



자율운항선박의 국제해상충돌예방규칙 준수를 위한 합성곱 신경망 기반의 선박 분류에 관한 연구

A Study on Vessel Classification based on CNNs for COLREGs Compliance of Autonomous Ships

김민영*, 정치윤**†

Min Yoeng Kim and Chi Yoon Jeong[†]

*한국기술교육대학교 컴퓨터학부, **한국전자통신연구원 SW·콘텐츠원천연구그룹

*School of Computer Science and Engineering, KOREATECH

**SW·Contents Basic Technology Research Group, ETRI

요약

최근 자율운항선박에 대한 관심이 증가하고 있으며, 바다를 항해하는 자율운항선박은 유인선과 같이 국제해상충돌방지규칙을 준수해야 한다. 따라서 본 논문에서는 자율운항선박이 국제해상충돌예방규칙을 준수하기 위해서 필요한 선박 범주 및 합성곱 신경망 기반의 선박 분류 기술을 제안하였다. 먼저 국제해상충돌예방규칙을 분석하여 자율운항선박이 구별해야 되는 14개의 선박 범주를 정의하였다. 또한 본 논문에서 정의된 선박 범주에 맞도록 인터넷 영상 검색 및 기존 데이터 셋 정제를 통하여 40,300장 규모의 선박 범주 분류 데이터 셋을 구축하였다. 마지막으로 최신 합성곱 신경망 모델을 구축된 선박 범주 분류 데이터 셋에 적용하여 선박 범주 분류 성능을 분석하였다. 실험결과 전이학습을 통하여 학습된 Inception-ResNet v2 모델은 14개 선박 범주를 91%의 높은 정확도로 분류함을 확인하였다.

키워드 : 자율운항선박, 선박 분류, 국제해상충돌예방규칙, 합성곱 신경망

Abstract

The interest in autonomous ships for marine industries has increased significantly over the past few years and autonomous ships also must follow maritime laws in the same way as regular ships operated by crews. Therefore, in this paper, we propose the vessel taxonomy for COLREGs compliance of autonomous ships and evaluate the performance of the vessel classification method using CNNs. First, we define the vessel taxonomy for complying with maritime laws by analyzing the COLREGs. And then, we build our dataset separated manually by the vessel taxonomy. For the dataset, 40,300 images are collected by image search on websites and refining the publicly available dataset. Finally, the state-of-the-art CNN model is applied to evaluate the recognition rate of our dataset. The experimental results show that the Inception-ResNet v2 model which is trained by transfer learning effectively classifies the ships with a high accuracy of 91%.

Key Words : Autonomous Ships, Vessel Classification, COLREGs, Convolutional Neural Networks

Received: Mar. 19, 2019

Revised: Apr. 12, 2019

Accepted: Jun. 13, 2019

[†]Corresponding authors

iamready@etri.re.kr

이 연구는 2019년도 산업통상자원부 및 산업기술평가관리원(KETIP) 연구비 지원에 의한 연구임(10077551).

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

자율운항선박은 사람의 개입 없이 스스로 최적의 항로를 설정하고 목적지까지 안전하게 자율적으로 항해할 수 있는 선박을 의미한다. 자율운항선박은 인공지능기술이 선원들의 역할을 대신함으로써 선박의 운영비용과 항해비용을 절감할 수 있을 것으로 기대되고 있으며, 최근 연구 [1]에서는 자율운항 벌크선을 25년 동안 운영할 경우 기존 선박대비 4.3%의 비용 절감 효과가 있다는 것을 확인하였다. 또한 선박충돌사고 등의 해양사고는 인적 요인에 의한 인적 오류로 많이 발생하기 때문에 [2], 자율운항선박은 해양사고 발생을 줄일 수 있을 것으로 기대되고 있다. 이런 장점으로 인하여 최근 자율운항선박에 대한 관심이 증가하고 있으며, 자율운항선박의 안전한 운항을 위한 상황인지 방법 및 최적 운항 경로 설정에 관한 연구들이 많이 진행되고 있다.

바다를 항해하는 선박은 선박 간 충돌 방지를 위해 국제해상기구에서 정의한 국제해상충돌예방규칙(COLREGs, The International Regulations for Preventing Collisions at Sea 1972)을 반드시 준수해야 한다. 국제해상충돌예방규칙에서는 선박 간 충돌이 예상될 때 각 선박이 충돌을 회피하기 위해서 지켜야 하는

운항 방법을 규정하고 있으며, 이는 선박의 범주에 따라 다르게 적용된다 [3]. 따라서 자율운항선박이 국제해상충돌예방규칙을 준수하기 위해서는 선박의 범주를 분류하는 기술이 필요하다.

선박 범주를 분류하는 기술들은 주로 군사적 목적으로 연구되어왔으며, 고성능 영상레이더(synthetic aperture radar), 인공위성 영상 등 선박 상공의 원거리에서 획득된 영상으로부터 저수준 특징과 기계학습 방법을 사용하여 선박을 검출하고 분류하는 방법이 많이 연구되었다 [4,5]. 최근에는 선박에 장착된 광학 센서를 사용하여 촬영된 영상으로부터 선박 범주를 인식하는 방법에 대한 연구가 진행되고 있다 [6,7]. 하지만 기존 방법의 경우 연안 감시를 목적으로 선박의 범주를 구분하거나 [8], 선박 분류 방법의 성능 검증을 위하여 선박의 크기 [9], 또는 데이터 셋에 존재하는 선박 범주의 비율 [10] 등을 사용하여 선박 범주를 정의하였다. 이와 같이 현재 해양 환경에서의 선박 범주 인식에 관한 연구는 국제해상충돌예방규칙과 무관하게 진행되고 있어, 자율운항선박이 국제해상충돌예방규칙을 준수하기 위한 선박의 범주를 정의하고, 분류 성능을 평가하는 연구가 필요하다.

본 논문에서는 자율운항선박이 국제해상충돌예방규칙을 준수하기 위해 필요한 선박 범주 분류 기술에 관한 연구를 진행하였다. 먼저, 본 연구의 출발점으로 국제해상충돌예방규칙을 분석하여 자율운항선박이 구별해야 되는 선박의 범주를 정의하였다. 또한 본 논문에서 정의된 선박 범주에 맞도록 공개 데이터 셋과 인터넷을 통해 수집된 데이터를 사용하여 국제해상충돌예방규칙을 준수하기 위한 선박 범주 분류 데이터 셋을 새롭게 구축하였다. 마지막으로 구축된 데이터 셋에 최신 합성곱 신경망 기술을 적용하여 선박 범주의 분류 성능을 분석하였다.

본 논문의 구성은 다음과 같다. 2절에서는 해양 환경에서 선박 범주 분류 기술과 관련된 연구 동향에 관하여 소개하고, 3절에서는 국제해상충돌예방규칙을 준수하기 위한 선박 범주를 정의한다. 4절에서는 3절에서 정의한 선박 범주에 따라 새롭게 구축된 선박 범주 분류 데이터 셋 및 선박 범주 분류를 위해 사용된 합성곱 신경망에 대해서 소개하고, 5절에서는 선박 범주 분류 실험 결과에 대한 분석을 수행한다. 6절에서는 결론 및 향후 연구방향을 제시한다.

2. 관련 연구

카메라로부터 촬영된 영상을 사용하여 선박을 분류하는 기술은 사용 목적에 따라 선박의 범주를 다르게 구분하고 있다. 수로를 운항하는 보트의 감시와 통행량 분석을 위한 목적으로 보트를 5개의 일반적인 범주와 24개의 세부범주로 분류한 후, 색상의 분포 특성을 비롯한 영상 특징과 결정 트리 및 랜덤포레스트 등의 기계학습 방법을 사용하여 보트의 범주를 분류하는 방법이 연구되었다 [1]. 보트의 범주

분류를 위한 데이터는 총 13,000장의 이미지로 구성되며, 약 10,000장을 학습 데이터로 사용하였다. 다양한 기계학습 방법 중 결정트리를 사용하였을 때 가장 높은 분류 성능을 보여주었으며, 5개 범주를 평균 70% 정확도로 분류하였다. 연안 감시 등의 군사적 목적을 위해서 선박을 함정, 상선 등의 4개 상위 범주로 구분하고, 함정을 다시 10개의 세부 범주로 분류하기 위한 방법이 연구되었다. 이 연구에서는 선박의 상위 범주 및 함정의 세부 범주 분류를 위하여 딥러닝 네트워크 [12]에서 추출된 특징과 지지 벡터 머신(SVM, Support Vector Machines)을 사용하였다 [6].

영상인식 분야에서 높은 성능을 보여준 딥러닝 방법들은 일반적으로 많은 양의 학습 데이터를 요구하기 때문에, 선박 범주 분류를 위한 합성곱 신경망을 학습시키기 위한 목적으로 대량의 선박 범주 데이터 셋을 구축하고 데이터 셋의 성능을 평가하는 연구도 진행되었다 [7,8,10]. 선박 범주 분류 데이터 셋을 구축하기 위한 연구는 선박 영상을 공유하는 인터넷 사이트에서 선박 영상을 수집한 후, 선박 범주 별 데이터의 양, 선박 범주 간 유사성 등을 분석하고 세분화된 선박 범주를 통합하여 최종적으로 구별해야 되는 선박 범주를 정의하였다. E2S2-Vessel 데이터 셋 [7]은 선박을 35개 범주로 분류하였으며, Marvel 데이터 셋 [10]은 선박을 26개 범주로 구분하였다.

E2S2-Vessel 데이터 셋의 총 이미지의 수는 약 13만장 정도이며, 이 중 80%를 학습 데이터로 사용하고 나머지를 테스트 데이터로 사용하여 분류 성능을 검증하였다. AlexNet [11]을 사용한 선박 범주 분류 성능 실험에서 35개의 선박 범주를 약 80%의 정확도로 분류함을 보여주었다.

Marvel 데이터 셋은 26개 범주, 약 23만장 정도 규모이며, 각 범주가 모두 학습 데이터 8,192 장, 테스트 데이터 1,024장으로 구성되어 있다. 선박 범주를 분류하기 위한 방법으로 VGG 네트워크 [12]에서 추출된 특징을 사용한 SVM과 AlexNet [11]을 사용하였으며, SVM은 54%, AlexNet은 73%의 분류 정확도를 보여주었다.

최근 전함과 상선 등 대형선을 각각 세 개의 세부 범주로 구분하고, 소형선으로 보트까지 추가하여 총 7개의 선박 범주를 Faster R-CNN [14]을 사용하여 분류하려는 연구가 진행되었다 [8]. 기존의 방법들이 영상 분류를 위한 딥러닝 프레임워크를 사용한 것과 달리 이 방법은 동영상에서 Faster R-CNN 프레임워크를 사용하여 프레임 단위로 객체 검출 및 분류를 수행하고, 다수 프레임에서의 검출 결과를 베이시안 함수를 사용하여 통합하여 판단함으로써 객체 분류의 정확도를 향상 시켰다.

해양 환경에서 선박의 범주를 분류하기 위해서 다양한 데이터 셋들이 제안 되었지만, 기존 데이터 셋은 국제해상충돌예방규칙과 무관하게 수집된 데이터의 특성을 분석하여 선박 범주를 정의하고 있다. 따라서 자율운항선박이 국제해상충돌예방규칙을 준수하기 위해서는 국제해상충돌예방규칙에 맞는 선박의 범주를 새롭게 정의해야 되며, 이를 기반으로 선박 범주의 분류 성능을 높이기 위한 연구가 필요하다.

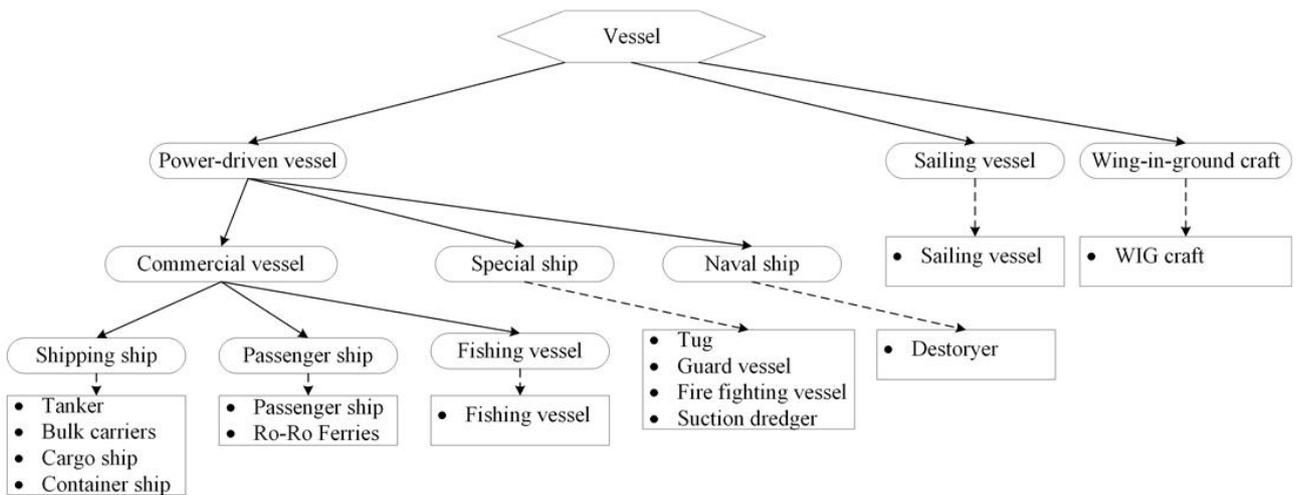


그림 1. 국제해상충돌예방규칙을 준수하기 위한 선박 분류
 Fig. 1. Vessel taxonomy for complying with the COLREGs

3. 국제해상충돌예방규칙을 위한 선박 범주

국제해상충돌예방규칙은 국제해상기구에서 바다를 운항하는 선박 간 충돌 사고를 예방하기 위하여 1972년 채택한 협약으로, 1977년부터 적용되고 있다. 국제해상충돌예방규칙은 해상에서 조우하는 선박이 충돌을 회피하기 위해서 따라야 하는 일련의 절차를 제시하고 있다 [5]. 국제해상충돌예방규칙은 규칙의 적용 범위 및 용어를 정의하는 총칙, 모든 상태의 시계 또는 상호시계, 제한된 시계 등의 상황에 따른 항법 규정, 선박의 운항 의도를 표현하기 위한 등화 및 형상물, 음향 및 발광신호에 대한 규정 등으로 구성되어 있다. 이 규칙은 외양 항해선이 항행할 수 있는 해양과 이와 접속되어 항행선이 항행할 수 있는 모든 수역의 모든 선박에 적용된다. 따라서 자율운항선박도 국제해상충돌예방규칙을 준수해야 하며, 이를 위해서는 선박의 범주를 인식하는 것이 필요하다.

국제해상충돌예방규칙의 1장 제1조 총칙에서는 규칙의 적용 범위를 규정하고, 제2조에서는 규칙 이행을 태만히 한 결과에 대한 책임을 기술하고 있다. 1장 제3조에서는 규칙의 적용 대상이 되는 선박 및 관련된 용어들을 정의하고 있다. 1장 제3조에서는 선박을 배수량을 갖지 아니 하는 선박, WIG(Wing-in-ground)선 및 수상항공기를 포함한 운송수단으로 정의하고 있으며, 선박은 기계를 동력으로 사용하여 움직이는 동력선과 추진 장치를 사용하지 않고 돛을 사용하는 범선으로 구분하고 있다. 따라서 본 논문에서 국제해상충돌예방규칙 준수를 위한 선박의 대분류를 동력선과 범선 및 WIG 선으로 구분하였으며, 본 논문에서 제안하는 국제해상충돌예방규칙을 준수하기 위한 선박 분류는 그림 1과 같이 3개의 대분류 및 14개의 세부 범주로 구성된다.

국제해상충돌예방규칙의 1장 제3조에서는 조정능력이 제한된

선박을 세부적으로 규정하고 있다. 조정능력이 제한된 선박은 예인 작업에 종사하고 있는 선박, 준설, 측량 등의 작업에 종사하고 있는 선박, 기뢰제거 작업에 종사하고 있는 선박 등 종사하고 있는 작업의 성질 상 규칙에서 정의한대로 조정 할 수 없어 타선의 진로를 피할 수 없는 선박을 의미한다. 이와 같은 선박의 경우 타선과 충돌을 피하기 위해서는 예외 규정을 적용해야 되기 때문에 선박의 세부 범주로 구별되어야 한다.

국제해상충돌예방규칙의 2장 제1조에서는 모든 상태의 시계 내에서 선박이 운항할 때 지켜야 하는 견시, 선박의 안전운항 속도, 충돌을 피하기 위한 기본적인 원칙을 제시하고 있다. 또한 협수도에서 범선이나 어로에 종사중인 선박이 지켜야 되는 규칙과 통항분리방식에서 선박들이 지켜야 되는 규칙에 대해서 정의하고 있다.

국제해상충돌예방규칙의 2장 제2조에서는 상호 시계 내에 있는 선박의 운항 규칙에 대해서 정의하고 있다. 선박이 서로 접근하여 충돌할 위험이 있는 경우, 2장 제1조에서 규정하고 있는 경우를 제외하고 동력선은 운전이 자유롭지 못한 상태의 선박, 조정능력이 제한을 받고 있는 선박, 어로에 종사하고 있는 선박, 범선 등의 진로를 피해야 한다고 정의하고 있다.

본 논문에서는 선박의 대분류를 세분화하기 위하여 다양한 범주를 가질 수 있는 동력선의 경우 목적에 따라서 상선, 특수선, 군함 등의 중분류로 구분하였다. 범선과 WIG선의 경우 각각 외형적으로 유사한 특성을 가지기 때문에 범주를 세분화하지 않았다. 상선, 특수선, 군함 등의 중분류는 각 범주의 선박 형태가 매우 다양하기 때문에 용도에 따라서 세부적으로 분류하였다. 상선은 선박의 용도에 따라서 화물선, 여객선, 어선 등으로 구분되며, 화물선의 경우 적재하는 화물의 종류에 따라서 4가지 범주로 구분하였다 [6]. 여객선의 경우 사람만 탑승하는



그림 2. 국제해상충돌예방규칙 준수를 위한 선박 분류 데이터 셋 샘플 영상
 Fig. 2. Sample image for each of the vessel categories for comply with the COLREGS

여객선과 사람과 짐을 모두 운반하는 연락선으로 구분하였다. 특수선은 견인선, 감시정, 소방선, 준설선 등 선박이 사용되는 용도로 구분하였다. 군함은 많은 세부 범주를 가지고 있지만 본 논문에서는 자율운항선박과 조우할 가능성이 가장 큰 구축함만을 고려하였다. 또한, 국제해상충돌예방규칙에서 정의한 조정능력이 제한된 선박을 고려하기 위하여 견인선, 준설선, 어선 등을 세부 범주를 포함하였으며, 긴급 상황에서 타선으로부터 진로의 우선순위를 가질 필요가 있는 선박을 고려하기 위하여 감시정, 소방선, 구축함 등을 별도로 분류하였다.

공유 사이트와 인터넷 영상 검색을 통하여 수집하였다. 본 논문에서는 구축한 국제해상충돌예방규칙 준수를 위한 선박 범주 데이터 셋은 14개 범주 총 40,300장의 이미지로 구성되며, WIG선을 제외한 13개 선박 범주는 3,000장, WIG선은 1,300장의 영상으로 구성되어 있다. 그림 2는 본 논문에서 사용한 14개 선박 범주의 대표 영상을 나타낸다.

본 논문에서 구축한 국제해상충돌예방규칙 준수를 위한 선박 범주 분류 데이터 셋의 성능을 측정하기 위하여 합성곱 신경망(CNNs, Convolutional Neural Networks)을 사용하였다. 합성곱 신경망은 영상 인식 분야에서 뛰어난 성능을 보여 주었으며 [11], 이후 음향 인식, 센서

4. 선박 범주 분류 데이터 셋 및 합성곱 신경망

본 논문에서 정의한 국제해상충돌예방규칙 준수를 위한 선박 범주의 분류 성능을 살펴보기 위하여 먼저 선박 범주 분류 데이터 셋을 구축하였다. 기존 연구에서 많은 데이터 셋들 [6,7,9,10,14]이 구축되었지만, Marvel 데이터 셋 [10]만 공개되어 본 연구에서 활용 가능하였다. Marvel 데이터 셋은 선박 사진 공유 사이트로부터 선박 영상을 수집하여 26개 범주, 총 23만장 정도의 규모이지만, 한 개의 선박 영상이 다수의 선박 범주에 매핑 되어 실제 유일하게 존재하는 영상의 수는 17만장 규모이다. 또한 선박의 외부가 아닌 내부 실내 사진, 선박의 일부만 존재하는 사진 등 잘못 분류된 영상들이 다수 존재하여 그대로 활용하기에는 어려움이 있다.

따라서 본 논문에서는 Marvel 데이터 셋의 선박 범주와 본 연구에서 정의한 선박 범주가 일치하는 경우, 해당 범주에서 중복 영상을 제거한 후 데이터를 정제하여 사용하였다. Marvel 데이터 중 선박의 외형과 관련이 없는 영상(선실, 갑판 등)과 산, 건물 등의 배경이 두드러지는 영상, 선박 상공에서 수직으로 촬영한 영상 등은 선박을 분류하는 데 있어 도움이 되지 않는다고 판단하여 제외하였다. Marvel 데이터 셋에 없는 감시정, 구축함, WIG선 등의 선박 범주 데이터들은 선박 영상

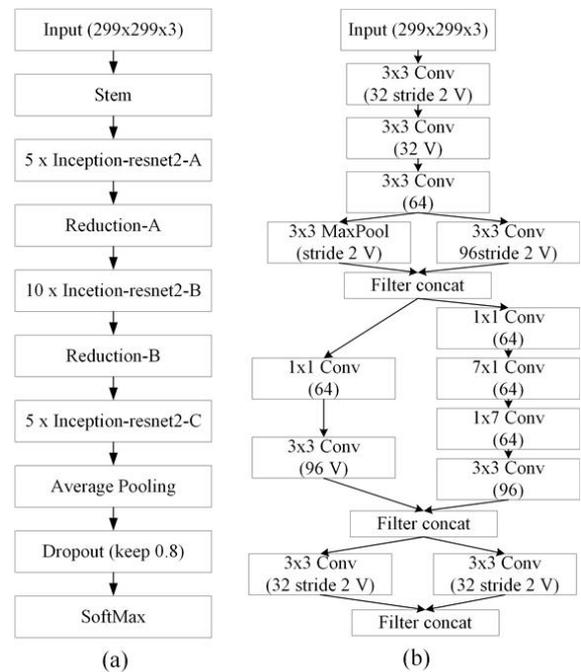


그림 3. (a) Inception-ResNet v2 네트워크 구조 (b) 스템 레이어의 상세 구조 [18]

Fig. 3. (a) Overall schema for the Inception-ResNet v2 network (b) detailed composition of the stem layer (reproduced from reference [18])

데이터 분석 등의 다양한 분야에서 적용되어 높은 성능을 보여주고 있다. 영상 인식 분야에서 비약적인 성능 향상을 보여준 AlexNet [11] 이후 다양한 합성곱 신경망들이 제안되고 있다. 이 중 신경망 층 사이에 잔류 네트워크(residual network)를 연결하여 신경망 층을 우회할 수 있도록 함으로써 신경망의 깊이를 비약적으로 증가시키면서 학습에 소요되는 시간을 줄일 수 있는 합성곱 신경망 모델이 제안되어 영상인식대회에서 높은 성능을 보여주었다 [16]. 또한 한 개의 합성곱을 다수의 작은 합성곱으로 이루어진 미니 네트워크로 구성하여 계층마다 반복적으로 합성곱 연산을 수행함으로써 다양한 해상도의 특징을 반영함과 동시에 합성곱의 연산량을 줄일 수 있는 합성곱 신경망 모델도 제안되었다 [17].

최근에는 잔류 네트워크를 사용한 신경망과 작은 합성곱으로 이루어진 네트워크를 사용한 신경망의 장점을 결합한 Inception-ResNet v2 불리는 합성곱 신경망 모델이 제안되어 기존의 모델보다 뛰어난 성능을 보여주었다 [18]. 따라서 본 논문에서는 최근 기술 동향을 반영하여 선박 범주를 분류하기 위한 합성곱 신경망 모델로 Inception-ResNet v2 모델을 사용하였으며, 합성곱 신경망 모델의 전체 구조 및 스텝 레이어의 상세 구조는 그림 3과 같다.

5. 선박 범주 분류 실험 결과

본 논문에서 새롭게 제안한 선박 범주를 기반으로 구축된 데이터 셋과 Inception-ResNet v2 모델을 사용하여 선박 범주의 분류 성능을 측정하였다. 선박 범주 분류 실험을 위한 프로그램은 Python과 TensorFlow를 백엔드로 사용하는 Keras 라이브러리를 사용하여 구현되었으며, 실험은 인텔 i7-6700K 프로세서와 GTX 1080 Ti 그래픽 카드가 탑재된 윈도우 10 64 bit 환경에서 수행되었다.

본 연구에서 구축한 선박 범주 데이터 셋은 14개 범주 총 40,300 장으로 Inception-ResNet v2 모델을 새롭게 학습시키기에는 데이터의 양이 부족하여 전이학습을 사용하였다. 전이학습은 다른 도메인에서 사전 학습된 모델을 새로운 도메인의 데이터를 이용하여 재학습시켜 최적 모델을 생성하는 방법으로써, 최근 다양한 분야에 적용되어 상대적으로 적은 시간과 자원으로 높은 성능을 보여주고 있다 [19, 20]. 본 연구에서는 기존의 ImageNet 데이터를 사용하여 만들어진 네트워크 모델의 마지막 완전연결 계층만을 미세 조정하는 전이학습 방법을 사용하였다. 선박 범주 데이터 셋의 각 범주 별 70%의 데이터를

표 1. 데이터 셋 상세 정보

Table 1. Details of the dataset

Class	Training set	Test set
13 classes (excluding WIG craft)	27,300 (2,100 per class)	11,700 (900 per class)
WIG craft	910	390
Total	28,210	12,090

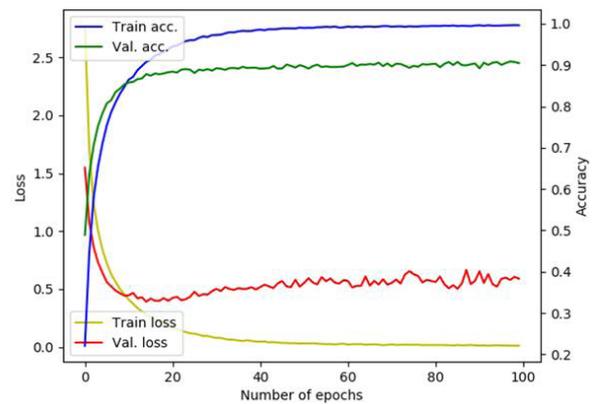


그림 4. 학습 및 검증 데이터의 정확도와 손실 값 흐름

Fig. 4. Traces of the accuracy and loss of training and validation

학습 데이터로 사용하고, 학습 데이터 중 20%의 데이터를 학습 모델을 검증하기 위한 데이터로 사용하였다. 전체 선박 범주 데이터 셋의 30%를 테스트 데이터로 사용하였으며, 데이터 셋의 상세한 구성은 표 1에 표시하였다.

Inception-ResNet v2 모델은 299 x 299의 해상도를 가진 영상을 입력으로 사용하기 때문에 데이터 셋의 영상 크기를 입력에 맞게 변경하는 전처리 과정을 수행하였다. 또한, 분류 모델의 성능 향상을 위하여 이미지에 회전, 수평 플립, 가로 및 세로 위치 이동 등의 방법을 적용하여 데이터의 수를 확장하는 데이터 증강(data augmentation) 기법을 추가로 사용하였다.

합성곱 신경망 모델의 학습을 위해서는 Adam 최적화 방법을 사용하였으며 학습 비율은 0.00001로 설정하였다. 배치 사이즈는 클수록 학습 속도가 향상되지만, 메모리의 제한을 고려하여 24로 설정하였다. 반복(epoch) 횟수는 학습 모델의 분류 정확도 및 일반화 성능에 영향을 많이 주기 때문에 반복 횟수에 따른 검증 데이터의 분류 성능 및 손실 값의 흐름을 관찰하였다.

그림 4는 학습 및 검증 데이터에 대한 정확도 및 손실 값의 흐름을 나타낸다. 반복 횟수가 20 이전에서는 학습 및 검증 데이터에 대한 손실 값이 같이 감소하지만, 그 이후에는 검증 데이터에 대한 손실 값이 증가함을 보여준다. 따라서 Inception-ResNet v2 모델 학습 할 때에는 과적합(overfitting)을 방지하기 위하여 조기 중단(early stopping) 방법을 사용하였다. 조기 중단 방법은 검증 데이터에 대한 손실 값을 관찰하여 10회 이상 손실 값의 감소가 없는 경우 학습을 중단하도록 설정하였다.

선박 범주에 대한 분류 성능은 Inception-ResNet v2 모델에 조기 중단 방법을 적용한 후 10번 반복하여 측정하였으며, 분류 모델 학습 과정에서 한 번 반복을 수행하는데 평균 750초가 소요되었다. Inception-ResNet v2 모델의 테스트 데이터에 대한 선박 범주 분류 정확도는 91.20 ± 0.27 %이며, 정규화된 선박 범주 분류 행렬은 그림 5에 표시하였다. 그림 5를 살펴보면 화물선, 여객선 등의 동일 범주에 속한 세부 범주

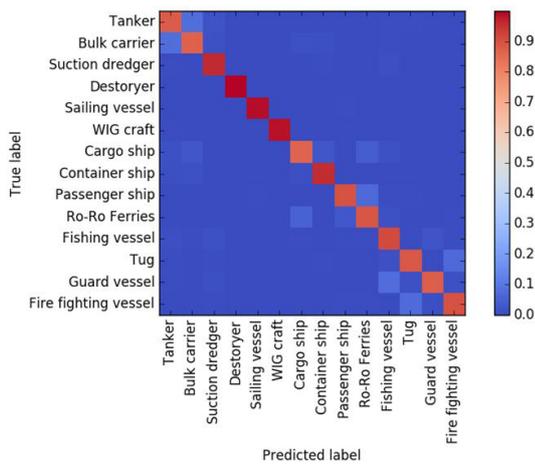


그림 5. Inception-ResNet v2 모델의 정규화된 선박 범주 분류 행렬
 Fig. 5. Normalized confusion matrix of Inception-ResNet v2 for vessel classification task

선박들의 분류 성능이 낮음을 확인 할 수 있다. 특히 화물선의 세부 범주인 'Tanker' 와 'Bulk Carrier' 의 분류 정확도가 낮게 나타났다. 이는 동일 범주에 속한 세부 범주 간 형태적 유사성이 크기 때문이며, 이를 고려하여 선박 범주의 분류 정확도를 향상시키기 위한 방법에 대한 추가적인 연구가 필요하다.

6. 결론 및 향후 연구

본 논문에서는 처음으로 자율운항선박이 국제해상충돌예방규칙을 준수하기 위해 필요한 선박의 범주를 정의하고, 정의된 선박 범주의 분류 성능을 평가하기 위한 선박 범주 분류 데이터 셋을 구축하였다. 또한 자율운항선박에서 선박 범주 분류 기술의 활용 가능성을 확인하기 위하여 최신 합성곱 신경망 모델인 Inception-ResNet v2 모델을 구축된 선박 범주 분류 데이터 셋에 적용하여 분류 성능을 분석하였다. Inception-ResNet v2 모델은 14개 선박 범주를 91% 이상의 높은 정확도로 분류하여 자율운항선박에 활용 가능할 것으로 판단된다.

향후 연구에서는 현재 부족한 WIG선의 데이터를 비롯하여 기 구축된 선박 범주 분류 데이터 셋을 확장하고, 합성곱 신경망의 학습 성능을 향상시키기 위하여 입력 영상에서 선박 영역을 정교하게 검출하는 방법 등의 전처리 방법에 대한 연구를 진행할 예정이다. 또한 선박 범주에 특화된 합성곱 신경망 모델을 설계하여 기존의 합성곱 신경망들과 분류 성능을 비교하는 연구도 진행할 예정이다. 마지막으로, 자율운항선박이 국제해상충돌예방규칙을 완전히 준수 할 수 있도록 해양 영상에서 존재하는 다양한 객체를 인지하고 객체들의 히스토리 정보를 분석하여 해양에서 발생하는 상황 정보를 분석할 수 있는 기술에 대한 연구도 추가로 진행할 예정이다.

References

- [1] L. Kretschmann, H.-C. Burmeister, and C. Jahn, "Analyzing the economic benefit of unmanned autonomous ships: An exploratory cost comparison between an autonomous and a conventional bulk carrier," *Research in Transportation Business & Management*, vol. 25, pp. 76-86, Dec. 2017.
- [2] D.S. Kim, "Analysis of Causes of Collision Caused by Human Error of Captain and OOW in Ship collision Accidents," *J. Ergon. Soc. Korea*, vol. 37, pp. 1-13, Dec. 2017
- [3] International Maritime Organization, "Convention on the International Regulations for Preventing Collisions at Sea, 1972 (COLREGs)," Available: <http://www.imo.org/en/pages/default.aspx>, [Accessed: Dec. 25, 2018]
- [4] H. Lang, "Ship Classification in SAR Image by Joint Feature and Classifier Selection," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, no. 2, pp. 212-216, Feb. 2016.
- [5] H. Lang, J. Zhang, T. Zhang, D. Zhao, and J. Meng, "Hierarchical ship detection and recognition with high-resolution polarimetric synthetic aperture radar imagery," *J. Appl. Remote Sens.*, vol. 8, no. 1, May 2014.
- [6] B. Solmaz, E. Gundogdu, K. Karaman, V. Yucesoy, and A. Koc, "Fine-grained visual marine vessel classification for coastal surveillance and defense applications," *Proc. SPIE 10434, Electro-Optical Remote Sensing XI*, Oct. 2017.
- [7] C. Dao-Duc, H. Xiaohui, and O. Morere, "Maritime Vessel Images Classification Using Deep Convolutional Neural Networks," *Proceedings of International Symposium of Information and Communication Technology*, pp. 276-281, 2015
- [8] K. Kim, S. Hong, B. Choi, and E. Kim, "Probabilistic Ship Detection and Classification Using Deep Learning," *Applied Sciences*, vol. 8, no. 6, June 2018.
- [9] D. Bloisi, L. Iocchi, A. Pennisi, and L. Tombolini, "ARGOS-Venice Boat Classification," *Proceedings of 12th IEEE International Conference on Advanced Video and Signal Based Surveillance*, pp. 1-6, Aug. 2015.
- [10] E. Gundogdu, B. Solmaz, V. Yucesoy, and V. Koc, "Marvel: A Large-Scale Image Dataset for Maritime Vessels," *Proceedings of 13th Asian Conference on Computer Vision*, pp. 1-16, Nov. 2016.
- [11] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural network," *Advances in Neural Information Processing Systems*, vol. 25, pp. 1097-1105, 2012.

[12] K. Chatfield, K. Simonyan, A. Vedaldi, and A. Zisserman, "Return of the Devil in the Details: Delving Deep into Convolutional Nets," *Proceedings of British Machine Vision Conference*, pp. 1-11, Sep. 2015.

[13] S. Ren, K. He, R. Girshick, and J. Sun, "Faster-RCNN: Towards real-time object detection with region proposal networks," *Advanced in Neural Information Processing Systems*, pp. 91-99, Dec. 2015.

[14] D.-G. Kim, J. S. Jeong, and G.-K. Park, "A Study on Ship Collision Avoidance Algorithm by CORLEG," *Journal of Korean Institute of Intelligent Systems*, vol. 21, no. 3, pp. 290-295, November 2011.

[15] Y. Cho, J.W. Han, J. Kim, and P. Lee, "Automatic Ship Collision Avoidance Algorithm based on Probabilistic Velocity Obstacle with Consideration of COLREGs," *Journal of the Society of Naval Architects of Korea*, vol. 56, no. 1, pp. 75-81, Feb. 2019.

[16] J. Hoffmann, R. Asariotis, H. Benamara, A. Premti, V. Valentine, and F. Youssef, "Review of Maritime Transport 2016," *United Nations Conference on Trade and Development*, Nov. 2016.

[17] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818-2826, June 2016.

[18] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning," *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, pp. 4278-4284, Feb. 2017.

[19] H. Lee, J. Kim, J. Yu, Y. Jeong, and S. Kim, "Multi-class Classification using Transfer Learning based Convolutional Neural Network," *Journal of Korean Institute of Intelligent Systems*, vol. 28, no. 6, pp. 531-537, Dec. 2018.

[20] W.-S. Jeon, S.-Y. Rhee, and N.-H. Yoo, "Detection of Marine Garbage and Jellyfish Cluster using CNN and Post-processing," *Journal of Korean Institute of Intelligent Systems*, vol. 29, no. 1, pp. 16-22, Feb. 2019.

저자 소개



김민영(Min Yoeng Kim)

2012년 : KOREATECH 컴퓨터공학과 공학사

관심분야 : Deep Learning, Machine Learning

E-mail : goldenwatchplus@gmail.com



정치윤(Chi Yoon Jeong)

2002년 : POSTECH 전자전기공학과 공학사

2004년 : POSTECH 전자전기공학과 공학석사

2018년 : KAIST 전신학부 공학박사

현재 : 한국전자통신연구원 책임연구원

관심분야 : Computer Vision, Machine Learning

E-mail : iamready@etri.re.kr