



Received: 2024/02/24
Revised: 2024/03/10
Accepted: 2024/03/26
Published: 2024/03/31

***Corresponding Author:**

Dae-Jin Jung

Department of Artificial Intelligence, Republic of Korea Naval Academy, Republic of Korea
1 Jungwon-ro, Jinhae-gu, Changwon-si, Gyeongsangnam-do, 51704, Republic of Korea
Tel: +82-55-907-5244
E-mail: djjung@navy.ac.kr

엣지 컴퓨팅 환경을 위한 토널 주파수 탐지 기법

Tonal Frequency Detection Method for an Edge-computing Environment

정대진*

해군사관학교 인공지능학과 조교수

Dae-Jin Jung*

Assistant professor, Dept. of Artificial Intelligence, Republic of Korea Naval Academy

Abstract

해군 무인운용 체계에서 활용 가능한 저전력 고성능의 소나탐지 기술을 위하여, 본 연구에서는 엣지 컴퓨팅 환경에서 동작 가능한 딥러닝 기반의 로파그램 토널 탐지 기술을 제안한다. 일반적인 딥러닝 운용환경인 GPU를 활용하지 않는 엣지 컴퓨팅 환경에서도 효율적으로 토널 신호 탐지를 위한 설계 기법을 제시하고 상용의 엣지 컴퓨팅 환경에서 제안 기술의 효율성과 우수성을 확인하였다.

In this study, a deep learning-based tonal frequency detection technology is proposed to operate in an edge computing environment, enabling low-power, high-performance sonar detection capabilities for naval unmanned systems. Design techniques for efficient tunnel signal detection are presented, even in edge computing environments without the typical deep learning hardware support, such as GPUs. Additionally, the effectiveness and superiority of the proposed technology are validated in commercial edge computing environments.

Keywords

토널 주파수(Tonal Frequency), 수동 소나(Passive SONAR), 엣지 컴퓨팅 환경(Edge-computing Environment), 딥 러닝(Deep Learning)

1. 서론

수중 환경에서는 수상에 비해 시야 또는 전파를 통하여 수중 물체를 탐지/식별하는 데 어려움을 겪는다. 이것은 빛과 전파가 수중에서는 공기중과 달리 전달 손실이 매우 커지기 때문이다. 이와는 반대로 음향은 수중에서 전달 손실이 매우 적다. 이로 인하여 음향은 빛과 전파에 비해 수중에서 훨씬 넓은 지역에 전파될 수 있으며, 이러한 성질을 활용한 소나(SONAR: sound navigation and ranging) 기술로 수중 물체를 탐지 및 식별할 수 있게 되었다.

해군에서 소나 시스템은 해양작전 및 항해 등 다양한 분야에서 극도로 중요한 역할을 담당하고 있다. 특히 수중 탐지 분야에서는 그 중요성이 더욱 부각된다. 소나 시스템은 수중 물체의 존재와 위치까지 탐지 및 추적하는 데 활용될 수 있으며, 이는 해군의 전략적 우위 유지를 위한 핵심적 역할 수행에 도움이 된다. 또한 소나 시스템은 해양 환경에서 수중 장애물 및 지형을 탐지하여 안전한 항해를 지원하는 데에도 사용된다.

소나는 그 사용 원리에 따라서 크게 능동 소나(active SONAR)와 수동 소나(passive SONAR)로 구분된다. 능동 소나는 특정 펄스 음향을 생성하여 방사하고, 반사되어 되돌아온 반향 신호를 이용하여 수중 및 수상 물체의 존재 유무, 방향 및 특성을 파악할 수 있다. 수동 소나는 오로지 주변 환경 및 방사된 소음을 청취하고, 녹음된 음향을 통하여 주변 소음을 발생시키는 물체의 존재 유무, 방향 및 특성을 파악할 수 있다. 일반적으로 반향신호를 활용하는 능동 소나에 비하여 수동 소나의 탐지 거리가 훨씬 넓으며, 능동 소나 운용 중

발생하는 음향으로 인한 위치 노출 위험을 최소화하기 위하여 수동소나의 활용빈도가 상대적으로 더 높아지게 된다.

수중 및 수상에서 함정이 기동할 때, 함정 내부 구동기관들의 움직임으로 발생하는 소음이 물을 매질로 하여 전파되며, 각 소음은 구동 기관의 특성에 따라 서로 다른 음향적 특성을 갖는다. 함정이 구동하고 있지 않을 때에도 함정 내의 보조기관들(에어컨, 전원장치 등)의 동작으로 인하여 소음이 발생, 전파된다. 수동 소나 분석 기법은 이러한 소음들을 분석하게 되는데, 수동 소나 시스템은 일반적으로 수중음향 센서를 배열로 나열하여 더 높은 신호대잡음비(SNR)를 얻는 방식으로 분석 대상의 음향신호를 획득한다. 이후, 신호처리 과정을 거쳐 획득된 신호에서 배경소음을 최소화하고 탐지 대상의 신호를 추출하게 된다. 일반적으로 이 과정에서 음향신호를 영상화된 자료로 변환하여 분석을 거치게 되며, 주로 로파(LOFAR: low frequency analysis and recording) 또는 데몬(DEMON: detection envelope modulation on noise) 그래프의 형태로 변환하여 분석이 수행된다. 변환된 이미지는 타고난 청력의 소유자 이외의 사람도 충분히 전문가가 되어 음향신호를 분석할 수 있도록 한다. 또한 시각적으로 변환된 음향신호는 분석 결과를 효과적으로 파악할 수 있도록 하며, 최신의 비전 기술을 적용하여 분석 가능하다.

변환된 소나의 음향신호는 토널신호와 배경소음 등으로 분류될 수 있으며, 토널신호로 분류된 신호들은 추가적인 처리 및 특정 DB와의 비교 등의 과정을 통하여 함정의 존재 유무, 소음원의 종류, 함정의 클래스 및 특정 함정의 식별에도 활용될 수 있다.

소나 음향신호 기반의 물체 식별 연구는 과거로부터 이어져 왔으며, 특히 인공지능을 활용한 소나 음향신호 기반 분석 기법은 1980년대를 기점으로 꾸준히 발표되었다[1-4]. 가장 처음 제안된 기법은 능동 소나 신호로부터 금속과 비금속의 물체를 구분하는 기법이며, 이후 발전을 거듭하여 능동 소나를 활용한 합성 개구소나(SAS) 영상에 CNN 기반의 물체인식 기법을 적용하는 연구까지도 제안되었다[2]. 일반적으로 능동 소나 기반의 연구가 주로 이뤄져 왔으나, 수동 소나 기반 탐지의 중요성에도 불구하고 상대적으로 관련 기법은 많은 연구가 이뤄지지 않았다. 하지만 최근 들어 해군사관학교에서는 CQT 변환을 통한 그래프 형태의

이미지를 기반으로 원샷 학습기법을 활용한 개별 함정 분류 기법을 제안하였으며[3], 국방과학연구소의 연구팀은 본 논문에서 다루는 수동 소나 기반의 로파 그래프에서의 토널신호 탐지를 위한 딥러닝 기반의 기법을 제안하였다[4].

앞서 서술한 수동소나 기반 탐지/분석 관련 기법들은 최신의 인공지능 기법을 활용하기 위하여 워크스테이션 이상의 컴퓨팅 장비와 최신의 GPU를 활용한다. 이러한 기술들은 현재까지 유지 및 활용되고 있는 유인체계에서는 활용이 가능하지만, 최근 각광받고 있는 무인체계 및 유·무인 복합체계에서는 활용에 다양한 제약을 받는다. 이러한 제약의 가장 큰 이유는 바로 소형화와 저전력화이다. 무인체계에 포함되는 장비는 소형화를 통한 체계의 활용성이 중요하게 여겨지며, 배터리를 활용하여 단독으로 활용되는 경우가 많기 때문에 저전력의 요구사항은 필수적이다. 따라서 소형화된 저전력의 무인화 체계를 위해서는 NPU, TPU 등 소형/저전력 장비에서도 활용될 수 있는 기술 개발 및 개발 기술의 검증이 필요하며, 최근 관련 기술의 발전이 이어지고 있다[5].

해군 무인운용 체계에서 활용 가능한 저전력 고성능의 소나탐지 기술을 위하여, 본 연구에서는 엣지 컴퓨팅 환경에서 동작 가능한 딥러닝 기반의 로파그래프 토널 탐지 기술을 제안한다. 기존 발표된 관련 연구에서 나타나는 시간효율성 저하를 보완하기 위한 설계 내용을 제시하고, 실제 엣지 컴퓨팅 환경에서 고성능의 정확도와 실시간 수행 여부에 대한 실험성능을 보여 제안 기법의 우수성을 확인한다.

2. 제안 기법

본 장에서는 딥러닝 기반으로 로파그래프의 토널신호를 탐지하는 기법을 제안한다. 기존 국방과학연구소 연구팀에서 제안한 기법[4]과의 가장 큰 차이점은 엣지 컴퓨팅 환경에서의 효율성 향상과 관련된 부분이다.

알고리즘의 기본적 수행 차이를 Fig. 1에 나타냈다. 기존의 알고리즘은 로파그래프에서 토널신호 탐지를 위한 패치를 추출하고 해당 패치의 중앙 부분에 해당하는 픽셀에 토널신호가 존재하는지 여부를 판단하는 딥러닝 모델을 활용한다. 이 알고리즘은 주어진 로파그래프의 크기가 $m \times n$ 이라고 가정하였을 때, 특정 시간

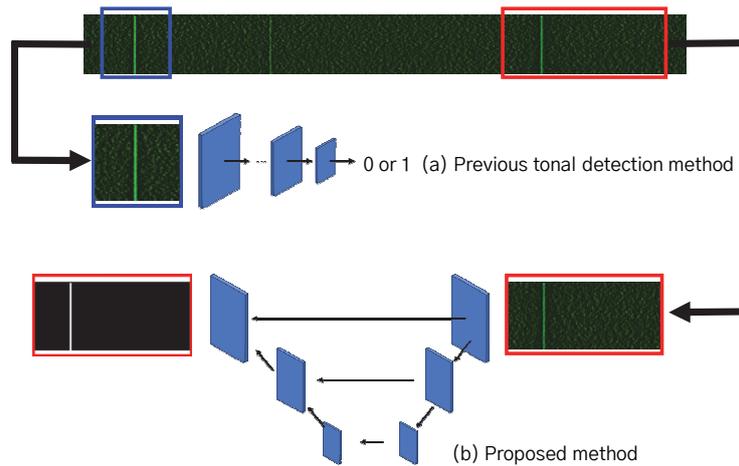


Fig. 1. Comparison between previous and proposed method

에 대하여 전체 n 개의 주파수 픽셀 영역을 탐지하기 위해 n 회의 알고리즘 수행 시간이 필요하다. 이것을 보완하기 위하여 알고리즘의 입력을 패치를 배치로 구성하고 배치의 입력에 대해 병렬처리를 수행하여 속도를 향상시킬 수 있다. 하지만 여전히 m 만큼의 시간축 영역을 고려하였을 때, 로파그램 전체 영역에 대해 알고리즘을 수행하기 위해서는 mn 개의 패치 데이터가 필요하고, 주어진 알고리즘의 시간복잡도는 $O(mn)$ 이 되며, 실시간성 보장을 위하여 이를 실행하는 하드웨어의 병렬처리 능력에 의존할 수밖에 없다. 이러한 단점은 옛지 환경에서 주로 활용되는 NPU 및 TPU에서는 매우 치명적이다. 일반적인 NPU 및 TPU에서 처리 가능한 최대 배치의 수 B 는 1이기 때문이다. 따라서 GPU의 배치 처리능력에 의해 효율성이 결정되는 기존 알고리즘은 옛지 컴퓨팅 환경에 적합하지 않다.

본 연구에서 제안하는 기법은 크게 두 가지 방법으로 옛지 컴퓨팅 환경에서의 속도 향상을 유도한다.

- 패치 기반 출력결과 추론
- 정수 양자화를 통한 속도 향상

제안 기법은 기본적으로 기존 방법과 동일한 $O(mn)$ 의 수행시간 복잡도를 가진다. 하지만 기존의 방법은 주어진 로파그램에 대한 추론을 위하여 무조건 nm 개의 $r \times c$ 크기 패치 데이터를 처리해야 하는 것에 반하여, 제안하는 기법은 최대 $\lceil m/r \rceil \lceil c/n \rceil$ 횟수만큼만 알고리즘을 수행하면 된다. 이것은 제안하는 알고리즘이 $r \times c$ 크기 패치 데이터를 입력으로 받아 동

일 크기의 추론 데이터를 제공하기 때문이다. 인공지능 모델의 수행 횟수만으로 기존 제안된 알고리즘과 제안된 알고리즘의 수행 속도를 비교하는 것이 가능한 것은 각 제안된 인공지능 모델은 모두 병렬처리를 통해 연산을 수행하여 각 모델의 처리속도 차이는 미미한 것으로 가정하기 때문이다.

옛지 컴퓨팅 환경에서의 속도 향상을 위한 두 번째 노력은 정수 양자화이다. 최근의 인공지능 모델 경량화 및 속도 향상을 위한 기술들은 가지치기, 양자화, 지식증류 등의 방법을 포함하여 정확도에서 발생하는 손해를 최소화하며 실행속도 향상의 이점을 얻는다. 하지만 가지치기 기법의 경우 다양한 TPU 및 NPU에서 항상 지원되는 것은 아니며, 지식증류 기법은 고용량의 인공지능 모델에서 파라미터 수를 줄이기 위한 방법으로, 상대적으로 적은 수의 파라미터 수로 구성할 수 있는 토널 주파수 탐지를 위한 인공지능 모델에는 적용하기 적합하지 않다. 또한 거의 모든 NPU 및 TPU에서 메모리 용량의 한계 및 원가 절감의 이유로 정수 양자화된 모델의 사용이 권장되기 때문에 옛지 컴퓨팅 환경에서의 속도 향상을 달성할 수 있다.

본 논문에서는 로파그램에서의 토널 주파수 탐지에 가장 적합한 패치출력을 위한 인공지능 모델로 세그멘테이션 기술에서 기술적 발전을 이끈 UNet을 선정하여 활용하였다. UNet의 선정은 해당 모델의 초기 제안 목적인 세포 세그멘테이션 환경과 로파그램에서의 토널 주파수 탐지 환경 간에 유사성이 높으며, NPU 및 TPU에서 활용될 수 있는 인공지능 모델 레이어 및 텐서 연산의 종류가 한정적이고 최신의 기법들을 포함하지 못하는 점 등이 고려되었다.

3. 실험 결과

3.1 실험 데이터

본 논문에서 제안하는 기법의 성능을 테스트하기 위하여 제주도에서 측정된 실험 데이터를 활용하였다. 단일 하이드로폰을 활용하여 제주도의 항구 근처에서 입·출항 중인 선박의 소음 측정을 수행하였으며, 측정 원음의 샘플링 레이트는 32,768 Hz, 분량은 총 169분이다.

측정된 원음은 로파그램 생성을 위하여 주파수 해상도를 0.5 Hz로 설정하였으며, 로파그램의 생성 시간과 STI(short-time integration)는 각각 1초와 2초로 설정하였다. 또한 생성된 로파그램에서의 저역대 토널 신호를 보존하기 위하여 SnPM(split-window n-pass mean) 규준화 기법을 활용하였으며[6], 그 중에서도 3-pass 기법으로 구현하여 최종 로파그램을 생성하였다.

생성된 로파그램 내에서의 토널 신호를 추출하기 위한 레이블링 작업이 필요하였는데, 일반적인 CVAT 등의 세그멘테이션 레이블링 도구의 적용은 상당한 수준의 복잡도가 발생하여 자체적으로 라벨링 도구를 제작하여 픽셀 단위의 세그멘테이션 레이블링을 수행하였다. 레이블링 완료된 로파그램 중에서 시간 축 상에 토널신호가 존재하지 않는 시간과 시간적으로 연속하여 토널 신호가 존재하지 않는 영역도 모두 제거하여 최종 약 3,900초 분량의 레이블링된 그림 영상을 획득하였다.

비교실험을 위한 레이블링 데이터의 패치 규격은 기존 제안 기법[4]과 본 논문에서의 제안 기법 간에 크기 차이가 존재하였기 때문에 각 기술에서 요구하는 크기에 적절하도록 슬라이싱을 수행하여 분류하였다. 본 논문에서 제안하는 기법의 입력 패치에는 토널 신호가 포함되는 확률이 적기 때문에 각 패치별로 포함된 토널 신호의 비중이 1.5% 미만인 패치들은 극심한 데이터 불균형으로 인하여 발생할 수 있는 모델 성능 저하를 방지하기 위하여 패치 데이터셋에서 배제되었다.

3.2 실험 환경

본 논문에서 제안하는 기법은 로파그램으로부터 토

널신호를 정확하게 추정하여 이후 단계의 추가적인 분석 단계에서의 오차를 최소화하기 위한 기법으로서, 관련 연구의 수는 많지 않으며, 오직 국방과학연구소 연구팀에서 제안한 기법[4]이 직접적으로 비교 가능하다. 해당 기법과 제안 기법의 비교를 위하여 관련 논문에 표기된 좋은 성능지표에 해당하는 파라미터(dense 블록 활용 및 패치 사이즈: 31×7)를 기준으로 비교실험체를 구현하였다.

본 논문에서 달성하려는 저전력 고성능의 엣지 컴퓨팅 환경을 구성하기 위하여 Raspberry Pi 4와 Google사에서 제작한 USB 형식의 Coral TPU를 실험대상 하드웨어로 선정하였다. 위 하드웨어에 대한 세부사항은 Table 1에 기술하였으며, 해당 표에 표기된 TPU의 하드웨어 사양과 관련하여 본 논문에서 활용하는 UNet 모델의 TPU 상에서 동작을 보장하기 위하여 기본 UNet과 비교하여 이미지 피라미드 상에서 입력 패치 사이즈와 동일 크기를 갖는 레이어의 채널 사이즈를 64에서 32로 축소하였다. 또한 입력 패치 사이즈를 64×192로 설정하여 Google TPU에서 활용할 수 있는 최대의 메모리 크기(8 MB)를 활용할 수 있도록 모델의 파라미터 수를 설정하였다. 이로 인하여 기존 제안 기법의 모델 크기는 양자화 전과 후를 기준으로 각각 8.72 MB 및 2.2 MB이며, 본 논문의 제안 기법 모델의 크기는 양자화 전과 후를 기준으로 각각 29.6 MB 및 7.5 MB이다.

Table 1. H/W specification utilized for experiments

Computing environment	CPU	RAM	Parallel processing unit
Laptop	i9-13900HX	32 GB DDR5	RTX 4060 Laptop GPU (8 GB) multi-batch support
Edge-computing	Cortex-A72 (RPi-4)	4 GB DDR4	Google Coral USB TPU (8 MB) single-batch support

3.3 학습 결과

엣지 환경의 TPU를 고려한 모델의 설계에 기반하여 레이블링된 데이터는 기존 기법과 본 논문의 기법에 대하여 각각 79,276개와 8,863개의 수량을 포함하며 학습과 검증을 위하여 8:2의 비율로 무작위 분할되었다. 각각의 기법에 대한 모델 학습 과정에서의

손실(loss)에 대한 변화 추이와 F1-score에 대한 결과는 Fig. 2에 도시하였다.

기존 기법[4]은 1 에포크(epoch) 학습을 위하여 약 240초 가량의 시간이 요구되었으며, 제안 기법은 1 에포크 학습에 평균적으로 65초가 필요하였다. 기존 기법은 약 20 에포크를 기점으로 검증 데이터셋의 손실 값이 증가하여 과적합 상태로 전이되는 것으로 판단하였다. 제안 기법은 100 에포크 수행 도중 손실값 발산의 형태를 보이지 않았지만, 약 90 에포크 이상의 지점에서 지속적인 성능 개선의 여지가 보이지 않았다. 이후의 테스트 결과는 각 학습 그래프의 붉은 원 위치에 해당하는 체크포인트를 활용하여 분석 및 기술되었다. 각 그래프의 푸른색 원은 손실 및 F1-score를 기준으로 유의미한 값일수도 있으나 과적합 상태

를 고려하여 실험 대상 체크포인트로 선정되지 않은 결과이다. 전체적인 학습 결과를 미루어 볼 때, 제안 기법의 학습 결과가 우수한 것을 확인할 수 있다.

3.4 토널 탐지 테스트 결과

학습되어 최종 선정된 체크포인트를 기준으로 검증 데이터에 대한 토널/비토널 클래스 기준 정확도와 F1-score에 대한 실험결과를 Table 2에 나타냈다. 전반적으로 제안 기법이 기존 기법에 비하여 월등한 성능을 보이며, 양자화에 의한 정확도 저하는 크게 나타나지 않는 것으로 확인되었다.

함축된 정량적인 수치 이외에 정성적으로 제안된 기법의 우수성과 옛지 컴퓨팅 환경에서의 활용성을

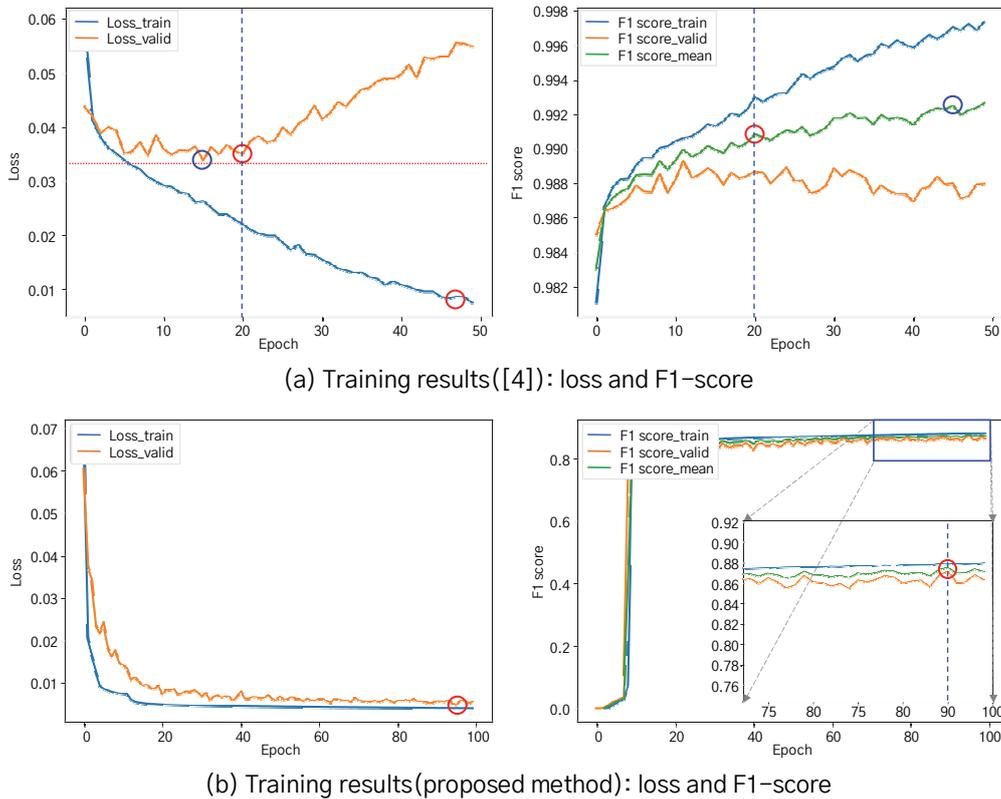


Fig. 2. Model training test result

Table 2. Tonal detection test result

Operating precision	Previous method [4]		Proposed method	
	Accuracy	F1-Score	Accuracy	F1-Score
Floating-point operation	0.65	0.44	0.85	0.77
Integer operation	0.666	0.458	0.839	0.763

확인하기 위하여 동일한 로파그램을 입력으로 각각의 기법들을 활용한 출력결과를 Figs. 3-4에 나타냈다. 각 출력결과에 대하여 0.5를 문턱값으로 활용하여 최종결과를 도출하였다. 각 그림에서 붉은 사각형으로 표시된 영역은 토널 신호로 보기 어려운 bath-tub 신호 등으로 추측되는 영역으로, 해당 영역에 대한 오탐지율이 학습률과 전체적인 F1-score의 향상을 저해한 것으로 파악된다. 기존 기법은 토널신호로 예측된 영역은 전체적으로 높은 신뢰도값으로 추정하였으며 토널신호보다 조금 더 넓은 영역을 토널신호로 추정하는 경향이 있다. 반대로 제안하는 기법은 실제 토널로 예측되는 경향성에 맞추어 신뢰도를 나타내는 경향을 보였으며, 상대적으로 토널의 영역 이하의 부분

에 토널 신호에 대한 신뢰도를 나타내고 있다. Bath-tub 추측 영역에 대한 오탐지율이 상대적으로 낮게 나타나고 있으나 여전히 토널신호로 예측하는 문제는 동일하게 가지고 있다.

엣지 컴퓨팅 환경에서도 GPU 환경과 크게 차이 나지 않는 탐지 결과가 두 기법에서 모두 확인됨으로써, 정수 양자화를 통하여 정확도가 높고 손실 없는 모델의 경량화 가능성을 확인하였다.

3.5 수행 시간 테스트 결과

제안된 기법이 GPU 기반의 환경 외에 엣지 컴퓨팅 환경에서도 여전히 좋은 연산 효율성을 나타내는지 확

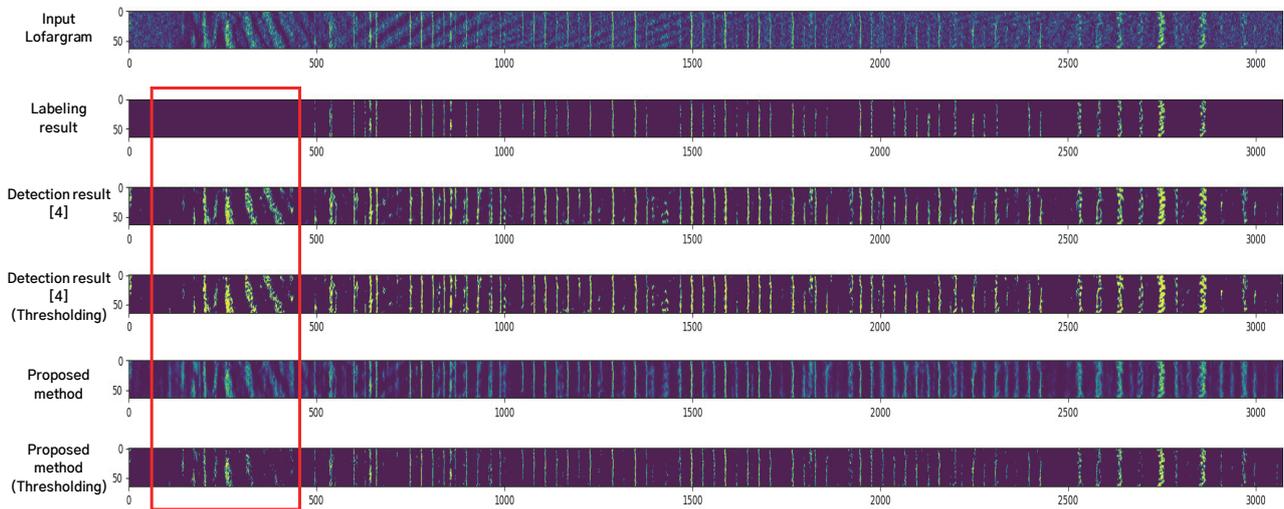


Fig. 3. GPU-based validation data tonal detection test result

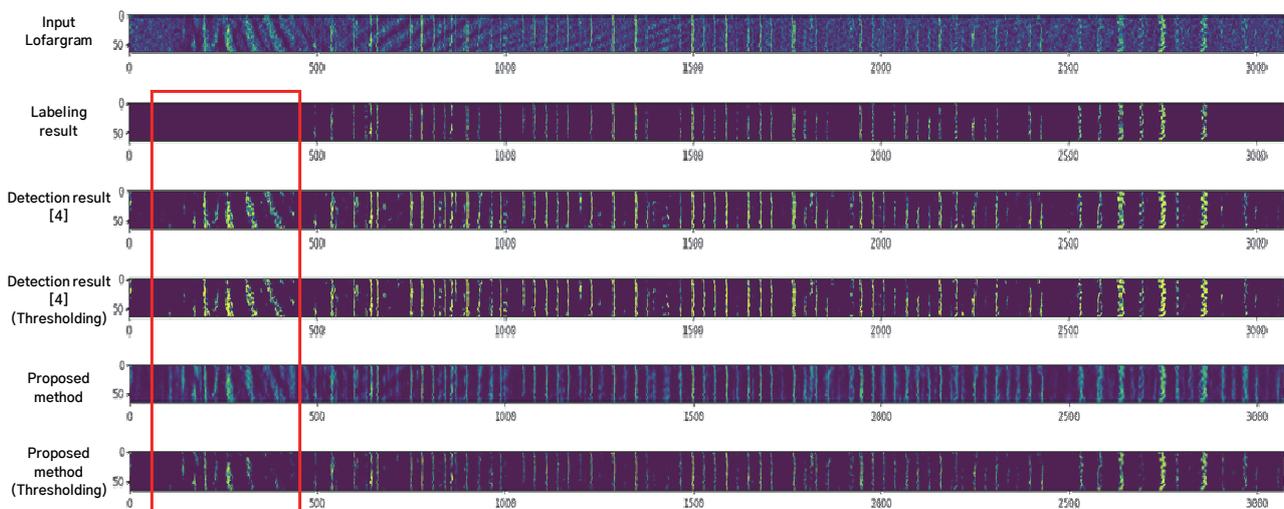


Fig. 4. TPU-based validation data tonal detection test result

Table 3. Evaluation of elapsed inference time under various H/W configurations

H/W configuration	Processing time of [4] (sec)		Processing time of proposed method (sec)	
	Preprocessing	Model inference	Preprocessing	Model inference
Laptop+CPU inference (batch inference)	0.003*	123.3*	0.001	0.245
Laptop+GPU inference (batch inference)	0.003*	14.25*	0.001	0.035
Laptop+TPU inference (single inference)	0.003	275.3	0.001	0.069
RPi 4+CPU inference (batch inference)	0.134	2,368	0.002	4.35
RPi 4+TPU inference (single inference)	0.134	499	0.002	0.165

*batch unit: LOFAR-gram row (time-axis)

인하기 위하여 랩탑, 라즈베리파이, Coral TPU를 활용한 다양한 하드웨어 구성환경을 설정하고 실험을 진행하였다. 각 구성 환경에서의 실험 결과는 Table 3과 같다.

기존 기법은 GPU의 배치 연산을 활용하지 못할 경우 로파그램의 픽셀 수만큼의 인공지능 모델의 연산을 요구하기 때문에 소요시간이 매우 증가하는 것을 볼 수 있으며, GPU 배치 연산을 활용한다 하여도 GPU의 메모리가 배치연산의 한계점을 지정하게 되어 결과적으로 오랜 실행 시간이 요구된다. 하지만 제안 기법은 훨씬 넓은 면적을 입력 패치로 받아들여 동일 크기의 출력결과를 반환하기 때문에 면적 대비 훨씬 적은 수의 연산 횟수가 요구된다. 또한 양자화를 통한 TPU의 정수 연산을 통하여 GPU와 유사한 연산속도 획득이 가능하다. 추가적으로, 입력 패치크기의 증가는 인공지능 모델의 입력 데이터 분할 처리 횟수도 감소시켜 더 높은 효율성을 얻을 수 있다.

4. 결론

해군 무인운용 체계는 저전력 고성능의 소나탐지 기술이 요구된다. 이를 위해서 범용적 GPU 활용이 불가능한 엷지 컴퓨팅 환경의 사용이 필수적이며, 하드웨어 특성으로 인한 제한적 기능에 요구되는 딥러닝 모델 설계가 필요하다. 본 논문에서는 엷지 컴퓨팅 환경을 고려한 딥러닝 모델의 설계와 구현을 통한 저전력

무인운용 체계에서의 소나탐지 기술의 활용 가능성을 확인하였다. 제안된 기술은 기존의 기술 대비 저전력 엷지 컴퓨팅 환경에서도 실시간활용이 가능함을 확인할 수 있었으며, 로파그램에서의 토널 주파수 탐지에도 높은 성능을 보임을 확인하였다.

참고문헌

- [1] R. P. Gorman and T. J. Sejnowski, "Analysis of Hidden Units in a Layered Network Trained to Classify Sonar Targets," *Neural Networks*, Vol. 1, No. 1, pp. 75–89, 1988.
- [2] A. Galusha, J. Dale, J. Keller, and A. Zare, "Deep Convolutional Neural Network Target Classification for Underwater Synthetic Aperture Sonar Imagery," in *Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXIV*, Vol. 11012, International Society for Optics and Photonics, 1101205, 2019.
- [3] D. Kim, "Use of One-shot Learning for Automatic Target Recognition of Surface Ship Noise," *Journal of KNST*, Vol. 6, No.3, pp. 221–226, 2023.
- [4] J. Park, and D.-J. Jung, "Deep Convolutional Neural Network Architectures for Tonal Frequency Identification in a Lofargram," *International Journal of Control, Automation and Systems*, Vol. 19, pp. 1103–1112, 2021.
- [5] J. Park et al. "Multi-object Tracking on SWIR Images for City Surveillance in an Edge-computing Environment," *Sensors*, Vol. 23, No. 14, 6373, 2023.
- [6] J. H. Shapiro and T. J. Green, "Performance of Split-window Multipass-mean Noise Spectral Estimators," in *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 36, No. 4, pp. 1360–1370, Oct. 2000.