

Smart Safety Belt for High Rise Worker at Industrial Field

Se-Hoon Lee*, Hyo-Jae Moon**, Jin-Hyun Tak***

Abstract

Safety management agent manages the risk behavior of the worker with the naked eye, but there is a real difficulty for one the agent to manage all the workers. In this paper, IoT device is attached to a harness safety belt that a worker wears to solve this problem, and behavior data is upload to the cloud in real time. We analyze the upload data through the deep learning and analyze the risk behavior of the worker. When the analysis result is judged to be dangerous behavior, we designed and implemented a system that informs the manager through monitoring application. In order to confirm that the risk behavior analysis through the deep learning is normally performed, the data values of 4 behaviors (walking, running, standing and sitting) were collected from IMU sensor for 60 minutes and learned through Tensorflow, Inception model. In order to verify the accuracy of the proposed system, we conducted inference experiments five times for each of the four behaviors, and confirmed the accuracy of the inference result to be 96.0%.

▶ Keyword: Worker's Safety Management, Real-time Monitoring, Deep-Learning, Data collection

I. Introduction

오늘날에도 산업현장에서 많은 안전사고가 발생한다. 2016년 안전보건공단¹의 산업재해 분석결과 2016년에 건설업 산업현장에서 총 608건의 산업재해가 발생하였다. 그 중 추락, 넘어짐으로 인한 안전사고 발생건수가 434건으로 전체 산업재해의 71%로 가장 많은 비율을 차지하였다[1].

하인리히의 도미노 이론에 따라 추락, 넘어짐으로 인한 사고의 88%가 작업자의 위험행동으로 인해 발생한다[2]. 실제로 작업자들이 빠른 작업을 위해 안전 고리를 체결하지 않고 작업을 하거나, 작업장에서 뛰는 등의 위험행동을 하고 있다. 이런 사고를 방지하기 위해서 산업안전보건법은 작업장에 관리자를 두어 관리자가 육안으로 관리, 감독하도록 명시하였다. 하지만, 관리자가 다수의 작업자의 안전장비를 착용여부와 위험행동을 실시간으로 관리 감독하는 것은 현실적으로 불가능하다. 작업자가 사용하는 안전벨트에 사물인터넷(IoT) 기술을 적용하여 안전사고를 예방하기 위한 연구들은 계속 되어왔지만 규칙기반

의 알고리즘을 사용하여 위험행동 분석 정확도가 낮다[3].

본 논문에서는 실시간으로 작업자의 안전장비 착용여부와 위험행동을 딥러닝 기술을 이용하여 행동을 분석하여 작업자가 위험행동을 할 경우 관리자에게 알림을 주는 시스템을 설계한다. 본 논문의 구성은 2장에서 산업현장에서의 작업자의 위험행동에 대해 정의하고 분류하였으며 3장에서는 결정트리, Conv-Net, LSTM+RNN 세 가지 행동분석 알고리즘에 대해 설명하고 4장에서 알고리즘에 따른 고리체결 분석 정확도 실험결과와 행동분석 알고리즘에 따른 정확도 실험결과를 기술하였으며, 마지막 5장에서 결론으로 마무리한다.

• First Author: Se-Hoon Lee, Corresponding Author: Se-Hoon Lee

* Se-Hoon Lee (seihoon@inhac.ac.kr), Dept. of Computer Systems & Engineering, Inha Technical College

** Hyo-Jae Moon (hydrozenium@gmail.com), Dept. of Computer Systems & Engineering, Inha Technical College

*** Jin-Hyun Tak (takkor@naver.com), R&D Center, DucSan Information Telecom Co., Ltd.

• Received: 2018. 01. 29, Revised: 2018. 02. 04, Accepted: 2018. 02. 27.

• This work was supported by INHA TECHNICAL COLLEGE Research Grant and Purchase Condition New Product Development Project Grant of Ministry of SMEs and Startups.

II. Preliminaries

1. Definition of risk behaviors and conditions

안전보건공단이 정의하는 산업현장에서의 작업자의 위험행동은 크게 안전고리를 체결하지 않고 작업하는 행위, 작업장을 빠른 속도로 이동하는 행위, 무거운 것을 들 때 무릎을 굽히지 않고 드는 행위, 기울어진 발판에서 이동 또는 작업행위가 있으며 작업시 위험한 상태로는 추락사고가 발생하여 안전벨트에 의지해 매달려 있거나 바닥으로 떨어진 경우, 넘어지거나 엎어진 상태, 일정시간 움직임이 없는 상태 등이 있다.

2. Research on Risk Behavior and Status Analysis

기준에도 산업현장 위험행동과 상태를 분석하기 위한 연구들이 있었고, 각 행동과 상태에 따른 관련 연구에서 위험행동을 감지할 센서를 정리하면, 표 1과 같다[4,5].

Table 1. Research on Risk Behavior and Status

Risk behavior and risk status	related research	desing
No safety ring	[10]	Safety ring pressure sensing using FSR (Force Sensitive Resistor) sensor
If a crash occurs and hangs on the seatbelt or falls off the floor		
Move at a fast pace	[7, 8, 9, 11]	Using IMU sensor, operator's motion tracking
Moving and working on a slanted footrest		
Do not bend your knees when lifting heavy things		
No motion for a period of time		
Falling or lying down	[15]	

III. Behavior Analysis

1. Rule-based stride estimation




Fig. 1. position of IMU sensor

작업자의 위험행동들 중에서 현장에서 작업자가 뛰면서 작업하는 행동을 감지하기 위해서 작업자가 현장에서 서 있는지 뛰는지 아니면 정지 상태 인지를 추정하고 위험상황을 빠르게 인지할 수 있도록 규칙 기반의 알고리즘을 구현한다. 작업자의 보폭을 추정하기 위해서 IMU(inertial measurement unit)를 그림 1 와 같이

부착하여 가속도와 자세계(attitude) 값을 센싱한다.

발의 가속도(Af)를 적분하여 작업자의 움직임을 판단한다. 하지만 보행하지 않을 때에도 여러 움직임과 변수에 의해 Af의 가속도 변화가 일어나며 적분만으로 속도를 구할 경우에는 오차가 발생한다. 이런 오차를 줄이기 위해 사람의 보행추정에서 ZUPT(Zero Velocity Update) 알고리즘이 많이 사용된다. 알고리즘은 보행 중 발이 신체를 지지하는 동안 속도가 0이 되는 보행의 특성을 이용한 알고리즘이다. 사람의 보행은 그림 2와 같이 순차적으로 두 발이 번갈아 가며 연속적으로 반복 수행함으로써 움직이는 과정이며, 입각기(Stance Phase)와 유각기(Swing Phase)로 구분된다.




Fig. 2. gait phase

유각기는 TO(Toe Off)에서 HS(Heel Strike)까지의 구간, 발이 지면을 떠나 움직이는 단계이며 HS에서 TO가 일어나기 전까지 단계인 입각기 단계로 반대쪽 발의 유각기가 진행되며, 몸을 지지하는 축으로서 지면에 고정된다. 입각기 단계에서 발은 지면에 고정되기 때문에 Af는 중력가속도(g) 만을 가지게 되고, 중력가속도가 1g인 환경에서 Af = 1g 인 경우에 입각기 단계라고 판단할 수 있다. Af는 식 (1)과 같이 낼 수 있다.

$$A_f = \sqrt{A_{fx}^2 + A_{fy}^2} - A_{fz} \tag{1}$$

실제 실험 결과 입각기 단계에서도 여러 환경요인에 따라 Af 값이 1g에 머물지 않는다. 입각기에서 가속도 출력이 중력가속도를 중심으로 평균 0.1m/s2의 떨림이 나타는 것을 확인할 수 있다. 오차의 최대 중력가속도의 두배(10.5m/s2)를 입각기 판별기준(Thp)로 하였고 보폭을 추정하였다. 오차를 보정하여 입각기와 유각기를 구분하는 알고리즘은 식 (2)와 같다.

$$Ph_p = \begin{cases} stance, & \text{if } (A_f \leq Th_p) \\ swing, & \text{else} \end{cases} \tag{2}$$

이 알고리즘을 통해서 입각기와 유각기 검출을 통하여 보폭을 추정할 수 있으며, 추정된 결과를 토대로 정리, 걷기, 달리기 판별이 가능함을 확인할 수 있다[11].

2. Behavior analysis using ConvNet model

IMU에서 측정된 가속도를 적분하는 방식으로는 작업자의 이동여부, 이동속도를 분석할 수 있다. 하지만, 무릎을 굽히지 않고 무거운 것을 들거나 기울어진 발판에서 작업하는 행동에 대해서는 분석할 수 없다. 규칙기반 알고리즘으로 위험행동인

지 분석할 수 없지만, 사람은 눈으로 그래프를 보고 작업자가 위험행동을 하는지 구분할 수 있다. 머신러닝 기법 중 신경망 회로를 적용하여 작업자의 행동을 분석하는 방법이 있다. 신경망 회로 중에서 실험에 적용하기 위해 인간의 시각세포를 모사한 ConvNet 모델을 이용하여 IMU 데이터를 그래프화하여 학습하도록 하였다[11].

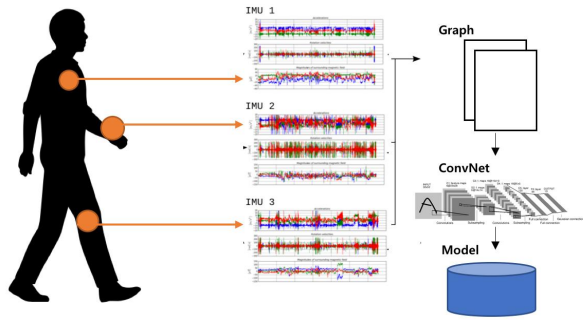


Fig. 3. Overview of the proposed approach

이 모델을 적용하면 IMU 데이터를 별도의 사전 필터링 과정 필요없이 많은 데이터를 축적하면 높은 정확도를 낼 수 있다. IMU에서 측정된 각 3축 가속도와 자세계를 그래프화하여 ConvNet 모델을 적용하여 행동을 분석하는 구조는 그림 4과 같다.

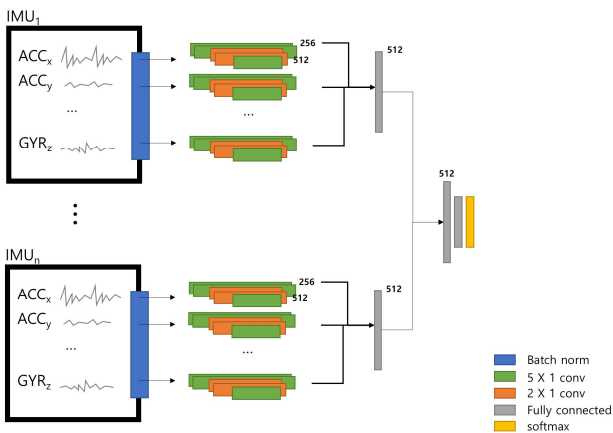


Fig. 4. Overview of the IMU-CNN architecture

ConvNet 모델을 적용하여 10가지 행동에 대해 분류한 연구의 행동 분석 정확도는 93.15(±6.84)의 결과를 나타내었다[12].

3. Behavior analysis using RNN(LSTM) model

ConvNet에서는 일정시간으로 작업자의 3축 가속도와 자세계 값을 쪼개서 실시간으로 처리하는 과정에서 이전의 데이터와 관계 없이 독립적인 사건으로 판단하여 행동을 분석한다.

하지만 사람의 행동은 연속적이고 앞서 했던 행동과 깊은 연관이 있다. 그러므로 지금 들어온 입력 데이터의 분석결과는 과거에 입력 받았던 데이터와 연관되도록 모델을 세워야한다. 신경망 회로 중에서 히든 노드가 방향을 가진 엣지로 연결돼 순환구조를 이루는 RNN(Recurrent Neural Network) 모델을 사용하여 해당 문제를

해결하였다. 그림 5은 RNN 모델에 대한 구조를 나타낸 것이다.




Fig. 5. Structure of RNN

RNN은 학습이 진행됨에 따라 기존에 대한 노드들의 변수를 고려하지 않는 장기 의존성 문제가 발생한다. 이 문제를 해결하기 위해 LSTM(Long Short Term Memory)구조를 적용하여 장기 의존성 문제를 해결하였다. 그림 6는 LSTM 구조를 나타낸 것이다[14].




Fig. 6. Structure of LSTM

그림 7은 행동분석을 위해 IMU에서 3축 가속도와 자세계값을 측정하여 LSTM 구조를 통해 행동 분석하는 방법에 대해 나타내었고, LSTM, DRNN 모델을 적용하여 10가지 행동에 대해 분류한 연구의 행동 분석 정확도는 96.5(±3.5)의 결과를 나타내었다[12, 13].

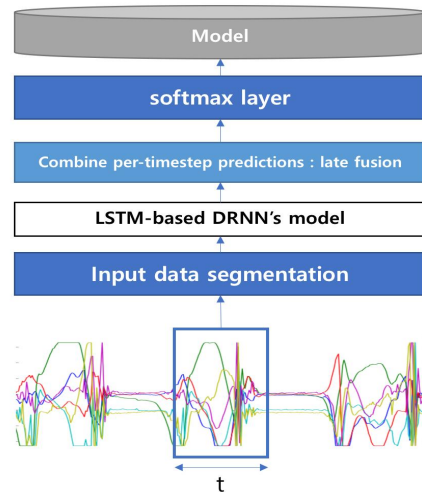


Fig. 7. Overview of the IMU-CNN architecture

IV. Design of Safety belt system

1. The system configuration

작업자 안전벨트 시스템은 그림 8과 같이 블랙박스, 클라우드, 스마트폰 세 부분으로 구성하였으며, 작업자의 행동을 정확하게 인지하고 작업자가 작업하는데 방해되지 않도록 설계하였다.

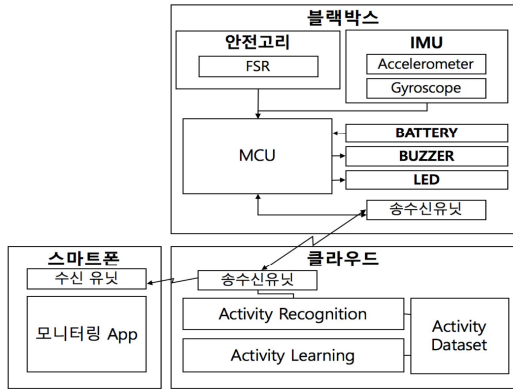


Fig. 8. System Architecture

블랙박스는 작업자의 하네스형 안전벨트에 장착되며 블랙박스 내부의 IMU로 가속도와 자세계 값을 수집하고, 안전고리 내부의 압력값을 수집한다. 클라우드부는 블랙박스로 부터 수신 받은 IMU, FSR 등 센서 데이터와 메타데이터를 전처리과정을 수행하고 기존에 학습한 데이터셋을 가지고 행동 인식 알고리즘을 통해 작업자의 위험행동 여부를 판단한다. 스마트폰은 관리자가 클라우드에서 판단한 작업자의 행동을 모니터링할 수 있으며 클라우드에서 행동분석 결과 작업자가 위험행동을 한다고 판단하면, 알림을 주도록 구성하였다[10].

2. Design of the Blackbox

2.1 Black box configuration

블랙박스는 행동 데이터를 수집하는 IMU, 송수신 모듈, LED와 부저, 배터리로 구성된다. 블랙박스에서 클라우드로의 데이터 전송은 무선망 LAN을 이용하여 송수신한다. 그리고 작업자의 행동 데이터 수집을 위한 IMU로는 MPU-6050을 사용하였다.

IMU센서는 그림 9와 같이 하네스형 안전벨트를 부착하여 고정하였다. 블랙박스의 위치는 작업자의 등 쪽에 요추 4-5번 사이에 오도록 설치하였다.




Fig. 9. Blackbox Attached Placement

IMU 센서를 등에 부착한 이유는 작업자의 작업에 방해되지 않으며, 등 부분이 다른 신체부위 보다 살이 얇고 작업자의 행동에 대한 정확한 데이터를 얻을 수 있는 장점이 있다. IMU센서에서 출력되는 값은 6개 이며, 그림 10과 같이 3축 가속도 (ACC_X, ACC_Y, ACC_Z) 3축 자이로(GYR_X, GYR_Y, GYR_Z)이다.




Fig. 10. Definition of Axis of IMU

IMU의 3축 가속도(ACC_X, ACC_Y, ACC_Z)로 작업자가 걷는지 뛰는지, 서있는지와 같은 작업자의 이동과 몸의 움직임과 관련된 데이터를 얻는다. 축 자세계로 얻어지는(GYR_X, GYR_Y, GYR_Z)로 작업자가 허리를 숙이거나, 기울어진 작업장에서 일하는지와 같은 작업자의 자세와 관련된 데이터를 얻는다[6,16,17]. 위험행동을 한 경우에 작업자에게도 알림을 주기 위해, 안전벨트에 LED스트립과 부저를 설치하였다. 배터리는 리튬 이온 배터리로 3.7V, 5,000mAh이다.

2.2 Carabiner configuration

안전고리는 작업 현장의 안전대에 체결되어 작업자의 추락을 방지하는 역할을 한다. 하지만, 작업자들이 빠른 작업과 불편함을 이유로 안전고리를 체결하지 않고 작업하다가 추락, 부상 또는 사망하는 경우가 발생하고 있다. 따라서, 안전벨트 시스템에 작업자가 안전고리를 체결했는지 여부도 확인할 수 있도록 하였다. 본 논문에서 제안하는 장치에서는 2개의 센서를 이용하여 안전고리의 체결여부를 확인한다. 안전고리의 단점여부를 전류의 흐름으로 감지하며, 압력센서를 이용하여 안전벨트가 안전대에 체결되었는지 확인하며, 그림11와 같이 안전고리 끝 결합부에 위치한 도체와의 접촉유무를 판단함으로써 고리가 제대로 닫혔는지 확인하도록 하였다.




Fig. 11. Switch of Carabiner

안전고리는 손으로 압력을 가해야 고리가 열리는 구조이지만, 안전벨트의 노후화나 안전대의 굵기등 여러가지 환경 변수로 인해 안전고리가 제대로 닫히지 않는 경우가 발생한다.

이런 경우 작업자는 안전고리가 안전대에 체결되었다고 판단하고 작업하다 고리가 열려 추락하는 경우가 발생할 수 있으므로 안전벨트의 끝이 스위치 역할을 하여 전류의 흐름으로 안전고리의 단합여부를 판단하도록 설계하였다. 안전고리 끝 부분의 전류의 흐름으로는 안전고리의 단합 여부는 판단할 수 있지만, 고리가 안전대에 체결되었는지 여부는 판단하기 어렵다. 이를 해결하기 위해 안전고리 안에 압력센서를 부착하여 안전대와와의 체결여부를 판단한다. 그림 12는 압력센서가 부착된 안전고리의 디자인이다.




Fig. 12. FSR Sensor of Carabiner

압력센서는 안전고리 윗 부분에 부착되어 안전대와 접촉하게 되면 중력으로 인한 압력을 감지하게 되고 시스템에서는 고리의 정상체결여부를 판단하게 된다. 안전고리에는 FSR-402가 사용되며 10~10,000g의 압력에 의해 저항값이 100~0.1kΩ사이로 변화하여, 블랙박스로 전달하도록 설계하였다. 그림 13은 본 논문에서 제안한 안전고리에서 인지하는 압력에 따른 저항 변화값을 그래프로 나타낸 것이다.




Fig. 13. Graph of the resistance value corresponding to the pressure

그림 14은 안전고리의 프로토타입이다. 안전고리는 작업자 안전벨트에 부착된 블랙박스와 연결되어 위험여부를 판단하고, 클라우드로 데이터 값을 전송된다 [10].



Fig. 14. Prototype of Carabiner

3. Design of the cloud

Table. 2는 행동 분석 실험에 사용할 클라우드 프로토타입 사양이다. 클라우드 플랫폼은 GCP(Google Cloud Platform)을 사용하여, 구글에서 제공하는 Tensorflow 머신러닝 라이브러리를 통해 작업자의 행동분석을 하였다.

Table 2. Cloud Prototype Specification

		GCP Setting Spec.
Machine Type		8 vCPUs.
Memory Section		8
Firewall Section		HTTP Traffic
Network Section	Interface	Default
IP Address		Static IP Address

V. Experiments

1. Algorithm Accuracy of Ring Clamp Analysis

고리 체결 여부를 분석하기 위해서 두 가지 알고리즘으로 정확도 실험을 하였다. 규칙기반 알고리즘과 ConvNet으로 실험하였다. 고리체결 안함, b. 고리 안 단합, c. 고리 정상 체결, d. 작업자 추락 4가지 스탠스로 구분하였다. 실험은 각 스탠스별로 10분 동안 200개의 데이터셋으로 실험하였다. 규칙기반은 고리 내부의 압력센서가 일정 경계값을 넘었을 때의 각각 스탠스를 미리 정의하였다. 고리 개폐여부를 전류의 흐름으로 감지하여 흐를 때는 단합 흐르지 않을 때는 열림으로 판단하였다. 4가지 스탠스를 각각 실시하고 실제 스탠스와 시스템에서 분류된 결과를 비교하기 위한 실험을 실시하였다. 실험결과를 표 3에 나타내었으며, 총 인식률은 평균 98.2% 였다.

Table 3. Rule-based Algorithm Analysis Accuracy

		Activity Classification				Recognition rate
		a	b	c	d	
L A B E L	a. don't tighten ring	199	1			.995
	b. safety ring not closed	2	194	4		.970
	c. normal fastening of safety ring		1	197	2	.958
	d. Worker crash			4	196	.980
Avg.						.982

ConvNet은 고리에서 감지되는 압력과 개폐 스위치의 전압 값을 matplotlib 라이브러리를 이용하여 그래프화한 뒤, 클라우드에서 제공하는 Tensorflow 라이브러리와 Inception-v3모델로 30분 간의 각 스탠스를 학습한 뒤 분석실험을 하였다. 실험결과는 표 4에 나타내었으며, 총 인식률은 평균 96.0%였다. 따라서 고리 체결 여부를 분석 알고리즘으로 ConvNet을 사용하는 것보다 규칙기반 알고리즘으로 분석하는 것이 적합하다고 판단하였다.

Table 4. ConvNet Algorithm Analysis Accuracy

		Activity Classification				Recogni- tion rate
		a	b	c	d	
L A B E L	a. don't tighten ring	192	5	2	1	.960
	b. safety ring not closed	2	187	8	3	.935
	c. normal fastening of safety ring	2	3	192	3	.960
	d. Worker crash			3	197	.985
Avg.						.960

2. Algorithm-Based Behavior Analysis Accuracy

작업자의 행동 분석의 정확도를 높이기 위해 세가지 알고리즘으로 정확도 실험 하였다. 결정트리 알고리즘과 ConvNet, LSTM으로 실험을 진행하였다. 표5와 같이 서있기, 앉기, 걷기, 달리기, 무릎 굽혀 물건잡기, 무릎 굽히지 않고 물건 잡기 등 6가지 자세로 구분하였다. 실험은 각 자세별로 10분 동안 각각 200개의 데이터셋을 가지고 알고리즘을 실험하였다. 결정트리로 실험 결과는 표 5와 같으며, 총 인식률은 73.0%이다.

Table 5. Rule-based Algorithm Analysis Accuracy

		Activity Classification						Recogni- tion rate
		a	b	c	d	e	f	
L A B E L	a. Standing	198		2				.990
	b. Sitting		153			33	14	.765
	c. Walking			161	39			.805
	d. Running			52	148			.740
	e. Bend knees and catch things		23	1		89	87	.445
	f. Hold things without bending knees		25			53	122	.610
Avg.								.730

ConvNet을 사용하기 위해 ACC_X, ACC_Y, ACC_Z, GYR_X, GYR_Y, GYR_Z 6개의 값을 matplob 라이브러리를 이용하여 그래프화한 뒤, GCP 클라우드에서 제공하는 Tensorflow 라이브러리와 Inception-v3 모델로 각 스탠드를 30분 동안 수집한 트레이닝셋을 학습한 뒤 분석실험을 진행하였다. 학습 단계에 따른 오차는 그림 15과 같으며, 실험결과는 표 5로 총 인식률은 평균 96.0%이다.




Fig. 15. Cross entropy according to steps

Table 6. ConvNet Algorithm Analysis Accuracy

		Activity Classification						Recogni- tion rate
		a	b	c	d	e	f	
L A B E L	a. Standing	192	6	1	1			.960
	b. Sitting	3	196	1	1			.980
	c. Walking	1	2	194	2	1		.970
	d. Running			2	197	1		.985
	e. Bend knees and catch things		1	2	3	187	8	.935
	f. Hold things without bending knees			2	1	8	189	.945
Avg.								.96

LSTM을 사용하기 위해 ACC_X, ACC_Y, ACC_Z, GYR_X, GYR_Y, GYR_Z, TOT_X, TOT_Y, TOT_Z 9개의 값을 Tensorflow와 Scikit-Learn 라이브러리로 학습한 뒤, 30분 간의 각 스탠드를 학습한 뒤 분석 실험을 하였다. 실험결과는 표 7로, 총 인식률은 95.4%이다.

Table 7. LSTM(RNN) Algorithm Analysis Accuracy

		Activity Classification						Recogni- tion rate
		a	b	c	d	e	f	
L A B E L	a. Standing	189	2					.954
	b. Sitting	1	198	1				.990
	c. Walking		3	189	6	2		.945
	d. Running		2	5	192	1		.960
	e. Bend knees and catch things				11	187	2	.935
	f. Hold things without bending knees				3	9	188	.940
Avg.								0.954

VI. Conclusions

기존의 규칙 기반 안전벨트 시스템은 여러 다양한 위험행동을 분석하기 어렵기 때문에 문제를 해결하기 위한 시스템이 필요하다. 본 논문에서는 작업자가 안전 고리를 제대로 장착하였는지 판단하는 시스템으로, 행동 분석을 위한 데이터를 수집하기 위해 블랙박스, 수집된 데이터를 기반으로 데이터를 학습해 작업자의 위험행동을 분석이 가능한 시스템을 제안하였다. 제안된 시스템을 결정트리, ConvNet, LSTM으로 작업자의 행동 분석 하였다. ConvNet으로 실험결과가 96.0%로 가장 정확하였다. 기존 보행자 분석 연구의 룰 베이스 방식이나 결정트리 알고리즘에서 벗어나 신경망을 이용한 딥러닝 방식의 작업자 행동 분석을 제안 하였고 행동분석 결과 96.0% 이상의 정확도로 위험행동을 분석할 수 있음을 확인하였다. 이를 통해 모든 작업자의 행동을 보다 정확하게 분석하고, 고소작업 중 발생할 수 있는 안전사고를 사전에 예방할 수 있을 것으로 기대된다.

REFERENCES

- [1] Korea Occupational Safety & Health Agency, "Industrial Accident Analysis", 2016
- [2] J. W. Jeong, "Theory and Real of Industrial Safety and Health Management", 2015
- [3] K.T. Kim. "A study on the Implementation of USN Technologies for Safety Management Monitoring of Architectural Construction Sites", J, Korea Inst. Building Construction. Vol. 9, No. 4, pp. 103-109 Aug. 2009
- [4] Korea Occupational Safety & Health Agency, "Manpower transport safety", 2008
- [5] Korea Occupational Safety & Health Agency, "Standard Work Safety (Manufacturing)", 2009
- [6] S. G. Hong, (2017) "Gait feature extraction algorithm based on useractivity recognition using inertial sensors", Master's Thesis, University of Science and Technology, Daejeon
- [7] Nils Y. Hammerla, S. Halloran & T. Plotz, (2016) "Deep, Convolutional, and Recurrent Modelsfor Human Activity Recognition Using Wearables", Proceedings. the Twenty-Fifth International Joint Conference on Artificial Intelligence, 1533-1540
- [8] Geun Chul Park, A. Y. Jeon, S. H. Lee at al, (2013) "Implementation of a Falls Recognition System Using Acceleration and Angular Velocity Signals", Journal of Sensor Science and Technology, Vol.22 No.1, 54-65
- [9] K. Y. Lee (2012), An Algorithm of Indoor Pedestrian Dead-Reckoning using IMU Sensor and Map Matching, Master's Thesis, Kangwon National University, Kangwon
- [10] S.J. Jeong, J.H. Lim (2015) "Implementation of USN based Personal Safety Belt Monitoring System", urnal of the Korea Institute of Information and Communication Engineering, Vol.19 No.3, 724-730
- [11] B. G. Ahn , Y. H. Noh ,Jeong & D. U. Jeong (2015), "Implementation of Behavior Notification System for Guide Dog Harness Using IMU and Accelerometer Sensor", The Journal of Korea Institute of Signal Processing and Systems, Vol.16 No.1, 15-21
- [12] R. Grzeszick, J.M. Lenk, & F.M. Rueda[1 at el, (2017). Deep Neural Network based Human Activity Recognition for the Order Picking Process. Proceedings Of The 4Th International Workshop On Sensor-Based Activity Recognition And Interaction - Iwoar '17. <http://dx.doi.org/10.1145/3134230.3134231>
- [13] Dehzangi, O., Taherisadr, M., & ChangalVala, R. (2017). IMU-Based Gait Recognition Using Convolutional Neural Networks and Multi-Sensor Fusion. *Sensors*, 17(12), 2735. <http://dx.doi.org/10.3390/s17122735>
- [14] Woo-Young Kang, B.H. Kim & B.T.Zhang (2016) "Hangeul Handwriting Recognition using Deeper Convolutional Neural Networks Based on Inception Modules",KCC, Vol.2016 No.6, 883-885
- [15] Christian Szegedy, W. Liu, Y. Jia et al, "Going deeper with convolutions", Retrieved from <https://arxiv.org/pdf/1409.4842.pdf>
- [16] Jürgen, Schmidhuber (2014), "Deep Learning in Neural Networks: An Overview" <http://arxiv.org/abs/1404.7828>
- [17] Choi, Hyoungin (2016), "A Study of Fall Detection before Impact Point usingan IMU Sensor",Master's Thesis, Korea University of Technology Education

Authors



Se-Hoon Lee received the B.S. degree in Computer Science from Inha University, Korea, in 1985 and M.S. and Ph.D degrees in Computer Science from Inha University, Korea, in 1987 and 1996, respectively. From 1987 to 1990, he worked as a information

analyst officer in the Computing Center, at Marine Corp. Dr. Lee joined the faculty of the Department of Computer Engineering at Inha Technical College, Incheon, Korea, in 1993. He is currently a Professor in the Department of Computer Systems & Engineering at Inha Technical College. He is interested in IoT embedded software, Embedded Deep learning.



Hyo-Jae Moon is currently studying in the Department of Computer & Engineering at Inha Technical College. He is interested in IoT embedded software, Deep learning, Blockchain Technologies.



Jin-Hyun Tak received the B.S. degree in Computer Science from Inha University, Korea, in 1992 and M.S. and Ph.D degrees in Computer Science from Inha University, Korea, in 1994 and 2000, respectively. He is currently a Director in the R&D Center

at DucSan Information Telecom. He is interested in IoT industrial safety systems