

공학석사 학위논문

콜라주 데이터 증강기법을 이용한
심층학습 기반의 해상객체 검출에 관한 연구

A Study on Maritime Object Detection
based on Deep Learning using Collage Data Augmentation



지도교수 이 광 일


2020년 8월

한국해양대학교 대학원

제어계측공학과

신 현 철

본 논문을 신현철의 공학석사 학위논문으로 인준함.



위원장 조 석 제

위 원 김 재 훈

위 원 이 광 일



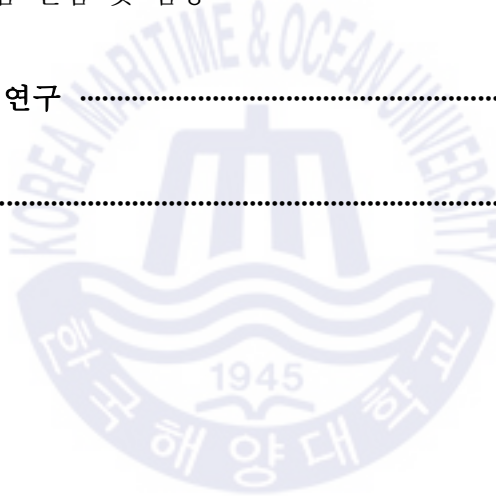
2020년 07월 17일

한국해양대학교 대학원

목 차

List of Tables	iii
List of Figures	iv
Abstract	vi
1. 서론	1
1.1 연구배경 및 필요성	1
1.2 연구목적 및 범위	3
2. 관련 연구	5
2.1 수평선 검출	5
2.2 해상 객체검출	7
2.2.1 심층학습 기반의 객체검출 기법	7
2.2.2 데이터 증강기법	9
2.3 다중센서 정보융합기술	12
3. 연구 방법	14
3.1 이중 허프변환을 활용한 고속수평선검출 기술	14
3.1.1 색상 기반의 관심 영역 설정	16
3.1.2 이중 허프변환	17
3.2 심층학습 기반의 해상 객체검출 기술	18
3.2.1 Retina-Net	18
3.2.2 콜라주 데이터 증강기법	21
3.3 선박자동식별 장치를 이용한 다중센서 정보융합 기술	26
3.3.1 선박자동식별 시스템 메시지 처리 모듈	26

3.4 다중센서 정보융합 시스템 설계	30
3.4.1 수평선 정보를 활용한 표적 대상 필터링	32
3.4.2 거리정보를 활용한 표적 대상 정보융합	33
4. 실험 및 검증	34
4.1 개발 환경	34
4.2 실험 및 검증	35
4.2.1 수평선 검출 실험 및 검증	35
4.2.2 해상 객체검출 실험 및 검증	38
4.2.3 시스템 실험 및 검증	44
5. 결론 및 향후 연구	47
참고문헌	48



List of Tables

Table 1	Image and matrix shapes of collage data augmentation method	22
Table 2	The definition of object size in MS COCO and SMD	23
Table 3	AIS Message parameters, types and descriptions	27
Table 4	Message type 1 : position report class A	28
Table 5	An example sentence of message type 1	29
Table 6	System environments descriptions	34
Table 7	Statistics of errors in Y and α for different methods	36
Table 8	Values of processing time per frame for different methods	36
Table 9	Conditions of precision and recall	39
Table 10	Results of SMD detailed analysis	41
Table 11	Results of object detection in SMD	42
Table 12	Detailed results of object detection in SMD	43
Table 13	Results of the built data set analysis	44
Table 14	Results of object detection of the built data set	44

List of Figures

Fig. 1	An example of ship bridge for maritime situational awareness	1
Fig. 2	Main components of proposed method	3
Fig. 3	An example of horizon detection method(red dotted line)	5
Fig. 4	Object detector architecture based on deep learning approach	8
Fig. 5	Bounding box representation of object in maritime image	9
Fig. 6	Examples of data augmentation methods	10
Fig. 7	Examples of the frame images extracted from SMD	11
Fig. 8	Visual and VTS data projection based on data normalization	13
Fig. 9	Mapping from cartesian coordinates of images	13
Fig. 10	Example of the elements that interfere with horizon detection	14
Fig. 11	Flowchart of the proposed horizon detection method	15
Fig. 12	Multi-scale median filtering process with region of interest	16
Fig. 13	Dual hough transformation applied to the edge detected	17
Fig. 14	Histogram of the object's bounding box area ratio	18
Fig. 15	Many negative background and few positive foreground boxes	19
Fig. 16	Cumulative distribution functions of the normalized loss	20
Fig. 17	Sample images along every 50 frames in SMD	21
Fig. 18	Collage data augmentation method for object detection	24
Fig. 19	The data examples by generated collage data augmentation	25
Fig. 20	An system experiment environment	30

Fig. 21 Process chart of general system 31

Fig. 22 Object filtering processing by selected horizon line 32

Fig. 23 An measurement method for comparing detected horizon line ... 35

Fig. 24 The line indicates the horizon detected by proposed method 37

Fig. 25 Definition of the intersection over union 38

Fig. 26 Results and graphs of SMD analysis 40

Fig. 27 Built data set test image size analysis 44

Fig. 28 Results of object filtering processing by selected horizon line ... 45

Fig. 29 Result of data visualization through multi-sensor data fusion ... 46



l

콜라주 데이터 증강기법을 이용한 심층학습 기반의 해상객체 검출에 관한 연구

신 현 철

한국해양대학교 대학원

제어계측공학과

초록

제 4차 산업혁명 시대를 맞이하여 해양산업 전반으로 인공지능과 빅데이터, 사물인터넷과 같은 진보된 기술이 접목된 해상 물류 4.0(Shipping 4.0) 이라는 새로운 개념이 도입되었다. 해상 물류 4.0에서는 자율운항 선박과 스마트 항만의 개념이 정립되고 있으며, 이는 해상에서 인적오류로 인한 사고의 감소와 작업의 효율성 및 안전성을 위해 해상상황을 올바르게 인지하고 분석하여 자동으로 작업을 수행할 수 있는 해양 상황인식기술이 필수적이다. 최근 인공지능 기술을 기반으로 한 비전 기술을 활용하여 해상상황을 인지하고, 더불어 정보의 신뢰성을 보장하기 위해 선박 자동식별시스템과 같은 다중센서 장치들과의 정보융합을 통한 해양 상황인식기술 연구가 진행되고 있다.

본 논문에서는 해상 상황인식을 위한 심층학습 기반의 해상 객체검출기술을 위해서 콜라주 데이터 증강기법을 제안하였다. 그리고 이중 허프변환을 이용한 고속수평선 검출기술과 선박자동식별 장치를 활용한 다중센서 융합 기술을 제안하고 기술요소들에 따라 시스템을 설계, 개발 및 해상환경에 적용하여 실험을 통해 이를 검증하였다.

제안하는 콜라주 데이터 증강기법을 검증 절차에 따라 공개된 해상 객체검출 데이터 Singapore Maritime Dataset에 실험 및 검증하였을 때, 객체검출 평균 정밀도가 기존보다 약 1.43% 향상되는 것을 확인할 수 있다. 또한, 한국해양대학교에서 촬영한 부산항 인근 해상환경에서 콜라주 데이터 증강기법을 실험 및 검증을 수행하였을 때, 기존보다 약 25.7% 향상됨을 알 수 있다. 고속 수평선검출기술과 다중센서 융합기술을 활용한 전체 시스템의 성능은 약 30.2% 향상되는 것을 확인할 수 있으며, 이를 통해 제안하는 기법이 해상객체 검출의 성능을 높일 수 있고 특히, 범용적인 해상환경에서 효과적으로 성능을 발휘할 수 있음을 알 수 있다.

본 논문에서 제안하는 방법을 통하여 정확한 해상객체 검출이 가능하며 선박자동식별 장치와의 다중센서 정보융합 기술을 통해 유용한 정보를 함께 제공 가능함으로써 인공지능 비전 기술이 적용된 자율운항 선박 및 스마트 항만에서 효율적이고 신뢰성 있는 해상 상황인식기술을 기대한다.



KEY WORDS: 심층학습, 객체검출, 다중센서 정보융합, 수평선 검출, 해상 상황인식

A Study on Maritime Object Detection based on Deep Learning using Collage Data Augmentation

Shin, Hyeon Cheol

Department of Control and Instrumentation Engineering

Graduate School of Korea Maritime and Ocean University

Abstract

In the 4th industrial revolution era, a new concept of shipping logistics 4.0(Shipping 4.0) was introduced that combines advanced technologies such as artificial intelligence, big data, and the internet of things throughout the marine industry. In Shipping 4.0, the concept of autonomous vessels and smart ports is established, which entails technologies that can automatically recognize and analyze maritime conditions and perform work automatically, reducing accidents due to human error at sea and working maritime situational awareness technology is essential for its efficiency and safety. Recently, maritime situational awareness technology is being developed through information fusion with multiple sensors, such as an automatic identification system(AIS), to recognize the maritime situation by using vision technology based on artificial intelligence method and to ensure information reliability.

In this paper, we proposed a collage data augmentation technique for deep learning-based maritime object detection for maritime situational awareness. In addition, we proposed a high-speed horizontal line detection method using a dual hough transform and a multi-sensor fusion method using AIS device, and verified this through experiments by applying the system to design, development, and maritime environments according to technical factors.

When the proposed collage data augmentation method was experimented and verified in the maritime object detection data Singapore Maritime Dataset published according to the verification procedure, it can be seen that the average accuracy of object detection is improved by about 1.43%. In addition, it can be seen that collage data augmentation method has been improved by about 25.7% compared to the previous ones when experiments and verification were conducted in the marine environment near Busan Port, which was taken by Korea Maritime and Ocean University. The performance of the entire system using high-speed horizontal line detection method and multi-sensor data fusion method can be seen to be improved by about 30.2%, which shows that the proposed method can enhance the performance of maritime object detection and, in particular, effectively perform in a general marine environment.

Through the method proposed in this paper, accurate maritime object detection is possible, and useful information can be provided together through the multi-sensor information fusion with AIS device. We expect reliable maritime situational awareness from autonomous ship and smart port.

KEY WORDS: Deep learning, Object detection, Multi-sensor data fusion, Horizon detection, Maritime situational awareness

제 1 장 서 론

1.1 연구배경 및 필요성

해양 분야에서는 최근 제 4차 산업혁명 시대와 함께 해상 물류 4.0(Shipping 4.0)이라는 새로운 개념의 도입이 진행되어 인공지능(artificial intelligent), 빅데이터(big data), 해상 사물인터넷(internet of things at sea) 등의 기술들이 접목되어 활용되고 있다. 이를 통해, 효율성, 안전성 및 신뢰성을 달성하기 위한 친환경/스마트 자율운항 선박을 위한 개발이 이슈이다[1, 2].

자율운항 선박(Maritime Autonomous Surface Ship, MASS)이란, 다양한 자율단계에서 인간의 상호작용과 독립적으로 작동할 수 있는 선박으로 국제해사기구(International Maritime Organization, IMO)에서 정의하고 있다[3]. 자율운항 선박이 안전하고 효율적인 운항을 자율적으로 행하기 위해서는 인간의 시각적 역할을 담당하는 해상 상황인식기술이 중요한 기술요소로 여겨진다. 해상 상황인식 기술은 Fig. 1과 같이 해상에서 발생할 수 있는 각종 상황에 대해 인간의 시각 인지 능력을 대체 또는 보조하는 기능으로 관련된 이해 관계자들에게 의사결정 또는 자율운항에 필요한 정보를 제공할 수 있는 기술을 말한다.



Fig. 2 An example of ship bridge for maritime situational awareness

해상 상황인식을 위해서는 단일 센서만을 활용하는 것이 아닌 다중센서 기반의 정보융합을 통해 신뢰성 있고 데이터를 제공하는 것이 중요하다. 그중에서 특히, 해상의 주변 상황을 인지하기 위해 인간의 시각 정보와 유사한 카메라를 활용하여 자동으로 객체 정보를 획득하는 기술에서 객체검출 기술은 해상 상황 인식기술의 전반적인 성능을 좌우하는 중요한 역할을 담당한다. 최근 인공지능 기술요소 중 인공 신경망(neural network)을 활용한 심층학습(deep learning)을 통해 발전된 객체검출이 기존 방법보다 뛰어난 성능을 보여 이를 활용한 관련 연구들이 진행되었다[4].

심층학습은 주어진 데이터에서 설계된 인공 신경망을 통해 자동으로 학습하여 결과를 추론하는 기술로 질 좋은 대량의 데이터와 인공 신경망 알고리즘 모델을 설계하는 두 기술이 주요 핵심 요소이다. 이러한 방법은 주어진 데이터에 의존하여 학습하기 때문에 뛰어난 성능을 보이는 인공 신경망 모델일지라도, 주어진 데이터의 품질이 나쁘면 좋은 성능을 보일 수 없으며 데이터의 양이 적으면 학습 데이터에만 좋은 성능을 보이는 과적합(over-fitting) 문제가 발생한다. 따라서 수행하고자 하는 과제의 기반이 되는 대량의 데이터를 확보하는 것뿐만 아니라 심층학습 모델이 올바른 학습을 진행하고 좋은 성능을 보이기 위한 질 좋은 데이터를 구축하는 것이 중요하다.

하지만, 일반적으로 많은 인적자원을 활용하여 수작업으로 데이터를 구축하여야 하므로 심층학습을 활용한 연구를 수행하기 위해 대량의 좋은 데이터를 확보하는 것은 우선으로 고려되는 사항이다. 현재 심층학습을 활용하여 해상객체 검출에 활용될 수 있는 데이터는 SMD(Singapore Maritime Dataset)[5]가 유일한 상황이지만[6], 영상을 기반으로 데이터가 구축되어 한 영상에서 환경적 변화가 적어 다양한 특징을 학습하기엔 어려움이 따라 과적합 문제가 발생할 수 있는 문제점이 있다. 이러한 문제점을 해결하기 위해 데이터를 가공하여 확장시키는 데이터 증강기법이 활용되었으며 품질 좋은 대량의 데이터를 효율적이고 경제적으로 생성하기 위해 많은 실험과정 및 분석과정이 고려되어야 한다.

1.2 연구목적 및 범위

본 논문에서는 자율운항 선박의 주변 상황을 인식하기 위한 해상객체검출기술 개발과 다중센서 정보융합기술에 대해서 다루고 있다. 이를 위해 콜라주 데이터 증강기법을 활용한 심층학습 기반의 해상객체 검출과 선박자동식별 시스템 장치와 카메라 정보의 융합을 통하여 항해자에게 시각적으로 표현하는 시스템에 대해서 제안하고 있다. 또한, 해상객체검출의 성능을 높이기 위해 고속으로 정확한 수평선 검출기술을 제안한다.

본 논문에서는 연구 목표인 해상 상황인식기술 개발을 수행하기 위해서 활용된 주요 기술요소로는 Fig. 2와 같이 수평선 검출기술, 심층학습을 활용한 해상객체 검출기술, 선박자동식별 시스템 센서를 포함한 다중센서 정보융합기술을 제안한다.

해상 객체검출 기술은 영상에서 객체가 위치하는 좌표와 객체분류 기술을 동시에 수행하는 기술이다. 따라서 객체가 존재할 후보 영역을 검출하는 것과 함께 객체의 유무 및 종류를 판별하는 객체분류기술이 수행되는 것을 포함한다. 검출기술은 검출한 후보 영역을 기반으로 표적 대상을 선정하여 수행하기 때문에 해상 상황인식기술 전반에 지대한 영향을 끼친다[7].

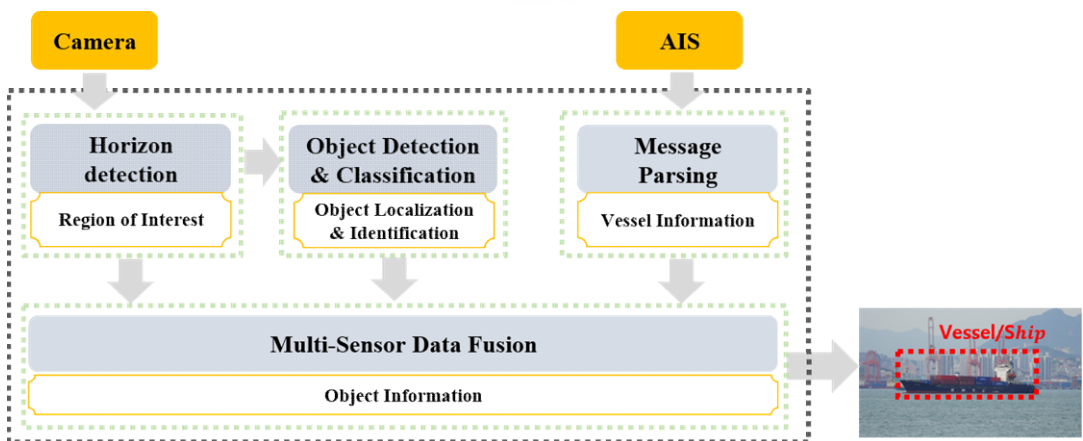


Fig. 3 Main components of the proposed method

다중센서 정보융합(Multi-sensor data fusion)기술은 여러 센서로부터 취득된 정보를 결합하여 유용한 정보를 함께 제공하는 기술을 말한다. 해상 상황인식에서 사용되는 센서는 카메라, 적외선 카메라, 레이더 및 선박자동식별 시스템 센서가 있다.

수평선 검출 기술은 하늘과 바다 또는 육지와 바다를 구분 짓는 경계를 구분하는 기술이다. 수평선을 기반으로 관심 영역(region of interest)을 설정하면 영역 이외의 잡음을 제거하여 알고리즘 성능향상과 연산량 및 수행시간 단축이 가능하다[8]. 그리고 수평선을 기준으로 흔들리는 영상의 기울기 보정 및 표적 대상과의 거리산출에 활용될 수 있다[9, 10].

본 논문에서는 심층학습 기반의 해상객체 검출을 중심으로 하여 해상 객체검출 데이터의 특징을 분석 및 활용하고 항해자에게 효율적으로 신뢰성 있는 해상상황 정보를 제공하기 위해 선박자동식별 장치와 수평선 정보를 활용한 다중센서 정보융합기술을 제시하고자 한다. 이를 바탕으로 심층학습을 위해 활용되는 해상 영상 데이터의 부족한 데이터 특징을 극복하기 위해 데이터 증강기법을 제안하고 수평선 정보와 선박자동식별 시스템에서 수신한 메시지를 활용하여 시스템을 구성하고 제안한 방법의 타당성을 실제 해상환경에 적용하여 검증하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문과 관련된 주요 기술요소의 관련된 연구 동향을 살펴본다. 3장에서는 본 논문에서 제안하는 연구 방법에 관하여 기술하고 4장에서 실험 및 검증 과정을 설명한다. 마지막으로 5장에서 본 논문의 결론을 맺고 향후 연구과제에 대해 살펴보하고자 한다.

제 2 장 관련 연구

본 장에서는 본 논문에서 제안하는 해상 상황인식기술을 위해 필요한 기술요소로 수평선 검출기술, 심층학습 기반의 객체검출 기술, 그리고 선박자동식별 시스템과의 다중센서 정보융합기술에 관한 관련 연구를 기술한다

2.1 수평선 검출

수평선 검출은 상황인지를 위한 첫 단계로 정확한 경계를 구분하는 것이 핵심으로, 최근 자율운항 선박과 같이 선상에서 동적으로 시시각각 변화하는 환경에서는 빠른 연산 수행 성능 또한 중요한 요소로 인식될 수 있다. 해상 영상에서 수평선은 Fig. 3과 같이 하늘과 바다 또는 육지와 바다를 구분하는 하나의 긴 경계선으로 선형적 특성이 강한 성분을 찾는 연구가 수행되었다.

일반적으로 하나의 긴 직선으로 표현되는 수평선의 선형적 특성을 검출하기 위해 영상이 에지(edge) 정보를 활용한 방법이 제안되었다. 케니(Canny) 에지 검출기[11]를 통해 에지 맵(edge map)을 생성한 후 대표적으로 허프변환(Hough transform)[12]과 같이 영상 좌표 공간에서 다른 매개변수 공간으로 투영(projection)하는 수평선 검출기법이 제안되었다[10, 13]. 이 방식은 비교적 간단하고 연산 수행시간이 짧은 장점이 있으나, 잡음에 민감하여 오검출 확률이 높은 단점이 있다.



Fig. 4 An example of horizon line detection (red dotted line)

에지 성분의 기울기(gradient)를 활용하는 방법으로는 영상에서 수직 방향의 강도(intensity)를 분석하여 수직 방향이 강한 에지를 기반으로 하나의 수평선을 검출하는 방법이 제안되었다[14]. 이 방식은 비교적 적은 계산복잡도를 가지고 있으나 수평선 주위에 선박과 같은 물체로 인한 폐색(occlusion) 현상에 민감한 단점이 있다.

다중 스케일(Multi-scale) 방식은 수평선 검출을 저해하는 선형적 잡음을 갖는 에지 성분을 완화하기 위해 제안되었다[15, 16]. 다중 스케일 연산은 여러 크기를 갖는 영상에 대해 잡음을 제거하기 위한 블러링 연산을 수행한 후, 에지맵을 병합한다. 이 방식은 주변 잡음을 제거함과 동시에 수평선의 선형적 특징을 보장할 수 있어 높은 수평선 검출 정확도를 보였다. 하지만 다양한 스케일 연산을 수행하기 때문에 연산 시간이 오래 걸리는 단점이 있다.

바다와 다른 지역을 구분하는 경계선으로 사용되는 특징을 활용한 연구로 이미지를 바다와 하늘이 포함된 지역의 성분을 통계적으로 분석하여 영역을 분할하는 방법이 제안되었다[9]. 이 방식은 픽셀 기반의 지역적 정보를 기반으로 수평선을 검출하기 때문에, 에지 성분을 활용한 방법보다 강인한 수평선 검출이 가능하지만, 많은 연산량이 요구되는 단점이 있다.

에지 성분을 활용한 기법과 통계적 분석 기법의 단점을 보완하고 장점을 활용하기 위해 허프 변환과 통계적 분석 기법을 결합하여 수평선 탐지 정확도를 높이는 하이브리드(hybrid) 방법이 제안되었다[16]. 허프변환을 사용하여 후보선을 찾고 RGB 색상 기반의 분포도를 분석하여 하늘과 바다가 포함된 지역의 차이를 최대화하여 최적의 수평선을 검출한다. 하이브리드 방식은 단일 기법을 사용한 방법에 비해 정확도가 향상되었으나, 여전히 많은 연산량과 시간이 요구되고 파도의 장파나 항적과 같은 잡음에 민감한 단점이 있다.

본 논문에서는 잡음에 강인하고 정확한 수평선 검출을 수행하기 위해 멀티 스케일 기법을 사용하고 색상 기반의 관심 영역을 설정하여 멀티 스케일 연산 시간의 단점을 보완하여 정확하고 고속의 수평선 검출을 수행한다. 관련된 내용은 3장에서 기술할 것이다.

2.2 해상 객체검출

기존의 객체검출 및 분류기법은 주어진 이미지에서 색상, 윤곽선 등 가용할 특징을 결정하고 추출하기 위한 전반적인 것을 엔지니어의 알고리즘 설계에 따라 수행된다[4]. 즉, 엔지니어가 직접 데이터를 분석하여 규칙을 기반으로 수행하는 반면, 인공지능 기법에서 기계학습(machine learning)은 대량의 데이터를 기반으로 인공 신경망 등을 통해 데이터의 규칙을 자동으로 학습하고 추출한다. 기계학습 분야에서 인공 신경망을 활용하여 깊게 쌓아 계층적으로 학습을 진행하는 것을 심층학습이라 하는데, 어떠한 문제에 대해 지속적인 경험을 통해 성능을 높이는 것으로 이를 학습할 좋은 품질의 데이터와 스스로 규칙을 형성할 인공 신경망 알고리즘에 관한 관련 연구가 수행되었다. 최근 엔지니어가 직접 설계한 기존 방법보다 대량의 데이터를 기반으로 기계학습을 통해 추론된 규칙이 좀 더 좋은 결과를 보였으며, 해상객체 검출 및 분류기술에 많은 관련된 연구가 수행되고 있다[17].

2.2.1 심층학습 기반의 객체 검출기법

일반적으로 심층학습을 활용한 객체검출 기술은 객체가 위치할 곳을 판단하는 영역 제안(regional proposal)과 객체를 인지하는 분류(classification)가 모두 수행되는 과제로, 이를 수행하는 방식은 절차의 단계(stage)에 따라 1-단계와 2-단계 검출기로 구분된다. 단계를 구분하는 기준은 Fig. 4-(a)와 같이 순차적으로 수행하면 2-단계, Fig. 4-(b)와 같이 영역제안과 객체분류를 동시에 수행하면 1-단계로 구분된다.

먼저, 2-단계 검출기 방식의 경우 입력받은 이미지에서 RPN(Region Proposal Network)[18], selective search[19] 등의 방법으로 객체가 위치할 영역을 제안받는다. 그리고 제안된 영역에 대해서 기학습(pre-trained)된 객체분류 모델을 통해 객체분류를 수행하여 객체의 유무와 종류를 결정한다. 이처럼 차례로 영역 제안과 객체분류를 수행하는 방식을 R-CNN(Region proposal Convolution Neural Network) 계열의 검출기로 표현하고 대표적으로 Faster R-CNN[18],

Mask R-CNN[20] 등의 2-단계 검출기들이 있다. 이 방식은 제안된 모든 영역에 객체분류를 수행하여 정확도가 높은 장점이 있으나, 연산량이 많아 수행시간이 낮은 단점이 있다.

1-단계 검출기 방식은, 입력받은 이미지 속 객체들의 특징들을 기반으로 객체의 위치 및 종류를 동시에 결정한다. 객체들이 가진 주요한 특징들은 입력 이미지에 심층학습 기반의 기학습된 객체분류 모델을 적용하여 추출하는데, 이를 특징 맵(feature map)이라 한다. 생성된 특징 맵을 구성하는 이미지 속 객체들의 특징들을 기반으로 객체의 위치 및 종류를 동시에 결정하여 1-단계 검출기로 표현하고. 대표적으로 SSD(Single Shot Multi Detector)[21], YOLO(You Look Only Once)[22], Retina-Net[23] 등의 1-단계 검출기들이 있다. 이 방식은 2-단계 검출기에 비해 빠르게 연산 수행이 가능한 장점이 있으며, 최근 2-단계 검출기의 성능과 견주어 보았을 때 준수한 정확도를 보여 빠른 객체검출을 수행하는 과제에서 주로 활용된다.

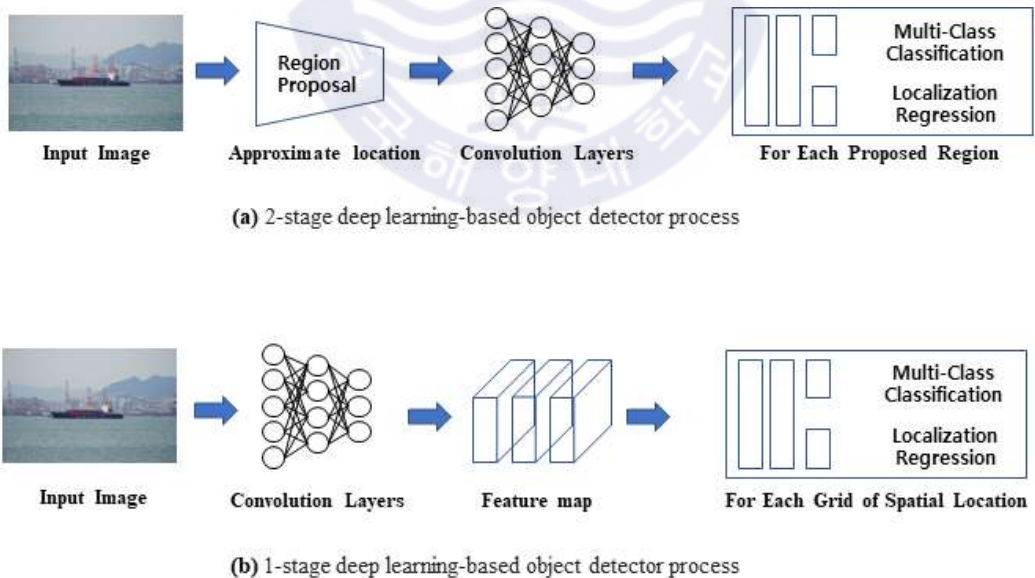


Fig. 5 Object detector architecture based on deep learning approach

2.2.2 데이터 증강기법

심층학습을 활용한 객체 검출기법은 대량의 데이터를 바탕으로 규칙을 생성하기 때문에 데이터의 품질과 양에 따라 성능 차이를 보인다. 앞서 설명하였듯이 검출기술은 객체의 위치 정보와 함께 객체분류를 수행해야 하므로 이에 따른 데이터의 구성은 Fig. 5와 같이 객체가 위치할 경계 상자(bounding box)와 객체의 종류(class)로 구성되어야 한다.

객체검출을 위한 데이터를 구축하는 것은 일반적으로 수작업을 통해 데이터를 생성하게 되는데, 이는 많은 인적자원과 시간이 소모된다. 따라서 양질의 데이터를 구축하기 어려운 문제를 해결하고 한정된 자원을 효율적으로 활용하기 위한 데이터 증강기법이 활용되었다. 데이터 증강기법이란, 회전, 크기, 색상, 조도, 합성 등의 동작들을 통해 이미지를 가공하여 부족한 훈련데이터를 보완하기 위해 새로운 훈련데이터를 생성하는 기법이다.

데이터 증강기법을 활용하면 얻을 수 있는 몇 가지 이점이 있다. 첫째, 과적합을 방지할 수 있다. 과적합이란, 심층학습 모델의 학습이 훈련데이터에 치중되어 실험 데이터에는 올바른 성능을 발휘하지 못하는 것을 말한다. 데이터 증강기법을 통해 다양한 특징들을 확보하여 학습을 수행하면 과적합을 방지하여 성능을 높일 수 있다.

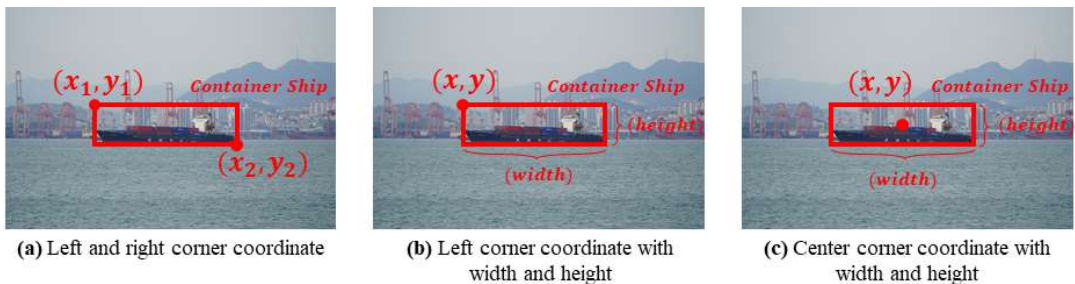
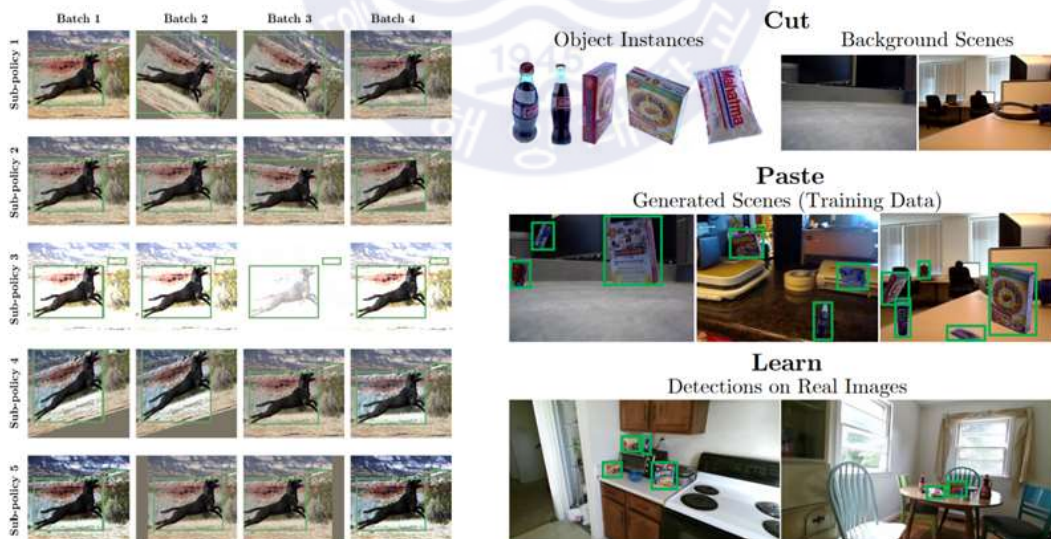


Fig. 6 Bounding box representation of object in maritime images

둘째, 적은 훈련데이터에서도 데이터 증강기법을 통해 높은 성능의 학습효과를 낼 수 있다. 심층학습은 많은 양의 데이터를 요구하게 되는데, 여건상 많은 양의 데이터를 확보하기 어려울 때 데이터 증강기법을 활용하면 성능을 향상시킬 수 있다. 관련된 연구로 회전, 반전, 크기, 색상, 늘리기 등의 22가지 동작을 정의하고, 이러한 동작들을 5가지 하위 정책(sub-policy)으로 조합하여 수행했을 때 최고의 성능을 내는 정책을 찾는 기법이 Fig. 6-(a)와 같이 제안되었다[24]. 이를 통해 정의된 조합들에서 최적화된 데이터 증강기법을 발견할 수 있으나, 탐색영역(search space)에 따른 많은 연산량과 시간을 요구한다.

셋째, 기존 훈련데이터를 가공하는 방식 이외에 새롭게 인위적인 데이터의 합성을 통해 수작업으로 라벨링을 수행하는 것보다 효율적으로 데이터를 구축할 수 있다. 객체와 배경을 따로 수집하여 배경 이미지에서 원하는 위치에 객체를 합성하는 방식을 통해 새로운 데이터를 생성하는 방법이 Fig. 6-(b)와 같이 제안되었다[25, 26]. 이 방식과 같이 한정된 데이터 구성에서 범용적인 성능 향상을 위해 다양한 배경과 객체를 정의하여 새로운 훈련데이터 생성이 가능하기 때문에 경제적이며 효율적이다.



(a) Examples of learned augmentation sub-policies

(b) Examples of cut, paste and learn

Fig. 7 Examples of data augmentation methods

마지막으로, 학습 시 많은 양의 객체를 포함하는 이미지를 생성하여 학습을 수행할 수 있다. 이미지 데이터 합성을 통해 한 이미지의 객체가 많이 존재하도록 이미지를 생성하면, 심층학습 모델이 특징을 학습할 때 많은 객체 특징들을 학습할 수 있다. 고도의 연산량을 요구하는 심층학습에서는 효율적으로 그래픽카드를 사용할 수 있도록 미니배치(mini-batch) 방법을 사용하여 학습을 수행한다. 미니배치란, 많은 양의 데이터를 모두 메모리에 적재할 수 없는 문제점을 해결하기 위해 데이터를 작은 단위, 즉 여러 개의 미니배치로 나눠 학습을 진행하는 방법을 활용한다. 데이터 합성을 활용한 데이터 증강기법을 활용하면 미니배치에 많은 인스턴스를 포함한 이미지를 구성할 수 있기 때문에, 한번에 많은 특징을 학습할 수 있어 효율적이며 이를 통해 성능을 향상시킬 수 있다.

본 논문에서는 Fig. 7과 같이 선상과 육상에서 찍은 영상을 포함하는 공개된 해상객체 검출데이터 SMD를 활용하여 해상객체 검출을 수행한다. 영상의 특성상 한 영상에서 프레임 간의 이미지 특징 차이가 크게 나지 않아 다양한 특징을 학습할 수 없어 범용적인 환경에서 성능이 낮은 문제점이 있다. 이를 해결하기 위해 콜라주 데이터 증강기법을 제안하고 심층학습 기반 객체 검출기에 적용하여 제안하는 방법의 타당성을 확인한다. 제안하는 방식의 내용은 3장 2절에서 기술할 것이다.



Fig. 8 Examples of the frame images extracted from SMD

2.3 다중센서 정보융합기술

본 논문에서는 다중센서 정보융합기술을 수행하기 위한 센서는 카메라와 선박자동식별 시스템을 활용한다. 해상 상황인식에서 다중센서 정보융합기술을 위해 활용되는 장비는 앞서 언급한 카메라, 레이더, 적외선 카메라 등이 있지만 가용 가능한 한계가 있어 카메라와 선박자동식별 시스템을 활용한다.

선박자동식별 시스템은 선박의 선명, 제원 등 선박 정보와 운항 정보를 선박과 선박, 선박과 육상 간 자동 송수신하는 장비로 항해의 관제수단 및 충돌사고방지과 유사시 수색, 구조활동을 지원하거나 항해 안전정보를 제공할 수 있어 해상 상황인식을 위한 항해 통신 장비로 사용되었다. 그러나 IMO에서 정의한 SOLAS 협약(International Convention for the Safety of Life at Sea)에서는 300톤급 이상 선박에서만 의무적으로 탑재가 의무화되어 카메라와 레이더와 같이 선박자동식별 시스템으로 감지되지 못한 선박에 대한 검출 및 추적 기술이 요구된다.

해상교통관제시스템(Vessel Traffic System, VTS)에서 사용되는 레이더와 선박자동식별 시스템의 융합된 정보를 기반으로 카메라의 영상정보를 융합하기 위한 연구가 수행되었다[27-32]. 해상교통관제시스템은 레이더, 선박자동식별 시스템 등을 이용하여 항만 또는 연안해역의 선박 교통안전과 효율성을 확보하고 해양환경을 보호하기 위하여 관제구역 내 통항 선박의 동정을 관찰하고 이에 필요한 정보를 제공하는 정보교환체제이며 이를 통해 항만 입출항 선박 및 인근 해역의 운항 정보를 제공하고 항로이탈, 위험구역 접근, 충돌위험 등을 예방하기 위한 선박 교통관제, 해양사고 및 비상상황 발생 시 신속한 초동조치 및 전파 등의 목적이 있다.

카메라로부터 획득된 영상객체의 픽셀 좌표계 기반의 위치 좌표와 해상교통관제시스템에서의 융합된 레이더 및 선박자동식별 시스템 월드 좌표계의 경위도 좌표 정보를 공통 좌표계로 정규화를 수행하고 인접한 정보와의 확률적 근집화를 Fig. 8과 같이 시도되었다[27-29]. 해상교통관제시스템에서 관측된 레이더의 객체 정보는 하나의 표적에 관하여 여러 표적으로 분리되는 현상과 인접

한 다중 표적이 하나의 표적으로 합쳐지는 문제점을 해결하기 위해서 카메라에서 획득된 표적 정보를 활용하여 해결하였다.

영상 좌표를 활용하여 객체 정보를 융합하는 다른 방법으로는 Fig. 9와 같이 해상 영상에서 주요 지형지물의 경위도를 기준으로 영상의 직교좌표계와 선박 자동식별 시스템과의 경위도 좌표를 결합하는 연구가 수행되었다[32]. 고정된 카메라의 정해진 화각을 기준으로 영상처리를 활용하여 객체 추적을 수행하고 이를 주변 지형지물에 의해 설정된 격자 좌표를 기반으로 선박자동식별 시스템의 경위도 좌표를 객체좌표와 융합하는 방법이 제안되었다. 이처럼 영상 좌표를 활용하는 경우 정해진 범위 내에서 빠르게 다중센서 정보융합을 수행할 수 있으나 제한된 범위와 수평선이 영상과 비교적 평행한 조건으로 수행되어야 하는 제한이 있다.



Fig. 9 Visual and VTS data projection based on data normalization

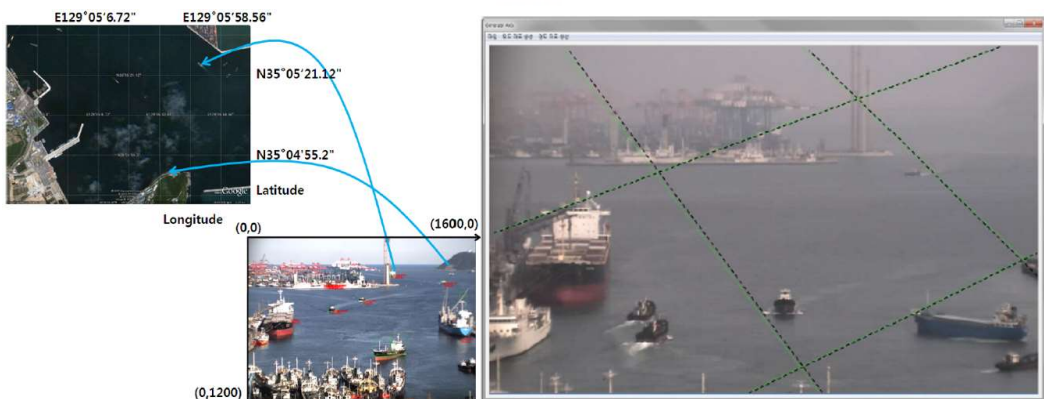


Fig. 10 Mapping from cartesian coordinates of images

제 3 장 연구 방법

본 장에서는 고속의 정확한 수평선 검출기법과 심층학습 기반의 해상객체 검출기를 위한 효율적인 데이터 증강기법을 제안한다. 그리고, 분석된 영상정보와 선박자동식별 시스템과의 다중센서 정보융합기술을 통해, 항해사에게 해상 상황인식을 위한 시스템을 제공하고자 한다

3.1 이중 허프변환을 활용한 고속수평선검출 기술

본 논문에서는 Fig. 10과 같이 수평선 검출의 성능을 저해하는 요인으로 파도, 선박의 항적과 같은 잡음을 없애고 수행시간을 단축하기 위해서 입력 영상을 행으로 5개의 구역으로 나눈 후 구역간의 색상 차이를 바탕으로 수평선이 존재할 구역을 관심 영역으로 설정한다. 설정된 관심 영역을 대상으로 잡음을 제거하고 수평선의 선형적 특징을 강화하기 위해서 다중 스케일 기반의 에지 검출기를 사용한다. 그리고 최종적으로 수평선을 검출하기 위해 이중 허프 변환을 통한 선형적 특징이 가장 뚜렷한 선을 결정한다. 제안하는 수평선 검출기법의 절차는 Fig. 11과 같다.



Fig. 11 Example of elements that interfere with horizon detection

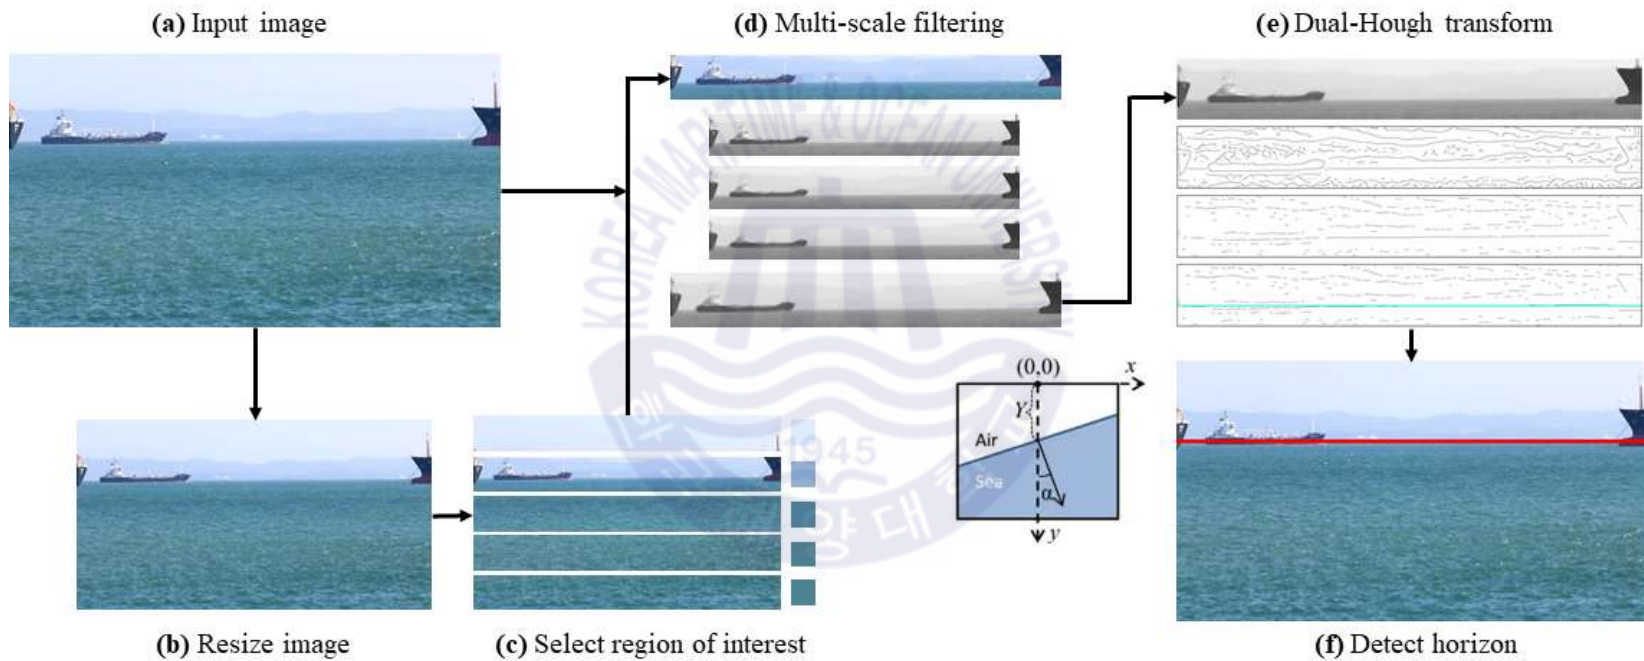


Fig. 12 Flowchart of the proposed horizon detection method

3.1.1 색상 기반의 관심 영역 설정

먼저 입력 영상에 대해서 처리 속도를 높이기 위해 영상을 1/4로 축소하고 수평선이 위치할 영역을 선정하기 위해 가로로 5개의 구역을 나눈다. 수평선이 위치하는 구역을 관심 영역으로 설정하기 위해서 Fig. 12와 같이 해양 영상에서 하늘과 바다의 경계인 수평선을 색상 변화가 큰 특징을 활용한다. 분할된 각 영역의 평균 색상을 계산하고 순차적으로 영역의 평균 색상 차이를 식 (1)과 같이 유클리디안 거리로 비교하여 인접 영역에서 평균 색상 차이가 가장 큰 영역을 수평선이 존재하는 관심 영역으로 산출한다.

$$Distance_{section} = (\sum (w_i |(u_i - v_i)|^2))^{1/2} \quad (1)$$

설정된 관심 영역을 대상으로 본 영상에서 다중 스케일 중앙값 연산을 수행한다. 다중 스케일 중앙값 연산은 식 (2)와 같이 다양한 스케일로 중앙값 연산을 수행하는 방법으로 잡음으로 인한 에지 검출의 불안정성을 해결하고 경계 성분이 큰 수평선의 특징을 강인하게 만들어 선형적 특징을 더욱 뚜렷하게 할 수 있다.

$$I_s(x, y) = f_x \otimes I(x, y) = \underset{i, j \in [-3s, 3s]}{\text{median}} I(x+i, y+j) \quad (2)$$

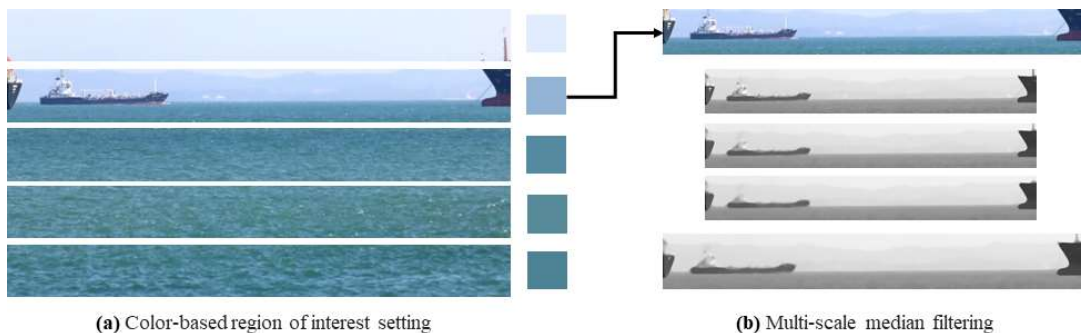


Fig. 13 Multi-scale median filtering process with region of interest

3.1.2 이중 허프변환

다중 스케일을 수행한 관심 영역에 대해서 케니 에지 검출기를 사용하여 윤곽선 성분을 검출한다. 검출된 에지 성분을 기반으로 수평선의 선형적 특징을 활용하여 하나의 수평선을 결정짓기 위해서 허프변환을 수행하였다. 허프 변환은 영상 좌표 공간의 모든 픽셀 좌표들을 허프 공간으로 사상시키면 영상 좌표 공간의 픽셀들은 곡선의 형태를 그리며 교점을 형성하고 가장 많이 겹친 교점이 하나의 가장 뚜렷한 직선의 형태로 표현된다.

본 논문에서 제안하는 이중 허프변환은 Fig. 13과 같이 확률적(probabilistic) 허프변환을 수행한 후 기존의 허프 변환을 수행한다. 확률적 허프변환은 임의의 픽셀값을 선정하여 일정 길이의 선형적 특징을 가진 후보 선들을 검출하므로 선박이나 부유물로 인한 수평선의 폐색 현상을 보완할 수 있다. 따라서 다중 스케일 필터를 거친 관심 영역에 케니 검출기를 적용한 후 확률적 허프변환을 적용하여 선형적 특성을 가지는 후보 선을 추출한 후 기존의 허프변환을 다시 사용하여 가장 선형적 특성이 뚜렷한 후보 선을 수평선으로 결정한다. 제안하는 방법은 수평선이 존재할 영역을 색상 차이를 활용하여 관심 영역이 설정되어 기존의 방법보다 고속으로, 다중 스케일 중앙값 연산과 이중 허프 변환을 통해 정확한 수평선 검출이 가능하다.




Fig. 14 Dual hough transform applied to the edge detected

3.2 심층학습 기반의 해상 객체검출 기술

본 논문에서는 해상객체를 검출하기 위해 심층학습 기반의 객체 검출기를 활용되고 있다. 따라서, 보다 객체 검출기의 성능을 높이기 위해 자동으로 학습 데이터를 생성 가능한 콜라주(collage) 데이터 증강기법을 제안한다. 제안하는 데이터 증강기법을 통해 효율적이고 경제적으로 학습 데이터 생성이 가능하고, 이를 통해 검출기의 범용적인 성능을 높일 수 있어 보다 정확하게 객체검출을 수행할 수 있다.

3.2.1 Retina-Net

본 논문에서는 제안하는 콜라주 데이터 증강기법의 성능을 실험 및 검증하기 위해서 2-단계 검출기와 견주어 비슷한 정확도와 함께 빠른 연산 수행이 가능한 1-단계 기반의 심층학습 검출기를 활용한다. 또한, 해상 객체검출 데이터 SMD와 더불어 일반적인 해상 영상은 Fig. 14와 같이 영상에서 객체가 존재하는 영역이 매우 적어 배경 영역과 비교하여 극히 불균형한 분포를 보인다. 이러한 해상환경에서 심층학습 기반의 객체 검출기를 활용할 때 객체가 존재하지 않는 후보 영역이 대량 등장하는 문제로 인하여 학습의 성능을 저해하는 특징이 있다. 이를 위해 본 논문에서는 심층학습 기반의 1-단계 검출기로 Retina-Net을 활용하여 해상객체 검출을 수행한다.




Fig. 15 Histogram of the object's bounding box area ratio

Retina-Net 검출기는 심층학습 기반의 객체검출 모델이 학습을 진행할 때 Fig. 15와 같이 객체가 존재하는 전경(foreground)보다 객체가 존재하지 않는 배경(background)의 출현이 극도로 많은 불균형 문제로 인하여 학습이 저해되는 특징을 해결하기 위해 제안되었다.

Retina-Net 검출기는 식 (4)와 같이 기존의 Cross-Entropy Loss에 식 (5)과 같이 Balanced Cross-Entropy를 위한 하이퍼 파라미터(hyper-parameter) α_t 와 Focal-Loss를 위한 $-(1-p_t)^r$ 을 추가하여 제안함으로써 클래스 불균형으로 인한 학습 저하를 해결하는 방법을 제안하였다.

$$CE(p_t) = \begin{cases} -\log(p_t) & \text{if ground-truth class} \\ -\log(1-p_t) & \text{otherwise} \end{cases} \quad (4)$$

$$FL(p_t) = -\alpha_t(1-p_t)^r \log(p_t), \quad p_t = \begin{cases} p & \text{if ground-truth class} \\ 1-p & \text{otherwise} \end{cases} \quad (5)$$




Fig. 16 Many negative background and few positive foreground boxes

Balanced Cross-Entropy의 a 는 전경과 후경을 구분하기 위한 이진 분류(binary classification)에서 후경이 극도로 많아 불균형한 상태로 학습되는 현상을 해결하기 위해서 사용된 하이퍼 파라미터이다. 주목하는 객체(positive example)에 비해 의미 없는 객체(negative example)가 많아지면 심층학습 모델의 올바른 학습이 수행되지 않는다. 따라서 의미 없는 객체에 대해서는 $(1-a)$ 값을 적용하여 객체에 따라 가중치를 다르게 조정하여 클래스 불균형을 해결한다.

Focal-Loss의 $-(1-p_i)^r$ 는 심층학습 모델이 학습 과정에서 예측하기 쉬운 오검출 예시(easy negative example)들이 대다수를 이루게 되면서 학습에 지장을 주는 문제를 해결하기 위해 사용된 하이퍼 파라미터이다. 쉽게 검출되는 객체들의 중요도를 낮춤으로써 검출이 어려운 예시들(hard example)에 집중할 수 있도록 도와준다. 이는 Fig. 16과 같이, 수렴된 모델로부터 각각 다른 r 를 사용하여 전경과 배경 예시들에서 정규화된 손실 값을 구해 그린 누적 분포 함수(cumulative distribution function)를 통해 확인할 수 있다. 전경에서는 효과가 크지 않지만, 배경에서는 r 가 증가할수록 손실 값이 어려운 곳에 학습을 집중하게 한다.

본 논문에서는 제안하는 콜라주 데이터 증강기법을 심층학습 기반의 객체 검출기에 적용하기 위해 하이퍼 파라미터는 디폴트 값으로 $r=2$, $a=0.25$ 를 사용한 Retina-Net 검출기를 활용한다.

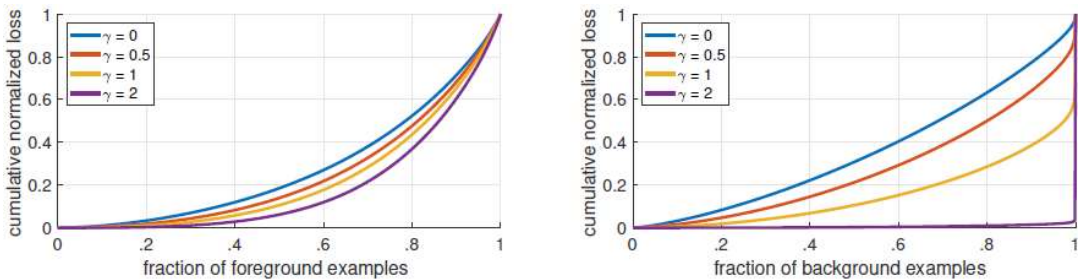


Fig. 17 Cumulative distribution functions of the normalized loss

3.2.2 콜라주 데이터 증강기법

해상 객체검출 데이터 SMD는 Fig. 17과 같이 데이터에서 50프레임마다 이미지를 추출하여 나열한 그래프를 보면, 1프레임과 200프레임 사이의 이미지 변화가 적은 것을 알 수 있다. 이러한 데이터의 구성은 학습 데이터의 다양성이 부족하여 과적합에 빠질 수 있으며, 범용적인 성능을 저해할 수 있다. 따라서 본 논문에서는 이러한 문제를 해결하기 위해서 단일 객체 이미지를 활용하여 영상 분할(image segmentation)을 통해 자동으로 경계상자를 추출하고, 이를 결합하여 새로운 데이터를 생성하는 콜라주(collage) 데이터 증강기법을 제안한다. 콜라주란, 별개의 조각들을 붙여 모아 새로운 이미지를 만드는 미술 기법으로, 이와 비슷하게 단일 객체가 포함된 이미지 데이터에서 추출한 이미지를 붙여 모아 새로운 객체검출 이미지를 생성한다.

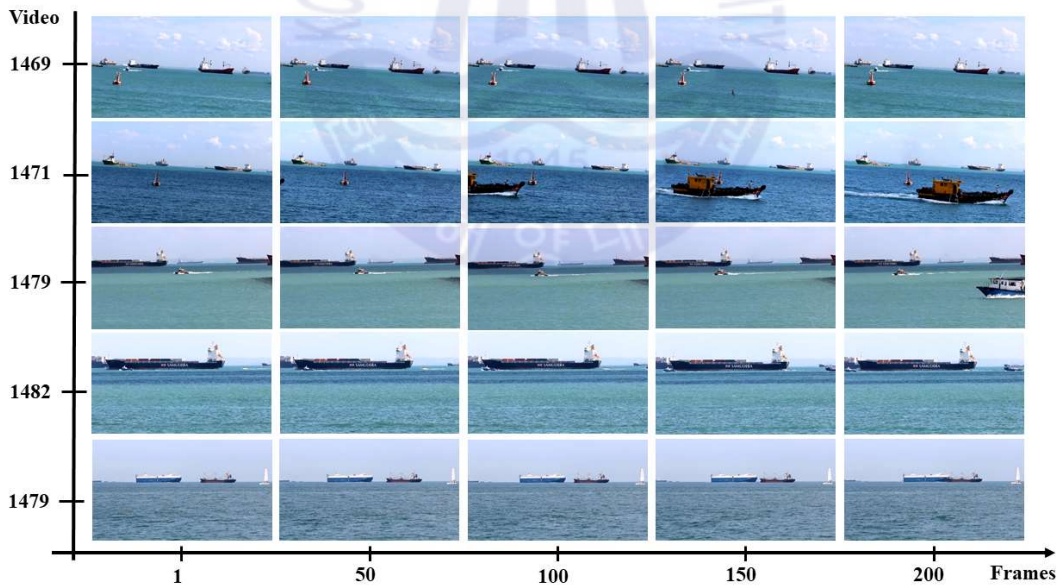


Fig. 18 Sample images along every 50 frames in SMD

본 논문에서 제안하는 데이터 증강기법의 전체 흐름도는 Fig. 18과 같다. 먼저, 단일 이미지는 선박 분류 데이터 MARVEL[16]에서 컨테이너선(container ship), 여객선(passenger ship), 유조선(tanker), 그리고 예인선(tug) 클래스에 대해 약 1,000장의 이미지를 추출하여 구성한다. 구성된 단일 이미지에 대해서 기 학습된 영상 분할 모델 DeepLab-V3+[33]를 활용하여 픽셀 단위로 이미지에서 객체영역을 구분한다. 픽셀 단위로 분할된 영역을 바탕으로 추출된 윤곽선의 수직, 수평 방향으로 마지막 픽셀을 선택하여 경계상자의 위치 좌표로 설정한다. 위와 같은 절차를 통해 생성된 단일 객체 이미지와 경계상자를 행렬 형태로 이어붙여 새로운 해상객체 검출 훈련데이터를 생성한다. 행렬의 크기와 단일 객체 이미지 크기를 다양한 조합의 구성을 이룰 수 있고, 원하는 클래스를 선택하여 효율적이고 경제적으로 데이터 생성이 가능하다.

본 논문에서 제안하는 데이터 증강기법은 단일 객체 이미지를 행렬 형태로 이어 붙이는 방식이기 때문에, 행렬과 객체의 크기를 조절하여 다양한 조합이 가능한 것을 고려한다. 따라서, 해상 객체검출 데이터 SMD 이미지의 크기인 1920x1080을 기준으로 256x256 크기인 MARVEL 데이터의 단일 객체 이미지를 행렬의 크기에 따라 다르게 정의하였다. Table. 1은 단일 객체 이미지 크기와 행렬의 크기 조합에 따라 구성되는 한 이미지의 총 객체 수를 나타낸다.

Table 1 Image and matrix shapes of collage data augmentation method

Image size (width*height) = 1920 x 1080							
Image size	Resize image	Matrix shape	Total instances	Image size	Resize image	Matrix shape	Total instances
Large	240 x 216	8 x 5	40	Medium	96 x 90	20 x 12	240
Medium	192 x 180	10 x 6	60	Small	80 x 72	24 x 15	360
Medium	160 x 135	12 x 8	96	Small	64 x 60	30 x 18	540
Medium	128 x 120	15 x 9	135	Small	60 x 54	32 x 20	640
Medium	120 x 108	16 x 10	160	Small	48 x 45	40 x 24	960

콜라주 데이터 증강기법에서 행렬의 크기와 이미지 크기에 따른 최적의 조합을 찾기 위해서 객체의 크기에 따라 대(large), 중(medium), 소(small)로 구분하여 정의한다. 크기의 기준을 정의하기 위해서 일반객체 검출 대규모 공개 데이터 MS COCO[34]에서 정의한 기준을 바탕으로 SMD 이미지 크기에 맞게 새롭게 정의하고, 이를 Table. 2와 같이 나타낸다.

Table 2 The definition of object size in MS COCO and SMD

MS COCO			SMD		
Image size	≅ (640 x 480)		Image size	≅ (1920 x 1080)	
Area	Min Rectangle Area	Max Rectangle Area	Area	Min Rectangle Area	Max Rectangle Area
Small	0 x 0	32 x 32	Small	0 x 0	80 x 72
Medium	32 x 32	96 x 96	Medium	80 x 72	216 x 216
Large	96 x 96	∞ x ∞	Large	216 x 216	∞ x ∞

위와 같이 정의한 조합의 성능을 크기 기준에 따라 확인하기 위해서 240x216, 192x180, 80x72 크기를 각각 large, medium, small 크기로 선택하였고, Fig. 19는 large 크기로 콜라주 데이터 증강기법이 수행된 데이터 예시이다. Fig. 19-(a)는 실제 심층학습 기반의 객체 검출기에 학습 시 기존 학습 데이터에 증강되어 들어가는 데이터를 의미하며, Fig. 19-(b)는 생성된 데이터와 경계상자를 함께 시각화하여 표현한 것을 나타낸다.

본 논문에서 제안하는 콜라주 데이터 증강기법을 Retina-Net 검출기 적용하여 성능입증 결과를 확인하며, 제안하는 방법의 실험결과 및 분석은 4장 2절에서 기술할 것이다.

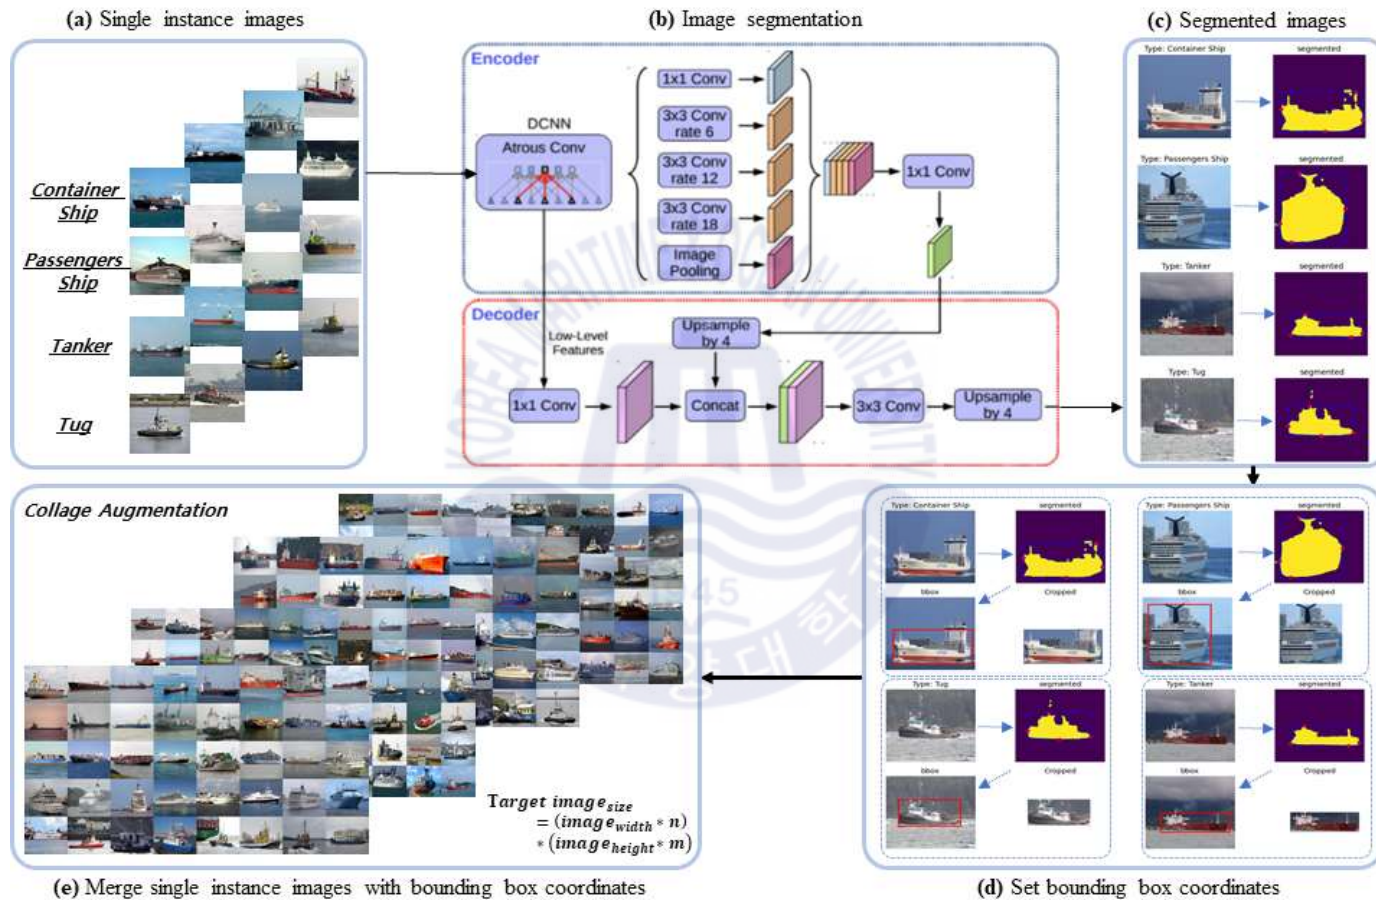


Fig. 19 Collage data augmentation method for object detection



(a) Examples of generated image using collage data augmentation



(b) Examples of generated image using collage data augmentation with ground-truth

Fig. 20 The data examples by generated collage data augmentation

3.3 선박자동식별 장치를 이용한 다중센서 정보융합 기술

선박에서는 해상객체 검출할 수 있는 장비로는 레이더, 라이다, 선박자동식별 시스템 등의 장치들이 있다. 본 논문에서는 모든 센서를 가용하기엔 한계가 있어 다중센서 기반의 정보융합 기술을 위해 선박 자동식별시스템만을 활용한다. 본 장에서는 다중센서 정보융합 시스템을 위해 선박자동식별 시스템에서 메시지 분석을 위한 파라미터를 분석 및 가공하는 기법에 관하여 기술한다.

3.3.1 선박자동식별 시스템 메시지 처리 모듈

본 논문에서는 영상에서 표현되는 영상좌표계의 위치와 선박자동식별 시스템에서 표현되는 좌표계의 정보를 융합하기 위해서 가공하는 메시지의 정보는 해상이동업무식별번호(Maritime Mobile Service Identity, MMSI) 필드 값과 위도(latitude), 경도(longitude) 필드 값을 활용한다. MMSI란, 선박국, 해안국 및 집단호출을 유일하게 식별하기 위해 사용되는 부호로써, 9개의 숫자로 구성되어 있다. 앞에서부터 3자리는 선박이 속한 국가 또는 지역을 나타내는 해상식별부호(Maritime Identification Digits, MID)이며, 선박마다 고유한 부호를 의미한다.

선박자동식별 장치로부터 얻어진 메시지 파라미터와 타입은 쉽표로 파라미터를 구분한다. 파라미터 필드 1번의 값은 Talker ID를 나타내며 문장에서 'AI'는 모바일 선박자동식별 시스템 기지국을 의미하며 'VDM'은 다른 선박으로부터 수신한 메시지를 의미한다. 필드 2번과 3번의 값은 송신되는 정보의 양이 많은 번에 송신이 불가하여 정보를 나눠 송신할 때 나눠진 메시지의 총 개수 및 나눠진 메시지 중 해당하는 순서를 의미한다. 필드 4번 값은 선박자동식별 시스템의 채널을 의미하며, 필드 6번에는 오류 검사를 위한 체크섬 정보로 구성된다. 필드 5번 값은 전송하고자 하는 정보의 데이터가 ASCII 코드로 인코딩된 비트 값을 의미한다. 정의된 메시지 타입에 따른 세부 목록은 Table 3과 같이 나타낸다.

Table 3 AIS Message parameters, types and descriptions

Field	Description	Field	Description
1	Message Type	4	AIS Channel
2	Number of Sentence	5	Payload
3	Sentence Number	6	Checksum
ID	Name	Description	
1	위치보고 (스케줄)	계획된 위치보고 (class A)	
2	위치보고 (할당)	할당된 위치보고 (class A)	
3	위치보고 (풀링)	요청 시 위치보고 (class A)	
4	기지국 보고	기지국의 위치, UTC, 날짜, slot 번호	
5	정적 데이터 및 항해 관련 데이터	계획된 정적 데이터 및 항해 관련 데이터	
6	개별 이진 메시지	지정된 통신을 위한 이진 데이터	
7	이진 확인	수신한 이진 데이터 확인	
8	이진 방송 메시지	방송 통신을 위한 이진 데이터	
9	표준 수색구조 항공기 위치보고	표준 수색구조 항공기 위치보고	
10	UTC 및 날짜요청	UTC 시간 요구	
11	UTC 및 날짜 응답	현재 UTC 시간 응답	
12	안전 관련 개별 메시지	지정된 통신을 위한 안전 관련 데이터	
13	안전 관련 확인	수신한 안전 관련 메시지 확인	
14	안전 관련 방송 메시지	방송 통신을 위한 안전 관련 데이터	
15	질의	특정 메시지 타입 요구 (기지국으로부터 다중응답 가능)	
16	할당 모드 명령	기지국 사용 당국의 특정 보고의 할당	
17	DGNSS 방송 이진 메시지	기지국에서 제공한 DGNSS 교정	
18	표준 Class B 장비 위치보고	Class B의 표준 위치 정보 (메시지 1, 2, 3 대신)	
19	확장 Class B 장비 위치보고	Class B의 확장된 위치 정보 (정적정보 포함)	
20	데이터 링크 관리 위치보고	기지국을 위해 남겨 놓은 slot	
21	항해 지원 장치 보고	AtoN을 위한 위치 및 상태 보고	
22	채널 관리 메시지	기지국에 의한 채널 및 수신기 모드 관리	
23	그룹 할당	구역 내의 모든 이동국에 대한 동작 파라미터를 설정	
24	Class B 정적 정보	Class B의 계획된 정적 데이터 및 항해 관련 데이터	
25	단일 슬롯 이진 메시지	한 장치에서 다른 장치로 이진 데이터를 전송	
26	다중 슬롯 이진 메시지	한 장치에서 다른 장치로 이진 데이터를 전송	
27	장거리 AIS 방송 메시지	장거리에서 위치보고 (압축된 메시지)	

위치보고 메시지의 Payload 48개 문자는 6개의 비트 값으로 변환되어 총 168개의 비트 값으로 변환되고 Table 4에서 정의된 형식에 따라 의미를 디코딩한다. 본 논문에서는 8-37 필드까지 할당된 MMSI 정보와 61-115 필드까지 할당된 위도 및 경도 정보를 활용한다.

Table 4 Message type 1: position report class A

Number	Field	Length	Description	Member
1	0-5	6	Message Type	type
2	6-7	2	Repeat Indicator	repeat
3	8-37	30	MMSI	mmsi
4	38-41	4	Navigation Status	status
5	42-49	8	Rate of Turn (ROT)	turn
6	50-59	10	Speed Over Ground (SOG)	speed
7	60-60	1	Position Accuracy	accuracy
8	61-88	28	Longitude	longitude
9	89-115	27	Latitude	latitude
10	116-127	12	Course Over Ground (COG)	course
11	128-136	9	True Heading (HDG)	heading
12	137-142	6	Time Stamp	second
13	143-144	2	Maneuver Indicator	maneuver
14	145-147	3	Spare	spare
15	148-148	1	RAIM Flag	raim
16	149-167	19	Radio Status	radio

해상 영상에서의 상황인식을 위해 추출한 객체의 정보를 기반으로 하여 선박 자동식별 시스템에서 수신된 메시지를 융합하기 위해 사용되는 메시지는 위치 보고 정보를 담고 있는 1번, 2번, 그리고 3번 메시지 타입이다. Table 5는 한국 해양대학교에서 부산항 인근의 선박들에 대해 수신한 메시지 중 한 예시로서 Table 4와 같이 정의된 메시지 타입 1번 위치보고에 관련한 내용을 담고 있다.

Table 5 An example sentence of message type 1

Message	!AIVDM, 1, 1, , B, 16T68g2uPP009>oKTD4ud8A?vD2@6L, 0*38			
Contents	Description	Value	Description	Value
Parameters	Message Type	!AIVDM	AIS Channel	B
	Number of Sentence	1	Payload	
	Sentence Number	1	Checksum	0*38
Decoded Payload	Message Type	1	Course Over Ground	211.6
	Repeat Indicator	0	True Heading	511
	MMSI	440124150	Time Stamp	10
	Navigation Status	0	Maneuver Indicator	0
	Rate of Turn	128.0	Spare	0
	Speed Over Ground	0.0	RAIM Flag	1
	Position Accuracy	0	Sync State	0
	Longitude	35.088080	Slot Time-out	4
	Latitude	129.076670	Slot Number	412

3.4 다중센서 정보융합시스템 설계

본 논문에서 구성한 다중센서 정보융합시스템은 Fig. 20과 같이 한국해양대학교에서 부산항 인근 항만을 촬영한 영상과 선박자동식별 장치에서 수신한 메시지로 구축한 환경을 기반으로 진행하였다. 제안하는 시스템은 수평선 검출, 콜라주 데이터 증강기법을 이용한 심층학습 기반의 객체검출, 선박자동식별 시스템 메시지 처리, 그리고 다중센서 정보융합기술을 포함하는 네 개의 유닛으로 구성된다.

본 논문에서 제시한 심층학습과 다중센서 정보융합을 활용한 해상객체 검출 기법에 관한 전체 시스템 설계는 Fig. 21과 같다. 첫 번째 유닛에서 수평선 검출을 수행하여 입력받은 영상 첫 프레임에서 수평선을 검출하여 추출한 수평선 정보를 두 번째 유닛으로 넘겨준다. 수평선 정보와 영상정보를 입력받은 두 번째 유닛에서는, 심층학습 기반의 해상객체 검출을 수행하고 수평선 정보를 기반으로 표적 대상을 구분한다. 세 번째 유닛에서는 선박자동식별 장치로부터 수신한 메시지를 처리하여 네 번째 유닛으로 전달한다. 두 번째 유닛으로부터 전달받은 수평선 및 객체 정보와 세 번째 유닛으로 전달받은 메시지 정보를 네 번째 유닛에서 전달받아 영상에 함께 출력하여 시각화하여 정보를 제공한다.



Fig. 21 An system experiment environment

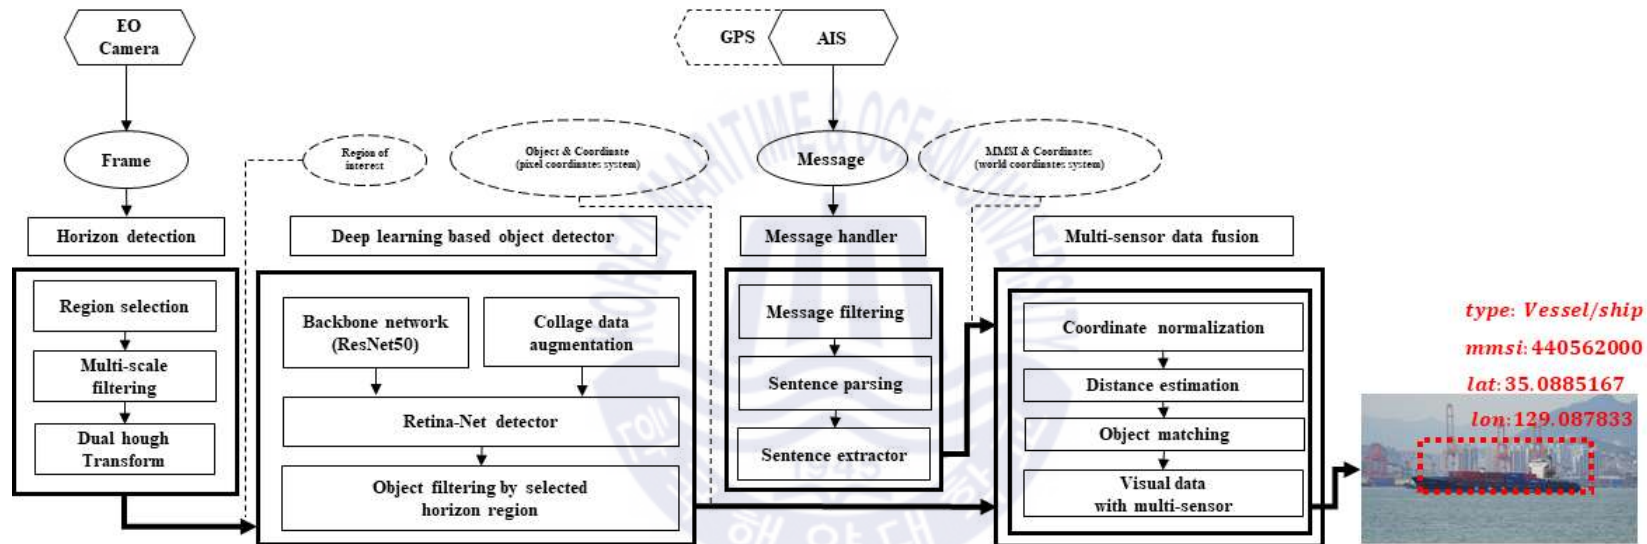


Fig. 22 Process chart of the general system

3.4.1 수평선 정보를 활용한 표적 대상 필터링

입력 영상에서 제안하는 이중 허프변환을 활용한 고속수평선 검출을 수행하여 수평선을 검출한다. 제안하는 시스템의 범용적인 능력을 평가하기 위해 촬영된 부산항 인근의 영상은 원양보다 배경이 다채롭고 복잡하여 객체 검출 성능을 저해하는 영향이 있다. 따라서 본 논문에서는 주목하는 객체를 검출된 수평선 경계 아래 영역, 즉 해상 영역으로 정해 Fig. 21과 같이 설정한다.

관심 영역에 해당하는 객체를 선별하기 위해서 검출된 해상객체의 경계상자의 영상 위치 좌표에서 식 (5), (6)과 같이 중앙좌표와 수평선과의 수직거리를 계산하여 수평선 아래의 위치하는 객체에 대해서만 표적 대상으로 선정하였다. 검출된 경계상자가 수평선과 인접하였을 때 확실한 표적 대상을 지정하기 위해서 경계상자의 맨 아래 좌표가 아닌 중앙의 좌표를 채택한다.

$$Distance = Centroid_y - Horizon_y \quad (6)$$

$$Horizon_y = \left(\frac{y_{h1} - y_{h0}}{x_{h1} - x_{h0}} \right) (Horizon_x - x_{h0}) + y_{h0} \quad (7)$$

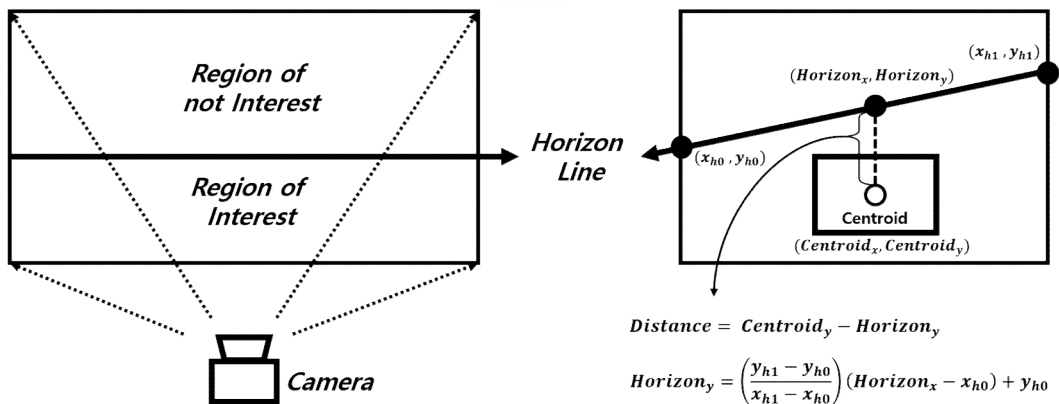


Fig. 23 Object filtering processing by selected horizon line

3.4.2 거리정보를 활용한 표적 대상 정보융합

본 논문에서는 한국해양대학교에 설치된 카메라의 시야(field of view) 내에 존재하는 선박을 표적 대상으로 선별하여 선박자동식별 장치에서 수신되어 디코딩된 정보에서 해상이동통신 식별번호 및 위도와 경도 값을 영상이 객체 정보와 결합하여 정보융합을 수행한다. 영상에서 선별된 선박과 선박 자동식별시스템 정보와의 결합을 위한 정보융합은 각 센서에서 추정된 거리정보를 활용한다.

선박 자동식별장치에서 얻어진 정보에서 거리를 추정하기 위해 위도와 경도 값을 활용하여 식 (6)과 같이 하버사인 공식(haversine Formula)을 통해 거리를 산출한다. 하버사인 공식은 두 경위도 좌표 사이의 거리를 계산하는 공식으로 실제 지도 좌표 사이의 거리는 호(arc)로 표현되기 때문에 두 점 사이의 거리를 계산하는 유클리디안(euclidean) 거리 공식과 비교할 때 짧은 거리에서는 오차율이 적다. 그러나 표적 대상과의 거리가 증가할수록 오차율이 증가하기 때문에 하버사인 공식을 바탕으로 표적 대상과의 거리를 계산한다.

$$Distance_{AIS} = 2r \arcsin \left(\sqrt{\sin^2 \left(\frac{\varphi_2 - \varphi_1}{2} \right) + \cos(\varphi_1) \cos(\varphi_2) \sin^2 \left(\frac{\lambda_2 - \lambda_1}{2} \right)} \right) \quad (6)$$

또한, 카메라로부터 얻어진 영상정보에서 선정된 표적 대상에 관한 상대 거리를 산출하기 위해 수평선과 검출된 객체의 경계상자의 맨 아래 픽셀과의 차이를 활용한다. 이를 통해 영상과 선박 자동식별시스템의 객체 정보를 맵핑하기 위해 각도와 거리에 근거하여 가장 근접한 객체를 맵핑하여 영상에 출력하여 시각화한다.

본 논문에서 제안하는 다중센서 정보융합 시스템을 통해 한국해양대학교에서 수집한 부산항 인근의 영상과 메시지를 기반으로 실험결과 및 분석은 4장 3절에서 기술할 것이다.

제 4 장 실험 및 검증

본 장에서는 제안하는 심층학습 및 다중센서 정보융합 기술을 활용한 해상 객체검출 기술에 대해 실험 및 타당성을 검증한다. 연구에서 수행하는 개발환경과 수평선 검출, 객체검출 및 다중센서 융합에 관한 기술요소들의 실험결과와 이에 따른 검증 방법을 토대로 제안하는 방법의 타당성을 입증한다.

4.1 개발 환경

본 논문에서 연구를 수행하기 위한 개발 환경은 아래의 Table 6과 같이 하드웨어와 소프트웨어 세부 목록을 기술한다.

Table 6 System environments descriptions

Device Description			
Item	Name	Capacity	Quantity
Mainboard	ASUS Z10PE-D16 WS	-	1
CPU	Intel® Xeon(R) CPU E5-2640 v4 @ 2.40GHz×20	-	1
GPU	NVIDIA GeForce GTX 1080ti	11GB	2
RAM	Samsung DIMM DDR4 Synchronous 2400 MHz	16GB	1
HDD	WDC WD10EZEX-08WN4A0 (02.01A02)	1TB	1
SSD	Samsung SSD 850 EVO (RVT01B6Q)	250GB	1
AIS	Samyung ENC Class B AIS-50N/AIS-50B	-	1
Software Description			
Item	Name	Version	
OS	Ubuntu	18.04 LTS	
IDE	Pycharm	2019.3.3	
Framework	Anaconda	2020.02	
Language	Python	3.6.10	
Library	numpy	1.16.1	
Library	scikit-image	0.17.1	
Library	scikit-learn	0.23.1	
Library	tensorflow-gpu	1.14.0	
Library	pandas	1.0.3	
Library	keras-applications	1.0.8	
Library	keras	2.3.1	
Library	opencv	2.4.1	

4.2 실험 및 검증

본 장에서는 제안하는 기법들의 타당성을 입증하기 위한 검증 방법과 절차에 따른 실험결과를 기술한다. 공개된 데이터를 기반으로 수평선 검출과 객체검출 및 분류기법의 검증을 수행하였으며 심층학습과 다중센서 정보융합기술을 활용한 해상객체 검출은 자체적으로 구축한 데이터를 활용한다.

4.2.1 수평선 검출 실험 및 검증

본 논문에서 제안하는 수평선 검출기법의 실험을 진행하기 위해서 SMD에서 제공된 수평선 정보 및 검증 방법을 활용한다. 실험에 사용된 데이터는 11개의 Full-HD(1920x1080) 영상으로 이루어진 2,772개의 프레임을 활용하여 Fig. 22와 같이 수평선의 각도와 픽셀 차이의 오차율로 수평선 검출 정확도 검증을 수행한다. 수평선 검출 정확도는 검출된 수평선과 실제 수평선과의 위치 오차율과 각도 오차율을 활용하여 측정한다.




Fig. 24 An measurement method for comparing detected horizon line

본 논문에서 제안하는 수평선 검출기법을 각도 오차와 픽셀 오차를 함께 나타내어 다른 기법과의 비교결과를 Table 7과 같이 기술하였다. 정확도 결과는 전체 오차율을 오름차순으로 정렬하여 오차율에 따라 25th, 50th, 95th 순으로 나눠 비교하였다. 이와 함께 Table 8은 각 기법에 따른 연산 실행속도를 비교하여 나타내었다.

Table 7 Statistics of errors in Y and α for different methods

Method	Percentile position error (pixel) / Angle error (degree) ($ Y - Y_{a_{GT}} / \alpha - \alpha_{GT} $)		
	25 th	50 th	95 th
Proposed	0.82/0.11	1.82/0.30	16.23/0.99
MuSoWERT[15]	0.54/0.11	1.49/0.29	8.17/0.88
ENIW[15]	1.82/0.30	117.81/1.10	224.48/4.88
Hough[15]	16.23/0.99	221.02/1.69	384.01/7.83

Table 8 Values of processing time per frame for different methods

Method	Proposed	MusCoWERT[15]	ENIW[15]	Hough[15]
Time(sec)	0.32	9.2	~hours	0.3

정확도 측면에서는 MuSoWERT[15] 기법이 가장 뛰어난 정확도를 보인다. 하지만 연산속도 측면에서 9.2초로 상대적으로 늦은 연산 수행속도를 보인다. 연산속도에서는 Hough[15] 기법이 가장 뛰어나나 정확도 측면에서는 좋지 못한 결과를 보인다. 제안하는 수평선 검출기법은 가장 뛰어난 정확도를 보이는 MuSoWERT 기법과 비교할 때 각도 오차율이 준수한 것에 비해 속도 측면에서는 8.88초 빠른 것을 알 수 있다. 따라서 제안하는 수평선 검출기법이 정확하면서 고속으로 수평선 검출이 가능한 것을 알 수 있다.

본 논문에서 제안하는 수평선 검출기법의 결과를 Fig. 23과 같이 영상과 함께 나타내었다. 이를 통해 제안하는 방법은 다양한 날씨 및 조도 변화에도 정확한 수평선 검출이 이루어지는 것을 알 수 있으며, 수평선 근처에 긴 선박으로 인한 폐색 현상이 있음에도 불구하고 성능이 좋은 것을 알 수 있다. 이를 통해 제안하는 수평선 검출기법이 빠르고 정확하게 수평선 검출이 가능한 것을 나타낸다.




Fig. 25 The line indicates the horizon detected by the proposed method

4.2.2 해상 객체검출 실험 및 검증

본 논문에서는 객체검출 알고리즘의 성능평가를 위해 정밀도-재현율 (precision-recall) 곡선을 기반으로 한 평균 정밀도(mean-average precision)로 평가한다. 정밀도(precision)이란 객체검출 알고리즘에 의해 검출된 결과가 실제 물체를 얼마나 정확하게 포함하여 검출하였는지 의미한다. 재현율(recall)은 정답으로 검출해야 할 객체에 대하여 알고리즘이 올바르게 검출한 비율을 의미하며, 검출해야 하는 대상 물체들을 얼마나 잘 잡아내는지에 대한 성능을 평가하게 된다.

객체검출의 척도는 겹침 정도(Intersection over union, IoU)로 정의하여 Fig. 24와 같이 실제 객체가 위치한 정답 경계상자와 알고리즘이 예측한 경계상자의 위치 겹침 정도를 판단하는 기준으로 사용된다. 겹쳐진 정도는 알고리즘이 검출한 객체의 위치 신뢰도를 나타내며 문턱 값(IoU threshold)보다 높은 경계상자를 갖는 객체만을 활용한다. 겹쳐진 정도를 나타내는 a_0 는 예측한 경계상자 B_p 와 정답 경계상자 B_{gt} 를 합한 전체 면적에 대하여 두 경계상자가 겹쳐있는 부분의 면적으로 산출된다.

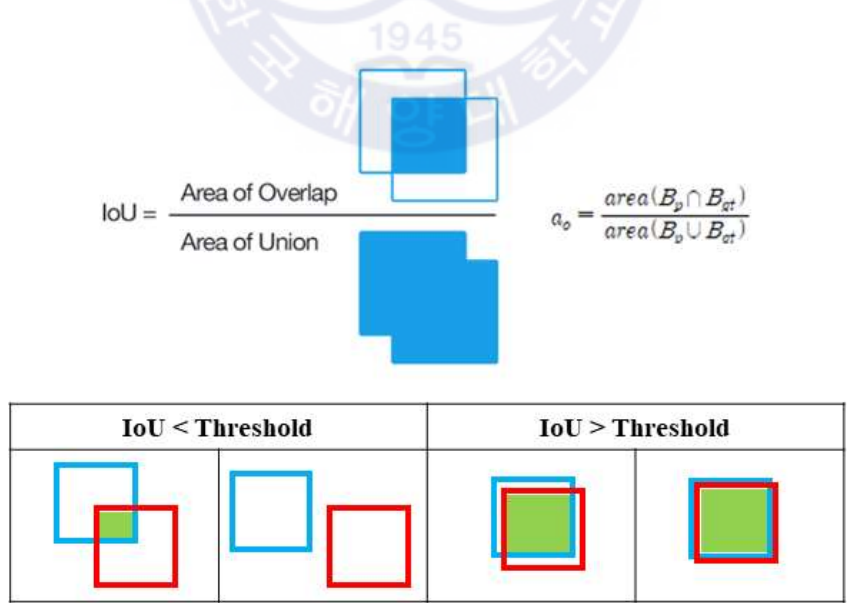


Fig. 26 Definition of the intersection over union

객체검출 알고리즘의 일반적인 성능을 측정하고 검증하기 위해 재현율과 정밀도를 함께 고려하는 것이 중요하다. 따라서, 제시된 Table 9의 관계를 기반으로 식 (7)을 바탕으로 재현율과 정밀도를 계산한다. 이를 기반으로 식 (8)을 활용하여 평균 정밀도를 산출하여 객체검출 알고리즘의 성능을 검증한다.

Table 9 Conditions of precision and recall

Name	Description	
True Positive (TP)	검출한 객체가 다음과 같은 조건을 충족하여 정답과 일치함	
	1	검출한 객체의 confidence score가 문턱 값보다 큼
	2	검출한 객체의 클래스가 정답과 일치함 (다중 객체검출 시)
	3	검출한 객체의 경계상자의 IoU가 문턱 값보다 큼
False Positive (FP)	검출한 객체가 다음 조건을 충족하지 못하여 정답과 일치하지 못함	
	1	검출한 객체의 클래스가 정답과 불일치함 (다중 객체검출 시)
	2	검출한 객체의 경계상자의 IoU가 문턱 값보다 작음
True Negative (TN)	실제 정답에는 객체가 존재하나 검출기가 검출하지 못함	
False Negative (FN)	검출기가 검출한 객체의 confidence score가 문턱 값을 넘기지 못함	

$$Precision = \frac{True\ Positive}{all\ detections}, \quad Recall = \frac{True\ Positive}{all\ ground\ truths} \quad (7)$$

$$AP = \int_0^1 p_{interp}(r) dr, \quad mAP = \frac{\sum_{class_i} AP_{class_i}}{total\ number\ of\ classes} \quad (8)$$

본 논문에서는 SMD 데이터를 활용하여 위와 같이 평균 정밀도를 기준으로 객체 검출성능을 평가를 진행한다. Fig. 25-(a)는 전체 데이터에서 각 클래스의 총 객체 수를 그래프로 표현한 것으로, 'Vessel/Ship' 데이터가 약 75%를 차지하는 분포를 보인다. 데이터의 불균형을 고려하여 관심 대상을 선박에 한정하여, 'Ferry', 'Vessel /Ship', 'Speed boat', 'Boat', 'Sail boat' 클래스에 대해서만 실험을 진행하였으며, 전경과 배경으로 이진 분류로 클래스를 나눠 실험을 진행하였다.

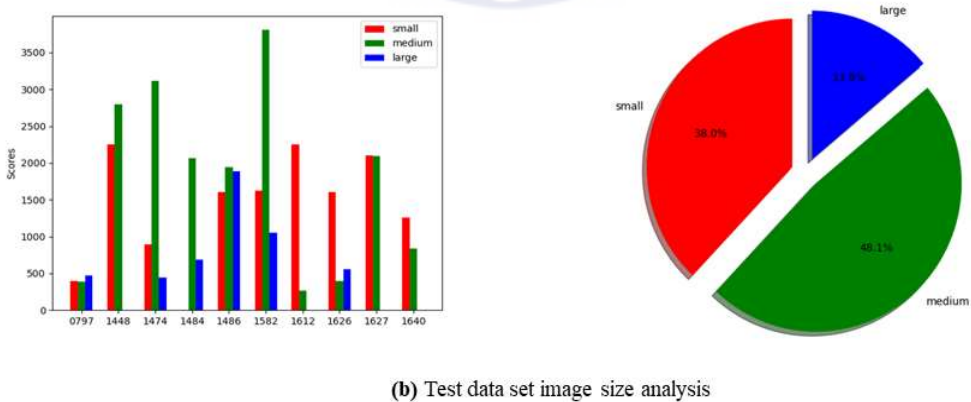



Fig. 27 Results and graphs of SMD analysis

본 논문에서 사용된 데이터 SMD는 총 10개 영상, 5,232 프레임, 36,779개의 객체에 대해 객체검출을 수행하였으며 앞서 정의한 크기를 바탕으로 콜라주 데이터 증강기법과 그에 따른 실험결과를 크기에 따라 평균 정밀도 성능 실험을 진행한 비교결과를 Table 10에 데이터 구성을 나타낸다.

Table 10 Results of SMD detailed analysis

MVI	Frames	Labels			
		small	medium	large	total
0797	600	399	391	468	1,258
1448	604	2253	2795	-	5,048
1474	445	890	3115	445	4,450
1484	687	-	2061	687	2,748
1486	629	1604	1942	1887	5,433
1582	540	1620	3806	1054	6,480
1612	261	2249	265	-	2,514
1626	556	1602	392	556	2,550
1627	600	2104	2096	-	4,200
1640	310	1258	836	4	2,098
Total	5,232	13,979	17,699	5,101	36,779

실험결과 Table. 11에 정의된 것처럼 기존 SMD 데이터만을 사용한 모델의 전체 평균 정밀도는 87.94% 성능을 보였으며, 콜라주 데이터 증강기법을 활용하였을 때, 각각 88.28%, 89.37%, 88.31%로 약 0.34%, 1.43%, 0.37% 향상된 성능을 보인다. 크기에 따른 증강기법 중 medium 크기로 데이터 증강을 시도하였을 때 가장 좋은 성능을 보였으며, 이는 Fig. 25-(b)와 같이 실험 데이터의 객체 크기 분포가 중간 크기가 48.1%를 차지하여 효과적으로 성능향상이 이루어진 것을 볼 수 있다.

Table 11 Results of object detection in SMD

SMD	Only Collage	SMD + Collage(S)	SMD + Collage(M)	SMD + Collage(L)
96.50	79.69	96.92	<u>97.13</u>	96.62
85.55	40.44	86.53	<u>86.99</u>	84.35
85.01	79.94	83.37	<u>87.70</u>	86.69
97.69	83.13	97.72	<u>99.09</u>	98.13
77.70	59.42	79.82	<u>82.92</u>	81.51
86.13	65.62	86.29	<u>88.08</u>	87.81
83.98	62.14	85.20	<u>85.57</u>	84.84
80.57	76.47	79.72	<u>81.29</u>	79.70
<u>97.98</u>	74.13	97.74	96.69	97.17
88.25	77.11	<u>89.52</u>	88.22	86.26
87.94	69.81	88.28	<u>89.37</u>	88.31

이를 크기에 따른 실험결과를 상세히 분석하기 위해 실험 데이터를 크기 별로 라벨을 분리하여 각각 검증을 수행한 결과의 평균 정밀도를 비교하였다. 실험결과 기존 SMD 데이터만을 사용한 기법과 비교하였을 때, large 크기를 사용한 결과는 큰 차이를 보이지 않았으나, small, medium 크기를 활용하여 콜라주 데이터 증강기법을 통해 성능향상이 이루어진 것을 볼 수 있다. 성능향상 결과는 작은 크기로 데이터 증강하여 작은 크기의 객체에 대해 검증결과 약 1.11%, 중간 크기로 데이터 증강하여 중간, 큰 크기의 객체에 대해 약 0.98%, 6.24%로 성능향상이 이루어졌다. 이를 통해, 콜라주 데이터 증강기법을 활용한 심층학습 기반의 객체검출 성능향상이 가능하며 중간 크기를 사용하여 데이터를 증강하였을 때 효과적으로 데이터를 증강할 수 있는 것을 보인다. 이에 따른 실험결과를 Table 12와 같이 기술한다.

Table 12 Detailed results of object detection in SMD

MVI	SMD			SMD + Collage(S)			SMD + Collage(M)			SMD + Collage(L)		
	small	medium	large	small	medium	large	small	medium	large	small	medium	large
0797	33.22	<u>82.93</u>	75.40	34.50	78.74	87.95	<u>35.62</u>	75.35	<u>92.93</u>	34.59	77.92	86.98
1448	32.24	72.24	-	30.49	73.96	-	<u>32.68</u>	<u>75.86</u>	-	32.61	71.94	-
1474	<u>10.69</u>	77.52	<u>26.06</u>	10.37	74.13	23.80	09.12	<u>84.71</u>	17.27	09.71	83.20	21.61
1484	-	68.55	73.69	-	67.51	44.33	-	71.70	<u>91.69</u>	-	<u>78.04</u>	39.57
1486	<u>32.42</u>	22.27	40.37	31.09	22.66	44.14	31.47	<u>29.94</u>	39.32	29.48	26.64	<u>48.14</u>
1582	16.50	<u>89.61</u>	06.10	<u>19.44</u>	83.17	05.98	18.20	88.15	<u>07.27</u>	17.89	86.94	06.11
1612	76.06	15.80	-	76.12	15.55	-	77.27	15.88	-	<u>79.36</u>	<u>15.94</u>	-
1626	34.47	<u>49.89</u>	33.88	<u>42.27</u>	34.44	35.31	35.77	40.31	<u>45.33</u>	38.52	35.14	34.33
1627	<u>46.30</u>	84.67	-	44.67	88.92	-	44.30	<u>90.66</u>	-	45.34	80.35	-
1640	70.52	50.51	06.25	<u>73.46</u>	50.25	09.42	68.88	51.22	<u>11.60</u>	70.39	<u>55.93</u>	09.38
Total	39.16	61.40	37.39	<u>40.27</u>	58.93	35.85	39.27	<u>62.38</u>	<u>43.63</u>	39.77	61.20	35.16

4.2.3 시스템 실험 및 검증

본 논문에서 제안하는 시스템의 범용적인 성능 측정을 위해서 한국해양대학교 인근 앞바다에서 수집된 데이터를 기반으로 구축한 데이터에 실험하여 검증하였다. 수집된 데이터는 Table 13과 같이 총 1,032프레임의 동영상으로 5,412개의 객체를 포함하고 있으며, Table 14는 실험결과를 나타낸다. Fig. 26은 Table 13을 기반으로 데이터를 그래프로 시각화하여 표현한 것을 나타낸다.

Table 13 Results of the built data set analysis

Video	Frames	Labels			
		small	medium	large	total
C0022	516	1,548	2,064	0	3,612
C0030	516	0	517	515	1,032
C0048	384	0	384	384	768
Total	1,032	1,548	2,965	899	5,412

Table 14 Results of object detection of the built data set

SMD	SMD+Collage(S)		SMD+Collage(M)		SMD+Collage(L)	
	-	horizon	-	horizon	-	horizon
63.28	70.03	66.68	<u>83.04</u>	<u>90.20</u>	70.87	68.31
61.97	80.54	82.40	93.56	95.45	<u>98.65</u>	<u>99.09</u>
37.37	76.06	96.44	<u>92.50</u>	<u>96.87</u>	84.42	94.56
<u>62.63</u>	75.29	74.54	<u>88.30</u>	<u>92.83</u>	84.76	83.70




Fig. 28 Built data set test image size analysis

Table 14에 나타난 것과 같이 공개된 데이터 SMD만을 사용한 결과는 62.63%에 비해 제안하는 콜라주 증강기법을 통해 학습된 모델은 88.30%로 평균 정밀도가 약 25.67% 상승한 결과를 보인다. 그리고 제안하는 수평선 검출기법을 통해 표적 대상을 정제하였을 경우 92.83%로 약 4.53% 상승하여 최종적으로 평균 정밀도는 약 30.2% 증가하며 Fig. 27과 같이 나타내었다. 이를 통해 제안하는 기법이 한정된 SMD뿐만 아니라, 범용적인 데이터에서도 좋은 성능을 보일 수 있음을 나타낸다.



Fig. 29 Results of object filtering processing by selected horizon line

본 논문에서 제안하는 다중센서 정보융합을 통한 해상객체 데이터 정보 시각화 결과는 Fig. 28과 같이 청록색으로 표현된 제안하는 수평선 검출기법을 통해 추출된 수평선 정보를 기반으로 객체를 필터링한 결과 주목하는 객체는 초록색, 필터링 된 경계상자는 빨간색으로 표현하였다. 다중센서 정보융합을 통해 객체의 정보를 시각화하기 위해서 영상에서 주목하는 객체 경계상자 왼쪽 위쪽에 해상이동업무식별번호, 위도, 그리고 경도 순으로 표현하여 나타낸다. 이를 통해 제안하는 기법을 활용하여 영상의 시각 정보와 더불어 관련된 선박 자동 식별시스템의 정보를 함께 확인이 가능한 것을 검증하였다.




Fig. 30 Results of data visualization through multi-sensor data fusion

제 5 장 결론 및 향후 연구

본 논문에서는 콜라주 데이터 증강기법을 이용한 심층학습 기반의 해상객체 검출기술을 제안하여 효율적으로 데이터를 자동생성이 가능하며, 이를 심층학습 기반의 해상객체 검출기에 적용하여 공개 데이터 세트 환경뿐만 아니라 범용적인 환경에서도 성능향상이 가능함을 검증하였다. 그리고 항만 인근의 환경을 고려하여 관심 영역을 제한하기 위해 이중 허프 변환을 활용한 고속수평선 검출기법을 제안하였고, 선박자동식별 시스템에서 얻어진 메시지를 분석하여 선박의 고유식별 번호와 위치 정보를 추출한 후 영상과의 다중센서 융합을 통해 선박 정보를 영상에 가시화하여 효율적인 해상 상황인식기술이 가능한 시스템을 개발하였다.

제안하는 콜라주 데이터 증강기법을 검증 절차에 따라 공개된 해상 객체검출 데이터 SMD에 실험 및 검증하였을 때, 객체검출 평균 정밀도가 기존보다 약 1.43% 향상되는 것을 확인할 수 있었다. 그리고 한국해양대학교에서 촬영한 부산항 인근 해상환경에서 콜라주 데이터 증강기법을 실험 및 검증을 수행하였을 때, 기존보다 약 25.7% 향상됨을 알 수 있다. 고속 수평선검출기술과 다중센서 융합기술을 활용한 전체 시스템의 성능은 약 30.2% 향상되는 것을 확인할 수 있으며, 이를 통해 제안하는 기법이 해상객체 검출의 성능을 높일 수 있고 특히, 범용적인 해상환경에서 효과적으로 성능을 발휘할 수 있음을 알 수 있었다.

이를 통해 다양한 해상환경에서 정확하고 효율적인 심층학습 기반의 해상객체 검출과 해상 상황인지를 위한 정보요소를 영상정보와 융합하고 시각적으로 제공하여 자율운항 선박 및 스마트 항만에서 시각적 인지 정보를 효과적으로 전달할 수 있을 것으로 예상된다.

향후 연구로는 자율운항 선박 및 스마트항만의 실현을 위해서 더욱 많은 다중센서로 수집가능한 모든 해양정보를 전자적으로 통합, 교환, 표현 및 분석을 통해 인간의 시각적 능력을 보조, 지원 또는 대체하여 안전하고 신뢰성있는 정보를 제공하는 해상 상황인식 기술을 연구하는 것이다.

참고문헌

- [1] 이광일, 황승욱, 2018, 자율운항선박 국제표준화 동향, *한국정보통신기술협회*, 175호, pp.115-122
- [2] 이윤석, 2018, 자율운항선박(MASS) 개발 동향 분석, *한국정보통신기술협회*, 178호, pp.20-26
- [3] International Maritime Organization (IMO), 2018, *Maritime safety committee session 99 -16*
- [4] Niall O', M., Sean, C., Anderson, C., Suman, H., Gustavo, V. H., Lenka, K., Daniel, R., & Joseph, W., 2019, Deep Learning vs. Traditional Computer Vision, *arXiv:1910.13796*
- [5] Prasad, D. K., Rajan, D., Rachmawati, L., Rajabaly, E. & Quek, C., 2017, Video processing from electro-optical sensors for object detection and tracking in maritime environment: A Survey, *IEEE Transactions on Intelligent Transportation Systems*, 18(8), pp.1993-2016.
- [6] Moosbauer, S., König, D., Jäkel, J., & Teutsch, M., 2019, A benchmark for deep learning based object detection in maritime environments, *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*
- [7] Moreira, R., Ebecken, N., Alves, A. S., Livernet, F., & Campillo-Navetti, A., 2014, A survey on video detection and tracking of maritime vessels, *International Journal of Research and Reviews in Applied Sciences*, 20(1), pp.37-50
- [8] Praczyk, T., 2017, A quick algorithm for horizon line detection in marine images, *Journal of Marine Science and Technology*, 23(1), pp.164-177
- [9] Fefilatyeve, S., Goldgof, D., Shreve, M., & Lembke, C., 2012, Detection and tracking of ships in open sea with rapidly moving buoy-mounted camera system. *Ocean Engineering*, 54, pp.1-12

- [10] Gladstone, R., Moshe, Y., & Barel, A., 2016, Distance estimation for marine vehicles using a monocular video camera, *Proceeding of the European signal processing conference, Budapest, Hungary, 28 August-2 September 2016*, pp.2405-2409
- [11] Canny, J., 1986, A computational approach to edge detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6), pp.679-698
- [12] Duda, R. O., & Hart, P. E., 1972, Use of the Hough transformation to detect lines and curves in pictures, *Communications of the Association for Computing Machinery*, 15(1), pp.11-15
- [13] Bouma, H., Lange, D. J., Broek, S. P., Kemp, R. A., & Schwering, P. B., 2008, Automatic detection of small surface targets with electro-optical sensors in a harbor environment. *Proceedings of SPIE - The International Society for Optical Engineering*. 7114.
- [14] Gershikov, E., Libe, T., & Kosolapov, S., 2013, Horizon line detection in marine images: which method to choose?, *International journal on advances in intelligent systems*, 6(1), pp.79-88.
- [15] Prasad, D. K., Rajan, D., Rachmawati, L., Rajabally, E., & Quek, C., 2016 MuSCoWERT: Multi-scale consistence of weighted edge Radon transform for horizon detection in maritime images, *Journal of the Optical Society of America. A, Optics, image science, and vision*, 33(12), pp.2491-2500
- [16] Prasad, D. K., Rajan, D., Prasath, C. K., Rachmawati, L., Rajabally, E., & Quek, C., 2016, MSCM-LiFe: Multi-scale cross modal linear feature for horizon detection in maritime images, *Proceedings of 2016 IEEE Region 10 Conference, Singapore*, pp.1366-1370
- [17] Liu, B., Wang, S. Z., Xie, Z. X., Zhao, J. S., & Li, M. F., 2019, Ship recognition and tracking system for intelligent ship based on deep learning framework, *The International Journal on Marine Navigation and Safety of Sea Transportation*, 13(4), pp.699-705

- [18] Ren, S., He, K., Girshick, R., & Sun, J., 2017, Faster R-CNN: Towards real-time object detection with region proposal networks, *Proceedings of the IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), pp.1137-1149
- [19] Uijlings, J. R. R., van de Sande, K. E. A., Gevers, T., & Smeulders, A. W. M., 2013, Selective search for object recognition, *International Journal of Computer Vision*, 104(2), pp.154-171
- [20] He, K., Gkioxari, G., Dollár, P., & Girshick, R., 2017, Mask R-CNN, *arxiv.org/abs/1703.06870*
- [21] Wei, L., Dragomir, A., Dumitru, E., Christian, S., Scott, R., Cheng-Yang, F., & Alexander, C. B., 2016, SSD: Single Shot MultiBox Detector, *Proceedings of the 2016 European Conference on Computer Vision*, pp.21-37
- [22] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A., 2016, You Only Look Once: Unified, Real-Time Object Detection, *Proceeding of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, 2016*, pp.779-788
- [23] Lin, T., Goyal, P., Girshick, R., He, K., & Dollár, P., 2017, Focal Loss for Dense Object Detection, *Proceedings in the IEEE International Conference on Computer Vision, Venice, 2017*, pp.2999-3007
- [24] Barret, Z. E., Cubuk, D., Golnaz, G., Tsung-Yi, L., Jonathon, S., & Quoc, V. L., 2019, Learning data augmentation strategies for object detection, *arXiv:1906.11172*
- [25] Debidatta, D., Ishan, M., & Martial, H., 2017, Cut, Paste and Learn: Surprisingly easy synthesis for instance detection, *arXiv:1708.01642*
- [26] Mate, K., Zbigniew, W., Jakub, M., Jacek, N., & Cho, K., 2019, Augmentation for small object detection, *arXiv:1902.07296*

- [27] Bloisi, D., Iocchi, L., & Fiorini, M., 2011, Automatic maritime surveillance with visual target detection, *Proceedings of the International Defense and Homeland Security Simulation Workshop, Rome, September 12-14, 2011*, pp.141-145.
- [28] Bloisi, D. D., Previtali, F., Pennisi, A., Nardi, D., & Fiorini, M., 2015, Integrated visual information for maritime surveillance, *Proceedings of the Clean Mobility and Intelligent Transport Systems*, pp.237-264
- [29] Bloisi, D. D., Previtali, F., Pennisi, A., Nardi, D., & Fiorini, M., 2017, Enhancing automatic maritime surveillance systems with visual information, *Proceedings in IEEE Transactions on Intelligent Transportation Systems*, 18(4), pp.824-833
- [30] Matthijs, H. Z., Rob, G. J. W., & Peter, H. N. W., 2018, Ship detection in harbour surveillance based on large-scale data and CNNs, *Proceedings of the 13th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, 5, pp.153-160
- [31] Wei, H., Nguyen, H., Ramu, P., Raju, C., Liu, X., & Yadegar, J., 2009, Automated intelligent video surveillance system for ships, *Optics and Photonics in Global Homeland Security V and Biometric Technology for Human Identification VI*, 7306, pp.274-285
- [32] 김현태, 박장식, 유윤식, 2010, 영상의 배경추정기법과 AIS정보를 이용한 선박검출, *한국정보통신학회논문지*, 14(12), pp.2636-2641
- [33] Liang-Chieh, C., Yukun, Z., George, P., Florian, S., & Hartwig, A., 2018, Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, *arXiv:1802.02611*
- [34] Tsung-Yi, L., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L., & Dollár, P., 2014, Microsoft COCO: Common Objects in Context, *arxiv.org/abs/1405.0312*