

인체 통신에서 다중 접속을 위한 Autoencoder 기반 전송 파형 최적화 및 다중 노드 검파

황성준*, 박재현°, 홍준표*, 이훈*

Autoencoder-Based Transmission Waveform Design for Non-Orthogonal Multiple Access and Multi-Node Detection in Human Body Communication

Seong-Jun Hwang*, Jaehyun Park°, Jun-Pyo Hong*, Hoon Lee*

요약

본 논문은 인체를 통신 매체로 활용하는 인체통신(human body communication, HBC) 환경에서 다수의 웨어러블 센서들의 정보를 데이터 컬렉터 또는 허브에 전송하는 다중접속 시스템을 고려한다. Point-to-point 인체통신 시스템과 시분할 다중접속 (time division multiple access, TDMA) 방식이 적용된 기존의 인체통신 시스템과 달리 본 논문에서는 autoencoder 기반 딥러닝 학습 기법을 활용하여, 비직교 다중접속 (non-orthogonal multiple access, NOMA) 방식을 위한 전송 파형 최적화 및 다중 노드 검파 기법을 제안한다. 특히 인체통신 특성상 다중 노드들과 데이터 컬렉터와의 떨어진 거리에 따른 손실이 다른 환경에서 전송파형을 최적화하면서 노드들의 전력 최적화를 위한 신경망 구조를 제시한다. 또한 다중 노드 검파 성능 개선을 위한 NOMA 환경에서 간섭제거 학습에 용이한 신경망 구조를 제시하고자 한다. 모의 실험을 통해 인체 통신 환경에서의 제안한 autoencoder 기반 다중 노드 검파 기법의 성능을 검증하였다.

Key Words : Multi-node Human Body Communication, AutoEncoder, Body Area Network

ABSTRACT

In this paper, we consider human body communication (HBC) that exploits the human body as a communication medium, where multiple wearable sensors transmit their sensed data to a data collector or hub. Unlike conventional HBC in which a point-to-point HBC is extensively investigated, we utilize an autoencoder(AE)-based deep learning technique to propose new transmission waveform optimization and multi-node detection schemes for non-orthogonal multiple access (NOMA) in HBC. The proposed AE-based detection schemes can learn how to make transmit waveforms and allocate the transmit power to improve the multi-node detection performance in the multi-node HBC. In addition, we also propose a neural network structure that can efficiently learn the interference cancellation in the NOMA to improve multi-node detection performance. Through simulations, we verify the performance of the proposed AE-based multi-node detection methods in multi-node HBC.

※ 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2018R1D1A1B07043786).

♦ First Author : Pukyong National University, Department of Electronics Engineering, never9898@naver.com, 학생회원

° Corresponding Author : Pukyong National University, Department of Electronics Engineering, jaehyun@pknu.ac.kr, 종신회원

* Pukyong National University, Department of Information and Communication Engineering, 정회원

논문번호 : 202003-059-B-RN, Received March 20, 2020; Revised April 27, 2020; Accepted April 27, 2020

I. 서론

최근 여러 가지 센서를 이용한 헬스케어 기기 및 웨어러블 기기에 대한 관심이 커지고 있다^{1,2}. 이들 기기들의 수집한 데이터 및 제어용 데이터를 전송하기 위해 RF 신호를 활용한 무선 통신 기술을 활용할 수 있지만, RF 신호 변복조 등의 과정에서 많은 전력이 소모되는 문제점이 있다. 최근 이러한 문제를 해결하기 위해 전도성을 갖는 인체를 전송 매체로 활용하여 데이터 송수신을 하는 인체통신 (human body communication, HBC)기술에 대한 연구가 많이 이루어지고 있다²⁻⁴. 이 HBC 기술은 무선 통신 기술에 비해 RF 소자들이 필요 없어 저전력, 저비용의 장점을 가지고 있으며, 보안 측면에서도 기존 무선통신 기술에 비해 우수함을 보이고 있다. 하지만 대부분의 인체통신 기술의 경우 point-to-point (P2P) 통신 환경을 고려하여 데이터를 송수신하는 전송 기술에 대한 연구가 이루어졌다^{4,5}. 특히 최근에는 autoencoder (AE) 기반의 P2P 인체 통신 파형 최적화 및 검파 기법이 제안되었다⁶. 하지만 착용하는 웨어러블 기기의 개수가 늘어나고 요구되는 전송 데이터량이 높은 환경에서는 증가하는 간섭량으로 인해 기존 전송 기술은 성능 제약이 따르게 된다.

본 논문에서는 다중 노드 HBC 환경에서 AE기반 전송 파형 최적화 및 다중 노드 검파 기법을 제안한다. 구체적으로 P2P 인체통신 시스템과 시분할 다중 접속 (time division multiple access, TDMA) 방식이 접목된 기존의 인체통신 시스템과 달리 본 논문에서는 AE기반 딥러닝 학습 기법을 활용하여, 비직교 다중접속 (non-orthogonal multiple access, NOMA) 방식을 위한 전송 파형 최적화 및 다중 노드 검파 기법을 제안한다. 특히 인체통신 특성상 다중 노드들과 데이터 컬렉터와의 떨어진 거리에 따른 손실이 다른 환경에서 전송파형을 최적화하면서 노드들의 전력 최적화를 위한 신경망 구조를 제시한다. 또한 다중 노드 검파 성능 개선을 위한 NOMA 환경에서 간섭제거 학습에 용이한 신경망 구조를 제시하고자 한다. 즉, 다중 노드 환경에서는 각 송신 신호들은 수신단에서 서로 간섭으로 작용하게 되므로 각 센서 노드들의 신호를 검파한 후 이를 다른 노드 신호를 검파하는 신경망 입력으로 넣는 형태의 새로운 신경망 구조를 제안한다. 구체적으로 병렬적으로 검파한 노드들의 신호를 다시 검파하는 신경망의 입력으로 넣어 간섭을 제거하는 형태의 신경망 구조를 제안한다. 이를 통해 기존의 신경망 보다 간섭제거 학습에 용이하여 우수한 성

능을 가질 수 있다. 또한 제한한 구조의 계산 복잡도를 줄이기 위해 순차적 간섭 제거 기반의 심층 신경망을 제안한다. 특히, 끝으로 모의 실험을 통해 인체 통신 환경에서의 제안한 AE기반 다중 노드 검파 기법의 성능을 검증하였다.

이 논문의 2장에서는 본 논문에서 사용한 시스템 모델을 소개한다. 3장에서는 AE 기반 전송 신호 최적화 및 다중 노드 검파 기법을 제안한다. 4장에서는 모의실험 결과를 확인하고 5장에서는 결론을 맺는다.

II. 시스템 모델

2.1 인체통신 시스템 모델

본 논문에서는 그림 1과 같이 다수의 센서 노드가 데이터 컬렉터 1개로 수집 데이터를 전송하는 통신 환경 고려한다. 이때 각각의 노드들은 2개의 전극을 가지고 있으며, 하나는 접지된 상태에서 또 다른 하나는 인체에 접촉되어 신호를 전송하는 capacitive coupling 방식을 고려한다.

전송 방식은 IEEE 802.15.6의 물리계층 표준과 호환되는 FSDT 방식을 고려한다⁷. FSDT에서는 Walsh code에 기반한 대역 확산 방식을 취하고 있는데, 이는 전송신호를 채널 잡음과 유사한 같은 신호로 확산시켜 정보 신호에 대한 보안성을 높이며 안정적인 데이터 송수신을 하기 위함이다⁸. 즉, 그림 2와 같이 구체적으로 FSDT 방식에서는 4bit를 길이 16 chip들을 가지는 Walsh code를 활용해서 변환한 뒤, 전송 속도 (164, 328, 656, 1312, 2624, 5250 kbps)에 따라 추가적인 주파수 선택코드 (frequency selective code, FSC)를 곱해 1024, 512, 256, 128, 64, 32 chip 길이를 가지는 chip 시퀀스로 변환하여 대역을 확산하여 출력 전송 속도는 42Mcps로 고정되도록 하여 전송한다. 예를 들면, 328kbps의 전송속도를 내기 위해서 입력 4bit를 Walsh code를 곱한 뒤에는 1.312Mcps가




Fig. 1. HBC system with multi-node sensors




Fig. 2. FSDT structure

되며 추가적인 32bit FSC를 곱하게 되면 42Mcps의 전송 신호를 생성해낼 수 있다. 본 논문에서는 전송속도에 상관없이 같은 길이로 곱해지는 Walsh code 기반 파형을 최적화하는데 초점을 맞춘다. 하지만 이는 서로 다른 전송속도를 가지는 FSC 최적화로 쉽게 확장이 가능하다.

2.2 인체통신 채널 모델

IEEE 802.15.6에 따르면 채널 모델은 인체 내 지방 및 근육 등의 인체 내 전도 특성과 전송 거리에 따른 전송 손실을 모델링한 것으로써, 인체 채널의 impulse response는 다음과 같이 주어진다^[6].

$$h(t) = \left[A_v A e^{-(t-t_r)/t_0} \times \sin\left(\frac{\pi(t-t_r-x_c)}{w}\right) \right] C_h \quad (1)$$

$$C_h = (0.0422G_T - 0.184)(0.078G_R + 0.782) \times \left(\frac{120.49/d_{\text{body}}}{1 + (d_{\text{air}}/d_{\text{body}})^5} \right)^2 \quad (2)$$

여기서 주요 파라미터는 다음과 같이 정리할 수 있다. 그림 3은 수식(2)에 따른 normalized channel impulse response를 나타내고 있다. 참고로 본 논문에서 고려하는 IEEE 802.15.6의 물리계층 표준에 따르면, 4개의 bit를 16개의 chip으로 변환하므로 전송속도가 1.312Mbps일 때, chip 전송속도는 4배인 5.248Mcps의 전송속도를 가지게 된다. 따라서 chip period는 대략 0.2μsec가 된다. 따라서 그림 3으로부터 0.2μsec의 chip 길이에 걸쳐 무시할 수 없는 채널 응답을 가지는 것을 확인할 수 있으므로, 본 논문에서는 Two-ray channel model을 가정한다. 따라서 수신 신호의 i 번째 chip 샘플은 다음과 같이 나타낼 수 있다.

$$y_{rx}[i] = \sum_{n=1}^N \sum_{l=0}^1 h_{nl} x_n[i-l] + \nu[i] \quad (3)$$

여기서 $x_n[i]$ 는 n 번째 노드에서 보낸 i 번째 chip 신호가 되며, $\nu[i]$ 는 수신단에서의 additive white Gaussian noise (AWGN) 잡음을 나타낸다.

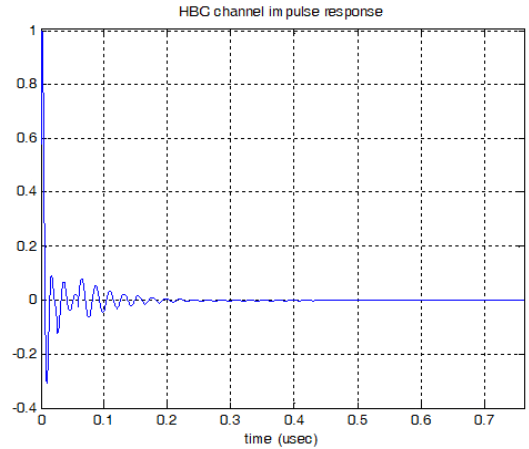


Fig. 3. Human body channel impulse response

III. Autoencoder 기반 전송파형 최적화 및 다중 노드 검파 기법

3.1 기존 단일 노드 P2P Autoencoder 기반 전송 파형 최적화

논문 [6]에서 단일 노드 기반 송수신기 파형 최적화를 위한 AE 기법을 제안하였다. 그림 4는 AE를 이용한 시스템 모델을 나타냈다. 즉 4bit 메시지 m ($m = 1, \dots, 16$)을 16차원의 one-hot encoded vector e_m 로 변환하여 송신단의 deep neural network (DNN)을 거쳐게 된다. One-hot encoded vector e_m 는 m 번째 원소만 1이고 나머지 원소는 모두 0인 벡터로 송신하고자 하는 정보 m 을 표현한다. 이후 HBC 채널을 거친 뒤 수신단에서 DNN을 거쳐 메시

표 1. HBC 채널의 주요 상수 파라미터
Table 1. Main parameters for HBC channel

Time range(μs)	A	t_r	t_0	x_c	w
$0 \leq t < 0.025$	0.00032	0.00000	0.00621	-0.00097	0.00735
$0.025 \leq t < 0.058$	0.00003	0.02500	0.01684	-0.01225	0.00944
$0.058 \leq t$	0.00002	0.05800	0.05610	0.00100	0.01109




Fig. 4. AE structure for P2P HBC

지 \hat{m} 을 추정한다. AE 기법을 통해 송수신단의 DNN을 훈련시켜 송신 메시지 m 에 대해 수신단의 \hat{m} 사이의 차이가 최소가 되도록 한다.

AE의 송신단은 송신 신호 벡터 \mathbf{x} 를 출력하도록 설계된다. Power normalization 계층에서는 송신 신호 전력 P_{tx} 가 되도록 전력을 정규화한다. 이 계층의 출력 신호 \mathbf{x} 와 \mathbf{x}_{in} 의 관계는 다음과 같이 나타낼 수 있다.

$$\mathbf{x} = \frac{\sqrt{P_{tx}}}{\|\mathbf{x}_{in}\|} \mathbf{x}_{in} \quad (4)$$

송신 신호 벡터 \mathbf{x} 는 HBC 채널을 거치고, AE 수신단은 채널 출력 벡터 \mathbf{y} 를 활용하여 송신 메시지를 추정한다. Softmax 활성화수를 통해 각 메시지 m 이 전송되었을 사후확률 $p(m|\mathbf{y})$ 을 표현하며, 최종 추정 값 \hat{m} 는 사후확률이 가장 높은 메시지인 $\hat{m} = \operatorname{argmax}_m p(m|\mathbf{y})$ 로 계산된다. AE의 학습을 위해 실제 송신 메시지 m 에 해당하는 one-hot encoded vector \mathbf{e}_m 과 수신단에서 계산한 사후확률 $p(m|\mathbf{y})$ 간의 categorical cross-entropy (CE)가 손실 함수로 활용된다. Categorical CE는 다음과 같이 정의된다.

$$CE = - \sum_{m=1}^{16} \log p(m|\mathbf{y})$$

3.2 다중 노드 기반 HBC 환경에서 AE 기반 전송 파형 최적화 및 다중 노드 검파 기법

본 절에서는 다중 노드 기반 HBC 채널에서 다중 노드의 송신 파형과 허브의 수신 검파기를 최적화하기 위해 AE 기법을 제안한다. 그림 5와 같이 M 개의 송신 노드가 있을 때 n 번째 송신 노드는 m_n 의 4bit 메시지를 one-hot encoded vector로 변환하여 Digital-to-analog converter (DAC)를 거쳐 채널을 통해 인체 채널로 신호를 내보낸다. 수신단에서는 중첩된 다중 신호를 받아 decoder 망에 전달하면 이를 바탕으로 각 사용자의 신호를 검파하게 된다. 수신기는 모든 송신 노드 $n = 1, \dots, M$ 의 송신 메시지에 대한 사후확률 $p(m_n|\mathbf{y})$ 을 추정하도록 설계한다.

이때 송수신 DNN 학습을 위한 손실함수로 CE를 활용하였으며 다음과 같이 주어진다.

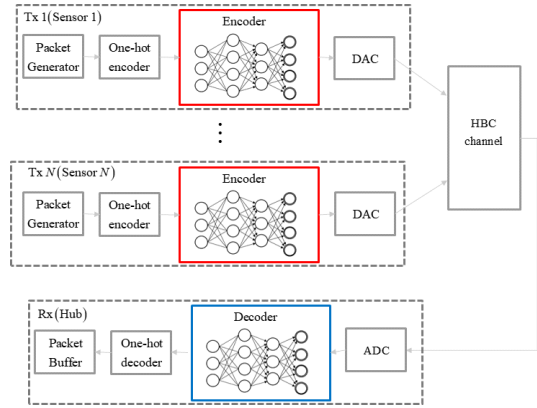


Fig. 5. AE-based multi-node HBC system

$$CE = \sum_{n=1}^N w_n CE_n \quad (5)$$

여기서 w_n 은 n 번째 사용자에 대한 CE 가중치를 나타내며, CE_n 은 n 번째 사용자의 CE로써 다음과 같이 표현할 수 있다.

$$CE_n = - \sum_{m=1}^{16} \log p(m_n|\mathbf{y})$$

따라서 그림 6과 같이 다중 노드 기반 송신 파형 최적화와 다중 노드 검파를 위한 심층 신경망은 수식 (5)를 최소화하도록 학습할 수 있다. 즉, 이는 3.1절의 단일 노드 환경의 심층 신경망을 각 사용자 별 CE를 정의하여 이들의 weighted sum을 최소화하도록 확장한 형태이다. 참고로 노드별 데이터의 중요도에 따라 가중치를 달리 둘 수 있으며, 노드의 가중치를 높여

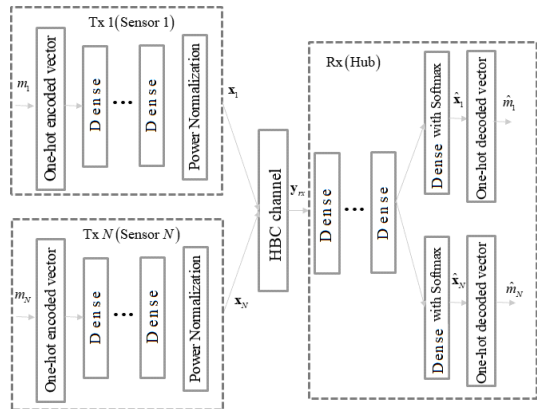


Fig. 6. AE structure for Multi-node HBC

해당 노드의 심층 신경망 손실이 적게 발생하도록 학습을 유도할 수 있다. 즉 손실이 적을수록 해당 노드의 데이터 검파 오차가 적어질 수 있다.

3.3 개선된 간섭 제거 기반 다중 노드 검파 위한 심층 신경망

본 절에서는 3.2절에서 제안하는 다중 노드 HBC 환경에서 AE 기반 심층 신경망의 성능을 개선시키기 위한 새로운 신경망 구조를 제안하고자 한다. 우선 다중 노드 환경에서는 각 송신 신호들은 수신단에서 간섭으로 작용하게 되므로 그림 6에서 각 송신단에서 전력을 정규화 하는 과정(수식 (4))을 다음과 같이 수정한다면, 각 송신 신호의 필요 전력을 줄이는 동시에 다른 센서 노드들의 신호 검파 과정에 간섭을 줄이는 효과를 낼 수 있다.

$$\mathbf{x} = \begin{cases} \mathbf{x}_{in} & \|\mathbf{x}_{in}\|^2 \leq P_{tx} \\ \frac{\sqrt{P_{tx}}}{\|\mathbf{x}_{in}\|} \mathbf{x}_{in} & \text{Otherwise} \end{cases} \quad (6)$$

수신단에서는 수신 신호로부터 다중 센서 신호를 검파하여야 하기 때문에 수신 신호들간의 상관성을 고려하여 신호 분리 및 검파에 용이한 convolutional neural network (CNN)을 활용하여 검파하였다. 즉, 송신단 (encoder) 쪽은 DNN을 수신단 (decoder) 쪽은 CNN 구조를 따르는 DCNN 구조를 활용하여 검파하였다. 또한, 기존의 다중 신호 검파 기법에서 잘 알려진 간섭 신호 제거 기법을 심층 신경망이 학습할 수 있다면 검파 성능이 개선될 수 있다. 이를 반영한 송수신 파형 최적화 및 다중 노드 검파 심층 신경망은 그림 7과 같다. 즉, 그림 7에서 붉은색 상자의 경우 첫 번째 사용자를 제외한 노드들의 신호를 일차적으로 추정한 뒤, 이 출력과 수신신호를 다시 푸른색 상자의 CNN의 입력으로 넣는 구조로 신경망을 구성해 훈련하였다. 훈련과정에서 푸른색의 CNN 상자에서는 수신신호에서 일차적으로 추정한 신호들을 활용하여 수신신호에서 간섭 효과를 줄일 수 있도록 하여 학습을 용이하게 한다.

또한, 수신단의 계산 복잡도를 감소시키기 위해 위와 같이 모든 노드들의 신호를 일차적으로 추정하여 간섭을 제거하는 구조 (말하자면, parallel interference cancellation, PIC 구조)가 아닌 노드 별로 순차적으로 검파하여 다음 노드의 신호를 검파하는데 입력으로 넣어 간섭을 제거하는 구조 (말하자면, successive

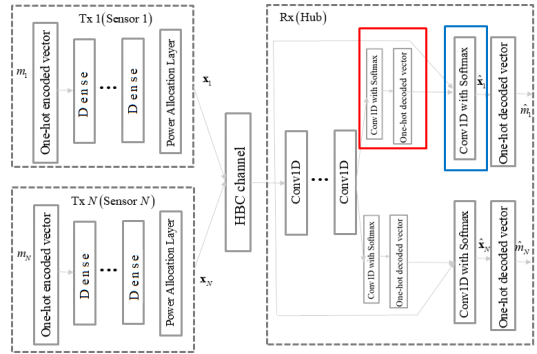


Fig. 7. PIC enabled AE structure for multi-node HBC

interference cancellation, SIC 구조)를 제안하며, 이는 그림 8과 같이 나타낼 수 있다.

이 경우 먼저 검파한 신호에서 오차가 발생할 경우 이후 검파 과정에 오차가 전파될 수 있다 (즉, error propagation 효과). 따라서 이를 해결하기 위해 수신 신호의 path-loss 정보에 기반하여 검파 순서를 결정하도록 하여 신경망을 최적화하였다. 참고로 인체 통신 환경에서도 노드의 부착된 위치 및 송신 거리에 따른 path-loss 정보는 long-term fading 정보로써 시간에 따라 빠르게 변하지 않기 때문에 송수신단 모두 알고 있다고 가정한다.

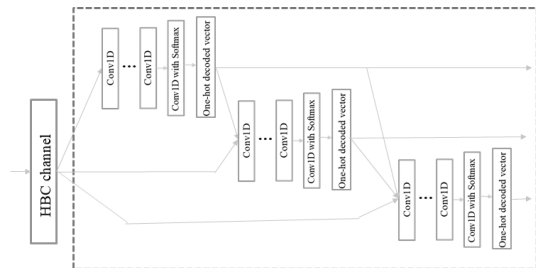


Fig. 8. SIC enabled AE structure for multi-node HBC

IV. 모의실험 결과

본 절에서는 모의실험을 통해 3개의 센서 노드와 하나의 데이터 컬렉터(Rx)로 구성된 시스템에서 block error rate (BLER)를 비교하였다. 신경망은 batch size를 64로 설정하고 epoch을 1500으로 설정하여 학습하였으며, optimizer는 Adam을 사용했다. 데이터 훈련을 위해 수신 SNR이 14dB인 환경을 가정하였고 w_n 은 모두 0.3으로 설정하였다.)) 각각의

1) 참고로 각 SNR별로 훈련하여 훈련된 심층 신경망 모델을 각

센서 노드로부터 수신단까지의 평균 채널 이득은 각각 [0.2 1 5]의 값을 가지도록 설정하였다. 또한, 수식 (3)과 같은 Two-ray channel model을 활용하였으며, 그림 3으로부터 첫 번째 다중경로 탭과 두 번째 다중경로 탭의 상대적인 크기는 평균적으로 10배 정도의 차이를 가진다고 설정하였다. 초기 학습률 (learning rate)는 0.005로 설정하였으며, 학습 도중에 손실함수가 개선되지 않는다면 학습률을 낮추도록 설정하였다. 또한 손실함수는 수식 (5)를 활용하였으며, 가중치는 모든 사용자가 같은 값을 가지며 0.3으로 설정했다. 각 센서 노드에서는 4비트를 입력으로 받아 16개의 원소를 가지는 One-hot encoded vector를 입력으로 받는 입력층 1개, 2개의 은닉층(입력차원:32)을 가지는 DNN 신경망을 구성하였다.

그림 9에서는 그림 6의 구조와 같이 모든 사용자가 NOMA 방식으로 접속하는 환경에서 파형 최적화를 수행한 경우에 대한 성능을 나타내었다. 제안하는 다중 접속방식의 성능 비교를 위해 심층 학습 기법이 적용되지 않은 기존의 선형 검파 기법과 [6]에서 제시한 P2P 인체 통신에 적용된 DNN 구조를 TDMA 방식을 접목한 방식의 성능을 함께 나타내었다. 그림 9에서 확인할 수 있듯이, 48(=16x3) chip period 동안 센서 노드 별로 시간 자원을 16 chip 씩 직교하도록 전송하는 방식에 비해 48 chip period 동안 NOMA 방식과 파형 최적화를 수행하여 학습한 신경망의 검파 성능이 우수함을 확인할 수 있다.

그림 10에서는 3.3절의 개선된 간섭 제거 기반 다중 노드 검파 위한 심층 신경망의 성능을 비교하였다. 각 노드는 4bit를 16 chip period 동안 전송하도록 전송 파형을 최적화하였으며, 각각의 센서 노드로부터 수신단까지의 평균 채널 이득은 각각 [0.1 1 5]의 값을 가지도록 설정하였다. 비교를 위해 그림 6의 DNN 방식의 성능을 함께 나타내었다. 그림에서 확인할 수 있듯이 전반적으로 개선된 DCNN 구조가 그림 6의 DNN보다 우수한 성능을 가지는 것을 확인할 수 있으며, PIC 구조가 가장 낮은 BLER을 나타내고 있다. 그리고 붉은색 실선은 SIC의 구조의 성능을 나타내고 있는데, 높은 SNR에서 성능이 크게 개선되지 않는 것을 확인할 수 있다. 이는 검파 과정에서 경로 손실에 따른 순서에 상관없이 검파하였는데, 이 경우 검파 과

SNR별 검파 성능을 평가할 때 활용하여도 되지만, 이는 학습의 일반화측면에서 바람직하지 못하기 때문에 본 논문에서는, 관심 성능 평가 SNR영역에서의 전형적인 SNR값으로 14dB를 선택하였다. 하지만, 이는 관심 성능 평가 SNR영역에 따라 달리 설정할 수 있다.

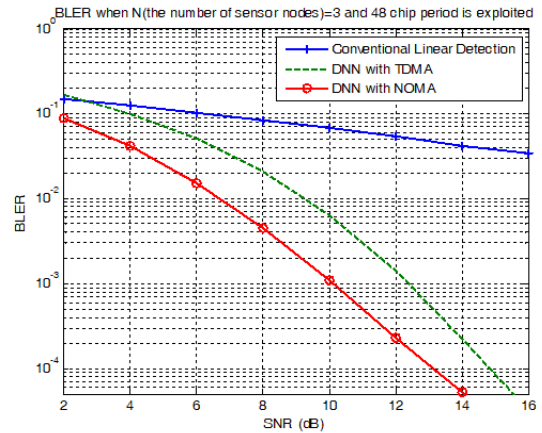


Fig. 9. BLERs of DNN with TDMA and DNN with NOMA

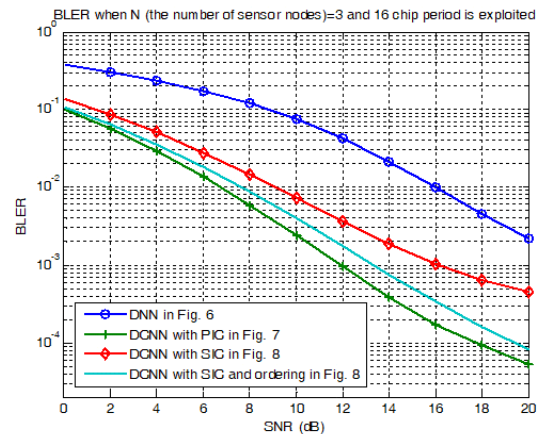


Fig. 10. BLERs of various neural network structures

정의 오차가 전파되어 성능이 포화 (saturation) 되어 BLER이 더 낮아지지 않음을 확인할 수 있다. 반면 경로 손실이 가장 적은 순서대로 검파한 ordering 기법을 적용한 하늘색의 실선은 PIC 구조에 가까운 성능을 나타내고 있다. 즉 ordering을 통해 그림 8의 SIC 구조의 단점인 검파 과정의 오차 전파를 최소화하여, PIC 구조와 비슷한 성능을 가지면서 PIC 구조에 비해 적은 계산 복잡도 및 계산 시간을 가질 수 있다.

기존의 DNN 기반 전송 기법 [6]과 제안하는 DCNN 방식의 복잡도 비교를 위해 epoch 1회 당 소요된 평균 훈련 시간 및 BLER 시험 평균 계산 시간을 표 1에 비교하였다. 계산 시간 평가는 CPU 3.4GHz, 메모리 16GB, GPU 8GB의 사양을 가지는 컴퓨터를 활용하였다. 표에서 확인할 수 있듯이 평균 훈련 시간의 경우 기존의 DNN with TDMA에 비해

표 2. Epoch 1회당 소요된 평균 훈련 (training) 시간 및 BLER 시험 (evaluation) 계산 시간
Table 2. Training time per epoch and BLER evaluation time per channel use

전송 기법	DNN with TDMA [6]	DCNN with PIC	DCNN with SIC
Training time per Epoch	5.36 sec	7.06 sec	6.49 sec
BLER Evaluation time per channel use	5.00 usec	4.01 usec	3.83 usec

서 제안하는 NOMA 방식의 DCNN 구조가 전반적으로 높은 계산 시간을 소요하고 있으며, PIC에 비해서 SIC 구조가 적은 계산 시간을 대략 8.1% $(= (7.06 - 6.49) / 7.04)$ 단축할 수 있음을 확인할 수 있다. BLER 시험 계산 시간의 경우도 SIC 구조가 PIC 구조에 비해 적은 계산 시간을 소요하고 있다. 흥미로운 점은 DNN with TDMA의 경우 시험 계산 시간이 다른 두 구조에 비해 많이 소요되고 있는데, 이는 TDMA의 경우 각 노드 별로 시간 자원을 나눠 순차적으로 송수신이 이루어지는 반면, NOMA의 경우 동시에 보내고 받는 구조로 구현되어, TDMA의 경우 오히려 더 많은 시간을 요구됨을 확인할 수 있다.

그림 11은 PIC 기반 AE 구조의 신경망을 학습할 때 epoch 증가에 따른 손실을 나타내었다. 이때 학습률은 0.00001로 설정하였으며, 데이터 훈련을 수신 SNR이 14dB인 환경을 가정하였고 w_n 은 모두 0.3으로 설정하였다. epoch이 증가함에 따라 손실이 감소하는 것을 확인할 수 있으며 구체적으로 100의 epoch부터 서서히 손실이 감소함을 확인할 수 있다. 참고로




Fig. 11. Weighted sum of CE for DCNN with PIC in Fig. 7

학습률의 변화에 따른 손실 overshoot 현상을 확인할 수 있었는데, 이를 없애기 위해서는 학습률을 작게 설정하여 overshoot 현상을 없앨 수 있다. 그림 12는 SIC 기반 AE 구조의 신경망을 학습할 때 epoch 증가에 따른 손실을 나타내었다. PIC와 비슷한 경향성을 띠는 것을 확인할 수 있었으며, 상대적으로 그림 11의 PIC 기반 AE 구조에 비해 손실함수가 더 높게 나오는 것을 확인할 수 있다.

그림 13은 노드의 개수를 2, 3, 4개로 달리 두었을 때 그림 8의 SIC 구조 기반 DCNN 기법의 BLER을 비교하였다. 세 경우 모두 각각의 센서 노드로부터 수신단까지의 평균 채널 이득은 동일한 값 1로 설정하였다. 그림에서 확인할 수 있듯이, 사용자의 수가 늘어남에 따라 BLER의 성능이 열화되는 것을 확인할 수 있다.




Fig. 12. Weighted sum of CE for SIC with ordering in Fig. 8

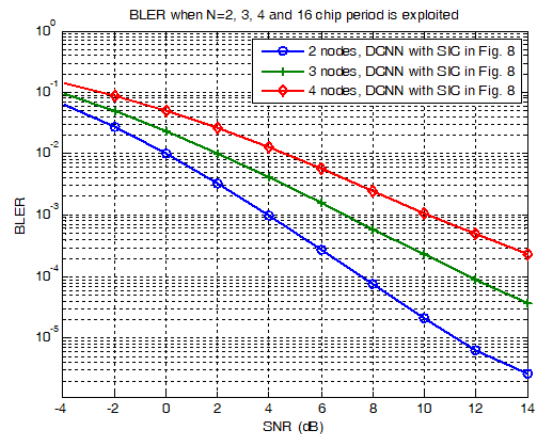


Fig. 13. BLERs of various numbers of nodes when DCNN with SIC is exploited

V. 결 론

본 논문은 다중 노드 HBC 환경에서 AE 기반 전송 파형 최적화 및 다중 노드 검파 기법을 제안하였다. 특히 다중 노드들이 서로 직교한 자원에 기존 P2P 인체 통신 전송 기법을 활용해 전송하는 기술에 비해 제안한 기법을 비직교 다중 접속 방식과 접목하여 전송할 때 우수한 성능을 보임을 모의실험을 통해 확인하였다.

또한 다중 노드 HBC 환경에서 AE 기반 심층 신경망의 다중 노드 검파 성능을 개선시키기 위해 송신단 전력 제어 및 간섭 신호 제거 기법을 학습하기 용이한 심층 신경망 구조를 제안하였으며, 모의 실험을 통해 성능을 검증하였다. 특히 SIC 기반 심층신경망의 경우 검파 순서 조절을 통해 SIC 구조의 단점인 검파 과정의 오차 전파를 줄여, PIC 기반 심층 신경망 구조와 비슷한 성능을 가지면서 PIC 구조에 비해 적은 계산 복잡도를 가질 수 있음을 모의실험을 통해 검증하였다.

References

[1] A. Lymberis, "Smart wearables for remote health monitoring, from prevention to rehabilitation: Current R&D, future challenges," *4th Int. IEEE EMBS Special Topic Conf. Inf. Technol. Appl. in Biomed.*, pp. 272-275, Birmingham, UK, 2003.

[2] S. Kim, et al., "Trends of human body communications in WBAN," *Electron. and Telecommun. Trends*, vol. 31, no. 6, pp. 31-38, 2016.

[3] S. Maity, M. He, M. Nath, D. Das, B. Chatterjee, and S. Sen, "Bio-physical modeling, characterization, and optimization of electro-quasistatic human body communication," *IEEE Trans. Biomed. Eng.*, vol. 66, no. 6, pp. 1791-1802, Jun. 2019.

[4] S. Maity, D. Das, B. Chatterjee, and S. Sen, "Characterization and classification of human body channel as a function of excitation and termination modalities," *2018 40th Annu. Int. Conf. IEEE Eng. Med. and Biology Soc. (EMBC)*, pp. 3754-3757, Honolulu, HI, 2018.

[5] C. Hyoung, S. Kang, and S. Park,

"Transceiver for human body communication using frequency selective digital transmission," *ETRI J.*, vol. 34, no. 2, Apr. 2012.

[6] A. Ali, K. Inoue, A. Shalaby, M. S. Sayed, and S. M. Ahmed, "Efficient autoencoder-based human body communication transceiver for WBAN," in *IEEE Access*, vol. 7, pp. 117196-117205, 2019.

[7] H. Cho, H. Lee, J. Bae, and H. Yoo, "A 5.2mW IEEE 802.15.6 HBC standard compatible transceiver with power efficient delay-locked-loop based BPSK demodulator," *2014 IEEE A-SSCC*, pp. 297-300, KaoHsiung, 2014.

[8] D. Das, S. Maity, B. Chatterjee, and S. Sen, "Enabling covert body area network using electro-quasistatic human body communication," *Scientific Reports*, vol. 9, no. 1, 2019.

황 성 준 (Seong-Jun Hwang)



2020년 2월 : 부경대학교 전자공학과 학사
 2020년 3월~현재 : 부경대학교 전자공학과 석사 과정
 <관심분야> OFDM, 통신공학, 사물인터넷, MIMO radar

박 재 현 (Jaehyun Park)



2003년 2월 : KAIST 전기 및 전자공학과 학사
 2010년 2월 : KAIST 전기 및 전자공학과 박사
 2010년~2013년 : 한국전자통신연구원, 선임연구원
 2013년~2014년 : Imperial College

London, Research Associate
 2014년~현재 : 부경대학교 부교수
 <관심분야> 다중안테나 기반 통신 신호처리, 동시 전력 및 정보 전송 기술, 인지무선기술
 [ORCID:0000-0001-5327-9111]

홍 준 표 (Jun-Pyo Hong)



2008년 2월 : 한국정보통신대학교 전자공학과 학사

2010년 2월 : KAIST 전기 및 전자 공학과 석사

2014년 2월 : KAIST 전기 및 전자 공학과 박사

2015년 : 한국전자통신연구원, 연구원

2015년~현재 : 부경대학교 부교수

<관심분야> 이동통신시스템, 무선캐시네트워크, 기계학습

[ORCID:0000-0001-7478-8513]

이 훈 (Hoon Lee)



2012년 2월 : 고려대학교 전기전자전파공학부 학사

2017년 2월 : 고려대학교 전기전자전파공학과 박사

2017년~2018년 : 고려대학교 정보통신기술연구소, 연구교수

2018년~2019년 : Singapore University of Technology and Design, Postdoctoral Fellow

2019년~현재 : 부경대학교 조교수

<관심분야> 통신 네트워크 최적화, 딥러닝 기반 분산 컴퓨팅

[ORCID:0000-0003-0753-8324]