

기대최대화 기반 사용자 클러스터링을 통한 D2D 광고 확산

김준선*, 이호원^o

D2D Based Advertisement Dissemination Using Expectation Maximization Clustering

Junseon Kim*, Howon Lee^o

요약

지역 기반 D2D 광고를 위하여 소스 단말은 인근에 분포되어 있는 불특정 다수의 사용자들에게 광고를 전송한다. 유효 범위 내에 사용자들이 무작위로 균일하게 분포되어 있는 경우, 광고 확산을 위하여 적절하게 목표지역을 설정하는 것은 매우 어려운 문제 중 하나이다. 본 논문에서는 기대최대화 기반 사용자 클러스터링을 이용한 D2D 광고 확산 알고리즘을 제안한다. 각 클러스터로 분류된 사용자들의 분포는 주성분을 통해 예측할 수 있다. 즉, 각 클러스터의 주성분을 이용하여 광고 확산을 위한 목표지역 및 확산 경로를 설정할 경우 예측한 사용자 분포를 따라 광고가 확산되는 효과를 기대할 수 있다. 시뮬레이션을 통해 전체 사용자 수 대비 광고를 수신한 사용자 수의 비율을 의미하는 포함확률과 사용자 당 평균 광고 수신 수에 대해 비교 분석한다.

Key Words : device-to-device, advertising, clustering, EM algorithm, principal component

ABSTRACT

For local advertising based on D2D communications, sources want advertisement messages to be diffused to unspecified users as many as possible. It is one of challenging issues to select target-areas for advertising if users are uniformly distributed. In this paper, we propose D2D based advertisement dissemination algorithm using user clustering with expectation-maximization. The user distribution of each cluster can be estimated by principal components (PCs) obtained from each cluster. That is, PCs enable the target-areas and routing paths to be properly determined according to the user distribution. Consequently, advertisement messages are able to be disseminated to many users. We evaluate performances of our proposed algorithm with respect to coverage probability and average reception number per user.

1. 서론

Mobile ad-hoc network (MANET)는 기지국 및

Access Point(AP)와 같은 통신 인프라의 도움 없이, 모바일 단말들 간의 멀티홉을 통해 통신하는 기술이다. 재난 및 전쟁과 같이 통신 인프라가 없거나 정상

* 이 논문은 2016년도 정부(미래창조과학부)의 재원으로 한국연구재단 기초연구사업의 지원을 받아 수행된 연구임(No. 2016R1D1A1B03935902)

• First Author : Ulsan Institute of Science and Technology (UNIST) Department of Computer Science Engineering (CSE), jskim@unist.ac.kr, 학생회원

o Corresponding Author : Hankyong National University Department of Electrical, Electronic and Control Engineering (EECE) and IITC, hwlee@hknu.ac.kr, 종신회원

논문번호 : KICS2016-08-174, Received August 1, 2016; Revised March 30, 2017; Accepted April 18, 2017

적으로 동작할 수 없는 상황에서 주로 고려되었으며, 최근에는 더 나아가 소셜 서비스에도 많은 사례 적용되고 있다^{11,12}. 이러한 MANET은 최근 부각되고 있는 D2D (device-to-device) 통신과 결합되면서 다양한 응용 영역들로 확장되고 있다. D2D는 인접 단말간 직접 통신이 가능한 기술로 저전력, 높은 전송속도, 높은 자원 효율성 및 저지연 등 5G의 여러 가지 요구조건들을 만족시킬 수 있는 기술로써, 다양한 연구가 진행되고 있다^{3,7}.

중단 단말들 간에 멀티홉 전송을 통한 신뢰성 있는 데이터 송수신을 위해, 전송 경로 설정을 위한 효율적 라우팅 기법의 적용이 필수적이다. 하지만, MANET과 같이 단말들의 이동성을 고려하는 환경에서는 네트워크 구조가 시시각각 변하기 때문에, 신뢰성 있는 전송 경로를 유지하는데 어려움이 있으며, 이를 위한 다양한 라우팅 프로토콜들에 대한 연구가 진행되었다⁸⁻¹¹. 라우팅 프로토콜들은 특정 목적 (destination) 단말에 데이터를 전송하기 위해, 데이터를 수신한 모든 단말들이 릴레이를 수행하는 flooding 기법을 이용하거나 인접 단말과의 contact history를 이용하여 최적의 릴레이 단말을 선정한다. 하지만, 불특정 다수의 단말을 목적 단말로 고려하는 재난 및 광고와 같은 소셜 네트워크 서비스에서는 contact history를 이용하여 전송 경로를 설정하는데 한계가 있다.

[12], [13]에서는 소스 (source) 단말로부터 일정 범위 내에 분포되어 있는 불특정 다수의 단말들에게 적은 수의 전송으로 많은 수의 단말들에게 광고를 전송하기 위한 알고리즘을 제시했다. 특정 목적 노드가 존재하지 않기 때문에, 단말 분포를 이용해 광고 확산을 위한 목표지역 (target-area)을 설정한다. 하지만, 단말들이 특정 지역에 밀집되어 있는 분포를 따르는 경우에만 가능한 방법으로 단말들의 밀집도에 대한 정보가 없을 경우 한계가 존재한다. 본 논문에서는 단말들이 균일하게 분포되어 있는 일반적인 환경에서, 적은 수의 전송으로 가능한 많은 수의 단말들에게 광고를 전송하기 위한 기대최대화 (Expectation-Maximization, EM) 기반 사용자 클러스터링을 통한 D2D 광고 확산 알고리즘을 제안한다. 광고 확산을 위한 목표지역을 설정하기 위해 사용자들을 EM 클러스터링을 통해 다수의 클러스터로 분류하며, 각 클러스터의 주성분 (Principal Component, PC)을 구한다. 주성분은 각 클러스터에 포함된 사용자 분포에 대한 정보를 가지기 때문에, 이를 이용하여 목표지역과 광고 확산 경로를 설정할 경우, 효율적인 광고 확산 효과를 기대할 수

있다. 제안 방안의 성능 검증을 위한 시뮬레이션을 통해 광고를 수신한 사용자 수의 비율을 의미하는 포함 확률 (coverage probability) 및 사용자 당 평균 광고 수신 수 (average reception number per user)에 대해, 제안한 주성분 기반 알고리즘과 단순한 EM, k-means 클러스터의 중심값 기반 알고리즘 및 Epidemic 알고리즘의 성능을 비교 분석한다.

II. 관련 연구

Epidemic^[8]은 데이터를 수신한 모든 단말들이 릴레이 역할을 수행하는 flooding 기법이다. 송신 단말의 전송 수 대비 목적 단말이 데이터를 수신하는 수의 비율을 의미하는 데이터 전달률을 최대화 시키는 기법이다. 하지만, 다수의 불필요한 전송이 발생하면서 비효율적으로 에너지 및 자원을 소모하며, 네트워크의 과부하를 야기시킨다. 반면, ProPHET, Delegation Forwarding 및 PIS^[9-11]는 인접 단말과의 contact history를 이용하여 목적 단말로 데이터를 전송하기 위한 최적의 릴레이 단말을 선정하는 라우팅 기법이다. Contact history는 목적 단말과의 contact 주기 및 마지막 contact 시간 등과 같은 정보를 릴레이 선정 지표로 이용한다.

EM 및 k-means 클러스터링은 주어진 데이터들을 미리 설정한 클러스터의 개수로 분류 하는 기법으로 널리 알려진 계층적 비감독 클러스터링 알고리즘이다. 구체적인 EM 및 k-means 알고리즘은 다음과 같다.

2.1 EM 클러스터링 알고리즘

EM 알고리즘은 최대가능도 (Maximum Likelihood Estimation, MLE) 기법을 통해 사용자들의 분포를 가정한 확률 모델 (statistical model)로 최적화 시키는 기법이다^[14]. 본 논문에서는 사용자 분포를 수식 (1)과 같이 K개의 다변량 가우시안 (multi-variate Gaussian, $N(x|\mu_k, \Sigma_k)$) 분포가 혼합되어 있는 가우시안 혼합 모델 (Gaussian Mixture Model, GMM)을 가정한다.

$$p(x) = \sum_{k=1}^K \tau_k N(x|\mu_k, \Sigma_k). \quad (1)$$

μ_k , Σ_k 및 τ_k 는 각각 k번째 클러스터의 중심값,

1) 본 논문에서는 우선적으로 널리 사용되는 가우시안 분포를 가정하며, 추후에 포아송 분포와 같은 다양한 확률적 모델에 대해서 추가 연구할 예정이다.

공분산 (covariance) 및 가중치 (weight)를 나타낸다. 즉, 미리 설정한 클러스터의 수에 따라 사용자 분포, $\{x_1, \dots, x_N\}$ 에 적합한 GMM을 찾기 위해 아래와 같은 반복적인 MLE 기법 통해 최적의 파라미터들 (μ_k, Σ_k, τ_k)을 구한다.

- ① 파라미터 τ_k, μ_k 및 Σ_k 의 초기값을 설정한다.
- ② 초기값으로 설정되거나 새롭게 업데이트된 파라미터들을 이용하여 분포된 사용자, x_n 이 k번째 확률 모델에 포함될 사후 확률 (posterior probability, $\gamma(z_{nk})$)을 구한다.

$$\gamma(z_{nk}) = \frac{\tau_k N(x_n | \mu_k, \Sigma_k)}{\sum_{j=1}^K \tau_j N(x_n | \mu_j, \Sigma_j)} \quad (2)$$

- ③ ②에서 연산한 사후 확률은 사용자 분포에 더 적합한 확률 모델을 구하기 위해, 수식 (3)~(5)와 같이 계산한 파라미터들로 업데이트 한다.

$$\mu_k^{new} = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{nk}) x_n \quad (3)$$

$$\Sigma_k^{new} = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{nk}) (x_n - \mu_k^{new})(x_n - \mu_k^{new})^T \quad (4)$$

$$\tau_k^{new} = \frac{N_k}{N} \quad (5)$$

EM 알고리즘은 파라미터 τ_k, μ_k 및 Σ_k 가 수렴할 때까지 ②, ③의 과정을 반복적으로 수행한다. 분포된 사용자들은 최종적으로 얻은 각 확률 모델 중 가능도 (likelihood)가 가장 높은 모델로 분류된다.

2.2 K-means 클러스터링 알고리즘

K-means는 분포된 사용자, $\{x_1, \dots, x_N\}$ 를 미리 설정한 K개의 클러스터로 분류하는 알고리즘으로, 분포된 사용자와 각 클러스터의 중심값 (μ_k) 사이의 거리 차이 분산을 최소화하는 방식으로 동작한다. 수식 (6)은 k-means 알고리즘의 목적함수 (objective function)로써 제곱합 (sum of squares)의 형태로 표현한다^[4].

$$J = \sum_{n=1}^N \sum_{k=1}^K \gamma_{nk} \|x_n - \mu_k\|^2 \quad (6)$$

γ_{nk} 는 x_n 에 가장 인접한 클러스터를 나타내는 값으로, 수식 (7)과 같이 k번째 클러스터가 가장 인접한 클러스터인 경우 γ_{nk} 은 1 이 되며, 그렇지 않은 경우 0을 가진다.

$$\gamma_{nk} = \begin{cases} 1 & \text{if } k = \operatorname{argmin}_j \|x_n - \mu_j\|^2 \\ 0 & \text{otherwise.} \end{cases} \quad (7)$$

목적함수를 최소화하기 위해 아래와 같이 사용자들을 가장 인접한 클러스터로 분류하고, 분류된 사용자들을 이용해 각 클러스터의 새로운 중심값을 구하는 과정을 반복한다.

- ① 지정된 범위 내에서 무작위로 중심 값, $\{\mu_1, \dots, \mu_K\}$ 을 선정한다.
- ② 수식 (7)에서 초기값으로 설정되거나 새롭게 업데이트된 각 클러스터의 중심값을 이용하여, 사용자 x_n 이 k번째 클러스터의 중심값에 가장 인접한지 아닌지를 나타내는 γ_{nk} 를 구한다.
- ③ ②에서 γ_{nk} 를 통해 각 클러스터로 분류된 사용자들을 이용해 수식 (8)과 같이 각 클러스터의 새로운 중심값 μ_k^{new} 을 계산한다.

$$\mu_k^{new} = \frac{\sum_n \gamma_{nk} x_n}{\sum_n \gamma_{nk}} \quad (8)$$

K-means 알고리즘은 목적함수, J가 수렴할 때까지 ②, ③의 과정을 반복적으로 수행한다. 최종적으로 각 클러스터의 중심값과 분류된 사용자들을 구할 수 있다.

III. 기대최대화 클러스터링 기반 D2D 광고 확산 알고리즘

소스 단말은 가능한 많은 사용자들에게 광고를 전 송하고자 한다. 사용자들이 유효 범위 내에 무작위로 균일하게 분포 되어있을 경우, 광고 확산을 위한 적절한 목표지역 및 경로를 설정해야 한다. 또한, 설정된 경로에 따라 연속적으로 릴레이 단말을 선정하면서 최종 목표지역까지 광고가 확산되어야 한다. 따라서 제안 방안은 2가지 부분 알고리즘으로 구성되며, 구체적인 알고리즘은 다음과 같다.

3.1 목표지역 및 광고 확산 경로 설정

광고 확산을 위한 목표지역을 설정하기 위해, 소스 단말은 분포된 사용자들의 좌표정보에 따라 2차원에서 소개한 EM 클러스터링 알고리즘을 이용하여 GMM으로 모델링한다. GMM은 K개의 2-차원 가우시안 분포가 혼합되어 있는 형태로, 사용자들은 각각의 가우시안 분포를 따르는 클러스터로 분류된다. 임의로 지정한 위치에 있는 소스 단말 인근의 사용자 분포에 대한 정보는 상권정보시스템^[15]에서 제공하는 지역별 통계 자료를 이용하여 유추할 수 있다. 본 논문에서는 광고 확산을 위한 효율적인 목표지역을 설정하는데 있어, 어떠한 정보도 얻을 수 없는 무작위로 균일하게 분포되어 있는 형태를 가정한다.

EM 알고리즘에서 수식 (3), (4)를 통해 최종적으로 각 클러스터의 중심 (μ_k)과 공분산 (Σ_k)을 구할 수 있다. 각 클러스터의 PC는 공분산의 고유벡터 (eigenvector)를 통해 그림 1의 (a)와 같이 구할 수 있다^[16]. 이러한 K개의 PC들을 이용하여 그림 1의 (a)와 같이 3가지 목표지역을 설정한다.

- Boundary point (T_{BP}): 각 PC와 유효범위 경계의 교점으로 광고 범위를 제한하는 목표지역이다. 각 PC 당 2개의 T_{BP} 를 가진다.
- Intersection point (T_{IP}): 서로 다른 PC들의 교점으로 광고가 다른 PC로 확산되기 위한 목표지역이다. T_{IP} 는 다른 PC들과 교차하는 수에 따라 개수가 정해진다.
- Closest point (T_{CP}): 소스 단말과 가장 인접한 PC

의 한 지점으로 광고가 PC를 따라 확산하기 위한 단 하나의 목표지역이다.

각 클러스터의 PC들을 이용해 선정된 3가지 목표지역들을 이용하여 그림 1의 (a)와 같이 광고 확산 경로 (routing path)를 설정한다. 광고 확산 경로는 PC를 기반으로 생성된 선분을 따르기 위한 경로로써 아래의 알고리즘을 통해 설정된다.

- ① 소스 단말이 생성된 PC의 인근에 있지 않을 경우를 위해, 소스 단말로부터 T_{CP} 로 향하는 경로를 첫 번째 경로로 설정한다.
- ② T_{CP} 로부터 T_{BP} 를 포함하는 PC에 소속된 T_{IP} 들을 경유하여 T_{BP} 로 향하는 경로를 그 다음 경로로써 설정한다.
- ③ T_{IP} 는 2개의 서로 다른 PC의 교점으로, T_{IP} 를 포함하는 다른 PC의 직선을 ②와 같이 다음 경로로써 설정한다.
- ④ 광고 확산 경로 중 도달하는 모든 T_{IP} 에서 ③과 같은 과정을 수행하며, 모든 PC에 대한 경로가 설정되면 알고리즘을 종료한다.

3.2 광고 확산

광고 확산 경로가 설정되면 소스 단말이 광고 전송 및 릴레이 단말을 선정함으로써 광고 확산을 시작한다. 선정된 릴레이 단말은 최종 목표지역까지 광고를 확산하기 위해, 광고 확산 경로에 따라 연속적으로 릴레이 단말을 선정한다. 이와 같이 연속적인 릴레이 선정을 통한 광고 확산 알고리즘은 다음과 같다.




그림 1. 클러스터 수가 4일 경우, EM 또는 k-means 알고리즘 기반 클러스터의 주성분 또는 중심을 이용한 목표지역과 광고 확산 경로 설정의 예시.

Fig. 1. Example of determining target-areas and routing paths using PCs or centroids of each cluster based on EM or k-means algorithm when the number of clusters is 4.

- ① 소스 및 릴레이 단말은 D2D 통신 반경 내에 있는 사용자 단말들과 D2D Group을 형성하여 광고를 전송한다. 또한, 다음 릴레이 단말 선정을 위해 GPS를 통해 알고 있는 사용자들의 위치 정보를 요청한다.
- ② 사용자 단말들은 광고 수신 여부와 요청한 위치 정보를 전송한다.
- ③ 사용자들의 위치 정보를 수신한 소스 및 릴레이 단말은 사용자 단말들의 위치와 목표지역 간의 거리를 비교하여, 목표지역에 가장 인접한 사용자 단말을 다음 릴레이 단말로써 선정한다. 릴레이 단말의 통신 반경 내에 목표지역이 존재할 경우, 그 다음 목표지역을 기준으로 다음 릴레이 단말을 선정한다.
- ④ ①-③의 반복적인 과정을 통해 연속적으로 릴레이 단말을 선정하며, 경로의 최종 목표지역에 도달할 경우 광고 확산은 종료된다.

IV. 성능분석

MATLAB을 이용한 시뮬레이션 환경은 다음과 같다. 유효범위 1,000m 내에 5,000개의 사용자들이 무작위로 배치되어 있으며, D2D AP 및 단말의 전송 반경은 각각 200m, 80m로 가정하였다. 시뮬레이션을 통해 제안한 PC 기반 알고리즘과 EM, k-means 클러스터의 중심값 기반 알고리즘 및 Epidemic의 성능을 비교 분석한다.

- PADA(PC based Advertisement Dissemination Algorithm): 제안 방안으로 EM 기반 클러스터의 PC를 이용한 광고 확산 알고리즘
- CADA(Centroid based Advertisement Dissemination Algorithm): 그림 1의 (b), (c)와 같이 EM 및 k-means 기반 클러스터의 중심을 목표지역으로 설정하며, 모든 목표지역을 경유하는 최단거리를 확산 경로로 설정하는 광고 확산 알고리즘
- Epidemic: Flooding 기법으로 광고를 수신한 모든 사용자들이 릴레이를 수행하는 알고리즘

그림 2와 3은 각각 클러스터의 수에 따른 전체 사용자 수 대비 성공적으로 광고를 수신한 사용자 수의 비율을 의미하는 포함확률 (coverage probability)과 사용자 당 평균 광고 수신 수 (average reception number per user)를 나타낸다. Epidemic은 광고를 수신한 모든 사용자들이 릴레이를 수행하기 때문에, 분포되어 있는 모든 사용자들에게 광고를 확산 할 수 있다. 그 결과 그림 2에서 포함확률이 1인 결과를 보여

준다. 하지만 그만큼 불필요한 전송이 증가하여 사용자 당 평균 광고 수신 수가 다른 알고리즘에 비하여 월등히 높은 것을 그림 3에서 보여준다. 이러한 불필요한 전송이 많을수록 자원 및 에너지 효율성이 감소한다.

PADA는 각 클러스터로 분류된 사용자들의 분포를 예측할 수 있는 PC를 이용하여 그림 1 (a)와 같이 목표지역을 설정한다. 각 클러스터의 중심만 고려하는 CADA에 비하여, 다수의 목표지역을 전범위에 걸쳐 설정하기 때문에 확산 경로가 상대적으로 길어져 릴레이에 참여하는 사용자 수가 증가한다. 그림 4에서




그림 2. 클러스터 개수 변화에 따른 포함확률 결과
Fig. 2. Coverage Probability vs. Number of Clusters




그림 3. 클러스터 개수 변화에 따른 사용자 당 평균 수신 수
Fig. 3. Average Reception Number per User vs. Number of Clusters




그림 4. 클러스터 개수 변화에 따른 릴레이 참여확률
Fig. 4. Participating Probability for Relay vs. Number of Clusters

전체 사용자 수 대비 릴레이에 참여하는 사용자 수의 비율을 의미하는 릴레이 참여확률 (participating probability for relay)을 보여주며, PADA의 경우 클러스터의 수가 증가함에 따라 릴레이에 참여하는 사용자수가 급격하게 증가하는 것을 나타낸다. 그 결과 포함확률 측면에서 클러스터 수에 따라 차이는 있지만, PADA가 CADA 보다 약 2배 이상 좋은 성능을 가지는 것을 그림 2에서 보여준다. PADA에서 클러스터의 수가 3 이하 일 경우, 각 클러스터의 PC들이 교차하는 경우가 거의 발생하지 않아 생성된 대부분의 PC들로 광고가 확산되지 않는다. 반면, 클러스터의 수가 4이상 일 경우 각 PC들이 교차하는 경우가 급증하면서 대다수의 PC들로 광고를 확산할 수 있다. 그 결과 클러스터의 수가 3에서 4로 증가할 때, 포함확률이 급격하게 증가하는 것을 보여준다.

클러스터의 수가 50일 때, k-means 및 EM 기반 CADA의 포함확률은 각각 약 0.57과 0.43의 성능을 보여준다. 하지만 PADA의 포함확률은 Epidemic의 성능과 유사한 0.99까지 달성할 뿐만 아니라 사용자 당 평균 광고 수신 수가 Epidemic에 비해 약 3배가량 적은 것을 보여준다. 이에 따라, 제안 방안은 flooding 기법과 유사한 광고 확산 효과를 보여주며, 불필요한 전송을 줄임으로써 광고 확산을 위한 비용을 감소시킬 수 있다. 하지만, 클러스터의 수가 증가함에 따라 EM 알고리즘의 계산 복잡도 (computational complexity)가 급격하게 증가한다. 클러스터의 수가 50인 경우, PADA 및 EM 기반 CADA의 시뮬레이션 실행시간은 각각 10.0 및 8.9 초의 시간이 소요되는 반면, k-means 기반 CADA의 실행시간은 0.84 초를 기록했다.

클러스터의 수가 증가할수록 광고 확산 경로의 길이가 증가함에 따라 릴레이에 참여하는 사용자 수가 증가하여 광고를 수신 받는 사용자 수가 증가한다. 하지만, 불필요한 전송 및 수신이 상대적으로 증가할 뿐만 아니라 복잡도가 급격하게 증가하는 trade-off 관계에 있다. 이에 따라, 향후에는 최적의 클러스터 수를 찾는 알고리즘에 대한 연구가 필요할 것으로 생각된다.

V. 결론

본 논문에서는 유효범위 내에 사용자들이 무작위로 균일하게 분포되어 있는 경우, 가능한 많은 사용자들에게 광고를 확산하기 위한 알고리즘을 제안했다. 먼저, 기대최대화 알고리즘을 통해 사용자들을 미리 설정한 클러스터의 수로 분류한다. 각 클러스터로 분류

된 사용자들의 분포를 예측할 수 있는 PC를 구한다. 제안 방안은 각 클러스터로 분류된 사용자들의 분포를 고려하는 PC를 이용하여 목표지역과 광고 확산 경로를 설정한다. 그 결과 단순하게 각 클러스터의 중심을 이용하여 목표지역과 광고 확산 경로를 설정하는 알고리즘에 비하여, 제안 방안의 포함확률은 클러스터의 수에 따라 차이는 있지만 약 2배 이상 더 좋은 성능을 보여준다. 또한 클러스터의 수가 증가함에 따라 제안 방안의 포함확률은 flooding 알고리즘인 Epidemic의 성능과 유사해진다. 그리고 사용자 당 평균 광고 수신 수는 Epidemic에 비해 약 3배 가량 적은 것을 볼 수 있다. 따라서 제안 방안은 불필요한 전송은 줄이면서 대부분의 사용자들에게 광고를 전송할 수 있다.

References

- [1] L. Pelusi, A. Passarella, and M. Conti, "Opportunistic networking: Data forwarding in disconnected mobile ad hoc networks," *IEEE Commun. Mag.*, vol. 44, no. 11, pp. 134-141, Nov. 2006.
- [2] J. Joo, H. Lee, J. Kim, and D. S. Han, "A dual beaconing scheme for effective context awareness in vehicular ad hoc networks," *J. KICS*, vol. 39B, no. 2, pp. 114-122, Feb. 2014.
- [3] L. Lei, Z. Zhong, C. Lin, and X. Shen, "Operator controlled device-to-device communications in LTE-Advanced networks," *IEEE Wirel. Commun.*, vol. 19, no. 3, pp. 96-104, Jul. 2012.
- [4] D. Camps-Mur, A. Garcia-Saavedra, and P. Serrano, "Device-to-device communications with wifi direct: Overview and experimentation," *IEEE Wirel. Commun. Mag.*, vol. 20, no. 3, pp. 96-104, Jul. 2013.
- [5] M. Jung and S. Choi, "Analysis of energy efficiency considering device-to-device (D2D) communications in cellular networks," *J. KICS*, vol. 38A, no. 7, pp. 571-579, Jul. 2013.
- [6] G. Kang and O. Shin, "Resource and power allocation method for device-to-device communications in a multicell network," *J. KICS*, vol. 40, no. 10, pp. 1986-1993, Oct.

2015.

[7] A. Osseiran, et al., "Scenarios for 5G mobile and wireless communications: The vision of the METIS project," *IEEE Commun. Mag.*, vol. 52, no. 5, pp. 26-35, May 2014.

[8] A. Vahdat and D. Becker, *Epidemic routing for partially-connected ad hoc networks*, Duke Tech Report CS-2000-06, 2000.

[9] A. Lindgren, A. Doria, and O. Schelen, "Probabilistic routing in intermittently connected networks," *ACM Mobile Computing and Commun. Rev.*, vol. 7, no. 3, pp. 239-254, Jul. 2004.

[10] V. Erramilli, et al., "Delegation forwarding," in *Proc. ACM MobiHoc 2008*, pp. 251-260, Hong Kong, China, May 2008.

[11] F. Xia, et al., "PIS: A multi-dimensional routing protocol for socially-aware networking," *IEEE Trans. Mob. Computing*, vol. 15 no. 11, pp. 2825-2836, Nov. 2016.

[12] J. Kim and H. Lee, "VADA: Wi-Fi direct based voluntary advertisement dissemination algorithm for social commerce services," in *Proc. IEEE VTC Spring 2015*, pp. 1-6, Glasgow, Scotland, May 2015.


[13] J. Kim and H. Lee, "Geographical proximity based target-group formation algorithm for efficient D2D advertisement dissemination," in *Proc. IEEE PerCom 2015*, pp. 275-278, St. Louis, Missouri, USA, Mar. 2015.

[14] C. Bishop, *Pattern Recognition and Machine Learning*, Springer, New York, 2006.

[15] *SEMAS Marketing Area Analysis System*, Retrieved, Apr., 08, 2017, from <http://sg.kmdc.or.kr/main.sg#/main>

[16] I. T. Jolliffe, *Principal Component Analysis*, John Wiley & Sons, 2002.

김 준 선 (Junseon Kim)



2014년 2월 : 국립환경대학교 전
자공학과 학사
2016년 2월 : 국립환경대학교 전
기전자제어공학과 석사
2016년 3월~현재 : 울산과학기술
연구원 컴퓨터공학과 박사과정

<관심분야> IoT/Mobile Network Architecture and
Protocol Design

이 호 원 (Howon Lee)



2009년 : KAIST 전기및전자공
학과 박사
2009년~2010년 KAIST IT융
합연구소 선임연구원
2010년~2012년 KAIST IT융
합연구소 팀장/연구조교수

2012년~2016년 : 국립환경대학교 전기전자제어공학
과 조교수

2015년~2016년 : 국립환경대학교 IT융합연구소장

2016년~현재 : 국립환경대학교 전기전자제어공학과
부교수

2012년~현재 : KAIST IT융합연구소 겸직교수

<관심분야> 5G 모바일 네트워크, 사용자 클러스터
링, 3D 비디오 통신 등