

Watershed Algorithm-Based RoI Reduction Techniques for Improving Ship Detection Accuracy in Satellite Imagery

Seung Jae Lee[†] · Ji Won Yoon^{††}

ABSTRACT

Research has been ongoing to detect ships from offshore photographs for a variety of reasons, including maritime security, identifying international trends, and social scientific research. Due to the development of artificial intelligence, R-CNN models for object detection in photographs and images have emerged, and the performance of object detection has risen dramatically. Ship detection in offshore photographs using the R-CNN model has also begun to apply to satellite photography. However, satellite images project large areas, so various objects such as vehicles, landforms, and buildings are sometimes recognized as ships. In this paper, we propose a novel methodology to improve the performance of ship detection in satellite photographs using R-CNN series models. We separate land and sea via marker-based watershed algorithm and perform morphology operations to specify RoI one more time, then detect vessels using R-CNN family models on specific RoI to reduce typology. Using this method, we could reduce the misdetection rate by 80% compared to using only the Fast R-CNN.

Keywords : Coastline Extraction, Satellite Image, R-CNN, Watershed Algorithm

인공 위성 사진 내 선박 탐지 정확도 향상을 위한 Watershed 알고리즘 기반 RoI 축소 기법

이 승 재[†] · 윤 지 원^{††}

요 약

해상 안보, 국제 동향 파악 등 다양한 이유로 해상 사진에서 선박을 탐지하고자하는 연구는 지속되어 왔다. 인공지능의 발달로 인해 사진 및 영상 내 객체 탐지를 위한 R-CNN 모델이 등장하였고 객체탐지의 성능이 비약적으로 상승하였다. R-CNN 모델을 이용한 해상 사진에서의 선박 탐지는 인공위성 사진에도 적용되기 시작하였다. 하지만 인공위성 사진은 넓은 지역을 투사하기 때문에 선박 외에도 차량, 지형, 건물 등 다양한 객체들이 선박으로 인식되는 경우가 있다. 본 논문에서는 R-CNN 계열 모델을 이용한 인공위성 사진에서의 선박 탐지의 성능을 개선하기 위한 새로운 방법론을 제안한다. 표지자 기반 watershed 알고리즘을 통해 육지와 바다를 분리하고 morphology 연산을 수행하여 RoI를 한 차례 더 특정한 뒤 특정한 RoI에 R-CNN 계열 모델을 사용하여 선박을 탐지하여 오탐을 줄인다. 해당 방법을 이용하여 Faster R-CNN을 사용하였을 경우, Faster R-CNN만을 사용했을 때에 비해 오탐률을 80% 줄일 수 있었다.

키워드 : 해안선 추출, 인공위성 사진, R-CNN, Watershed 알고리즘

1. 서 론

사진과 영상으로부터 기계가 스스로 객체를 감지하고 검출하는 컴퓨터 기술인 객체 탐지는 지금까지도 활발히 연구되고 있는 연구주제이다.

Canny et al[1]은 이미지 혹은 영상에서의 경계를 탐지하

기 위한 고성능 영상 처리 기법을 제안하였다. Harris et al. [2]은 경계선의 교차점인 모서리를 탐지하는 기법을 제안하여 이미지 혹은 영상에서 객체의 특징을 더욱 강하게 잡아내는 방법을 제안하였다. Viola[3]가 제안한 Haar-like 특징은 영역간의 밝기 차를 이용하여 객체와 배경을 구분하는 방법으로, 실시간 인물 탐지기에 활용되었다. 이후 Dalal et al[4]은 대상 영역을 분할하여 히스토그램을 구하고 이를 연결하여 객체를 식별하는 HOG 알고리즘을 통해 객체를 식별하고 탐지하고자 하였으며, David et al.[5]은 코너 등 특징들을 중심으로 특징 벡터를 추출하여 객체를 식별하고자 하였다.

[†] 준 회원 : 고려대학교 정보보호대학원 석사과정

^{††} 정 회원 : 고려대학교 정보보호대학원 교수

Manuscript Received : January 11, 2021

First Revision : April 9, 2021

Accepted : May 17, 2021

* Corresponding Author : Ji Won Yoon(jiwon_yoon@korea.ac.kr)

이미지 및 영상에서 발견되는 특징들을 중심으로 객체를 식별하고자 하는 연구가 진행되는 한편, 많은 연산을 빠르게 수행할 수 있는 고성능 하드웨어와 다양한 정보들을 수집할 수 있는 센서들이 등장하게 되고, 딥러닝에 관한 연구가 활발하게 이루어졌다. 딥러닝의 발달은 다양한 분야의 높은 성능의 증가로 이어졌는데, 특히 이미지/영상 분류의 경우 CNN(Convolutional Neural Network)의 등장으로 이전에 비할 수 없을 정도로 높은 성능을 보장할 수 있게 되었다.

CNN의 등장 이후 Girshick et al.[6]는 딥러닝 모델을 통해 객체가 발견될 수 있는 위치를 유추하고 객체를 분류할 수 있는 R-CNN 모델을 제안하였다. 이후 Girshick et al.[7]은 RoI(Region of Interest) pooling을 활용한 fast R-CNN을 제안하여 R-CNN에 비해 속도와 성능을 높일 수 있었고 Ren et al.[8]은 fast R-CNN에서 활용하던 selective search를 없애고 RPN(Region Proposal Network)개념을 도입함으로써 GPU를 통한 더 빠르고 정확한 결과를 도출하는 모델인 faster R-CNN을 제안하였다.

이후에도 객체가 탐지되는 위치와 객체를 분류하는 네트워크를 통합하여 만들어진 YOLO[9], SSD[10] 등의 모델이 제안되고 있으며 지금도 객체 탐지를 위한 네트워크가 활발히 연구되고 제안되고 있다.

객체 탐지에 관한 연구가 활발히 진행되며 영상과 이미지 속에서 객체를 탐지하고자 하는 시도는 위성 사진으로까지 확대되었다. 위성 사진은 넓은 영역에 대해 각 객체 및 자연현상들의 변화 추이를 관측할 수 있다는 점에서 데이터 과학, 자연과학, 사회과학 등 다양한 영역에서 유용하게 활용되고 있다. 특히 선박 탐지의 경우 해상 안보, 국제 동향 파악과 같이 안보적, 외교적으로 매우 중요하며 인공 위성 사진을 통해 관심해역의 선박을 파악함으로써 많은 문제들을 해결할 수 있다. 하지만 위성 사진은 굉장히 높은 해상도로 다양한 환경 및 상황에서 촬영되기 때문에 동일한 위치와 동일한 고도에서 촬영한 사진이라도 햇빛, 구름, 그림자, 수질, 기상, 시간 등 다양한 요소가 위성 사진에 영향을 준다.

이런 환경요인으로 인해 위성 사진의 객체 탐지 성능을 높이는 연구는 지금도 어려운 주제로 다뤄지고 있으며 활발히 연구 중이다. 특히 위성 사진에서의 선박 탐지는 높은 해상도와 다양한 선박 종류로 인해 육지의 구조물, 차량, 건물 등 선박이 아닌 객체들로 인해 오탐이 빈번하게 발생한다.

본 논문에서는 해안선을 탐지하고 분리하여 선박이 관측될 수 있는 해역을 특정함으로써 위성 사진에서 선박 탐지 시 발생하는 오탐을 효과적으로 줄이는 방안을 제안한다. 해안선 분리의 경우, Di et al.[11]은 mean shift segmentation 알고리즘을 활용하여 해안선을 분리하는 방법을 제안했다. Chunli et al.[12]은 NDWI(Normalized Difference Water Index)를 바탕으로 해안선을 자동으로 분리하는 방법에 대해 제안하였으며, Kilian et al.[13]이 구글 어스를 기반으로 위성 사진의 해안선을 탐지하는 연구를 진행하였다. 또한 Vasilis et al.[14]는 엣지 검출을 활용한 해안선 탐지 자동화

기법에 대해 제안하였다.

하지만 기존에 제안된 해안선 탐지/분리 방법들은 많은 연산을 요구하기 때문에 시간이 많이 소요될 뿐만 아니라 사진/영상의 픽셀 분포가 해당 기법들을 적용하기 부적절한 경우 해안선을 분리해내지 못할 수 있다. 따라서 본 논문에서는 watershed 알고리즘을 활용하여 해안선을 효율적으로 분리하는 방법을 제시한다.

Watershed 알고리즘은 기존의 다른 해안선 분리 연구에 비해 훨씬 적은 연산을 요구하기 때문에 속도가 빠른 뿐만 아니라 다른 방법보다 더 높은 정확도로 해안선을 분리할 수 있기 때문에 선박이 관측될 수 있는 복잡한 해안 영역에서도 효과적인 성능을 보인다.

2. 배경 지식

2.1 Watershed 알고리즘

Watershed 알고리즘은 1979년 Beucher, S[15]에 의해 처음으로 제안되었다. 회색조 이미지를 지형으로 인식하여 이미지를 나누는 알고리즘으로, 이미지 분할(Image segmentation)에 자주 사용되는 알고리즘 중 하나이다.

Watershed 알고리즘은 영상 혹은 이미지의 회색조 픽셀 값에 따라 높은 값은 봉우리(peak)로, 낮은 값은 골짜기(valley)로 인식하며, 각 독립된 골짜기들에 다른 색의 물을 채워넣기 시작한다. 각 골짜기들의 물은 점점 차올라 인접한 봉우리에서 다른 색의 물들은 만나게 되는 순간 경계선이 형성된다. 이 때 생성된 경계선이 watershed 알고리즘에 의해 분리된 결과를 나타낸다.

하지만 바로 watershed 알고리즘을 사용할 경우 과다분할(oversegmentation)이 발생할 수 있기 때문에 추가적인 전처리를 통해 성능을 더욱 높일 수 있으며 대표적인 방법으로 표지자(Marker) 기반 watershed 알고리즘이 있다.

표지자 기반 watershed 알고리즘은 전경 혹은 객체가 확실하다고 판단되는 영역에 라벨을 붙이고 배경이 확실하다고 판단되는 영역에도 라벨을 붙인다. 이후 watershed 알고리즘을 수행함으로써 과다분할을 방지하고 분리하고자 하는 배경과 객체 혹은 전경을 구분해낼 수 있다.

2.2 Morphology 연산

Morphology 연산은 이미지 영상 분야에서 활용되는 형태학적 연산을 가리키며, 영상 내 물체의 구조를 명확히 하고 추출하기 위한 영상의 분리, 전처리 과정에서 활용된다. 처음엔 이진 영상을 대상으로 제안되었으나 회색조 영상에도 Morphology 연산을 적용할 수 있도록 확장되었다.

기본적으로 팽창(dilation)과 침식(erosion) 연산을 활용하며 응용 연산으로는 열림(opening), 닫힘(closing), 그래디언트(gradient), 탐햇(tophat), 블랙햇(blackhat) 등의 연산이 있다.




Fig. 1A. Example of Erosion Operation




Fig. 1B. Example of Dilation Operation

기본 연산인 침식 연산과 팽창 연산은 커널 혹은 마스크로 불리는 필터를 설정하고, 입력 영상에 대해 필터 크기만큼을 윈도우 크기로 설정한 후 슬라이딩 윈도우 방식으로 미끄러지며 연산을 수행한다.

이진 영상에서의 침식 연산의 경우 윈도우 크기의 입력 영상과 필터와 비교했을 때 필터의 1인 원소들에 대응되는 입력 영상의 픽셀이 모두 일치하면 1을, 그렇지 않으면 0을 지정한다. 침식 연산은 영상 내 물체의 잡음을 제거하고 돌출부를 제거하는 데 활용된다.

팽창 연산의 경우 윈도우 크기의 입력 영상과 필터와 비교했을 때 필터의 1인 원소들에 대응되는 입력 영상의 픽셀중 1개 이상 일치하면 1을, 모두 일치하지 않으면 0을 지정한다. 팽창 연산은 영상 속에서 객체 내부의 잡음은 줄어 들고, 객체 외부의 잡음은 커지는 효과를 가져온다.

열림 연산은 침식 후 팽창을 수행함으로써 잡음을 제거하고 윤곽선을 부드럽게 만들어주며 닫힘 연산은 팽창 후 침식을 수행함으로써 물체의 크기는 보존하며 내부 구멍을 메워 주는 효과를 가진다. 이 외에도 그래디언트, 탑햇, 블랙햇은 아래와 같이 Equation (1)~(3)으로 표현된다.

$$gradient = dilate(src) - erode(src) \quad (1)$$

$$tophat = src - open(src) \quad (2)$$

$$blacrhath = close(src) - src \quad (3)$$

2.3 딥러닝을 활용한 객체 탐지

객체 탐지는 영상 혹은 사진에 나타난 다수의 객체에 대해 분류와 위치를 탐지하는 것을 동시에 수행하는 작업이다.

현재까지 제안된 객체 탐지를 위한 탐지기는 1단계 검출기(1-stage detector)와 2단계 검출기(2-stage detector)가 있다. 2단계 검출기는 selective search와 같은 알고리즘 혹은 RPN과 같은 네트워크를 통해 객체가 관측될 수 있는 영역인 RoI를 먼저 확보한 후, 도출된 RoI에 대해 CNN을 활

용하여 분류와 위치 탐지를 수행한다. 반면, 1단계 검출기는 RoI를 추출하지 않고 입력받은 영상에 대해 바로 분류와 위치 파악을 수행한다. 이러한 특성 때문에 1단계 검출기는 속도가 빠르지만 2단계 검출기만큼 정확도가 높지 않다.

2단계 검출기의 대표적인 예시로 R-CNN 계열 모델이 있다. R-CNN은 CNN을 활용하여 객체를 탐지하였다는 점에서 주목을 받았으며 R-CNN의 등장 이후 Fast R-CNN을 거쳐 Faster R-CNN이 제안되었다.

R-CNN은 selective search 알고리즘을 활용하여 수많은 region proposal을 추출하고 추출된 각 proposal에 대해 CNN을 통해 특징 벡터를 추출한 다음 SVM(Support Vector Machine)을 통해 객체를 분류하여 결과를 얻고 위치를 조정하여 결과를 도출하였다.

Fast R-CNN은 RoI Pooling을 도입함으로써 selective search 알고리즘의 결과물에 대해 각각 수행되던 CNN 연산을 한 번의 연산으로 줄여 속도를 줄일 수 있었다.

Faster R-CNN은 기존의 Fast R-CNN의 구조를 이어받는 한편, Fast R-CNN에서 여전히 많은 시간을 소모하던 단계인 region proposal 단계에서 기존의 selective search를 없애고 RPN을 도입하여 RoI를 계산하도록 구조가 설계되었다. RPN을 도입함으로써 Fast R-CNN과는 달리 GPU를 활용하여 RoI를 계산하는 것이 가능해졌기 때문에 요구 시간의 비약적 단축을 이뤄냈을 뿐만 아니라 정확도 또한 올라갔다.

3. 제안하는 방법

본 논문에서 제안하는 방법은 크게 두 단계로 구성된다. 첫 번째 과정은 데이터 전처리 과정으로 해당 과정을 통해 해안 영역과 육지 영역을 나누게 된다. 두 번째 과정은 위성 사진에 R-CNN 계열 모델을 적용하여 객체를 찾은 후 첫 번째 과정을 통해 획득한 해안 영역을 바탕으로 선박을 탐지한다.

전처리 단계에서는 네 가지 절차를 거쳐 육지와 해안 영역을 나눈다. 위성 사진의 픽셀 분포 히스토그램을 통해 watershed 알고리즘을 통해 육지와 바다를 분리하기 적합한지 여부를 검사한다. 위성 사진이 검사를 통과하면 노이즈를 제거한 이후 watershed 알고리즘을 통해 육지와 바다를 구분한다. 마지막으로 해안선 인근의 육지에 정박한 선박을 탐지하기 위해 morphology 연산으로 육지 영역을 좀 더 축소시킨다. 전반적인 과정은 Fig. 2에 나타나있다. 만약 watershed 알고리즘을 통해 육지와 해안 영역을 분리하기 적합하지 않을 경우엔 별다른 프로세스를 거치지 않고 위성 사진에 바로 R-CNN 모델을 활용하여 선박을 탐지한다.

3.1 검은 영역 필터링

위성 사진에 watershed 알고리즘을 작성할 수 있는지 여부를 판별하기에 앞서 위성 사진에 검은 색으로 처리된 영역이 있는지 확인해야 한다.

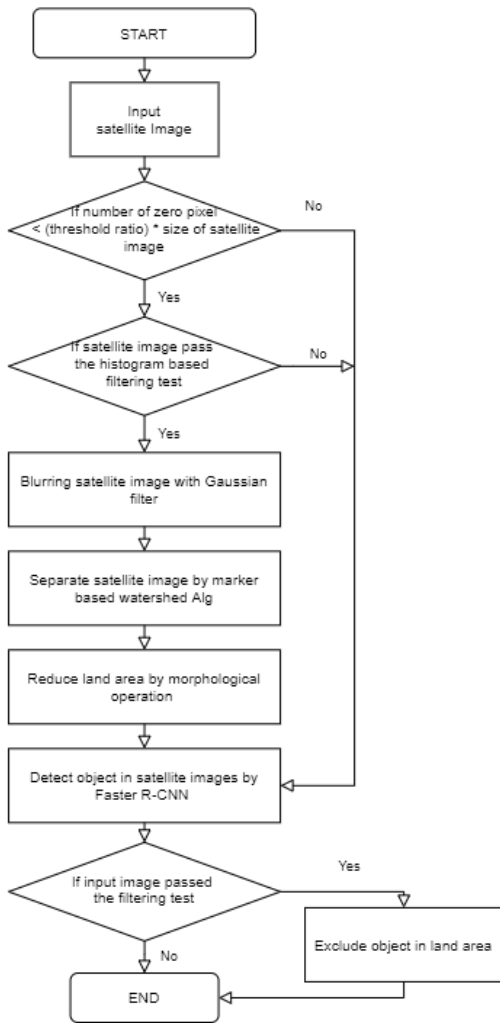


Fig. 2 Flowchart of Proposed Method




Fig. 3 Example of Satellite Image with Dark Area

위성 사진을 촬영할 때 경계선에 해당되는 부분이거나 모종의 이유로 검은 영역으로 전처리를 했을 경우 Fig. 3과 같이 검은 영역이 발견된다.

검은 영역이 발견되면 watershed 알고리즘은 바다보다 더 어두운 영역을 배경 혹은 전경으로 인식을 하게 되기 때문에 제대로 watershed 알고리즘이 수행되지 않을 수 있다. 따라서 전체 영역에서 watershed 알고리즘 수행에 영향을 줄 수 있을 만큼 어두운 영역이 많이 발견되는지 먼저 확인한다.

3.2 히스토그램 기반 필터링

Watershed 알고리즘은 픽셀값을 기준으로 수행되는 알고리즘이기 때문에 바다와 육지의 픽셀 분포가 watershed 알고리즘을 수행하기에 적합한지 여부를 검사할 필요가 있다.

본 연구에선 위성 사진이 watershed 알고리즘을 수행하기에 적합한지 알아보기 위해 회색조 이미지와 이미지의 RGB 채널 각각의 픽셀 분포를 활용하며, 바다 영역과 육지 영역을 구분하기 위한 픽셀 분포 조건을 실험적으로 도출하였다.

3.3 노이즈 제거

히스토그램 기반 필터링을 통과함으로써 위성 사진으로부터 선박이 관측될 수 있는 영역을 구분할 수 있다고 판단되면 위성 사진의 노이즈를 제거하기 위한 전처리를 수행한다. 위성 사진의 해상도는 매우 높기 때문에 조그마한 잡음이라도 객체 탐지에 큰 영향을 줄 수 있으며, 구름, 그림자같이 관측되는 현상들이 더욱 객체 탐지를 어렵게 한다. 육지와 해안을 분리하는 것에 악영향을 주는 노이즈를 효과적으로 제거하는 한편 위성 사진의 특성을 그대로 보존할 수 있는 노이즈 제거 방식을 채택해야 한다. 이미지 필터를 활용한 이미지 블러링은 널리 활용되는 노이즈 제거 방식으로, 본문에선 실험적으로 여러 이미지 필터를 사용하여 어떤 이미지 필터가 본문에서 가장 효과적인 필터인지 알아본다.

3.4 Watershed 알고리즘 수행

노이즈가 제거된 위성 사진의 육지와 해안을 구분짓기 위해 watershed 알고리즘을 사용한다. 다양한 watershed 알고리즘 중에서도 해안과 육지를 효과적으로 분리해낼 수 있는 표지자 기반 watershed 알고리즘을 사용한다.

3.5 Morphology 연산 수행

노이즈를 제거한 위성 사진에 watershed 알고리즘을 적용함으로써, 육지와 해안 영역을 구분지을 수 있다. 이 때 위성 사진과 노이즈 제거 방식에 따라 육지와 해안의 경계선이 다르게 포착된다. 하지만 선박은 해안뿐 아니라 해안선 인근 육지에서도 발견될 수 있다. 따라서, watershed 알고리즘에 의해 분리된 해양 영역을 더 넓히고 육지 영역을 좀 더 축소할 필요가 있다. 본문에선 morphology 연산들을 활용하여 분리된 육지 영역을 더욱 축소시켜 해안선 인근 육지에서도 선박이 탐지될 수 있도록 하였다.

3.6 R-CNN 계열 모델 적용

선박이 관측될 수 있는 영역이 도출되었다면 이를 바탕으로 해안으로 간주되는 영역 내에서 선박을 탐지한다. 선박을 탐지할 때 R-CNN 계열 딥러닝 모델을 사용하여 Fig. 4에 R-CNN 계열 모델 사용 예시가 나와있다. R-CNN 계열 모델은 관측된 선박들에 대해 선박의 위치와 선박의 분류를 위성 사진 위에 표기한다. 본문에선 Faster R-CNN을 활용하였다.




Fig. 4. Result of Applying Faster R-CNN to Satellite Image




Fig. 5A. Histogram of Pixels of Satellite Image Appropriate to use Watershed Algorithm

4. 실험

4.1 실험 준비

모실험에 사용된 데이터는 국방과학연구소로부터 제공받은 데이터셋을 사용하였다. 데이터셋은 1663개의 30003000 픽셀의 이미지로 이루어져 있다.

전처리된 위성 사진으로부터 선박을 탐지하기 위해 사용된 딥러닝 모델은 Faster R-CNN을 활용하였다. 해상 선박(maritime_vessels), 항공모함(aircraft_carrier), 유조선(oil tanker), 컨테이너선(container) 4가지 종류의 선박들을 학습하였다.

horizontal flip, vertical flip, rotation를 적용하여 학습하였으며 네트워크는 ResNet50을 사용하였다. Optimizer 알고리즘은 Adam, Stochastic gradient descent를 사용하였으며 학습률은 10^{-5} 로 설정하였고 loss function은 Mean absolute error를 사용하였다.

4.2 실험 과정

실험 과정은 Fig. 2에 표시된 바와 같다. 먼저 위성 사진에서 검은 영역이 전체 영역에서 일정 비율 이상 관측될 경우 히스토그램 기반 필터링 단계로 넘어가지 않고 바로 Faster R-CNN 단계로 넘어간다.

만약 검은 영역이 일정 비율 미만으로 관측될 경우 위성 사진의 히스토그램을 바탕으로 watershed 알고리즘을 수행하기 적합한지 여부를 검사하고 필터링한다.

Fig. 5에 watershed 알고리즘을 수행하기 적합한 히스토그램 분포와 그렇지 않은 분포가 그려져 있다. Fig. 5B와 같이 회색조 히스토그램의 분포가 전 픽셀에 대해 고르게 분포하고 RGB 채널 중 녹색 채널의 히스토그램 분포가 회색조 히스토그램의 분포와 매우 높은 유사도를 가질 경우 육지 영역과 바다 영역을 watershed 알고리즘을 이용해서 분리해내기 힘들다.

Watershed 알고리즘을 수행하기 적합한지 확인하기 위해 위성 사진은 픽셀 분포에 대해 세 가지 필터를 거치게 되며, 세 가지 필터를 모두 통과한 위성 사진들은 watershed 알고리즘을 통해 육지와 해안을 분리할 수 없다고 간주한다. 첫




Fig. 5B. Histogram of Pixels of Satellite Image Inappropriate to use Watershed Algorithm

번째 필터와 두 번째 필터는 회색조 위성사진의 히스토그램만을 사용하며 마지막 필터는 회색조 위성 사진의 히스토그램과 위성 사진의 RGB 채널 중 녹색 채널에 해당하는 히스토그램을 사용한다.

첫 번째 필터는 회색조 위성 사진의 히스토그램의 최대 빈도의 10%보다 높은 빈도를 갖는 픽셀값이 150개보다 많을 때 첫 필터를 통과한다.

두 번째 필터는 최대 빈도의 40%보다 높은 빈도를 갖는 픽셀이 80개보다 많을 때 두 번째 필터를 통과한다.

세 번째 필터의 경우 초록색 히스토그램과 회색조 히스토그램의 값을 비교한다. 0~255의 각 픽셀값에 대해 초록색 히스토그램과 회색조 히스토그램의 빈도값의 차이가 회색조 히스토그램의 빈도의 15%보다 적은 픽셀이 130개보다 많으면 마지막 필터를 통과하게 된다.

세 필터를 모두 통과한 이미지는 watershed 알고리즘을 수행하기 부적절한 이미지로 간주되어 필터 기반 테스트를 통과하지 못한다.

히스토그램 기반 필터링 테스트를 통과하였으면 해당 위성 사진의 노이즈를 제거하여 watershed 알고리즘의 분리 성능을 향상시켜준다.

노이즈 제거를 위해 이미지 블러링을 활용하였으며 이미지




Fig. 6A. Original Satellite Image




Fig. 6B. Satellite Image with Mean Filter



Fig. 6C. Satellite Image with Median Filter



Fig. 6D. Satellite Image with Gaussian Filter




Fig. 6E. Satellite Image with Bilateral Filter



Fig. 7A. Original Satellite Image



Fig. 7B. Separated Satellite Image by Marker Based Watershed Algorithm

블러링을 위해 Mean, Median, Gaussian, Bilateral 필터를 사용하였다. Fig. 6에 나타나있듯, Mean 필터와 Median 필터는 노이즈를 없애주는 반면 이미지 평활화가 과도하게 진행되어 이미지 특성을 보존하지 못하는 경우가 있다. 한 편, Bilateral 필터는 노이즈를 없애고 동시에 경계선이 강하게 나타나기 때문에 특정 사진에서는 성능이 더 좋을 수 있지만 위성 사진의 경우 경계선보다 윤곽선 것이 더 중요하게 작용할 때가 있기 때문에 본 연구에선 노이즈도 제거할 수 있으며 이미지 특성을 잘 보존할 수 있는 Gaussian 필터를 사용한다.

노이즈가 충분히 제거되었다면, 표지자 기반 watershed 알고리즘을 수행하는 단계에 진입한다.

먼저 노이즈가 제거된 위성 사진을 회색조로 변환한 다음, 이진화를 적용하고 열립 연산을 수행하여 노이즈를 제거하고 배경과 전경을 나누기 위한 준비를 한다.

열립 연산 결과에 확장 연산을 수행하여 연결되지 않은, 아무것도 없다고 판단되는 부분을 배경으로 설정하고 열립 연산 결과에 거리 변환 함수를 적용한다. 거리 변환 함수는 이미지의 각 픽셀에 대해 가장 가까운 0픽셀과의 거리를 계산하여 반환하는 함수이다. 0픽셀과 일정한 거리 이상 떨어진 지점을 전경 혹은 객체로 지정한다. 배경에서 전경을 감산한 결과를 미확인 부분으로 지정하고 연결된 각 컴포넌트들에 대해 라벨을 붙인다. 라벨 즉, 표기된 표지자들에 대해 watershed 알고리즘을 수행하여 육지와 바다를 구분한다.

히스토그램 기반 테스트를 통과한 위성 사진의 경우 육지와 해양의 구분이 비교적 잘 되지만, 테스트를 통과하지 못한 경우 해안 영역과 육지 영역이 제대로 구분되지 않을 수 있다.

Fig. 7A는 위성사진 원본이며, Fig. 7B는 표지자 기반 watershed 알고리즘을 적용하여 육지와 바다를 분리해낸 결과를 나타낸다.

표지자 기반 watershed 알고리즘을 통해 육지와 해안을 분리하였다면, morphology 연산 중 침식 연산을 통해 분리된 육지 영역을 축소한다.

Fig. 8A에서는 표지자 기반 watershed 알고리즘을 활용하여 육지와 바다 영역을 분리했으며 Fig. 8B에서는 Fig. 8A에 대해 침식 연산을 수행시킨 결과를 나타낸다.

육지 영역이 침식 연산에 의해 축소되었으면 Faster R-CNN을 이용하여 선박을 탐지한다.

4.3 실험 결과

데이터셋에 대해 진행한 실험 결과는 Table 1과 같다.

Table 1에 표기된 바와 같이, 1663개 이미지에 대해 실험을 진행하였으며, 1663개 이미지 중 166개 이미지가 검은 영역이 많거나, 히스토그램 기반 필터링을 통과하지 못해 watershed 알고리즘을 수행하기 부적절한 이미지로 분류되어 원본 위성 사진에 바로 Faster R-CNN을 적용하였으며 약 90%의 이미지는 watershed 알고리즘을 사용할 수 있었다.

기존의 Faster R-CNN만을 사용하였을 때 11078개의 물



Fig. 8A. Before Applying Morphological Operation



Fig. 8B. After Applying Morphological Operation

Table 1. Experimental Results

	Faster RCNN	Faster RCNN + Watershed Alg.
Number of Data	1633	1633
Real Object	10682	10682
Object detected	11078	6223
True Positive	5374	5069
False Positive	5704	1154
False Negative	5308	5613
Precision	0.485	0.814
Recall	0.503	0.475

체가 감지된 반면 watershed 알고리즘을 적용하여 탐지하였을 때 6223개로 크게 줄어든 것을 볼 수 있다.

watershed 알고리즘을 통해 육지에서의 오염을 4550개 줄일 수 있었으며 오염률이 80% 감소하였고 Precision 값이 0.485에서 0.814로 증가하였다.

4.4 고찰

먼저 1663개의 위성 사진 중 watershed 알고리즘을 적용하지 못한 166개의 이미지는 별다른 프로세스를 거치지 않고 바로 Faster R-CNN을 적용하여 선박을 탐지했기 때문에 제외한 1497개의 위성 사진에 대해서만 실험결과를 비교했을 때 더욱 정밀한 결과가 나왔을 것이다.

실험에서 사용한 Faster R-CNN의 성능이 약 기대 성능보다 30%정도 떨어졌는데, 국방과학연구소에서 제공받은 학

습 훈련용 위성사진의 개수가 1663개로 적었기 때문으로 보인다. 더 많은 훈련용 위성 사진을 활용했다면 Faster R-CNN 자체의 성능이 더욱 향상되었을 것이다.

마지막으로, watershed 알고리즘을 적용한 결과 True Positive가 줄어들어 재현율(Recall rate)이 떨어졌는데, 그 이유는 크기가 매우 거대한 선박이 탐지되지 않은 경우와 육지가 없는 위성 사진에서의 선박이 탐지되지 않는 경우가 주로 작용하였으며 각 경우에 대해 탐지된 객체 크기에 대한 예외와 탐지된 육지 영역이 매우 작을 경우를 예외로 처리함으로써 해결할 수 있다.

5. 결 론

위성 사진에서의 R-CNN 계열 딥러닝 모델을 통해 선박을 탐지하고자 할 때, 탐지의 오염률을 줄여 성능을 개선하기 위해 watershed 알고리즘을 적용하는 방법을 제안하고 실험하였다.

위성 사진이 찍히는 상황과 환경, 전처리기법 등 다양한 요소에 의해 동일한 위치에 대해 촬영된 위성 사진이라도 다른 분석 방법을 적용해야 할 수 있다.

따라서 watershed 알고리즘을 수행할 수 있는지 여부를 판별하기 위한 조건을 실험적으로 도출하였는데 위성 사진에 의도적으로 검은색으로 처리한 영역이 있거나 회색조 히스토그램의 분포가 녹색 채널의 히스토그램 분포가 유사할 때 watershed 알고리즘을 수행할 수 없었다. 히스토그램의 분포를 역으로 이동시키는 연산을 통해 watershed 알고리즘을 수행할 수 없었던 위성 사진들에 대해 알고리즘을 수행할 수 있는 위성 사진으로 전환할 수 있는지에 대한 추가 연구를 통해 더 많은 위성사진에 대해 본 연구에서 제안하는 방법을 사용할 수 있을 것으로 기대된다.

또한 구름, 그림자와 같은 환경적 요인으로부터 객체를 분리해내는 것은 아직도 어려운 작업으로 인식되고 연구되고 있다. 복잡한 환경에서 객체를 분리해내는 방법과 본 연구를 통해 더욱 정확한 객체 탐지 효과를 기대할 수 있을 것이다.

References

- [1] J. Canny, "A computational approach to edge detection," In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.PAMI-8, No.6, pp.679-698, Nov. 1986.
- [2] C. Harris and M. Stephens, "A combined corner and edge detector," *Paper Presented at the Meeting of the Proceedings of the 4th Alvey Vision Conference*, 1988.
- [3] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2001*, IEEE, Vol.1, 2001.

- [4] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," In *International Conference on Computer Vision & Pattern Recognition*, Vol.1, pp.886-893, 2005.
- [5] D. G. Lowe, "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, Vol.60, No.2, pp.91-110, 2004.
- [6] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," In *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, OH, USA, pp.580-587, 23-28 Jun. 2014.
- [7] R. Girshick, "Fast R-CNN," In *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, pp.1440-1448, 7-13 Dec. 2015.
- [8] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," In *Proceedings of the 28th International Conference on Neural Information Processing Systems*, Montreal, QC, Canada, pp.91-99, 7-12 Dec. 2015.
- [9] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," In *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp.779-788, 27-30 Jun. 2016.
- [10] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, "SSD: Single shot multibox detector," In *Proceedings of the 14th European Conference on Computer Vision (ECCV2016)*, Amsterdam, The Netherlands, Vol.9905, pp.21-37, 8-16 Oct. 2016.
- [11] K. Di, J. Wang, R. Ma, and R. Li, "Automatic shoreline extraction from high-resolution IKONOS satellite imagery," In *Proceedings of the ASPRS 2003 Annual Conference*, Anchorage, AK, USA, 5-9 May 2003.
- [12] C. Dai, I. M. Howat, E. Larour, and E. Husby, "Coastline extraction from repeat high resolution satellite imagery," *Remote Sensing of Environment*, Vol.229, pp.260-270, 2019.
- [13] K. Vos, K. D. Splinter, M. D. Harley, J. A. Simmons, and I. L. Turner, "CoastSat: A Google Earth Engine-enabled Python toolkit to extract shorelines from publicly available satellite imagery," *Environmental Modelling & Software*, Vol.122, 2019.
- [14] V. Paravolidakis, L. Ragia, K. Moirogiorgou, M. E. Zervakis, "Automatic coastline extraction using edge detection and optimization procedures," *Geosciences*, Vol.8, No.11, pp.407, 2018.
- [15] S. Beucher, "Use of watersheds in contour detection," *Proceedings of the International Workshop on Image Processing*, CCETT, 1979.
- [16] Rhammel, Ships in Satellite Imagery [Internet], <https://www.kaggle.com/rhammel/ships-in-satellite-imagery>



이 승 재

<https://orcid.org/0000-0001-5437-2967>
 e-mail : blueyagon@korea.ac.kr
 2016년 고려대학교 정보보호학부(학사)
 2018년 ~ 현 재 고려대학교 정보보호대학원 석사과정
 관심분야 : Information Security, Bigdata Analysis



윤 지 원

<https://orcid.org/0000-0003-2123-9849>
 e-mail : jiwon_yoon@korea.ac.kr
 2003년 성균관대학교(학사)
 2004년 Edinburgh University Informatics(석사)
 2008년 Cambridge University Statistical Signal Processing (박사)

2012년 ~ 현 재 고려대학교 정보보호대학원 교수
 관심분야 : Intelligence Research, Signal and Information Processing for Cyber Security