

딥러닝 기반의 다중 클라우드 환경에서 빅 데이터의 안전성을 보장하기 위한 비대칭 데이터 저장 관리 기법

정윤수

목원대학교 정보통신융합공학부 교수

Asymmetric data storage management scheme to ensure the safety of big data in multi-cloud environments based on deep learning

Yoon-Su Jeong

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

요약 분산 클라우드 환경에서는 다양한 이기종 장치의 정보들이 꾸준히 증가하고 있다. 이 같은 이유는 고속의 네트워크의 속도와 대용량의 멀티미디어 데이터가 사용되고 있기 때문이다. 그러나, 이기종의 장치에서 송수신되는 빅 데이터의 정보 오류를 최소화하기 위한 방법은 여전히 연구가 진행되고 있다. 본 논문에서는 클라우드 환경에서 송수신되는 정보들에 의해 발생하는 네트워크의 대역폭과 데이터 오류 최소화를 위한 딥러닝 기반의 비대칭적 저장 관리 기법을 제안한다. 제안 기법은 각각의 디바이스에서 생성되는 빅 데이터정보를 비대칭적으로 해시 처리한 후 로드 밸런스를 최적화하기 위해서 딥러닝 기술을 적용하고 있다. 제안 기법은 각 디바이스에서 수집된 빅 데이터의 오류를 허용하는 동시에 빅 데이터의 연계 정보를 n 개의 클러스터 그룹으로 그룹핑함으로써 빅 데이터의 연결성을 확보한 것이 특징이다. 특히, 제안 기법은 빅 데이터간의 유사 값을 시드로 추출한 손실 함수를 사용하였기 때문에 비대칭적으로 빅 데이터를 저장 관리 할때의 정보 오류를 최소화하였다.

주제어 : 클라우드, 빅 데이터, 비대칭, 딥러닝, 연계 정보, 로드 밸런스

Abstract Information from various heterogeneous devices is steadily increasing in distributed cloud environments. This is because high-speed network speeds and high-capacity multimedia data are being used. However, research is still underway on how to minimize information errors in big data sent and received by heterogeneous devices. In this paper, we propose a deep learning-based asymmetric storage management technique for minimizing bandwidth and data errors in networks generated by information sent and received in cloud environments. The proposed technique applies deep learning techniques to optimize the load balance after asymmetric hash of the big data information generated by each device. The proposed technique is characterized by allowing errors in big data collected from each device, while also ensuring the connectivity of big data by grouping big data into groups of clusters of dogs. In particular, the proposed technique minimizes information errors when storing and managing big data asymmetrically because it used a loss function that extracted similar values between big data as seeds.

Key Words : Cloud, Big data, Asymmetry, Deep learning, Link information, Load balance

*Corresponding Author : Yoon-Su Jeong(bukmunro@gmail.com)

Received January 25, 2021

Accepted March 20, 2021

Revised March 8, 2021

Published March 28, 2021

1. 서론

최근 클라우드 환경은 다양한 기기종 장치로부터 수집 되는 정보를 관리하기 위해서 다양한 기술들이 사용되고 있다. 그 중에서도 빅 데이터들에 대한 정보 오류를 최소화하기 위한 방법들 중에 해시 코드를 생성하여 빅 데이터의 의존성을 유지하는 방법들이 많이 사용되고 있다[1, 2].

클라우드 환경에서 사용되고 있는 해시 방법들은 크게 데이터 종속 방법과 데이터 독립 방법으로 구분되어 사용되고 있다[3]. 데이터 독립 방법은 초기 단계에 제안된 방법으로써 전형적인 데이터 독립 방법으로 랜덤 해시 함수를 통해 이진 해시 코드를 수행한다. 반면에 데이터 종속 방법은 데이터 독립 방법보다 성능측면에서 우수하며, 학습에 사용되는 라벨 정보에 따라 비지도 해싱으로 분류된다[4].

최근 몇 년동안, 클라우드 환경에서 해시 관련 연구는 전통적인 방법보다 더 나은 결과를 얻기 위해서 크로스-뷰 해시와 딥러닝 해시를 중심으로 연구가 대부분 진행되고 있다. 크로스-뷰 해시는 한 뷰의 쿼리 포인트가 서로 다른 뷰의 가장 가까운 인접 결과를 얻을 수 있도록 선형 투영 또는 비선형 투영법을 채택하고 있다. 딥러닝 해시는 원시 데이터에서 형상을 추출하기 때문에 상당한 정보 손실을 초래하는 단점을 가지고 있지만 검색 효율성 측면에서 효율성이 높아 딥러닝과 해싱 학습을 결합하고 있다.

본 논문에서는 클라우드 환경에서 처리되고 있는 빅 데이터의 안정적인 처리를 위한 딥러닝 기반의 비대칭적 저장 관리 기법을 제안한다. 제안 기법은 각 디바이스에서 생성되는 기기종의 빅 데이터를 비대칭적으로 해시 처리한 후 딥러닝 기술을 적용하였다. 제안 기법은 각 디바이스에서 수집된 빅 데이터의 오류를 허용하는 동시에 빅 데이터 연계 정보를 n 개의 클러스터 그룹으로 그룹핑함으로써 작은 크기로 분류된 빅 데이터의 연결성을 확보한 것이 특징이다. 또한, 제안 기법은 빅 데이터간의 유사 정도 값을 시드로 추출하여 사용하기 때문에 빅 데이터의 정보 오류를 최소화하였다.

이 논문의 구성은 다음과 같다. 2장에서는 클라우드 환경에서 사용하고 있는 해싱 기법에 대해서 알아본다. 3장에서는 클라우드 환경에서 빅 데이터의 안전성을 보장하기 위한 딥러닝 기반의 비대칭 저장 관리 기법을 제안하고, 4장에서는 제안 기법과 기존 기법을 비교 평가하고, 마지막으로 5장에서 결론을 맺는다.

2. 관련연구

클라우드 환경에 다양한 기기종의 장치들(PC, 태블릿, 휴대폰, 다양한 IoT 장치 등)이 사용되면서 텍스트, 이미지 그리고 멀티미디어 등의 콘텐츠들이 폭발적으로 증가하고 있어서 클라우드 서버에 저장되어 있는 정보를 원활하게 검색하는 해싱 기술들이 최근 가장 큰 이슈 중 하나로 대두되고 있다.

크로스-뷰 해싱 기법은 LSH[6], CVH[7], LCMH[8], CMSSH[9], CMFH[10] 등이 있다.

Gionis et al. 은 유사성이 높은 표본에서 랜덤 투영에 의한 확률이 높은 유사 이진 코드를 삽입한 LSH 기법을 제안하였다 [6]. 이 기법은 기존 기법에 비해 간단하고 구현하기 쉬운 장점이 있지만 실제 활용 측면에서 정확도가 낮고 인코딩 시간이 오래 걸리는 단점을 가지고 있다.

Kumar et al. 은 단일 뷰의 전통적인 스펙트럼 해싱을 크로스 뷰로 확장한 기법이다 [7]. 이 기법은 코드 간의 거리를 최소 해밍 거리가 되도록 고유값 분해로 해시 함수를 사용한 것이 특징이다.

Zhu et al. 은 혼란 복잡성을 줄이기 위해서 원본 데이터를 클러스터 중심에서 유사성을 유지하기 위한 기법을 제안하였다 [8]. 그러나, Bronstein et al. 은 해시 함수를 해킹 공간에 다양한 임의의 보기의 입력 데이터를 내장한 기법을 제안하였다 [9]. 이 기법은 유사성을 보존하기 위해서 많은 양의 컴퓨팅 능력과 많은 해시 코드 길이가 증가할 경우 효과가 감소하는 단점을 가지고 있다.

Ding et al. 은 집단 매트릭스 인수분해를 통해 이진 코드를 학습하는 경로 기법을 제안하였다 [10]. 이 기법은 해시 코드 길이로 인한 효과 감소를 해결하기 위해서 크로스 뷰 작업에서 검색 정확도를 향상시킨 것이 특징이다.

딥해쉬를 사용하는 기법은 DBRC[11], UDCMH[12], DMHOR[13], ADSh[14], DADH[15] 등이 있다.

Hu et al. 은 활성화 함수를 효율적으로 사용하기 위해서 Adaptive Tanh 함수를 제안하였다 [11]. 이 기법은 원본 데이터를 공통 해밍 공간에 투영하여 제약 조건을 통해 해시 코드를 유지하는 것이 특징이다.

Wu et al. 은 교차 모달 검색을 위한 제안된 비감독 심층 해싱 방법 중 하나의 기법이다 [12]. 이 기법은 해시 코드 내 유사성을 유지하기 위해서 원본 데이터를 공통 해밍 공간에 투영하기 때문에 검출 정확도는 높지만 혼란이 복잡한 것이 단점이다.

Wang et al. 은 표본간 상관관계를 이용하기 위해서 직교 단위를 사용한 딥 멀티모달 해싱 기법을 제안하였다[13]. 이 기법은 심층 신경 네트워크에 의한 멀티뷰 검색 수행이 가능한 것이 특징이다.

Jiang et al. 은 비대칭 심층 감지 해싱 기법으로써 쿼리 포인트에 대한 해시 함수만 학습한다 [14]. 이 기법은 해시 함수만 학습하기 때문에 성능을 유지하면서 계산 속도를 향상시킨 것이 특징이다.

Li et al. 는 형상 생성 능력을 향상시키기 위해서 2개의 심층 네트워크를 제안하였다 [15]. 그러나, 이 기법은 유사성을 보존하기 위해서 라벨 정보가 반드시 필요한 것이 단점이다.

3. 딥러닝 기반의 다중 클라우드 환경의 빅 데이터 저장 관리 기법

이 절에서는 빅 데이터의 빠른 처리를 위해서 딥러닝 기반의 다중 클라우드 환경의 빅 데이터를 안정적으로 처리하기 위해서 각 디바이스가 생성한 빅 데이터를 비대칭적으로 해시 처리하는 기법을 제안한다. 제안 기법은 시스템 모델 내 통신채널은 안전하다고 가정한다. Fig. 1 은 제안 기법의 전체적인 동작과정을 보여주고 있다.

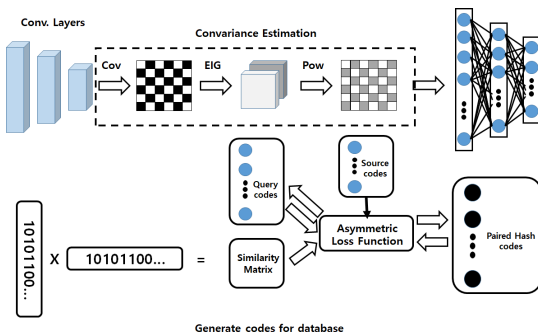


Fig. 1. Asymmetric storage management process of deep learning based proposal scheme

3.1 시스템 구성

제안 기법은 딥러닝 기반의 클라우드 환경에서 빅 데이터의 안전성을 보장하기 위해서 각 서버 계층이 빅 데이터를 비대칭적으로 해시 처리한 후 분산되어 있는 각각의 빅 데이터 정보를 로드 밸런싱하도록 딥러닝 처리한다. 제안 기법의 시스템 모델은 Fig. 2처럼 디바이스

장치 계층, 사전처리 계층, 처리 계층, 클라우드 계층 등 4개의 계층으로 구성되어 있다.




Fig. 2. System components of the proposed scheme

제안 기법을 구성하고 있는 각 계층에 대한 세부적인 정의는 다음과 같다.

· 디바이스 장치 계층

디바이스 장치 계층은 서버에 등록된 장치로써 수집된 정보를 서버로 전송하는 역할을 담당한다. 디바이스 장치는 모든 유형의 정보 타입을 포함하고 있으며 RTP 프로토콜을 통해 스트리밍이 기본적으로 지원된다. 디바이스 장치는 인터넷 통신 채널을 통해서 서버에 접속하여 등록 유·무를 확인받는다.

· 사전처리 계층

사전처리 계층은 클라우드 환경의 에지 레이어와 동일한 역할을 수행한다. 디바이스 장치로부터 수집된 정보는 상위 계층에 보내기 전에 대역폭을 줄이기 위해서 n 개의 크기로 분류한 후 로드 밸런싱 역할을 수행하는 처리 계층에 직접적으로 액세스를 수행한다.

· 처리 계층

처리 계층은 사전처리 계층으로부터 액세스에 대한 요청이 있을 경우 n 개의 크기로 분류된 빅 데이터들에 대해서 로드 밸런싱을 수행한다. 이 과정은 사전처리 계층보다 더 많은 계산력이 필요하지만 대역폭이 절약되고 빅 데이터의 인식 결과도 유지될 수 있다.

· 클라우드 계층

클라우드 계층은 디바이스 장치 계층에서 전달된 빅 데이터 정보를 모두 저장하며 저장된 빅 데이터 정보의 오류 체크를 통해 서비스 제공 유·무를 결정한다. 클라우

드 계층은 키를 생성하고 관리하는 역할을 담당한다.

3.2 해쉬 체인을 이용한 빅 데이터의 비대칭 처리 과정

3.2.1 빅 데이터 정보의 상관관계

디바이스 장치로부터 수집된 빅 데이터 정보는 로드 밸런스 전에 빅 데이터 정보를 식 (1)과 같이 $n \times n$ 행렬의 벡터로 정의한다. 빅 데이터 간 정확도는 식 (1)에서 d_{ij} 를 고유벡터의 쌍대비교 행렬로 나타낸다.

$$D = \begin{bmatrix} B_1 & 1 & d_{12} & \dots & d_{1n} \\ B_2 & d_{21} & 1 & \dots & d_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ B_n & d_{n1} & d_{n2} & \dots & 1 \end{bmatrix} \approx \begin{bmatrix} B_1 & w_1/w_1 & w_1/w_2 & \dots & w_1/w_n \\ B_2 & w_2/w_1 & w_2/w_2 & \dots & w_2/w_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ B_n & w_n/w_1 & w_n/w_2 & \dots & w_n/w_n \end{bmatrix} \quad (1)$$

식 (1)의 대각선을 중심으로 반대편의 빅 데이터는 역수 값의 형태를 취하며 빅 데이터 정보 간 상관관계의 가중치를 식 (2)~식 (4)처럼 생성한다.

$$d_{ik} = d_{ij} \cdot d_{jk} \quad (2)$$

$$d_{ij} = w_j/w_i \quad i, j=1, 2, \dots, n \quad (3)$$

$$d_{ij} \cdot d_{jk} = (w_j/w_i) \cdot (w_k/w_j) = a_{ik} \quad (4)$$

제안 기법에서는 쌍대비교 행렬 d_{mn} 과 d_{nm} 사이에서 m 이 0이상이고 n 이 1미만일 때, 동일한 결과 값을 가질 수 있으며, d_{mn} 이 0이라면 빅 데이터 정보 간 상관관계는 존재하지 않는다.

3.2.2 비대칭 처리를 위한 빅 데이터 연계 정보

빅 데이터의 비대칭 처리를 위한 연계 정보를 구하기 위해서 제안 기법에서는 고유벡터의 쌍대비교 행렬인 d_{ij} 의 i 번째 벡터와 j 번째 벡터 사이의 연계 정보 R_{ij} 를 이용한다. 로드 밸런스 과정에서 생성되는 연계정보 R_{ij} 는 디바이스 계층에서 생성한 벡터 정보가 k 번째의 사전처리 계층에서의 연관성에 따라서 Fig. 3의 과정을 통해 식 (5)을 생성하게 된다.




Fig. 3. Big Data Link Information for Asymmetric Processing

$$R_{ij} = \sum_{k=1}^h D_{ik}^x \times D_{jk}^y \quad (5)$$

여기서, D_{ik}^x 는 i 번째 벡터와 k 번째 사전처리 계층 사이의 연계성을 나타내고, D_{jk}^y 는 k 번째 벡터와 k 번째 사전 처리 계층 사이의 연계성을 나타낸다. Fig. 3에서 빅 데이터의 비대칭 처리를 위한 연계 정보는 디바이스 계층에서 수집된 정보를 해쉬 함수에 의해 처리한 로드 밸런스 정보를 이용하기 때문에 대역폭은 낮아지지만 사전 처리 계층에 비해 계산 비용은 더 소모된다. 그러나, 이 과정들을 통해 중복되는 빅 데이터 정보를 제거할 수 있을 뿐만 아니라 빅 데이터 간 정보 연계가 유지할 수 있다.

3.2.3 해쉬 체인을 이용한 빅 데이터의 비대칭 연계 정보 처리

제안 기법에서는 디바이스 장치로부터 수집된 빅 데이터 정보를 로드 밸런스 과정에서 연계성을 유지하기 위해서 빅 데이터 벡터를 이진 코드로 표현함으로써 처리 과정에서의 빅 데이터 손실을 최소화하고 있다.

제안 기법에서는 해쉬 체인을 이용하여 빅 데이터의 비대칭 연계 정보를 처리하기 위해서 n 개의 벡터 정보 $x_1, x_2, x_3, \dots, x_n$ 가 서로 직교하도록 비대칭적으로 그룹화하도록 한다. 로드 밸런스 과정이 끝난 빅 데이터의 비대칭 연계 정보의 그룹 과정은 식 (6)과 같이 수행한다.

$$g \cong c_1x_1 + c_2x_2 + \dots + c_nx_n \quad (6)$$

식 (6)의 비대칭 그룹 정보는 식(7)과 같은 확률 함수를 적용하여 벡터의 중요도를 확률 조건으로 활용한다.

$$E(D_i^x) = - \sum_{i=1}^n \frac{1}{n} \log \frac{1}{n} = \log n \quad (7)$$

4. 성능 평가

제안 기법은 다중 클라우드 환경에서 빅 데이터의 안전성을 보장하기 위해서 비대칭 저장 관리를 딥러닝을 이용하여 평가하였다.

4.1 실험환경

실험 평가를 위해서 비대칭적 빅 데이터 저장 관리에 따른 시뮬레이션 환경을 Table 1과 같이 설정하였다.

Table 1. Simulation parameter

Parameter	Value
Dataset Size	20,000
Training Set	18,000
Test Set	20,00
CPU	2.2 Gbps
Memory	128 GB
OS	Ubuntu 16.04.6
Number of Subnet	$s = \{2, 4, 6, 8, 10, 12\}$
Deep Learning Toolbox	MatConvNet

제안 기법은 Intel Xeon CPU E5-2630 @ 2.20GHz, 128GB 메모리 및 2080Ti GPU가 탑재된 Ubuntu 16.04.6 LTS 서버에 있는 딥러닝 도구 상자 MatConvNet[16]에 의해 구현하였다.

4.2 해시 코드 길이에 따른 비대칭 저장 속도

제안 기법은 다중 클라우드 환경에서 빅 데이터를 비대칭적으로 저장 관리하기 위해서 딥러닝을 사용하기 때문에 데이터셋에서 해시 코드 길이에 따른 비대칭 저장 속도가 Table 2와 같은 결과를 얻었으며 기존 기법에 비해 평균 13.3% 향상된 결과를 얻었다. 이 같은 결과는 각 서버 계층이 빅 데이터를 비대칭적으로 해쉬 처리한 후 분산되어 있는 각각의 빅 데이터 정보를 로드 밸런싱하도록 딥러닝하였기 때문이다. 특히, 제안 기법은 빅 데이터의 비대칭 처리를 위해서 디바이스 계층에서 수집된 빅 데이터 정보를 로드 밸런싱하기 때문에 해시 코드 길이에 따른 비대칭적 저장 속도가 기존기법에 비해 향상된

결과를 얻었다.

Table 2. Asymmetric storage speed(ms) by hash code length

Method	Hash code length			
	16	32	64	128
Hu et al. Scheme	0.624	0.638	0.643	0.674
Wu et al. Scheme	0.591	0.612	0.635	0.657
Wang et al. Scheme	0.417	0.445	0.475	0.517
Jiang et al. Scheme	0.399	0.424	0.448	0.489
Li et al. Scheme	0.368	0.394	0.421	0.433
Proposed Scheme	0.347	0.358	0.397	0.414

4.4 서버 저장 효율성

Table 3은 클라우드 환경에서 비대칭으로 빅 데이터를 로드 밸런싱하여 오류를 줄임으로써 서버 저장 효율성을 향상시키고 있다. 이 같은 결과는 디바이스 장치로부터 수집된 정보를 상위 계층으로 보내기 전에 대역폭을 줄일 수 있을 뿐만 아니라 n 개의 크기로 분류된 정보를 처리 계층에서 직접적으로 액세스를 수행할 수 있기 때문에 기존 기법보다 서버 저장 효율성이 평균 7.1% 높게 나타났다. 또한, 제안 기법은 코드 길이가 길어질수록 반폐어링된 데이터의 유사성과 학습 능력을 효과적으로 탐구함으로써 성능 효율이 높게 나타났다.

Table 3. Server storage efficiency(%)

Method	Hash code length			
	16	32	64	128
Hu et al. Scheme	42.932	47.646	53.581	62.273
Wu et al. Scheme	47.863	51.113	55.376	63.487
Wang et al. Scheme	52.714	55.672	59.535	64.961
Jiang et al. Scheme	58.425	61.713	63.743	66.749
Li et al. Scheme	60.678	63.552	66.827	69.352
Proposed Scheme	64.759	69.488	70.171	77.323

5. 결과

최근 클라우드 환경은 다양한 기기종 장치들에 의해 송수신되는 정보들을 오류없이 처리하기 위해서 다양한 데이터 저장 관리 기술들을 연구하고 있다. 그러나, 안정적으로 데이터를 저장 관리하는 과정 중에 데이터의 오류 및 처리 속도가 여전히 완벽하게 처리되지 않은 상황

이다. 본 논문에서는 클라우드 환경에서 처리되는 빅 데이터를 안정적으로 처리하기 위해서 딥러닝 기반의 비대칭적 저장 관리 기법을 제안하였다. 제안 기법은 크게 2가지 특징을 가지고 있다. 첫째, 제안 기법은 이기종의 장치에서 송수신되는 빅 데이터를 비대칭적으로 해시 처리하여 대역폭을 줄였다. 둘째, 제안 기법은 빅 데이터 연계 정보를 n 개의 클러스터 그룹으로 그룹핑함으로써 작은 크기로 분류된 빅 데이터의 연결성을 확보하였다. 제안 기법은 빅 데이터간의 유사 값을 시드로 추출하여 사용하기 때문에 빅 데이터의 정보 오류를 최소화하였다. 성능평가 결과, 제안 기법은 빅 데이터 정보를 비대칭적으로 저장 관리하기 위해서 딥러닝을 수행하였기 때문에 데이터셋에서 해시 코드 길이에 따른 비대칭 저장 속도가 기존 기법에 비해 평균 13.3% 향상된 결과를 얻었다. 또한, 제안 기법은 상위 계층으로 보내기 전에 대역폭을 줄이도록 n 개의 크기로 분류된 정보를 처리 계층에서 직접적으로 액세스를 수행하여 기존 기법보다 서버 저장 효율성이 평균 7.1% 높게 나타났다. 향후 연구에서는 본 연구의 결과를 기반으로 제안 기법이 다양한 분야에 활용가능함을 실험할 계획이다.

REFERENCES

- [1] S. Y. Wang, H. J. Lai, and Y. F. Yang, and J. Yin, "Deep Policy Hashing Network with Listwise Supervision," in Proceedings of the 2019 on International Conference on Multimedia Retrieval (ICMR-19), ACM, 2019, pp. 123-131.
- [2] S. Jin, H. X. Yao, and X. S. Sun, S. C. Zhou, L. Zhang, and X. S. Hua, "Deep saliency hashing," arXiv preprint arXiv:1807.01459 (2018).
- [3] J. X. Li, B. Zhang, G. M. Lu, and D. Zhang, "Dual Asymmetric Deep Hashing Learning," IEEE Access, vol.7, pp. 113372-113384. 2019
- [4] P. H. Li, J. T. Xie, Q. L. Wang, and W. M. Zuo, "Is Second-Order Information Helpful for Large-Scale Visual Recognition?" in 2017 IEEE International Conference on Computer Vision (ICCV-17), IEEE, 2017, pp. 2089-2097.
- [5] M. Zhou, X. H. Zeng, and A. Z. Chen, "Deep Forest Hashing for Image Retrieval," Pattern Recognition, 2019.
- [6] A. Gionis, P. Indyk, and R. Motwani, "Similarity search in high dimensions via hashing," VLDB, vol. 99, no. 6, pp. 518-529, 1999.
- [7] S. Kumar and R. Udupa, "Learning hash functions for cross-view similarity search," in Proc. 32nd Int. Joint Conf. Artif. Intell., Jun. 2011, pp. 1360-1365.
- [8] X. Zhu, Z. Huang, H. T. Shen, and X. Zhao, "Linear cross-modal hashing for efficient multimedia search," in Proc. 21st ACM Int. Conf. Multimedia (MM), 2013, pp. 143-152.
- [9] M. M. Bronstein, A. M. Bronstein, F. Michel, and N. Paragios, "Data fusion through cross-modality metric learning using similarity-sensitive hashing," in Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., San Francisco, CA, USA, Jun. 2010, pp. 3594-3601.
- [10] G. Ding, Y. Guo, and J. Zhou, "Collective matrix factorization hashing for multimodal data," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., Jun. 2014, pp. 2075-2082.
- [11] D. Hu, F. Nie, and X. Li, "Deep binary reconstruction for cross-modal hashing," IEEE Trans. Multimedia, vol. 21, no. 4, pp. 973-985, Apr. 2019.
- [12] G. Wu, Z. Lin, J. Han, L. Liu, G. Ding, B. Zhang, and J. Shen, "Unsupervised deep hashing via binary latent factor models for large-scale crossmodal retrieval," in Proc. Twenty-Seventh Int. Joint Conf. Artif. Intell., Jul. 2018, pp. 2854-2860
- [13] D. Wang, P. Cui, M. Ou, and W. Zhu, "Deep multimodal hashing with orthogonal regularization," in Proc. Int. Joint Conf. Artif. Intell., 2015, pp. 2291-2297.
- [14] Q.-Y. Jiang and W.-J. Li, "Asymmetric deep supervised hashing," in Proc. AAAI, 2017, pp. 3342-3349.
- [15] J. Li, B. Zhang, G. Lu, and D. Zhang, "Dual asymmetric deep hashing learning," IEEE Access, vol. 7, pp. 113372-113384, 2019.
- [16] A. Vedaldi and K. Lenc, "MatConvNet: Convolutional neural networks for MATLAB," in Proc. 23rd ACM Int. Conf. Multimedia (MM), 2015, pp. 689-692.

정 윤 수(Jeong, Yoon Su)



- 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