

컨볼루션 신경망 기반의 능동소나 표적 식별

김정훈* · 최대성 · 이형수 · 이정우

Target Classification of Active Sonar Returns based on Convolutional Neural Network

Jeong-Hun Kim* · Dae-Sung Choi · Hyung-Soo Lee · Jung-Woo Lee

LIG Nex1 Co., Ltd., 333, Pangyo-ro, Bundang-gu, Seongnam-si, Gyeonggi-do, Korea

요 약

최근 딥 러닝 알고리즘이 다양한 분야에 적용되어 좋은 성능을 내고 있지만, 소나시스템에는 아직 활발히 적용되지 않고 있다. 본 논문에서는 기뢰와 같은 금속 물체와 바위로부터 반사된 능동소나 수신음 데이터를 딥 러닝 알고리즘의 하나인 컨볼루션 신경망으로 식별하는 실험을 수행하였다. 과적합 방지 및 성능 향상을 위해 데이터 확장을 하였고, 확장 및 하이퍼파라미터 값 변화에 따른 성능 변화를 분석하였다. 훈련데이터를 수신각도에 독립적인 경우와 의존적인 경우로 나누어 실험을 수행하였고, 그 결과 각각 88.9%, 94.9%의 성능을 보였다. 이는 이전 연구에서 인공 신경망 및 Support Vector Machine 알고리즘을 적용하여 얻은 성능보다 최대 4.5% 포인트 향상되었다.

ABSTRACT

Recently, deep learning algorithms have good performance in various fields, but they are not actively applied to sonar systems. In this study, we carried out experiments to classify active sonar returns into a metal object such as a mine and a rock using a convolutional neural network which is one of the deep learning algorithms. Data augmentation is applied on this paper to avoid overfitting and increase performance. And we analyzed performance variation depending on hyperparameter value and change of the number of training data through data augmentation. The experiments are performed with two training data; an aspect-angle independent and an aspect-angle dependent. As a result, the performances are 88.9% and 94.9% in aspect-angle independent and dependent, respectively. These are up to 4.5% point higher than the performance obtained by applying artificial neural network and support vector machine algorithm in the previous study.

키워드 : 능동소나, 딥 러닝, 컨볼루션 신경망, 기뢰

Key word : Active Sonar, Deep Learning, Convolutional Neural Network, Mine

Received 07 June 2017, Revised 13 June 2017, Accepted 10 July 2017

* Corresponding Author Jeong-Hun Kim(E-mail:jeonghun.kim@lignex1.com, Tel:+82-31-8026-4830)
LIG Nex1 Co., Ltd., 333, Pangyo-ro, Bundang-gu, Seongnam-si, Gyeonggi-do, Korea

Open Access <https://doi.org/10.6109/jkiice.2017.21.10.1909>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서론

능동소나는 적 잠수함과 같은 표적을 탐지/추적 및 식별하기 위한 수상함의 주요장비이다. 하지만 수중환경에서의 음향 신호가 시간·공간적으로 특성이 변화하고, 천해 다중경로 환경을 반영하는 복잡한 특성으로 인해 능동소나를 이용한 표적 식별은 여전히 어려운 문제로 남아있다[1]. 특히, 잠수함 또는 기뢰를 바위와 같은 클러터와 식별하는 것은 중요한 문제 중 하나이지만 시스템에서 자동으로 하는 것은 쉽지 않다. 그래서 이를 극복하기 위한 연구들이 지속적으로 수행되고 있다. Gorman과 Sejnowski은 기뢰와 같은 금속 실린더 물체와 실린더 모양의 바위로부터 반사되는 능동소나 반향 신호를 인공신경망 알고리즘으로 식별하는 연구[2]를 수행하였다. 그 후, 동일한 데이터를 Support Vector Machine (SVM) 알고리즘을 적용하여 인공신경망 알고리즘보다 성능을 향상시켰다[3]. 또한 합성된 능동소나 표적신호를 Fractional Fourier 변환을 적용하여 특징추출하고 신경망으로 인식하는 연구가 수행되었다[4]. 동일 표적의 서로 다른 자세각(Aspect)에서 수신된 신호들을 Hidden Markov Model(HMM)을 이용한 다중 자세각 표적 인식 기법도 연구 되었다[5].

신경망은 적응성과 병렬 처리의 효율성 때문에 능동 소나 인식에 적합하다고 고려된다[6]. 하지만 고전적 인공신경망은 많은 계층으로 구성된 깊은 신경망을 학습하기 어려운데, 적은 수의 계층으로 구성된 신경망만으로는 복잡한 문제를 해결하는데 좋은 성능을 내기 어렵다. 최근에 고성능 CPU 및 GPU의 발전으로 딥러닝(Deep Learning)은 빅데이터를 다룰 수 있는 확장성 높은 알고리즘으로 각광받고 있다. 또한 다양한 분야에 적용되어 기존 방법들을 능가하는 높은 성능을 내고 있지만 소나시스템에는 아직 활발히 적용되지 않고 있다. 딥 러닝 알고리즘의 하나인 컨볼루션 신경망(Convolutional Neural Network)은 고전적 인공신경망보다 깊은 계층의 신경망 학습이 잘 되는 장점을 가진다. 능동소나 수신 신호는 해양환경에 따른 다중 경로를 통한 여러 신호가 수신되고 잔향음, 수중 생물 등의 원하지 않는 신호도 포함되는데, 이처럼 복잡한 신호를 분류하기에는 컨볼루션 신경망이 적합할 것으로 보인다. 본 논문에서는 컨볼루션 신경망을 능동소나 수신신호에 적용하여 기뢰와 바위를 식별하고 그 성능을 분석

해보고자 한다.

실제 해상에서 잠수함 및 기뢰로부터 반사된 능동소나의 데이터 획득이 어려운 점이 있어, 본 논문에서는 UCI machine learning repository[7]에서 공개한 데이터셋을 이용하였다. 이 데이터는 기존 연구[2]에서 사용된 능동소나의 표적 반사음에 대한 데이터로써, 60차 주파수 스펙트럼 특징벡터로 구성된 데이터로 구성되어 있다.

컨볼루션 신경망은 일반적으로 2차원 이상의 이미지 식별에 많이 쓰이는데, 본 논문에서 사용하는 데이터는 1차원 주파수 스펙트럼이므로 이를 컨볼루션 신경망에 적용하기 위해 2차원 형태로 변경하여 입력데이터로 사용하였다. 실험 결과, 2차원으로 변경된 1차원 주파수 스펙트럼도 컨볼루션 신경망에서 좋은 성능을 내는 것을 확인하였다.

딥 러닝의 경우 빅데이터 기반에서 좋은 성능을 내는데, UCI 소나 데이터는 208개의 적은 데이터를 제공한다. 이를 극복하기 위해 본 논문에서는 일반적으로 이미지에 많이 적용되었던 데이터 확장(Data augmentation) 기법을 주파수 데이터에 적용하였고, 그 결과 성능이 향상 되는 것을 확인하였다.

기계학습에서 하이퍼파라미터(Hyperparameter)는 성능에 영향을 미치는 중요한 요소로써, 데이터 특성에 따라 다른 최적의 하이퍼파라미터 값을 가진다[8]. 본 논문에서는 하이퍼파라미터의 변화에 따른 성능의 변화를 조사하고, 최적의 하이퍼파라미터를 탐색하였다.

본 논문의 구성은 다음과 같다. 2장에서는 컨볼루션 신경망을 간략히 설명하고, 3장에서는 UCI 소나 데이터 구조와 본 논문에서 설계한 컨볼루션 신경망의 구조 및 분석 방법을 설명한다. 4장에서는 실험결과를 제시 및 분석하고, 5장에서 결론을 맺는다.

II. 컨볼루션 신경망

컨볼루션 신경망은 1989년 LeCun이 발표한 논문[9]에서 최초로 소개된 인공신경망 이론으로 기존 신경망 알고리즘과 달리 별도의 전처리(Pre-processing) 단계를 필요로 하지 않고, 특징 추출하는 단계가 내부에 포함되어 있어 원(Raw) 이미지에 대해 직접 연산이 가능하다는 장점을 가지고 있다. 컨볼루션은 신호처리에서

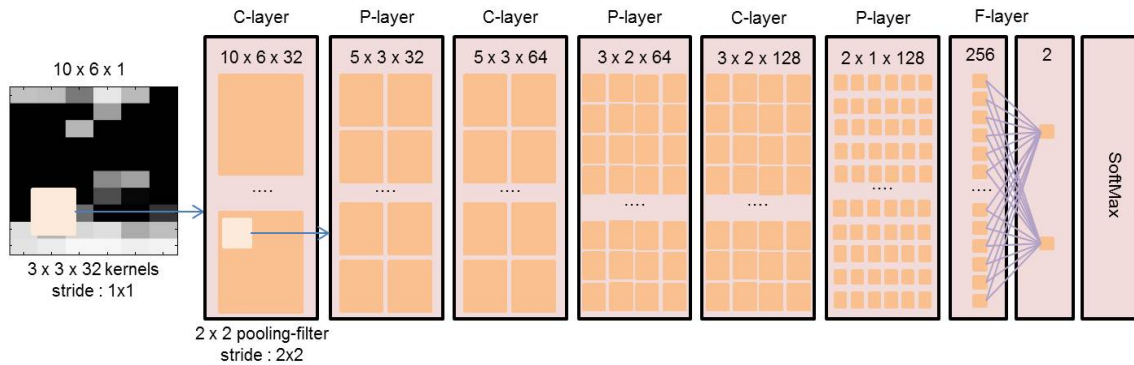


Fig. 1 Structure of convolutional neural network used in the experiment

주로 사용하는 이론으로써, 필터를 사용하여 주어진 이미지의 적절한 특징을 뽑아내기 위해 사용한다.

컨볼루션 신경망은 특징 추출을 하는 Convolution layer (C-layer), 특징 맵의 차원을 낮추는 Pooling layer (P-layer)와 분류를 수행하는 Fully connected layer (F-layer)로 구성된다. C-layer와 P-layer 과정을 여러 번 반복적으로 수행하여 지역 특징 (Local feature)으로부터 전역 특징 (Global feature)을 얻어낸다. C-layer는 임의의 이미지에서 국소적인 부분의 특징을 추출하기 위해 Layer와 Layer간에 모든 Connection을 연결하는 대신 일부만 연결하고, 컨볼루션 연산을 통해 특징을 추출한다. P-layer에서는 C-layer의 중요한 정보를 손실하지 않으면서 특징 맵 차원을 낮추는 역할을 한다. 샘플링을 할 때 최댓값을 추출하는 Max-pooling 방식과 평균값을 추출하는 Average-pooling 방식 등이 있고 일반적으로 Max-pooling을 많이 사용한다.

컨볼루션 신경망은 순전파 (Forward propagation)와 역전파 (Backpropagation)에 기반하여 작동하는데, 순전파는 입력데이터와 가중치 벡터를 이용하여 출력을 계산한다. 역전파는 출력과 희망출력 값의 오차에 비례하여 각 층의 가중치 벡터를 갱신한다. 갱신은 식 (1)과 같이 경사법 (gradient method)을 사용한다.

$$x_i = x_i - \eta \frac{\partial E}{\partial x_i} \quad (1)$$

식 (1)에서 x 는 가중치 벡터, η 는 학습률 (learning rate), E 는 손실함수 (Cost function)을 의미한다. 손실함

수는 교차 엔트로피 오차를 사용하며, 식 (2)와 같다.

$$E = - \sum_k t_k \log(y_k) \quad (2)$$

$$y_k = \frac{e^{x_i}}{\sum_i e^{x_i}} \quad (3)$$

식 (3)에서 x_i 는 최종 출력 뉴런의 값, i 는 뉴런 인덱스, y_k 는 분류에 대한 확률 분포를 나타내며 소프트맥스 (Softmax)라 한다. 식 (2)의 t_k 는 정답 레이블로, 정답에 해당되는 인덱스의 원소만 1이고 나머지는 0이다.

활성화 함수는 뉴런에서 임계값을 넘었을 때만 출력하는 부분을 표현한 것으로 계단 함수, 시그모이드 함수, Rectified Linear Unit (ReLU) 등의 방법이 있다.

컨볼루션 신경망에서는 Layer 구성이 정형화 되어 있지 않고 C-layer, P-layer, F-layer 순서와 개수에 따라서 성능이 결정되므로 최적의 Layer 설계 연구가 중요하다.

III. 실험대상 및 방법

3.1. 데이터 셋

본 논문에서 사용한 UCI 능동소나 데이터는 미국 캘리포니아대학의 UCI machine learning repository[7]에서 공개한 데이터이다. 해상에서 기뢰와 같은 금속 실린더와 실린더 모양의 바위를 대상으로 Linear

Frequency Modulated (LFM) 능동신호를 여러 각도에서 수신한 신호로써, 각 신호를 STFT (Short-time Fourier transform)을 취한 후, 주파수 대역에 대해 0에서 1 사이의 값으로 정규화 한 60차의 스펙트럼으로 구성된 특징벡터 데이터로 제공된다. 수신한 신호의 각도 범위는 금속 실린더는 0~90도, 바위는 0~180도 사이이다. 총 208개의 데이터 중 111개는 금속 실린더로부터의 반향신호이고, 97개는 바위로부터 얻어진 반향신호의 특징벡터로 구성되어 있다. 그리고 훈련데이터에 다양한 각도에서 수신된 신호가 고르게 분포되도록 [2]에서 훈련데이터와 시험데이터로 분류를 하였는데, 104개는 훈련데이터이고 나머지 104개는 시험데이터로 분류하여 데이터 셋에 표시 되어있다.

3.2. 설계한 컨볼루션 신경망 구조

본 논문에서 설계한 컨볼루션 신경망 구조는 Alexnet[10] 네트워크 구조를 기반으로 일부 변경하여 구성하였다. 입력 데이터 크기가 작고 훈련데이터 수가 적기 때문에 Alexnet 보다 Layer 층을 작게 하여 그림 1과 같이 설계하였다. 구현은 구글에서 제공하는 Tensorflow 라이브러리를 사용하였다. 컨볼루션 신경망은 일반적으로 2차원 이미지를 입력으로 사용하기 때문에, UCI 소나데이터의 1차원 특징벡터 60개를 2차원 구조인 10x6 구조로 변경하여 입력 데이터로 사용하였다. C-layer에서는 3x3 크기의 커널마스크를 사용하였고, Stride의 크기는 1, 특징 맵의 크기를 보존하기 위해 Zero padding을 사용하였다. P-layer에서는 2x2 크기로 Max-pooling 하고, Stride는 1로 하였다. F-layer의 가중치 벡터 초기화 방법은 He 초기화 방식[11]을 이용하였고, 은닉 뉴런은 256개를 사용하였다. 그리고 활성화 함수는 ReLu 함수를 사용하고, 과적합 (Overfitting) 방지를 위해 L2 정규화 (Regularization)와 Drop-out 방법 [12]을 이용하였다. L2 정규화는 손실함수 값을 정의할 때 여러 값에 가중치 벡터 값의 제곱을 더해주는 것이고, Drop-out은 학습 시에 은닉 층에서 랜덤하게 몇 개의 뉴런들만 사용하는 것이다.

본 논문에서는 Drop-out의 비율을 훈련 시에는 30%로 하고, 시험 시에는 0%로 하였다. 마지막 Layer에는 출력을 얻기 위해 Softmax 함수를 사용하였다. 가중치 벡터의 갱신을 위한 최적화 함수는 AdamOptimizer [13]을 사용하였다.

Table. 1 The range of hyperparameter value

Hyper-parameter	Min	Max	Default
Weight decay	0	0.1	0.001
Hidden unit	2	512	256
Batch size	1	5000	50
Learning rate	10 ^{^-6}	1	0.0001
Drop out ratio	0	50	30

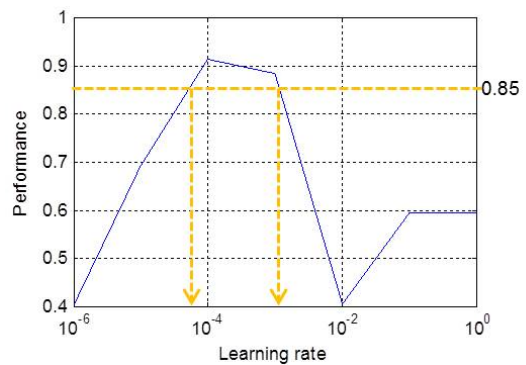


Fig. 2 Performance depending on learning rate. The plot uses 10 logarithmic scale for x-axis

3.3. 데이터 확장

데이터 확장은 데이터를 인위적으로 만들어 데이터의 수를 많게 하는 것으로, 이는 과적합 방지에 효과적이고 성능 향상에 도움이 된다[10]. 이미지 식별을 위한 신경망에서는 이미지를 좌우 반전하거나 일부를 잘라내는 방법[9] 등으로 확장하는데, 본 논문에서는 주파수 데이터의 크기 변환 후 노이즈를 더하는 방식으로 데이터를 확장을 하였다. 식은 다음과 같다.

$$x_i \times a + n_i \text{ where } i = 1, 2, \dots, 60 \quad (4)$$

식 (4)에서 x_i 는 주파수 Bin, i 는 주파수 Bin의 인덱스, a 는 스케일 변환 값으로 0.5~1사이의 값을 가진다. n_i 는 노이즈로써, 생성 방법은 시간 도메인에서 평균이 0이고 표준편차가 1인 정규분포를 가지는 랜덤 노이즈를 생성 후 60차수의 정규화 된 주파수 스펙트럼으로 변환한 값이다. 훈련데이터에만 UCI 소나데이터와 확장된 데이터를 섞어서 사용하였고, 시험데이터는 UCI 소나 데이터만을 사용하였다.

3.4. 분석 방법

데이터 확장이 성능에 미치는 영향을 조사하기 위해, 훈련데이터 증가 수를 다르게 하면서 성능의 변화를 조사하였다.

UCI 소나 데이터에서 하이퍼파라미터의 변화에 따른 성능의 변화를 분석하고, 이를 기반으로 최적의 하이퍼파라미터를 찾기 위한 탐색 알고리즘의 초기 입력 범위로 사용하였다. 조사한 하이퍼파라미터는 가중치 감소, 은닉 유닛 수, 배치 (Batch) 크기, 학습률, Drop out 비율로 총 5개이다. 표 1과 같이 하이퍼파라미터 값을 설정하여 조사하였다. 조사하고자 하는 하이퍼파라미터 값 크기를 Min에서부터 Max까지 점진적으로 증가시켰고, 조사하지 않는 하이퍼파라미터는 Default 값으로 고정하여 수행하였다. 시간 절약을 위해 Epoch를 100까지만 하고, 수행을 1번만 하였다. 그림 2와 같이 수행결과 성능이 85% 이상 되는 하이퍼파라미터 값의 Min, Max를 탐색 알고리즘의 초기 입력 범위로 사용하였다.

본 논문에서는 훈련데이터 내에서 20%를 검증데이터로 분리했고, 훈련데이터로 학습하고 검증데이터로 하이퍼파라미터의 성능을 평가하였다. 최적의 하이퍼파라미터를 찾은 다음, 시험데이터로 신경망의 범용 성능을 평가 하였다. 검증데이터를 사용하는 이유는, 시험데이터로 하이퍼파라미터를 조정하면 하이퍼파라미터 값이 시험데이터에 과적합 되기 때문이다.

신경망에서는 최적의 하이퍼파라미터를 찾기 위한 방법으로 그리드 탐색 (Grid search) 방법보다 랜덤 탐색 (Random search) 방법이 더 좋은 결과를 가져온다고 알려져 있다[8]. 그래서 본 논문에서도 랜덤 탐색을 사용하였고, 방법은 다음과 같다. 설정된 하이퍼파라미터 값의 범위 내에서 무작위로 값을 추출한다. 추출된 값을 이용하여 학습 후, 검증데이터로 성능을 평가한다. 평가된 결과를 기반으로 하이퍼파라미터의 범위를 좁힌다. 좁힌 범위 내에서 다시 무작위로 값 추출 후 성능 검증한다. 이 방법을 10번 반복하여 최적의 하이퍼파라미터를 설정하였다.

최종 성능을 측정할 때는 Epoch를 300으로 늘리고, 훈련데이터와 시험데이터를 Gorman과 Sejnowski 연구 [2]와 같이 2가지 방법으로 나누어 실험하였다. 첫째로는 수신각도에 독립적으로 랜덤하게 구성 된 192개의 훈련데이터와 16개의 시험데이터로 구성된 뒤, 13-fold

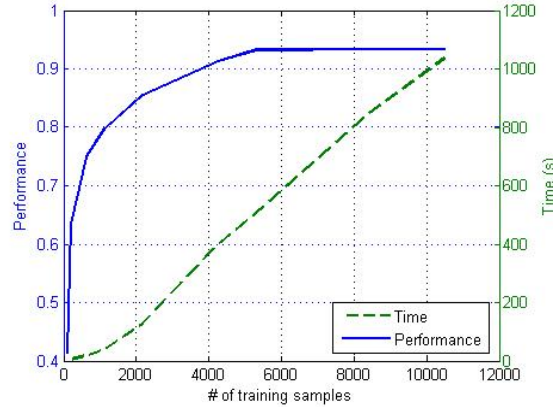


Fig. 3 Performance and training time depending on training samples

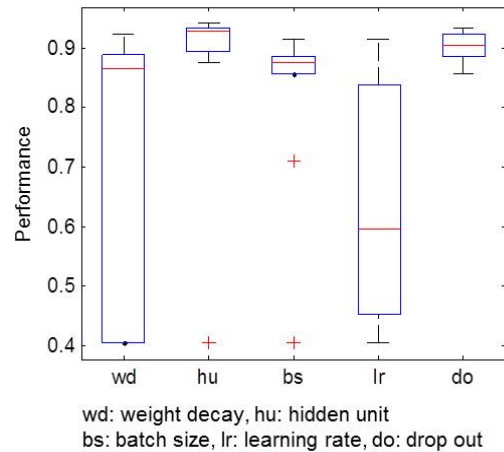


Fig. 4 Performance depending on hyperparameter value

cross-validation을 수행하여 식별 성능을 구했다[14]. 두 번째로는 다양한 각도에서 수신된 신호가 고르게 분포되도록 나누어진 훈련데이터 104개와 나머지 104개를 시험데이터로 구성한 뒤, 실험을 수행하였다. 첫 번째의 수신각도에 독립적인 경우는 랜덤하게 훈련데이터가 생성되기 때문에 다양한 각도에서 수신된 신호가 학습되기 어려울 수 있는 반면, 두 번째의 수신각도에 의존적인 경우는 다양한 각도에서 수신한 신호가 학습될 수 있다. 실험은 가중치 벡터의 초기 값을 다르게 하여 10번 수행 후 평균하여 성능을 구했다.

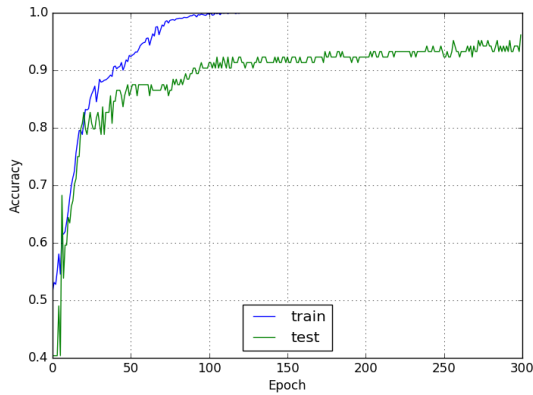


Fig. 5 Performance depending on epoch

Table. 2 Summary of the performance and standard deviation in parenthesis

	Aspect-Angle Dependent Series	Aspect-Angle Independent Series
Artificial Neural Network [2]	90.4% (1.8%)	84.7% (5.7%)
SVM [3]	93.27%	-
Proposed Method (CNN)	94.9% (0.79%)	88.9% (6.8%)

IV. 실험 결과 및 분석

4.1. 데이터 확장으로 인한 성능 변화

UCI 소나데이터에서 제공된 훈련데이터 104개로 약 10000개까지 데이터 확장을 하였고, 훈련데이터 수의 증가에 따른 성능 및 학습 시간의 변화는 그림 3과 같다. 훈련데이터 수가 증가함에 따라 성능이 향상되지만, 훈련데이터가 약 5300개 넘어가면 더 이상 성능이 향상되지 않았다. 데이터 확장 방법으로 만든 훈련데이터가 과적합 방지에 기여하여 성능이 향상되지만, 일정 수 이상의 확장된 데이터는 이미 만들어진 데이터와 큰 차이가 없는 비슷한 데이터라서 성능향상에 기여하지 못하는 것으로 추측된다. 그리고 훈련데이터 수가 증가함에 따라 학습 시간도 점진적으로 증가하였다. 학습이 끝나고 난 후의 테스트 셋의 분류 시간은 학습 시간에 비해 극히 작았는데, 약 10000개의 샘플을 분류하는데 걸린 시간은 약 0.56초였다. 학습하는데 많은 시간이 소요되지만, 학습이 끝난 이후에는 적은 시간으로 분류를

수행할 수 있었다.

4.2. 하이퍼파라미터 값에 따른 성능 변화

표 1의 하이퍼파라미터 값을 이용해서 얻은 성능은 그림 4와 같다. 은닉 유닛 수와 배치 크기 및 Drop out 비율 값의 변화보다 가중치감소와 학습률 값 변화에 따른 성능의 변화가 더 민감했다. 특히, 학습률은 작은 값의 변화에도 성능의 변화가 컸고 (그림 2 참조), 일정한 크기가 넘어가면 성능이 수렴하지 않고 발산하는 경향을 보였다.

4.3. 성능 및 타 알고리즘과 비교

랜덤 탐색으로 찾은 최적의 하이퍼파라미터를 이용한 성능은 그림 5와 같다. Epoch의 증가에 따라 성능도 점진적으로 증가하는 것을 볼 수 있다. 10번 수행하여 얻은 평균 성능은 표 2와 같이 훈련데이터가 수신 각도에 의존적인 경우와 독립적인 경우 각각 94.9%, 88.9% 이고, 표준 편차는 0.79%, 6.8%를 얻었다. 이전 연구에서 사용한 인공신경망[2], SVM[3]과 비교하면, 수신각도에 의존적인 훈련데이터의 경우에는 인공신경망과 SVM보다 각각 4.5% 포인트, 1.63% 포인트 향상되었고, 수신각도에 독립적인 경우는 인공신경망보다 4.2% 포인트 향상되었다. 수신각도에 독립적인 경우는 랜덤으로 형성된 훈련데이터와 시험데이터의 조합에 따라 성능의 변화가 커서, 표준편차가 수신각도에 의존적인 경우보다 크게 나왔다. 깊은 신경망은 학습데이터 수가 적을 때는 [2]와 같은 얇은 신경망과 SVM[3]과 같은 고전적 기계학습 알고리즘보다 낮은 성능을 가지지만, 일정 수 이상의 학습데이터를 가지게 되면 얇은 신경망과 고전적 기계학습 알고리즘보다 성능이 좋아지는 것으로 알려져 있다[15]. 그림 3에서 데이터 수가 [2,3]과 동일한 104개 일 때는 약 40%의 낮은 성능을 가지지만, 학습데이터 수가 증가할수록 성능이 향상되어 얇은 신경망과 SVM 보다 높아지는 것을 확인할 수 있다.

V. 결론

본 논문에서는 능동소나 데이터에 딥 러닝 알고리즘의 하나인 컨볼루션 신경망 적용을 제안하였고, 제안한 방법으로 기뢰와 같은 금속물체와 바위를 식별하는 실

험을 수행하였다. 컨볼루션 신경망은 2차원 이상의 데이터에 적용하므로 본 논문에서는 1차원 주파수 데이터를 2차원으로 변형하여 적용하였고, 그 결과 성능이 잘 나오는 것을 확인하였다. 또한 이미지에 주로 적용하던 데이터 확장 방법을 주파수 데이터에 적용해도 성능이 향상됨을 확인하였다. 랜덤 탐색 기법으로 찾은 하이퍼 파라미터를 사용하여 얻은 성능은 훈련데이터가 수신 각도에 의존적인 경우와 독립적인 경우 각각 94.9%, 88.9% 이었고, 이는 이전 연구에서 사용한 인공신경망과 SVM 알고리즘보다 식별성능이 최대 4.5% 포인트 향상되었음을 확인 할 수 있었다.

REFERENCES

- [1] J. W. Seok, T. W. Kim, and K. S. Bae, "Active Sonar Target Recognition Using Fractional Fourier Transform," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 17, no. 11, pp. 2505-2511, Nov. 2013.
- [2] 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.
- [3] J. H. Park, C. S. Hwang, and K. S. Bae, "Analysis of target classification performances of active sonar returns depending on parameter values of SVM kernel functions," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 17, no. 5, pp. 1083-1088, Nov. 2013.
- [4] J. W. Seok, T. H. Kim, and K. S. Bae, "Active Sonar Target Recognition Using Fractional Fourier Transform," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 17, no. 11, pp. 2505-2511, Nov. 2013.
- [5] H. Liu and L. Carin, "Class-based Target Classification in Shallow Water Channel based on Hidden Markov Model," *Proceedings of International Conference Acoustics Speech and Signal Processing*, vol. 3, pp. 2889-2892, 2002.
- [6] J. H. Seok, "Multi-aspect Based Active Sonar Target Classification," *Journal of Korea Multimedia Society*, vol. 19, no. 10, pp. 1775-1781, Oct. 2016.
- [7] Center for Machine Learning and Intelligent Systems. UCI Machine Learning Repository [Internet]. Available: <http://archive.ics.uci.edu/ml/index.html>.
- [8] J. Bergstra and Y. Bengio, "Random Search for Hyper-Parameter Optimization," *Journal of Machine Learning Research*, vol. 13, pp. 281-305, Nov. 2012.
- [9] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, "Backpropagation applied to handwritten zip code recognition," *Neural Computation*, vol.1, no.4, pp. 541-551, Dec. 1989.
- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Advances in Neural Information Processing Systems*, pp. 1097-1105, Dec. 2012.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification," in *Proceedings of the 2015 IEEE International Conference on Computer Vision*, Santiago, pp. 1026-1034, 2015.
- [12] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *Journal of Machine Learning Research*, vol. 15, pp. 1929-1958, Jun. 2014.
- [13] D. Kingma and J. L. Ba, "ADAM: A Method for stochastic optimization," *3rd International Conference for Learning Representations*, San Diego, pp. 1-15, 2015.
- [14] J. H. Kim, F. Bießmann, and S. W. Lee, "Decoding Three-Dimensional Trajectory of Executed and Imagined Arm Movements From Electroencephalogram Signals," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 23, no. 5, pp. 867-876, Sept. 2015.
- [15] A. Ng, "Nuts and bolts of building AI applications using Deep Learning," *Conference on Neural Information Processing Systems*, Tutorial, 2016.



김정훈(Jeong-Hun Kim)

2009년 한국항공대학교 전자 및 항공전자과 학사 졸업
 2014년 고려대학교 뇌공학과 석사 졸업
 2015년 1월~ 현재: ㈜ NIG넥스원 연구원
 ※관심분야 : 소나, 기계학습, 신호처리, 뇌-컴퓨터 인터페이스



최대성(Dae-Sung Choi)

2007년 경북대학교 컴퓨터공학과 학사 졸업
2008년 2월~ 현재: ㈜ LG넥스원 연구원
※관심분야 : 기계학습, 데이터과학, 소프트웨어공학



이형수(Hyung-Soo Lee)

2000년 경북대학교 공과대학 전자전기공학부 학사 졸업
2002년 경북대학교 대학원 전자공학과 석사 졸업
2009년 경북대학교 대학원 전자공학과 박사 졸업
2009년 1월~ 현재: ㈜ LG넥스원 연구원
※관심분야 : 수중음향신호처리, 표적탐지



이정우(Jeong-Hun Kim)

2007년 서강대학교 컴퓨터공학과 학사 졸업
2011년 서강대학교 컴퓨터공학과 석사 졸업
2011년 1월~ 현재: ㈜ LG넥스원 연구원
※관심분야 : 소나, 기계학습, 신호처리