

딥러닝 및 증강현실을 이용한 재난대응 역량 강화를 위한 네트워크 자원 확보 방안[☆]

Deployment of Network Resources for Enhancement of Disaster Response Capabilities with Deep Learning and Augmented Reality

신 영 환¹ 윤 주 식¹ 서 순 호¹ 정 중 문^{1*}
Younghwan Shin Jusik Yun Sunho Seo Jong-Moon Chung

요 약

본 논문에서는 재난상황에서 딥러닝과 증강현실 기술을 활용한 재난대응 방안과 그에 따른 네트워크 자원 확보 방안을 제안한다. 딥러닝과 증강현실 기술의 특징과 현황을 파악하고, 재난분야와의 연관성에 관하여 설명한다. 딥러닝 기술을 사용하여 재난 상황을 정확하게 인지하고 관련 재난 정보를 증강현실로 구현하여 재난대응 현장 및 통합지원본부, 재난안전대책본부 등에 제공함으로써 재난대응 역량을 강화할 수 있다. 각종 재난사례 중 화재상황을 중점으로, 딥러닝 기반 화재상황 인식 및 증강현실 정보제공을 통해 효과적으로 재난대응 역량을 강화할 수 있는 방안을 제시한다. 마지막으로, 본 논문의 재난대응 방안을 활용하기 위한 네트워크 자원 확보 기법을 제시한다.

☞ 주제어 : 증강현실, 인공지능, 객체인식, 재난대응, 네트워크 자원

ABSTRACT

In this paper, a disaster response scheme based on deep learning and augmented reality technology is proposed and a network resource reservation scheme is presented accordingly. The features of deep learning, augmented reality technology and its relevance to the disaster areas are explained. Deep learning technology can be used to accurately recognize disaster situations and to implement related disaster information as augmented reality, and to enhance disaster response capabilities by providing disaster response On-site disaster response agent, ICS (Incident Command System) and MCS (Multi-agency Coordination Systems). In the case of various disasters, the fire situation is focused on and it is proposed that a plan to strengthen disaster response capability effectively by providing fire situation recognition based on deep learning and augmented reality information. Finally, a scheme to secure network resources to utilize the disaster response method of this paper is proposed.

☞ keyword : Augmented Reality, Deep learning, Object detection, Disaster Response, Network Resource

1. 서 론

최근 산불 및 화학물질 유출사고, 화재 등과 같이 전국적으로 다양한 유형의 사건, 사고가 발생하면서 재난 대응에 대한 관심이 집중되고 있다. 재난대응의 목표는 재난상황을 빠르게 인지하고 정확한 행동매뉴얼을 적용함으로써, 추가적인 인적 및 물적 피해를 최소화하는 것

이다. 그러나 재난상황을 빠르게 인식하고 정확한 행동매뉴얼을 적용함에 있어서, 인간이 모든 과정을 정확히 이행하기에는 한계가 있다. 재난 대응 담당자들의 재난역량은 재난을 경험하면서 향상되는 것이기 때문에, 재난 대응 담당자의 재난 대응 경험이 적다면 재난 대응 과정이 정확히 이행되기란 더욱 어려운 일이다. 게다가, 재난대응 과정에서는 통합지원본부 (Incident Command System, ICS), 지역재난대책본부 (Multi-agency Coordination Systems, MCS) 등 재난 대응 담당자들뿐만 아니라, 재난현장과 관련된 모든 사람의 협조가 필요하다. 그러나 평범한 사람이 항상 모든 재난현장을 감시하고 있고, 모든 매뉴얼을 숙지하기란 불가능하다. 이러한 문제점을 해결하기 위하여, 5G (5th Generation mobile networks), IoT (Internet of Things), GIS (Geographic Information System), WSN

¹ School of Electrical and Electronic Engineering, Yonsei University, Seoul, 03722, Korea.

* Corresponding author (jmc@yonsei.ac.kr)

[Received 19 July 2017, Reviewed 20 July 2017, Accepted 25 July 2017]

☆ 본 연구는 정부(국민안전처)의 재원으로 재난안전기술개발사업단의 지원을 받아 수행된 연구임 [MPSS-재난-2015-10]

(Wireless Sensor Network), MEC (Mobile Edge Computing), CDN (Content Delivery Network) 등 다양한 ICT기술을 재난 상황에 적용하려는 시도가 늘어나고 있다. [1-3] 최신 ICT기술 중에서 딥러닝 (Deep Learning, DL)과 증강현실 (Augmented Reality, AR) 기술력이 크게 향상되어 다양한 분야의 관심을 받고 있다. 다른 ICT기술들과 마찬가지로 딥러닝 및 증강현실 기술 역시 재난대응역량을 강화하는데에 사용될 수 있다. 그러나, 딥러닝과 증강현실 기술은 상당히 많은 네트워크 자원을 필요로 한다. [4]

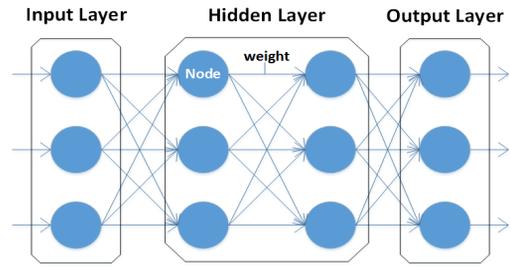
본 논문에서는 최신 딥러닝 및 증강현실 기술을 통한 재난대응 역량을 향상시킬 수 있는 방안과 그에 따른 네트워크 자원 확보 방안을 제시한다. 본 논문의 구성은 다음과 같다. 2장에서 딥러닝과 증강현실 기술을 설명한다. 3장에서 앞서 서술한 딥러닝 및 증강현실 기술을 재난 분야에 적용시킬 방안에 관하여 설명한다. 4장에서 그에 따른 네트워크 자원 확보 방안을 제시한다. 이어서 5장에서 결론을 맺는다.

2. 딥러닝 기반 객체인식 기술과 증강현실

2.1 딥러닝(Deep Learning)

딥러닝 (Deep Learning)은 머신러닝 (Machine Learning)의 한 분야이다. 머신러닝은 컴퓨터에게 문제를 해결할 수 있는 정확한 알고리즘을 제공하지 않고, 문제 해결능력을 배우게 하는 방법이다. 딥러닝에서는 컴퓨터가 인공신경망 (Artificial Neural Network)을 사용하여 문제 해결능력을 배운다. 인공신경망이란 인간의 뇌에 있는 신경망 (Neural Network)을 모사하여 만든 모델이다. 인간은 뇌를 쓰면서 신경망을 발달시켜 문제 해결 능력을 기른다. 이러한 인간의 특징에 주목하여, 컴퓨터에게 인간과 비슷한 문제 해결 과정을 부여하는 방법이 바로 딥러닝이다.

그림 1은 딥러닝에 사용되는 인공신경망의 구조를 간략하게 설명한 것이다. 인공신경망은 노드 (Node)들로 구성되어 있다 각 노드들은 가중치 (Weight)로 연결되어 있다. 딥러닝 기술을 통해 훈련시켜야 하는 가중치들이 모인 곳을 은닉계층 (Hidden Layer)라고 한다. 은닉계층의 계층의 숫자나, 노드의 숫자, 가중치의 숫자들은 모두 임의로 조절할 수 있다. 딥러닝의 최종 목적은, 테스트 데이터 (Test Set)를 인공신경망에 통과시켜서 원하는 결과 (Output)를 얻는 것이다. 딥러닝에서는 은닉계층에 가중치를 훈련용 데이터 (Training Set)를 이용하여 훈련 (Training) 시킨다. 훈련된 가중치를 이용하여 테스트 데



(그림 1) 인공신경망의 구조

(Figure 1) Structure of artificial neural network

(표 1) 인공신경망 적용 예

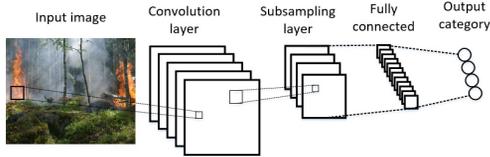
(Table 1) Usage of Artificial Neural Networks

인공신경망 종류	적용 예시
합성곱 신경망	이미지 인식, 영상 인식
순환 신경망	음성 인식, 텍스트 인식

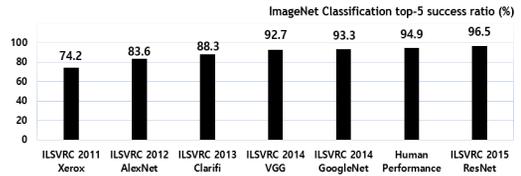
이터를 사용했을 때 정확한 결과를 얻게 한다. 인공신경망은 인간의 뇌를 참고하여 만든 것으로서, 노드는 뉴런 (Neuron)을 가중치는 시냅스 (Synapse)를 참고하여 만들어졌다. 인공신경망에는 다양한 종류가 있다. 인공신경망이 다양한 종류로 발전됨으로써 딥러닝 기술이 여러 연구 분야에 이용되기 시작했다. [5]

표 1은 대표적인 인공신경망의 종류와 그에 따른 딥러닝 기술 적용 예시를 나타낸 것이다. 합성곱 신경망 (Convolutional Neural Network, CNN)과 순환 신경망 (Recurrent Neural Network, RNN)은 현재 딥러닝 분야에서 가장 대표적인 인공신경망 모델이다. 합성곱 신경망은 현재 이미지 인식에서 가장 많이 쓰이는 모델이다. 2012년 ILSVRC라고 명명된 이미지 인식 기술 대회에서 합성곱 신경망으로 만들어진 Alexnet이 압도적인 차이로 우승한 이래로 합성곱 신경망의 이미지 인식분야에서의 우수성이 입증되어 왔다. [6] 순환 신경망은 현재 음성인식에서 가장 많이 쓰이는 인공신경망 모델이다. 현재, Apple의 Siri, Amazon의 Alexa 등 대부분의 ICT기업에서 음성 인식모델로서 사용하고 있다. 본 논문에서는 재난상황을 인식하기 위한 방법으로 합성곱 신경망을 쓸 것은 제안하며, 합성곱 신경망을 중심으로 서술한다.

그림 2는 합성곱 신경망의 구조를 나타낸 것이다. 합성곱 신경망은 동물의 시신경 구조를 모방하여 만든 것이다. 첫 번째 입력 이미지 (Input Image)와 합성곱 계층



(그림 2) CNN의 구조
(Figure 2) Structure of CNN



(그림 3) 역대 ILSVRC 우승 모델 성능
(Figure 3) Previous ILSVRC Winning Model Performance

(표 2) 대표적인 합성곱 신경망 모델
(Table 2) Representative CNN models

Network	Team
VGG	Visual Geometry Group (Oxford university)
Inception	Google
ResNet	Microsoft

(Convolutional Layer)의 사이에는 필터 (Filter)라는 값이 가중치를 대신한다. 필터를 움직이며 합성곱 연산을 진행한다. 인공신경망에서 가중치를 구해야 했던 것과는 달리 합성곱 신경망에서는 필터의 값을 구한다. 필터와 일반적인 가중치와의 결정적인 차이는 변수의 개수이다. 가중치는 각각의 계층마다 모든 노드와 연결되어 있기 때문에 개수가 많다. 그러나 합성곱 신경망에서는 필터 하나로 다음 계층의 값을 합성곱 연산을 통해 구하기 때문에, 필터의 개수만큼만 구하면 된다. 이러한 적은 연산량은 합성곱 신경망 모델의 큰 장점이 된다. 연산량이 적기 때문에 보다 빠른 계산이 가능해진다. 재난 상황에서는 빠른 대응이 필요하므로, 이러한 장점은 큰 도움이 된다.

표 2는 합성곱 신경망을 사용한 모델 중 대표적인 모델들을 정리해 놓은 것이다. 합성곱 신경망은 1998년에 Y. LeCun에 의해 처음 만들어졌다. [7] 그 후 발전을 거듭하여, 현재 VGG, Inception, ResNet 등은 모두 적게는 수십 개에서 많게는 백 개가 넘는 은닉계층을 갖는다. 은닉계층이 깊어짐에 따라서 합성곱 신경망은 점점 더 정교한 이미지 인식 기술을 갖게 되었다. 오늘날에는 ILSVRC에서 인간의 이미지 인식능력을 넘어서는 성능을 보인다. 그림 3은 역대 ILSVRC의 우승 모델 성능을 나타낸 것이다. 2015년에 Microsoft의 ResNet은 인간의 성능을 앞서기 시작했다. [8] VGG와 Inception 또한 그에 못지않게 뛰어난 성능을 보이고 있다. [9,10] 따라서, 이와 같은 최신 합성곱 신경망 모델을 재난 인식에 관하여 충

분히 훈련시킨다면, 실제 재난이 발생했을 때 빠르고 정확한 재난인식이 가능할 것이다.

2.2 증강현실(Augmented Reality, AR)

기존의 가상현실 (Virtual Reality)은 실제와 유사한 특정 환경을 만드는 기술이다. 만들어진 가상의 상황은 이용자의 감각을 자극하여 현실과 상상의 경계를 자유롭게 드나들게 하였다. 더 나아가 가상현실의 진보된 형태로 증강현실 (Augmented Reality)이 등장하였고, 증강현실에서는 현실위에 덧붙여진 추가적인 정보를 그래픽으로 합성하여 제공하므로 현실에서 이용자의 행동을 보조해 줄 수 있다. [11] 가상현실은 일반적으로 훈련, 게임 등의 특수 환경에서 사용되는 반면, 증강현실은 영상이 있는 환경이라면 어디에서나 적용할 수 있기 때문에 일반인들에게도 널리 대중화되고 있다.

증강현실은 GPS (Global Positioning System), 중력 가속도 센서 (Gravitational Acceleration Sensor) 등의 센서 정보나 OpenGL (Open Graphics Library) 등의 컴퓨터 비전 기술을 이용할 수 있다. [12] 증강현실 기술의 발전은 이러한 다양한 정보가 융합된 하이브리드 형태로 진화하고 있다. 증강현실 기기의 주 형태는 착용식 컴퓨터 (Wearable Computer)이다. 머리에 장착하는 HMD (Head Mounted Display), 안경 형태의 기기가 있으며 사용자가 바라보는 실제 환경에 컴퓨터 그래픽을 겹쳐 실시간으로 보여주어 증강현실을 구현한다. [13] HMD 형태의 증강현실 기기는 실제 재난상황 시 현장 소방대원에게 장착할 수 있다. 소방대원의 HMD 장비의 카메라에 의해 현장의 영상 정보를 얻는다. 본 논문에서는 현장의 영상 정보를 딥러닝 과정을 통해 인식하는 방법을 제안한다. 딥러닝을 토대로 얻은 정보는 네트워크를 통해 서버로 전송되고, 서버내의 데이터베이스 (Database) 정보와의 매칭을 통해 관련 증강현실 정보를 현장 대원에게 전달한

다. 이러한 일련의 증강현실 과정을 통해 현장에 파견된 재난대응 요원들은 구호활동에 필요한 정보를 맞춤형으로 제공받을 수 있다.

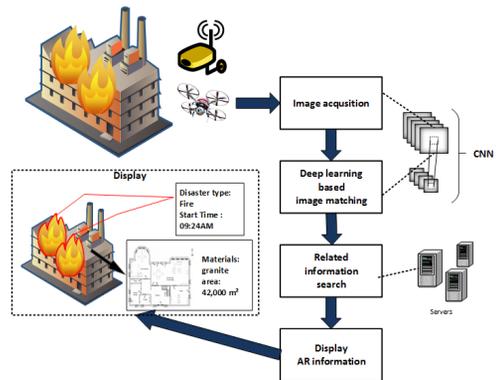
3. 재난상황에서 딥러닝을 활용한 증강현실 기술 적용 방안

재난대응의 성패는 크게 두 가지 요소에 달려있다. 첫 번째는 초동 대응의 속도이고, 두 번째는 초동 대응의 정확성이다. 앞서 언급했듯이, 재난 발생 시 인간이 바로 재난 상황을 포착하여 정확히 인지하기에는 큰 어려움이 있다. 모든 건물, 공장 등 지역을 인간이 언제나 감시하고 있을 수 없기 때문이다. 설사 재난을 바로 발견했다 하더라도 침착하게 재난의 종류, 재난의 시점, 재난의 규모 등을 바로 파악하여 정확한 초동대응이 이루어지게 하는 것은 일반인에게 어려운 일이다. 2017년 6월 런던 그린펠 타워 화재 재난을 보면 빠른 초동 대응과 정확한 대응의 실패로 작은 화재가 타워 전체로 옮겨가게 되었다.

딥러닝 기반 증강현실 기술을 사용하면 신속하고 정확한 재난 대응이 가능해진다. 그림 4에 딥러닝 및 증강현실 기술을 활용한 재난 대응 과정이 나타나 있다.

그림 4의 왼쪽 상단에는 드론, CCTV와 같은 무인으로 영상을 획득할 수 있는 기기를 통해 건물, 공장, 주택가, 산림지역 등 재난사고 유발 지역을 상시 감시하고 있는 장면을 나타낸 것이다. 그림에 나타난 장면은 공장 화재 발생 장면이다. CCTV나 드론과 같은 무인영상획득기기가 공장을 상시 감시하고 있다가 화재 장면을 포착한다. 화재 장면을 포착한 것만으로는 충분하지 않다. 일반적인 무인영상획득기기에는 화재 감별 능력이 없기 때문에, 일반적인 상황과 화재 상황을 분별할 수 없다. 무인영상획득기기에게 화재감별능력을 부여하기 위하여 딥러닝 기술이 사용된다. 획득된 영상 이미지는 Inception, VGG, ResNet 등 합성곱 신경망 모델을 사용한 딥러닝 기술로 분석 된다.

그림 5는 구글의 Inception-v3를 활용한 재난 이미지 인식의 예이다. [14] Python 3.5 기반 TensorFlow 0.12 라이브러리 (Library) 환경에서 실험한 것이다. 사고가 난 배를 Wreck이라고 정확히 인식하는 모습을 보여준다. 위와 같이 한 단어로 인식하는 것뿐만 아니라 이미지와 관련된 많은 설명을 도출하는 것도 가능하다. 그림 5의 실험에서 알 수 있듯이, 딥러닝 기술은 그림 4에서 예로 든 화재상황 뿐만 아니라 다양한 재난을 인지할 가능성을 내포하고 있다. 적절한 훈련 (Training)을 컴퓨터에 적용



(그림 4) 딥러닝 및 증강현실 기반 재난 정보 획득 과정 (Figure 4) Deep Learning and Augmented Reality Based Disaster Information Acquisition Process



(그림 5) Google Inception-v3를 이용한 이미지 인식 결과 (Figure 5) Image recognition using Google Inception-v3

한다면, 컴퓨터가 딥러닝을 활용해 화학사고 현장, 풍수 및 댐 붕괴 현장, 교통 및 선박 사고 현장 등 다양한 재난 상황을 인지할 수 있다. 이처럼 딥러닝을 통해 재난 상황 파악 속도와 정확성을 확보할 수 있다.

재난 대응에 있어서, 재난 상황 파악만큼 중요한 것이 바로 재난 관련 정보 획득이다. 화재 발생 시간, 장소, 규모, 공장의 구조 등등을 정확히 알고 있는 것이 중요하다. 재난 관련 정보가 단순히 글과 그림으로만 제공될 경우, 재난 대응 담당자가 정확히 파악하는 데 많은 시간이 소요된다. 지역재난대책본부, 통합지원본부 등 재난대응 담당자들이 재난 관련 정보를 파악해서 다시 현장요원들에게 제공한다 하더라도, 현장요원들이 정보를 파악하는 데 다시 한 번 시간이 소요된다. 2017년 6월 런던 그린펠 타워 화재 재난을 보면 알 수 있듯이, 초동대응에서의 시간지연은 대재난을 불러온다.

이를 증강현실 기술로 해결할 수 있다. 그림 4에 나타난 알고리즘의 후반부가 바로 이에 해당된다. 재난 유형,

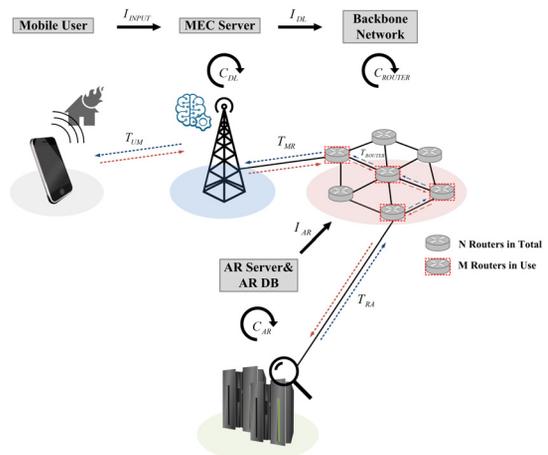
과거 사례, 재난 대응 방안, 유관 기관, 예상 피해 규모, 주변 상황 등 재난 관련 정보를 서버에서 찾아서 (Related information search) 증강현실 기술로 실감나게 표현하여 재난 대응 담당자에게 제공 (Display AR information) 한다. 이처럼 증강현실로 실감나는 정보를 제공한다면 재난 대응 담당자와 현장요원의 빠르고 정확한 재난 상황 이해와 대응이 기대된다.

4. 재난상황에서 딥러닝 및 증강현실 기술 적용을 위한 네트워크 지연 문제 해결 방안

앞서 서술하였듯이, 딥러닝 및 증강현실 기술을 사용하면 재난대응역량을 획기적으로 발전시킬 수 있다. 그러나, 딥러닝과 증강현실과 같은 최신 ICT 기술을 모바일 기기, CCTV 등에서 사용하기에는 기기에 부담이 많이 된다. 딥러닝의 경우 고성능의 CPU와 GPU뿐만 아니라 많은 전력 (Power)이 필요한 데, 모바일 기기 및 CCTV 등 소형 기기에 고성능 CPU 및 GPU에 많은 전력까지 확보하는 것은 불가능하다. 증강현실의 경우 다양한 정보를 서버에서 받아와야하기 때문에 네트워크 환경이 중요하다. 많은 계산과 통신 과정을 거쳐야 하므로 네트워크 지연문제가 생긴다. AR은 사용자에게 원본 이미지와 AR정보 합성까지 13ms 속도를 보장해야 한다. 13ms보다 시간이 지연되면 인간이 어지러움을 느낀다. [15] 그러나 기존 네트워크 환경에서는 딥러닝과 증강현실 기술을 전부다 사용하면서 13ms의 속도를 보장하기란 어렵다. 특히, 재난 상황에서는 네트워크 트래픽량이 폭주하기 때문에 더욱 힘들어진다. 본 논문에서는 이 문제를 해결할 네트워크 모델 및 해결 방안을 제시한다.

4.1 네트워크 모델

그림 6은 앞서 서술한 문제를 해결하기 위한 네트워크 모델이다. 딥러닝과 같은 계산량이 많은 기술을 모바일 상황에서 사용하기 위해 클라우드 형태의 네트워크 모델을 활용하는 방안이 활발히 연구되고 있다. [16] 본 논문에서도 클라우드 형태의 네트워크 모델을 제시한다. 모델에 관한 설명은 다음과 같다. 첫 번째로, 모바일 기기, CCTV 등에서 재난 이미지나 영상을 획득하여 MEC (Mobile Edge Computing) 서버에 I_{Input} 만큼 전송한다. 이때 소요되는 시간은 T_{UM} 이다. 그 뒤, MEC 서버에서 딥러닝 연산을 수행한다. 5G 시대에서는 MEC 서버가 상



(그림 6) 딥러닝 및 증강현실 기술을 재난 대응에 활용하기 위한 네트워크 모델

(Figure 6) Network Model for Utilizing Deep Learning and Augmented Reality Technology for Disaster Response

용화 되어, 각종 ICT 연산에 도움을 줄 것으로 예상 되고 있다. [17]

따라서, 본 네트워크 모델에서는 MEC 서버가 딥러닝 연산능력이 있다고 가정한다. MEC서버에서의 딥러닝 계산 속도는 C_{DL} 로 정의한다. 또한, MEC 서버는 사전에 충분한 딥러닝 훈련이 되어있다고 가정하여, 테스트(test) 과정을 수행한다고 가정한다. 딥러닝 연산 결과 I_{DL} 의 정보량이 나오며, 이 연산 결과를 AR 서버에 전송하여, 관련 정보를 획득하고자 한다. 이 때, AR 서버를 항상 근처에 두고 관련 DB를 확보하는 것은 힘들기 때문에 AR 서버와 DB (DataBase)는 재난 현장과 거리가 떨어져 있다고 가정한다. 따라서 AR서버에 접근하기 위해선 백본 네트워크 (Backbone Network)를 거치게 된다. MEC 서버에서 백본 네트워크에 있는 첫 번째 라우터까지 걸리는 시간을 T_{MR} 로 정의한다. 또한, 백본 네트워크에는 총 N 개의 라우터가 존재하고 그 중 M 개의 라우터를 사용한다고 가정한다. 또한, 라우터 간 통신 속도는 $T_{Routers}$ 라고 정의한다. 이 때, 총 $M-1$ 개의 라우터 간 통신이 이루어지기 때문에 백본네트워크에서 총 걸리는 시간은 $(M-1)T_{Routers}$ 이다. 또한 라우터에서 그리고 백본네트워크에 있는 마지막 라우터에서 AR서버 및 DB까지 걸리는 시간은 T_{RA} 이다. AR서버와 AR DB는 같은 장소

에 있어서 통신시간이 없다고 가정한다. AR서버에서는 딤러닝 연산 결과를 받고 AR 관련 정보를 DB에서 찾아서 관련 정보를 내보낸다. AR서버와 DB에서 일어나는 일련의 과정을 모두 포함한 계산 속도를 C_{AR} 로 정의한다. 정보를 DB에서 찾아오는 데 까지 시간이 상황마다 유동적으로 변할 것이므로 C_{AR} 은 평균 속도를 의미한다. 그리고 AR 정보량을 I_{AR} 로 정의한다. AR 정보를 받아 다시 유저에게 돌아가는 과정 및 시간은 이 전과 같다고 가정한다. 모델과 관련된 파라미터들은 표 3에 정리되어 있다. 따라서 유저가 AR정보를 받는 데 까지 총 걸리는 시간 T_{total} 은 다음과 같다.

$$T_{total} = 2T_{UM} + 2T_{MR} + \frac{I_{Input}}{C_{DL}} + M \frac{I_{DL}}{C_{Router}} + M \frac{I_{AR}}{C_{Router}} + 2(M-1)T_{Routers} + 2T_{RA} + \frac{I_{DL}}{C_{AR}} \quad (1)$$

4.2 네트워크 지연 문제 해결 방안

딤러닝과 증강현실을 사용하기 위해선 초저지연 네트워크 환경을 확보하는 것이 핵심이다. 그러나, 재난 상황에서는 네트워크 트래픽이 폭주하므로, 네트워크 속도를 확보하는 것이 쉽지 않다.

본 논문에서는 재난 상황에서는 다른 통신보다 재난 통신이 가장 중요하다는 점에 착안하여, 백본 네트워크에 있는 라우터들에게 일정 이상의 Forwarding rate를 확보하라는 패킷을 보내는 것을 제안한다. 딤러닝 및 증강현실을 위한 재난 통신이 이루어 질 때, 네트워크 관련 정보를 패킷에 실어서 보낸다. 그 정보를 보고, AR 서버에서 최종 결정하여, 백본 네트워크에 있는 라우터들에게 어느 정도의 Forwarding rate 성능을 보장하고 있어야 하는지 알려준다. 라우터들은 재난 상황에서 성능 보장을 위해, 재난 대응과 관련되지 않은 모든 통신 정보 처리를 후순위로 미룬다. 증강현실을 위해선 T_{th} 이내에 통신이 완료되어야 한다. 이를 식으로 표현하면,

$$T_{th} \geq T_{total} = 2T_{UM} + 2T_{MR} + \frac{I_{Input}}{C_{DL}} + M \frac{I_{DL}}{C_{Router}} + M \frac{I_{AR}}{C_{Router}} + 2(M-1)T_{Routers} + 2T_{RA} + \frac{I_{DL}}{C_{AR}} \quad (2)$$

(표 3) 네트워크 모델에 관련된 파라미터
(Table 3) Parameters related to network model

Parameter	Unit	Definition
T_{Total}	s	총 재난영상 AR처리까지 걸리는 시간
T_{th}	s	증강현실을 위해 요구되는 총 재난영상 AR처리까지 걸리는 시간
T_{UM}	s	User와 MEC 서버 간 전송 시간
T_{MR}	s	MEC 서버와 Router 간 전송 시간
T_{RA}	s	Router와 AR 서버 간 전송 시간
$T_{Routers}$	s	Router 간 전송 시간
C_{Router}	bps	Router의 Forwarding rate
C_{DL}	bps	MEC 서버의 이미지를 딤러닝 분석 성능
C_{AR}	bps	AR 서버의 증강현실 정보 검색 성능
I_{Input}	bit	재난 현장 영상 정보량
I_{DL}	bit	이미지 분석 결과 정보량
I_{AR}	bit	증강현실 정보 검색 결과 정보량
M	-	실제 통신에 활용되는 Router의 개수
N	-	백본 네트워크에 존재하는 총 Router 개수

라우터에서 확보해야 할 C_{Router} 를 구하기 위하여 C_{Router} 에 관하여 식을 정리하면 다음과 같다.

$$\frac{M(I_{DL} - I_{AR})}{T_{th} - 2T_M - (\frac{I_{DL}}{C_{AR}} + \frac{I_{Input}}{C_{DL}})} \leq C_{Router} \quad (3)$$

이 때, $T_M = T_{UM} + T_{MR} + (M-1)T_{Routers} + T_{RA}$ 을 뜻한다. 이 때, 최악의 네트워크 상황을 가정하여 Forwarding rate를 준비해야 하므로, N개의 라우터를 전부 다 지난다고 가정하면,

$$\frac{N(I_{DL} - I_{AR})}{T_{th} - 2T_N - (\frac{I_{DL}}{C_{AR}} + \frac{I_{Input}}{C_{DL}})} \leq C_{Router} \quad (4)$$

이 때, $T_N = T_{UM} + T_{MR} + (N-1)T_{Routers} + T_{RA}$ 을 뜻한다. 이 때, $I, I_{DL}, I_{AR}, I_{Input}, T_N$ 과 같은 값은 네트워크 엔티티 (Entity)의 성능과 관련이 없으므로 임의로 조정할 수 없다. T_{th} 는 요구되는 성능이므로 또한, 임의로 조정

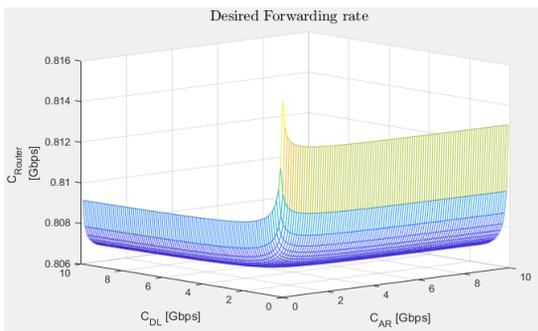
할 수 없다. C_{AR} 과 C_{DL} 값은 MEC나 AR서버에서의 계산 속도이므로 성능과 관련이 있다. 따라서 빠르면 빠를수록 좋을 것이라는 추측이 가능하다. 식 4에서는 이러한 사실이 잘 나타난다. C_{AR} 과 C_{DL} 값을 높일수록, 요구되는 C_{Router} 의 값이 낮아진다는 것을 알 수 있다.

4.3 실험 결과

본 실험은 MATLAB 2017a에서 진행되었다. 4번 식에서 C_{Router} 에 관한 요구 성능을 알아보기 위하여, C_{DL} 값과 C_{AR} 값을 조정하면서 C_{Router} 의 요구 성능을 측정해 보았다. 네트워크 환경과 관련된 파라미터들은 다음과 같다고 가정되었다.

T_{UM} , T_{MR} , T_{RA} 와 같은 통신 속도와 관련된 파라미터들은 1ms로 가정하였다. 라우터들의 거리는 매우 가까우므로 $T_{Routers}$ 는 0.1ms로 가정하였다. 또한, 인간이 증강현실을 체험할 때 어지러움을 느끼지 않는 지연시간이 13ms 이므로 T_{th} 는 13ms로 설정하였다. I_{AR} 은 1M bit, I_{DL} 은 2M bit, I_{Input} 은 5M bit로 가정하였다. 총 라우터의 개수 N은 5개로 가정하였다.

그림 7은 실험 결과를 나타낸다. C_{AR} 과 C_{DL} 이 높아질수록 요구되는 C_{Router} 가 낮아지는 것을 알 수 있다. 또한, C_{AR} 과 C_{DL} 이 너무 낮아질 경우 요구되는 C_{Router} 가 급격하게 높아지는 것을 볼 수 있다. 따라서, C_{AR} 과 C_{DL} 이 어느 정도 값을 보장해 주지 않으면 라우터의 부담이 급격하게 증가하는 것을 알 수 있다.



(그림 7) 딥러닝 계산속도와 AR 계산속도에 따른 Forwarding Rate 요구 성능
(Figure 7) Desired Forwarding Rate according to Deep Learning calculation speed and AR calculation speed

5. 결 론

본 논문에서는 재난대응 상황에서 딥러닝 및 증강현실 기술을 이용하여 재난대응 역량을 강화시킬 수 있는 방안을 제시하였다. 또한, 그에 따른 네트워크 성능 확보 방안도 제시하였다. 딥러닝 기술을 사용하는 모델인 인공신경망 중 합성곱 신경망을 사용한 모델은 현재 이미지 인식 분야에서 압도적인 성능을 내고 있다. 따라서, 빠르고 정확한 상황 인식이 중요한 재난 상황에서 합성곱 신경망기반 딥러닝 기술을 탑재한 기기는 재난대응역량을 강화할 수 있다. 컴퓨터가 재난을 인식한 것만으로는 실제 재난대응 담당자에게 정확한 정보를 제공하기 힘들다. 증강현실 기술을 사용하면, 재난 인식 정보를 가공하여 빠르고 알기 쉬운 정보로 바꿀 수 있다. 그러므로, 재난 대응 담당자가 정보를 더 빠르고 정확하게 받아들일 수 있다.

결론적으로, 딥러닝 및 증강현실 기술을 사용하여 실제 재난 대응 상황에서 현장요원 및 재난대응 담당자에게 정확하고 신속한 정보전달을 통해 재난 초기 대응 능력을 향상시킬 수 있다. 또한 통합지원본부, 지역재난대책본부와 같은 재난대책기관에 신속하게 현장상황을 보고하여 관련기관의 교통통제, 주민대피 등의 의사결정 과정을 보다 신속하고 정확하게 처리할 수 있다. 더 나아가 재난 상황에 로봇이 투입되는 등 자율적인 차세대 재난 대응 시스템 등이 활발히 논의되고 있으므로, 딥러닝 기반 증강현실 기술의 활용 분야는 미래에 더욱 중요해질 것으로 예상된다.

참 고 문 헌(Reference)

- [1] H. Nishiyama, M. Ito and N. Kato, "Relay-by-smartphone: Realizing Multihop Device-to-device Communications," *IEEE Commun. Mag.*, vol. 52, no. 4, pp. 56-65, Apr. 2014.
<https://doi.org/10.1109/MCOM.2014.6807947>
- [2] M. Kobayashi, "Experience of Infrastructure Damage Caused by the Great East Japan Earthquake and Countermeasures against Future Disasters," *IEEE Commun. Mag.*, vol. 52, no. 3, pp. 23-29, Mar. 2014.
<https://doi.org/10.1109/MCOM.2014.6766080>
- [3] T. Sakano, Z. Fadlullah, T. Ngo, H. Nishiyama, M. Nakazawa, F. Adachi, N. Kato, A. Takahara, T.

- Kumagai, H. Kasahara, and S. Kurihara, "Disaster-resilient Networking: a New Vision Based on Movable and Deployable Resource Units," *IEEE Network*, vol. 27, no. 4, pp. 40-46, Aug. 2013.
<https://doi.org/10.1109/MNET.2013.6574664>
- [4] D. Chatzopoulos, C. Bermejo, Z. Huang, and P. Hui, "Mobile Augmented Reality Survey: From Where We Are to Where We Go," *IEEE Access*, vol. 5, pp. 6917-6950, 2017.
<https://doi.org/10.1109/ACCESS.2017.2698164>
- [5] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, pp. 436 - 444, May. 2015.
<https://doi.org/10.1038/nature14539>
- [6] A. Krizhevsky, I. Sutskever, and G. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Proc. Neural Information and Processing Systems*, 2012.
<http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>
- [7] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based Learning Applied to Document Recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998.
<https://doi.org/10.1109/5.726791>
- [8] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," *Proc. IEEE conf. on comp. vision and pattern recognition*, pp. 770-778, 2016.
<https://doi.org/10.1109/CVPR.2016.90>
- [9] C. Szegedy, S. Ioffe, V. Vanhoucke, "Inception-v4, Inception-resnet and the Impact of Residual Connections on Learning," arXiv:1602.07261v2, Aug. 2016.
<https://arxiv.org/abs/1602.07261>
- [10] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," arXiv:1409.1556v6, Apr. 2015.
<https://arxiv.org/abs/1409.1556>
- [11] D. Chatzopoulos, C. Bermejo, Z. Huang, and P. Hui, "Mobile Augmented Reality Survey : From Where We Are to Where We Go," *IEEE Access*, vol. 5, pp. 6917-6950, Apr. 2017.
<https://doi.org/10.1109/ACCESS.2017.2698164>
- [12] R. Shea et al., "Location-Based Augmented Reality With Pervasive Smartphone Sensors: Inside and Beyond Pokemon Go!," *IEEE Access*, vol. 5, pp. 9619-9631, Apr. 2017.
<https://doi.org/10.1109/ACCESS.2017.2696953>
- [13] B. Thomas and C. Sandor, "What Wearable Augmented Reality Can Do for You," *IEEE Pervasive Computing*, vol. 8, no. 2, pp. 8-11, Jun. 2009.
<https://doi.org/10.1109/MPRV.2009.38>
- [14] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," arXiv:1512.00567v3, Dec. 2015.
<https://arxiv.org/abs/1512.00567>
- [15] M. Potter, B. Wyble, C. Hagmann, and E. McCourt, "Detecting Meaning in RSVP at 13 ms per Picture," *Attention, Perception, & Psychophysics*, vol. 76, no. 2, pp.270-279, 2014.
<https://doi.org/10.3758/s13414-013-0605-z>
- [16] N. Lane and P. Georgiev, "Can Deep Learning Revolutionize Mobile Sensing?," *Proc. 16th ACM Int'l. Wksp. Mobile Computing Systems and Applications*, pp. 117 - 122, 2015.
<https://doi.org/10.1145/2699343.2699349>
- [17] D. Sabella, A. Vaillant, P. Kuure, U. Rauschenbach, and F. Giust, "Mobile-Edge Computing Architecture: The role of MEC in the Internet of Things," *IEEE Consumer Electronics Magazine*, vol. 5, no. 4, pp. 84-91, Oct. 2016.
<https://doi.org/10.1109/MCE.2016.2590118>

◎ 저 자 소개 ◎



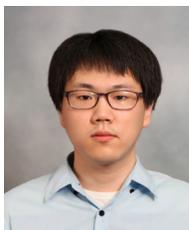
신 영 환(Youngwan Shin)

2016년 연세대학교 전기전자공학과 (공학사)
2016년~현재 연세대학교 대학원 전기전자공학과 석박사통합과정
관심분야 : Cognitive Radio, Deep Learning, etc.
E-mail : shinyh1115@yonsei.ac.kr



윤 주 식(Jusik Yun)

2016년 연세대학교 전기전자공학과 (공학사)
2016년~현재 연세대학교 대학원 전기전자공학과 석박사통합과정
관심분야 : Trust, Augmented Reality, etc.
E-mail : awp212@yonsei.ac.kr



서 순 호(Sunho Seo)

2014년 연세대학교 전기전자공학과 (공학사)
2014년~현재 연세대학교 대학원 전기전자공학과 석박사통합과정
관심분야 : Trust, Augmented Reality, etc.
E-mail : trial@yonsei.ac.kr



정 종 문(Jong-Moon Chung)

1992년 연세대학교 전자공학과 (공학사)
1994년 연세대학교 대학원 전자공학과 (공학석사)
1999년 Pennsylvania State University, Dept. of Electrical Engineering (공학박사)
1997년~1999년 Assistant Professor & Instructor, Pennsylvania State University, Dept. of Electrical Engineering
2000년~2005년 Director, Advanced Communication Systems Engineering Laboratory (ACSEL)
2000년~2005년 Director, Oklahoma Communication Laboratory for Networking & Bioengineering (OCLNB)
2000년~2005년 Associate Professor (Tenured), Oklahoma State University, School of Electrical & Computer Engineering
2005년~현재 연세대학교 전기전자공학과 교수
관심분야 : IoT & Smartphones, Smart Cars & ITS, Military Communications, NFV / ICN / SDN, LTE-A / 5G Networks, Cloud Computing & Big Data, Public Safety AR Simulators and Networking.
E-mail : jmc@yonsei.ac.kr