

딥러닝을 활용한 에지 컴퓨팅 기반의 지능형 컨스트럭션 영상 관제 시스템

김귀훈*, 서방원**

Intelligent Construction Video Management System Based on Edge Computing Using Deep Learning

Kwihoon Kim*, Bangwon Seo**

이 논문은 2015년도 정부(미래창조과학부)의 재원으로 국가과학기술연구회 융합연구단 사업(No. CRC-15-05-ETRI)의 지원을 받아 수행된 연구임. 또한, 이 논문은 2018년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임. (No. 2016R1D1A3B03935210)

요 약

인공지능 기술이 발달함에 따라 다양한 분야에서 인공지능을 적용하기 시작하였다. 특히, 산업계의 각 도메인 영역에서는 기존 서비스 형태에서 여러 가지 인공지능 기술을 적용하여 비용 절감이나 수익 창출하려는 시도가 많이 발생하고 있다. 지능형 컨스트럭션 영상 관제 시스템은 민원 발생시 현장에서의 소음, 진동, 가스 수치 및 현장 영상을 최대한 신속하게 동기를 맞춰서 온라인으로 보여주는 지능형 사물인터넷 현장 라이브 모니터링 시스템이다. 본 논문에서는 지능형 에지 컴퓨팅 기반으로 클라우드에 저장되는 현장 영상이 오버플로우(overflow) 되는 것을 방지하기 위해 효율적으로 에지 노드에서 클라우드로 전송되는 트래픽을 자동으로 제어하는 시스템을 구현한다. 구현된 시스템으로 성능 측정 결과를 확인해 보았고, 동일한 서비스 품질을 유지하면서 기존 대비 10%이상 트래픽 사용 감소율을 보이는 성능 개선 효과가 있었다. 이 시스템을 소규모 건설 현장에 적용할 경우에 매달 수십 만원 정도 통신비용을 절감할 것으로 보인다.

Abstract

With the development of artificial intelligence technology, artificial intelligence has begun to be applied in various fields. In particular, in each domain area of the industry, attempts are made to reduce costs or generate revenue by applying various artificial intelligence technologies in the existing service types. The intelligent construction video management system is an intelligent internet field live monitoring system that synchronizes noise, vibration, gas levels and on-site images at the site as quickly as possible and presents them online in the event of a civil complaint. Based on intelligent edge computing, this paper implements a system that automatically controls traffic transmitted from edge node to cloud efficiently in order to prevent overflow of field images stored in the cloud. Performance measurement results were checked with the implemented system and performance improvement was achieved with a traffic reduction rate of more than 10% compared to the previous one while maintaining the same quality of service. If the system is applied to small construction sites, it is expected to save some hundreds of thousands of won per month in communications costs.

Keywords

edge computing, machine learning, deep learning, video management system, supervised learning

* 한국전자통신연구원 KSB 융합연구단
- ORCID: <http://orcid.org/0000-0002-0798-1687>
** 공주대학교 전자공학전공
(IT융합기술연구소) 부교수 (교신저자)
- ORCID: <http://orcid.org/0000-0002-7152-1941>

• Received: May 14, 2019, Revised: Jun. 24, 2019, Accepted: Jun. 27, 2019
• Corresponding Author: Bangwon Seo
Dept. of Electrical, Electronics and Control Engineering, the Institute of IT
Convergence Technology (IITC), Kongju National University, Cheonan Korea,
Tel.: +82-41-521-9178, Email: seobw@kongju.ac.kr

1. 서 론

사물인터넷(Internet of Things, IoT)은 사물에 각종 센서와 통신 기능을 내장해 인터넷에 연결하는 기술을 의미한다. 참고문헌 [1]에서 보면, IoT 환경에서는 사물들 간의 연결성을 제공하기 위하여, 기존 인터넷 기술인 TCP/IP 또는, UDP/IP 스택을 탑재함으로써, 네트워킹 및 데이터 전송 서비스를 지원한다. 또한, 참고문헌 [2]에서는 매우 많은 IoT 디바이스들에게 IP 주소를 할당해야 되므로, 기존 인터넷 프로토콜인 IPv4로는 주소 할당이 불가능하며, 대신 IPv6를 이용하게 된다. 그리고 참고문헌 [3]에서 IoT 환경에 LPWA와 같은 새로운 무선 기술을 탑재하는 것이 가능하도록 하기 위하여, IPv6 계층과 MAC 계층 사이의 융합 레이어(Convergence layer)에 대한 표준화 및 구현 방법에 대한 연구가 진행되고 있다. 추가적으로, 응용 계층을 위해서는 HTTP를 경량으로(Lightweight) 만든 CoAP 등의 기술을 제공하고 있다.

향후 다양한 IoT 디바이스들이 늘어나는 것뿐 아니라, 이 단말들을 통해 발생하는 수 많은 데이터를 처리하기 위한 확장성, 그리고 효과적인 네트워킹 및 컴퓨팅 플랫폼 기술의 필요성이 대두되고 있다 [4]. 이에 따라, 사용자 및 IoT 디바이스 가까이에서 데이터를 처리하기 위한 에지 컴퓨팅(Edge computing) 기술이 대중화되고 있는 상황이며, 이동통신을 위한 모바일 에지 컴퓨팅(Mobile Edge computing, MEC) 기술이 이에 해당된다. 모바일 에지 컴퓨팅 기술은 디바이스, 액세스 게이트웨이(Access gateway), 그리고 기지국(Base station) 등에서 서비스에 필요한 기능 등을 직접 수행하는 것이다[5]. 한편, 포그 컴퓨팅(Fog computing) 기술은 디바이스와 인터넷을 통해 제공되는 중앙 클라우드 컴퓨팅(Cloud computing) 구조 사이에 위치하는 분산형 컴퓨팅 플랫폼으로서, 최근에 기술적 논의가 시작되고 있다. 기존의 다양한 IoT 서비스 분야를 위해 개발된 수많은 IoT 플랫폼과 함께, 이러한 다양한 에지 컴퓨팅 기술이 양립하는 상황에서, 이들을 통합 및 호환성(Inter-working)을 지원하기 위한 추가적인 연구 개발 및 표준화 활동이 진행 중이다[6].

인공지능 기술은 지속적으로 발달하여 통신기술과 접목하여 여러 가지 성능 효과를 보는 사례가 발생하고 있다. 참고문헌 [7]에서는 NDN에 지도학습 기법을 적용하여 많은 경우의 수를 줄이는 방법을 제안했다. 참고문헌 [8]에서는 ML 기법을 무선 안테나 선택하는 기술에 적용하였다. 또한, 딥러닝 자체 기술도 ImageNet 대회를 통해서 영상인식 기술을 경쟁하여 기술이 발전하는 장이 마련되었다 [9][10]. 참고문헌 [11]에서는 ResNet이 제안되어 97% 정확도로 사람보다 우수한 수준까지 이르렀다.

최근 건설 분야에서는 정부 주도 하에 여러 건설사들이 사물 인터넷과 스마트 홈 기술을 공동으로 개발하는 협약을 맺고, 관련 기술들을 개발하는 노력을 진행 중이다. 구체적으로는 국내의 대표적인 가전 업체들을 포함하여, 통신 회사, 반도체 센서 소프트웨어(SW) 업체, 그리고 한국토지주택공사(LH), 서울주택공사(SH)와 같은 건설 업체들이 참여하고 있다. 이처럼 스마트 홈 관련 기업들이 참여하여, 향후 스마트 홈 플랫폼간 상호 운용과 연계를 위해 협력하고 있다. 이러한 기반 위에, 참여 업체들은 스마트 건설 등에 대한 기술도 지속적으로 개발하고 있으며, 주택·건축·토목·플랜트 등 각종 건설 현장에 사물인터넷(IoT: 사물에 각종 센서와 통신 기능을 내장해 인터넷에 연결하는 기술)을 도입하고 모바일·웨어러블 기기, 드론(무인비행장치) 등을 활용함으로써, 건설 공정(工程) 전반을 실시간으로 관리하는 시스템을 개발하는 방향으로 확장해 나갈 계획이다.

스마트 건설 기술에서는 인터넷 사업자와 건설사 간 상호 기술을 융합하여 스마트 건설에 대한 서비스를 제공하고 있으며, 건설 현장의 공기 상태 정보를 실시간으로 알려주는 기술 및 서비스 등을 제공한다. 또한, 주변 거주자들에게 이러한 정보들을 제공하는 것은 상당한 효과가 있다. 건설 현장에서 발생할 수 있는 다양한 민원 등에 대해 사전에 예방할 수 있는 장점을 가지고 있다[12].

한편, 공사 현장에서 기존의 영상 관제 서비스는 24시간 대응량으로 고화질 영상을 모니터링을 하게 된다. 그리고 소규모 공사현장에서는 유선 인터넷 연결이 안 되기 때문에, 무선으로 연결하는 것이 일

반적이다. 따라서 기존의 영상 관제 서비스에서는 24시간 동안 무선으로 고해상도로 비디오를 전송하기 때문에, 통신비용이 많이 나오는 문제가 발생하게 된다.

본 논문에서는 이러한 문제를 해결하는 영상 관제 시스템을 구현한다. 건설 현장에서의 영상 관제 서비스 특성상, 밤 시간 대에는 일반적으로 공사를 하지 않기 때문에 이상 상황이 발생할 가능성이 낮고, 주로 낮 시간 대에 이상 상황이 발생하게 된다. 또한, 낮 시간 대 중에서도 일정 시간 동안 크게 공사를 수행할 경우에만 이상 상황이 발생하게 된다.

따라서 이러한 건설 현장에서의 특성을 고려하여, 평상시에는 비디오 영상을 저해상도로 제공하다가, 공사 소음이나 진동이 큰 경우에만 고해상도로 영상을 제공하는 것이다. 우선적으로 중요한 것은 현재 장비 구성을 최대한 활용하는 것이다.

단지, 추가로 에지 컴퓨팅 시스템을 제공함으로써, 비디오 전송량을 줄이고, 이상 상황이 발생할 때만 고해상도 영상을 제공하는 방안을 제안한다. 새롭게 구현한 영상 감시 시스템을 사용하여 성능 측정 결과를 확인한 결과, 동일한 서비스 품질을 유지하면서 기존 대비 10%이상 트래픽 사용 감소율

을 보이는 성능 개선 효과가 있었다. 따라서 이 시스템을 소규모 건설 현장에 적용할 경우, 매달 수십 만원 정도의 통신비용을 절감할 것으로 예측된다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 제안하는 지능형 컨스트럭션 영상 관제 시스템 모델을 설명하고, 3장에서는 예측 및 결정 알고리즘을 제안한다. 4장에서는 실제 구현을 통한 실험 결과를 통해 성능 개선 효과를 보여준다. 5장에서는 결론 및 향후 연구 계획에 관해서 설명한다.

II. 제안하는 지능형 컨스트럭션 영상 관제 시스템 모델

그림 1은 지능형 컨스트럭션 영상 관제 시스템 구성도로서, 스마트 IoT 건설 모니터링을 위한 지능형 IoT 에지 컴퓨팅 기술의 네트워크 구성도이다. 공통 구조로서 지능형 에지 컴퓨팅과 머신러닝 프레임워크 시스템이 있고, 왼쪽에 있는 부분은 센싱 박스를 나타내며 오른쪽에 있는 부분은 클라우드 서비스로 연동되는 네트워크를 나타낸다. 그리고 민원인, 현장 감독관, 시스템 관리자는 클라우드를 통해서 서비스를 이용한다.

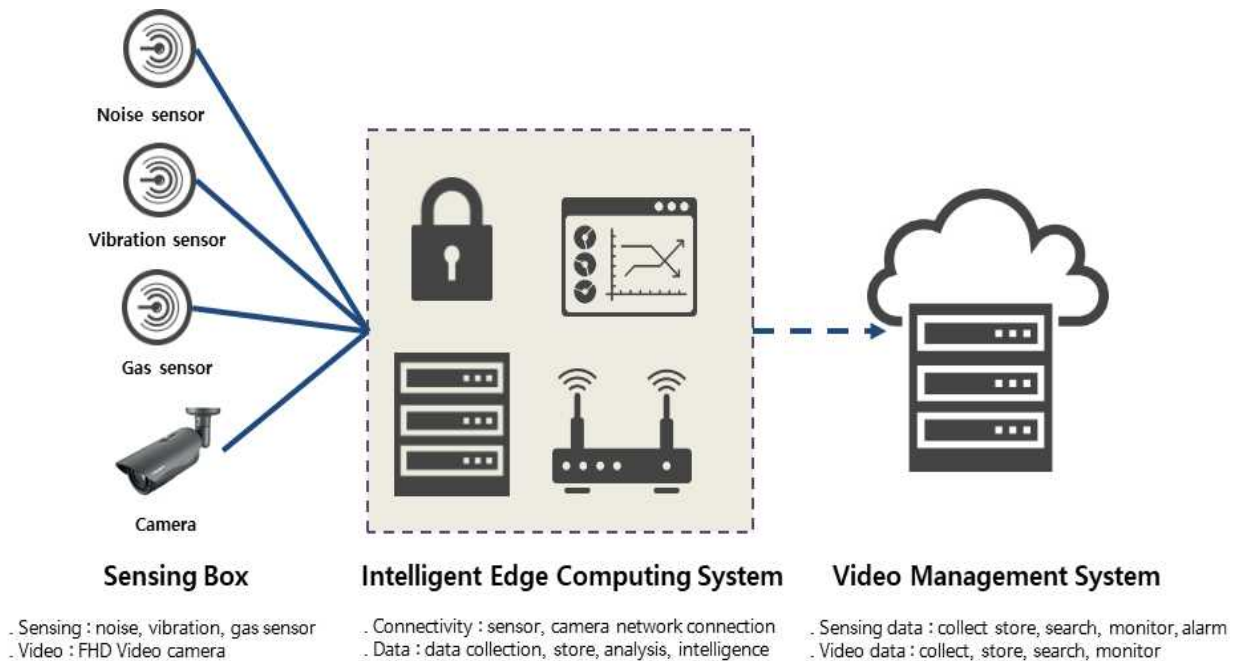


그림 1. 에지 컴퓨팅 기반 지능형 컨스트럭션 영상 관제 시스템 모델 개념도

Fig. 1. System concept of intelligent construction video management system based on edge computing

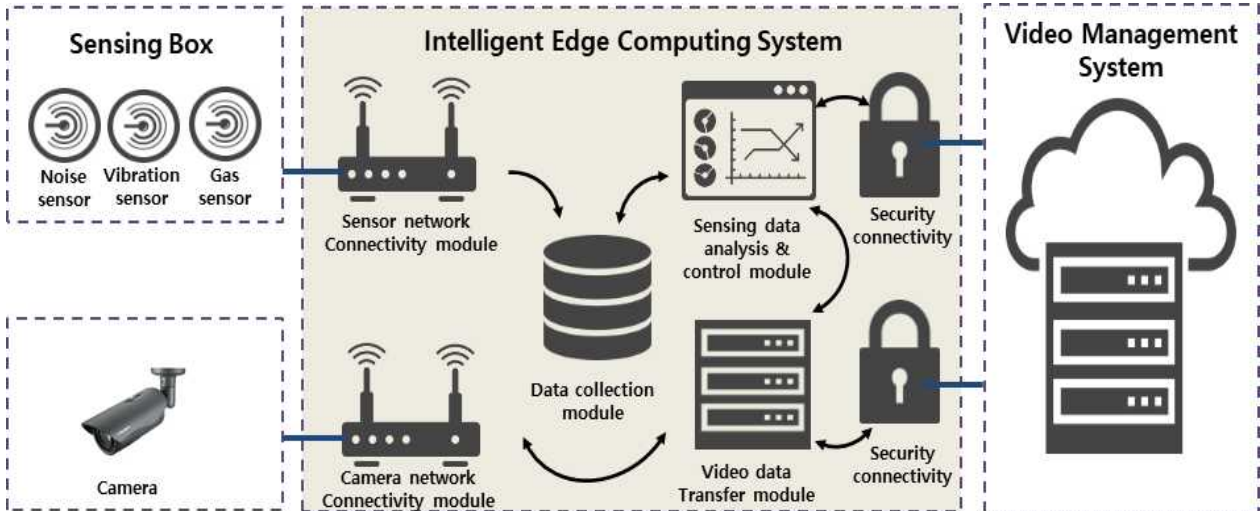


그림 2. 에지 컴퓨팅 기반 지능형 컨스트럭션 영상 관제 시스템 구성도
 Fig. 2. System configuration of intelligent construction video management system based on edge computing

그림 2는 본 논문에서 제안하는 지능형 IoT 에지 컴퓨팅 기술의 시스템 구성도를 나타내며, 큰 틀에서는 센싱 박스, 카메라, 에지 컴퓨팅, 클라우드 서버로 구성된다. 센싱 박스는 여러 개의 센서들의 집합으로서, 소음, 진동, 가스 등 다양한 센서들의 정보를 에지 컴퓨팅에 제공해 준다. 카메라에서는 완전 고해상도(Full High Density, FHD)급으로 공사현장의 영상을 실시간으로 촬영하여 에지 컴퓨팅 장비에 전달해 준다. 에지 컴퓨팅 장비는 IoT 정보 처리를 제공하는 기능 뿐만 아니라, 사물 네트워크(Things network)로부터 데이터를 제공하기 위한 연결성 제공, 각 프레임워크의 구성 노드 및 컴포넌트 사이의 네트워킹, 그리고 인터넷 상에 존재하는 클라우드(Cloud) 서버 등과의 네트워킹을 제공하는 네트워킹 플랫폼으로써 동작을 포함하고 있다. 에지 컴퓨팅의 구성요소는 크게 5가지로 구분 된다.

센서 네트워크 연결 모듈, 카메라 네트워크 연결 모듈, 데이터 수집 모듈(Sensing data collection), 센싱 데이터 분석 및 제어 모듈, 비디오 데이터 트랜스폼 모듈로 구성된다. 클라우드 서버는 AWS IoT를 통해서 센서 정보를 받거나 RTMP를 통해서 비디오 정보를 받는다.

다양한 IoT 센서로부터 센서 정보를 수집하는 모듈은 와이파이, 블루투스, 지그비, BACnet, Modbus, REST 등 다양한 통신 프로토콜 지원하도록 설계하였다. 그리고 센서에 추가적으로 프로토콜 스택을

설치하지 않고도 동작하기 때문에, 분석 모듈은 수집된 센서 정보로부터 현장의 상황을 분석하고, 기존 센서 활용 가능 여부를 판단한다. 이 때, 통계분석 방식과 기계학습을 통한 예측 방식 지원하도록 한다. 네트워크 카메라(CCTV)로부터 비디오 스트림 수신하는 모듈에서는 RTSP, RTMP, HTTP 등 다양한 스트리밍 프로토콜을 지원하며, 기존의 네트워크 카메라 장비를 활용하게 된다. 송출 화질을 제어하는 센서의 정보 분석 결과를 바탕으로 비디오 화질을 제어하는 모듈에서는 실시간 트랜스코딩 모드와 네트워크 카메라의 송출 화질 변경 모드 지원을 지원하도록 한다. 그리고 외부로 센서 정보 및 비디오 스트림을 전송하는 모듈에서는 Cloud, 서버, 사용자 어플리케이션 등 다양한 외부 기기 및 서비스와의 안정적인 연결을 지원하도록 한다.

III. 제안하는 소음 센싱 예측 알고리즘 및 비디오 전송률 결정 알고리즘

3.1 전체 흐름도

본 논문에서 제안하는 지능형 IoT 에지 컴퓨팅 장치는 센서로부터 발생하는 원시데이터(Raw data 또는 single unit data)를 처리한다. 즉, 센서를 통해 들어온 데이터는 센싱 데이터 수집 모듈을 거쳐 데이터베이스에 저장된 후에, 통계학적/기계학습

(Machine learning) 기반의 예측 모듈로 전송된다. 통계학적/기계학습 기반의 예측 모듈은 수집된 데이터를 기반으로 다음 주기의 데이터를 예측한다. 예측된 데이터는 결정 모듈에 전달된다. 결정 모듈은 그림 3의 알고리즘에 따라 비디오 데이터를 고화질로 보낼지, 저화질로 보낼지를 판단한다. 판단한 결과는 비디오 품질 적응 모듈로 전송된다. 비디오 품질 적응 모듈은 결정 모듈의 결과에 따라서 비디오 데이터를 클라우드 서버로 송출한다.

3.2 소음 센싱 예측 알고리즘

비디오 전송률 결정을 위한 소음 센싱 예측(NSP) 알고리즘은 통계학 기반의 알고리즘과 머신러닝/딥러닝 기반의 알고리즘을 사용하며, 각각에 대한 내용은 다음과 같다.

- 통계학 기반 알고리즘
 - LV 방식: 이전 값(Last value)을 예측 값으로 사용한다.
 - MA 방식: 최근 평균(Moving average)을 예측 값으로 사용한다. 예를 들어, MA-30 이면 최근 30 개 구간의 평균을 예측으로 사용한다.
- 머신러닝/딥러닝 기반 알고리즘
 - MVRP 방식: 머신러닝 기법 중의 하나로서, 다중 변수의 선형 예측 기술(Multi-variable

regression prediction)을 이용하여 다음 값을 예측한다,

- LSTM 방식 : 딥러닝 기법 중의 하나로써 시계열 데이터 예측기술(Long short-term memory)을 이용하여 다음 값을 예측 한다.

3.3 비디오 전송률 결정 알고리즘

소음 센싱 예측 기반의 비디오 전송률 결정(VRD) 알고리즘은 정적 알람 및 동적 알람을 기반으로 결정하는 방법이 있으며, 각각에 대한 설명은 다음과 같다.

- 정적 알람 기반 비디오 전송률 결정(Static Alarm based Video Rate Decision, SA-VRD) 알고리즘 : 최대 소음 허용치(Nth)을 고정 기준 값으로 두고, 최대 소음 허용치 이상이면 고화질로 전송하고, 최대 소음 허용치 이하이면 저화질로 전송하는 알고리즘
- 동적 알람 기반 비디오 전송률 결정(Dynamic Alarm based Video Rate Decision, DA-VRD) 알고리즘 : 그림 3처럼 최대 소음 허용치(Nth)과 민감도(α)의 곱을 기준 값으로 둔다. 최대 소음 허용치와 민감도의 곱 이상이면 고화질로 전송하고, 한계 소음과 민감도의 곱 이하이면 저화질로 전송하는 알고리즘

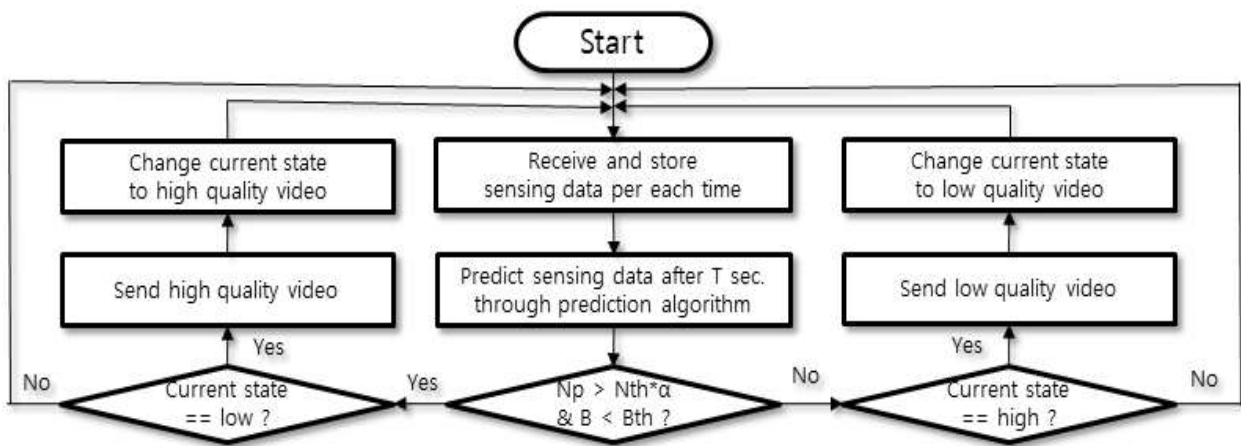


그림 3. 제안된 소음 센싱 예측 및 비디오 전송률 결정 알고리즘 기법
 Fig. 3. Proposed noise sensing prediction and video rate decision algorithm method

비디오 전송률 결정 알고리즘에 대한 파라미터는 다음과 같다. Nth는 최대 소음 허용치(dB) 이고, α 는 화질 변경에 대한 민감도이며 0에서 1까지 값을 허용한다. Np는 다음 예측 시간의 소음 예측값(dB)이다. Bth는 네트워크 트래픽 사용에 대한 최대 허용치(Kbps) 이고, B는 현재까지 네트워크 사용률이 다. T는 향후 희망하는 예측 시간 간격이다.

비디오 전송률 결정 알고리즘의 작동방법은 다음과 같다. 그림 3에서 보여진 것처럼, 향후 T 초 동안의 소음 레벨을 예측한다. 만약에, $N_p > N_{th} \times \alpha$ 이고, $B < B_{th}$ 인 경우에, 현재의 화질이 저화질이면 고화질로 화질을 변화시킨다. 그렇지 않은 경우에, 현재의 화질이 고화질이면 화질을 저화질로 변화시킨다. 반드시 현재의 상태를 관리해야 한다. 만약, 현재 상태가 고화질이면 고화질 변경 조건이어도 화질변환 요청을 하지 않도록 한다. 반대 상황도 마찬가지로, 현재 상태가 저화질이면 저화질 변경 조건이어도 저화질로 변경하지 않는다.

IV. 실험 결과

4.1 성능 지표

제안된 시스템의 성능에 대한 결과를 시뮬레이션 하기 위해서, 다음과 같은 성능 지표를 사용한다.

- 샘플 예측 오차 : RMSE(Root Mean Squared Error), MAPE(Mean Absolute Percentage Error)

- 예측 실패 횟수 : False negative(저화질 구간에서 S를 초과하는 샘플의 개수 (or 비율)), False positive(고화질 구간에서 S를 초과하지 않는 샘플의 개수 (or 비율))
- 고화질 전송 시간 비율 : 전체 시간 대비 고화질로 전송되는 시간의 비율
- 네트워크 사용량 : 에지 노드의 상향링크 인터페이스에서 측정
- LTE 비용 감소 : LTE 비용 감소액 측정

4.2 실험 환경 및 결과

본 절에서는 실제 구현 및 시뮬레이션 결과에 대해서 설명한다. 제안된 시스템에 대한 중요한 소프트웨어 요구사항은 다음과 같다. OS는 Ubuntu 16.04를 사용했고, 개발 언어는 Python 3.6을 이용하였다. 머신러닝과 딥러닝을 개발하기 위한 개발툴로써 Tensorflow 1.12를 사용하였다.

본 논문에서는 유튜브 전송률을 기본으로 비디오 대역폭을 계산한다. 저화질(Low)은 500Kbps 이고, 고화질(High)은 3,000Kbps 로 가정한다. 4가지 알고리즘에 대한 MAPE 결과는 표 1과 같다. 시뮬레이션 결과로부터, LSTM > LV > MA > MV_RP 순으로 예측 알고리즘 성능이 좋다는 것을 알 수 있다. 예측 성능은 미래의 예측 결과 정확도를 나타내기 때문에, 본 데이터 환경에서는 가능하면 정확도가 높을수록 좋은 성능을 갖는 알고리즘이다.

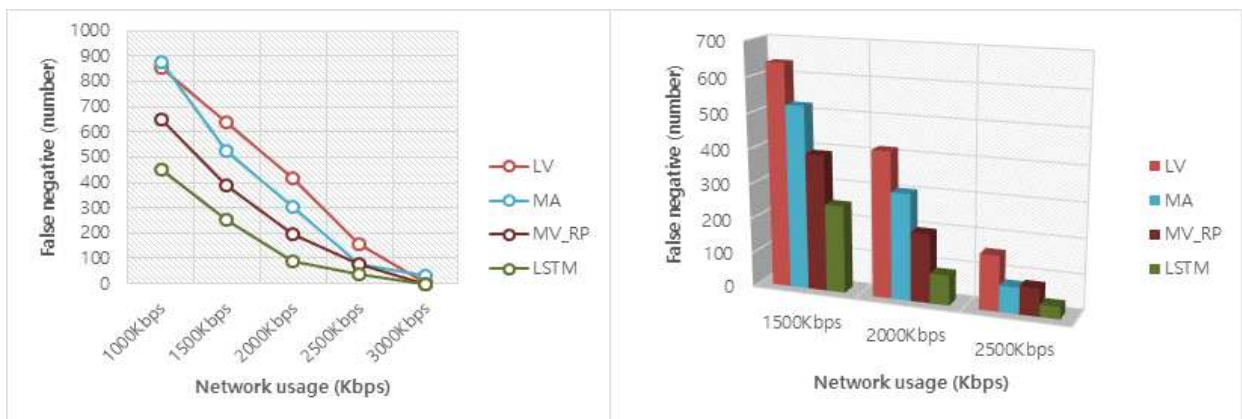


그림 4. 성능 평가 : 제안된 영상 관제 시스템을 위한 폴스 네거티브 수
 Fig. 4. Performance evaluation : false negative number for proposed video management system

표 1. 평균 퍼센티지 에러

Table 1. Average percentage error

Last value	Moving average (30)	MV_RP	LSTM
1.572378	1.783128	2.741338	1.206706

그림 4는 Nth=69dB, T=10초, 그리고 T=10초 인 경우, 폴스 네거티브(False negative) 수를 비교한다. 이 결과로부터, 폴스 네거티브 수는 동일 네트워크 사용량 경우에, LSTM > MV_RP > MA > LV 순으로 성능이 좋다는 것을 알 수 있다.

폴스 네거티브 수는 서비스 품질에 관계가 있다. 폴스 네거티브 수가 크다는 것은 잘못 예측한 확률이 높다는 것이다. 본 영상 관제 서비스의 경우는 비정상 구간에서 반드시 고화질 영상이 있어야 한다. 그런데, 폴스 네거티브가 있으면 비정상 구간에서 저화질 영상으로 전송이 된 경우이다. 비디오 전송률을 낮추면서 폴스 네거티브가 작거나 거의 없게 만드는 것이 본 시스템의 핵심 아이디어 이다.

그림 5는 Nth=69dB, T=10초, 그리고 T=10초인 경우에 네트워크 트래픽 사용을 비교한다. 네트워크 트래픽 사용량 성능은 같은 폴스 네거티브 수 일 때, LSTM > MV_RP > MA > LV 순으로 성능이 좋다는 것을 알 수 있다. 네트워크 트래픽 사용은 서비스 비용에 관계가 있다. 네트워크 트래픽 사용이 높으면 무선 구간에 전송한 데이터가 많기 때문에 서비스 비용이 높아진다. 본 논문은 가능하면 동

일 서비스 품질에서 네트워크 트래픽 양을 줄일 수 있는 알고리즘을 제안하였다.

V. 결론 및 향후 과제

본 논문에서 제안한 영상 관제 시스템을 사용하면, 지능형 컨스트럭션을 위한 실시간 미디어 및 데이터 협업 서비스를 이용한 모니터링 서비스를 제공할 수 있다. 현재 사물인터넷을 이용한 서비스는 여러 기업에서 경쟁적으로 선보이고 있지만, 공공서비스로는 아직 개발해야 될 많은 부분이 존재한다. 본 기술은 과거의 수동적인 모니터링 방안을 능동적 또는 즉각적 협업 서비스로 전환시키는 계기를 마련하게 될 것이다. 또한, 수집된 데이터는 머신러닝 등의 기초 데이터로 활용할 수 있다.

본 논문은 비용 감소를 위한 비디오 트래픽 제어 정책, 고신뢰를 위한 트래픽 셰이핑(Shaping) 제어 기술을 포함한다.

기존 영상 관제 기술은 상시로 민원인, 감독관, 관리자에게 실시간 현장 영상으로 FHD 영상 및 360 영상 데이터를 제공하고, VOD로 FHD 영상, 360 영상, 공중 영상, 열 영상을 제공하기 때문에, 서버로 데이터를 전송할 때 인터넷 데이터 사용량이 크게 증가할 수 있다. 공사장의 경우는 유선 인터넷 설치가 제도적으로 어려워서 무선 LTE를 사용하는 경향이 있으며, 결국 LTE 통신비용이 많이 소요될 수 있다.

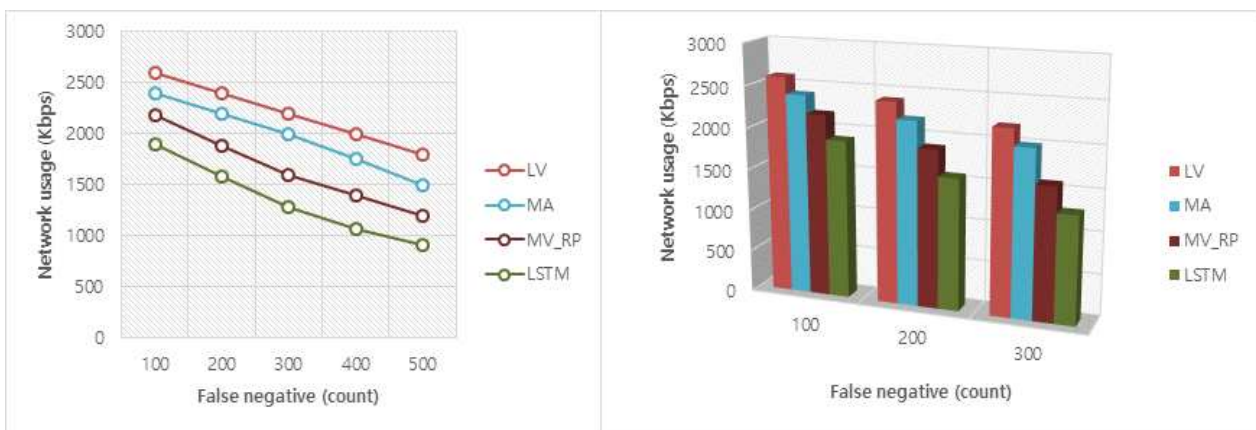


그림 5. 성능 평가 : 제안된 영상 관제 시스템을 위한 네트워크 트래픽 사용량

Fig. 5. Performance evaluation : network traffic usage for proposed video management system

본 논문에서 제안하는 시스템은 소음 정보, 가스 누출 정보, 진동 정보가 해당 건설현장에서 법적 기준치를 초과할 경우에만 고용량 영상을 전송하기 때문에, 사용자가 동일한 서비스를 받으면서 최소의 통신비용이 발생하는 효과가 있다.

향후 연구 주제로는, 에지 컴퓨팅 계산량을 분석해서 에지 컴퓨팅을 사용하지 않을 경우와 사용할 경우를 비교할 예정이다. 현재는 가장 민감한 부분인 소음 예측 기반으로 트래픽을 제어했는데, 향후 진동, 가스 센서 등도 함께 예측하여 트래픽을 효율적으로 제어하는 방안도 연구할 예정이다.

References

[1] M. Alsheikh, S. Lin, D. Niyato and H. Tan, "Machine learning in wireless sensor networks: Algorithms, strategies, and applications", IEEE Commun. Sur. & Tut., Vol. 16, No. 4, pp. 1996-2018, Apr. 2014.

[2] M. A. Wijaya, K. Fukawa and H. Suzuki, "Intercell-interference cancellation and neural network transmit power optimization for MIMO channels", IEEE Vehicular Technology Conference Fall, Sep. 2015.

[3] A. Mestres, etc, "Knowledge-defined networking", ACM SIGCOMM Computer Communication Review., 2016.

[4] G. Stampa, etc, "A deep-reinforcement learning approach for software-defined networking routing optimization", Arxiv., 2017.

[5] N. Kato, etc, "The deep learning vision for heterogeneous network traffic control: Proposal, challenges, and future perspective", IEEE Wireless Communication, 2017.

[6] L. Liu, etc, "Deep learning based optimization in wireless network", IEEE ICC 2017, 2017.

[7] L. Mekinda and L. Muscariello, "Supervised machine learning-based routing for named data networking", 2016 IEEE GLOBELOM, Vol. 20, pp. 1-6, Dec. 2016.

[8] J. Joung, "Machine learning-based antenna selection in wireless communications", IEEE Commun. Letters, Vol. 20, No. 11, pp. 2241-2244, Nov. 2016.

[9] J. Deng, W. Dong, R. Socher, L. Li, K. Li and L. Fei-Fei, "ImageNet: A large-scale hierarchical image database", The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Miami, FL, USA, pp. 248-255, Jun. 2009.

[10] E. Park, W. Liu, O. Russakovsky, J. Deng, L. Fei-Fei, and A. Berg, "ILSVRC-2017", URL <http://www.image-net.org/challenges/LSVRC/2017/>, 2017. [accessed: Jul. 17, 2019]

[11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition", The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, pp. 770-778, Jun. 2016.

[12] S.-H. Yang, S.-J. Kim, and H. Ok, "Design of user friendly prototype UI of construction work accident information for big data contents service", Journal of Korean Institute of Information Technology, Vol. 13, No. 12, pp. 99-107, Dec. 2015.

저자소개

김 귀 훈 (Kwihoon Kim)



1998년 2월 : KAIST
전기 및 전자공학과 (공학사)
2000년 2월 : KAIST
전기 및 전자공학과 (공학석사)
2019년 2월 : KAIST
전기 및 전자공학부 (공학박사)
2000년 2월 ~ 2005년 6월 :

LG데이콤 주임연구원

2005년 7월 ~ 현재 : 한국전자통신연구원 책임연구원
관심분야 : 에지컴퓨팅, 인공지능, 딥러닝, 강화학습

서 방 원 (Bangwon Seo)



1997년 2월 : KAIST

전기 및 전자공학과 (공학사)

1999년 2월 : KAIST

전기 및 전자공학과 (공학석사)

2010년 2월 : KAIST

전기 및 전자공학과 (공학박사)

2004년 11월 ~ 2013년 2월 :

한국전자통신연구원 선임연구원

2013년 3월 ~ 현재 : 공주대학교 부교수

관심분야 : 이동통신, 단말간 직접통신 (D2D), 다중
안테나 기술 (MIMO), 프리코더 설계, 인공지능