Journal of the Korea Industrial Information Systems Research Vol.25 No.4, Aug. 2020 :29-38
http://dx.doi.org/10.9723/jksiis.2020.25.4.029 ISSN:1229-3741

다중 레이블 콘볼루션 신경회로망을 이용한 능동펄스 식별 알고리즘 연구+

(A Study of Active Pulse Classification Algorithm using Multi-label Convolutional Neural Networks)

김 근 환[1], 이 석 진[2], 이 균 경[3], 이 동 화[4]*
(Guenhwan Kim, Seokjin Lee, Kyunkyung Lee, and Donghwa Lee)

요 약 본 논문에서는 다중 레이블 콘볼루션 신경회로망(Multi-label Convolution Neural Networks)을 이용하는 능동펄스 식별 알고리즘을 제안한다. 제안하는 기법은 기존의 단일 레이블 기반 알고리즘이 여러 개의 신경회로망 구조로 되어 있던 것과 달리 하나의 신경회로망 구조로 능동펄스의 정보를 한번에 획득할 수 있으며, 학습과정 역시 간편해지는 장점이 있다. 제안한 능동펄스 식별 알고리즘을 검증하기 위해서 해상실험 데이터를 이용하여 신경회로망을 학습시키고 성능을 분석하였다. 분석결과 제안한 능동펄스 식별 알고리즘이 수렴하는 것을 확인하였으며, 오차행렬(Confusion Matrix) 분석을 통하여 우수한 능동펄스 식별성능을 가지는 것을 확인하였다.

핵심주제어: 능동소나, 펄스식별, 콘볼루션 신경회로망, 다중 레이블

Abstract In this research, we proposed the active pulse classification algorithm using multi-label convolutional neural networks for active sonar system. The proposed algorithm has the advantage of being able to acquire the information of the active pulse at a time, unlike the existing single label-based algorithm, which has several neural network structures, and also has an advantage of simplifying the learning process. In order to verify the proposed algorithm, the neural network was trained using sea experimental data. As a result of the analysis, it was confirmed that the proposed algorithm converged, and through the analysis of the confusion matrix, it was confirmed that it has excellent active pulse classification performance.

Keywords: Active Sonar, Pulse Classification, Convolutional Neural Networks, Multi-Label

1. 서 론

소나 시스템 (Sonar System)은 음파를 사용하여 수중의 정보를 획득하는 시스템으로 해양 생태계 연구, 어군 탐지기 등의 상업용, 군사용 목적 등 다양한 분야에서 사용된다. 특히 군사적으로는 수중의 기뢰를 제거하는 소해 (Mine

* Corresponding Author: leedonghwa@daegu.ac.kr
+ 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2019R1F1A1058434).
Manuscript received June 17, 2020 / revised July 17, 2020 / accepted July 20, 2020
1) 경북대학교 전자공학부, 제1저자
2) 경북대학교, 전자공학부, 공동저자
3) 경북대학교, 전자공학부, 공동저자
4) 대구대학교, ICT융합학부, 교신저자

Hunting), 항만감시체계 (Harbor Underwater Surveillance System), 잠수함을 탐지, 추적, 식별하는 대잠전 (Anti-Submarine Warfare) 등의 목적으로 주로 사용되고 있다 (Urick, 1967; Cox, 1989; Kim, 2006; Kim et al., 2019; Lee and Oh, 2000; Waite, 2002).

대잠전을 위한 소나 시스템은 크게 표적의 방사하는 소음을 수신하여 정보를 획득하는 수동소나 (Passive Sonar)와 함선에서 음파를 송신하여 반사되는 신호를 수신 후 분석하는 능동소나 (Active Sonar)로 구분할 수 있다. 초기의 소나 시스템은 수동소나를 주로 사용하였으나 잠수함의 방사소음이 점차 감소함에 따라 탐지가 어려워졌으며, 능동소나에 대한 연구가 활발히 진행되고 있다.

일반적인 능동소나 시스템은 송신기에서 송신한 능동펄스의 정보를 수신플랫폼에서 획득할 수 있고, 시간동기화가 되어있기 때문에 정합필터를 이용하여 표적의 거리를 추정할 수 있다. 그러나 송신기의 정보를 공유받지 못하는 비협동 양상태 소나 시스템 (Non-cooperative Bi-static Sonar System)이나 적함 및 어뢰의 능동펄스를 분석하는 방수소나 (Intercept Detectinon and Ranging Sonar: IDRS) 시스템의 경우에는 수신된 신호에 정합필터를 수행하기 위해서 능동펄스의 정보를 추정, 식별해야 하는 문제가 발생한다 (Schmidt-Schierhorn et al., 2007; Lee et al., 2012; Schmidhuber 2015).

최근 Kim et al. (2019)은 콘볼루션 신경회로망 (Convolutional Neural Networks)을 이용하여 능동펄스를 식별하는 알고리즘을 제안하였다. Kim et al. (2019)이 제안한 알고리즘은 신호를 시간-주파수 영역으로 변환하는 전처리 과정과 전처리 된 시간-주파수 영역의 데이터를 2개의 콘볼루션 레이어 (Convolution Layer)와 완전연결 레이어 (Fully Connected Layer)로 구성된 신경회로망에 입력하는 구조로 되어있다.

이들이 제안한 알고리즘은 성공적으로 데이터를 학습하였으며, 성능 분석 결과 능동펄스의 정보를 높은 정확도로 식별할 수 있었다. 그러나 Kim et al. (2019)이 제안한 기법은 수신 신호에서 펄스의 종류, 수신 시간 등과 같은 개별적인 정보를 획득하기 위해서 각각에 해당하는 신경회로망을 일일이 설계, 학습해야 하는 문제점이 있다. 따라서 동일한 데이터를 여러 번 이용해서 개별 신경회로망을 일일이 학습시켜야 하기 때문에 학습이 번거롭고 계산량이 상대적으로 많아지는 문제점이 발생한다. 즉 Kim et al. (2019)의 알고리즘은 능동펄스를 식별하는 문제를 여러 개의 단일 레이블 (Single-Label Classification) 문제로 해석한 것으로 분석할 수 있다.

그러나 능동펄스 식별문제는 수신된 신호에서 여러 개의 펄스 정보를 추정하는 문제이기 때문에 하나의 다중 레이블 식별 (Multi-Label Classification) 문제로 다루는 것이 타당하다. 본 논문에서는 다중 레이블 콘볼루션 신경회로망을 이용하는 능동펄스 식별 알고리즘을 제안한다. 제안하는 기법은 기존의 단일 레이블 기반 알고리즘이 모든 능동펄스 정보를 획득하기 위해서 여러 개의 신경회로망 구조가 필요했던 것과 달리 하나의 신경회로망 구조로 능동펄스의 정보를 한 번에 획득할 수 있으며, 학습과정 역시 간편해지는 장점이 있다.

본 논문의 구성은 다음과 같다. 1 장의 서론에 이어 2 장에서는 본 논문에서 능동펄스 식별 문제가 발생하는 상황에 대해서 기술하고, 3 장에서 다중 레이블 콘볼루션 신경회로망을 이용한 능동펄스 식별 알고리즘을 제안한다. 4 장에서 해상 데이터를 이용하여 제안한 알고리즘을 분석 및 검증하고, 5 장에서 결론과 향후연구에 대한 논의로 끝을 맺는다.

2. 문제 설정

일반적인 능동소나 시스템은 송신기에서 송신된 능동펄스의 정보가 수신플랫폼에 공유된다는 가정하에 정합필터를 수행하거나 그 밖에 다양한 신호처리를 수행한다. 그러나 상황에 따라서 수신플랫폼이 능동펄스의 정보를 직접적으로 획득하지 못하는 상태로 운용되는 경우가 발생한다. 이 경우 능동펄스가 송신된 시점 역시 불확실하기 때문에 표적의 거리 추정 또한 불가능한 문제가 발생한다. 이러한 시스템의 대표적인 예로 능

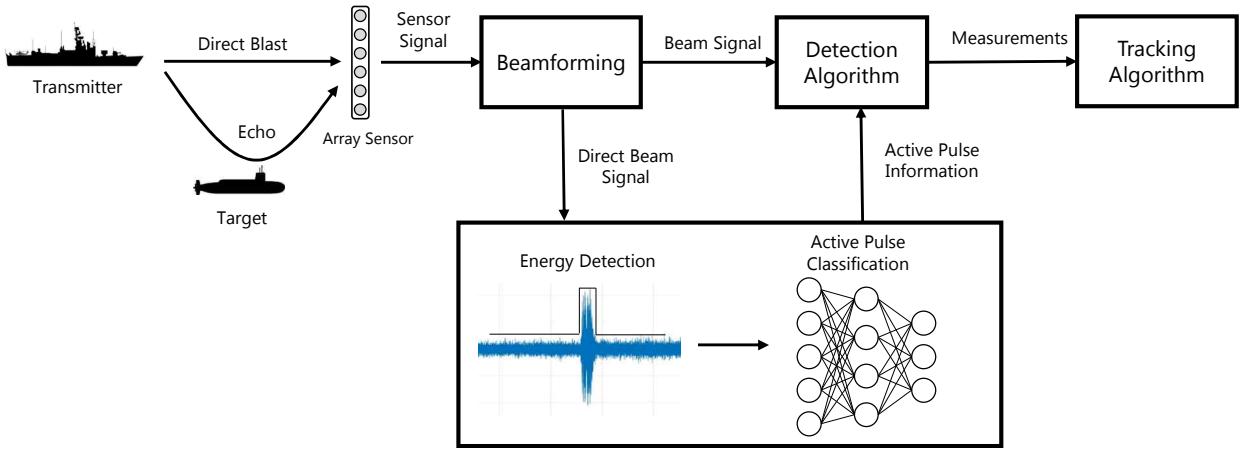

Fig. 1 Active Sonar System Requiring Active Pulse Classification Algorithm

동펄스의 정보를 공유받지 못하는 상태로 운용되는 양상태 소나 시스템과 적함이나 어뢰가 방사한 핑을 수신하여 분석하는 방수소나 시스템이 있다. 이처럼 능동펄스의 정보를 직접적으로 획득하지 못하는 경우에는 Fig. 1의 구조와 같이 송신기에서 직접적인 경로로 수신되는 송신직접파 (Direct Blast)를 수신하여 능동펄스 정보를 분석하는 능동펄스 식별 알고리즘이 필수적으로 요구된다 (Lee et al., 2012; Kim et al., 2019).

Kim et al. (2019)은 최근 콘볼루션 신경회로망을 이용하여 능동펄스 식별하는 알고리즘을 제안하였다. 콘볼루션 신경회로망은 시각 피질 (Visual Cortex)이 시각적인 정보를 처리하는 방식에서 영감을 받은 딥러닝 구조로 현재 영상을 처리하는 다양한 분야에서 연구되고 있으며, 우수한 성능을 보여주고 있다. 능동펄스 식별 문제에서 다뤄지는 능동펄스의 특성은 시간에 따라 변화하는 특성을 가지고 있으며, 따라서 수신된 시간 영역의 신호를 시간-주파수 영역으로 변환하여 분석하는 것이 효율적이다. 시간 영역의 신호를 시간-주파수 영역으로 변환하여 분석하는 방법은 오디오/음향/수중음향 데이터를 다루는 분야에서 자주 사용되는 방법이며, 이를 일종의 이미지 데이터로 취급하여 콘볼루션 신경회로망에 적용할 수 있다 (Krizhevsky et al., 2012; Satt et al., 2017; Sakashita et al., 2018; De Magistris et al., 2019).

그러나 Kim et al. (2019)은 능동펄스 식별 문제를 여러 개의 단일 레이블 식별문제로 해석하였으며, 따라서 능동펄스의 각 정보에 대한 여러 개 콘볼루션 신경회로망을 병렬적으로 설계하였다. 그러나 능동펄스 식별문제는 단일 데이터에서 여러 개의 정보를 한 번에 추정하는 다중 레이블 식별문제로 해석하는 것이 타당하며, 이렇게 해석할 경우 설계되는 신경회로망이 훨씬 간단해지는 장점이 있다.

3. 다중 레이블 콘볼루션 신경회로망을 이용한 능동펄스 식별 알고리즘

본 논문에서는 능동펄스 식별 문제를 다중 레이블 식별 문제라고 판단하고, 이에 적합한 다중 레이블 콘볼루션 신경회로망 기반의 능동펄스 식별 알고리즘을 제안하였다. Fig. 2에 본 논문에서 제안하는 능동펄스 식별 알고리즘의 흐름도를 나타내었다.

펄스 식별 과정을 자동화하기 위해서는 먼저 능동펄스가 수신되었는지 판정하는 에너지 탐지 기법이 먼저 수행되어야 한다. 수신되는 신호의 에너지를 탐지하는 기법은 중앙값 (Median) 탐지기, 엔트로피 (Entorpy) 탐지기 등이 있으며 (Neumeister, 2002), 본 논문에서는 구현이 간편하고 계산량이 적은 중앙값 탐지기를 사용하였다. 탐지기를 통해서 능동펄스 정보가 포함된 적절한 길이(수 초 이내) 신호를 추출할 수 있다.

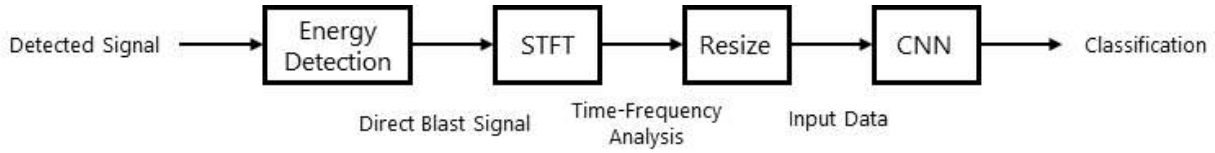

Fig. 2 Flow Diagram of the Proposed Active Pulse Classification

이렇게 추출된 시간 영역의 신호는 이후 시간-주파수 영역으로 변환된다. 시간-주파수 영역으로 신호를 변환하는 것은 단시간 퓨리에 변환(Short Time Fourier Transform)을 적용하여 얻을 수 있다. 탐지된 추출 신호를 $x(n)$이라고 할 경우, 식 (1)과 같이 나타낼 수 있다.

$$X_m(f) = \sum_{n=-\infty}^{\infty} x(n)g(n-mR)e^{-j2\pi fn} \qquad (1)$$

여기서 n은 시간 인덱스, f는 주파수 빈, m은 시간 프레임, R은 홉 크기 (Hop Size), 그리고 $g(n)$은 길이 M의 창함수 (Window Function)이다. 식 (1)에 절댓값을 취하여 크기(Magnitude) 값을 얻고 제곱을 취하면 식 (2)의 스펙트로그램 (Spectrogram) 데이터를 얻을 수 있다 (Mitra, 2001).

$$\mathrm{S}(f,m) = \left| X_m(f)RIGHT \right|^2 \qquad (2)$$

Fig. 3에 능동소나에서 일반적으로 사용되는 CW (Continuous Wave) 펄스와 LFM (Linear Frequency Modulated) 펄스의 스펙트로그램을 나타내었다.

Fig. 3에서 확인할 수 있듯이 실제 능동펄스가 존재하는 주파수 스펙트럼은 전체 샘플링 구간에 비해서 좁은 대역폭 (Narrow Band)을 가지기 때문에 신경회로망의 입력으로 사용할 때 불필요한 부분이 있다. 따라서 스펙트로그램에서 필요한 주파수 대역을 추출하여 콘볼루션 신경회로망의 입력으로 사용하는 것이 바람직하며, 이렇게 처리한 입력 데이터 S_{In}은 식 (3)과 같이 나타낼 수 있다.

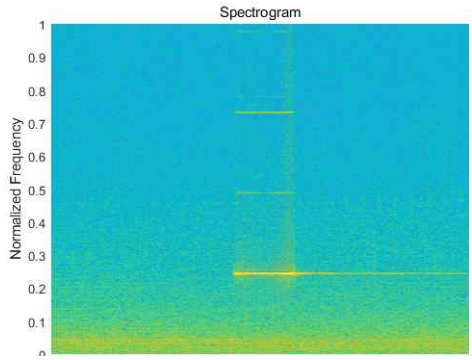

(a) CW Pulse

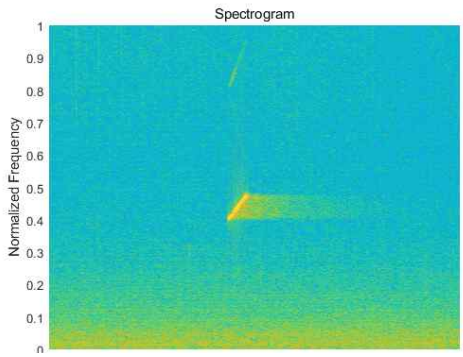

(b) LFM Pulse

Fig. 3 Spectrogram of Active Pulse

$$\mathrm{S}_{In} = \mathrm{S}(f,m)\,,\ B_l \leqq f \leqq B_h \qquad (3)$$

여기서 B_l은 추출하는 주파수 대역의 가장 낮은 주파수, B_h는 높은 주파수를 의미한다. 따라서 신경회로망의 입력으로 사용되는 데이터는 시간과 주파수가 제한된 2차원 스펙트로그램 데이터이다.

본 논문에서 정의하는 능동펄스의 정보는 펄스 종류 (Pulse Type), 시작 시간 (Start Time), 끝 시간 (End Time), 시작 주파수 (Start Frequency), 끝 주파수 (End Frequency), 이렇게 5 개로 구성된다.

이 정보들을 콘볼루션 신경회로망과 연관을 짓기 위해서는 Fig. 4와 같이 시간과 주파수를

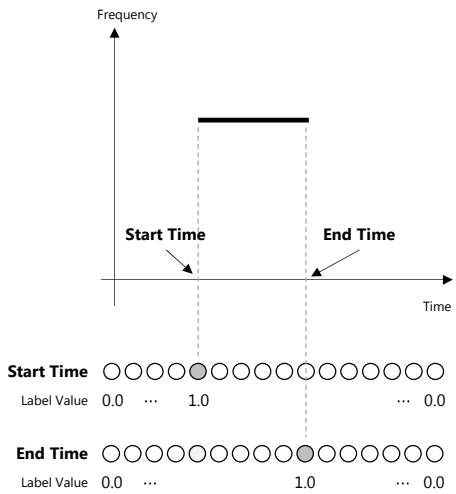

(a) CW Pulse

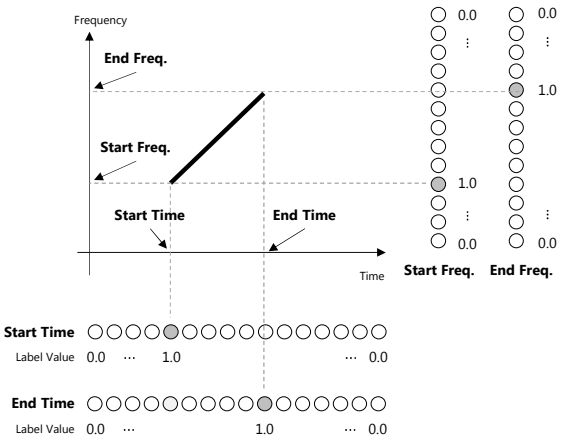

(b) LFM Pulse

Fig. 4 Discretization of Pulse Features

일정한 간격으로 이산화하여 각각을 출력노드와 일대일 대응시켜 레이블을 생성하는 것이 처리하기 편하다. 이를 위해서 스펙트로그램 데이터의 시간 프레임과 주파수 빈 개수를 재조정(Resize)하는 과정이 필요하다. 본 논문에서는 시간 프레임과 주파수 빈을 모두 112 개로 재조정하여 스펙트로그램 데이터를 112×112 픽셀(Pixel)의 이미지로 변환하였다.

제안하는 다중 레이블 콘볼루션 신경회로망의 구조는 Table 1에 정리하였다. 입력은 112×112 픽셀의 이미지 데이터이며, 3개의 콘볼루션 층(Convolutional Layer)을 사용하고 과적합 방지를 위해서 최대풀링 (Max Pooling)과 드롭아웃

Table 1 Convolutional Neural Networks Architecture

Operation		Kernel Size /Dropout Rate	Output Shape
Input			(112,112,1)
Conv2D		(3,3)	(110,110,32)
MaxPooling2D		(2,2)	(55,55,32)
Dropout		50%	(55,55,32)
Conv2D		(3,3)	(53,53,64)
MaxPooling2D		(2,2)	(26,26,64)
Dropout		50%	(26,26,64)
Conv2D		(3,3)	(24,24,64)
MaxPooling2D		(2,2)	(12,12,64)
Dropout		50%	(12,12,64)
Flatten		-	9216
Dense	Pulse Type	-	2
	Start Time	-	112
	End Time	-	112
	Start Freq.	-	112
	End Freq.	-	112

- Activation Function of Conv2D : ReLU
- Activation Function of Dense : Softmax

(Dropout) 구조를 뒤따라 적용하였다. 이어서 특징 추출을 위한 플래튼 층 (Flatten Layer)를 사용하였으며, 최종 출력노드는 5 개의 전결합층(Fully Connected Layer/Dense Layer)으로 구성되며 총 450 개의 노드를 가진다. 각각의 전결합층은 차례대로 펄스 종류, 시작 시간, 끝 시간, 낮은쪽 주파수, 높은쪽 주파수를 의미한다. 콘볼루션층의 활성화 함수는 ReLU 함수를 사용하였고, 출력노드에는 확률적 의미를 부여하기 위해서 소프트맥스 (Softmax) 함수를 사용하였다.

4. 시뮬레이션

제안하는 다중 레이블 콘볼루션 신경회로망을 이용한 능동펄스 식별 기법을 검증하기 위해서 해상실험 데이터를 이용하여 학습시키고 검증하였다.

분석에 사용된 해상실험 데이터는 수심 약 90m

의 천해환경 (Shallow Water)에서 송신기와 수신기가 수 km 이격되어 있는 상황에서 실험하였으며 총 3천여 개의 핑으로 구성되어 있다. 송신된 펄스의 종류는 CW 펄스와 LFM 펄스이며 수신기는 무지향성의 단일 센서를 사용하였다. 펄스의 길이는 세 가지로 0.05 s, 0.3 s, 1.0 s이다. 중심주파수와 대역폭 역시 몇 가지를 사용하였으나 보안상 문제로 정확한 값은 논문에 명시하지 않았다. 그러나 본 논문에서 다루는 능동펄스 식별문제는 스펙트로그램 상에서 펄스가 시간-주파수 상에서 나타나는 상대적인 위치 정보를 다루는 것이기 때문에 절대적인 값에 알고리즘의 성능이 좌우되지 않아 검증에 사용하는 것은 문제가 없을 것으로 판단된다.

학습과 검증을 위해서 해상 데이터에서 수집된 3천여 개의 핑을 8:2 비율로 학습과 검증용으로 분할 하였다. 또한 학습에 사용되도록 분류된 데이터를 시간 축과 주파수 축으로 천이하는 방식으로 데이터 증강 (Data Argumentation)을 적용하여 60만 개의 학습 데이터를 생성하였다. 데이터 학습을 위한 최적화 알고리즘은 최근 자주 사용되는 Adam (Adaptive Moment Estimation)을 사용하였고 에폭 (Epoch) 100회, 배치크기 (Batch Size)는 500으로 설정하여 학습을 수행하였다. 학습에 사용된 컴퓨터 시스템은 Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz 3.19GHz, 64.0GB RAM, GeForce GTX 1080 Ti GPU, Window 10 64bit OS를 사용하였다.

Fig. 5에 학습과정에서 매 에폭마다 변화하는 모델의 정확도 (Accuracy)와 손실함수 (Loss)를 나타내었다.

Fig. 5에서 매 에폭마다 비용함수의 값이 감소하여 수렴하는 것을 확인할 수 있다. 따라서 다중 레이블 구조를 가지는 콘볼루션 신경회로망에 대해서 학습이 문제없이 수행되는 것을 확인하였다. 알고리즘의 성능 평가를 위해 Fig. 6에 각각의 출력 레이블에 대한 오차행렬 (Confusion Matrix) 계산하여 나타내었다. 그림에서 모든 레이블에 대해서 오차행렬의 값이 대각성분 근처에 위치하는 것을 확인할 수 있으며, 따라서 제안한 알고리즘이 우수한 성능을 가지는 것을 알 수 있다. 이를 정량적으로 평가하기 위해서 오차행렬 결과를 이용한 평가지표를 정의하였다. 일반적으로 신경회로망과 같은 기계학습 (Machine Learning) 알고리즘

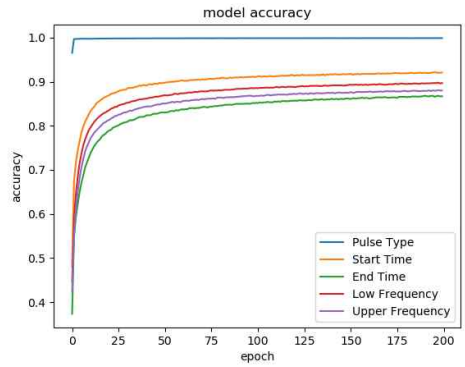

(a) Accuracy

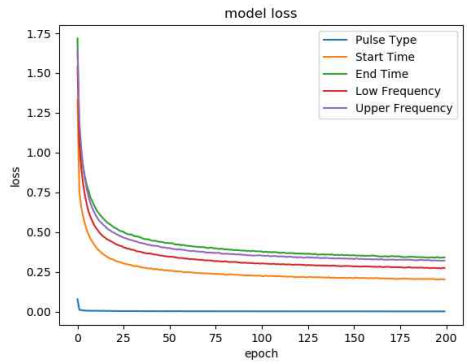

(b) Loss

Fig. 5 History of Model Training

의 평가는 다양한 방법이 있지만 오차행렬에서 대각성분이 차지하는 비율을 의미하는 정확도 (Accuracy)가 주로 사용된다. 한편 능동펄스 식별을 위해 사용되는 스펙트로그램은 근본적으로 시간과 주파수에 대한 해상도의 한계가 존재하기 때문에 학습 시 정답 (Ground Truth)을 정확하게 설정하는 것이 어려우며, 이에 대한 오차가 알고리즘에 반영된다. 따라서 오차행렬의 비대각 성분도 평가에 반영하는 일반화된 정확도 (Generalized Accuracy)를 식 (4)와 같이 정의하고 함께 계산하였다.

$$Acc_D = \frac{\sum_{i=1}^{L}\sum_{j=i-D}^{i+D} C_{(i,j)}}{\sum_{i=1}^{L}\sum_{j=1}^{L} C_{(i,j)}} \tag{4}$$

여기서 i와 j는 각각 행과 열에 해당하는 인덱

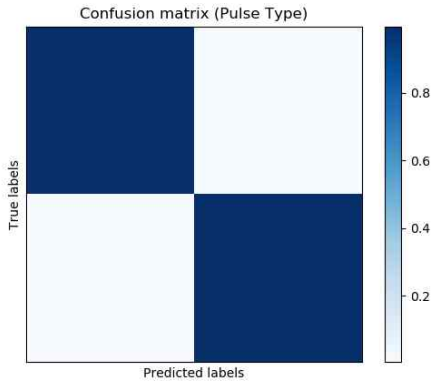

(a) Pulse Type

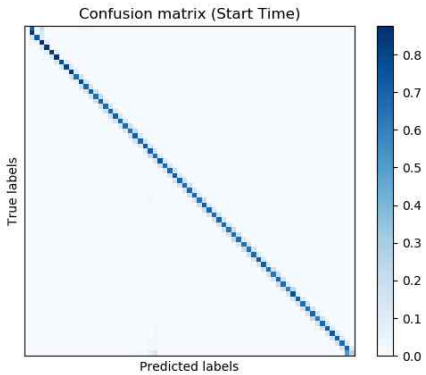

(b) Start Time

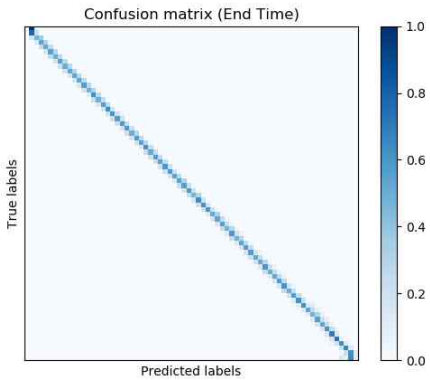

(c) End Time

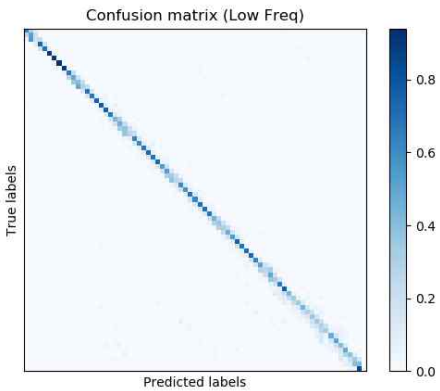

(d) Start Frequency

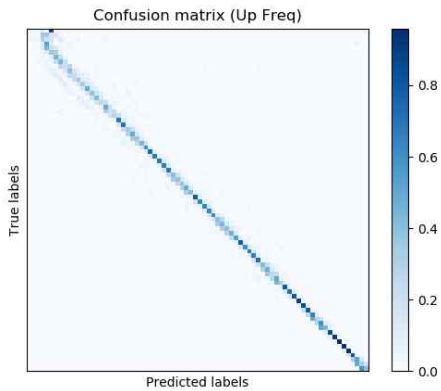

(e) End Frequency

Fig. 6 Confusion Matrix

Table 2 Assessments of the Proposed Algorithm

Class	Acc_0	Acc_1	Acc_2
Pulse Type	99.8	-	-
Start Time	70.5	98.8	98.9
End Time	55.7	97.1	99.6
Start Freq.	56.3	89.0	92.9
End Freq.	56.9	87.3	90.9

스로 양의 정수인 경우에만 유효하며, $\mathrm{C}_{(i,j)}$는 오차행렬의 i행, j열에 해당하는 성분을 의미한다. 또한 L은 레이블의 개수, D는 대각성분의 인덱스를 의미한다. 따라서 Acc_D는 D 번째 비대각 성분까지 포함되는 오차행렬의 성분이 전체에서 가지는 비율을 의미하며, 이는 곧 정답 픽셀에서 오차를 몇 픽셀 허용하더라도 정답으로 판단한다는 의미이다. 이때 $D=0$인 Acc_0의 경우 일반적인 정확도와 동일한 의미를 가진다.

계산된 평가지표를 Table 2에 정리하였다. 펄스 종류를 구별하는 것은 쉬운 문제이기 때문에 표에서 이에 대한 결과를 확인해 보면 99.9%의 정확도를 나타내는 것을 확인할 수 있으며, 이를 구별하는 것 확인할 수 있다. 그러나 그 외의 펄스 정보의 경우 대각성분만을 고려하는 Acc_0의 값이 55%에서 70% 정도로 낮게 나타나는 것을 확인할 수 있다. 이는 콘볼루션 신경회로망의 성능 문제라기 보다는 앞서 언급했듯이 스펙트로그램의 해상도 한계로 인한 정답 설정의 어려움 때문이며, 이를 고려한 Acc_1와 Acc_2에 대해서는 최대 98.9%의 정확도를 보이는 것을 확인할 수 있다.

이때 시간에 대한 1 개의 픽셀 차이는 0.01 s, 주파수의 경우 10 Hz 간격을 의미하기 때문에 Acc_2에 대해서 각각 0.02 s, 20 Hz의 오차가 발생한다. 따라서 제안하는 다중 레이블 콘볼루션 신경회로망을 이용해서 능동펄스의 정보를 효율적으로 추정할 수 있음을 확인하였으며, 실제 시스템에서 운용하기에 어려움이 없을 것으로 판단된다.

Table 3에 기존의 Kim et al. (2019)이 제안한 단일 레이블 구조와 제안하는 다중 레이블 구조를 정량적으로 비교 분석하였다. 제안한 다중 레이블 구조는 기존의 구조보다 콘볼루션 층을 1 개 더 사용하였으며, 이때 함께 사용되는 풀링구조로 인해 최종적으로 최적화해야 하는 파라미터의 구조가 감소하는 장점이 있다. 더욱이 기존의 구조는 여러 개의 펄스에 대한 특징을 각각 식별해야하기 때문에 최적화 파라미터의 개수가 약 5배 많은 단점이 있다. 또한 기존의 알고리즘과 제안하는 알고리즘을 이용하여 얻어진 정확도를 비교해본 결과 제안한 알고리즘의 성능이 최소 2.1%, 최대 6.2% 향상된 것을 확인할 수 있다. 이는 제안하는 알고리즘이 구조가 더 깊고 펄스의 여러 특징인자를 한 번에 반영하는 특성을 가지기 때문으로 분석된다.

Table 3 Comparison of Single-label and Multi-label Convolutional Neural Networks

Analysis Parameters		Single-label (Kim's)	Multi-label (Proposed)
Number of Parameter		105,346+ 4,864,496×4 =19,563,330	4,203,394
Accuracy for Start Time	Acc_0	64.3%	70.5%
	Acc_1	93.2%	98.8%
	Acc_2	96.8%	98.9%
Accuracy for End Time	Acc_0	49.4%	55.7%
	Acc_1	88.7%	97.1%
	Acc_2	95.4%	99.6%

5. 결론 및 향후 연구방향 논의

본 논문에서는 다중 레이블 콘볼루션 신경회로망을 이용한 능동펄스 식별 알고리즘을 제안하였다. 제안한 알고리즘은 능동펄스 식별 문제를 여러 개의 단일 레이블 문제로 인식한 기존의 알고리즘과 달리 다중 레이블 문제로 다루었기 때문에 신경회로망의 구조가 단순하고 학습이 편리한 장점이 있다. 제안한 알고리즘을 검증하기 위해 실제 해상실험을 통해 수집된 능동펄스 데이터를 이용하였으며, 펄스의 정보를 효율적으로 추정할 수 있음을 확인하였다.

향후에는 Comb 펄스, SFM 펄스 등 시간-주파수 상에서 특징이 빠르게 변화하는 능동펄스를 식별하기 위한 신경회로망의 구조를 연구할 예정이다. 이를 위해서 시간-주파수 해상도를 향상시키기 위한 전처리 과정에 대한 연구가 필요할 것으로 판단되며, 신경회로망의 구조도 복잡한 정보를 추정할 수 있도록 개선이 필요할 것으로 판단된다.

감사의 글

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2019R1F1A1058434).

References

Cox, H. (1989). Fundamentals of Bistatic Active Sonar. *Handbook of Underwater Acoustic Data Processing*, (edit) Chan Y. T., Springer, Netherlands.

Kim, G. H., Choi, S. R., Yoon, K. S., and Lee, K. K. (2019). Active Pulse Classification Algorithm using Convolutional Neural Networks, *The Journal of the Acoustical Society of Korea*, 38(1), 106-113.

Kim, J. G. (2006). Whitening Method for Performance Improvement of the Matched Filter in the Non-white Noise Environment, *Journal of the Korea Industrial Information Systems Research*, 11(3), 15-19.

Krizhevsky, A., Ilya, S., and Geoffrey, E. H., (2012). Imagenet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, 1097-1105

Lee, C. W., and Oh, S.-B. (2000). A Data Processing System on the Transportable Meteorological Radar, *Journal of the Korea Industrial Information Systems Research*, 5(3), 44-50.

Lee, D. H., Jung, T. J., Lee, K. K., and Hyun, M. (2012). Source Information Estimation using Enemy's Single-ping and Geographic Information in Non-cooperative Bistatic Sonar, *IEEE Sensor Journal*, 12(9), 2784-2790.

Magistris, D. G., Stinco, P., Bates, J. R., Topple, J. M., Canepa, G., Ferri, G., Tesel, A., and Page K. L. (2019). Automatic Object Classification for Low-frequency Active Sonar using Convolutional Neural Networks, Oceans 2019 MTS/IEEE Seattle. IEEE.

Mitra, S. K. (2001). *Digital Signal Processing: A Computer-Based Approach. 2nd Ed.* New York: McGraw-Hill.

Neumeister, D. (2002). Strategies and Future Trends in Submarine Intercept-processing with an Example of an Intercept Entropy Detector, *UDT EUROPE*, 1-6.

Sakashita, Y., and Aono, M. (2018), Acoustic Scene Classification by Ensemble of Spectrograms based on Adaptive Temporal Divisions, *Detection and Classification of Acoustic Scenes and Events (DCASE) Challenge*.

Satt, A., Rozenberg, S., and Hoory, R. (2017). Efficient Emotion Recognition from Speech using Deep Learning on Spectrograms. Interspeech, *Interspeech*, 1089-1093

Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview, *Neural Networks*, 61, 85-117.

Schmidt-Schierhorn, H., Corsten, A., Strassner, B., Benen, S., and Meister, M. (2007), The Use of Bistatic Sonar Functions on Modern Submarines, *UDT EUROPE*, 5-7.

Urick, R. J. (1967). *Principles of Underwater Sound for Engineers,* McGraw-Hill Book Company.

Waite, A. D, (2002). *Sonar for Practising Engineers*, New York: Wiley.

김 근 환 (Geunhwan Kim)
- 정회원
- 경북대학교 전자공학부 학사
- 경북대학교 전자공학부 석사
- (현재) 경북대학교 전자공학부 박사과정
- 관심분야: 소나신호처리, 배열신호처리, 탐지이론

이 석 진 (Seokjin Lee)
- 서울대학교 전자공학부 학사
- 서울대학교 전자공학부 석사
- 서울대학교 전자공학부 박사
- LG전자 CTO연구소 선임연구원
- 경기대학교 전자공학과 조교수
- (현재) 경북대학교 전자공학부 조교수
- 관심분야: 음향신호처리, 배열신호처리, 블라인드 음원분리

이 균 경 (Kyunkyung Lee)
- 서강대학교 전자공학과 학사
- 텍사스 주립대 전자공학과 석사
- 텍사스 주립대 전자공학과 박사
- (현재) 경북대학교 전자공학부 교수
- 관심분야: 소나신호처리, 배열신호처리, 탐지이론

이 동 화 (Donghwa Lee)
- 정회원
- 경북대학교 전자전기공학부 공학사
- 경북대학교 전자전기컴퓨터학부 공학석사
- KAIST 건설및환경공학과 공학박사
- (현재) 대구대학교 정보통신대학 ICT융합학부 조교수
- 관심분야: 컴퓨터비전, 로봇비전, 머신러닝, 소나 신호처리