

딥러닝을 활용한 엣지 컴퓨팅 기반 산업현장 작업자 행동 분석 시스템

이세훈*, 박정준^o, 이태형*

^o인하공업전문대학 컴퓨터시스템과,

*인하공업전문대학 컴퓨터시스템과

e-mail : seihoon@inhac.ac.kr*, dev_bjun@meshyam.io^o, thlee0700@gmail.com*

Edge Computing based Industrial Field Worker's Behavior Analysis System using Deep Learning

Se-Hoon Lee*, Jeong-Jun Bak^o, Tae-Hyeong Lee*

^oDept. of Computer Systems & Engineering, INHA Technical College,

*Dept. of Computer Systems & Engineering, INHA Technical College

● 요약 ●

본 논문에서는 딥러닝을 이용한 작업자 위험 행동 모니터링 선행 연구에 기반해, 엣지 컴퓨팅 기반 딥러닝을 사용하여 클라우드에 대한 의존성 문제를 해결하였다. 작업자는 IoT 안전벨트와 영상 전송 안전모를 통해 정보를 수집, 처리한다. 또한 LSTM 방식에서 개량된 필터를 통한 FFNN 딥러닝 방법을 사용하여 작업자 위험 행동 패턴 분석을 하며 선행 연구의 작업자 행동 모니터링 시스템을 엣지 컴퓨팅 기반 위에서 구현하였다.

키워드: 작업자 위험 행동(Worker's Risk Behavior), 엣지 컴퓨팅(Edge Computing), 딥러닝(Deep Learning)

I. Introduction

작업자 위험 행동 분석 시스템은 산업현장 행동강령에도 불구하고 작업자 위험 감지 능력 저하로 인해 발생할 수 있는 부주의 행동에 의한 산재 예방 및 감소를 목표로 하며 클라우드 의존성을 문제를 해결한다.[1][2]

본 논문에서는 이러한 의존성 문제를 작업자의 IoT 안전벨트와 영상 전송이 가능한 안전모를 통해서 엣지 컴퓨팅을 구현해 해결하며, 딥러닝 작업을 위해 LSTM 방식에서 개량된 필터를 통한 FFNN(Feed-Forward Neural Network)을 사용한다.

작업자 행동 모니터링 엣지 시스템은 그림 1과 같이 3가지 즉, 센싱 디바이스, 프로세싱 디바이스, 모니터링 서버 부분으로 구성된다. 센싱 디바이스에서는 자이로 센서를 사용하여 작업자의 행동 정보를 수집하고, 프로세싱 디바이스로부터 전달받은 결과를 작업자에게 피드백하는 역할을 담당한다. 프로세싱 디바이스는 센싱 단말로부터 전달받은 작업자의 행동 정보를 기반으로 위험 행동 판단 여부를 작업자에게 피드백하고 해당 피드백 정보와 함께 카메라 모듈을 사용하여 작업자의 주변 환경 정보를 모니터링 서버로 전달한다. 모니터링 서버는 프로세싱 디바이스로부터 전달받은 작업자 위험 행동 판단 정보와 주변 환경 정보를 토대로 관리자가 다양한 작업자들에게 대한 실시간 모니터링을 가능하게끔 서비스를 제공한다.

II. Design of the System

1. Worker's Behavior Monitoring System




Fig. 1. Edge System Architecture

2. Filtering for Deep Learning

선행 연구[2][3]에서의 RNN 및 LSTM은 엣지 컴퓨팅에 적합하지 않으므로 본 논문에서는 FFNN 네트워크를 사용한다. 하지만, 작업자 행동과 같은 시계열 학습에 적합하지 않다는 문제가 존재한다.

$$\sqrt{Ac_x^2 + Ac_y^2 + Ac_z^2} + \sqrt{Gy_x^2 + Gy_y^2 + Gy_z^2} \dots (1)$$

따라서 본 논문에서는 이 문제를 해결하기 위해 작업자로부터 얻어온 6축 자이로센서 raw data를 (1)과 같이 각 축의 제곱 값의 합에 루트를 씌워 방향성과 노이즈를 제거해 가속도의 크기와 기울기의 크기만을 가지고 작업자의 행동을 구분할 수 있도록 하며 해당 값을 FFNN의 $X_1, X_2, X_3 \dots X_{n-1}, X_n$ 에 시계열 형태가 되도록 입력하여 시간 축 손실에 의한 데이터 오류를 최소화 한다. [4][5]

본 논문은 IoT 안전벨트와 안전모를 활용하여 엡지 컴퓨팅 기반의 작업자 위험 행동 판단 시스템 및 작업자 모니터링 서비스를 구현하였으며, 이를 통해 클라우드 의존성을 제거함과 동시에 최소한의 컴퓨터 자원을 사용한 작업자 위험 행동 판단 FFNN 학습 방법이 유효함을 입증하였다.

2. Model of Deep Learning

프로세싱 대바이스에서 작업자의 위험 행동 판단 분류는 Dataset으로 두 명의 실험자가 4가지 행동(standing, walking, running, jump)에 대해 0.8초당 8개의 데이터를 한 묶음으로 총 1천개를 수집했으며 학습 결과로 그림 2와 같이 79.05%의 정확도가 나왔다.




Fig. 2. Preprocessed Data for Deep Learning

모니터링 서버는 그림 3처럼 프로세싱 임베디드 기기로부터 전달받은 영상 정보를 Yolo 프레임워크의 실시간 객체 탐지 기능을 사용하여 관리자에게 영상 정보를 제공하며, 객체 탐지에 문제가 없음을 확인하였다. 그림 4와 같이 IoT 단말을 활용하여 엡지 컴퓨팅 기반의 작업자 위험 행동 판단 시스템 및 작업자 모니터링 서비스를 구현하였다.

III. Conclusions




Fig. 3. Object recognition with YOLO



Fig. 4. IoT Device Prototype

REFERENCES

- [1] Jeong, Inseok et al, "Analysis of Structural Relation between the Shipyard Workers' Ego-state, Safe and Unsafe Behaviors, and Industrial Accidents", Journal of the Korean Society of Safety, v.33 no.5, pp.101-108, 2018
- [2] Se-hoon Lee et al, "Deep Learning based Behavior Analysis System for High Rise Worker at Industrial Field.", Proceedings of the Korean Society of Computer Information Conference, pp. 51-52, 2018.
- [3] Se-hoon Lee et al, "Deep Learning and IoT Standards based High Rise Fieldworker's Behavior Analysis System", Proceedings of the Korean Society of Computer Information Conference, pp. 247-248, 2019
- [4] Jeon Myung Hoong et al, "Robust User Activity Recognition using Smartphone Accelerometer Sensors", KIPS Transactions on Software and Data Engineering, Vol. 2, No. 9, pp. 629-642, 2013
- [5] H.K Yang et al, "Real-Time Physical Activity Recognition Using Tri-axis Accelerometer of Smart Phone", Journal of Korea Multimedia Society Vol. 17, No. 4, pp. 506-513, April 2014.