

## Lightweight Classification Model for Underwater Mines and Rocks Using Sonar Signals in Military Environment

Won-Jun Han\*, Soo-Jin Lee\*\*, Gwang-Ho Kim\*, Ki-Pyong Park\*

\*Graduate Student, Dept. of Cyber Security and Computer Engineering, Korea National Defense University, Nonsan, Korea

\*\*Professor, Dept. of Cyber Security and Computer Engineering, Korea National Defense University, Nonsan, Korea

### [Abstract]

The purpose of this study is to develop a lightweight machine learning model that can quickly and accurately classify underwater objects such as rocks and mines in a maritime military environment using SONAR data. To achieve this, we trained five machine learning models including KNN, SVM, Logistic Regression, LightGBM, and MLP, and analyzed and compared their classification performances. In order to improve the classification performance of the models, preprocessing techniques such as PCA and LDA were applied. Hyperparameters were also fine-tuned for each training model to derive optimized values. As a result of the experiment, the SVM model, which was trained by reducing the feature dimensions to 29 through PCA, achieved the highest accuracy of 96.15%, and all performances were superior to those of existing machine learning-based models. In particular, the proposed approach does not cause any misclassification of underwater mines at all, so it is expected to be useful for detecting submarines and underwater drones in a marine military environment in the future.

▶ **Key words:** Sonar, Underwater Mines, Machine Learning, SVM, Principal Component Analysis (PCA)

### [요약]

본 연구의 목표는 SONAR 데이터를 활용하여 해양 군사 환경에서 수중 물체인 암석과 지뢰를 신속하고 정확하게 탐지하는 경량화된 기계학습 모델을 개발하는 것이다. 이를 위해 KNN, SVM, Logistic Regression, LightGBM 및 MLP 등 5종의 기계학습 모델로 학습을 실시하고 분류 성능을 비교 분석하였다. 모델의 분류 성능을 향상시키기 위해 주성분 분석(PCA) 및 선형 판별 분석(LDA)과 같은 전처리 기법을 적용하였고, 학습 모델별로 하이퍼파라미터를 미세조정하면서 최적화된 값을 도출하였다. 실험 결과, PCA를 통해 특성 차원을 29개로 축소하여 학습을 실시한 SVM 모델이 96.15%로 가장 높은 정확도를 달성하였으며, 기존 기계학습 기반 모델 대비 모든 성능이 우수하게 나타났다. 특히 제안하는 접근방법은 수중 지뢰에 대한 오분류가 전혀 발생하지 않아 향후 해양 군사 환경에서 잠수함 및 수중 드론 등의 탐지에도 유용할 것으로 판단된다.

▶ **주제어:** Sonar, 수중 지뢰, 기계학습, SVM, 주성분 분석(PCA)

- First Author: Won-Jun Han, Co-Author: Gwang-Ho Kim, Ki-Pyong Park, Corresponding Author: Soo-Jin Lee
- \*Won-Jun Han (dnjswngsksdnjs@gmail.com), Dept. of Cyber Security and Computer Engineering, Korea National Defense University
- \*\*Soo-Jin Lee (cyberma@gmail.com), Dept. of Cyber Security and Computer Engineering, Korea National Defense University
- \*Gwang-Ho Kim (champion2409@naver.com), Dept. of Cyber Security and Computer Engineering, Korea National Defense University
- \*Ki-Pyong Park (pgp1003@naver.com), Dept. of Cyber Security and Computer Engineering, Korea National Defense University
- Received: 2025. 04. 10, Revised: 2025. 05. 20, Accepted: 2025. 05. 20.

## I. Introduction

수중 물체 탐지 및 식별 기술은 해양 환경에 대한 모니터링, 자원 개발, 생태 보호 및 군사 작전 수행 등 다양한 분야에서 중요성이 부각되고 있다. 특히 수중 지뢰는 각종 민간 선박과 군 함선, 잠수함 등의 안전한 항해에 가장 큰 위협이자 군사 작전 수행을 심각하게 방해하는 핵심 요소이기에 해상 안전 확보 및 군사 작전 수행 여건 보장 차원에서 정확한 탐지 기술 개발이 필수적이다.

수중 지뢰 탐지는 일반적으로 선박이나 수중 이동체에 장착되는 SONAR(Sound Navigation and Ranging)를 기반으로 수행되고 있다. SONAR는 음파를 이용하여 수중 물체를 탐지하고 위치, 크기 및 형태 등과 같은 특성까지 식별하는 것이 가능해 SONAR를 통해 생성되는 신호 데이터는 수중 환경 모니터링 및 분석을 위한 핵심 데이터라고 할 수 있다. 군사적 관점에서는 이러한 SONAR 데이터를 활용하여 수중 지뢰뿐만 아니라 적 잠수함이나 수중 드론 같이 해양으로 은밀하게 침투하는 위협 요소도 신속하게 탐지할 수 있다. 그리고 탐지된 표적들에 대한 지속적인 추적을 통해 크기, 이동 경로 및 작전 패턴 등도 분석할 수 있어 실시간 정보 기반 전략적 의사결정이 가능해진다.

그러나 SONAR 데이터를 기반으로 수중 지뢰를 탐지할 때 암석과 수중 지뢰를 정확하게 구분하는 작업은 여전히 개선이 필요한 도전 과제로 남아 있다[1, 2]. 과거 SONAR 운영자의 청각 및 시각적 인식에 전적으로 의존하여 수동으로 탐지를 시도했던 시기에는 다양한 해양 환경의 특성 및 조건으로 인해 두 물체의 신호 패턴 차이를 정밀하게 분석하는 것이 쉽지 않았다. 그리고 반사되는 신호를 감소시킬 수 있는 재료의 등장으로 인해 저주파 대역의 특성이 증가하면서 기존 신호 분석 방법의 한계는 더욱 극명하게 나타났다[3]. 이러한 한계를 극복하기 위해 데이터를 기반으로 한 고도화된 분류 모델 개발 필요성이 꾸준히 제기되면서 최근에는 딥러닝이나 기계학습 모델을 적용하는 연구가 활발하게 진행되고 있다.

SONAR 데이터를 기반으로 한 수중 지뢰 탐지 및 암석 분류와 관련된 연구는 크게 이미지에 기반한 방법과 음향(acoustic) 데이터에 기반한 방법으로 구분하여 진행되고 있다. 이미지 기반 접근은 SONAR 데이터에서 음향 펄스(sound pulse)를 제거한 후 반사 신호만 사용해 생성된 사이드스캔 소나 이미지(side-scan sonar image)를 통해 탐지 및 분류를 수행한다[4-7]. 음향 데이터 기반 접근은 다양한 주파수 대역과 각도에서 수집된 음파 반사 신호를 이용한다[1].

두 가지 접근방법 중 본 연구와 같이 음파 반사 신호를 기반으로 수중 지뢰 탐지를 시도 할 경우에는 신호가 내포하고 있는 특성을 정확하게 학습하기 위해 데이터 전처리 및 학습 모델 최적화가 중요하다. 그러나 많은 선행연구가 학습 모델에 적합한 데이터 전처리를 고려하지 않거나 [8-13], 학습 모델의 하이퍼파라미터 최적화를 통한 성능 개선을 시도하지 않았다[9, 12-14]. 또한, 군사 작전 환경에서는 모델의 실시간 처리 성능 보장과 경량화가 필수적이나, 딥러닝이나 앙상블 모델 기반 접근방법들[14-18]은 탐지 및 분류에 과도한 시간이 소요된다. 경량화된 모델의 경우[9, 16, 18] 탐지 및 분류 성능이 다른 선행연구들에 비해 현저하게 낮다. 이러한 선행연구의 문제점들을 해결하기 위해 본 연구에서는 SONAR 음파 데이터를 기반으로 실제 군사 작전에 활용할 수 있는 경량화된 기계학습 기반 수중 지뢰 탐지 모델을 개발하고, 모델의 하이퍼파라미터 미세 조정을 통해 탐지 성능을 개선하고자 한다.

이후 논문의 구성은 다음과 같다. 2장에서는 모델 학습 및 성능 평가에 활용한 데이터세트에 대해 살펴보고, 이어서 SONAR 데이터를 기반으로 수중 지뢰 탐지를 시도했던 선행연구를 정리한다. 3장에서는 연구 방법을 설명한 후 실험에 적용한 5가지 기계학습 모델의 하이퍼파라미터를 미세 조정하면서 진행한 초도 실험 과정을 설명한다. 4장에서는 최종적으로 생성된 기계학습 모델의 수중 지뢰 및 암석 분류 결과를 비교 분석한다. 마지막으로 5장에서 연구 결과를 요약하고 향후 연구의 방향을 제시한다.

## II. Preliminaries

### 1. Dataset

모델 학습 및 성능 평가를 위해 사용한 데이터세트는 UCI Machine Learning Repository에서 제공하는 Connectionist Bench(Sonar, Mines vs. Rocks) 데이터 세트[19]이다. SONAR 신호를 기반으로 지뢰(mine) 및 암석(rock)을 구분하기 위해 생성된 이 데이터세트는 통제된 실험 환경에서 노이즈가 최소화된 상태로 수집되었으며, 기계학습 및 패턴 인식 연구에서 다양하게 활용되고 있다.

데이터세트는 “sonar.mines”와 “sonar.rocks” 2개의 파일을 포함하고 있다. sonar.mines 파일은 다양한 각도 및 조건에서 금속 실린더로부터 반사된 111개의 SONAR 반사 신호를 포함하고 있다. sonar.rocks 파일은 유사한 조건으로 암석에서 획득한 97개의 반사 신호를 포함하고 있다.

데이터세트에 포함된 SONAR 반사 신호 샘플 수는 총 208개이며, 개별 샘플은 60개의 특성과 1개의 레이블을 가진다. 특성의 값은 0.0 ~ 1.0 범위의 실수로, 각 실수는 특정 주파수 대역 내의 에너지 강도를 의미하며 일정 시간 동안 측정된 값을 통합하여 표현하였다. 첫 번째 특성은 낮은 주파수 대역(저주파수)의 에너지 강도를 나타내고, 마지막 특성으로 갈수록 더 높은 주파수 대역(고주파수)의 에너지를 나타낸다. 레이블은 해당 샘플이 암석인 경우 “R”, 금속 실린더인 경우 “M”의 값을 가진다.

SONAR 반사 신호를 측정하는 실험은 약 1.52m(5피트) 크기의 수중 지뢰를 모사한 금속 실린더와 원통형 암석이 모래 해저에 배치된 환경에서 수행되었다. 신호 수집은 10m 떨어진 위치에서 목표물에 광대역 선형 FM Chirp 신호를 송신 후 반사되는 신호를 수집하는 방식으로 진행되었다. 그리고 물체의 특성과 구조가 반사 신호에 미치는 영향을 극대화하기 위해서 각도를 달리하여 신호를 송신하면서 반사 신호를 측정하였다. 원형 단면을 가지는 금속 실린더는 음파가 수직 방향으로 입사될 때 가장 강력한 반사 신호를 생성하기 때문에 90° 각도에서 측정하였고, 불규칙한 표면을 가지는 암석은 비대칭적인 반사 특성을 반영하기 위해 180° 각도에서 측정하였다.

## 2. Related works

X. Wang 등[4]은 Adaptive Weights Convolutional Neural Network을 통해 Convolutional Neural Network(이하 CNN)의 랜덤 필터 가중치를 Deep Belief Networks(이하 DBM)의 학습된 가중치로 대체하는 모델을 제시했다. 사전 학습된 DBM의 의미 있는 가중치를 사용하여 더 빠른 수렴과 지역 최적 탈출을 통해 모델의 안정성과 성능 향상을 달성하였다.

A. Preciado-Grijalva 등[5]은 CNN 기반 자기 지도 학습 모델을 통해 few-shot 학습으로도 라벨링 되지 않은 SONAR 이미지 데이터의 주요 특징을 추출하는 모델을 제안했다. 사전학습을 통해 이미지 분류를 위한 특징 추출기를 구성하고, 이를 Support Vector Machine(이하 SVM)에 전이하여 추출된 특징을 이용한 분류가 잘 이루어지는지 평가했다. 실험 결과, Jigsaw 알고리즘에서 최고 97.02%의 정확도를 기록했다.

Kim 등[6]은 하이라이트 모델 기반 합성 SONAR 데이터에 대해 FrFT를 적용하여 특징을 추출한 후 DBM 모델에 학습시키고 분류를 시도한 결과 91.40%의 정확도를 달성하였다. 이후 후속 연구에서[7] 합성 SONAR 데이터를 시간-주파수 영역의 2차원 데이터인 스펙트로그램으로 이미지화

해 CNN 모델을 통해 분류한 결과 표적 신호의 인식률은 99.67%, 비표적 신호의 인식률은 96.63%로 나타났다.

T. Li 등[8]은 해저 25~30인치 깊이에 금속을 매설하고 능동 SONAR를 이용하여 직접 수집한 데이터를 기반으로 학습 및 성능 평가를 실시하였다. 먼저 수집된 데이터에 대해 Fractional Fourier Transform(이하 FrFT)을 적용하여 특징을 추출하였고, K-L(Karhunen-Loeve) 변환을 사용해 특징을 압축한 후 SVM 모델로 학습한 결과 87.5%의 정확도를 달성했다.

본 연구와 동일하게 UCI Connectionist Bench (Sonar, Mines vs. Rocks) 데이터세트를 대상으로 모델 학습 및 분류를 시도했던 연구들은 다음과 같다.

H. Singh 등[9]은 Gini Index를 사용해 상위 50개의 특성을 추출한 후, 10개의 기계학습 알고리즘에 학습시켜 분류 성능을 비교하였다. 그 결과 Random Forest(이하 RF) 모델의 정확도가 83.17%로 가장 높게 나타났다.

A. Khare 등[10]은 주성분 분석(Principal Component Analysis, 이하 PCA)과 t-SNE를 사용하여 특징을 추출한 후, Logistic Regression과 RF 모델에 학습시켜 각각 72%와 91%의 정확도를 달성하였다. 또한, 딥러닝 모델인 CNN과 LSTM(Long Short-Term Memory)은 각각 80.77%와 99%의 정확도를 보였다.

S. Monika 등[11]은 데이터 표준화(standardization)를 실시하고 PCA를 통해 차원을 축소한 후 KNN(k-Nearest Neighbors)(K=3) 및 SVM(C=1.7, RBF Kernel) 모델에 학습시켜 88.09% 및 92.85%의 정확도를 달성하였다.

S. Gobade 등[12]은 6가지 기계학습 모델들의 하이퍼파라미터에 대해 미세조정을 실시한 후 정확도를 비교했다. 그 결과 SVM(C=1.7, RBF Kernel) 모델이 94.23%로 가장 정확도를 달성하였다.

M. S. Ram 등[13]은 Gradient Boosting 기반의 XGBoost를 이용해서 다른 머신러닝 모델과 정확도를 비교한 결과 87.30%를 기록하며 가장 높은 성능을 보였다.

A. Sar 등[14]은 딥러닝 모델과 기계학습 모델의 분류 성능을 비교하였다. 그 결과 RDNN 모델의 정확도가 90.47%로 가장 높게 나타났으며, SVM이나 Logistic Regression과 같은 기계학습 모델의 정확도보다 약 10% 이상 높음을 확인하였다.

K. Yurii 등[15]은 학습 과적합 방지 기법을 적용하여 분류 모델의 성능이 향상될 수 있는지를 확인하였다. 실험 결과 과적합 방지 기법을 적용하지 않은 다중 퍼셉트론(Multi-Layer Perceptron, 이하 MLP) 모델과 AdaBoost 기반 RF 모델의 정확도는 80.31%와 87.50%로 나타났다.

그러나 과적합을 방지하기 위해 Dropout 및 L2 정규화를 적용한 MLP 모델의 정확도는 88.45%로 나타났으며, 기본 MLP 모델보다 정확도가 8.14% 향상되었다.

B. M. Sherin 등[16]은 SVM 모델에 다양한 하이퍼파라미터 최적화 기법을 적용하여 분류 성능을 비교하였다. 그 결과 BAT 알고리즘을 사용해 하이퍼파라미터를 선택하고 커널 최적화를 시도한 모델이 Particle Swarm Optimization(이하 PSO)을 기반으로 최적화된 모델보다 약 4~6% 더 높은 75%의 분류 정확도를 나타냄을 확인하였다.

S. Elakkiya 등[17]은 하이퍼파라미터를 자동으로 조정하는 MCNN(Meta-cognitive Neural Network)와 고정된 파라미터를 사용하는 ELM(Extreme Learning Machine) 모델을 사용하여 분류 모델을 구성한 후 성능을 비교했다. 실험 결과, MCNN 모델(87.5%)이 ELM 모델(84%)보다 더 우수한 결과를 보였다.

V. Sireesha 등[18]은 K-fold 교차 검증(K-fold cross-validation)과 다수결 투표 방식인 배깅(bagging) 기법을 앙상블하여 기계학습 기반 모델을 구성했다. 실험 결과, 크로스 검증(K=26)과 배깅 기법을 앙상블한 RF 모델이 86.6%로 가장 높은 정확도를 기록했다. 그러나 병렬적인 다수의 의사결정트리 사용, 다수결 투표, K-Fold로 인한 계산량 증가 등으로 인해 실시간 분류가 제한되는 한계가 존재한다.

S. Sahoo 등[20]은 데이터를 전처리하는 과정에서 표준화 및 리밸런싱(rebalancing)을 적용하였으며, 선형판별분석(Linear Discriminant Analysis, 이하 LDA)과 SVM(RBF Kernel)을 사용한 모델이 각각 98% 및 94%의 높은 정확도를 기록하였다. 그러나 해당 연구는 전처리 과정과 모델 최적화 기법에 대한 구체적인 설명이 부족하여 연구 결과의 재현 가능성이 제한적이기 때문에 본 연구에서 제안하는 모델과의 직접적인 비교는 진행하지 않았다.

이상에서 살펴본 선행연구들은 하나의 차원 축소 기법만을 적용한 후 모델별 분류 성능을 비교하거나, 전처리 없이 원본 데이터를 그대로 이용하는 등 모델의 최적화를 적절하게 고려하지 않았다. 또한 모델별 성능을 비교함에 있어서는 단순히 분류 정확도에 초점을 맞춰 최종 모델을 제안하는 등 실제 군사 작전에서 필수적이라고 할 수 있는 실시간 처리성에 대한 고려가 전반적으로 부족하다.

이에 본 연구에서는 각 학습 알고리즘에 적합한 데이터 전처리 기법을 차별적으로 적용하여 모델별 최적 성능을 도출할 수 있는 데이터 전처리 전략을 모색하고, 군사 작전 수행 환경에서 요구되는 실시간 처리성과 분류 정확도를 동시에 향상시킬 수 있는 최적화 방안을 제안한다.

### III. The Proposed Scheme

#### 1. Experiment Preparation

##### 1.1 Data preprocessing

데이터 전처리를 수행하기 위해 208개의 샘플데이터를 대부분의 선행연구와 동일하게 학습 데이터 75%, 테스트 데이터 25%의 비율로 구분한 후, 데이터 표준화를 수행하였다. 이후 본 연구에서 활용한 5종의 기계학습 모델(KNN, SVM, Logistic Regression, LightGBM 및 MLP) 각각에 대해 적합한 전처리 기법을 추가로 적용하였다.

먼저 SVM 모델에 입력되는 학습 데이터는 PCA를 통해 데이터의 특성 차원을 축소하였다. SVM은 감마(gamma) 값에 따라 결정 경계의 곡률과 분류 민감도가 크게 달라질 수 있다. 따라서 데이터 분포나 차원 수가 높은 경우 모델이 과적합을 일으키거나 결정 경계가 불안정해지며 복잡도가 증가한다. 이러한 이유로 본 연구에서는 PCA를 통해 데이터에서 주요 분산을 설명하는 주성분만 추출하여 입력 데이터로 사용함으로써 노이즈와 다중공선성(multicollinearity problem)을 완화하고자 하였다. PCA는 데이터 간 분산을 최대한 유지하면서 차원을 효과적으로 축소하기 때문에, 상관관계가 높은 특성들로 인한 혼선을 최소화하여 모델이 더 선명한 결정 경계를 학습하도록 돕고 계산 효율성을 개선할 수 있다.

LightGBM 모델은 GOSS(Gradient-based One-Side Sampling)와 EFB(Exclusive Feature Bundling) 알고리즘을 통해 중요도가 낮은 특성을 제거하고 상호 배타적인 특성들을 하나의 번들로 묶어 데이터의 차원을 축소하는 기능을 내장하고 있다. 그러나 이러한 과정은 주로 손실함수의 기울기에 기반하여 자동으로 처리되기 때문에 클래스별 분산 구조를 직접적으로 고려하기에는 한계가 있다. 따라서 명확한 클래스 구분이 가능한 특성 벡터를 추출해 불필요한 노이즈 및 중복 정보를 제거하는 LDA를 적용함으로써 클래스 간 분산은 최대화하면서 클래스 내 분산은 최소화하도록 변환하였다. 이러한 전처리를 거친 데이터를 LightGBM 모델에 입력하여 내부 특성 축소 기법과 상호 보완적 효과를 기대하였다.

Logistic Regression과 KNN 모델은 데이터의 특성에 대한 본래의 분포를 잘 반영하여 추가적인 데이터 전처리 기법을 적용하지는 않았다. 선형 분류 모델인 Logistic Regression은 하이퍼파라미터만을 미세조정만 초도 실험 과정에서 데이터셋에 적용 가능한 최적의 선형 구분을 찾을 수 있기 때문에 전처리가 필요하지 않았다. 또한, KNN 모델은 거리 기반 알고리즘으로, 차원 축소가 필수적

이지 않다. 특히 본 연구에서 설정한 K=6이라는 하이퍼파라미터가 데이터의 분포와 잘 맞아떨어져 별도의 전처리 없이도 높은 정확도를 달성할 수 있었다.

MLP 모델 역시 별도의 차원 축소 기법을 적용하지는 않았다. 비선형 분류 모델인 MLP는 여러 개의 은닉층을 통해 복잡한 데이터 패턴을 학습할 수 있기 때문에 고차원 데이터에 대해서도 성능 저하 없이 분류할 수 있을 것으로 판단하였다. 그리고 초도 실험 과정에서 MLP의 하이퍼파라미터인 은닉층의 노드 수와 학습률을 적절히 조정하여 성능을 측정한 결과, 데이터 차원을 축소하지 않더라도 충분한 성능을 달성할 수 있음을 확인하였다.

1.2 Model Comparison Methodology

본 연구의 목적은 기계학습 기반 모델과 SONAR 데이터를 활용하여 군사 작전 수행 환경에 적합한 최적의 수중 지뢰 및 암석 분류 모델을 도출하는 것이다. 이를 위해 Fig. 1에서 보는 바와 같이 먼저 KNN, SVM, Logistic Regression, LightGBM 및 MLP 5종의 기계학습 모델에 대해 하이퍼파라미터 값만을 미세조정하는 초도 실험을 통해 모델별 분류 성능을 측정하고 비교하였다. 이어서 각 모델에 적합한 최적 데이터 전처리 기법을 추가로 적용한 후 2차 하이퍼파라미터 미세조정을 통해 최종 모델을 확정하고, 모델별 분류 성능을 측정하여 비교하였다.

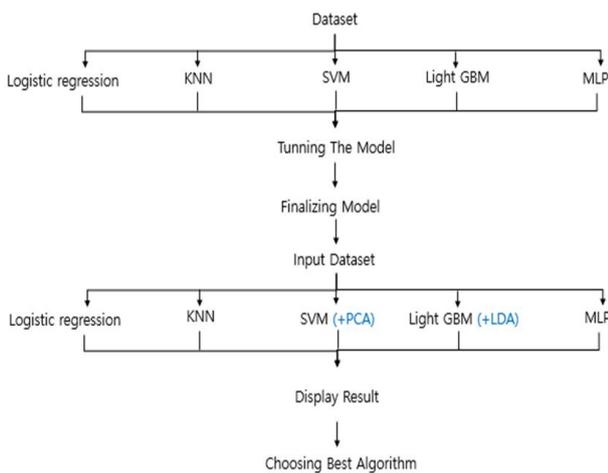


Fig. 1. Model Comparison Methodology

2. Experiment

2.1 Hyperparameter tuning

Logistic Regression, LightGBM 및 MLP 모델의 최초 학습률과 EPOCH는 각각 '0.01'과 '1000'으로 설정한 후 분류 결과를 확인하면서 미세조정을 반복 수행하였다.

KNN 모델에 대해서는 K값의 범위를 '1'부터 '31'까지

모두 탐색하며 최적의 K값을 찾도록 설정하였다. 또한, SVM 모델은 scikit-learn의 GridSearchCV를 사용하여 오차 허용도(C)는 [0.1, 1, 10], RBF 커널의 결정 경계의 곡률(gamma)은 [0.01, 0.1, 1, 10] 조합에 대해 5겹 교차 검증을 수행하고, 정확도 기준으로 가장 좋은 성능을 보인 조합을 선택하였다. 각 모델의 최초 하이퍼파라미터 값은 Table. 1에서 보는 바와 같다.

Table 1. Initial hyper-parameter setting

Model	Hyper-parameters
Logistic Regression	LR= 0.01, EPOCH= 1000
KNN	K = 6
SVM	RBF Kernel, C= 1, gamma= 0.01
LightGBM	colsample_bytree= 0.8, LR= 0.01, max_depth= -1, min_child_samples= 50, n_estimators= 100, num_leaves= 31, subsample= 0.8
MLP	LR= 0.01, EPOCH= 1000, Hidden Layers= 2, Number of Node = 100, 50

2.2 Model finalize

전처리 과정에서 표준화를 수행한 학습 데이터셋을 Logistic Regression 모델에 학습시켜 분류 성능을 측정한 결과 정확도가 82.69%로 확인되었다. 또한 학습률과 EPOCH를 변경해도 정확도에 큰 차이가 발생하지 않았다. 이러한 결과는 선형적 의사결정 경계를 학습하는 Logistic Regression 모델의 특성상 이미 학습 데이터셋에 대해 가능한 최적의 선형 구분을 찾았음을 시사한다. 즉, 데이터의 분포 특성이 모델의 선형 한계와 일치하여 더 이상의 성능 향상은 기대하기 어렵다는 판단하에 별도의 데이터 전처리나 하이퍼파라미터 미세조정을 수행하지 않았다.

학습 과정 없이 거리를 기반으로 분류를 수행하는 KNN 모델의 경우, 1.1에서 전술한 바와 같이 최초 설정한 하이퍼파라미터 값(K=6)이 학습 데이터셋의 분포와 잘 맞아 94.23%의 비교적 높은 정확도를 달성하였다. 따라서 Logistic Regression 모델과 마찬가지로 별도의 하이퍼파라미터 미세조정을 실시하지 않았으며, 차원 축소 기법도 적용하지 않았다.

SVM 모델의 초도 실험 분류 정확도는 85.71%로 나타났다. 그러나 PCA를 통해 차원을 축소한 후 학습을 실시하고 분류를 수행한 결과, 정확도가 최대 96.15%까지 큰 폭으로 향상되었다. 이러한 결과는 차원 축소 과정을 통해 특성 공간이 단순화되면서도 각 클래스 간 구분에 중요한

변동성을 유지한 채로 데이터가 모델에 입력되었기 때문에 해석할 수 있다. 결과적으로, SVM 모델에 PCA 기반 차원 축소를 결합한 접근방법은 특성이 고차원이고 샘플 수가 적은 상황에서도 노이즈와 다중공선성 문제를 해소하여 더 높은 정확도를 달성할 수 있음을 보여준다.

Fig. 2는 PCA를 수행했을 때, 주성분 개수에 따른 누적 설명 분산 비율(cumulative explained variance)을 보여 주고 있다. 29개의 주성분만으로도 전체 데이터 분산의 약 95% 이상을 설명할 수 있기 때문에 본 연구에서는 PCA를 통해 원본 데이터셋에 가진 60개의 특성을 29개의 주성분으로 변환하여 모델에 입력하였다.

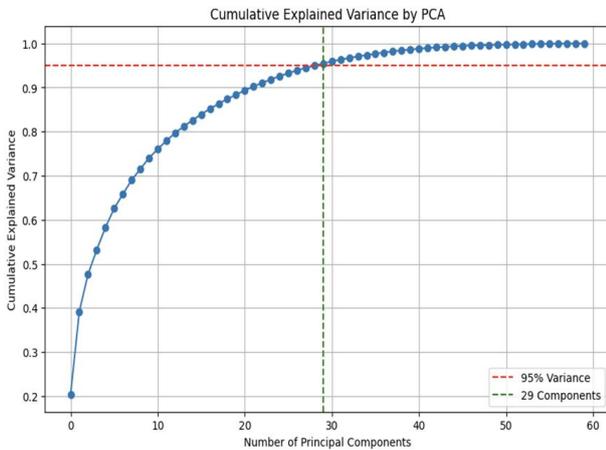


Fig. 2. Number of features derived through PCA

29개의 주성분이 SVM 모델의 분류 정확도에 기여하는 정도를 평가한 결과는 Fig. 3에서 보는 바와 같다. 기여도 평가 실험은 각 주성분을 하나씩 제거한 후 나머지 주성분들로 모델을 재학습하면서 분류 정확도의 하락폭을 측정하는 방식으로 진행하였다.

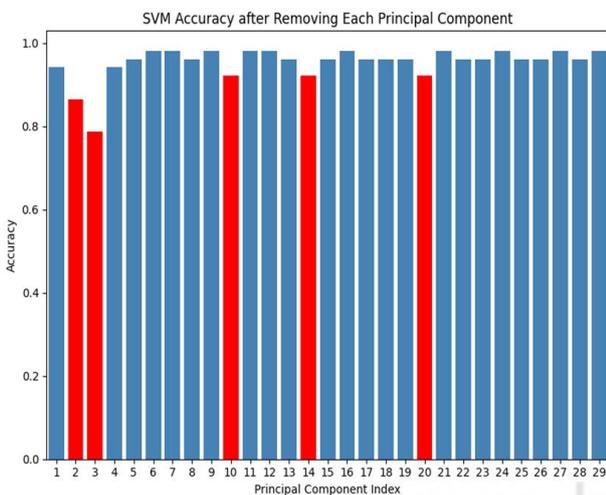


Fig. 3. Accuracy after removing each Principal Component

분석 결과, PC2, PC3, PC10, PC14 및 PC20을 제거하였을 때 정확도 하락폭이 상대적으로 증가하였다. 특히 PC3를 제거하였을 때에는 모든 주성분을 사용한 경우보다 정확도가 17.31%p 감소하였다. 이러한 결과는 해당 주성분이 클래스 간 분산을 효과적으로 반영하고 있다는 점을 시사한다.

LightGBM 모델은 분류 정확도가 71.15%로 다른 모델 대비 낮게 나타났다. 이어서 통계적 차원 축소 기법인 LDA를 적용하여 추출된 1개의 특성 벡터를 학습시키고 분류 성능을 다시 측정한 결과 정확도가 90.38%로 크게 향상되기는 하였으나 다른 모델에 비해 여전히 낮게 나타났다. 이에 LightGBM 모델에 대해서는 추가적인 하이퍼파라미터 미세조정을 수행하지 않았다.

MLP 모델의 최초 분류 정확도는 90.38%로 나타났고, 데이터의 수에 비해 학습률과 은닉층 노드의 개수가 과다하여 EPOCH=22 이상에서 Loss 업데이트가 더 이상 진행되지 않는 문제가 확인되었다. 이에 최종 모델은 학습률을 0.001, 은닉층 노드의 수를 100, 50개가 아닌 64, 32개로 재조정하였다.

초도 실험을 통해 최종 확정된 각 학습 모델의 하이퍼파라미터 값은 Table 2에서 보는 바와 같다.

Table 2. Hyper-parameter setting after model finalize

Model	Hyper parameters
Support Vector Machine (+ PCA)	Number of Features after PCA= 29, RBF Kernel, C= 10, gamma= 0.01
LightGBM (+ LDA)	Number of Features after LDA= 1, colsample_bytree= 0.8, LR= 0.01, max_depth= -1, min_child_samples= 50, n_estimators= 100, num_leaves= 31, subsample= 0.8
Multi Layer Perceptron	LR= 0.001, EPOCH= 1000, Hidden Layers= 2, Number of Nodes = 64, 32

#### IV. Experimental Results and Analysis

하이퍼파라미터 미세조정 및 차원 축소 기법 적용으로 최적화된 학습 모델을 사용해 분류 성능을 측정된 결과는 Table 3에서 보는 바와 같다. 실험은 구글 Colab 환경의 CPU 인스턴스 (python 3.10, Intel(R) Xeon(R) CPU @ 2.20GHz, 16GB RAM)에서 수행하였다.

Table 3. Experimental Model Comparison

Model	Index	Result	Deviation
Logistic Regression	Training time(s)	1.0061	Base
	Inference time(s)	0.0015	
	Accuracy	82.69	
	Precision	88.89	
	Recall	80.00	
	F1 score	84.21	
KNN	Training time(s)	0.0014	(-) 1.0047
	Inference time(s)	0.0015	0.0
	Accuracy	94.23	(+) 11.54
	Precision	94.26	(+) 5.37
	Recall	94.23	(+) 14.23
	F1 score	94.21	(+) 10.0
SVM with PCA	Training time(s)	2.3521	(+) 1.346
	Inference time(s)	0.0038	(+) 0.0023
	Accuracy	96.15	(+) 13.46
	Precision	96.47	(+) 7.58
	Recall	96.15	(+) 16.15
	F1 score	96.17	(+) 11.96
LightGBM with LDA	Training time(s)	0.1082	(-) 0.8979
	Inference time(s)	0.0074	(+) 0.0059
	Accuracy	90.38	(+) 7.69
	Precision	92.59	(+) 3.7
	Recall	89.29	(+) 9.29
	F1 score	90.91	(+) 6.7
MLP	Training time(s)	1.9299	(+) 0.9238
	Inference time(s)	0.0005	(-) 0.001
	Accuracy	92.31	(+) 9.62
	Precision	96.43	(+) 7.51
	Recall	90.00	(+) 10.0
	F1 score	93.10	(+) 8.89

Logistic Regression 모델을 제외한 4개 모델은 모두 분류 정확도가 90%를 넘었다. 특히 PCA를 통해 특성의 차원을 29개로 축소 후 학습을 진행한 SVM 모델의 분류 정확도는 96.15%로 나타났으며, 다른 모델과 비교해 최대 13.46%P 더 높았다. SVM 모델을 제외하고 가장 높은 성능을 기록한 KNN 모델과 비교하면, 정밀도(Precision)는 2.24%P, 재현율(Recall)은 1.92%P, F1 score는 1.96%P 향상되었다. 학습 및 추론 시간 측면에서는 SVM 모델의 학습 시간이 2.35초로 가장 장시간이 소요되기는 했지만, 추론 시간은 0.004초로 매우 짧아 실시간성이 요구되는 군사적 환경에서도 충분히 적용 가능할 것으로 판단된다.

주목할 만한 또 다른 중요한 결과는 SVM 모델만큼이나 KNN(K=6) 모델이 SONAR 신호 데이터 기반의 수중 지뢰 탐지 연구에 유용하게 적용될 수 있다는 사실이다. 데이터가 특정한 분포를 가정하지 않는 비모수적(non-parametric) 특성을 가질 경우 적합한 KNN 모델은 별도 학습 과정을 거치지 않고도 거리를 기반으로 즉시 분류를 수행하기 때문에 모델 학습 비용이 사실상 없다는 장점을 가진다. 따라서 모델의 사전학습이 제한되는 경우 적절한 선택지가 될 수도 있다. 또한, 본 실험에서 최적의 K값을

찾아내는 과정을 모두 포함하여 학습 시간을 산출하였음에도, 학습 및 추론 과정에 소요되는 시간이 약 0.003초로 가장 짧아 실시간 처리 성능이 매우 우수하다고 판단할 수 있다. 그러나 KNN 알고리즘은 추론 단계에서 모든 학습 데이터를 참조해야 하므로 데이터의 규모가 커지면 추론 시간이 크게 증가하며, 데이터 특성이 고차원인 경우에는 심각한 성능 저하가 발생할 수도 있다.

최고의 분류 성능을 달성한 SVM 및 PCA 결합 모델의 수중 지뢰 및 암석 분류 혼동행렬은 Fig. 4에서 보는 바와 같다. 52개의 테스트 데이터 샘플 중 50개가 수중 지뢰(M) 및 암석(R) 클래스로 정확하게 분류되었으며, 특히 수중 지뢰에 대해서는 오분류가 전혀 발생하지 않았다. 이러한 결과는 본 연구를 통해 제시된 접근방법이 기존 연구 대비 전반적인 분류 성능을 향상시킬 수 있을 뿐만 아니라 수중 지뢰 탐지 분야에서 더욱 특화된 모델로 발전할 가능성이 있음을 시사한다.

		Actual	
		Mine(M)	Rock(R)
Predicted	Mine(M)	28	2
	Rock(R)	0	22

Fig. 4. Confusion Matrix (SVM with PCA[PC=29])

실제 클래스는 암석이었으나 수중 지뢰로 오분류된 두 샘플(샘플 16 및 41)에 대해서는 오분류 발생 원인을 분석하였다. 우선 PCA 이후 샘플이 결정 경계인 초평면으로부터 얼마나 떨어져 있는지를 수치화한 값인 SVM Decision Score를 확인한 결과, 샘플 16은 0.0122, 샘플 41은 0.8216의 거리를 보였다. 이를 통해 모델의 결정 경계에서, 샘플 16은 결정 경계 인근, 샘플 41은 암석 군집 내에 위치함을 확인할 수 있었다.

오분류의 원인을 보다 세부적으로 확인하기 위해 PCA 적용 전 특성의 분포를 확인한 결과, 샘플 16은 다른 암석 클래스와 같이 중반 이후 매우 강한 반향 특성을 지니고 있었다. 이는 SVM의 결정 경계 설정에서 차원 축소 이후 PCA 공간의 비슷한 위치에 있는 수중 지뢰 샘플과 오인한 것으로 볼 수 있다. 반면, 샘플 41은 수중 지뢰처럼 전체적으로 완만하고 분산된 반향을 보여 차원 축소와 관계없이 암석과 유사한 신호 패턴으로 오인한 것으로 해석된다.

본 연구와 같이 UCI Connectionist Bench(Sonar, Mines vs. Rocks) 데이터세트를 대상으로 수중 지뢰 및 암석 분류를 시도했던 선행연구와의 성능 비교 결과는 Tabel 4에서 확인할 수 있다.

Table 4. Comparison with previous studies

Approach	Accuracy	Precision	Recall	F1 score
[9] RF with Gini Index	83.17	83.0	83.0	83.0
[10] LSTM with PCA, t-SNE	99.0	99.0	99.0	99.0
[11] SVM with PCA (C=1.7, RBF)	92.85	96.15	92.59	94.33
[12] SVM (C=1.7, RBF)	94.23	94.0	94.0	94.0
[14] RDNN	90.47	-	-	87.5
[15] MLP with Dropout & L2	88.45	-	-	-
[16] SVM with BAT	75.0	-	12.5	-
[17] MCNN	87.5	-	-	-
[18] RF with CV & Bagging	86.6	-	-	-
Our Approach SVM with PCA	96.15	96.47	96.15	96.17

선행연구에서 가장 좋은 분류 성능을 보인 모델은 PCA 및 t-SNE를 통해 추출된 특성 벡터를 딥러닝 모델인 LSTM에 학습시킨 모델[10]로서, 99.0%라는 상당히 높은 정확도를 달성했다. 그러나 시계열 분석에 적합한 LSTM 모델은 학습에 사용된 SONAR 데이터가 상대적으로 소규모이기 때문에 과적합 위험을 배제할 수 없고, 기계학습 기반 모델들보다 더 많은 계산 비용과 시간이 필요하다.

기계학습 모델을 기반으로 한 접근방법은 딥러닝 기반 접근방법에 비해 상대적으로 분류 정확도가 낮은 것으로 확인되었다. 가장 높은 분류 성능을 달성한 모델은 RBF 커널을 사용한 SVM 모델[12]이었고, 94.23%의 정확도를 달성하였다.

본 연구에서 하이퍼파라미터를 미세조정하고 차원 축소 기법을 추가로 적용해 분류 성능을 평가한 5개의 기계학습 모델 중 최고 성능을 보인 모델은 SVM 및 PCA(PC=29) 결합 모델로서, 96.15%의 정확도를 달성하였다. 이러한 결과는 동일한 데이터셋에 대해 최고 성능을 달성했던 딥러닝 기반 접근방법에는 미치지 못하였지만, 기계학습 기반 접근방법들과 비교해서는 가장 우수한 결과이다.

## V. Conclusions

본 연구에서는 SONAR 신호 데이터를 활용하여 수중 지뢰 및 암석을 분류하기 위해 5종의 기계학습 모델(KNN, SVM, Logistic Regression, LightGBM 및 MLP)을 비교 분석하였다.

그 결과, PCA를 통해 특성의 차원을 29개로 축소된 뒤 SVM으로 학습한 모델이 최고 성능(정확도 96.15%, 정밀도 96.47%, 재현율 96.15%, F1 Score 96.17%)을 달성하였다. 딥러닝 기반 접근방법에 비해서는 다소 부족한 성능이기는 하지만, 기계학습 기반의 접근방법보다는 월등하게 향상된 성능을 보임을 확인하였다.

연구 결과에서 특히 주목할 만한 점은 PCA와 SVM의 결합이 가져온 성능 향상 효과라고 할 수 있다. 차원 축소 기법을 통해 특성 벡터 추출, 노이즈 감소, 과적합 방지, 계산 효율성 향상 등 여러 이점을 얻을 수 있었으며, 이를 통해 기존 SVM 모델이나 다른 모델들보다 우수한 분류 성능을 달성할 수 있었다. 또한, 본 연구에서 사용한 데이터셋이 통제된 환경에서 획득되었다는 점을 고려하여 SVM 모델의 C값을 충분히 크게 설정하면 마진이 약하게 적용됨으로써 학습 데이터에 좀 더 정교하게 맞춰진 모델 구성이 가능하다는 점도 확인할 수 있었다.

SVM 및 PCA 결합 모델에 대한 혼동행렬에서 확인할 수 있는 바와 같이 수중 지뢰에 대한 오분류가 전혀 발생하지 않았다는 점도 본 연구의 중요한 성과로, 제안하는 모델이 실제 수중 물체 탐지 분야에 적용될 때 큰 장점이 될 수 있다. 군사적 신호정보 관점에서 본 연구의 결과는 국가 해양 경계를 더욱 견고히 하고, 수중을 통해 진행될 적의 위협을 조기에 파악·대응할 수 있는 중요한 기술적 토대를 제공할 것이다. 특히, 금속 물체를 정확히 식별할 수 있다는 장점은 잠수함 및 수중 드론 등의 위협 요소를 정확하게 탐지할 수 있다는 가능성을 의미하며, 더 나아가서는 신호정보 기반의 실시간 위협 탐지 및 의사결정 체계 강화에도 기여하게 될 것이다.

그러나 본 연구는 제한된 양의 테스트 데이터로만 분류 성능을 검증했다는 한계가 존재한다. 제안하는 접근방법의 적용 가능성 확인을 위해서는 실제 해양 환경에서 수집된 다양한 데이터를 활용한 추가 검증이 필요하다. 군사 작전 환경에서의 활용을 고려하여 계산 속도가 비교적 빠르고 경량화된 기계학습 모델을 채택했기 때문에, 딥러닝 기반 접근방법에 비해 정확도가 떨어지는 점도 개선이 필요한 부분이다. 따라서 향후 연구에서는 기계학습 모델의 빠른 연산 속도를 유지하면서도 딥러닝 모델 수준 이상의 정확도를 달성하기 위해, 다양한 전처리 기법과 앙상블 방법을 보다 정교하게 적용하는 방안도 검토할 예정이다. 그리고 수중 지뢰뿐만 아니라 수중에 존재할 수 있는 다양한 금속 물체들을 포함하는 데이터셋을 확보하여 모델의 다중 분류 성능을 강화하는 방향으로 연구를 확장할 계획이다.

## REFERENCES

- [1] J. B. Siddhartha, T. Jaya, and V. Rajendran, "RDNN for classification and prediction of Rock/Mine in underwater acoustics", *Materials Today: Proceedings*, Vol. 80(3), pp. 3221-3228, April 2023. DOI: 10.1016/j.matpr.2021.07.216.
- [2] S. Hozyń, "A Review of Underwater Mine Detection and Classification in Sonar Imagery", *Electronics* 10(23), pp. 2943-2964, Nov 2021. DOI: 10.3390/electronics10232943.
- [3] S. Feng, S. Ma, X. Zhu, and M. Yan, "Artificial Intelligence -Based Underwater Acoustic Target Recognition: A Survey", *Remote Sensing*, Vol. 16(17), pp. 3333-3365, Sep 2024, DOI: 10.3390/rs16173333.
- [4] Wang, Xingmei , Jiao, Jia , Yin, Jingwei , Zhao, Wensheng , Han, Xiao and Sun, Boxuan. "Underwater sonar image classification using adaptive weights convolutional neural network", *Applied Acoustics*. 146. pp. 145-154. Mar 2019. DOI: 10.1016/j.apacoust.2018.11.003.
- [5] A. Preciado-Grijalva, B. Wehbe, M. B. Firvida and M. Valdenegro-Toro, "Self-supervised Learning for Sonar Image Classification," 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp. 1498-1507, New Orleans, LA, USA, Jun 2022. DOI: 10.1109/CVPRW56347.2022.00156.
- [6] D. W. Kim, K. S. Bae and J. W. Seok, "Multiaspect-based Active Sonar Target Classification Using Deep Belief Network", *JKIICE*, Vol. 22, No. 3 pp. 418-424, Mar 2018. DOI: 10.6109/jkiice.2018.22.3.418.
- [7] D. W. Kim, K. S. Bae and J. W. Seok, "Active Sonar Target/Non-target Classification using Convolutional Neural Networks", *KMMS*, Vol. 21, No. 9, pp. 1062-1067, Sep 2018. DOI: 10.9717/kmms.2018.21.9.1062
- [8] T. Li, X. Li and Z. Xia, "Classification of underwater mines by means of the FRFT and SVM", *The 2010 IEEE International Conference on Information and Automation*, pp. 1824-1829, Harbin, China, Jun 2010, DOI: 10.1109/ICINFA.2010.5512223.
- [9] H. Singh and N. Hooda, "Prediction of Underwater Surface Target Through SONAR: A Case Study of Machine Learning", *Microservices in Big Data Analytics*. Springer, Singapore, pp. 111-117, Nov 2020. DOI: 10.1007/978-981-15-0128-9\_10
- [10] A. Khare and K. Mani, "Prediction of Rock and Mineral from Sound Navigation and Ranging Waves using Artificial Intelligence Techniques", 2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS), pp. 140-147, Trichy, India, Nov 2022. DOI: 10.1109/ICAISS55157.2022.10011104.
- [11] S. Monika, M. S. Shakthi and M. Merin. "Prediction of Underwater Sonar Targets", *International Journal of Advanced Research in Computer and Communication Engineering*, Vol. 11, No. 7, Jul 2022. DOI: 10.17148/IJARCCCE.2022.11793.
- [12] S. Gobade, P. Deshpande, M. Z. Bhaladar, A. Ghorpade and J. Bagade, "Comparative Study of Classification Algorithms on Sonar Rock and Mine Dataset", 2023 7th International Conference On Computing, Communication, Control And Automation (ICCUBEA), pp. 1-5, Pune, India, Aug 2023. DOI: 10.1109/ICCUBEA58933.2023.10392262.
- [13] M. S. Ram, P. S. Navyatha, R. L. A. Ashitha and S. A. J. Kumar, "Machine Learning based Underwater Mine Detection," 2023 7th International Conference on Intelligent Computing and Control Systems (ICICCS), pp. 47-50, Madurai, India, 2023. DOI: 10.1109/ICICCS56967.2023.10142384.
- [14] A. Sar, T. Choudhury, A. Goel. K. Kotecha, B. Pant, and B. K. Dewanganet, "Rock vs Mine Prediction and Detection for Aquatic Systems: A Comparative Analysis of Different Machine Learning and Deep Learning Algorithms", 2024 OPJU International Technology Conference (OTCON) on Smart Computing for Innovation and Advancement in Industry 4.0, pp. 1-7, Raigarh, India, Jun 2024. DOI: 10.1109/OTCON60325.2024.10688229.
- [15] K. Yurii and M. Dmytryshyn, "Utilization of Machine Learning in Recognition of Rocks and Mock-mines by Sonar Chirp Signals", 8th International Conference on Computational Linguistics and Intelligent Systems(COLINS), pp.209-218, April 2024.
- [16] B. M. Sherin and M. H. Supriya, "Selection and parameter optimization of SVM kernel function for underwater target classification", 2015 IEEE Underwater Technology (UT), pp. 1-5, Chennai, India, Feb 2015. DOI: 10.1109/UT.2015.7108260.
- [17] S. Elakkiya, J. Francis, and J. R. Parvin, "Classification of SONAR Targets Using Advanced Neural Classifiers", *International Journal of Pure and Applied Mathematics*, Vol. 114, No. 12, pp. 627-637, 2017.
- [18] V. Siresha, M. Mohammed, K. R. Prasad and K. Jeevitha, "Mine & Rock Prediction by Ensemble Machine Learning Algorithms," 2023 International Conference on Sustainable Computing and Smart Systems (ICSCSS), pp. 341-349, Coimbatore, India, Jun 2023. DOI: 10.1109/ICSCSS57650.2023.10169651.
- [19] T. Sejnowski and R. Gorman. "Connectionist Bench (Sonar, Mines vs. Rocks)," *UCI Machine Learning Repository*, 1988. DOI: 10.24432/C5T01Q.
- [20] S. Sahoo, R. K. Mohanta, P. P. Pani, S. K. Mohapatra and S. Chakravarty, "A Multi-Faceted Approach for Underwater Sonar Rock vs Mine Classification Using Machine Techniques", 2024 1st International Conference on Cognitive, Green and Ubiquitous Computing (IC-CGU), pp. 1-5, Bhubaneswar, India, May 2024. DOI: 10.1109/IC-CGU58078.2024.10530801

## Authors



Won-Jun Han received B.S. degrees in Economics from Korea Military Academy, and received B.S. degrees in Computer Science from National Institute for Lifelong Education. He is currently a graduate student

in the Department of Cyber Security and Computer Science, Korea National Defense University. His research interests include Artificial Intelligence, Intrusion Detection System, and the security of Artificial Intelligence.



Soo-Jin Lee received B.S., M.S. and Ph.D. degrees in Computer Science from Korea Military Academy, Yonsei University and Korea Advanced Institute of Science and Technology(KAIST) in 1992, 1996 and 2006.

He is currently a professor of the Department of Cyber Security and Computer Science from 2006. His research interests include National Cybersecurity Policy, Intrusion Detection System, Mobile Network Security, Machine Learning, Encryption theory and applications.



Gwang-Ho Kim received the B.S. degrees in Foreign Languages from the Korea Naval Academy. He is currently a graduate student in the Department of Cyber and Computer Science, Korea National Defense University.

His research interests include Machine learning, the security of Artificial Intelligence and Intrusion Detection System.



Ki-Pyong Park received the B.S. degrees in Electronic Engineering from the Korea Military Academy. He is currently a graduate student in the Department of Cyber and Computer Science, Korea National Defense

University. His research interests include Artificial Intelligence, Machine learning and Manned-Unmanned Teaming.