

자율차량 안정성을 위한 도로 거칠기 기반 제동압력 계산 시스템

손수락*, 이병관*, 심손권**

The road roughness based Braking Pressure Calculation System(BPCS) for an Autonomous Vehicle Stability

Su-Rak Son*, Byung-Kwan Lee*, Son-Kweon Sim**

요약 본 논문은 자율차량 안정성을 위한 도로 거칠기 기반 제동압력 계산 시스템을 제안한다. 제동압력 계산 시스템은 차량의 전방 이미지를 랜덤 포레스트의 입력에 맞게 가공하는 이미지 정규화 모듈, 기상정보와 이미지 정규화 모듈에서 정규화된 차량 전방 이미지를 입력으로 사용하여 차량이 주행 중인 도로의 거칠기를 구별하는 랜덤 포레스트 기반 도로 거칠기 분류 모듈과 도로 거칠기에 따라 차량에 적용되는 마찰 계수를 수정하고, 전방 차량에 따라 최적 주행을 유지하는 브레이킹 강도를 결정하는 차량 브레이크 압력 제어 모듈로 구성된다. 본 논문은 제동압력 계산 시스템의 효율성을 검증하기 위해 제동압력 계산 시스템에 사용되는 랜덤 포레스트 모델을 중심으로 실험이 진행되었다. 실험 결과, 랜덤 포레스트 모델의 정확도는 SVM보다 약 2% 높았고, 정확한 랜덤 포레스트 모델 구성을 위해 7개의 특징이 중복 허용 임의 추출되어야 한다는 결론이 도출되었다. 따라서 제동압력 계산 시스템은 차량이 제동해야 하는 상황에서 정확성 모두를 만족할 수 있다.

Abstract This paper proposes the road roughness based Braking Pressure Calculation System(BPCS) for an Autonomous Vehicle Stability. The system consists of an image normalization module that processes the front image of a vehicle to fit the input of the random forest, a Random Forest based Road Roughness Classification Module that distinguish the roughness of the road on which the vehicle is travelling by using the weather information and the front image of a vehicle as an input, and a brake pressure control module that modifies a friction coefficient applied to the vehicle according to the road roughness and determines the braking strength to maintain optimal driving according to a vehicle ahead. To verify the efficiency of the BPCS experiment was conducted with a random forest model. The result of the experiment shows that the accuracy of the random forest model was about 2% higher than that of the SVM, and that 7 features should be bagged to make an accurate random forest model. Therefore, the BPCS satisfies both real-time and accuracy in situations where the vehicle needs to brake.

Key Words : Brake pressure calculation, Random Forest, Road roughness classification, Region of Interest, Vehicle friction coefficient

1. 서론

현재 3레벨 자율주행차량은 지정된 도로에서만 자율주행이 가능하다. 또한, 현재 자율주행차량이

일으킨 사고의 대부분은 도심 교차로에서 발생했으며, 뒤따르던 일반 차와 충돌한 사고가 절반가량을 차지한 것으로 나타났다. 직진 주행 사고 49건 중 18건은 서행 중인 전방의 일반차량과 충돌이었

*Department of Software Engineering, Catholic kwandong University

**Corresponding Author : Department of Software Engineering, Catholic kwandong University (paranse@cku.ac.kr)
 Received July 30, 2020 Revised August 23, 2020 Accepted August 27, 2020

으며, 12건은 후방의 일반차량과 충돌이었다 [1]. 따라서 4레벨 이상의 완전 자율주행차량을 위해서는 지정되지 않은 도로에서도 차량의 안정성이 확보되어야 하며, 특히 직진 중인 일반차량과 자율주행차량의 사고를 방지하기 위해 자율주행차량의 제동능력이 향상되어야 한다. 따라서 본 논문에서는 차량 전방 이미지를 수집하여 차량이 주행 중인 도로의 거칠기를 계산하고, 도로의 거칠기와 전방 차량의 거리, 속도에 따라 브레이크의 강도를 조절하여 차량이 최적의 상태로 주행할 수 있게 하는 자율차량 안정성을 위한 도로 거칠기 기반 제동압력 계산 시스템을 제안한다. 제동압력 계산 시스템은 차량의 차선 인식에 주로 사용되는 ROI 기술을 이용하여 차량의 전방 이미지에서 도로가 아닌 부분을 제거하고 해당 이미지를 랜덤 포레스트의 입력에 맞게 재가공한다. 재가공된 이미지는 현재 기상정보와 함께 랜덤 포레스트의 입력으로 사용되며, 랜덤 포레스트는 도로 이미지와 기상정보를 통해 현재 도로의 거칠기를 계산한다. 랜덤 포레스트를 통해 도로의 거칠기가 계산되면, 제동압력 계산 시스템은 도로의 거칠기를 사용하여 차량에 적용할 도로 마찰 계수를 수정하고, 전방 차량과의 거리와 상대속도를 통해 차량이 최적 상태로 주행할 수 있도록 브레이크에 가해질 압력의 세기를 조절한다. 제동압력 계산 시스템은 차량 전방의 이미지를 ROI와 정규화를 통해 랜덤 포레스트의 입력에 맞게 수정하는 이미지 정규화 모듈, 이미지 정규화 모듈의 출력값과 현재 기상정보를 이용하는 랜덤 포레스트를 사용하여 차량이 주행 중인 도로의 상태를 결정하는 도로 거칠기 분류 모듈, 도로 거칠기와 차량의 상태에 따라 마찰 계수를 수정하고, 전방 차량과 거리를 측정하여 최적의 주행을 유지할 수 있는 브레이크 압력의 강도를 계산하는 차량 브레이크 압력 제어 모듈로 구성된다.

2. 관련 연구

2.1 ROI(Region of Interest)

ROI는 이미지의 관심 영역을 설정하여 이미지

에서 나오는 방대하지만 쓸모없는 데이터를 제거하기 위해 만들어진 알고리즘이다. 다음 연구들은 ROI를 차량에 적용한 연구들이다.

Nguyen Manh Cuong 외 1인은 차량에서 발생할 수 있는 GPS 수신 오류를 해결하기 위하여 낮은 성능의 컴퓨팅 시스템의 도로 경계 감지를 위한 알고리즘을 제안했다 [2]. 제안된 알고리즘은 ROI를 통해 차량이 자주 지나다니는 도로의 교통 항법을 위한 상태 지도를 생성한다. 이승현 외 3인은 관심 영역 내에 존재하는 그림자와 차량으로 인한 에지를 검출하고 두 특징 정보를 결합한 가설 생성 방법을 제안하고 차량 후방 영상을 이용하여 사각지대를 감시하는 시스템에 제안 방법을 적용하는 실험을 수행하였다 [3]. 해당 시스템은 이미지에서 수집되는 도로의 경계면(엣지)과 차량의 그림자 특성을 이용하여 이미지의 사각지대에서 도로의 차량을 검출한다. 윤현철 외 1인은 초음파 센서를 이용한 능동안전 경고시스템을 가상환경(PreScan)에서 실험하여 제안한다 [4]. 해당 시스템은 어린이 교통사고를 예방하기 위하여 차량 측면의 약 1m 내외로 사다리꼴 ROI 영역을 설정하여 주변에 존재하는 사물 혹은 사람을 탐지한다. 해당 시스템은 통학 시 발생하는 사고를 줄이기 위해 차량 측면에 ROI기술을 도입한 시스템이다.

2.2 랜덤 포레스트

차량 분야의 연구들은 랜덤 포레스트를 주로 차선 인식, 전조등 인식 등 시각적 판단에 사용하고 있다. 다음 연구들은 랜덤 포레스트를 차량에 적용한 연구들이다.

박종철 외 2인은 여러 개의 연속 변수 관측 벡터를 효과적으로 학습하고, 과적합을 방지하여 최적의 모델을 생성해주는 랜덤 포레스트 기법을 이용하여 실도로에서 취득한 운전자 주행데이터를 학습시키고, 자차 및 차선, 주변차량 정보를 통해 운전자의 차선변경 의도를 예측할 수 있는 모델을 수립하였다 [5]. 허두영 외 3인은 차량이 움직일 때 발생하는 카메라의 움직임, 도로상의 광원에 강건한 지능형 전조등 제어 시스템을 제안한다 [6]. 해

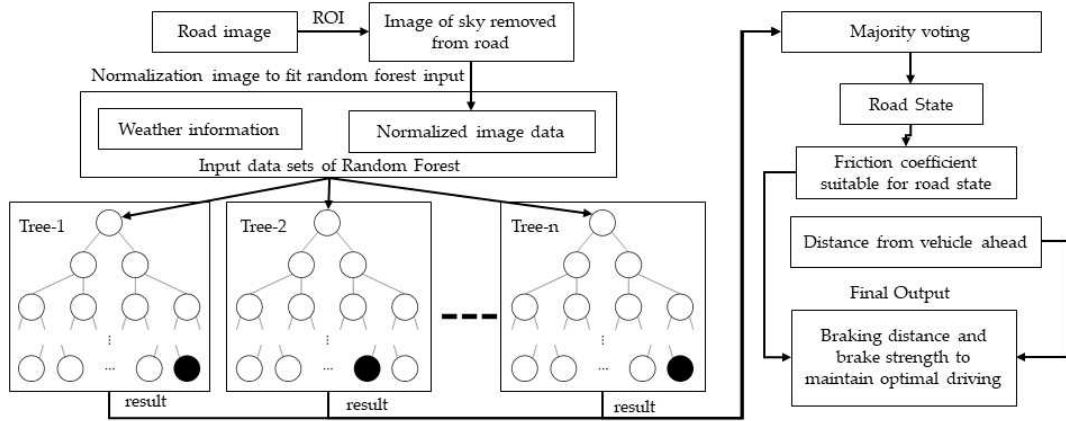


그림 1. 제동압력 계산 시스템의 구성
Fig. 1. the braking pressure calculation system

당 시스템은 후보 광원을 검출할 때 카메라의 원근 범위 추정 모델을 기반으로 한 ROI (Region of Interest)를 사용하며 이는 FROI (Front ROI)와 BROI (Back ROI)로 나뉘어 사용된다. ROI내에서 차량의 전조등과 후미등, 반사광 및 주변 도로의 조명등은 2개의 적응적 임계값에 의해 세그먼트화 된다. 세그먼트화 된 광원 후보군들로부터 후미등은 적색도(redness)와 Haar-like특징에 기반한 랜덤 포레스트 분류기에 의해 검출된다. 최찬용 외 3인은 열차의 차상가속도 데이터를 기반으로 궤도의 품질을 결정하는 지표 중 하나인 궤도 품질 지수를 기계학습 기법을 활용하여 예측하였다 [7]. 해당 연구는 기계학습 기법에서 적용모델에 따라 정확도가 달라질 수 있으므로, 차량 진동 가속도를 이용한 궤도품질지수를 예측하기 위해서는 앙상블 알고리즘 사용한 모델을 적용했다. 김광섭 외 6인은 차량의 횡방향과 종방향의 가속도와 조향각을 입력 데이터 세트로 사용하는 랜덤 포레스트 알고리즘을 통해 운전자의 졸음 상태와 정상 상태를 감지하는 기술을 개발했다 [8].

3. 본론

3.1 Overview

본 논문에서 제안하는 제동압력 계산 시스템은 현재 기상정보와 차량 전방의 이미지를 사용하여 도로의 거칠기를 분류하고, 도로에 거칠기에 맞게 도로와 타이어의 마찰 계수를 수정하여 전방 차량과의 간격에 맞게 최적 주행을 유지하는 최적의 브레이크 강도를 계산한다. 그림 1은 제동압력 계산 시스템의 구성을 나타낸다. 먼저 제동압력 계산 시스템은 차량 전방 카메라 등을 통해 차량 전방의 이미지를 수집하고 ROI를 적용하여 그 이미지의 하늘 영역을 제거하고 도로 영역만 남긴다. 다음으로 이미지의 픽셀 데이터를 벡터 열로 변환하고, 벡터 열과 기상정보를 랜덤 포레스트에 입력해 도로 상태를 분류한다. 마지막으로 분류된 도로 상태에 따라 마찰 계수를 조정하여 최대 제동 거리를 계산하고 제동압력 계산 시스템은 차량의 전방 이미지를 랜덤 포레스트의 입력에 맞게 가공하는 이미지 정규화 모듈과 기상정보와 이미지 정규화 모듈에서 정규화된 차량 전방 이미지를 입력으로 사용하고 차량이 주행 중인 도로의 거칠기를 구별하는 랜덤 포레스트 기반 도로 거칠기 분류 모듈과 도로 거칠기에 따라 차량에 적용되는 마찰 계수를 수정하고, 전방 차량에 따라 최적 주행을 유지하는 제동 강도를 결정하는 차량 브레이크 압력 제어 모듈로 구성된다.

3.2 이미지 정규화 모듈

본 논문에서 제안하는 이미지 정규화 모듈은 이미지 그 자체를 입력으로 사용하지 못하는 랜덤 포레스트 모델을 위하여 차량 전방의 이미지를 전처리하여 랜덤 포레스트의 입력 데이터로 가공한다. 이미지 정규화 모듈은 총 세 단계를 거쳐 이미지를 전처리한다. 그림 2는 이미지 정규화 모듈이 차량 전방 이미지를 랜덤 포레스트의 입력에 맞게 정규화하는 과정을 나타낸다. 우선 이미지 정규화 모듈은 ROI를 사용하여 차량 전방 이미지에서 도로 영역만을 추출한다. 그러나 랜덤 포레스트는 이미지 자체를 입력으로 사용할 수 없기 때문에 이미지 정규화 모듈은 도로 영역만 추출된 이미지를 벡터 열로 변경한다. 이미지 정규화 모듈은 도로 영역만 추출된 이미지의 픽셀마다 존재하는 R, G, B값을 저장하여 이미지를 R, G, B값 배열로 변경시킨다.

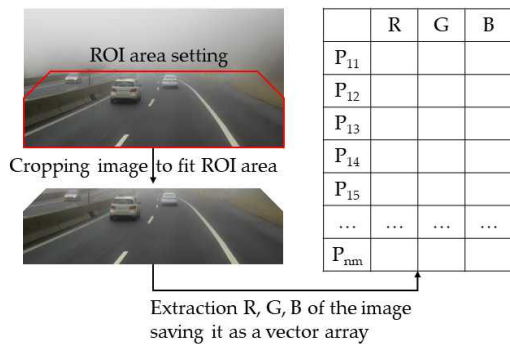


그림 2. 이미지 정규화 과정
Fig. 2. Process of image normalization

3.3 도로 거칠기 분류 모듈

본 논문에서 제안하는 도로 거칠기 분류 모듈은 이미지 정규화 모듈에서 정규화된 이미지 값과 현재 기상정보를 입력으로 사용하는 랜덤 포레스트를 이용하여 도로의 거칠기를 분류한다.

우선 도로 거칠기 모듈은 도로 거칠기 분류를 위한 랜덤 포레스트 모델을 생성한다. 표 1은 랜덤 포레스트 모델에서 사용되는 입력을 나타낸다. 랜덤 포레스트 모델은 표1의 입력을 사용하여 도로의 거칠기를 마른 포장도로, 젖은 포장도로, 마른 균열 도로, 젖은 균열

도로, 마른 비포장도로, 젖은 비포장도로의 6단계로 분류한다.

표 1. 랜덤 포레스트 모델의 입력
Table 1. Input of a random forest model

Kinds	Variable name	meaning
weather	Average precipitation	Precipitation divided by time
	Average temperature	Average daily temperature
	Current temperature	Temperature value of driving time
	Lowest temperature	Minimum value of day temperature
	Immediate temperature	Average temperature for 30 minutes immediately after rain
image	image_RGB[]	Sum of R, G, and B values of image pixels
	image_size_X	Horizontal size of the image
	image_size_Y	Vertical size of the image
	image_R[]	The set of red values in pixels
	image_G[]	The set of green values in pixels
	image_B[]	The set of blue values in pixels
	image_difference	Average of the sum difference of R, G, B between pixels

랜덤 포레스트 모델을 생성하기 위하여 변수들을 구분할 특징값과 랜덤 포레스트 내부의 의사 결정 모델의 개수, 특징값을 중복 허용 임의 추출할 개수가 정의되어야 한다. 본 논문에서는 랜덤 포레스트 모델을 위해 42개의 n_features를 사용한다. 예를 들어 'Average temperature > 21', 'image_difference > 50', 'image_RGB[] < 150' 등 n_features란 랜덤 포레스트의 각 노드에서 입력 데이터를 구분하기 위한 특징을 나타낸다. 그림 3은 도로 거칠기 분류 모듈이 랜덤 포레스트 모델을 구성하는 방식을 나타낸다.

랜덤 포레스트 모델의 구성이 완료되면 도로 거칠기 분류 모듈은 bootstrap sampling 방식을 사용하여 랜덤 포레스트를 학습시킨다. 본 논문에서는 bootstrap sampling을 위하여 차량의 이미지와 해당 주행의 기상정보로 이루어진 데이터 세트에 라벨을 부여한 약 300개의 트레이닝 데이터 세트를 사용한다.

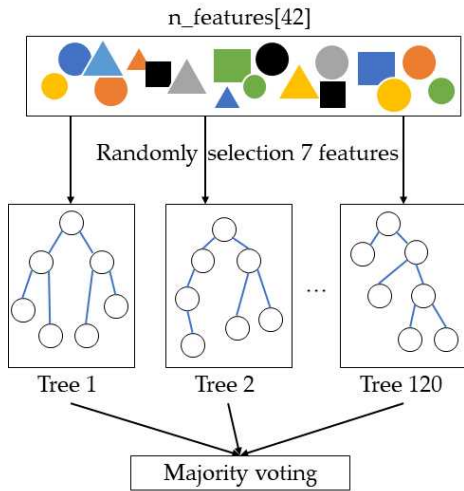


그림 3. 랜덤 포레스트의 구성 방식
Fig. 3. How random forests are structured

랜덤 포레스트의 학습은 다음과 같이 진행된다. 첫째, 300개의 트레이닝 데이터 세트 중 중복을 허용하여 300개를 랜덤하게 선택한다. 다음으로 선택된 300개의 데이터를 사용하여 랜덤 포레스트의 각 의사 결정 트리를 학습시킨다. 의사 결정 트리는 엔트로피를 사용하여 학습되며, 식 1은 엔트로피를 구하는 과정을 나타낸다.

$$Entropy(A) = - \sum_{k=1}^m p_k \log_2(p_k) \dots\dots\dots (1)$$

엔트로피는 각 의사 결정 트리의 최종 노드에서 계산되며, 식 1에서 m은 최종 노드에 존재하는 전체 데이터 수, p_k 는 최종 노드에서 발생한 확률값이다. 예를 들어 최종 노드에서 40개의 데이터 중 k라는 데이터가 21개라면, p_k 는 $\frac{21}{40}$ 이 된다. 도로 거칠기 분류 모듈은 엔트로피를 통하여 각 의사 결정 트리의 노드를 조정하여 랜덤 포레스트로 도로의 거칠기를 분류하고 분류된 도로의 거칠기를 차량 브레이크 압력 제어 모듈로 전송한다.

3.4 차량 브레이크 압력 제어 모듈

차량 브레이크 압력 제어 모듈은 분류된 도로의 거칠기를 통해 차량에 적용될 마찰 계수를 수정하여 브

레이크 시 제동거리를 계산한다. 우선, 차량 브레이크 압력 제어 모듈은 사전에 차량 내부 저장소에 상황별 마찰 계수를 저장한다. 마찰 계수는 Traffic Accident Reconstruction의 상황별 마찰 계수 중 도로 거칠기 분류 모듈에서 분류할 수 있는 마찰 계수만을 사용한다[9]. 표 2는 상황별 마찰 계수를 나타낸다.

표 2. 상황별 마찰 계수
Table 2. Context-specific friction coefficient

Road & driving condition	Pavement road	Crack road	Unpaved road
Dry road 48km/h or more	0.45~0.70	0.35~0.60	0.40~0.70
Less than 48km/h	0.55~0.80	0.50~0.60	0.40~0.70
Wet road 48km/h or more	0.45~0.65	0.25~0.55	0.45~0.75
Less than 48km/h	0.45~0.70	0.30~0.60	0.45~0.75

차량 브레이크 압력 제어 모듈은 도로 거칠기 분류 모듈에서 전달받은 도로 거칠기와 현재 차량 속도에 맞는 마찰 계수를 사용하여 차량의 제동 거리를 계산한다. 식 2는 제동거리를 계산하는 방식을 나타낸다.

$$d = \frac{v^2}{2g\mu} \dots\dots\dots (2)$$

식 2에서 d는 제동 거리, v^2 는 차량의 현재 속도를, g는 중력 가속도를, μ 는 지면과 타이어의 마찰 계수를 의미한다. 마찰 계수는 표 2를 기준으로 차량에 무게에 따라 결정된다. 식 2에서 계산된 제동 거리는 차량이 풀 브레이크를 사용했을 때, 즉 차량의 브레이크 디스크가 멈춰 있을 때의 제동 거리를 나타낸다. 만약, 주행 중인 전방에 차량이 존재한다면, 차량 브레이크 압력 제어 모듈은 구해진 제동거리와 전방 차량의 거리를 바탕으로 안전거리를 유지할 수 있는 최적의 브레이크 압력을 계산한다.

4. 실험

본 논문에서 제안한 도로 거칠기 기반 제동 입력 계산 시스템의 효율성을 검증하기 위하여 두 가지 실험이 진행되었다. 첫 번째 실험은 랜덤 포레스트의 최적화를 위하여 중복 허용 임의의 추출되는 특징의 개수를 조절하며 랜덤 포레스트가 최적으로 도로 거칠기를 계산할 수 있는 환경을 계산한다. 두 번째 실험은 랜덤 포레스트 모델과 유사한 입력, 출력을 사용하는

SVM(support vector machine)을 사용하여 랜덤 포레스트 모델과 SVM의 정확도를 계산한다. 표 3은 실험에 사용된 워크 스테이션의 사양을 나타낸다.

표 3. 실험이 진행된 워크 스테이션의 사양
Table 3. Specification of the workstation where the experiment was conducted

category	Specification
CPU	i5-6600, 3.30GHz, 6 MB Intel® Smart Cache
GPU	GTX 1080
RAM	16GB, 21300MHz




그림 4. 중복 허용 임의의 추출되는 특징 수에 따른 랜덤 포레스트 모델의 평균 정확도
Fig. 4. An average accuracy of random forest model according to the number of features being bagged

그림 4와 5는 중복 허용 임의의 추출되는 특징별 랜덤 포레스트의 정확도를 나타낸다. 그림 4에서 중복 허용 임의의 추출되는 특징의 수가 0~4일 경우는 60% 이하의 정확도가 측정되었으며, 중복 허용 임의의 추출 되는 특징의 수가 13개 이상일 경우 Overfitting에 의해 오히려 정확도가 감소하였다. 또한 7개에서 11개의 특징이 중복 허용 임의의 추출되었을 때 랜덤 포레스트 모델은 약 90%의 정확성을 가졌다. 따라서 최고의 정확성을 가지는 7~11개의 특징 중 연산 시간을 최소로 할 수 있는 7개의 특징만을 중복 허용 임의의 추출을 통하여 랜덤 포레스트를 구성하는 것이 가장 효율적이다.




그림 5. 중복 허용 임의의 추출되는 특징 수에 따른 랜덤 포레스트 모델의 라벨별 정확도
Fig. 5. An accuracy of each label of the random forest model according to the number of features being bagged

그림 6은 같은 입력과 출력을 사용하는 랜덤 포레스트 모델과 SVM 모델의 연산 시간과 정확도를 나타낸다. 테스트 데이터를 10개에서 200개까지 증가시키면서 각 모델의 정확도가 측정되었다.




그림 6. 테스트 데이터별 SVM과 랜덤 포레스트의 정확도
Fig. 6. An accuracy of SVM and random forest per test data

실험 결과, 입력 데이터 세트가 70개 이하일 경우 SVM이 랜덤 포레스트 모델보다 약 1% 높은 정확도를 가지지만, 입력 데이터 세트가 130개 이상일 때부터 랜덤 포레스트 모델이 약 2% 높은 정확도를 가지며, 200개의 입력 데이터 세트를 사용할 때 SVM의 정확도는 91.5%, 랜덤 포레스트 모델의 정확도는 94.5%로 랜덤 포레스트 모델이 SVM 모델보다 3%더 높은 정확도를 가졌다. 따라서 다양한 입력 데이터를 사용할수록 랜덤 포레스트 모델이 도로의 거칠기를 더 정확하게 분류한다.

5. 결론

본 논문에서 제안한 도로 거칠기 기반 제동압력 계산 시스템 (Braking Pressure Calculation System)는 이미지를 전처리하고 랜덤 포레스트를 사용하여 차량이 주행 중인 도로의 거칠기를 분석한 다음 마찰 계수를 수정하여 차량의 제동 거리를 계산하고, 계산된 제동 거리에 따라 최적 주행을 가능하게 하는 브레이크 압력을 계산했다. 실험 결과, 랜덤 포레스트 모델의 정확도는 SVM보다 약 2% 높았고, 정확한 랜덤 포레스트 모델의 구성을 위해 7개의 특징이 중복 허용 임의 추출되어야 한다는 결론이 도출되었다. 따라서 랜덤 포레스트 모델은 차량이 제동해야 하는 상황에서 정확성 모두를 만족할 수 있다. 그러나 본 논문은 빗판, 경사 등 다양한 도로 상황을 고려하지 않았으며, 주행 중인 차량에 직선거리에 있는 차량만을 대상으로 브레이크 강도를 측정했다. 또한, 300개의 트레이닝 데이터 세트만을 사용하여 정확도의 측정이 충분히 검증되지 않았다. 향후 연구는 도로 내부, 외부 변수들을 추가하고 10000개 이상의 트레이닝 데이터 세트를 확보하여 완벽하게 제어 가능한 브레이크 시스템의 개발을 목표로 한다.

REFERENCES

[1] "자율주행 차 사고, 뒤따르던 일반 차와 충돌 많았다." 김영주, <https://news.joins.com/article/23718449>

[2] Nguyen Manh Cuong, Jaesung Lee, "Automatic Detection of ROI for Vehicle Positioning", Proceedings of Symposium of the Korean Institute of communications and Information Sciences, pp. 164-165, June, 2016

[3] Lee, Seung-Hyun, Kim, Tae-Dong, Yi, Kang, Jung, Kyeong-Hoon, "Hypothesis Generation for Vehicle Detection by Combining Shadow and Edge", Conference of the Korean Society Of Broad Engineers, pp. 316-319, June, 2016

[4] Hyun-cheol Yoon, Ju Yong Choi, "Transportation vehicle active safety warning systems developed algorithms". Fall Conference and Exhibition of the Korean Society Of Automot

ive Engineers, pp. 734-735, November, 2014

[5] Jongcherl Park, Hojun Lee, Kyongsu Yi, "Cut-in Intension Inference based on Human Driving Data Analysis using Random Forest Method", The Korean Society of Mechanical Engineers 2018 Conference, pp. 1703-1708, December, 2018

[6] Duyoung Heo, Sang Jun Kim, Choong Sub Kwak, Jae-Yeal Nam, Byoung Chul Ko, "Vehicle Headlight and Taillight Recognition in Nighttime using Low-Exposure Camera and Wavelet-based Random Forest", JOURNAL OF BROADCAST ENGINEERING Vol.22, No.3, pp. 282-294, May, 2017

[7] Chanyong Choi, Hunki Kim, Young Cheul Kim, Sang-su Kim, "Prediction of Track Quality Index (TQI) Using Vehicle Acceleration Data based on Machine Learning", Journal of Korean Geosynthetics Society, Vol.19, No.1, pp. 45-53, March, 2020

[8] Kwangseub Kim, Wang Maosen, Naktak Jung, Seongmo Yang, Sehoon Yoo, Daeseong Gi, Myungwon Suh, "A Study on Drowsy Driving Behavior Detection Based on Driving Information", Spring Conference of the Korean Society Of Automotive Engineers, pp.702-705, May, 2015

[9] Lynn B. Fricke, Traffic Accident Reconstruction, pp. 62-114, Northwestern University Traffic Institute, 1990

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

이 병 관(Byung-Kwan Lee)

[정회원]



- 1979년 2월 : 부산대학교 기계설계학과(공학사)
- 1986년 2월 : 중앙대학교 전자계산학과(이학석사)
- 1990년 2월 : 중앙대학교 전자계산학과(공학박사)
- 1988년 3월 ~ 현재 : 가톨릭관동대학교 소프트웨어학과 교수

〈관심분야〉 네트워크보안, 빅데이터, 데이터마이닝, 사물인터넷

심 손 권(Son-Kweon Sim)

[정회원]



- 1996년 : 관동대학교 전자계산공학과 졸업(공학사)
- 1998년 : 관동대학교 전자계산공학과 공학석사
- 2003년 : 관동대학교 전자계산공학과 공학박사

〈관심분야〉 시스템 프로그래밍, 딥러닝, 빅데이터, 인공지능