



Received: 2025/02/21
Revised: 2025/03/04
Accepted: 2025/03/22
Published: 2025/03/31

***Corresponding Author:**

Hyunseung Kim

Marine R&D Center, LIG Nex1
333 Pangyo-ro, Bundang-gu, Seongnam-si,
Gyeonggi-do, 13488, Republic of Korea
Tel: +82-31-5179-7272
Fax: +82-31-5179-7086
E-mail: hyunseung.kim2@lignex1.com

CNN 기법을 활용한 해저지형 영상 내에서의 해저산 중심 위치 산출 연구

Research on Estimating the Central Position of Seamount in Seafloor Topography Images Using CNN Techniques

김현승^{1*}, 현철², 이성균², 고진용²

¹LIG넥스원 해양연구소 선임연구원

²LIG넥스원 해양연구소 수석연구원

Hyunseung Kim^{1*}, Chul Hyun², Sungkyun Lee², Jinyong Go²

¹Senior researcher, Marine R&D Center, LIG Nex1

²Chief researcher, Marine R&D Center, LIG Nex1

Abstract

본 논문은 해저지형 영상으로부터 해저산의 중심 위치를 산출할 수 있도록 CNN(convolutional neural network) 기법을 활용한 딥러닝 학습 알고리즘을 제안하였다. 실제 한반도 인근 해역 수심 데이터로부터 약 150장의 해저지형 영상을 생성하여 학습시키고, 해저산 중심 위치 산출 정확도를 분석함으로써 최적의 특징점 추출기를 모델링하는 연구를 수행하였다. 본 논문에서 제안하는 알고리즘을 기반으로 수중 운동체의 주행 경로상의 해저지형을 사전에 분석함으로써 자율 주행에 기여할 수 있다.

This paper proposed a deep learning training algorithm utilizing CNN(convolutional neural network) techniques to estimate the central position of seamount from seafloor topography images. Approximately 150 seafloor topography images were generated from bathymetric data near the Korean Peninsula for training, and the accuracy of sea mount center estimation was analyzed to model an optimal feature extractor. Based on the proposed algorithm, pre-analysis of seafloor topography along the trajectory of underwater vehicles can contribute to autonomous navigation.

Keywords

해저지형(Seafloor Topography),
합성곱 신경망(Convolutional Neural Network),
특징점 추출(Feature Extraction),
딥러닝(Deep Learning)

1. 서론

수중에서 운동체의 전진 방향에 존재하는 장애물을 탐지하고 회피하는 것은 자율 주행의 기본 요소이다[1]. 그중에서 해저지형은 위도 및 경도별 수심 데이터를 이용하여 사전에 운동체의 주행 경로상 존재 여부를 확인할 수 있기 때문에 예측 가능한 장애물로 분류된다. 해저지형에서도 충돌 가능성이 큰 해저산의 중심 위치를 정확히 산출함으로써 운동체 주행에 있어서 위험 요소를 사전에 입력하여 회피하는 데에 도움을 줄 수 있다[2]. 특히 한반도 동·서해는 수중전이나 훈련에 있어 복잡한 해저지형 특성을 지니고 있기 때문에, 영상으로부터 해저산의 중심 위치를 산출하여 경로점 주행 시나리오를 입력하거나 회피 기동을 수행할 수 있도록 해야 한다. 하지만 방대한 구역에서 해저산의 중심 위치를 일일이 산출하는 것은 한계가 있고, 중첩된 해저산의 경우 일반적인 기울기법으로 중심 위치를 산출하면 오차가 커진다[3].

따라서 본 연구에서는 국립해양조사원에서 제공하는 실제 수심 데이터(위도 31~42도, 경도 122~135도 내에서 거리 1.6km 간격)를 이용하여 해저지형 영상을 생성하고, CNN(convolutional neural network) 기법의 학습규칙을 적용함으로써 영상으로부터 불규칙적으로 다수 존재하는 해저산의 중심 위치를 추출하였다. CNN 기

법은 이미지에서 특징점을 추출하고 분류하는데 고성능을 보이는 신경망 구조이다[4-6].

본 연구에서는 CNN 기법의 딥러닝 알고리즘을 적용한 학습을 통해 실제 한반도 해저지형 영상에서 해저산 중심 위치를 추출하였으며, 실제 데이터와의 오차를 분석하고 학습에 필요한 계수를 보정함으로써 해저산 중심 위치 산출의 정확도를 높였다. 더불어 해저산 중심 위치 결과 분석을 통해 최적의 특징점 추출기 모델을 도출하였다. 수중에서 예측 가능하지만 회피 성능에 지대한 영향을 미치는 해저산을 추출함으로써, 수중자율운동체의 경로계획 수립에 활용할 수 있을 것으로 기대된다.

2. 한반도 해저지형 특성 분석

국립해양조사원에서 제공하는 동해 해역 해저지형은 위도 38.6~40.7도, 경도 128.5~131.5도 구간에 해당하며, 이 구역의 수심데이터를 Fig. 1에 가시화하였다. 평균 수심은 약 3 km로 깊고 다수의 완만한 해저산이 중첩 없이 존재하는 것을 확인할 수 있다.

Fig. 2는 서해 해역 해저지형에 해당하는 위도 35~37.1도, 경도 123~125.1도 구간의 수심데이터를 가시화한 것이다. 평균 수심이 약 100 m로 동해에 비해 얕지만 같은 구역에 대해 해저산이 다수 분포하며 그 기울기가 가파른 것을 확인할 수 있다.

3. CNN 기법을 활용한 해저산 중심 위치 산출 알고리즘

2장에서 가시화한 동·서해 해저지형 영상으로부터

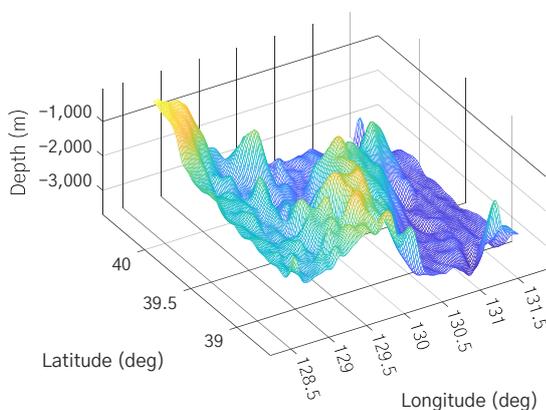


Fig. 1. Depth data of Korea East Sea

해저산 중심 위치를 산출하기 위하여 딥러닝 기반의 CNN 기법을 활용하여 해저지형 영상에 대해 학습을 수행하였다. 이때 영상의 크기는 위도 0.3도, 경도 0.3도 간격으로 설정하여 동해 해역에 대해 88장, 서해 해역에 대해 64장의 영상을 생성하였다. 또한 학습을 위해 동해 해역 50장, 서해 해역 40장의 영상을 선별하였고, 나머지 해저지형 영상 62장을 대상으로 CNN 기법을 활용한 해저산 중심 위치 산출 알고리즘 검증에 수행하였다.

CNN 기법은 입력된 이미지에서 특징점을 추출하기 위해 합성곱층, 활성화 함수층, 풀링층, 완전연결층 등 4개의 층으로 구분된다. 먼저 합성곱층에서는 이미지에서 특징을 추출하는 연산을 수행한다. 입력 이미지 X 와 커널 필터 K 가 주어졌을 때, 출력 특징 맵은 식 (1)과 같이 정의할 수 있다.

$$Y(i, j) = \sum_{m=0}^{k_H-1} \sum_{n=0}^{k_W-1} \sum_{c=0}^{C-1} X(i+m, j+n, c) \cdot K(m, n, c) + b \quad (1)$$

여기서, b 는 편향값이다.

다음으로 활성화 함수층은 비선형성을 도입하여 신경망이 복잡한 패턴을 학습할 수 있도록 한다. 대표적인 활성화 함수로 ReLU(rectified linear unit)를 사용하며 이는 식 (2)와 같다.

$$f(x) = \max(x, 0) \quad (2)$$

ReLU 함수는 음수를 0으로 변환함으로써 신경망 학습 속도를 높이고, 기울기 소실 문제를 완화하는 효과를 가진다.

세 번째로 풀링층에서는 특징 맵의 크기를 줄여 계

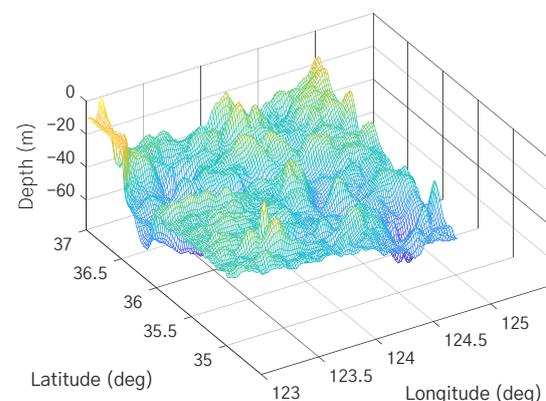


Fig. 2. Depth data of Korea West Sea

산량을 감소시키고, 성능을 높이는 역할을 수행한다. 대표적으로 최대 풀링 값, 평균 풀링 값을 사용하고 식 (3), 식 (4)와 같이 수행한다.

$$Y(i, j) = \max_{(m,n) \in R} X(i + m, j + n) \quad (3)$$

$$Y(i, j) = \frac{1}{|R|} \sum_{(m,n) \in R} X(i + m, j + n) \quad (4)$$

여기서, R 은 풀링 영역을 의미한다.

마지막으로 완전연결층은 최종 예측값으로 변환하는 역할을 수행한다. 특징 맵 벡터 X , 가중치 행렬 W , 편향 벡터 b 가 주어졌을 때 식 (5)와 같이 산출된다.

$$Y = \sigma(WX + b) \quad (5)$$

여기서, σ 는 활성화 함수 ReLU이다.

이렇게 4개의 층으로 구성된 CNN 기법의 학습 목표인 손실함수 최소화를 위해 손실함수 L 은 식 (6)과 같이 정의할 수 있다.

$$L = - \sum_{i=1}^N y_i \log(\hat{y}_i) \quad (6)$$

여기서, y_i 는 해저지형 데이터에서 실제 해저산의 중심 위치, \hat{y}_i 는 완전연결층에서 예측된 해저산의 중심 위치이다.

최종적으로 손실함수의 기울기가 0으로 수렴하도록 확률적 경사 하강법을 통해 식 (7)과 같이 가중치 θ 를 업데이트한다.

$$\theta \leftarrow \theta - \eta \nabla L \quad (7)$$

여기서, η 는 학습률이다.

이때 가중치 θ 를 식 (5)의 W 행렬에 업데이트하여 반복 학습을 통해 해저산 중심 위치 산출 정확도를 높인다.

4. 해저산 중심 위치 산출 분석

3장에서 제안한 CNN 기법을 활용한 해저산 중심 위치 산출 알고리즘의 학습을 해저지형 영상 90장에 적용하였다. 정확도 검증을 위해 대표적인 동해 해역 (Fig. 3 참조)과 서해 해역 (Figs. 4-5 참조) 해저지형 데이터 영상에 대한 결과를 분석하였다.

먼저 Fig. 3는 동해 해역의 완만한 해저산이 존재하는 경우로 해저산 중심 위치는 2개이다. Fig. 4는 서해 해역의 중첩된 해저산이 존재하는 경우로 해저산 중심 위치는 3개이다. 서해 해역에서 기울기가 가파른 영역을 가시화한 Fig. 5는 영상의 중심이 파여진 경우로 해저산 중심 위치는 2개이다.

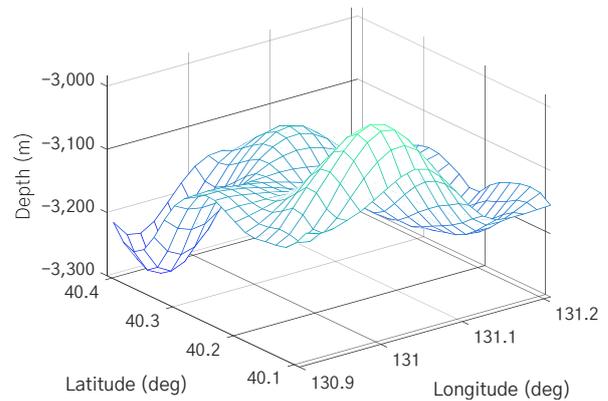


Fig. 3. Scenario for feature extraction algorithm for Korean East Sea

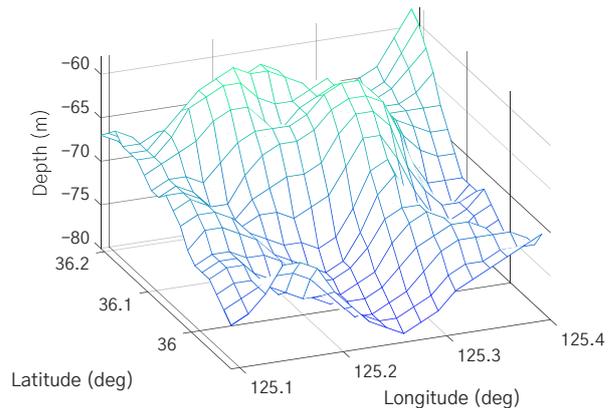


Fig. 4. Scenario for feature extraction algorithm for Korean West Sea with nested undersea mountains

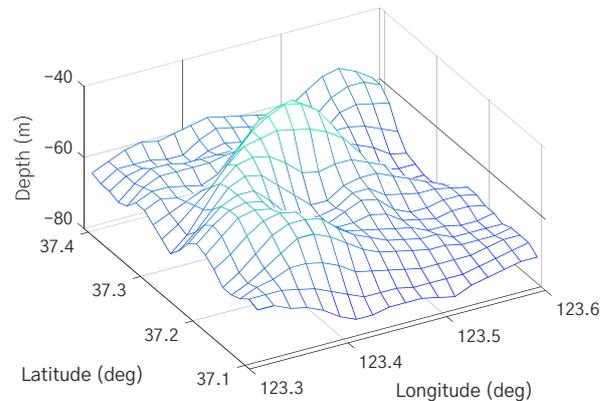


Fig. 5. Scenario for feature extraction algorithm for Korean West Sea with different slopes

Figs. 6-8은 Figs. 3-5에 대한 학습 결과로 산출된 해저산 중심 위치를 나타낸 것으로, 세 경우 모두 해저지형 데이터에서의 실제 해저산 중심 위치와 일치하는 것을 확인하였다.

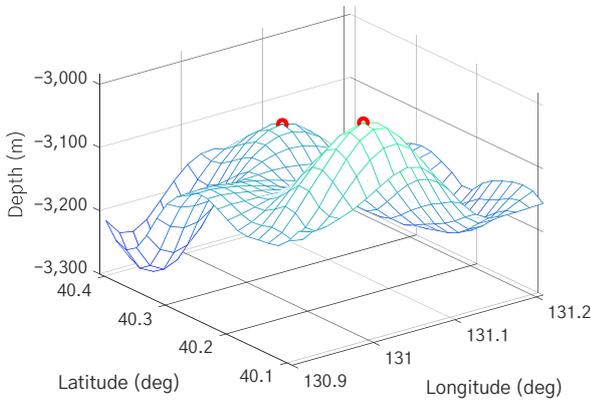


Fig. 6. Deep-learning result by predicting of center of the seafloor mountain based on Fig. 3

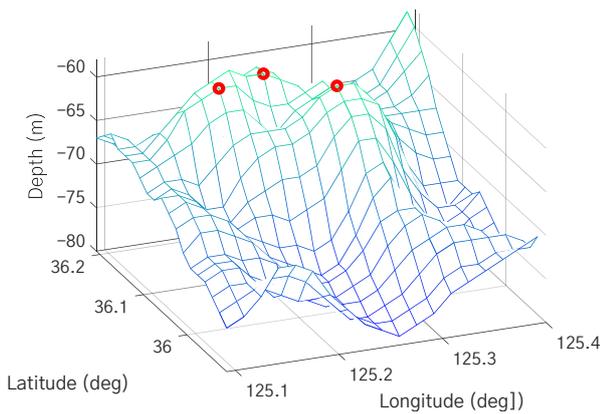


Fig. 7. Deep-learning result by predicting of center of the seafloor mountain based on Fig. 4

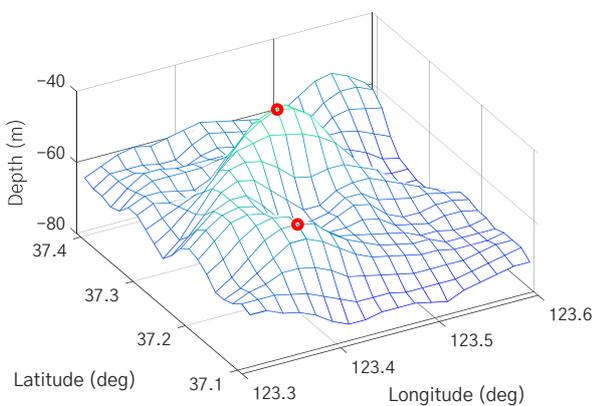


Fig. 8. Deep-learning result by predicting of center of the seafloor mountain based on Fig. 5

해저지형 영상 90장에 대한 해저산 중심 위치 산

출 정확도를 척도로 삼아 분석한 결과, 평균 정확도는 87.41 %이다(Table 1 참조). 해저지형 영상 90장에서 78장에 대해서는 해저산 중심 위치 산출 결과가 실제와 일치하였으나, 나머지 12장에서는 실제 산출해야 할 해저산 중심 위치 대비 가감하여 오차가 발생하였다.

Table 1. Result of CNN application for prediction of center of the seafloor mountain with 90 Images

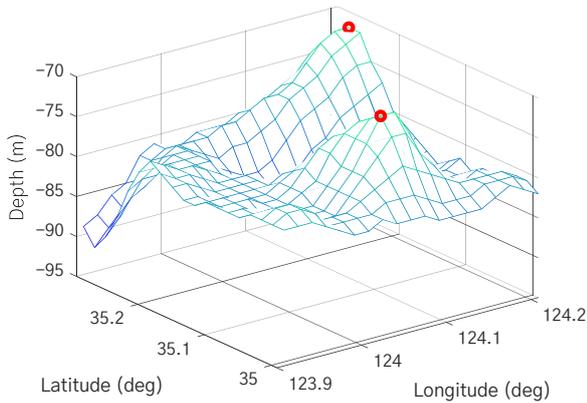
Algorithm	Extraction accuracy (%)
CNN application	87.41
CNN with gradient-based learning	95.68

Fig. 9은 이러한 오차 발생 사례를 도시한 것으로, Fig. 9(a)와 Fig. 9(b) 모두 경도 124.2도 부근에서 해저산 중심 위치가 산출되는 것을 확인하였다. 하지만 Fig. 9(c)에서 Fig. 9(a)와 Fig. 9(b) 영역을 동시에 가시화했을 때, 위도 35.3도, 경도 124.2도 부근에서는 해저산 중심 위치가 1개로 수렴하는 것을 확인할 수 있다. 이는 CNN 기법을 활용한 해저산 중심 위치 산출 학습 시 사용자가 지정한 영상 구역의 간격에 따라 경계면이 모호한 현상이 발생하기 때문이다.

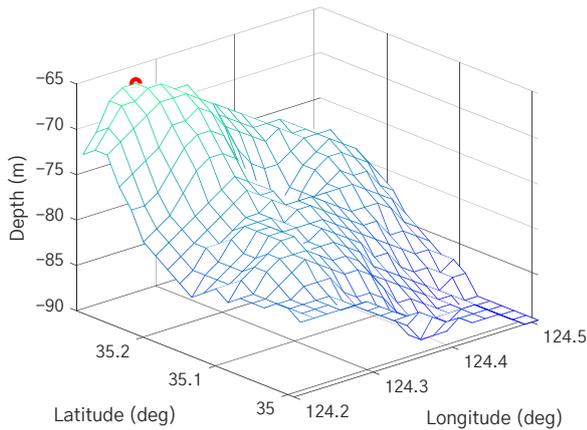
이러한 문제점을 해결하기 위한 방법은 크게 두 가지이다. 먼저 딥러닝 학습 시 해저지형 영상 구역의 위도 및 경도 간격을 넓게 지정하는 방법이 있다. 하지만 이 경우에는 한반도에 대한 학습 데이터의 양이 현저히 감소하여 정확도가 감소하는 문제점이 발생할 수 있다. 두 번째로는 3장에서 제안한 알고리즘으로 1차 학습을 수행하고, 2차적으로 전체 구역에 대한 해저산 중심 위치 산출 결과에서 특이점이 발생하는 지점에 대해 기울기법을 적용한 해저산 중심 위치를 재산출하는 방식이다.

두 번째 방식을 적용하여 앞선 해저지형 영상 90장에 대한 해저산 중심 위치 산출 정확도를 척도로 삼아 분석한 결과 평균 정확도는 95.68 %로(Table 1 참조), 오차가 발생한 12장에서 8장에서 해저산 중심 위치 산출결과가 실제와 일치함을 확인하였다. 하지만 Fig. 10과 같이 위도 35.2도, 경도 125.5도 근방에서 해저산의 꼭대기가 평평한 기묘 현상이 있는 경우 해저산 중심 위치 산출에 오차가 발생함을 확인

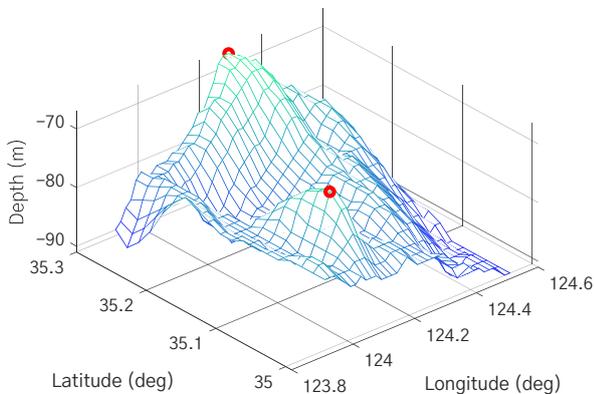
하였다. 이 경우 수중 운동체가 평평한 해저산맥 영역에 대해 가장 높은 고도 값을 가지는 지점을 해저산의 중심 위치로 산출하여 회피 기동하면 수중 운동체의 주행 성능에 지장이 없을 것으로 판단된다. 나아가 유사한 해저지형 영상을 다수 확보하여 반복 학습이 필요할 것으로 사료된다.



(a) Depth data within the longitude [123.9 124.2]



(b) Depth data within the longitude [124.2 124.5]



(c) Depth data within the longitude [123.9 124.5]

Fig. 9. Error in prediction of center of the seafloor mountain due to mountains spanning the boundary

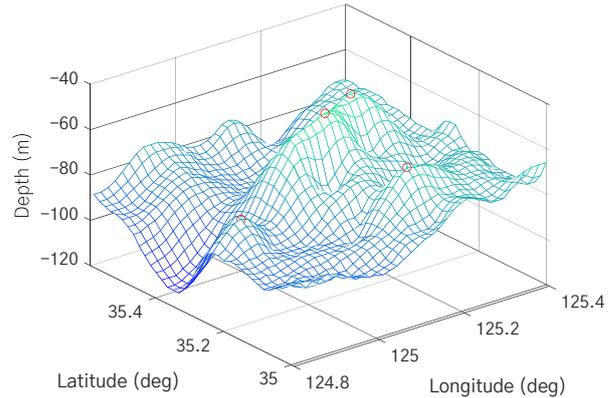


Fig. 10. Error in prediction of center of the seafloor mountain due to mountains spanning the boundary

6. 결론

운동체가 수중에서 주행할 때, 임무를 수행하면서 장애물을 회피하는 성능이 중요하다. 특히 해저지형은 예측이 가능하지만 한반도 동·서·남해 해역의 특징이 서로 다르므로 사전에 해저산의 중심 위치를 정확히 산출해야 주행 위험 요소를 제거할 수 있다.

이에 따라 본 논문에서는 국립해양연구원에서 제공하는 실제 한반도 해역의 해저지형 데이터를 기반으로 CNN 기법의 학습규칙을 적용함으로써 영상으로부터 불규칙적으로 다수 존재하는 해저산의 중심 위치를 추출하는 알고리즘을 제안하였다. 더불어 이를 검증하기 위해 중첩된 해저산맥과 완만한 해저산맥 시나리오에 대한 실제 해저산 중심 위치 값과 제안한 알고리즘을 비교 분석하였다.

하지만 기요 현상이 있는 평평한 해저산에 대해서는 제한된 학습량에 따라 오차가 발생함을 확인하였고, 사용자가 설정하는 영상 크기마다 경계면에 해저산이 모호하게 걸쳐 있는 현상이 발생하였다. 따라서 다양한 해저지형 영상을 다수 확보하여 반복 학습을 통해 최적의 특징점 추출기 모델로 보완하는 작업이 필요할 것으로 보인다.

본 논문에서 제시하는 알고리즘을 활용하여 해저산의 중심 위치를 미리 산출함으로써, 수중운동체의 경로계획 수립 및 회피 기동에 기여할 수 있을 것으로 기대된다.

참고문헌

[1] S. Y. Yang, J. H. Kim, B. J. Kim and K. S. Kim, "A Study

on the 3-D Digital Modeling of the Sea Bottom Topography,” *Journal of the Korea Institute of Military Science and Technology*, Vol. 5, No. 2, pp. 50–61, 2002.

[2] S. C. Yoo, J. Y. Mun, W. Park, G. H. Seo, S. J. Gwon and R. Heo, “Development of Bathymetric Data for Ocean Numerical Model Using Sea-floor Topography Data: BADA Ver. 1,” *Journal of Korean Society of Coastal and Ocean Engineers*, Vol. 31, No. 3, pp. 146–157, 2019.

[3] H. S. Kim, C. H. S. K. Lee, C. H. Kim and J. Y. Go, “Development of High-resolution Seafloor Topograph Map Generation Techniques Applying Feature Point Detection Algorithm,” *Journal of Korean Society for Naval Science and Technology*, Vol. 7, No. 1, pp. 11–16, 2024.

[4] D. G. Lee, Y. G. Sun, S. H. Kim, I. S. Sim, K. S. Lee, M. N.

Song and J. Y. Kim, “CNN-based Image Rotation Correction Algorithm to Improve Image Recognition Rate”, *The Journal of the Institute of Internet, Broadcasting and Communication*, Vol. 20, No. 1, pp. 225–229, 2020.

[5] S. B. Yang and S. J. Lee, “Improved CNN Algorithm for Object Detection in Large Images,” *Journal of the Korea Society of Computer and Information*, Vol. 25, No. 1, pp. 45–53, 2020.

[6] D. S. Park, S. G. Hong and J. M. Park, “Implementation of AI-based Object Recognition Model for Improving Driving Safety of Electric Mobility Aids,” *The Journal of Korea Institute of Convergence Signal Processing*, Vol. 24, No. 2, 2023.