

# 도로 거칠기와 차량의 승객 상태를 활용한 DSJS(Driving Situation Judgment System) 설계

손수락\*, 정이나\*, 안희학\*\*

## The Driving Situation Judgment System(DSJS) using road roughness and vehicle passenger conditions

Su-Rak Son\*, Yi-Na Jeong\*, Heui-Hak Ahn\*\*

**요약** 현재 자율주행차량은 테스트 이후 상용화를 눈앞에 두고 있다. 그러나 아직 자율주행차량이 완벽히 상용화되지 않았음에도 81건의 사고가 발생했으며, 사고를 피하기 위한 차량의 주행 방식은 LiDAR에 많이 의존하고 있다. 현재 상용화된 3레벨 자율주행차량이 4레벨 자율주행차량으로 발전하기 위해서는 기존에 수집되는 정보보다 더 많은 정보를 수집해야만 한다. 따라서 본 논문에서는 기존의 자율주행차량에서 수집하는 정보인 도로 정보, 기상정보를 포함하여 차량이 주행 중인 도로의 거칠기와 자기 자신 및 주변 차량의 탑승객 상태를 정확하게 인식하여 차량이 처한 위기 상황을 정확하게 계산하는 Driving Situation Judgment System (DSJS)을 제안한다. DSJS의 PDM에 대한 실험 결과, PDM은 기존 차량의 탑승객 인식 시스템보다 평균적으로 15.52% 더 정확하게 탑승객을 분류할 수 있었다. 본 연구는 기존 3단계 자율주행차량이 수집하는 데이터보다 더 다양한 종류를 수집하여 4단계 자율주행차량을 달성하는 기초연구가 될 수 있다.

**Abstract** Currently, self-driving vehicles are on the verge of commercialization after testing. However, even though autonomous vehicles have not been fully commercialized, 81 accidents have occurred, and the driving method of vehicles to avoid accidents relies heavily on LiDAR. In order for the currently commercialized 3-level autonomous vehicle to develop into a 4-level autonomous vehicle, more information must be collected than previously collected information. Therefore, this paper proposes a Driving Situation Judgment System (DSJS) that accurately calculates the crisis situation the vehicle is in by using the roughness of the road and the state of the passengers of surrounding vehicles including road information and weather information collected from existing autonomous vehicles. As a result of DSJS's PDM experiment, PDM was able to classify passengers 15.52% more accurately on average than the existing vehicle's passenger recognition system. This study can be a basic research to achieve the 4th level autonomous vehicle by collecting more various types than the data collected by the existing 3rd level autonomous vehicle.

**Key Words** : Dangerous situation Judgement, Deep neural network, Passenger recognition, Road roughness classification, Suspension pressure

### 1. 서론

3단계 자율주행차량은 지정된 도로를 자율주행할 수 있는 수준으로, 이미 상용화가 진행되고 있다. 또

한, 4단계 자율주행차량은 해외뿐만 아니라 한국에서도 테스트를 진행 중이다. 그러나 상용화된 3단계 자율주행차량에서도 81건의 사고가 발생했으며, 현재 자율

\*Department of Computer Engineering, Catholic Kwandong University

\*\*Corresponding Author : Department of Software, Catholic Kwandong University (hhahn@cku.ac.kr)

Received May 12, 2021

Revised May 27, 2021

Accepted June 10, 2021

주행차량의 주행 방식은 LiDAR에 많이 의존하고 있다 [1, 2]. 또한, 사고를 피하기 위한 연구들은 대부분 한정적인 조건을 사용하여 실험을 진행하고 있다. 4단계 자율주행차량을 달성하기 위해서 차량은 지정되지 않은 도로를 자동으로 주행해야 하며, 지정되지 않은 도로로 주행할 때 안전성 문제는 가장 먼저 해결되어야 한다. 최종적으로 4, 5단계 자율주행차량은 지정되지 않은 도로에서도 안정적으로 자율주행을 실행해야 하므로 자율주행차량은 현재 도로에서 수집하는 정보보다 더 많은 정보를 이용하여 실시간성을 잃지 않고 긴급상황을 정확하게 판단해야만 한다. 따라서 본 논문은 자율차량의 주행 안정성을 향상하기 위해 도로 거칠기와 승객 상태를 활용한 Driving Situation Judgment System(DSJS)을 제안한다. DSJS는 기존의 자율주행차량에서 수집하는 정보인 도로 정보, 기상정보를 포함하여 차량이 주행 중인 도로의 거칠기와 자기 자신 및 주변 차량의 탑승객 상태를 정확하게 인식하여 차량이 처한 위기 상황을 정확하게 계산한다.

## 2. 관련 연구

### 2.1. 도로 거칠기 분류

국내에서 도로 거칠기에 관한 연구를 살펴보면 다음과 같다. 군산대학교에서는 좌우 바퀴가 노면 거칠기 특성을 가지도록 노면의 특성을 분류하였으며, 좌우 바퀴 거칠기 상관도를 고려한 노면과 고려하지 않은 노면에 대한 차량의 주행을 시뮬레이션했다[3]. 해당 연구에서는 좌우 바퀴가 주행 중인 노면의 거친 정도를 수치화하여 차량의 운동 효율성에 대해 실험을 진행했다. 또한, 해당 연구는 노면의 거칠기를 수치화하기 위하여 국내 도로 거칠기 측정을 통하여 국내 도로 특성을 잘 반영할 수 있는 노면 거칠기 분류지수를 제시했다[4]. 그러나 해당 연구는 차량 뒤쪽에 레이저 변위계, 속도계, 가속도 센서로 구성된 센서 하드웨어를 추가로 부착하여야 했다. 서울 주요 도로 및 지방 국도, 고속도로만 분석했기 때문에 비포장도로, 공사 중인 도로 등 여러 환경에 대해 거칠기를 분류할 수 없다.

한양 대학교에서는 도로에서 기존보다 더 다양한 정보를 수집하기 위해 기존 태양광 LED 표지 병에 RF

방식의 통신을 사용한 무선 제어 기능을 내장한 도로 표지 병과 이를 제어하는 시스템에 대해서 제안하였다 [5]. 실험 결과 중앙 통제실의 데이터를 RF 통신을 사용하여 최종적으로 LED 도로 표지 병의 색상 및 점등 방법을 제어할 수 있었으며 이로 인한 2차 사고 방지 기능의 가능성을 확인할 수 있었다.

가톨릭관동대학교에서는 주로 불균형적인 도로에서 작업하는 농업용 고소 리프트의 위험성을 줄이기 위하여 고소 리프트의 견인 성능과 토양 상태를 이용하여 운동 저항과 구동력을 예측하는 모델을 제시했다[6].

### 2.2. 탑승객 인식

탑승객 인식의 경우 국내의 연구는 희박하고, 해외 연구에서도 사고 시 부상을 예측하기 위한 연구가 주로 진행되고 있다. 중국 장춘 길림 대학교에서는 서로 다른 자세로 앉은 탑승자의 좌석 압력 분포를 정확하게 분석하여 압력 분포로 계산된 무게에 따라 탑승자를 분류할 수 있는 새로운 탑승자 분류 방식을 제시했다. 본 논문에서는 착석 자세 변화의 간섭을 고려하여 간섭 제거에 적합한 T-S 퍼지 모델로 탑승자 분류 알고리즘을 구축하였으며, 일반화 능력과 비선형성 과정을 가졌다[7].

아주대학교에서는 스마트 폰의 사용 여부를 기반으로 스마트 폰 센서를 이용하여 차량에 탑승한 것이 운전자인지, 탑승객인지 구분하는 시스템을 제안했다[8]. 이 시스템은 차량 내에서 스마트 폰이 크게 움직이지 않는다는 것과 차량 내의 모든 스마트 폰이 본 시스템을 사용해야 한다는 한계를 가지고 있다. 하지만 외부 시스템을 사용하지 않고 스마트 폰만을 사용하여 운전자와 탑승객을 구분할 수 있다는 장점이 있다.

위와 같이 도로 분석은 실시간으로 이루어지지 않거나, 구분할 수 있는 도로의 종류가 적고, 탑승객의 탐지는 독립적인 연구로 수행되었다. 본 논문에서는 실시간으로 도로를 분석하고 탑승객을 정확하게 탐지하여 그것들을 위험 상황 분석에 이용함으로써 자율주행차량의 안정성을 높이고자 한다.

## 3. Driving Situation Judgment System

Driving Situation Judgment System(DSJS)은 그

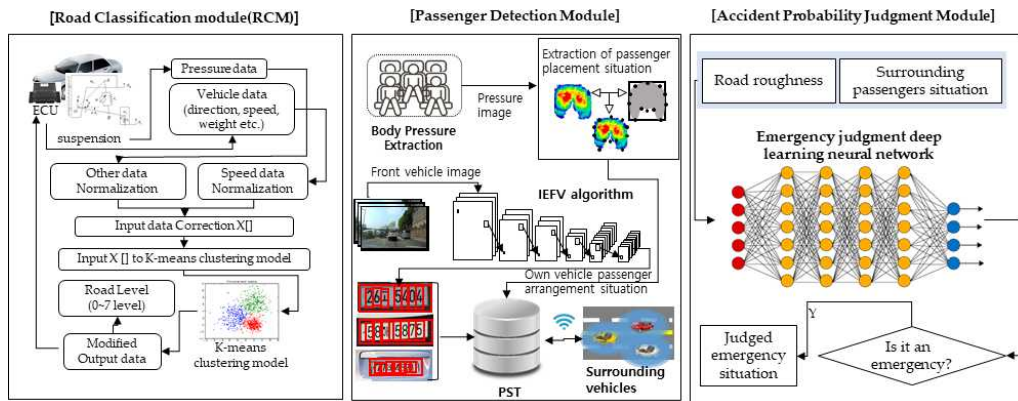


그림 1. Driving Situation Judgment System의 구성  
 Fig. 1. Configuration of Driving Situation Judgment System

림 1과 같이 3개의 모듈로 구성된다.

Road Classification module(RCM)은 차량의 서스펜션에 3개의 축을 설치하여 바퀴가 도로 주행 중 받는 압력을 입체적으로 분석하고, 도로의 상태를 8단계로 구분하여 도로 주행 중 서스펜션에 가해지는 압력에 따라 현재 차량이 주행 중인 도로의 거칠기를 분류한다. Passenger Detection Module (PDM)은 체압 센서를 사용하여 기존 승객 인식 방식보다 더 정확하게 차량의 탑승객 상태를 구분한다.

PDM은 차량의 각 좌석에 존재하는 것이 성인인지, 아동인지, 화물인지 인식하고 인식된 승객 상태를 차량의 위치, 차량번호와 함께 Passenger status information (PSI)로 저장한다. 차량은 V2V를 통해 PSI를 주변 차량과 공유함으로써 주변에 주행 중인 차량의 위치와 탑승객 상태를 정확하게 인식할 수 있다. Accident Probability Judgment Module(APJM)은 분류된 도로 거칠기와 PDM이 인식한 주변 차량의 승객 상태를 바탕으로 현재 상황이 긴급상황인지 아닌지 판단하고, 긴급상황이라면 긴급상황을 출력한다.

### 3.1. Road Classification Module

본 논문에서 제안하는 Road Classification module(RCM)은 차량의 서스펜션에 적용되는 압력을 측정하고 k-means 분류 알고리즘을 통해 차량이 주행 중인 도로의 거칠기를 7단계로 판단한다.

RCM은 도로의 거칠기를 판단하기 위해 서스펜션에 3축 압력 센서를 설치하여 차량의 서스펜션에 가해지는 충격을 주파수 형태로 수신한다. k-means 분류 알고리즘을 학습하기 위한 학습 데이터는 x, y, z축의 주파수와 도로 거칠기를 매칭시켜 도로를 7단계로 분류하도록 설계된다. 표 1은 RCM에서 분류되는 7가지의 도로 상태를 나타낸다. RCM은 K-means 분류 알고리즘에서 데이터 세트에서 찾을 것으로 예상되는 클러스터(그룹) 수인 k를 7로 설정하고 도로 상태를 분류한다. 그러나 k-means 알고리즘은 k의 수가 커지면 분류의 정확도가 떨어지는 문제가 발생한다. 따라서 본 논문에서는 데이터 중 가장 올바르게 도로를 분류한 각 7개의 데이터를 미리 군집화의 중심으로 설정하고 k-means 알고리즘을 실행한다. 또한, 도로 환경에 따라 서스펜션에 입력되는 압력이 다르므로 RCM은 서스펜션의 압력 데이터뿐만 아니라 도로의 곡률, 현재 날씨와 과거 날씨를 통해 도로가 얼마나 젖었는지를 k-means 알고리즘에 같이 입력하여 도로 판별의 정확성을 높인다.

표 1. Road Classification module의 도로 분류기준  
Table 1. Road classification criteria of the Road Classification module

No.	Image	description	class
1		Clean roads such as highways	very_fine
2		Paved roads with irregularities	fine
3		Old pavement	up_normal
4		Roads made of concrete tiles	normal
5		A road made of bricks like tiles	low_normal
6		Dirt road	rough
7		Off road	very_rough

### 3.2. Passenger Detection Module

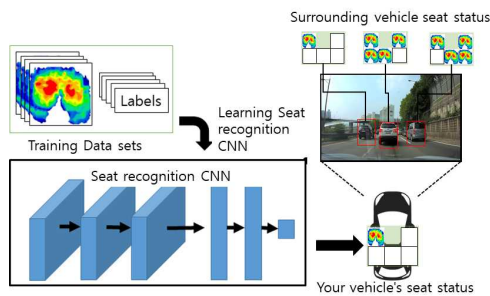


그림 2. Passenger Detection Module의 구성  
Fig. 2. Configuration of Passenger Detection Module

본 논문에서 제안하는 Passenger Detection Module (PDM)은 자율차량 내부의 탑승객 상황을 탐지하고, 그것을 V2V로 주변 차량에 공유한다. PDM은

본 연구의 선행 연구인 탑승객 탐지 및 공유 시스템 [9]을 사용한다. 그림 2는 PDM의 전체적인 구성을 나타낸다. PDM은 체압 센서의 이미지와 그 이미지가 짐인지, 성인인지, 아동인지 라벨링된 트레이닝 데이터 세트를 이용하여 Seat Recognition CNN을 학습시킨다. 체압 센서의 이미지는 64\*64 이미지를 사용하고 2000개의 데이터 세트를 이용하여 학습을 진행한다. Seat Recognition CNN의 학습 데이터는 웹 크롤링으로 수집한 차량 좌석을 포함한 좌석 압력 데이터와 20~30대 남성 2명, 여성 1명, 50~60대 남성 1명, 여성 1명, 9세 남성 아동 1명을 체압 센서가 부착된 시트에 다양한 자세로 앉게 하여 수집된 압력 데이터다. Seat Recognition CNN은 두 번의 Convolution 과정과 maxpooling 과정을 거친 후, Softmax 를 이용한 Fully Connected network를 통해 좌석에 존재하는 것이 짐인지, 성인인지, 아동인지 계산한다. Seat Recognition CNN는 64\*64의 이차원 벡터 행렬을 입력으로 사용하여, 3개의 출력노드 중 Softmax 값이 가장 높은 노드를 출력으로 사용한다. Seat Recognition CNN의 학습이 완료되면 PDM은 현재 주행 중인 본인 차량의 탑승객 상태를 파악하고 V2V 통신을 사용하여 전방에 주행 중인 다른 차량과 탑승객 상태를 공유한다.

### 3.3 Accident Probability Judgment

#### Module(APJM)

본 논문에서 제안하는 Accident Probability Judgment Module(APJM)는 RCM과 PDM의 출력을 사용하여 차량이 주행 중인 상황이 긴급상황인지 판단한다. APJM은 차량이 현재 주행 중인 도로의 거칠기 레벨과 주행 중인 차선, 본인 차량과 전방 차량의 탑승객 상태를 입력받아 위기 상황을 0~1로 출력한다.

표 2는 APJM의 입력값을 나타낸다. APJM은 입력값과 출력값으로 구성된 트레이닝 데이터 세트를 사용하여 DNN(Deep Neural Network)을 학습시킨다.

표 2. APJM의 입력

Table 2. Input values of APJM

node	meaning
X <sub>1</sub>	The number of vehicles ahead
X <sub>2</sub>	The distance to nearest vehicle
X <sub>3</sub>	The speed of nearest vehicle
X <sub>4</sub>	The distance to the farthest vehicle
X <sub>5</sub>	The number of pedestrians ahead
X <sub>6</sub>	The distance to nearest pedestrian
X <sub>7</sub>	The speed of the nearest pedestrian
X <sub>8</sub>	The distance to the farthest pedestrian
X <sub>9</sub>	Tire pressure
X <sub>10</sub>	Engine RPM
X <sub>11</sub>	Current speed
X <sub>12</sub>	Average speed over 5 seconds
X <sub>13</sub>	Headlight condition

이때, DNN의 그라디언트가 죽는 것을 막기 위해 입력층부터 마지막 은닉층까지는 ReLU 함수를 활성화 함수로 사용하고, 0~1 사이의 출력 노드 값을 위해 마지막 은닉층과 출력층 사이는 Sigmoid 함수를 활성화 함수로 사용한다. 수식 1은 ReLU 함수를, 수식 2는 Sigmoid 함수를 나타낸다.

$$f(x) = \max(0.01x, x) \quad (1)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

APJM은 DNN을 Back-propagation 방식으로 학습시킨다. 트레이닝 데이터 중 정상 주행데이터의 출력은 모두 0으로 설정되며, 사고 데이터는 차량의 수리 기록을 통하여 0~1 사이의 출력을 지정한다. 수식 3은 트레이닝 데이터를 사용할 때 손실함수를 나타낸다.

$$E = \frac{1}{2} \sum_{i=1}^k (d - y_i)^2 \quad (3)$$

APJM이 DNN의 학습을 완료하면 표 2의 입력값을 차량 주행 중 실시간으로 수집하여 사고 가능성을 계산한다. 만약 APJM의 출력값이 0.6 이상이라면, APJM은 사고 발생을 예측하여 자율주행차량의 탑승자에게 사고 위험성을 알린다.

### 4. 실험

본 논문의 DSJS의 유효성을 판단하기 위하여 가상 환경의 주행데이터를 사용하여 PDM의 정확성을 검증한다. 그림 3은 RCM에서 사용된 k-means 분류 알고리즘과 k-nn, 의사결정 트리의 정확성을 나타낸다. 분류 알고리즘 중 대표적으로 사용되는 SVM(Support Vector Machine)은 7개의 Decision Boundary를 구성하여 도로를 구분할 수 없으므로 사용되지 않았다. 테스트 데이터는 2000개 중 20%인 400개를 사용하여 테스트 되었다.




그림 3. k-means, k-nn, 의사 결정 트리의 정확도  
Fig. 3. an accuracy of the k-means, k-nn and decision trees

실험 결과, k-means 알고리즘의 평균 정확도는 96.31%, k-nn 알고리즘의 평균 정확도는 86.30%, 의사 결정트리의 평균 정확도는 75.91%로 k-means 알고리즘은 k-nn 알고리즘보다 약 10%, 의사결정트리보다 약 20% 더 높은 정확도를 가졌다.

그림 4는 데이터가 늘어남에 따라 무게를 이용한 기존 탑승객 인식 방식과 PDM의 정확도를 나타낸다. 학습되지 않은 1000 개의 데이터를 100개부터 900개까지 증가시키면서 기존 탑승객 인식 시스템과 PDM의 정확도가 측정되었다. 기존 탑승객 인식 시스템은 무게 데이터만을 입력받고, PDM은 체압센서의 이미지를 입력받는다.

실험 결과, 기존 탑승객 인식 시스템과 비교하여 PDM의 평균 정확도는 15.52% 더 높았다. 특히, 실험 데이터가 증가하여 짐으로 라벨링된 데이터의 입력이 높으면 높을수록 PDM의 정확도와 기존 탑승객 인식

시스템의 정확도가 크게 차이 났다.

기존 탑승객 인식 시스템은 해당 데이터가 집인지, 사람인지 구분하지 못했으며, PDM을 통해 더 정확한 차량 내부 상황을 파악할 수 있음이 입증되었다.




그림 4. 기존 탑승객 탐지 시스템과 PDM의 정확도  
Fig. 4. Existing passenger detection system and accuracy of PDM

그림 5는 기존 LiDAR를 통하여 전방 환경을 인식한 상태의 위험도와 APJM으로 위험도를 측정했을 때의 정확도를 나타낸다.




그림 5. LiDAR 시스템과 APJM의 사고 위험도 측정 정확도  
Fig. 4. Accident risk measurement accuracy of LiDAR system and APJM

위험도를 측정 후 정확도를 계산하기 위해 과거에 사고가 발생했을 때의 환경 데이터를 LiDAR 시스템과 APJM의 입력으로 사용하였으며, 사고 이후 처리 비용이 측정된 사고의 위험도와 얼마나 유사한지에 따라 정확도를 계산했다. LiDAR를 기반으로 한 사고 위험 측정 시스템은 과거 사고 발생 데이터를 기반으로 측정 가능한 도로 환경, 전방 차량 수를 설정하여 입력 데이터로 사용했으며, APJM은 사고 발생 데이터를 기반으로 도로의 거칠기, 도로 환경, 전방 차량 수, 차량

내부 탑승객 상태를 입력으로 사용했다. 사고 데이터 세트는 10개부터 30개까지 증가시키면서 실험을 진행했다. 실험 결과 기존 LiDAR 시스템의 평균 정확도는 68.81%였으며, APJM의 평균 정확도는 74.29%였다. 사고 이후 처리 비용이 사고 위험도와 비교되어서 두 시스템 모두 완벽한 정확도를 보장하지는 못했으나, APJM이 LiDAR보다 약 5.48% 높은 평균 정확도를 가졌다. 즉, 도로의 거칠기와 주변 차량 탑승객 수는 실제로 사고 위험도를 판단하는데 주요한 변수로 사용될 수 있다.

### 5. 결론

본 논문에서는 지정되지 않은 도로에서 자율주행을 실행해야 하는 4단계 자율주행차량을 위해 도로 거칠기와 주행 중인 차량의 탑승객 상황을 사용해 주행 중의 위험 상황을 판단하는 Driving Situation Judgment System (DSJS)을 제안했다. DSJS는 차량의 서스펜션에 3개의 축을 설치하여 바퀴가 도로 주행 중 받는 압력을 입체적으로 분석하고, 도로의 상태를 8 단계로 구분하여 도로 주행 중 서스펜션에 가해지는 압력에 따라 현재 차량이 주행 중인 도로의 거칠기를 분류하는 Road Classification module(RCM), 체압 센서를 사용하여 기존 승객인식 방식보다 더 정확하게 차량의 탑승객 상태를 구분하는 Passenger Detection Module (PDM)과 분류된 도로 거칠기와 PDM이 인식한 주변 차량의 승객 상태를 바탕으로 현재 상황이 긴급상황인지 아닌지 판단하고, 긴급상황이라면 긴급상황을 출력하는 Accident Probability Judgment Module(APJM)로 구성된다. 실험 결과, DSJS의 PDM은 기존 차량의 탑승객 인식 시스템보다 15.52% 더 정확하게 탑승객의 상태를 파악할 수 있었다. 그러나 DSJS는 해당 연구를 통해 기존의 LiDAR, CNN 등 전방 이미지에 크게 의존적이던 자율차량이 차량에 가해지는 압력, 내부 승객 상태 등 워크스테이션의 가상 데이터만을 사용하여 실험이 진행되었기 때문에 실제 센서들과 차량을 이용해 데이터를 측정하고 실험을 진행해야 한다. 또한, DSJS는 긴급상황에 완벽히 대응하기 위해서는 필요한 변수가 부족하여 긴급상



황을 오로지 판단만 하므로 향후 긴급상황에 완벽히 대처하여 주행을 결정할 수 있는 시스템이 연구되어야 한다.

## REFERENCES

- [1] Young-joo Kim, "Self-driving car accidents, there were many collisions with the general cars that followed.", <https://news.joins.com/article/23718449>
- [2] Jong-hwan Cha, "Too expensive sensor lidar, the 'headache' in the autonomous driving industry", <https://www.koit.co.kr/news/articleView.html?idxno=80662>
- [3] Gyoo-jae Choi, Bong-choon Jang, "Vehicle Dynamic Characteristics according to the Coherence of Road Roughness between Left and Right Wheels", *Proc. of the Korean Society of Automotive Engineers Spring/Autumn Conference*, The Korean Society Of Automotive Engineers, pp. 647-653, 2006
- [4] Gyoo-jae Choi, Seung-jin Heo, "Classification of the Korean Road Roughness", *Transaction of the Korean Society of Automotive Engineers*, Vol.14 No.5, pp.115-120, 2006
- [5] Hyung-Sik Kim, Joon-Hyeok Jeon, Hee-Jun Kim, Joon-Seon Ahn, "A Study on Smart Road Stud System with RF Wireless Control", *Journal of Korea Institute of Information, Electronics, and Communication Technology, Korea Information Electron Communication Technology*, Vol.12 No.3, pp.282-289, 2019
- [6] Jae-hyun Jo, Jun-tae Kim, Jin-hyoung Jeong, Young-yoon Chang, Won-yeop, Park, Sang-sik Lee, "Development of Modeling Technique for Prediction of Driving Force and Kinetic Resistance of Agricultural Forklift", *Journal of Korea Institute of Information, Electronics, and Communication Technology*, Korea Information Electron Communication Technology, Vol.12 No.3, pp.299-305, 2019
- [7] Zhenhai Gao, Yang Zhao, "Vehicle occupant classification algorithm based on T-S fuzzy model", *Procedia Engineering*, Vol.24, pp.500-504, 2011
- [8] Hyeon-Jung Park, Jeong-Gil Ko, "A Study on the System for Distinguishing between driver and passenger Using smartphone", *Proceedings of Symposium of the Korean Institute of communications and Information Sciences*, pp.910-911, 2018
- [9] Su-Rak Son, Byung-Kwan Lee, Son-Kweon Sim, Yi-Na Jeong, "A Design of Passenger Detection and Sharing System(PDSS) to support the Driving Decision of an Autonomous Vehicles ", *The Journal of Korea Institute of Information, Electronics, and Communication Technology*, Korea Information Electronic Communication Technology, 2021

---

### 저자약력

---

**손 수 략(Su-Rak Son)**

**[정회원]**



- 2018년 2월 : 가톨릭관동대학교 컴퓨터학과(공학사)
- 2019년 8월 : 가톨릭관동대학교 컴퓨터학과(공학석사)
- 2019년 8월 ~ 현재 : 가톨릭관동대학교 컴퓨터학과(공학박사 재학)

〈관심분야〉 빅데이터, 네트워크, 프로그래밍 언어

**정 이 나(Yi-Na Jeong)**

**[정회원]**



- 2011년 2월 : 가톨릭관동대학교 컴퓨터학과(공학사)
- 2013년 8월 : 가톨릭관동대학교 컴퓨터학과(공학석사)
- 2018년 8월 : 가톨릭관동대학교 컴퓨터학과(공학박사)
- 2020년 3월 ~ 현재 : 가톨릭관동대학교 소프트웨어학과 조교수

〈관심분야〉 빅데이터, 네트워크, 프로그래밍 언어

**안 희 학(Heui-Hak Ahn)**

**[정회원]**



- 1981년 2월 : 송실대학교 전자계산학과(공학사)
- 1983년 2월 : 송실대학교 컴퓨터학과(공학석사)
- 1994년 8월 : 송실대학교 컴퓨터학과(공학박사)
- 1984년 4월 ~ 현재 : 가톨릭관동대학교 소프트웨어학과 교수

〈관심분야〉 시스템소프트웨어, 프로그래밍 언어, IoT, 컴퓨터 보안