Smart Media Journal / Vol.7, No.2 / ISSN:2287-1322
http://dx.doi.org/10.30693/SMJ.2018.7.2.34

오픈 소스 기반의 딥러닝을 이용한 적조생물 이미지 분류

(Red Tide Algea Image Classification using Deep Learning based Open Source)

박선*, 김종원**
(Sun Park, Jongwon Kim)

요 약

국내 유해 적조발생에 따른 어패류 양식장에 지속적인 피해가 증가함에 따라서 적조에 대하여 많은 연구가 이루어지고 있다. 그러나 자동으로 적조 이미지를 인식하여서 유해적조생물을 판별하는 적조생물 이미지 검색에 대한 국내의 연구는 미흡한 실정에 있다. 본 논문은 오픈소스 기반의 딥러닝을 이용하여 적조생물 이미지를 분류할 수 있는 방법을 제안한다. 제안방법은 다양하게 표현되는 적조생물 이미지의 인식문제를 해결하기 위하여 텐서프로 프레임워크와 구글 이미지 분류 모델을 이용하여 구현하였다.

■ 중심어 : 적조생물, 딥러닝, 이미지 분류, 오픈소스

Abstract

There are many studies on red tide due to the continuous increase in damage to domestic fish and shell farms by the harmful red tide. However, there is insufficient domestic research of identifying harmful red tide algae that automatically recognizes red tide images. In this paper, we propose a red tide image classification method using deep learning based open source. To solve the problem of recognition of various images of red tide algae, the proposed method is implemented by using tensorflow framework and Google image classification model.

■ keywords : Red Tide ; Deep Learning ; Imge Classification ; Open Source

Ⅰ. 서 론

적조(red tide)란 해양에 서식하는 플랑크톤이 대량 번식으로 바다물의 색깔이 적색이나 황색으로 변하며 해양생태계를 파괴시키는 현상으로 적조에 의한 수산업에 피해가 지속적으로 증가하면서 유해 조류의 대번식이란 의미로 사용되고 있다. 전 세계적으로 적조를 발생 시키는 적조 생물의 종은 200여 종 정도가 확인되고 있으며, 국내에서는 녹조류 4종을 포함하여 70여 종의 적조 생물들이 발견되고 있다. 국내 수산업에 피해를 일으키는 유해조류는 어패류 폐사종 4종과 패독증 유발종 3종이 있다. 이들 중에서 패독증 유발종으로 굴, 홍합 등의 패류를 독화시켜 사람이 먹으면 마비성 패독증을 일으키는 알렉산드리아 타마렌세(alexandirum tamarense), 디노피시스 어큐미네이트(dinophysis acuminate), 니치아 푼젠스(nitzschia pungens) 물티세리스(multiseries) 등이 있다. 어패류 폐사 종으로 코크로디늄 폴리코데스(coclodinium polyrkoides), 헤테로시그마 아카시우(heterosigma akashiwo), 짐노디늄 미키모토이(gymnodinium mikimotoi), 기로디늄 에스피(gyrodinium sp) 등이 있다. 국내에서는 특히 coclodinium polykrikoides에 의한 양식업의 피해가 가장 크다[1, 2].

국내에서는 1990년 이후 연안 산업화의 진행으로 적조현상이 증가하고 있으며, 특히 1995년에는 764억 원으로 역대 최대의 수산업 피해를 입히며 매년 적조에 대한 피해를 입고 있다. 이러한 적조피해가 늘어남에 따라서 매년 방재작업과 적조 감시작업으로 많은 예산을 소모하고 있다. 적조를 연구하기 위해서는 적조류의 종류와 적조생물 밀도(개체/ml)를 정확히 파악해야 하나 국내에서는 대부분 수작업에 의해 이루어지고 있다. 적조 생물의 개체 수를 검사하는 방법으로 센서를 이용[3]한 연구가 국내에서 어느 정도 진행되고 있으나 수집된 적조생물 이미지 자료로부터 적조 생물을 분류하는 연구는 아직 초기단계에 있다[1, 2, 3].

국내 해역에서는 발생하는 70여종의 적조류들은 종의 수만큼이나 다양한 모양을 보이고 있어서 자동화된 분류방법을 이용하는 대에는 제한 사항이 있다. 특히 자동 적조 영상인식에서는 적조류 이미지들 간에 일치시킬 수 있도록 하는 기준 특징이 없

* 정회원, ** 교신저자, 광주과학기술원 전기전자컴퓨터공학부,
이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2016R1D1A1B03934823). 이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임 (No.R7117-16-0218, 이종 다수 클라우드 간의 자동화된 SaaS 호환성 지원 기술 개발)

접수일자 : 2018년 06월 12일
수정일자 : 2018년 06월 26일
게재확정일 : 2018년 06월 29일
교신저자 : 김종원, 박선 e-mail : sunpark@smartx.kr

어서 적조 이미지 인식을 더욱 어렵게 하고 있다. 이 때문에 적조인식에 대한 관련연구들은 자주 발생하는 몇 종류의 유해 적조에 SVM[4], 베이지안 분류자[5], 퍼지 c-means[6]등을 이용하여서 단일 적조 이미지를 인식하고 있다. 이는 요즘과 같이 2~3종의 복합 적조가 늘어나는 추세에서 정확하게 인식하기 어려운 문제점들을 가지고 있다. 이러한 문제를 해결하기 위해서 본 논문의 저자들은 이전에 PCA[7]와 NMF[8, 9]를 이용하여 의미특징을 추출한 후 이미지 객체의 원형율과 엔트로피를 이용한 적조 인식 방법을 제안하였다. 그러나 이 방법 역시 기준 특징을 추출하기에는 제약사항이 있다. 본 논문의 저자들은 적조 이미지 특징의 기준점 문제를 해결하기 위해서 딥러닝을 이용한 적조생물 이미지 분류에 대한 기본 개념[10, 11]을 제시하였다.

본 논문은 적조 이미지 인식률 향상을 위하여 딥러닝을 이용한 새로운 적조 이미지 인식방법을 제안한다. 제안방법은 오픈소스 프레임워크인 텐서플로를 사용하여 구현비용 부담과 적조생물 분류에 딥러닝 모델을 사용하여 이미지 전처리에 대한 비용을 감소시켰다.

본 논문의 구성은 다음과 같다. 2장에서는 관련연구로 기존의 적조생물 이미지 분류와 딥러닝 기술 및 Tensorflow에 대하여 알아보고, 3장에서는 제안방법을, 4장에서는 실험 및 평가를, 5장에서는 결론을 제시한다.

Ⅱ. 관련연구

1. 적조생물 영상 인식

Jiang외 저자들은 베이지안 분류자와 SVM을 이용한 적조류 분류방법을 제안하였다. 이들의 방법은 베이지안 분류자를 이용하여서 오염되거나 알려지지 않은 적조류를 제거하고, SVM을 이용하여서 적조류를 분류한다[6]. 그러나 알려지지 않은 적조류나 오염된 객체를 인식하는 대에는 좋은 성능을 보이지 않는다. 또한, 적조 분류의 학습에는 8종의 적조류만 사용하였다. Jiang외 저자들은 적조류 인식을 위하여 2단계 분류자를 사용한 방법을 제안하였다. 첫 번째 분류자인 SVDD(support vector data description)는 오염된 객체나 알려지지 않은 적조류를 제거하는 대에 사용하며, 두 번째 분류자인 SVM은 적조류를 미리 분류된 분류 계층으로 분류한다[4]. 이들의 방법은 우세종인 8종의 적조류만 학습에 이용하였다. Lili외 저자들은 적조류 분류를 위하여 SVM과 FCM(fuzzy c-means)군집방법을 이용하였다. 이들 방법은 먼저 SVM을 이용해서 검정 표본에 분류 표시를 하고, 확률 방법으로 잘못 분류된 자료를 FCM을 이용하여서 다시 분류 표시한다[5]. 이들 방법 역시 5종의 적조류를 학습하는 대에 이용하였다. 이들 방법[4, 5, 6]들은 소량의 학습된 적조류 이외의 적조류를 인식하는 대에는 어려움을 가지고 있다. 이러한 문제를 해결하기 위하여 본 논문의 저자들은 주성분분석[7, 8] 및 비음수 행렬 분해[9]를 이용하여 적조 이미지 분류방법을 제시하였으나 이미지 특징 매칭시 모호한 문제를 일부 가지고 있다. 본 논문의 저자들은 또한 적조생물 이미지 전처리 문제를 해결하기 위하여 적조생물 이미지에 딥러닝을 적용한 방법의 기본 개념을 제시하였다 [10, 11].

2. 딥러닝

딥러닝(Deep Learning)은 여러 비선형 변환기법의 조합을 통해 높은 수준의 추상화(abstractions, 다량의 데이터나 복잡한 자료들 속에서 핵심적인 내용 또는 기능을 요약하는 작업)를 시도하는 기계학습(machine learning) 알고리즘의 집합으로 정의된다. 딥러닝 알고리즘은 심층 신경망, 합성곱 신경망, 순환 신경망, 볼츠만 머신 등이 대표적이며, 이외에 다양한 형태의 딥러닝 알고리즘이 연구되고 있다. 딥러닝은 입력층(input layer)과 출력층(output layer) 사이에 여러 개의 은닉층(hidden layer)들로 이뤄진 인공신경망(Artificial Neural Network, ANN)이다. 합성곱 신경망(Convolutional Neural Network, CNN)은 최소한의 전처리(preprocess)를 사용하도록 설계된 다계층 퍼셉트론(multilayer perceptrons)의 한 종류이다. 순환 신경망은 인공신경망을 구성하는 유닛 사이의 연결이 Directed cycle을 구성하는 신경망을 말한다. 볼츠만 머신에서, 층간 연결을 없앤 형태의 모델이다 [12].

3. 오픈소스 프레임워크 Tensorflow

텐서플로(TensorFlow)는 다양한 작업에 대해 데이터 흐름 프로그래밍을 위한 오픈소스 소프트웨어 라이브러리이다. 심볼릭 수학 라이브러리이자, 뉴럴 네트워크 같은 기계학습 응용프로그램에도 사용된다. 텐서플로는 2015년에 오픈소스로 공개된 구글 브레인 팀의 두 번째 머신 러닝 시스템이다. 텐서플로는 안드로이드와 iOS같은 모바일 환경은 물론 64비트 리눅스, MacOS 의 데스크톱이나 서버 시스템의 여러 개의 CPU와 GPU에서 (GPU에서 일반 연산을 수행하게 하는 CUDA 확장 기능을 사용) 구동될 수 있다. 텐서플로 연산은 상태를 가지는 데이터 흐름(stateful dataflow) 유향 그래프로 표현된다. 구글에 있는 많은 팀이 연구와 제품 개발을 위해 구글 브레인 팀은 첫 머신러닝 시스템인 디스트빌리프에서 텐서플로로 이전했다 [13].

III. 적조생물 이미지 분류

본 논문에서 제안한 적조생물 이미지 분류 과정은 그림1과 같이 학습 및 평가 이미지 준비, 적조 이미지 분류 모델 학습, 적조 이미지 분류 모델 평가 단계로 구성된다. 학습 및 평가 이미지 준비 단계에서는 적조생물 이미지를 분류 모델을 학습하고 평가할 수 있도록 적조생물 이미지를 준비한다. 적조이미지 분류모델 학습단계에서는 잘 만들어진 이미지 학습 모델에 준비된 적조생물 이미지를 이용하여 재학습(retraining)을 한다. 적조 이미지 분류 모델 평가에서는 준비된 적조생물 이미지 평가자료를 이용하여 분류의 정확률을 평가한다.

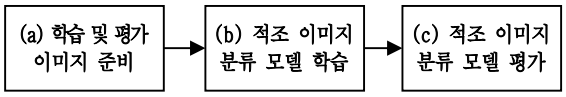

그림 1. 적조생물 이미지 분류 블록도

1. 학습 및 평가 이미지 준비

(1) 적조생물 기본 이미지 준비

적조생물 분류를 위한 학습 및 평가 이미지를 준비하기 위하여 지난 10년간 국내 연안에서 발생한 우세 13종의 적조생물을 선정하였다. 선정된 적조생물은 구글 이미지 검색을 통하여 검색하였으며, 검색된 적조생물 이미지들 중 정확한 적조생물 이미지만을 수작업으로 분류하여 총 782장의 적조생물 이미지를 준비하였다. 다음 표1은 선택된 적조생물 종 및 이미지 개수를 나타내며, 그림2는 아카시우 산규지네(Akashiwo sangujinea) 적조생물 종 이미지의 일부분을 보여준다.

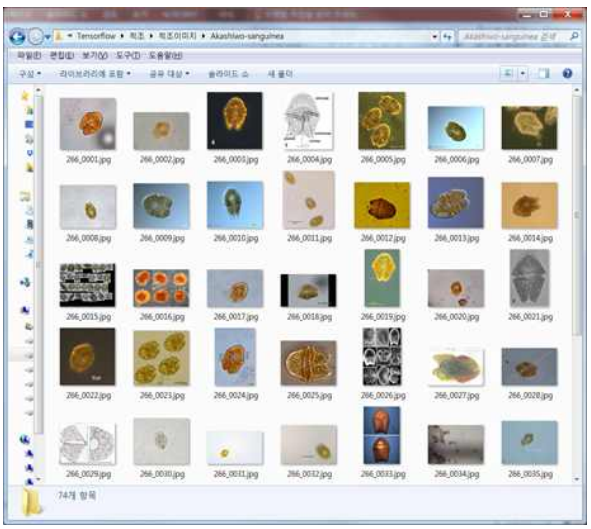

그림 2. Akashiwo sangujinea 적조생물 이미지 일부분

표 1. 선정된 적조생물종

Noctiluca scintillan: 20	Hetrosigma akashiwo: 78	Mesodinium rubrum: 47
Alexandrium sp.: 35	Ceratium sp.: 225	Prorocentrum dentatum: 4
Ceratium furca: 103	Cheatoceros sp.: 64	Akashiwo sangujinea: 74
Noctiluca sp.: 21	Cochlodinium polykrikoides: 56	Karenia mikimotoi: 43
Gyrodinium sp. : 12		

(2) 적조생물 이미지 데이터 증식

적조생물 이미지를 획득할 수 있는 방법은 매우 제한적으로 표1에서 보는 것과 같이 적조생물 종에 따라서 준비할 수 있는 이미지의 개수가 많게는 225개의 이미지로부터 적개는 4개의 이미지로 개수의 편차가 크다. 이러한 학습이미지 개수의 제약 문제를 해결할 수 있는 좋은 방법 중에는 데이터 증식 (Data Augmentation) 기법이 있다. 데이터 증식은 기존의 데이터에 새로운 데이터를 생성해 인공적으로 훈련 세트의 크기를 늘리는 기법이다. 본 논문에서는 Pai [14]의 python 코드를 이용하여 다음 표2의 데이터 증식기법을 적조생물 이미지에 적용하여 적조생물 학습 이미지의 개수를 늘렸다. 즉, 13종의 적조생물 각각의 종을 500개의 이미지로 추가 생성하여 총 6,500개의 이미지로 데이터 증식을 하였다.

표 2. 이미지 데이터 증식 종류

구분	내용
Scaling	· 원본 이미지 데이터를 크거나 작게 이미지 생성
Translation	· 원본 이미지 데이터를 좌, 우, 상, 하 방향으로 이동하여 이미지 생성
Rotation (at 90 degrees)	· 원본 이미지 데이터를 90도, 180도, 270도로 방향을 전환하여 이미지 생성
Rotation (at finer angles)	· 원본 이미지 데이터를 -90도, -76.15도, -62.31도, -48.46도, -34.62도, -20.77도, -6.92도, 6.92도, 20.77도, 34.61도, 48.46도, 62.31도, 76.15도, 90도로 방향을 전환하여 이미지 생성
Flipping	· 원본 이미지 데이터를 좌우 대칭, 상하 대칭, 치환 대칭으로 이미지 생성
Adding Salt and Pepper noise	· 원본 이미지 데이터를 흰점 과 검은점 노이지를 추가하여 이미지 생성
Lighting condition	· 원본 이미지 데이터에 그림자를 추가하여 이미지 생성
Perspective transform	· 원본 이미지 데이터에 원근감을 추가하여 이미지 생성

2. 적조 이미지 분류 모델 학습

본 논문에서는 텐서플로를 이용하여 이적학습(transfer learning)방식으로 기존 CNN 모델을 적조생물 이미지에 적합하도록 재학습하였다. 이적학습은 처음부터 CNN을 학습시키는 것은 너무 시간이 오래 걸리고 효율이 낮으므로, 성능이 입증된 CNN 모델을 가져다가 특징을 추출하고, 이를 바탕으로 우리가 원하는 분류를 수행하도록 한다. 즉, 딥러닝을 특징 추출기(feature extractor)로만 사용하고 추출한 특징을 가지고 다른 모델을 학습한다. 이는 ConvNet을 고정된 특징 추출기로 사용하는 경우에는 ConvNet 끝에 달린 전체연결계층(fully-connected layer)을 없애고, 컴벌루션계층(convolutional layer)을 통해 처리되는 값만 얻으며, 이렇게 얻어진 특징을 CNN codes라 한다. ConvNet을 fine-tuning하는 경우에는 끝의 전체연계층를 제거하고, 앞선 컴벌루션계층을 새로운 데이터를 사용해서 다시 학습시키고, 역전파를 통해 weight를 업데이트 한다 [15].

본 논문에서는 이적학습을 하기 위한 기본 이미지 분류 모델로 구글 Inception-v3 모델[16]과 MobileNet-v2 모델[17]을 사용한다. 구글 Inception 모델은 GoogleLeNet에 사용되어 2014년 IRSVRC에서 우승을 한 모델로 기존의 CNN 모델들이 입력 이미지에 같은 크기의 컨벌루션 필터를 하나씩 계속 덧대는 구조라면, Inception은 한 번에 여러 크기의 필터를 동시에 사용한다. MobileNet 모델은 컨벌루션 레이어의 깊이(특징 수)에 대한 배율에 의해 제어되는 다양한 크기로 제공하며, 추론 속도를 제어하기 위해 다양한 크기의 입력 이미지를 학습한다. 다음 그림3은 Inception-v3 모델과 MobileNet-v2 모델에 적조생물 학습이미지를 이용하여 재학습하는 구조를 텐서보드(tensorboard)를 이용하여 시각화된 도식으로 나타낸 것이다.

3. 적조 이미지 분류 모델 평가

본 논문에서는 적조생물 이미지 분류 모델을 평가하기 위하여 표3과 같이 적조생물 이미지 집합을 구성하였다. 이미지 분류 모델을 재학습하기 위한 Training 데이터로 총 적조생물 이미지 집합의 80%로 구성하였으며, 모델 재학습의 유효성을 검사하기 위한 Validation 데이터로 총 적조생물 이미지 집합의 10%로 구성하였고, 재학습된 이미지 분류모델을 평가하기 위한 Testing 데이터로 총 적조생물 이미지 집합의 10%로 구성하였다. Training:Validation:Testing = 80:10:10 비율은 구글에서 텐서플로의 이미지 재학습시 추천하는 비율을 본 논문에서는 적용하였다 [18].

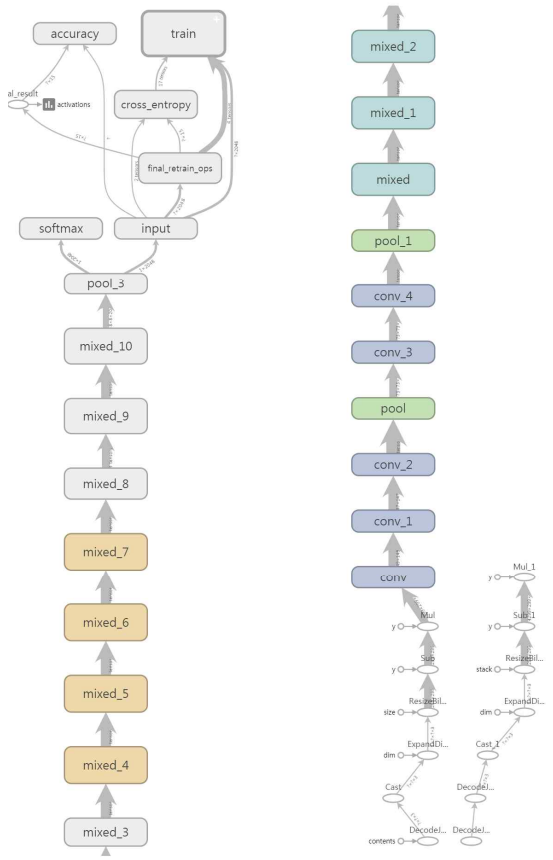

그림 3. 재학습 모델의 텐서보드를 이용한 시각화

표 3. Training, Validation, Testing 적조생물 이미지 집합구성

구분	Training (80%)	Training Validation (10%)	Testing of Predicting (10%)
적조생물 원본 이미지	626	78	78
적조생물 증식 데이터 이미지	5,200	650	650

Ⅳ. 적조분류 모델 평가

본 논문에서는 모델을 평가하기 위하여 신경망 평가에 기준으로 사용하는 Top-1과 Top-5 정확률을 이용한다. Top-1 정확률은 평가결과 정답이 가장 상위에 예측결과에 일치하는 정확률이며, Top-5정확율은 상위순위 5개의 평가결과에 정답이 포함되는 정확률이다. 그림4는 Inception 모델과 MobileNet 모델에 ImageNet 데이터 집합의 Top-1과 Top-5의 정확률 평가 결과이다. Inception 모델의 Top-1 정확률은 69.8%이고 Top-5 정확률은 89.6%이다. MobileNet 모델의 Top-1 정확률은 70.7%이고 Top-5 정확률은 89.5%이다. 그림5는 Inception 모델과 MobileNet 모델에

적조생물 원본 이미지 데이터 집합의 Top-1과 Top-5의 정확률 평가 결과이다. Inception 모델의 Top-1 정확률은 65.6%이고 Top-5 정확률은 87.5%이다. MobileNet 모델의 Top-1 정확률은 67.7%이고 Top-5 정확률은 88.9%이다. 그림6은 Inception 모델과 MobileNet 모델에 적조생물 이미지 증식 데이터 집합의 Top-1과 Top-5의 정확률 평가 결과이다. Inception 모델의 Top-1 정확률은 68.5%이고 Top-5 정확률은 89.4%이다. MobileNet 모델의 Top-1 정확률은 70.1%이고 Top-5 정확률은 89.6%이다.

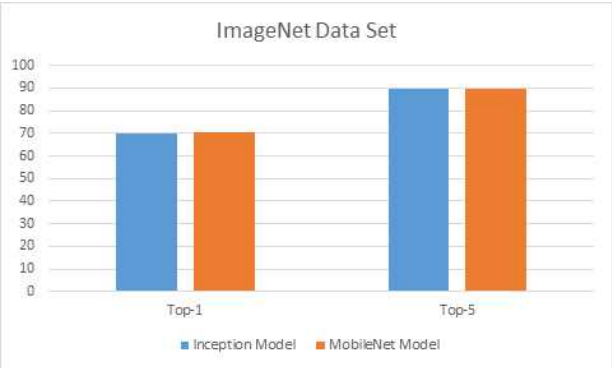

그림 4. ImageNet 데이터 집합 평가 결과

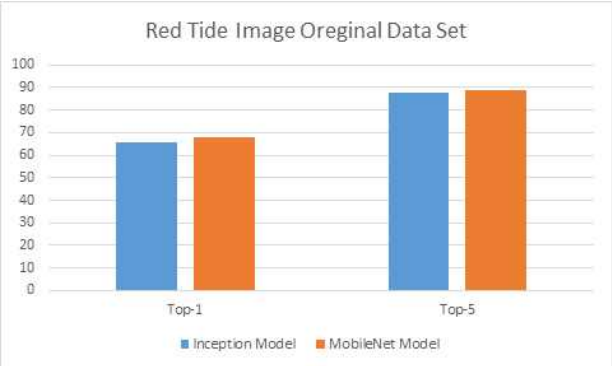

그림 5. 적조생물 원본 이미지 평가 결과

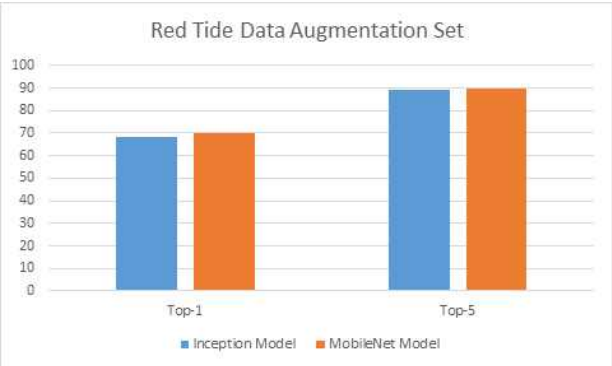

그림 6. 적조생물 증식 데이터 집합 평가 결과

V. 결 론

본 논문은 다양하게 표현되는 적조생물 이미지의 인식문제를 해결하기 위하여 구글 Inception 모델과 MobileNet 모델 기반의 적조생물 이미지 분류를 오픈소스인 텐서프로 프레임워크를 이용하여 구현하였다. 이를 위해서 구글 이미지 검색을 이용하여 13종의 적조생물 782개를 수작업으로 분류하여 원본 적조생물 이미지 집합을 구성하였으며, 원본 이미지 집합에 데이터 증식 기법을 이용하여 6,500개의 이미지 집합으로 증가시켰다. 적조생물 이미지 분류 모델 평가 결과 원본 이미지 집합의 Top-1 평균정확률은 66.65%, Top-5의 평균 정확률은 88.2%를 보였으며, 이미지 증식 데이터 집합의 Top-1 평균정확률은 69.3%, Top-5의 평균 정확률은 89.5%를 보였다. 모델에 적합한 이미지 크기 최적화 및 이미지 잡음을 제거하면 두 모델의 정확률을 높일 수 있을 것으로 예상한다.

REFERENCES

[1] 국립수산과학원 적조정보 홈페이지, https://www.nifs.go.kr/redtideInfo, 2018.

[2] FSIS 수산물안전정보, http://www.fsis.go.kr/front/api/totalView.do?cnts_id=15990&title=&select_list_no=2, 2018.

[3] B. C. Kim, H. W. Kang, Y. H. Kim, "Measurement of Algae Population for Red-Tide Prediction", SICE-ICASE Internation Joint Conference, pp.4684~4687, 2006.

[4] T. Jiang, C. Wang, B. Wang, J. Xie, N. Jia, T. Luo, "Real-time Red Tide Algae Recognition using SVM and SVDD", In proceeding of International Conference on Intelligent Computing and Intelligent System (ICIS), pp.602-606, Oct. 2010.

[5] X. Lili, J. Tao, X. Jiozhen, Z. Shaoping, "Red Tide Algae Classification Using SVM-SNP and Semi-supervised FCM", In proceeding of International Conference on Education Technology and Computer (ICETC), pp.389-392, Jun. 2010.

[6] T. Jiang, C. Wang, B. Wang, J. Xie, N. Jiao, T. Luo, "Real-time Red Tide Alge Classification Uing Bayes Classifier and SVM", In proceeding of International Conference on Bioinformatics and Biomedical Engineering (ICBBE), pp.2888-2891, May 2008.

[7] 박선, 이성로, 박석천, 임향섭, 신준우, 권장우, "주성분분석을 이용한 적조생물 영상 인식, 제35회 정

보처리학회 춘계대회, 2011.
[8] 박선, 이진석, 이성로, “의미특징을 이용한 적조 이미지 인식”, 대한전자공학회논문지, 제48권 5호, pp. 23-29, 2011.
[9] 박선, 이성로, “NMF와 이미지 보정을 이용한 적조 이미지 인식 향상”, 한국통신학회논문지, 제16권 제2호, pp. 331-336, 2012.
[10] 박선, 차병래, 김종원, “딥러닝을 이용한 적조생물 이미지 분류”, 한국통신학회 2018년도 동계학술발표회, pp. 302-303, 2018.
[11] S. Park, B. R. Cha, J. G. Jeong, J. W. Kim, “Red Tide Classification using Deep Learning based on Open Source”, Proc. of International Conference on Feture Information & Communication Engineering (ICFICE2018), 2018.
[12] Deep Learning, https://ko.wikipedia.org/wiki/%EB%94%A5_%EB%9F%AC%EB%8B%9D, 2018.
[13] Tensorflow, https://ko.wikipedia.org/wiki/%ED%85%90%EC%84%9C%ED%94%8C%EB%A1%9C, 2018.
[14] P., Pai, “Data Augmentation Techniques in CNN using Tensorflow”, https://github.com/Prasad9, 2018.
[15] A., Trivedi, “Deep Learning Part 2: Transfer Learning and Fine-tuning Deep Convolutional Neural Networks”, http://blog.revolutionanalytics.com/2016/08/deep-learning-part-2.html, 2018.
[16] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, “Rethinking the Inception Architecture for Computer Vision”, Proc, Conference of Computer Vision and Pattern Recognition 2016, 2016.
[17] M., Sandler, A., Howard, M., Zhu, A., Zhmoginov, L., C., Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks”, Proc, Conference of Computer Vision and Pattern Recognition, 2018.
[18] 차병래, 박선, 신병춘, 김종원, ""Abyss Storage Cluster 기반의 DataLake Framework의 설계,"" 스마트미디어저널, 제7권, 제1호, 9-15쪽, 2018년

저 자 소 개

박 선

2007년 인하대학교 컴퓨터정보공학과 공학박사
2008년 호남대학교 컴퓨터공학과 전임강사
2010년 전북대학교 인력양성사업단 박사후 과정
2010년 목포대학교 정보산업연구소 연구전임교수
2013년 ~ 현재 광주과학기술원 연구조교수
2017년 ~ 현재 제노테크(주) 연구소장
<주관심분야 : 정보검색, 데이터마이닝, 해양IT정보융합, 클라우드 컴퓨팅, IoT, 스토리지 시스템>

김종원

1997년 University of Southern California 연구 조교수
1999년 Technology Consultant for VProtect Systems Inc.
2000년 Technology Consultant for Southern California Division of InterVideo Inc.
2001년 광주과학기술원 정보기전공학부 부교수
2008년 ~ 현재 광주과학기술원 정보통신공학부 교수
<주관심분야 : Future Internet, SDN & NFV, SDI>