학석사)

1997년 프랑스 그르노블 I 대학교 대학원 위성원격탐사전공 졸업(공학박사)

1999년~2002년 여수대학교 해양공학과 교수

2002년~현재 부경대학교 공간정보시스템공학 교수

2012년~2013년 부경대학교 공간정보연구소 초대 소장

2013년 (사)한국클라우드센터터파크 이사

2014년 한국전자통신학회 부회장

2015년 공간정보 Big Data 센터장

2015년 행정공간정보화연구소 소장

2016년 (사)한국생태공학회 회장

※ 관심분야 : 해양 원격탐사, GIS



황도현(Do-Hyun Hwang)

2011년 부경대학교 공간정보시스템공학과 졸업(공학사)

2013년 부경대학교 대학원 공간정보시스템공학과 졸업(공학석사)

2018년 현재 부경대학교 대학원 지구환경시스템과학부 공간정보시스템공학전공(박사수료)

※ 관심분야 : 해양원격탐사, GIS



정민지(Min-Ji Jeong)

2017년 부경대학교 해양학과 졸업(이학사)

2020년 현재 부경대학교 대학원 지구환경시스템과학부 공간정보시스템공학과(석사과정)

※ 관심분야 : 해양 원격탐사

