

천공된 극 부호를 위한 딥 러닝 기반 복호기의 학습 방법

서은영*, 최연준*, 김종환**, 김상호^oTraining Method of Deep Learning-Based Decoder
for Punctured Polar CodesEun Young Seo*, Yeon Joon Choi*, Jong-Hwan Kim**, Sang-Hyo Kim^o

요약

최근 선형 부호에 대한 다양한 딥 러닝(deep learning) 구조의 복호기가 제안되었으며, 극 부호에 적용된 전방 전달 신경망 구조의 복호기는 충분히 학습된 경우 최적의 성능에 근접하는 것을 보였다. 하지만 기존 연구에서는 극 부호의 길이 호환성을 위한 천공(puncturing) 기법의 적용을 고려하지 않고, 모부호만을 이용하여 성능 비교가 이루어졌다. 따라서 본 논문에서는 천공 기법이 적용된 극 부호에 대한 기존 신경망 복호기의 성능을 확인하고, 천공된 부호를 효율적으로 학습하는 기법을 제안한다.

Key Words : deep learning, channel coding, polar codes, deep neural network(DNN), puncturing scheme

ABSTRACT

Recently, various decoders with deep learning structures for linear codes have been proposed, and a decoder with feedforward neural network structure for polar codes has been shown to be near-optimal performance when sufficiently learned. However, in the previous research, performance was evaluated by only mother code without considering puncturing scheme for length-compatibility of polar codes. Therefore, in this paper, we show the performance of existing neural network decoder for punctured polar codes and propose a training method to efficiently learn punctured polar codes.

1. 서론

최근 다양한 선형 부호의 복호 기법에 딥 러닝(deep learning)을 적용한 연구들이 진행됨에 따라 여러 구조의 신경망 복호기(neural network decoder: NND)가 제안되었다¹⁻⁴⁾. 이러한 신경망 복호기는 충분히 학습되었을 때 짧은 부호 길이에서 최적의 복호

성능에 근접할 수 있었다. 이에 [1-4]에서 제안된 신경망 복호기를 간단히 소개한다.

합-곱 알고리즘(sum-product algorithm)을 이용하는 신뢰 전파(belief propagation) 복호의 반복 구조를 기반으로 한 신경망 복호기가 [1]에서 제안되었고, 이를 BCH (Bose-Chaudhuri-Hocquenghem) 부호에 적용한 성능을 제시하였다. 또한, [2]에서는 이 구조에

※ 본 연구는 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었습니다. [18ZF1100, 다점대다점 환경에서 이론적 한계 도달을 위한 무선전송기술 개발]

• First Author : (ORCID:0000-0001-6625-903X) Department of Electrical and Computer Engineering, Sungkyunkwan University, enyung61@skku.edu, 학생회원

◦ Corresponding Author : (ORCID:0000-0002-0660-5516) Department of Electrical and Computer Engineering, Sungkyunkwan University, iamshkim@skku.edu, 종신회원

* (ORCID:0000-0001-5320-6166) Samsung Electronics, iamyj.choi@samsung.com, 정회원

** (ORCID:0000-0003-4620-3754) Samsung Electronics, jhwan729.kim@samsung.com, 정회원

논문번호 : 201806-0-136-SE, Received April 30, 2018; Revised July 6, 2018; Accepted July 24, 2018

신드롬 복호(syndrome decoding)를 적용해 과적합(overfitting) 문제를 해결하여 성능을 개선했다.

논문 [3]에서는 극 부호(polar codes) 복호 알고리즘을 학습할 수 있는 전방 전달 신경망(feedforward neural network) 구조의 복호기가 제안되었다. 이에 [4]에서는 여러 신경망 구조를 고려하여 전방 전달 신경망 구조뿐만 아니라 합성곱 신경망(convolutional neural network)과 순환 신경망(recurrent neural network) 구조를 적용한 복호기의 신경망 구조에 따른 복호 성능을 비교하였다.

본 논문에서는 [1-4]에서 제안된 여러 신경망 복호기 중 극 부호를 위한 전방 전달 신경망 구조의 복호기를 고려하였으며, 극 부호의 실용적인 이용에 필수적인 부호 길이 조절을 위한 천공기법(puncturing scheme)이 고려된 신경망 복호기를 살펴본다.

극 부호는 설계 특성 상 부호 길이가 2^n ($n=1,2,3,\dots$)으로 제한되므로, 임의의 부호 길이를 갖는 극 부호를 이용하기 위해서는 천공기법이 요구된다^[5]. 하지만 [3]의 신경망 복호기는 천공기법의 적용을 고려하지 않고, 모부호만을 이용해 성능을 확인하였다. 극 부호에 대한 딥 러닝 기반의 복호가 실용적으로 활용되려면 천공 기법이 적용된 부호에 대한 고려가 필요하다. 이에 본 논문에서는 다양한 천공 부호에 대해 기존 모부호만을 이용하여 학습된 신경망 복호기의 성능을 확인하고, 천공 부호에 대한 신경망 복호기의 효율적인 학습 방법을 제안한다.

II장에서는 딥 러닝 구조를 극 부호 복호기에 적용한 심층 신경망 구조의 복호기를 소개하고, 그 학습 방법에 대해 설명한다. III장에서는 천공된 극 부호를 효율적으로 학습하기 위한 신경망 복호기의 학습 방법을 제안하며, 모의실험을 통해 성능을 확인한다. 마지막으로 IV장에서 본 논문을 요약하고 결론을 내린다.

II. 심층 신경망 구조의 극 부호 복호기

본 장에서는 심층 신경망에 대해 간략히 설명하고, 극 부호 복호기에 딥 러닝 구조를 적용한 심층 신경망 복호기의 구조와 학습 방법에 대해 소개한다.

2.1 심층 신경망 구조의 복호기

인공 신경망(artificial neural network)은 머신 러닝에 사용되는 학습 알고리즘 중 하나로, 인공 뉴런(노드)들이 연결된 형태이다. 각 노드는 연결된 노드들의 출력 값에 가중치를 곱한 가중 합(weighted sum)을




그림 1. 신경망 극 부호 복호기를 사용하는 채널 부-복호화 시스템

Fig. 1. Channel encoding and decoding system of deep neural network based polar decoder

입력으로 하며, 이를 활성화함수(activation function)에 대입하여 얻은 값을 출력으로 한다. 이 노드들로 층(layer)이 구성되며, 신경망은 기본적으로 입력 층, 은닉 층, 출력 층의 구조를 가진다. 이때 2개 이상의 은닉 층을 가진 구조를 심층 신경망(deep neural network)이라 한다. 신경망은 학습 데이터를 기반으로 비용 함수(cost function)를 최소화하도록 노드들의 연결 관계를 학습하여 문제 해결 능력을 가지게 된다.

본 논문에서는 이러한 심층 신경망 구조를 복호기에 적용한 심층 신경망 구조의 극 부호 복호기를 다룬다. [3]은 그림 1과 같은 채널 부-복호화 시스템을 기반으로 신경망 구조의 극 부호 복호기를 제안하였다. 이때 m 은 메시지, c 는 부호어, s 는 송신할 신호이다. 수신단에서는 채널을 통과하여 백색 가우시안 잡음이 더해진 y 를 수신한다. 신경망 복호기는 수신된 신호 y 에 대해 추정된 메시지 \hat{m} 을 출력하여 복호하며, 충분히 학습된 신경망 복호기는 최대 사후 확률(maximum a posteriori: MAP) 성능에 근접한 비트 오류율(bit error rate: BER) 성능을 보였다. 이 구조의 신경망 복호기는 수신된 신호 y 가 신경망의 각 층을 오직 한 차례 지나며 복호가 진행되므로 원샷 복호(one-shot decoding)가 가능하다. 이는 반복 복호(iterative decoding)에 비해 복호기가 저지연(low-latency)으로 복호할 수 있도록 한다.

2.2 심층 신경망 복호기의 학습

신경망 복호기의 우수한 복호 성능을 위해서는 신경망의 가중치를 최적화하는 학습 과정이 중요하다. 신경망 복호기는 메시지 m 과 수신된 신호 y 의 집합을 학습 데이터로 사용하여 지도 학습(supervised learning)된다. 지도 학습은 머신러닝의 학습 방법 중 하나로, 입력과 그 입력에 대한 원하는 출력(label)까지 함께 학습 데이터로 이용한다. 이때 [3]의 신경망 복호기는 부호 길이 N , 정보 비트의 수가 K 인 극 부호에 대해 생성될 수 있는 2^K 개의 모든 부호어를 학습 데이터로 이용한다. 즉, 길이 N 의 부호어가 채널을 통과하며 잡음이 더해진 값을 입력으로, 길이 K 의 메시지를 각 입력에 대한 원하는 출력으로 하여 하나의 학습 데이터를 구성하며, 총 2^K 개의 학습 데이터를 고

려한다. 학습 데이터를 한번 사용하여 복호기를 학습 시키는 단위인 epoch의 횟수를 M_{ep} 라 할 때, 신경망 복호기는 2^K 개의 학습 데이터를 M_{ep} 번 학습하게 된다. 이 과정에서 오차 함수를 최소화하는 방향으로 가중치를 갱신하며 최적화한다. 즉, 충분히 학습된 신경망 복호기는 학습할 때 사용되지 않은 입력(unseen input) \mathbf{y} 에 대해 송신한 메시지 $\hat{\mathbf{m}}$ 을 올바르게 추정할 수 있는 문제 해결 능력을 가지게 된다.

신경망 복호기는 모든 가능한 부호어에 대해 채널을 통과시킨 값, 즉 수신된 신호와 그에 대한 메시지를 대응시키며 학습한다. 이는 지도 학습의 대표적인 알고리즘인 분류(classification)이다. 이러한 학습 방법은 정보 비트의 길이가 증가함에 따라 학습 데이터의 크기가 지수적으로 증가하여 학습 복잡도가 매우 복잡해진다. 이로 인해 [3]에서는 $N=16, K=8$ 의 매우 짧은 길이의 극부호만을 고려하는 한계를 가진다.

III. 천공 부호를 위한 신경망 복호기의 학습기법

[3]에서 제안된 신경망 복호기는 극 부호의 부호 길이 호환을 위한 천공기법의 적용을 고려하지 않고, 학습과 테스트에 오직 모부호만을 이용하였다. 하지만 극 부호에서의 신경망 복호기의 실용적인 이용을 위해서는 천공된 부호에 대한 고려가 필수적이다. 이에 본 장에서는 우선 천공기법이 적용된 극 부호에 대해 모부호로만 학습된 신경망 복호기의 성능을 확인한다. 또한, 다양한 부호 길이에 호환적인 신경망 복호기를 위한 학습 기법을 제안한다.

3.1 길이 호환적 극 부호를 위한 천공기법

극 부호는 이진 입력 이산 무기억 대칭 채널(binary-input discrete memoryless symmetric channel: B-DMC)에서 낮은 부호 복잡도로 채널용량을 달성하는 최초의 오류정정부호로^[6], 짧은 부호 길이에서 우수한 오류 성능을 가진다. 극 부호는 K 개의 정보 비트와 $N-K$ 개의 고정 비트로 이루어진 소스 벡터 \mathbf{u} 에 대해, 부호어 \mathbf{x} 는 $\mathbf{x} = \mathbf{u}\mathbf{G}_N$ 으로 얻어진다. $N=2^n$ 일 때, \mathbf{G}_N 은 Kronecker 거듭제곱 \otimes^n 과 $\mathbf{F} = \begin{bmatrix} 1 & 0 \\ 1 & 1 \end{bmatrix}$ 에 대해 $\mathbf{F}^{\otimes n}$ 으로 정의되는 $N \times N$ 생성행렬이다. 부호 길이 $N=2,4$ 의 극 부호화 구조는 그림 2와 같다.

이와 같이 극 부호는 설계 특성상 부호 길이가 2^n ($n=1,2,3,\dots$)으로 제한되므로, 임의의 부호 길이를 가




그림 2. $N=2,4$ 에 대한 극 부호화 구조
Fig. 2. Polar encoding structure for $N=2,4$

지는 극 부호를 위해서는 천공기법이 필요하다^[5]. 천공기법은 길이 호환적 극 부호를 위해 일부 부호어 비트를 전송하지 않는 기법이다. 천공된 비트 수를 p 라 할 때 천공된 부호어의 길이는 $N-p$ 가 된다. 이때 $N-p$ 개의 소스 비트 중에서 K 개의 정보 비트가 선택되고 부호율은 $K/(N-p)$ 가 되어 극 부호는 부호 길이 호환성을 가지게 된다. 본 논문에서는 두 가지 천공기법인 용량-0 천공기법과 용량-1 천공기법 중, 천공된 비트에 대응하는 채널의 용량이 0이 되는 용량-0 천공기법을 적용하여 성능을 확인하였다^[7]. 이때 천공 순서는 QUP(quasi-uniform puncturing) 기법을 적용하였다^[5].

3.2 천공된 극 부호를 적용한 신경망 복호기

극 부호를 적용한 신경망 복호기의 실용적인 이용을 위해서는 천공 부호에서의 성능 또한 중요하다. 따라서 본 절에서는 모부호로만 학습된 [3]의 신경망 복호기의 천공 부호에 대한 성능을 확인한다.

모의실험에는 파라미터가 $(N, K) = (16, 8), (32, 8)$ 인 극 부호를 사용하였다. AWGN(additive white Gaussian noise) 채널에서 BPSK(binary phase shift keying) 변조 기법을 적용하였고, 활성 함수로는 ReLU(rectified linear unit)을, 비용 함수는 평균제곱 오차(mean squared error)를, 확률 그래디언트 하강(stochastic gradient descent) 알고리즘으로 Adam(adaptive moment estimation)을 이용하였다^[8]. 3개의 은닉층들의 노드 개수는 각각 128, 64, 32개이며, $M_{ep} = 2^{14}$ 로 설정했다. 이때, 학습 시킬 때의 천공 비트 수는 p_{train} , 테스트할 때의 천공 비트 수는 p_{test} 라 정의한다.

모부호만으로 학습된 신경망 복호기($p_{train}=0$ 인 경우)는 천공된 극 부호에서 역시 M_{ep} 가 커질수록 MAP 성능에 근접하며, 그림 3에서는 모부호 (16,8)에 대해 $p_{test}=2$ 인 경우이다. 즉 짧은 부호 길이에 대하여 M_{ep} 가 충분히 크다면, 모부호만으로 학습한 신경망 복호기를 천공된 부호에 대해 적용할 수 있음을 나타

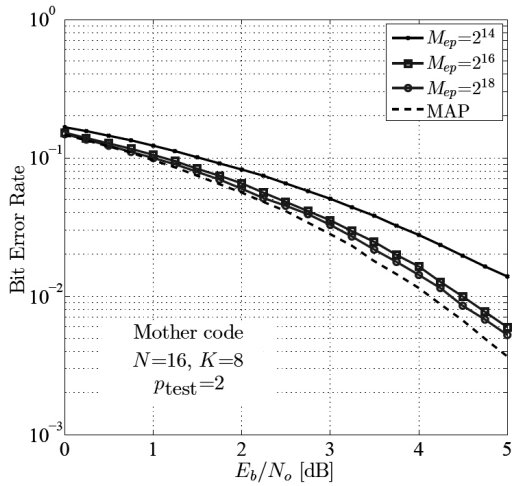


그림 3. 모부호로만 학습된 신경망 복호기의 천공된 부호에 대한 BER 성능
 Fig. 3. BER performance of NND trained with unpunctured codes for punctured polar codes

내지만, M_{ep} 가 커질수록 학습 복잡도가 증가한다. 따라서 천공 부호에 대해 최적에 근접한 성능을 얻기 위해서는 높은 학습 복잡도가 요구되므로, 실용적인 적용을 위해서는 낮은 복잡도로 천공 부호를 효율적으로 학습하는 기법이 필요하다. 이에 다음 절에서는 모부호로만 학습하는 기법 대비 다양한 부호 길이의 극 부호에 대해 효율적으로 신경망 복호기를 학습하기 위한 기법을 제안한다.

3.3 천공된 극 부호를 위한 신경망 복호기의 학습기법

모부호와 천공된 부호를 함께 학습시킨 신경망 복호기는 모부호로만 학습된 신경망 복호기보다 다양한 천공 부호에 대해 전반적으로 우수한 성능을 갖는다. 이에 모부호와 천공된 부호를 함께 학습 데이터로 이용하여 신경망 복호기가 천공 부호를 효율적으로 학습할 수 있는 기법을 제안한다. 즉, M_{ep} 번만큼 복호기를 학습시킬 때에 모부호로 $\alpha \times M_{ep}$ 번, 천공된 부호로 $(1-\alpha) \times M_{ep}$ 번 학습하며, 이때 α 는 0과 1 사이의 값을 가지는 설계 변수이다. $\alpha=1$ 인 경우, 즉 모부호로만 학습된 신경망 복호기보다 α 가 0.9 이하일 때, 즉 학습 데이터의 천공된 부호의 비율이 10% 이상인 신경망 복호기가 천공 부호에 대해 우수한 복호 성능을 보였다. 이때 신경망 복호기는 α 가 0.9 이하의 값을 가질 때 α 의 값의 변화에 따라 BER= 10^{-3} 기준 0.1dB 이하의 성능 차이를 보였으며, 이에 본 논문에서는 각 부호 파라미터에서 우수한 복호 성능을 가지

는 α 값을 실험적으로 확인하여 설정하였다.

제안기법은 학습된 신경망 복호기가 천공기법이 적용된 다양한 극 부호에 대해 전반적으로 우수한 성능을 가지도록 하는 것을 목적으로 한다. 하지만 신경망 복호기는 테스트할 때의 천공 비트 수 p_{test} 보다 학습할 때의 천공 비트 수 p_{train} 이 더 클 때, 즉 $p_{test} < p_{train}$ 인 경우 모부호로만 학습한 신경망 복호기에 비해 성능이 매우 저하되는 경향을 보인다. 예를 들어 $p_{train}=0,3$ 으로 학습한 신경망 복호기의 경우 $p_{train}=0$ 으로 학습한 신경망 복호기보다 $p_{test}=1,2$ 에 대해 성능이 저하된다. 이러한 성능 저하를 줄이기 위해서는 p_{test} 보다 적은 수의 p_{train} 으로 신경망 복호기를 학습시켜야 한다. 따라서 사용될 p_{test} 의 최솟값으로 p_{train} 을 설정하여 $p_{test} < p_{train}$ 인 경우 발생하는 성능 저하를 감소시켜 신경망 복호기가 다양한 천공 부호에 대해 우수한 성능을 가지도록 한다. 예를 들어, 모부호 (16,8)에 대한 천공 부호의 경우 p_{test} 는 1부터 8까지의 값을 가질 수 있으므로 모부호와 1비트 천공된 부호를 학습 데이터로 이용하였다. 그림 4에서 모부호 (16,8)에 대해 모부호로만 학습한 복호기($p_{train}=0$)와 모부호와 1비트 천공된 부호로 학습한 복호기($p_{train}=0,1$)의 p_{test} 에 따른 비트 오류 성능을 나타냈다. 이때 $p_{test}=3$ 인 경우 $\alpha=0.7$ 로, $p_{test}=5$ 인 경우 $\alpha=0.8$ 로 설정하였으며, 각각 BER= 10^{-3} 기준 모부호

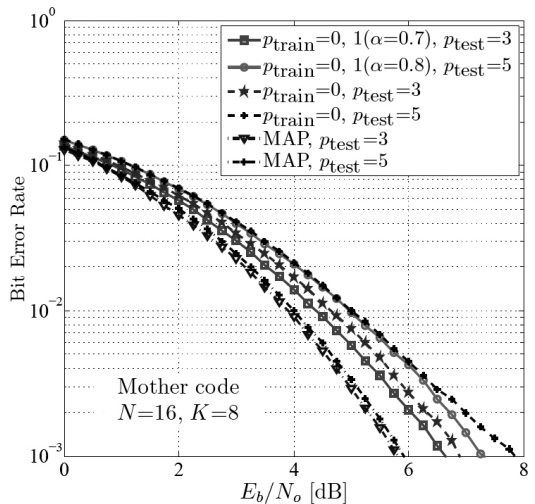


그림 4. 천공된 부호에 대한 학습기법별 신경망 복호기의 BER 성능 ($p_{train}=0,1/p_{train}=0$)
 Fig. 4. BER performance of NND with different training methods for punctured polar codes ($p_{train}=0,1/p_{train}=0$)

로만 학습하는 기법 대비 약 0.3 dB와 0.5dB의 성능 개선을 보였다.

모부호 (32,8)에 대한 천공 부호의 경우 p_{test} 는 1부터 24까지의 값을 가질 수 있다. 그러나 이전 경우와 마찬가지로 모부호와 1비트 천공된 부호로 학습할 경우 p_{test} 가 증가할수록 제안 기법으로 얻는 성능 이득이 감소한다. 따라서 다양한 천공 비트 부호에 대해 우수한 성능을 갖기 위해서는 학습 데이터의 천공 비트 수를 적절하게 설정하여 학습시켜야 하며 이때 긴 길이의 부호에 대하여 더욱 다양한 천공 비트 수를 고려할 경우 구간을 나누어 적절한 p_{train} 를 설정하여야 효율적인 학습이 가능하다. 그림 5에서 학습 데이터로 모부호와 1비트 천공된 부호를 사용하는 경우($p_{train}=0,1$)와 모부호와 8비트 천공된 부호를 사용하는 경우($p_{train}=0,8$)에 대한 신경망 복호기의 비트 오류 성능을 확인하였다. 이때 모부호와 8비트 천공한 부호를 학습하는 방법($p_{train}=0,8$)은 $p_{test}=13$ 인 경우 모부호와 1비트 천공한 부호를 학습하는 방법($p_{train}=0,1$) 대비 $BER=10^{-3}$ 기준 약 0.4 dB의 성능 개선을 보였다. 하지만 모부호와 8비트 천공한 부호를 학습하는 방법은 p_{test} 가 8보다 작은 경우 매우 큰 성능 저하를 보였으며, 그림 5에서는 $p_{test}=5$ 인 경우에 해당한다. 이때 모부호와 8비트 천공한 부호를 학습한 방법은 모부호와 1비트 천공한 부호를 학습한 방법 대비 $BER=10^{-3}$ 기준 약 0.5 dB의 성능 저하를 보였다. 즉, 사용할 p_{test}

의 범위에 따라 적절하게 학습 데이터의 천공 비트 수를 결정하여 성능 개선을 얻을 수 있었다. 이는 고려해야 할 p_{test} 의 범위가 커지면, 구간을 나눠 그에 적절한 p_{train} 을 설정하여야 함을 의미한다. 따라서 다양한 천공 부호에 대해 우수한 성능을 가지는 신경망 복호기를 위해서는 해당 시나리오의 부호 길이를 고려하여 p_{train} 을 설정하여 학습하여야 한다.

IV. 결론

본 논문에서는 심층 신경망 복호기가 다양한 천공 부호에 대해 우수한 복호 성능을 가질 수 있는 학습 기법을 제안했다. 우선 모부호로만 학습된 신경망 복호기에 천공된 부호를 적용해보았다. 또한, 천공된 부호의 효율적인 학습을 위한 기법으로 모부호와 천공 부호를 함께 학습 데이터로 이용하는 기법을 제안하였다. 모의실험을 통해 제안 학습기법이 다양한 부호 길이의 극 부호에 대해 모부호로만 학습하는 기법 대비 전반적으로 우수한 비트 오류 성능을 가지는 것을 확인하였다.

향후에는 보다 긴 길이의 다양한 극 부호 천공기법에서 우수한 성능을 얻을 수 있는 학습 방법과 천공 부호의 효율적인 학습을 위한 천공 순서에 관한 연구가 필요하다.

References

- [1] E. Nachmani, E. Marciano, L. Lugosch, Warren J. Gross, D. Burshtein, and Y. Be'ery, "Deep learning methods for improved decoding of linear codes," *IEEE J. Sel. Topics in Signal Process.*, vol. 12, no. 1, pp. 119-131, Feb. 2018.
- [2] A. Bennatan, Y. Choukroun, and P. Kisilev, "Deep learning for decoding of linear codes - a syndrome-based approach," arXiv:1802.04741v1, Feb. 2018.
- [3] T. Gruber, S. Cammerer, J. Hoydis, and S. ten Brink, "On deep learning-based channel decoding," in *Proc. 2017 51st Annual Conference on Information Sciences and Systems (CISS)*, pp. 1-6, Baltimore, MD, USA, Mar. 2017.
- [4] W. Lyu, Z. Zhang, C. Jiao, K. Qin, and H.




그림 5. 천공된 부호에 대한 학습기법별 신경망 복호기의 BER 성능 ($p_{train}=0,1/p_{train}=0,8$)
 Fig. 5. BER performance of NND with different training methods for punctured polar codes ($p_{train}=0,1/p_{train}=0,8$)

Zhang, "Performance evaluation of channel decoding with deep neural networks," arXiv:1711.00727v1, Nov. 2017.

- [5] K. Niu, K. Chen, and J. Lin, "Beyond turbo codes: rate-compatible punctured polar codes," in *Proc. 2013 IEEE Int. Conf. Commun.*, pp. 3423-3427, Budapest, Hungary, Jun. 2013.
- [6] E. Arıkan, "Channel polarization: A method for constructing capacity-achieving codes for symmetric binary-input memoryless channels," *IEEE Trans. Inform. Theory*, vol. 55, no. 7, pp. 3051-3073, Jul. 2009.
- [7] J.-H. Kim, Y. J. Choi, S.-H. Kim, and H. Park, "A coding-sequence-based puncturing scheme for length-compatible polar codes," *J. KICS*, vol. 42, no. 11, pp. 2093-2096, Nov. 2017.
- [8] D. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv:1412.6980v9, Jan. 2017.

서 은 영 (Eun Young Seo)



2017년 2월 : 성균관대학교 전자전기컴퓨터공학과 학사
 2017년 2월~현재 : 성균관대학교 전자전기컴퓨터공학과 석사과정
 <관심분야> 오류정정부호, 정보이론, 기계학습

최 연 준 (Yeon Joon Choi)



2016년 2월 : 성균관대학교 전자전기컴퓨터공학과 학사
 2018년 2월 : 성균관대학교 전자전기컴퓨터공학과 석사
 2018년 3월~현재 : 삼성전자 <관심분야> 통신공학, 오류정정부호, 정보이론

김 중 환 (Jong-Hwan Kim)



2010년 2월 : 성균관대학교 전자전기컴퓨터공학과 학사
 2018년 2월 : 성균관대학교 전자전기컴퓨터공학과 박사
 2018년 3월~현재 : 삼성전자 <관심분야> 오류정정부호, 정보이론, 부호이론

김 상 호 (Sang-Hyo Kim)



1998년 2월 : 서울대학교 전기공학부 학사
 2000년 2월 : 서울대학교 전기공학부 석사
 2004년 2월 : 서울대학교 전자컴퓨터공학부 박사
 2004년 3월~2006년 : 7월 삼성 전자 책임연구원
 2006년 8월~2007년 8월 : 박사후 연구원(USC)
 2007년 9월~2011년 9월 : 성균관대학교 전자전기공학부 조교수
 2011년 10월~2017년 9월 : 성균관대학교 전자전기공학부 부교수
 2017년 10월~현재 : 성균관대학교 전자전기공학부 교수
 <관심분야> 통신공학, 오류정정부호, 정보이론