

딥러닝을 이용한 주변 무선단말 파악방안

이웅섭 · 반태원 · 김성환 · 류종열*

Neighbor Discovery for Mobile Systems based on Deep Learning

Woongsup Lee · Tae-Won Ban · Seong Hwan Kim · Jongyeol Ryu *

*Department of Information and Communication Engineering, Institute of Marine Industry, Gyeongsang National University, Tongyeong 53064, Korea

요 약

최근 단말-대-단말(Device-to-device, D2D) 통신기술이 차세대 무선통신시스템의 핵심기술로 큰 관심을 받고 있다. 이러한 단말간 통신에서는 자신의 주변에 어떠한 단말이 있는지 파악하는 주변단말 탐색(Neighbor discovery)이 매우 중요하다. 본 논문에서는 최근 큰 관심을 받고 있는 딥러닝(Deep learning) 기술을 활용하여 단말간 통신에서 주변단말을 파악하는 방안에 대해서 제안한다. 제안 방안은 기존의 방안과 달리 무선채널의 공간적 연관성을 이용하여 단말간의 신호 전송 없이 단말이 기지국으로 전송하는 상향링크 파일럿 신호를 기반으로 주변 단말을 찾고 따라서 기존의 방식에 비해 신호전송 복잡도(signaling complexity)를 크게 줄일 수 있다. 또한 제안 방안에서는 떨어져 있는 거리에 따라서 주변 단말을 분류 가능하여 기존 방안에 비해서 좀 더 세밀한 단말 탐색이 가능하다. 마지막으로 본 논문에서는 tensorflow를 이용한 컴퓨터 시뮬레이션을 통해 제안 방안의 성능을 검증하였다.

ABSTRACT

Recently, the device-to-device (D2D) communication has been conceived as the key technology for the next-generation mobile communication systems. The neighbor discovery in which the nearby users are found, is essential for the proper operation of the D2D communication. In this paper, we propose new neighbor discovery scheme based on deep learning technology which has gained a lot of attention recently. In the proposed scheme, the neighboring users can be found using the uplink pilot transmission of users only, unlike conventional neighbor discovery schemes in which direct pilot communication among users is required, such that the signaling overhead can be greatly reduced in our proposed scheme. Moreover, the neighbors with different proximity can also be classified accordingly which enables more accurate neighbor discovery compared to the conventional schemes. The performance of our proposed scheme is verified through the tensorflow-based computer simulations.

키워드 : 딥러닝, 주변단말 탐색, 단말-대-단말 통신, 무선채널 연관성

Key word : Deep learning, Neighbor discovery, Device-to-device communication, Wireless channel correlation

Received 19 January 2018, Revised 24 January 2018, Accepted 20 February 2018

* Corresponding Author Jongyeol Ryu (E-mail: jongyeol_ryu@gnu.ac.kr, Tel:+82-55-772-9173)

Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong 53064, Korea

Open Access <http://doi.org/10.6109/jkiice.2018.22.3.527>

pISSN:2234-4772

©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. 서 론

최근 급증하는 모바일 트래픽 문제를 해결하고 사물인터넷 (Internet-of-Things)과 같은 새로운 모바일 서비스를 제공하기 위해서, 모바일 단말들이 기지국을 거치지 않고 단말간 직접 데이터를 전송하는 단말간 (Device-to-device, D2D) 통신기술이 큰 주목을 받고 있다. 그와 더불어 관련 연구들이 활발하게 이루어지고 있으며 통신 표준에서도 고려가 되고 있다 [1, 2, 3]. 단말간 통신을 위한 핵심기술로서 근처에 있는 단말을 탐색하는 주변단말탐색(Neighbor discovery) 기술이 있다. 만약 주변 단말을 정확하게 파악할 수 없다면 멀리 떨어져있는 두 단말이 주변에 있는 것으로 인식될 수도 있고 이 경우 단말 간 통신의 성능이 크게 저하된다.

효과적인 주변단말탐색을 위해 기존의 연구에서는 주로 프록시미터 비콘(Proximity beacon)기반 주변단말 탐색방안이 고려되었다 [4]. 이 방안에서는 단말간의 파일럿 (Pilot) 신호 송수신을 통해서 주변단말을 파악하게 된다. 한 단말이 파일럿을 송신하였을 때 주변에 위치한 단말들만 송신된 파일럿 신호를 제대로 받을 수 있으므로 효율적으로 주변단말을 찾을 수 있다.

하지만 이러한 프록시미터 비콘기반 단말탐색방안에서는 파일럿 전송에 따른 신호전송 복잡도(signaling complexity)가 높고 단말들의 파일럿 전송으로 인한 무선전력의 낭비가 발생할 수 있다. 이러한 기존 기술의 단점을 해결하기 위해서 단말이 기지국으로 전송하는 상향링크(Uplink) 파일럿 신호를 이용하여 주변단말을 탐지하는 기술이 제안되었다 [5]. 특히 [5]의 연구에서는 무선채널의 공간적 연관성, 즉 비슷한 위치에 있는 단말들이 비슷한 채널특성(무선 채널의 Azimuth spread, Delay spread, Shadow fading)을 갖는 것을 이용하여 단말과 기지국간의 무선채널 정보를 기반으로 어떠한 단말들이 가까이 위치한지 파악한다.

최근 기계학습 분야에서 심층 신경망(Deep neural network, DNN)을 활용한 다양한 딥러닝 (Deep learning) 관련 연구들이 큰 주목을 받고 있다 [6]. 이러한 딥러닝 기술은 주로 이미지 처리 및 음성인식 등에 많이 적용되어 기존 기술을 월등히 상회하는 성능을 보여주고 있다. 현재 딥러닝과 관련한 많은 연구들이 주로 컴퓨터 과학 분야에서 이루어지고 있지만, 무선통신 분야에서도 최근 일부 연구가 진행되고 있다 [7-9]. [7]의 연구에

서는 딥러닝 기술을 이용하여 Orthogonal frequency division multi-plexing (OFDM) 시스템에서 peak-to-average power ratio 을 줄이는 인코더와 디코더 구조를 찾는 방안이 제안되었다. 또한 [8]의 연구에서는 Non-orthogonal multiple-access (NOMA) 기술 중 하나인 Sparse code multiple access (SCMA)에서 딥러닝을 이용하여 최적의 인코더와 디코더 구조를 도출하였다. 더불어 [9]에서는 심층 신경망구조를 이용하여 무선신호의 특성 및 modulation을 찾는 방안이 제안되었다.

이러한 딥러닝 기술에서는 구체적인 수학적 모델링 없이 많은 양의 데이터로부터 심층 신경망 구조가 스스로 최적의 방안을 찾아내기 때문에 유연한 기술개발이 가능하다. 또한 학습에는 많은 시간이 걸리지만 학습된 신경망을 이용하여 결과를 도출하는 것(Inference)은 빠르게 연산이 가능하므로 실시간 계산에 적합하다. 따라서 본 연구에서는 딥러닝을 이용하여 단말이 기지국으로 보내는 상향링크 파일럿 신호를 통해 주변 단말들을 파악하는 방안을 제안한다. 특히 거리에 따라서 다양한 라벨(Label)을 생성하여 심층 신경망을 학습하게 함으로써 다양한 거리에 있는 주변 단말들을 분류하여 인식할 수 있도록 하였고 이를 통해 기존의 기술에 비해서 정확한 주변단말 인지를 가능케 하였다.

본 논문의 2장은 연구에서 고려한 무선 채널의 공간적 연관성 및 제안한 딥러닝 기반 주변단말 탐색방안에 대해서 설명한다. 3장에서는 컴퓨터 시뮬레이션을 통해 제안 방안의 성능을 검증한다. 마지막으로 4장에서는 논문을 마무리 한다.

II. 무선채널의 공간적 연관성 및 딥러닝 기반 주변단말 탐색방안

본 장에서는 제안한 주변단말 탐색방안에서 사용한 무선채널의 공간적 연관성에 대해서 우선 설명하고 제안 방안의 동작 및 사용한 심층 신경망구조와 학습방안에 대해서 설명한다.

2.1. 무선채널의 공간적 연관성

본 연구에서는 단말과 기지국간의 상향링크 무선 채널정보를 이용하여 어떤 단말이 주변에 있는지 파악한다. 기존에 수행된 무선채널측정에 따르면 무선채널의

요소들 중 Azimuth spread (AS), Delay spread (DS), Shadow fading (SF)은 공간적 연관성이 존재하여, 비슷한 위치에 있는 단말들은 비슷한 값을 갖게 된다[1, 2]. 본 연구에서는 AS와 DS는 사용하지 않고 측정과 사용이 용이한 SF를 사용하여 주변단말을 탐색하게 된다. 우선 SF에 의한 경로손실(path loss)의 영향을 Y라 하였을 때 Y의 값은 아래와 같이 표현할 수 있다.

$$Y = \sigma X. \quad (1)$$

여기서 σ 는 SF의 분산 값을 나타내고 X는 평균이 0이고 분산이 1인 가우시안 랜덤변수를 나타낸다. 이 때 거리가 d만큼 떨어져 있는 단말 A와 B의 X_A 와 X_B 사이의 연관성은 다음과 같이 표현할 수 있다 [2].

$$E[X_A X_B] = e^{-d/d_{ref}}. \quad (2)$$

앞의 수식에서 d_{ref} 는 무선 환경에 따라 변화하는 상수 값을 의미한다. 따라서 두 단말 A와 B가 서로 비슷한 위치에 있다고 하면 단말의 SF값인 Y_A 와 Y_B 도 비슷할 것이다. SF값 이외에도 비슷한 위치에 있는 단말은 비슷한 경로 손실 값을 가지게 된다. 따라서 만약 Z_A, Z_B, Z_C 가 각각 SF와 경로 손실의 영향을 고려한 단말 A, B, C의 무선채널 값일 때, B가 C보다 A에게 더 가까이 있다고 하면 다음의 수식이 성립하게 될 것이다.

$$\frac{E[Z_A Z_B]}{E[Z_A]E[Z_B]} > \frac{E[Z_B Z_C]}{E[Z_B]E[Z_C]}. \quad (3)$$

(3)의 수식에서 확인할 수 있듯이 무선채널 값을 이용하여 두 단말 중 어떠한 단말이 더 가까이 있는지 파악할 수는 있으나 실제 어떠한 단말이 주변단말인지는 확인할 수 없다. 예를 들어서 위의 예에서 C와 A 모두 B와 멀리 떨어져 있을 수도 있다. 실제 채널정보를 통해서 주변 단말을 찾기 위해서는 주변단말 선택을 위한 조건 (Selection Criteria)을 찾아야 하는데 이는 수학적으로 도출이 어려울 수 있다. 본 연구에서는 딥러닝 기술을 이용하여 이러한 선택조건을 심층 신경망이 학습을 통해서 스스로 찾게 하였다.

1) 채널 값은 상향링크 파일럿으로부터 얻을 수 있다.

2.2. 제안 단말탐색의 동작 방안

제안 단말탐색방안에서는 우선 딥러닝 학습을 위한 트레이닝 데이터 (Train set)를 수집해야 한다. 이를 위해서 주변 단말들 간의 거리에 따른 기지국과 단말간의 채널 데이터를 수집한다. 실제 측정데이터 수집이 어려울 경우 기존의 채널모델을 이용하여 인공적으로 데이터 생성도 가능하다. 멀티패스 페이딩(Multi-path fading)의 경우 공간적인 연관성이 없기 때문에 이러한 페이딩의 영향을 줄여주기 위해서 여러 채널 데이터를 평균화여준다. 이렇게 수집된 채널 데이터가 딥러닝을 위한 데이터가 되고 이 때 단말간의 거리가 라벨이 된다. 제안 방안에서는 이렇게 수집된 트레이닝 데이터를 구성한 심층 신경망(Deep neural network, DNN) 구조에 입력으로 집어넣고 주변단말 여부를 학습한다. 이 때 하나의 채널 샘플만 입력하는 것이 아니라 N개의 채널 샘플을 동시에 심층 신경망에 입력하여 예측의 정확도를 높였다. 또한 본 연구에서 개발한 기술의 경우 단순히 주변 단말 여부만 판단하는 것이 아니라 두 단말이 얼마나 가까이 있는지도 파악하게 구성하였다. 이를 위해서 다중 라벨 분류 (Multi-label classification) 고려하였다. 즉 단말간의 거리가 각각 3미터, 15미터, 1500미터 떨어져 있는 경우를 고려하였고, 개발한 심층 신경망은 단말간의 거리가 매우 가까운지 (3미터), 적당히 가까운지 (15미터), 아니면 아주 멀리 떨어져 있는지 (1500미터)를 예측한다. 이를 통해서 기존 연구에 비해서 더 정밀한 주변단말 분류가 가능하다. 더불어 제안방안은 모바일 장치가 아니라 높은 계산 성능을 지닌 기지국에서 동작하기 때문에 실제 구현에 문제가 없다.

2.3. 제안 단말탐색을 위한 딥러닝 구조 및 학습

본 연구에서 고려한 심층신경망 구조가 그림 1에 나와 있다. 그림에서 확인할 수 있듯이 서로 주변 단말인지를 확인할 2개의 단말(A, B)에 대한 N개의 채널 데이터($Z^1_A, Z^1_B, \dots, Z^N_A, Z^N_B$)가 신경망의 입력으로 들어가고 두 단말이 얼마나 가까운지 나타내는 분류결과가 출력으로 나온다. 즉 N_1, N_2, N_3 는 각각 두 단말이 얼마나 떨어져 있는지 알려주는 indicator이다. 만약 두 단말이 3미터 정도 떨어져 있으면 $N_1=1, N_2, N_3=0$ 이 되고, 15미터 정도 떨어져 있으면 $N_2=1, N_1, N_3=0$ 이 되고, 마지막으로 1500미터 정도 떨어져 있으면 $N_3=1, N_1, N_2=0$ 이 나오게 된다.




Fig. 1 Considered DNN structure to classify neighbors.

제한한 심층신경망은 5개의 sub-block으로 나누어져 있고 각 sub-block들은 Fully connected (FC) 기반 선형 (Linear) 레이어와 Rectifier linear unit (ReLU) 및 과적합 (over-fitting)을 줄이기 위한 Dropout unit으로 이루어져 있다. 각 선형 레이어는 100개의 히든노드(Hidden node)로 이루어져 있고 각 히든노드의 출력이 ReLU 및 Dropout unit으로 입력된다. ReLU는 심층신경망에 비선형성을 주는 구성요소로서 $[\cdot]^+$ 연산을 통해 음의 입력을 막고 positive한 값만 출력시킨다. Dropout unit은 심층신경망의 과적합을 막는 요소로 학습 시에는 50%의 확률로 weight를 랜덤하게 막아서 여러 히든노드들이 골고루 학습될 수 있게 한다.

마지막 sub-block의 출력은 3개의 노드로 합쳐진 뒤 softmax 연산을 통해서 N_1, N_2, N_3 의 값으로 출력된다. 즉 W_i 가 각 N_i 에 해당하는 weight라고 할 때 수식 (4)를 통해서 각 라벨의 분류 확률을 구하고 이 분류확률이 제일 큰 i 에 대해서 $N_i = 1$ 로 설정하고 나머지 N_j 에 대해서는 값을 0으로 설정한다.

$$N_i = \frac{e^{-W_i x}}{\sum_{j=1}^3 e^{-W_j x}} \quad (4)$$

이렇게 구성된 심층신경망은 기존의 stochastic gradient method (SGD)를 이용하여 학습된다. 이를 위해서 cross entropy를 이용하여 다음과 같은 loss function (L)을 고려하였다.

$$L = \sum_{j=1}^N p_j \log \left(\frac{e^{-W_j x_j}}{\sum_{i=1}^3 e^{-W_i x_j}} \right) \quad (5)$$

상기의 loss function에서 p_j 는 실제 label 값을 의미하고 x_j 는 이때의 채널 데이터를 의미한다. SGD에서는 아래의 수식과 같은 알고리즘을 통해서 신경망의 weight(W)를 업데이트 한다.

$$W^+ := W - \eta \nabla L \quad (6)$$

상기의 수식에서 ∇L 은 loss function의 gradient값을 나타내고 η 는 학습의 학습속도 (learning rate, LR)를 나타낸다.

III. 결과분석

본 장에서는 제안한 주변단말 탐색방안의 정확도를 Tensorflow 기반 시뮬레이션을 통해 비교하였다. 이를 위해서 제안 방안이 주변단말을 잘못 파악하는 확률인 예측오류 (prediction error)를 측정하였다. 성능 분석에서는 TU-32환경을 고려하여 $d_{ref} = 50$ 미터로 가정하였고 [2] 단말의 전송파워는 23dBm, 대역의 noise spectral density는 -174dBm/Hz, 전송대역 크기는 10 MHz로 가정하였다. 또한 경로손실지수가 3.45이고 경로손실상수가 38인 단순 경로손실모델(simplified path loss model)과 Rayleigh 페이딩을 고려하였다. 기지국 커버리지는 500미터로 가정하였다. 성능 분석을 위해서 32비트의 실수 연산자로 표시되는 총 3000개의 채널 샘플을 임의로 생성하였고 전체 채널샘플 중 90%는 학습(train set)에 사용하고 나머지 10%는 (test set)는 validation에 사용하였다. 다만 과적합등의 특성을 파악하기 위해서 결과 분석에서는 train set과 test set의 성능결과를 모두 보았다. 채널 샘플생성에서 각 단말이 3미터, 15미터, 1500미터 떨어져 있는 경우를 동일하게 고려하였다. 즉 채널 샘플을 통해 3가지 경우 중 한 가지를 선택하도록 구성하였다. 마지막으로 N의 값을 20으로 설정하였고, SGD에서 batch 사이즈를 100으로 설정하였고 학습속도는 0.001로 설정하였다.

우선 그림 2에서는 다양한 학습속도에 따른 제안 방안의 성능³⁾을 학습 횟수(number of iterations)에 따라

- 2) 따라서 주변단말 탐색은 총 40개의 채널 샘플을 가지고 이루어진다.
- 3) 실제 제안방안을 사용할 때는 최종 학습된 모델만 활용하기

분석하였다. 성능분석에서 확인할 수 있듯이 학습이 많이 진행될수록 성능이 수렴하는 것을 볼 수 있고, LR이 0.001일 때 성능이 제일 잘 나오는 것을 확인할 수 있다. 또한 train set의 경우 LR = 0.001일 때 예측 오류가 10% 이하로 나오는 것을 확인할 수 있고 이를 통해서 제안 방안이 높은 정확도로 주변단말을 파악할 수 있음을 확인할 수 있다. 다만 test set에 대해서 30% 정도의 오차를 보이는 것으로 일부 과적합이 발생했음을 확인할 수 있다.

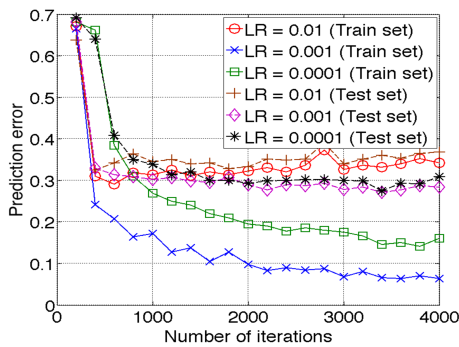


Fig. 2 Prediction error vs. number of iterations for different learning rate.

다음으로 그림 3에서는 학습에 사용한 채널데이터 수에 따른 성능을 분석하였다. 분석에서 확인할 수 있듯이 사용된 데이터가 많아질수록 과적합의 영향이 줄어들어서 train set에 대해서는 예측 오차가 증가하고 test set에 대해서 예측 오차가 줄어드는 것을 확인할 수 있다. 대략 3000개의 채널 샘플을 이용하면 안정적인 결과를 얻을 수 있는 것을 확인할 수 있다.

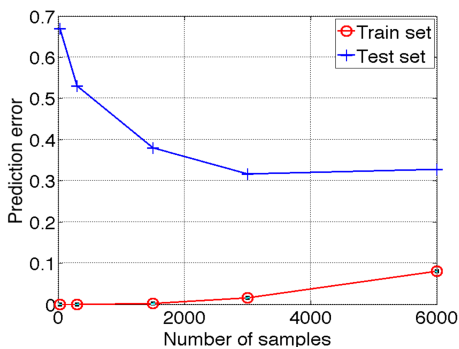


Fig. 3 Prediction error vs. number of samples.

때문에 학습도중의 오차 값은 제안방안의 성능과 관련이 없다.

다음으로 그림 4에서는 채널의 공간적 연관성을 결정하는 d_{ref} 에 따른 성능을 확인하였다. d_{ref} 의 값이 커질수록 무선채널의 공간적 연관성이 커져서 멀리 떨어져 있는 단말들의 채널이 비슷해지게 된다. 실험 결과에서 확인할 수 있듯이 무선 채널의 공간적 연관성이 커질수록(즉 d_{ref} 가 증가할수록) 제안 방안의 오차가 줄어드는 것을 확인할 수 있다. 따라서 제안 방안은 공간적 연관성이 큰 rural 환경에서 더 좋은 성능을 보일 것이다.

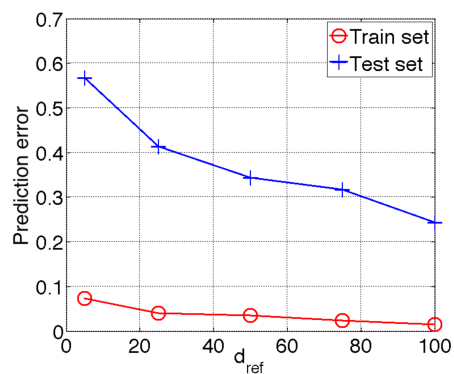


Fig. 4 Prediction error vs. d_{ref} .

마지막으로 그림 5에서는 가장 멀리 떨어져 있는 주변 단말의 거리 (D_3)를 바꾸면서 성능을 분석하였다. 결과에서 확인할 수 있듯이 분류할 주변 단말의 거리가 멀리 떨어질수록 정확한 예측이 가능함을 확인할 수 있다. 이는 거리가 멀수록 입력 데이터의 특성이 더 차이가 나기 때문이다.

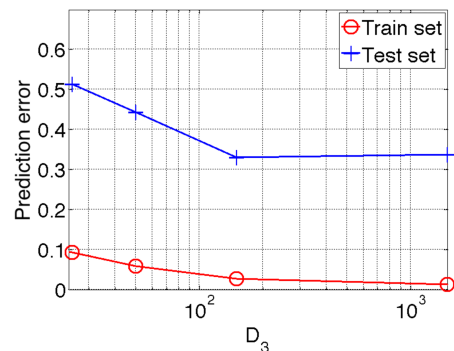


Fig. 5 Prediction error vs. D_3 .

V. 결 론

본 연구에서는 단말간 통신을 위한 주변단말 탐색방안에 대해서 제안하였다. 제안 방안은 무선채널의 공간적 연관성을 기반으로 딥러닝 기술을 이용하여 주변 단말을 탐색한다. 특히 기존의 방안과 달리 단말이 기지국으로 전송하는 상향링크 채널정보만을 이용하여 주변단말을 찾음으로써 신호전송 복잡도 및 단말의 전력소모를 줄일 수 있고, 주변단말의 거리에 따른 세밀한 탐색이 가능하다. Tensorflow를 기반으로 한 시뮬레이션 성능분석을 통해 제안 방안이 높은 정확도로 주변단말을 탐색하는 것을 확인할 수 있었다.

ACKNOWLEDGEMENT

This work was supported by Rural Development Administration(RDA) through Cooperative Research Program for Agriculture Science & Technology Development, funded by Ministry of Agriculture, Food and Rural Affairs (MAFRA) (Project No. PJ01229901201801).

REFERENCES

- [1] W. Lee, "Neighbor Discovery Scheme based on Spatial Correlation of Wireless Channel," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 19, no. 10, pp. 2256-2262, Oct. 2014.
- [2] W. Lee, J. Kim, and S. Choi, "New D2D Peer Discovery Scheme based on Spatial Correlation of Wireless Channel," *IEEE Transactions on Vehicular Technology*, vol. 65, no. 12, pp. 10120 - 10125, Feb. 2016.
- [3] E. M. Diouf and W. Lee, "An Implementation of LTE Simulator based on NS-3 for Evaluating D2D Performance," *IEICE Transactions on Fundamentals*, vol. E100.A, no. 10, pp. 2216 - 2218, Oct. 2017.
- [4] F. Baccelli, N. Khude, R. Laroia, J. Li, T. Richardson, S. Shakkottai, S. Tavildar, and X. Wu "On the Design of Device-to-device Autonomous Discovery," in *Proceedings of IEEE Communication Systems and Networks*, Bangalore, India, pp. 1-9, Jan. 2012.
- [5] W. Lee, J. Kim, and D. Cho, "Autonomous Peer Discovery Scheme for D2D Communications based on Spatial Correlation of Wireless Channel," *IEICE Transactions on Communications*, vol. E99-B, no. 1, pp. 224-231, Jan. 2016.
- [6] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp.436-444, May 2015.
- [7] M. Kim, W. Lee, and D. Cho, "A Novel PAPR Reduction Scheme for OFDM System based on Deep Learning," *IEEE Communications Letters*, vol. 22, no. 3, pp.510-513, Mar. 2018.
- [8] M. Kim, N. Kim, W. Lee, and D. Cho, "Deep Learning Aided SCMA," *IEEE Communications Letters*, vol. PP, no. 99, pp.1-4, Jan. 2018.
- [9] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional radio modulation recognition networks," in *Proceedings of International Conference on Engineering Applications of Neural Network*, Aberdeen, UK, pp. 213-226, Sep. 2016.



이웅섭(Woongsup Lee)

2006년 한국과학기술원 전기및전자공학과 학사
2011년 한국과학기술원 전기및전자공학과 박사
2012년 2월~2013년 2월 한국과학기술원 박사후 연구원
2013년 2월~2014년 2월 독일 FAU 박사후 연구원
2014년 3월~ 현재 경상대학교 정보통신공학과 조교수
※관심분야: 차세대 이동통신 시스템, 인지 라디오 시스템, 스마트 그리드, 빅 데이터 분석, 딥러닝



반태원(Tae-Won Ban)

1998년 2월 경북대학교 전자공학과 학사
2000년 2월 경북대학교 전자공학과 석사
2010년 2월 KAIST 전기및전자공학 박사
2009년 6월~2010년 10월 KT 연구 엔지니어
2011년 2월~2012년 8월 KT Project Manager
2012년 9월~2016년 8월 경상대학교 정보통신공학과 조교수
2016년 9월~ 현재 경상대학교 정보통신공학과 부교수
※관심분야: 차세대 이동통신, 무선 자원 관리, Cognitive Radios, Relay Systems, OFDM/MIMO



김성환(Seong Hwan Kim)

2006년 8월 고려대학교 전기전자전파공학부 학사
2008년 8월 KAIST 전자전산학과 석사
2013년 2월 KAIST 전기전자공학과 박사
2013년 8월~2016년 2월 맥길대학교 박사후 연구원
2016년 3월~ 국립경상대학교 정보통신공학과 조교수
※관심분야: 차세대 이동통신 시스템, 사물인터넷



류종열(Jong Yeol Ryu)

2008년 2월 충남대학교 전기정보통신공학부 학사
2010년 2월 KAIST 전기및전자공학과 석사
2014년 2월 KAIST 전기및전자공학과 박사
2014년 4월~2016년 8월 싱가포르기술디자인대학교 박사후 연구원
2016년 9월~국립경상대학교 정보통신공학과 조교수
※관심분야: 보안 통신 시스템, 차세대 이동통신 시스템, 사용자 릴레이 통신 등