

# IoT 정보 수집을 위한 확률 기반의 딥러닝 클러스터링 모델

정윤수

목원대학교 정보통신융합공학부 교수

## Probability-based Deep Learning Clustering Model for the Collection of IoT Information

Yoon-Su Jeong

Professor, Dept. of Information Communication & Engineering, Mokwon University

**요약** 최근 IoT 네트워크는 이기종의 IoT 장치에서 발생하는 데이터를 효율적으로 처리하기 위해서 다양한 클러스터링 기법들이 연구되고 있다. 그러나, 기존 클러스터링 기법들은 정적으로 네트워크를 분할하는데 초점을 맞추고 있어서 이동이 가능한 IoT 장치에는 기존 클러스터링 기법들이 적합하지 않다. 본 논문에서는 에지 네트워크를 이용하여 IoT 장치의 정보를 수집·분석하기 위한 확률적 딥러닝 기반의 동적 클러스터링 모델을 제안한다. 제안 모델은 수집된 정보의 속성값의 빈도수를 확률적으로 딥러닝에 적용하여 서브넷을 구축한다. 구축된 서브넷은 시드로 추출된 연계 정보를 계층적 구조로 그룹핑할 때 사용하며, IoT 장치에 대한 동적 클러스터링의 속도 및 정확도를 향상시킨다. 성능평가 결과, 제안모델은 기존 모델에 비해 데이터 처리 시간이 평균 13.8% 향상되었고, 서버의 오버헤드는 기존 모델보다 평균 10.5% 낮게 나타났다. 서버에서 IoT 정보를 추출할 때의 정확도는 기존모델보다 평균 8.7% 향상되었다.

**주제어** : 사물인터넷, 정보 수집 및 추출, 확률 기반, 딥러닝, 클러스터링

**Abstract** Recently, various clustering techniques have been studied to efficiently handle data generated by heterogeneous IoT devices. However, existing clustering techniques are not suitable for mobile IoT devices because they focus on statically dividing networks. This paper proposes a probabilistic deep learning-based dynamic clustering model for collecting and analyzing information on IoT devices using edge networks. The proposed model establishes a subnet by applying the frequency of the attribute values collected probabilistically to deep learning. The established subnets are used to group information extracted from seeds into hierarchical structures and improve the speed and accuracy of dynamic clustering for IoT devices. The performance evaluation results showed that the proposed model had an average 13.8 percent improvement in data processing time compared to the existing model, and the server's overhead was 10.5 percent lower on average than the existing model. The accuracy of extracting IoT information from servers has improved by 8.7% on average from previous models.

**Key Words** : Internet of Things, information collection and extraction, probability-based, deep learning, clustering

\*Corresponding Author : Yoon-Su Jeong(bukmunro@mokwon.ac.kr)

Received January 29, 2020

Revised February 21, 2020

Accepted March 20, 2020

Published March 28, 2020

## 1. 서론

IT 기술이 발달전하면서 네트워크 환경도 정적 환경에서 동적 환경으로 점점 변화하고 있는 상황이다. 그 이유는 데이터를 생성하는 장치가 과거에는 고정된 위치에서 수집하여 전송하였지만, 현재는 IoT 와 같이 이동이 가능한 장치를 통해서 데이터를 수집 및 전송하기 때문이다[1].

최근 네트워크에서 처리되는 데이터의 크기가 증가하면서 네트워크 서비스의 주된 목적은 데이터의 전송보다는 처리와 분석을 중요시하고 있다[2]. 특히, IoT 장치와 같은 이동성이 제공되는 장치는 환경 변화를 감지하고 측정하는 센서가 탑재돼 있어 수집된 데이터에서 가치를 추출하기 위한 데이터 분석이 필수적이다. 데이터 분석을 위해 사용되는 서비스로는 아파치 스파크 플랫폼, 클러스터링 및 딥 러닝(deep learning) 알고리즘 등이 있다[3].

클라우드 환경에서는 데이터를 효율적으로 수집 및 분석하기 위해서 중앙집중식 시스템에서 물리적으로 계산을 네트워크 가장자리와 데이터 소스로 밀어내는 에지 컴퓨팅이 제안되었다[4-6]. 에지컴퓨팅은 데이터 소스에 가까운 노드에서 계산의 일부 수행하기 때문에 클라우드로 전송하는 데이터 수를 줄여 지연 시간 및 응답 시간을 낮추었다. 에지 서버는 네트워크의 가장자리에 상주하면서 사실 네트워크와 인터넷 사이의 연결 역할을 수행한다[4]. Mao et al. 에서는 에지 컴퓨팅을 사용하여 기능을 추출하고 클라우드로 전송되는 피쳐 수를 줄이는 기법을 제안하였다[5].

본 논문에서는 네트워크 환경에서 이동성이 있는 IoT 장치를 이용하여 네트워크를 구성하고 있는 에지 서버와 노드들 간 데이터의 효율적인 수집·분석을 위한 확률적 딥러닝 기반의 동적 클러스터링 모델을 제안한다. 제안 모델은 IoT 장치의 정보를 효율적으로 수집·분석하기 위해서 수집된 정보의 속성 정보의 빈도수를 확률적으로 딥러닝에 적용하여 서브넷을 구축한다. 구축된 서로 다른 서브넷들은 에지 서버들의 연계 정보를 이용하여 계층적 구조로 그룹핑한다. 이 같이 하는 이유는 IoT 장치의 동적 클러스터링 속도 및 정확도를 향상시키기 위해서이다. 제안 모델은 IoT 정보를 효율적으로 분석할 수 있도록 딥 러닝 알고리즘을 적용하였다. 제안모델에서는 딥 러닝을 적용함으로써 IoT 장치의 데이터를 낮은 비용으로 정확하게 체크할 수 있다. 또한, 제안모델은 IoT 장치에서 수집된 정보를 처리하는 단계를 간소화시켰다.

이 논문의 구성은 다음과 같다. 2장에서는 딥러닝과

클러스터링 네트워크와 관련된 기존 연구에 대해서 알아본다. 3장에서는 IoT 정보 수집을 위한 확률 기반의 딥러닝 동적 클러스터링 모델을 제안하고, 4장에서는 기존 모델과 제안 모델을 비교 평가하고, 마지막으로 5장에서 결론을 맺는다.

## 2. 관련연구

### 2.1 인공지능 vs. 딥러닝

최근 인공지능과 관련된 보도가 미디어를 통해 알려지면서 딥러닝에 대한 관심이 대두되고 있다. 인공지능은 2015년 이후 병렬 처리 성능을 제공하는 GPU을 도입함으로써 모든 영역의 데이터(이미지, 텍스트, 맵핑 데이터 등)에 영향을 미쳤다[6]. 머신러닝은 알고리즘을 이용하여 데이터를 분석하고, 분석을 통해 학습하며, 학습한 내용을 기반으로 판단이나 예측을 하는 분야이다[7]. 머신러닝은 대량의 데이터와 알고리즘을 통해 작업을 학습한다. 머신러닝의 알고리즘 방식은 의사결정트리 학습, 귀납 논리 프로그래밍, 클러스터링, 강호 학습, 베이지안(Bayesian) 네트워크를 포함한다[8-9]. 딥러닝은 머신러닝의 특정한 분야로써 데이터로부터 연속된 층(layer)에서 점진적으로 의미 있는 표현을 학습하는 방식이다. 딥러닝은 뇌의 뉴런과 유사한 정보를 수백~수백만 개 학습시킨다.

### 2.2 기존 연구

최근까지 무선 환경에서 널리 사용되던 클러스터 기반의 데이터 수집 네트워크는 정적인 노드들을 이용하여 네트워크를 여러 그룹으로 클러스터링 한다. 클러스터링된 멤버 노드는 클러스터 헤드를 통해 데이터를 전송하였다[3,4].

기존 네트워크 클러스터링은 에너지 소비, 통신 지연 등 네트워크의 성능을 최적화하는 데 목적을 가진다 [10-12]. 또한, 대부분의 네트워크 클러스터링 솔루션은 네트워크의 글로벌 정보에 기초하기 때문에 이동이 가능한 IoT 장치에는 적합하지 않다. 글로벌 정보 없이 데이터를 전송하는 동적 IoT 장치를 위해서 일부 연구에서는 자기 적응형 자기 조직 시스템에 초점을 맞춘다[5]. Liu et al. 기법은 진화이론을 이용한 각 노드의 국부적 결정에 의해 네트워크를 최적화하는 클러스터링 기법을 제안하였다[13]. 이 기법은 복잡한 네트워크의 자원 관리 문제에 대처하기 위해서 강화 학습(RL)을 활용하였다. Mao et al. 기법은 네트워크 환경에서 여러 자원이 요구

하는 부분을 RL 문제로 변환하는 솔루션을 제안하였다 [14]. 이 기법에서 RL 모델은 실험을 통해 최첨단 휴리스틱 솔루션과 유사한 성능을 나타내었다. Ye et al. 기법은 DRL을 기반으로 차량 간 통신에 사용된 자원을 할당하는 메커니즘을 제안하였다[15]. 이 기법은 각 에이전트가 분산된 로컬 정보를 사용하여 자연 시간 제약 조건을 충족하기 위해 서버밴드 및 전송 전력을 최적화하도록 하였다.

### 3. 확률 기반의 딥 러닝 네트워크 클러스터링 모델

이 절에서는 네트워크 환경에서 IoT 장치를 이용하여 전송되는 대량의 데이터를 효율적으로 수집 및 분석하기 위한 딥 러닝 기반의 네트워크 클러스터링 모델을 제안한다. 제안 모델은 에지 서버에 전달된 IoT 정보의 속성 정보를 이용하여 계층적 서브넷을 구축하며, 서브넷 간 시드들의 연계 정보를 계층적으로 그룹핑함으로써 데이터 처리 속도 및 정확도를 향상시키는 특징을 가진다.

#### 3.1 개요

최근 다양한 분야에 인공지능이 적용되면서 네트워크 환경에 많은 변화가 일어나고 있다. 특히, IoT 장치를 통해 데이터를 처리하는 네트워크는 시간과 장소에 무관하게 실시간으로 센싱된 정보를 서버에 전달한다. IoT 기반의 네트워크 서비스는 이기종의 다양한 장치들을 통합하여 서비스를 제공하지만 단시간안에 수집된 데이터를 처리해야 하는 문제점을 가지고 있다.

본 논문에서는 네트워크 상에 존재하는 대량의 IoT 정보를 네트워크 구성 장치들을 이용하여 전달할 때, 대량의 수집 정보를 정확하게 전달할 수 있는 확률 기반의 딥러닝 클러스터링 모델을 제안한다. 제안 모델은 IoT 장치에서 수집된 정보를 빠르게 처리하기 위해서 IoT 정보의 확률정보를 서브넷의 시드로 구성함으로써 네트워크를 계층적으로 그룹핑한다.

제안 모델은 IoT 정보를 효율적으로 처리하기 위해서 다음과 같은 목적을 가진다. 첫째, 제안 모델은 네트워크 구성요소인 IoT 장치를 통해 수집된 정보의 특징에 따라 유사정보를 서브넷으로 묶는다. 둘째, 제안모델은 IoT 장치를 통해 수집된 정보의 분석 속도를 향상시키기 위해서 서브넷 정보에 딥러닝 알고리즘을 서로 연계하여 적용한다. 셋째, 계층적으로 그룹핑된 IoT 장치의 정보는

확률 기반의 빈도수를 적용하여 네트워크 처리 단계를 간소화 한다.

#### 3.2 시스템 모델

제안 모델의 시스템 모델은 Fig. 1처럼 IoT 네트워크와 엣지 컴퓨팅 서버가 포함되도록 IoT 동종 장치로 구성한다. IoT 장치는 임의의 지역에 배치되며 엣지 서버로 가는 통신 루트는 멀티 홉으로 되어있다고 가정한다. 네트워크를 구성하고 있는 IoT 장치의 정보는 주기적으로 수집한 후 멀티 홉 통신을 통해 에지 서버에 전송한다. 에지 서버는 전달된 정보를 병렬 처리하기 위해서 여러 개를 배치한다. 배치된 에지 서버는 수집된 정보가 균형있게 처리하도록 네트워크를 유지 관리하는 기능을 가진다. 여러 개의 에지 서버는 IoT 장치로 연결되며 네트워크는 클러스터로 분할된 후 분할된 클러스터에 최소 1개 이상이 상주하여 IoT 장치의 정보를 수집한다. 제안 모델에서 네트워크 클러스터링은 IoT 장치의 이동 위치와 데이터 수에 따라 변화된다. 제안 모델에서 네트워크에서 수집되는 데이터의 크기를 균등하게 유지하기 위해서 클러스터 영역에 존재하는 IoT 장치의 이동 정도를 반영한다.

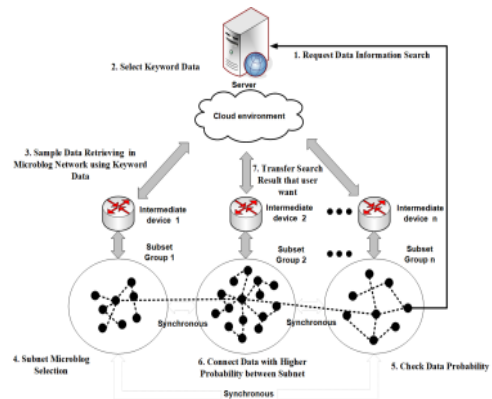


Fig. 1. Overall Process of Proposed Scheme

Fig. 1처럼 제안 모델은 서브넷의 크기가 IoT 장치에서 수집된 정보에 따라 연계정보를 이용하여 IoT 장치의 정보 수집 및 분석 속도를 향상시켰다.

#### 3.3 서브넷 생성

네트워크를 구성하는 IoT 장치들이 클러스터링을 통해 서브넷으로 구성되면, 각 서브넷은 에지 서버를 통해

IoT 장치 정보를 전달하게 된다. 이 때, 에지 서버는 연계정보를 통해 Fig. 2처럼 IoT 정보의 속성정보  $v_t$ 를 유사정도  $h_t$ 에 따라 시드  $\hat{y}_t$ 를 선택한다. 이 때, 서브넷은 네트워크를 클러스터링 할 때 사용된 연계 정보를 시드로 선택하여 IoT 장치의 유사정보를 Fig. 2과 같이 해쉬체인으로 묶는다.




Fig. 2. Subnet Component Generation using Deep Learning Algorithm

제안 모델은 Fig. 2처럼 IoT 장치에 따라 선별적으로 선택된 속성 정보와 서브넷 간 연계 정보를 해쉬체인으로 묶어 계층적으로 그룹핑한다. 이 때, 에지 서버는 수집된 정보를 데이터베이스에 저장되어 있는 정보와 비교하여 정확도를 향상시킨다. 에지 서버는 식 (1)과 같이 IoT 장치의 속성 정보와 연결 정도를 쌍으로 한 행렬 정보를 생성한다.

$$CI_k = \begin{pmatrix} x_{00} & \dots & x_{0j} \\ \dots & \dots & \dots \\ x_{i0} & \dots & x_{ij} \end{pmatrix}, \quad k=1,2,\dots, n \quad (1)$$

여기서,  $i$ 는 IoT 정보의 속성 수를 나타내며,  $j$ 는 연결 정도 수를 의미한다.

### 3.3.1 IoT 정보의 속성 정보 생성

제안 모델은 수집된 정보의 속성 정보를 부여하기 위해서 0과 1로 구성된 비트 수열을 식 (2)처럼 사용한다. 식 (2)는  $n$  비트의 상관관계 행렬을 사용한다. 식 (2)는 IoT 장치 정보의 상관 관계를 계층적으로 표현할 수 있다.

$$p_{i_k} = \{0, 1\}^* \rightarrow \{0, 1\}^N$$

$$= \begin{pmatrix} 0 & \lambda_{12} & \dots & \lambda_{1k} \\ \lambda_{21} & 0 & \dots & \lambda_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \lambda_{k1} & \lambda_{k2} & \dots & 0 \end{pmatrix} \quad (2)$$

여기서,  $k$ 는 IoT 장치에서 생성된 정보의 속성수를

의미하고,  $\lambda_{ij}$ 는 속성 정보 관계를 의미한다.

### 3.3.2 IoT 속성 정보 접근 방법

서브넷 상에 존재하는 IoT 정보의 속성 정보  $p_{i_k}$ 는 식 (3)와 같이 수집되면 서버는 식 (4)의 방법으로 IoT 정보의 속성 정보  $p_{i_k}$  중 일부 속성 정보  $M_l (= M_1 \cup M_2 \cup \dots \cup M_L)$ 를 추출할 수 있다.

$$\text{Gathering } p_{i_k} = (p_{i_1}, p_{i_2}, \dots, p_{i_n}) = \bigvee_{i=1}^n p_{i_n} \quad (3)$$

$$M_l = \{M_k | M_k \in p_{i_k}, 1 \leq l, k \leq L\} \quad (4)$$

### 3.4 IoT 정보 인증

네트워크가 클러스터링 된 후 서버는 에지 서버로부터 전달된 IoT 장치의 정보를 인증하기 위해서 제3자가 불법적으로 사용하지 못하는 동시에  $k$ 개의 속성  $p_{i_k} \in PI$  ( $1 \leq k \leq n$ )을 통해 IoT 정보를 인증하며, 다음과 같이 3 단계를 수행한다.

- 단계 1 : 네트워크를 구성하는 IoT 장치는 에지 서버를 통해 서버에게 공유키  $SK$ 로 암호화한 IoT 정보 인식자  $ID_V$ 와 공개키/개인키( $Q, q$ )를 전달한다.
- 단계 2 : 에지 서버로부터 전달된 IoT 정보의 인식자  $ID_V$ 를 서버가 비교 검증한 후 정상이라면 IoT 정보의 속성 값  $p_{i_k}$ 과  $\delta = h(ID_V, SK)$ 를 XOR 연산하여  $SID$ 를 생성한다.
- 단계 3 : IoT 장치는 서버로부터 전달받은  $SID$  정보 중  $p_{i_k} \oplus \delta$ 를 추출한 후 IoT 정보 인식자  $ID_V$ 와 공개키/개인키( $Q, q$ )를 사용하여  $\delta = h(ID_V, SK)$ 를 생성한다. 생성된  $\delta$ 는 서버로부터 전달된 정보와 비교한다.

## 4. 성능 평가

제안 모델과 기존 모델의 처리 시간, 오버헤드, 정확도 등을 평가한다.

### 4.1 실험환경

제안 기법을 수행하기 위해서 MatLab를 이용하여 Fig. 3과 같은 환경을 구성하였으며 Table 1과 같은 기본 파라미터를 설정하였다.




Fig. 3. Topology for experimental environment

Table 1. Simulation parameter

Parameter	Value
Network topology	Mesh topology
Number of server	1
Number of node	1-50
Number of relay nodes	5
Link capacity	1 Gbps
Link round trip delay	10ms
Internet Timeout Timer	500ms
Number of Subnet	$s = \{1, 2, 4, 8, 10\}$
Number of IoT Information	$d = \{1, 5, 10, 25, 50, 100\}$
Number of Property	$p = \{1, 2, 3, 4, 5\}$
Buffer	40 packet
Traffic	5 pkts/s

## 4.2 데이터 처리시간

Fig. 4은 제안 모델에서 IoT 장치의 데이터 처리 속도를 나타내고 있다. Fig. 4에서 제안 모델은 IoT 장치의 정보를 빠르게 처리하기 위해서 정보 속성과 확률 값을 연계하도록 하였다. 성능평가 결과, 서브넷 간 IoT 정보를 서로 연계 처리한 제안 모델은 처리시간이 기존 모델보다 13.8% 향상되었다. 이 같은 결과는 제안 모델이 IoT 장치에서 생성한 정보의 유사 정도를 비교한 후 적용하였기 때문에 나타난 결과이다.




Fig. 4. Data Process Time through the Number of IoT Device

## 4.3 오버헤드

Fig. 5은 IoT 정보 수집을 위해 딥러닝을 수행하는 서버의 오버헤드의 변화를 평가하였다. [Fig. 5]처럼 IoT 정보는 확률 연계 정보를 딥러닝에 적용하여 처리하기 때문에 기존 모델보다 서버의 오버헤드가 평균 10.5% 낮았다. 이 같은 결과는 제안 모델이 연계정보를 (확률값, 서브넷 정보) 쌍으로 서버에서 처리할 수 있도록 하였고, 연계 정보 중 확률정보가 높은 정보를 시드로 처리하도록 하였기 때문이다.




Fig. 5. Overhead of Server through the Number of IoT Device

## 4.4 정확도

Fig. 6은 IoT 장치에서 수집한 IoT 정보들을 서버에서 추출할 때의 정확도를 나타내고 있다. 제안 모델은 IoT 정보를 추출할 때 추출된 정보를 서버의 데이터베이스에 저장되어 있는 정보와 비교하여 정확도가 높은 정보만을 추출하였다. Fig. 6의 실험결과에서처럼 제안 모델은 IoT 정보의 확률 연계를 딥러닝에 적용하였기 때문에 기존 모델보다 정확도가 평균 8.7% 높게 나타났다. 이 같은 결과는 IoT 정보에 대한 확률값을 계층적 서브넷의 시드 값으로 사용하였기 때문에 나타난 결과이다.




Fig. 6. Accuracy through the IoT Property

## 5. 결과

최근 IT 기술이 발달함에 따라 데이터의 전송보다는 처리와 분석을 중요시하는 추세로 변화하고 있다. 특히, IoT 장치와 같은 이동이 가능한 장치는 데이터 분석에 활용되는 경우가 대부분이다. 대부분의 클러스터링 방법들은 에너지 소비, 통신 지연 등 네트워크의 성능을 최적화시키기 위해 사용되고 있다. 본 논문은 에지 네트워크 환경에서 IoT 장치의 정보를 이용한 확률적 딥러닝 기반의 동적 클러스터링 모델을 제안하였다. 제안 모델은 IoT 장치에서 수집되는 정보의 속성값의 빈도수를 확률적으로 딥러닝에 시드로 적용하여 서버넷을 구축하였기 때문에 기존 모델보다 향상된 결과를 얻었다. 성능평가 결과, 제안 모델은 처리시간이 기존 모델보다 13.8% 향상된 결과를 얻었고, 서버의 오버헤드는 평균 10.5% 낮았다. 제안 모델은 IoT 정보의 확률 연계를 딥러닝에 적용하였기 때문에 기존 모델보다 정확도가 평균 8.7% 높게 나타났다. 향후 연구에서는 본 연구의 결과를 기반으로 IoT 정보 분석 방법과 활용 방안을 이기중 클러스터 환경에 적용할 계획이다.

## REFERENCES

- [1] L. Cheng, S. Kotoulas, T. E. Ward & G. Theodoropoulos. (2017). Improving the robustness and performance of parallel joins over distributed systems, *Journal of Parallel and Distributed Computing*, 109, 310-323.
- [2] M. Zaharia, M. Chowdhury, M. J. Franklin, S. Shenker & I. Stoica. (2010). Spark: cluster computing with working sets, *Proceedings of the 2nd USENIX conference on Hot topics in cloud computing(HotCloud'10)*, 10-10.
- [3] W. R. Heinzelman, A. Chandrakasan HAND & alakrishnan. (2000). Energyefficient communication protocol for wireless microsensor networks, *Proceedings of the 33rd annual Hawaii international conference on System sciences, IEEE*, 10
- [4] G. Chen, C. Li, M. Ye & J. Wu. (2009). An unequal cluster-based routing protocol in wireless sensor networks, *Wireless Networks*, 15(2), 193-207.
- [5] H. Mao, M. Alizadeh, I. Menache & S. Kandula,. (2016). Resource management with deep reinforcement learning, in *Proceedings of the 15th ACM Workshop on Hot Topics in Networks*. ACM, 50-56.
- [6] X. Cui, J. S. Charles & T. Potok. (2013). GPU enhanced parallel computing for large scale data clustering, *Journal of Future Generation Computer Systems*, 29(7), 1736-1741.
- [7] G. Andrade, G. Ramos, D. Madeira, R. Sachetto, R. Ferreira & L. Rocha. (2013). G-dbscan: A gpu accelerated algorithm for density based clustering, *Journal of Procedia Computer Science*, 18, 369-378.
- [8] H. Karau, A. Konwinski, P. Wendell & M. Zaharia. (2015). Learning Spark: Lightning-Fast Big Data Analysis, *O'Reilly Media, Inc.* 1-276.
- [9] A. Katal, M. Wazid & R. H. Goudar. (2013). Big data: Issues, challenges, tools and Good practices, *2013 Sixth International Conference on Contemporary Computing(IC3)*, 404-409.
- [10] X. Cui, P. Zhu, X. Yang, K. Li & C. Ji. (2014) Optimized big data K-means clustering using MapReduce, *Journal of Supercomputing*, 70(3), 1249-1259.
- [11] Y. H. Kim, K. S. Shim, M. S. Kim & J. S. Lee. (2014). DBCURE-MR: an efficient density-based clustering algorithm for large data using MapReduce, *Journal of Information Systems*, 42, 15-35.
- [12] H. Hu, Y. Wen, T. S. Chua & X. Li. (2014). Toward Scalable Systems for Big Data Anaalytics: A Technology Tutorial, *IEEE Access*, 2, 652-687.
- [13] Q. Liu, A. Pruteanu, and S. Dulman. (2013). Gradient-based distance estimation for spatial computers, *The Computer Journal*, 56(12), 1469-1499.
- [14] Q. Liu, S. Dulman & M. Warnier. (2013). Area: an automatic runtime evolutionary adaptation mechanism for creating self-adaptation algorithms in wireless networks, *Proceedings of the Spatial Computing Workshop in AAMAS*, 23-28.
- [15] H. Ye & G. Y. Li. (2018). Deep reinforcement learning for resource allocation in v2v communications, in *2018 IEEE International Conference on Communications (ICC)*. IEEE, 1-6.

정윤수(Yoon-Su Jeong)

[정회원]



- 2000년 2월 : 충북대학교 전자계산학과 이학석사
- 2008년 2월 : 충북대학교 전자계산학과 이학박사
- 2009년 8월 ~ 2012년 2월 : 한남대학교 산업기술연구소 전임연구원
- 2012년 3월 ~ 현재 : 목원대학교 정보통신융합공학부 조교수

- 관심분야 : 유무선통신 보안, 정보보호, 센서 네트워크, IoT, 이동통신, 암호이론,
- E-Mail : bukmunro@mokwon.ac.kr