

수중 OFDM 통신 환경에서 심층신경망을 이용한 채널 보상 기법

송태영*, 김용관°, 고학림*

Channel Equalization Using Deep Neural Network in Underwater OFDM Communication

Tae-Young Song*, Yong-Kwan Kim°, Hak-Lim Ko*

요 약

수중 통신 환경은 수온 및 다양한 환경 변수들에 의해서 음파의 전송 속도가 변하여 다중 경로가 발생하므로 통신 채널의 추정 및 보상이 용이하지 않다. 따라서 본 논문에서는 최근 각광을 받는 심층신경망을 이용하여 수중 OFDM 통신 환경에서 채널 보상 기법을 제안하고 그 성능을 기존의 기법과 비교하였다. 본 논문에서는 서해상의 수중 채널 환경을 Bellhop Ray Tracing 기법을 이용하여 모델링하였다. 모의실험으로부터, 심층신경망을 이용한 제안하는 채널 보상 기법을 기존의 LS 채널 추정 및 보상 기법과 비교한 결과, QPSK 심벌 블록의 256개의 심벌들 중에 128개 파일럿 심벌, 및 64개의 파일럿 심벌을 배치한 경우에서, 제안하는 기법이 기존의 LS 기법에 비하여 우수한 결과를 나타내었다. 또한, 제안하는 기법에서 파일럿 심벌을 사용하지 않은 경우의 성능이 기존의 LS 기법에서 64개의 파일럿 심벌을 사용한 경우와 비교하여도, 여전히 우수한 성능을 나타내었다. 이상으로부터 제안하는 심층신경망을 이용한 채널 보상 기법이 기존의 LS 기법에 비하여 매우 견실하며 우수한 성능을 나타냄을 알 수 있었다.

Key Words : Underwater Communication, Channel Estimation, Channel Equalization, Deep Neural Network, OFDM

ABSTRACT

In the underwater communication environment, since the propagation medium is water, multipath occurs due to the medium fluctuation, and the propagation speed changes due to the water temperature or the like, which makes it difficult to estimate the channel. In this paper, deep neural network based channel equalization technique is proposed when QPSK symbols are OFDM modulated and transmitted thorough the underwater channel environment. We modeled the underwater channel in the West Sea using the Bellhop Ray Tracing method. From the computer simulation, when 128 or 64 pilot symbols were allocated in a symbol block which consist of 256 symbols, the proposed scheme performed better than the conventional LS scheme. In a further experiment, the proposed scheme without any pilot symbols is still better than the LS scheme with 64 pilot symbols. As a result, we confirmed that the performance of the proposed deep neural network based channel equalization method is more robust and better than the existing LS scheme in underwater channel environment.

※ 이 논문은 2019년 해양수산부 재원으로 해양수산과학기술진흥원의 지원을 받아 수행된 연구임(분산형 수중관측 제어망 개발)

♦ First Author : Hoseo University Department of Information and Communication, amasc03@naver.com, 학생회원

° Corresponding Author : Hoseo University Department of Information and Communication, ykkim@hoseo.edu, 정회원

* Hoseo University Department of Information and Communication, hlko@hoseo.edu, 종신회원

논문번호 : 201902-465-A-RE, Received February 14, 2019; Revised May 12, 2019; Accepted June 24, 2019

I. 서 론

수중에서의 무선통신은 전자기파를 이용하는 육상과는 다르게 음파를 통해서 이루어진다. 수중 채널 환경은 전달 매질이 물로 이루어져 있으므로 수심, 수온 분포 및 염분 농도 등에 따라 신호의 전파 속도가 변화하고, 계절이나 기상 상태가 변함에 따라 매질에 변동이 발생해 도플러 효과와 다중 경로가 발생하고 신호의 변형이 일어난다^[1,2]. 이러한 이유로 수중 통신에서는 육상 통신보다 복잡한 채널 추정 과정과 정확한 보상이 이루어져야 신뢰성 높은 통신이 가능하다. 이와 같은 수중 채널에서는 고속 통신을 위해 서로 직교하는 다수의 부반송파(subcarrier)를 사용해 데이터를 고속 전송하는 OFDM(Orthogonal Frequency Division Multiplexing; 직교 주파수 분할 다중화)을 이용한 연구가 이루어지고 있다^[2,3]. 한편, 최근 자연어 처리, 자율주행, 컴퓨터 비전 등 다양한 분야에서 복잡한 문제를 해결하기 위해 심층신경망(deep neural network)을 이용하는 연구가 활발하게 이루어지고 있다^[4]. 또한 지상에서 심층신경망을 이용하여 채널 추정 및 보상하는 연구가 활발히 이루어지고 있다^[5,6]. 본 논문에서는 수중 OFDM 통신 환경에서 심층신경망을 이용한 채널 보상 기법을 제안하고, 그 성능을 기존에 널리 사용하는 LS(Least Square) 채널 추정 및 보상 기법^[3]과 비교하였다. 본 논문의 II장 본론의 1절에서는 모의실험을 위한 수중 채널 모델링에 대하여 설명하고, 2절에서는 수중 환경에서 OFDM 통신 시스템에 대하여 설명하고, 3절에서는 수중 OFDM 통신 환경에서 채널 보상 기법들에 대하여 설명한다. 이때, 3절의 1)항과 2)항에서는 각각 기존에 널리 사용하는 채널 추정 및 보상 방식인 LS 기법과 본 논문에서 제안하는 심층신경망을 이용한 채널 보상 기법을 설명한다. III장 실험에서는 수중 통신 환경에서 기존의 LS 기법과 제안하는 심층신경망 기반 기법의 성능을 비교 분석한다. 마지막 IV장에서는 결론을 서술하고 향후 연구 방향을 제시한다.

II. 본 론

2.1 수중 채널 모델

수중에서의 무선통신은 전자기파를 대신해 음파로 이루어지는데 그 이유는 육상에서 전자기파는 큰 제약 없이 장거리 전파가 가능하지만, 수중에서는 전자기파의 감쇠 손실이 크기 때문에 감쇠 손실이 매우 작은 음파를 이용한다^[1]. 수중 채널 환경은 전달 매질이

물로 이루어져 있으므로 수심, 수온 분포 및 염분 농도 등에 따라 신호의 전파 속도가 변화하고, 계절이나 기상 상태가 변함에 따라 매질에 변동이 발생해 도플러 효과와 다중 경로가 생기고 신호의 변형이 일어난다^[1,2]. 본 논문에서는 이러한 수중 채널 환경에서의 모의실험을 위해 한국 해양자료센터(KODC)에서 제공하는 서해(36°56'23.99N-126°0'0E)지점의 음속 및 수온 정보를 가지고 Bellhop Ray Tracing 기법으로 채널을 생성하여 사용하였다^[7]. 표 1은 위의 방식으로 생성한 수중 채널의 파라미터이다.

그림 1은 표 1의 해당 파라미터에서의 수중 채널 임펄스 응답 중 하나이다. 그림 1에서 가로축 샘플들은 0.2ms 샘플링 주기로 샘플되는 순서를 나타내고 세로축은 신호의 증폭률을 나타낸다.

수중에서 송신기와 수신기는 대체로 사이에 신호를 가로막는 물체가 없어 LoS(Line of Sight)가 존재한다. 따라서 본 논문에서 사용한 수중 채널 모델도 Bellhop 방식을 이용한 Rician 채널 모델을 이용하였

표 1. 수중 채널 파라미터
Table 1. Underwater channel parameter.

delay (ms)	0	0.06	1.5	1.56	1.67	6.33
Magnitu de	0.45	0.58	0.42	0.27	0.27	0.18
K factor	43.50	52.48	19.95	119.31	61.68	12.59
delay (ms)	6.39	6.61	6.67	14.39	14.50	14.78
Magnitu de	0.07	0.07	0.07	0.03	0.01	0.01
K factor	79.43	31.62	50.12	50.12	31.62	12.59




그림 1 수중 채널의 임펄스 응답의 예
Fig. 1. An example of underwater channel impulse response.

다^[7,8].

2.2 수중 채널의 OFDM 시스템

OFDM은 고속의 송신 신호를 다수의 직교하는 부반송파로 변조시켜 다중화하는 방식으로 부반송파 간에 간섭이 발생하지 않도록 시간축상에서 서로 직교(orthogonal)하게 한 것이다. 따라서 주파수축에서는 부반송파가 겹치게 되어 기존의 FDM(Frequency Division Multiplexing)보다 주파수 대역 효율이 높다^[3].

본 논문에서 사용한 OFDM 시스템은 그림 2와 같다. 먼저 연속적으로 입력되는 비트(bit)열 신호를 2비트 단위로 구분하여 QPSK(Quadrature Phase Shift Keying) 심벌(symbol)들로 변조한 후에 연속하는 N 개의 직렬 QPSK 심벌들을 병렬로 정렬하여 주파수 영역의 각 부반송파에 할당한다. 이러한 QPSK 심벌 블록(block)은 푸리에(Fourier) 역변환에 의해 시간 영역의 신호들로 변조된다. 이 과정의 수식은 다음의 식 (1)과 같다.

$$x(n) = \text{IFFT}(X(k)), n = 0, 1, 2, \dots, N-1$$

$$= \sum_{k=0}^{N-1} X(k)e^{j2\pi kn/N} \quad (1)$$

여기서 N 은 IFFT 크기를 의미하고, $X(k)$ 는 주파수 영역에서 k 번째 부반송파에 할당된 QPSK 심벌을 나타낸다. $x(n)$ 은 푸리에 역변환 후의 n 번째 시간영역 신호를 나타낸다. 다음으로, 주파수 영역의 QPSK 심벌들 간에 ISI(Inter Symbol Interference; 심벌 간 간섭)가 발생하는 것을 방지하기 위해 $x(n)$ 신호들에 CP(Cyclic Prefix)를 추가해준다. CP의 길이는 채널 모델의 최대 지연 탭 수 보다 길어야 한다. 그 수식은 식 (2)와 같다.

$$x_t(n) = \begin{cases} x(N+n), & n = -N_c - N_c + 1, \dots, -1 \\ x(n), & n = 0, 1, \dots, N-1 \end{cases} \quad (2)$$

여기서 N_c 는 CP 길이를 뜻한다.

송신부의 결과물인 송신 신호 $x_t(n)$ 은 순차적으로 통신 채널을 통해서 수신부로 전달된다. 본 논문에서는 Bellhop 채널 모델링 방식으로 생성된 수중 통신 채널을 사용하였다^[7]. 이때 채널의 최대 지연 탭수는 그림 1과 같이 80으로 정하였다. 하나의 탭은 샘플링




그림 2. OFDM 통신 시스템
Fig. 2. OFDM communication system.

주기 시간에 해당하므로, 본 논문에서 통신 채널에 의한 최대 지연시간은 물리적으로 16ms에 해당한다. 수신부에서 받게 될 수신 신호는 다음 수식 (3)과 같다.

$$y_t(n) = x_t(n) \otimes h(n) + w(n) \quad (3)$$

여기서 $h(n)$ 은 수중 채널의 CIR(Channel Impulse Response)을 나타내고, $w(n)$ 은 AWGN(Additive White Gaussian Noise) 잡음을 나타낸다. 통신 채널을 거쳐서 수신된 신호 $y_t(n)$ 에서 CP를 제거하여 $y(n)$ 를 구한 후에, 푸리에 변환을 통해서 주파수 영역의 QPSK 심벌들로 복조된다. 그 과정은 다음 수식 (4)와 같다.

$$Y(k) = \text{FFT}(y(n)), k = 0, 1, 2, \dots, N-1$$

$$= \frac{1}{N} \sum_{n=0}^{N-1} y(n)e^{-j2\pi kn/N} \quad (4)$$

여기서 $Y(k)$ 는 주파수 영역에서 복조된 수신 신호를 나타낸다. 만약 ISI가 발생하지 않았다고 가정하면, 복조된 수신 신호는 식 (5)와 같이 나타낼 수 있다.

$$Y(k) = X(k)H(k) + W(k) \quad (5)$$

여기서 $H(k)$ 는 CIR의 푸리에 변환이고, $W(k)$ 는 AWGN 잡음의 푸리에 변환이다. $H(k)$ 를 찾는 과정을 채널 추정이라고 한다. 추정된 채널을 이용하여 수신된 $Y(k)$ 로부터 채널 보상 과정을 거쳐 최종적으로 송신 신호 $X(k)$ 를 추정한다.

2.3 OFDM 시스템에서 채널 추정 및 보상 기법

OFDM 시스템은 광대역의 주파수 선택적 감쇠 채널 특성을 부반송파 별로 협대역의 주파수 비선택적

감쇠 채널 특성으로 바뀌어 주파수 선택적 감쇠에 강한 특성을 갖는다^{2,3,5,6}. 따라서 채널 추정과 그에 대한 보상은 그림 2의 OFDM 통신 시스템 수신부의 주파수영역의 QPSK 심벌들에 대하여 이루어진다.

2.3.1 LS 채널 추정 및 보상 기법

기존의 OFDM 시스템에서 채널 추정 기법에는 일반적으로 LS(Least Square) 기법 또는 MMSE(Minimum Mean Squared Error) 기법을 이용한다^{3,5,6}. LS 기법은 파일럿 심벌(pilot symbol)들을 이용하여 쉽게 채널을 추정할 수 있는 장점이 있어 널리 사용된다. 반면 MMSE 기법은 채널 및 잡음의 통계적 분산 특성을 정확히 아는 것을 가정하는 방법으로서 최적의 성능을 나타내는 것으로 알려져 있다. 그러나 실시간 수중 채널 환경에서 복잡도가 높아 적용상의 어려움이 있다³. 따라서 본 논문에서는 성능 비교 대상으로 LS 기법을 이용하였다. LS 기법을 설명하면 다음과 같다. OFDM 통신 시스템에서 수신된 QPSK 심벌 신호는 송신된 신호의 크기가 잡음에 비해 매우 크다면 수식 (6)과 같이 나타낼 수 있고, 채널은 수식 (7)과 같다.

$$Y(k) = X(k)H(k) \tag{6}$$

$$H_{LS}(k) = \frac{Y(k)}{X(k)} \tag{7}$$

수신부에서는 파일럿 심벌이 위치하는 k 번째 부반송파 채널을 식 (8)과 같이 추정한다.

$$H_{LS}(k) = \frac{Y_p(k)}{X_p(k)} \tag{8}$$

여기서 $X_p(k)$, $Y_p(k)$ 는 각각 k 번째 부반송파의 송신 파일럿 심벌과 수신된 파일럿 심벌을 나타낸다. 일반적으로 OFDM 시스템의 파일럿 심벌 배치 방법에는 block-type 과 comb-type이 있다³. 통신 채널의 상태가 느리게 변하는 경우에는 파일럿 심벌들로만 이루어진 QPSK 심벌 블록을 시간 영역에서 데이터 심벌 블록들 중간에 일정한 주기로 배치하여 전송하는 block-type 방법을 이용한다. 반면에 통신 채널의 상태가 빠르게 변하는 환경에서는 매 QPSK 심벌 블

록내의 주파수 영역에서 일정 부반송파 채널 간격으로 파일럿 심벌을 배치시키는 comb-type 방법을 이용한다. 데이터 심벌이 할당된 부반송파 채널을 추정하기 위해서는 식 (8)을 이용하여 미리 추정된 부반송파 채널들을 활용하여 시간 영역 또는 주파수 영역에서 다양한 보간법을 이용한다. 본 논문에서는 변화가 심한 수중 통신 채널 환경을 고려하여 comb-type 방법을 이용하였고, 보간 방법으로는 선형 보간법을 이용하였다^{2,3}.

2.3.2 심층신경망 기반 채널 보상 기법

심층신경망을 이루는 기본 요소인 인공 뉴런은 생물학적 뉴런을 수식으로 모사한다. 그림 3은 3개 입력과 하나의 출력을 갖는 인공 뉴런 구조의 한 예이다. 그림 3에서 인공 뉴런은 입력 값에 가중치(weight)들을 각각 곱한 후에 이들 값들과 함께 편향(bias)을 더하고 그 결과 값에 대하여 활성화 함수를 적용한다. 활성화 함수로서 비선형 함수를 이용하는 경우, 선형적인 문제뿐만 아니라 비선형적인 문제를 처리하는데 우수한 성능을 나타낸다⁴.

그림 4는 심층신경망 구조의 한 예를 나타낸다. 심층신경망은 그림 4에서와 같이 입력층(input layer)과 출력층(output layer) 그리고 그 사이에 은닉층(hidden layer)들로 구성된다. 입력층의 각 요소(element)들은 입력 값들을 나타낸다. 입력층을 제외한 각 층의 각




그림 3. 인공 뉴런 구조의 예
Fig. 3. An example of artificial neuron structure.




그림 4. 심층신경망 구조의 예
Fig. 4. An example of deep neural network structure.

요소(element)들은 그림 3과 같은 구조를 갖는 인공 뉴런들을 나타낸다. 화살표는 각 요소의 출력에서 다음 요소로의 입력을 나타낸다. 이러한 인공 뉴런들 간의 연결도 다양한 형태를 취할 수 있지만, 본 논문에서는 이전 계층 요소의 출력이 다음 계층의 모든 요소들로 입력되는, 그림 4와 같은 형태의 Fully Connected Layer 구조를 취하였다^{4,6)}.

심층신경망의 학습은 풀어내고자 하는 문제에 따라서 비용 함수(cost function)를 적절히 선택하고, 비용 함수의 기울기를 구하여 낮은 쪽으로 계속 이동시키는 경사 하강법(gradient descent)을 이용하여 비용 함수 값이 최소화되는 최적의 가중치(weight)와 편향(bias)을 찾는 과정이다. 이러한 과정을 그림으로 나타내면 그림 5와 같다⁴⁾.

본 논문에서 은닉층의 인공 뉴런 활성화 함수는 다루는 데이터의 값을 고려해서 [-1 1] 사이의 출력을 가진 tangent sigmoid를 이용하였고, 수식으로 표현하면 다음의 식 (9)와 같다.

$$tansig(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (9)$$

그림 6은 tansig 활성화 함수를 나타내고 있다.

그림 7은 본 논문에서 제안하는 심층신경망을 이용한 채널 보상 기법의 전체적인 구조를 나타낸다. 본 논문에서는 식 (1)과 식 (4)의 N 을 256으로 정하였다. 따라서 그림 7에서는 수신된 QPSK 심벌 블록의 256개 심벌 $Y(k)$ 들의 실수부와 허수부 512개 값들을 입





그림 5. 경사 하강법
Fig. 5. Gradient descent method.



Tan-Sigmoid Transfer Function

그림 6. Tangent sigmoid 활성화 함수
Fig. 6. Tangent sigmoid activation function.




그림 7. 심층신경망 기반 채널 보상 구조
Fig. 7. Deep neural network based channel equalization structure.

력하여, 송신된 256개 심벌 $X(k)$ 들의 실수부와 허수부 512개 추정 값들을 출력하는 전체 구조를 나타낸다. 그림 7에서 학습에 따른 복잡도를 줄이기 위하여 32개의 독립적인 심층신경망들을 이용하여 송신 QPSK 심벌 블록의 256개 송신 심벌들 중 각각 8개씩 분담하여 추정한다. 이때 QPSK 심벌들은 복소수이므로 심층신경망에서는 실수부와 허수부 값들을 구분하여 처리한다.

그림 7에서 32개 각각의 독립적인 심층신경망은 입력층과 3개의 은닉층 그리고 출력층으로 구성된다. 이때 학습에 따른 복잡도를 줄이면서 채널 보상 성능을 유지하기 위하여 입력층의 요소 개수를 많게 하고, 출력층으로 갈수록 요소 개수를 적게 구성한다. 그림 8은 그림 7에서 Network i ($i = 1 \sim 32$)로 표시된 32개 각각의 독립적인 심층신경망 구조를 나타내고 있다. 그림 7에서는 입력층에 해당하는 512개 입력값들이 나타나있고, 그림 8에서는 이러한 입력층과 Fully Connected Layer 구조로 연결되어있는 3개의 은닉층과 1개의 출력층을 나타내고 있다

그림 7에서의 입력층과 연결된 그림 8과 같은 독립적인 심층신경망에서, 수신 QPSK 심벌 블록의 256개




그림 8. 독립적인 심층신경망 구조
Fig. 8. Independent deep neural network structure.

수신 심벌 $Y(k)$ 들의 실수부와 허수부 512개 값들이 입력층으로 전달된 후에, 그림 8과 같이 각각 512개와 256개, 그리고 128개의 인공 뉴런들로 구성된 3개의 은닉층들을 순차적으로 거치고, 최종적으로 16개의 인공뉴런들로 이루어진 출력층에서 해당 심층신경망에서 담당하는 8개 송신 심벌의 실수부와 허수부 16개 추정 값들이 출력된다. 본 논문에서는 출력층에서 활성화 함수로 선형함수를 이용하였다.

256개 QPSK 입력 심벌들로 이루어진 입력층과 함께 연결된 그림 8과 같은 구조의 32개 독립적인 심층신경망은 각각 독립적인 학습 과정을 거친다. 각 심층신경망에서 학습 과정의 비용 함수로 MSE(Mean Squared Error) 함수를 선택하였고, 그 수식은 다음의 식 (10)과 같다.

$$MSE = \frac{1}{MK} \sum_{i=1}^M \sum_{k=1}^K (\hat{X}_i(k) - X_i(k))^2 \quad (10)$$

여기서 M 과 K 는 각각 학습 과정에 사용한 QPSK 심벌 블록의 개수와 QPSK 심벌 블록 중에서 해당 심층신경망이 담당하여 추정하는 송신 심벌의 개수이다. 본 논문에서는 50,000개의 QPSK 심벌들을 학습 데이터로 사용하였으므로 M 은 50,000/256에 해당하는 195가 되고, K 는 각 심층신경망 출력 개수인 16개가 된다. $\hat{X}_i(k)$ 와 $X_i(k)$ 는 i 번째 QPSK 심벌 블록 중 k 번째 부반송파에서, 각각 학습 중간 단계의 해당 심층신경망 출력값과 목표값으로 설정한 송신 심벌 값을 나타낸다.

학습 과정에서는 그림 5와 같은 경사 하강법을 이용한다. 이때, 주어진 50,000개의 학습 데이터를 이용

하여 학습이 1회 이루어지는 에포크(epoch)를 1회 iteration 으로 표시한다. 이때 경사 하강법(gradient descent method)을 이용하여 각 심층신경망 전체 인공 뉴런들의 가중치(weight)와 편향(bias)을 갱신하는 과정을 거친다^[4]. 이와 같은 iteration을 최대 20,000회 반복하여 그림 5에서와 같이 비용함수의 값이 국소 최소값을 찾아가도록 한다.

본 논문의 심층신경망기반 채널 보상 기법에서는 파일럿 심벌의 비율에 따라 각각 따로 학습을 진행하였다. QPSK 심벌 블록의 256개 심벌들 중에 파일럿 심벌이 각각 0개, 64개, 128개 일정 간격으로 배치되는 경우, 매 8개 심벌들 중에 0개, 2개 및 4개의 파일럿 심벌들이 일정한 간격으로 배치되는 것과 같다. 예를 들면, 64개 파일럿 심벌을 사용하여 학습하는 경우, 각 심층신경망에서는 수신된 256개의 QPSK 심벌들이 입력되고, 2개 파일럿 심벌이 일정 간격으로 배치된 8개 송신 심벌들이 목표 값으로 설정되어 학습이 진행된다.

본 논문에서는 위와 같은 3가지의 파일럿 배치 비율에 따른 학습과 함께, 32개의 독립적인 신경망을 학습하였다. 이 경우, 학습하여야 할 심층신경망은 96개로 매우 많아진다. 따라서 본 논문에서는 각 SNR에 해당하는 AWGN 잡음에 따른 상황까지 학습하는 경우 그 복잡도는 기하급수적으로 많아지는 현실적인 상황을 고려하여, 심층신경망 학습 과정에서는 AWGN 잡음이 포함되지 않은 온전한 모의 다중 경로 페이딩 채널만을 고려하였다.

마지막으로 심층신경망의 적용 단계에서는, 학습 단계를 거친 32개의 독립적인 심층신경망들 각각에서 수신된 QPSK 심벌 블록의 256개 심벌들을 입력으로 받고, 각각 담당하는 8개의 송신 QPSK 심벌들을 추정하여 출력한다.

III. 실험

본 논문에서는 OFDM 통신 시스템 환경에서 제안하는 심층신경망 기반 채널 보상 기법과 기존에 널리 사용하는 LS 채널 추정 및 보상 기법의 성능을 비교하였다. 모의실험에 사용한 수중 OFDM 통신 시스템 구조는 그림 2와 같고, OFDM 시스템의 파라미터는 표 2와 같다.

본 논문의 모의실험에서 채널 부호화 기법은 따로 사용하지 않았다. 각 채널 보상 기법들의 비트 오류율(BER : Bit Error Rate)을 얻기 위하여, 불규칙하게 생성된 비트들을 이용하여 심층신경망의 학습에 사용

표 2. OFDM 시스템 파라미터
Table 2. OFDM system parameter.

Parameter	Value
Bandwidth	5kHz
Modulation	QPSK
No. of subcarrier	256
No. of Cyclic Prefix	113

된 50,000개의 QPSK 심벌들과는 별개의 20,000개의 송신 데이터 QPSK 심벌들을 구성하였다. 이러한 데이터 심벌들에 미리 준비된 파일럿 QPSK 심벌들을 일정 간격으로 배치하고 이것들을 256개씩 모아서 QPSK 심벌 블록들을 구성하였다. 이들 QPSK 심벌 블록들을 OFDM 통신 시스템에서 각 SNR에 해당하는 AWGN 잡음을 포함하는 모의 다중 경로 페이딩 채널에 통과시켜서 수신부에 전달하였다. 수신부에서는 채널 보상 과정을 통해 추정된 송신 데이터 심벌들을 출력한다. 위와 같은 실험을 반복함으로써 실제로 송신된 데이터 심벌들과 추정된 송신 데이터 심벌들로부터 비트 오류율의 평균을 구하였다. 이때 모의 다중 경로 페이딩 채널은 II장 1절에서 설명한 음속 및 수온 정보에 따라 결정된 표 1의 파라미터 값들을 가지고 Bellhop Ray Tracing 기법을 이용하여 매 QPSK 심벌 블록마다 불규칙하게 생성시켜 적용하였다⁷⁾.

본 논문에서 심층신경망 학습에 사용한 하드웨어의

표 3. 모의실험 컴퓨터 사양
Table 3. Computer simulation specification.

CPU	i7-7700
Main Board	ASUS H110M-C HDMI
RAM	DDR4 16G
VGA	GeForce 1080Ti Super Jetstream
O/S	Windows 10 Pro

표 4. GeForce 1080Ti Super Jetstream 상세 사양
Table 4. GeForce 1080Ti Super Jetstream specification.

Base Clock	1556 MHz
Boost Clock	1670 MHz
CUDA Cores	3584
Memory Amount	11GB GDDR5X
Memory Clock	11000 MHz
Memory Interface	352bit
Graphics Card Power	300W

사양은 다음의 표 3 및 표 4와 같다.

한편, 본 논문에서는 Matlab사의 Deep Learning Toolbox를 심층신경망 학습에 사용하였다. 그림 9와 그림 10은 각각 컴퓨터 모의실험에서 반복 학습 과정과 종료 과정을 보여준다.

그림 9에서 한 개의 독립적인 심층신경망을 학습하는데 걸리는 시간은 최대 20000번 반복했을 때 약 3시간 정도 소요되었다. 그림 10에서는 100번 반복할 동안 식 (10)에서의 MSE 값이 줄어드는 성능 향상이 없으면 학습을 종료하는 경우 약 1시간 정도 소요되었다.

그림 11은 LS 채널 추정 및 보상 기법에서 파일럿 심벌 개수에 따른 성능을 비교하고 있다.

송신 QPSK 심벌 블록의 256개 송신 심벌들 중에

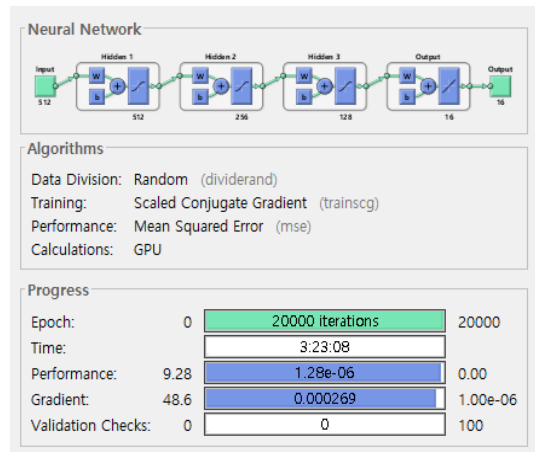


그림 9. 20000회 반복 학습
Fig. 9. 20000 training iteration.

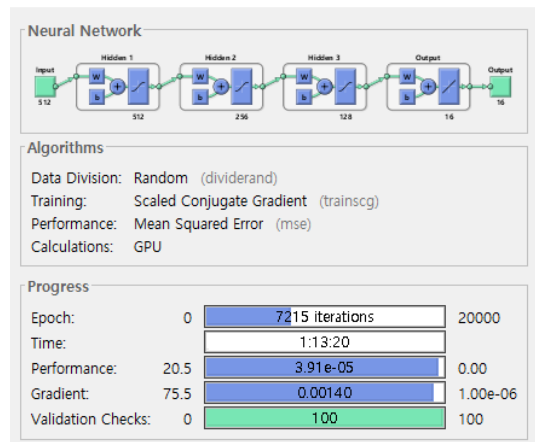


그림 10. Validation 도달 학습 종료
Fig. 10. Training stop at validation.




그림 11. LS 채널 추정 및 보상 기법에서 파일럿 심벌 개수에 따른 성능 비교
 Fig. 11. Performance of LS method for each number of pilot allocation.

서 각각 0개, 32개, 64개, 128개의 파일럿 심벌들을 데이터 심벌들 사이에 일정 간격으로 배치하여 실험한 결과들로부터 비트 오류율 성능을 비교하였다. 그림 11에서 파일럿 심벌을 배치하지 않은 경우에는 채널 보상이 이루어지지 않으므로 그 성능이 매우 열악하여 SNR이 증가함에 따라 비트 오류율은 약 0.2에 수렴하였다. 32개 파일럿 심벌을 배치한 경우에는 비트 오류율이 0.05에, 64개 파일럿 심벌을 사용한 경우에는 0.013에, 128개의 파일럿 심벌을 배치한 경우에는 0.0015에 각각 수렴하였다.

위의 결과들로부터 LS 채널 추정 및 보상 기법을 이용하는 경우, 파일럿 심벌의 개수가 많아질수록 비트 오류율 성능이 향상되는 것을 확인할 수 있었다. 일반적으로 널리 사용되는 LS 채널 추정 및 보상 기법에서, 심벌 블록 내에서 채널의 필터 탭수 보다 많은 개수의 파일럿 심벌을 부반송파에 할당해 주어야 채널의 상태를 충분히 추정해낼 수 있다. 만약 채널 탭수 보다 적은 파일럿 심벌을 할당해 주면 채널 추정 성능에서 열화가 심하게 발생한다⁹⁾.

본 논문에서는 수신단에서 수중 채널의 AWGN 잡음 특성을 모르는 것을 가정한 제한적인 상황을 가정하였다. 이러한 상황에서, LS 기법과 제안하는 심층신경망 기반 기법의 성능을 상대적으로 비교함으로써, 심층신경망 기법의 가능성을 검토하고자 하였다.

그림 12에서는 본 논문에서 제안하는 심층신경망 기반 채널 보상 기법과 LS 채널 추정 보상 기법의 성능을 비교하였다.

먼저 송신 QPSK 심벌 블록의 256개 송신 심벌들

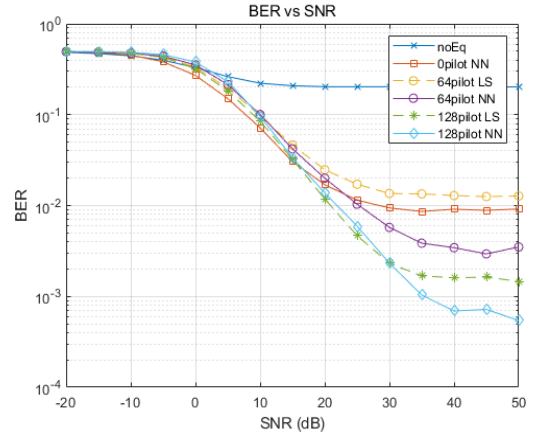


그림 12. LS 기법과 심층신경망기반 기법 성능 비교
 Fig. 12. Performance comparison of the LS method and the deep neural network based method.

중에서 128개의 파일럿 심벌을 할당해 주는 경우, 제안하는 신경망 기반 채널 보상 기법을 사용한 경우 비트 오류율이 0.0006에 수렴하여, 0.0015에 수렴한 LS 채널 추정기법 보다 우수한 성능을 나타내었다. 또한 그림 12로부터 제안하는 심층신경망 기반 기법에서 파일럿 심벌의 개수가 0개, 64개, 128개로 늘어날수록 그 성능이 좋아지는 것을 확인할 수 있었다. 또한 그림 12로부터, 제안하는 심층신경망 기반 기법에서 파일럿 심벌을 사용하지 않는 경우의 성능이 64개의 파일럿 심벌을 사용하는 LS 기법보다도 우수한 성능을 나타내었다.

이러한 결과들로부터 제안하는 심층신경망 기반 채널 보상 기법이 파일럿 심벌이 없는 경우에도 송수신 데이터들로부터 학습을 통하여 채널의 통계적 특성을 일정부분 파악하여 채널을 보상하는 능력이 있음을 확인할 수 있었다.

위의 실험 결과들로부터 동일한 개수의 파일럿 심벌이 할당된 경우, 제안하는 심층신경망 기반의 채널 추정 기법이 기존의 LS 추정 기법보다 우수한 성능을 나타냄을 확인할 수 있었다. 또한 파일럿 심벌이 없는 경우에도 제안하는 기법이 기존의 LS 기법에 비하여 강인한 채널 보상이 이루어져 우수한 성능을 나타낼 수 있었다.

IV. 결론

최근 여러 가지 어려운 문제를 해결하는데 있어서 심층신경망을 이용하는 연구가 늘어나고 있다. 수중 채널 환경에서는 전달 매질이 물이기 때문에 매질 변

동에 의해 다중 경로가 발생하고, 수은 등에 의해 전파 속도가 변해 채널을 추정하는데 어려움이 있다. 본 논문에서는 심층신경망을 이용해 수중 채널 환경에서 채널을 보상하는 알고리즘에 대한 연구를 수행하였다. 모의실험은 서해의 수중 환경을 Bellhop Ray Tracing 기법으로 모사한 채널을 생성하여 진행하였다. 본 논문에서는 다수의 독립적인 심층신경망을 사용하여 채널을 보상하는 기법을 제안하고, 기존에 널리 사용하는 LS 채널 추정 및 보상 기법과 그 성능을 비교하였다. QPSK 심벌 블록의 256개 심벌들 중에 64개 및 128개의 파일럿 심벌을 할당해 주었을 때, 심층 신경망 기반 채널 보상 기법이 기존의 LS 기법보다 더 좋은 성능을 내는 것을 확인하였고, 추가로 이루어진 실험에서 파일럿 심벌을 할당하지 않고 온전히 데이터 심벌들로만 이루어진 QPSK 심벌 블록을 사용해 학습시킨 심층신경망기반 기법이 64개 파일럿 심벌을 사용하는 기존의 LS 기법 보다 그 성능이 우수함을 확인할 수 있었다. 본 논문에서는 심층신경망 기반 채널 보상 기법에서 학습에 따른 복잡도를 고려하여 AWGN 잡음이 없는 경우만을 고려하여 학습하였지만, 앞으로 AWGN 잡음을 포함하여 학습하는 경우 추가적인 성능 향상이 있을 것으로 예상된다.

References

[1] J. W. Choi, S. H. Kim, S. W. Son, and S. M. Kim, "Properties of underwater acoustic communication channels in time-varying ocean environment," *Inf. and Commun. Mag.*, vol. 33, no. 8, pp. 52-62, Jul. 2016.

[2] T.-H. Lim and H.-L. Ko, "Physical layer description for underwater acoustic communications," *Inf. and Commun. Mag.*, vol. 33, no. 8, pp. 63-70, Jul. 2016.

[3] T. S. La, Y. I. Jun, W. J. Lee, and T. J. Park, "Channel estimation techniques for OFDM systems," *Electron. and Telecommun. Trends*, vol. 21, no. 6, pp. 124-132, Dec. 2006.

[4] C. C. Aggarwal, *Neural Networks and Deep Learning*, Springer, 2018.

[5] H. Ye, Y. Li, and B. Juan, "Power of deep learning for channel estimation and signal detection in OFDM systems," *IEEE Wireless Commun. Lett.*, vol. 7, pp. 114-117, no. 99, Feb. 2018.

[6] Y. W. Lee, D. Kwon, J. H. Park, and D. K. Kim, "Channel estimation using deep learning in wireless communication systems," in *Proc. KICS Winter Conf.*, pp. 877-878, Jan. 2018.

[7] M. B. Porter, "*The Bellhop manual and user's guide*," Retrieved Oct. 30, 2018, from <http://oalib.hlsresearch.com>.

[8] Paul C. Etter, *Underwater acoustic modeling and simulation*, CRC Press, 2018.

[9] R. Negi and J. Cioffi, "Pilot tone selection for channel estimation in a mobile OFDM system," *IEEE Trans*, vol. CE-44, no. 3, pp. 1122- 1128, 1998.

송 태 영 (Tae-Young Song)



2017년 2월 : 호서대학교 정보통신공학과 졸업
 2019년 2월 : 호서대학교 정보통신공학과 석사
 2019년 3월~현재 : 미국이민 <관심분야> 인공지능, 통신공학

김 용 관 (Yong-Kwan Kim)



1988년 2월 : 서울대학교 제어계측공학과 공학사
 1990년 2월 : 서울대학교 제어계측공학과 공학석사
 1996년 8월 : 서울대학교 제어계측공학과 공학박사
 1997년 3월~현재 : 호서대학교 정보통신공학과 정교수
 <관심분야> 신호처리, 인공지능, 통신공학

고 학 립 (Hak-Lim Ko)



1983년 2월 : 숭실대학교 전자
공학과 졸업

1986년 2월 : Fairleigh Dickinson
Univ. 전기 및 컴퓨터공학과
석사

1995년 8월 : North Carolina
state Univ. 전기 및 컴퓨터
공학과 박사

1996년~현재 : 호서대학교 정보통신공학부 교수
<관심분야> 배열신호처리, 이동통신, 수중통신