

신경회로망을 이용한 새로운 충돌 경고 시스템

Novel Collision Warning System using Neural Networks

김범성* · 최배훈* · 안종현* · 황재호** · 김은태*

Beomseong Kim, Baehoon Choi, Jhonghyun An, Jaeho Hwang, and Euntai Kim*

*연세대학교 전기전자공학과, **현대모비스

† School of Electrical & Electronics Engineering, Yonsei University

** Advanced Research Team, Hyundai Mobis Co., Ltd.

요 약

최근 지능형 자동차의 능동적 안전 기술에 많은 관심이 집중되고 있다. 능동적 안전 기술은 시스템이 운전자에게 위험 상황을 경고 하거나 교통사고를 회피하는 방향으로 차량 제어의 일부를 도와주어 운전자의 부주의 및 과실로 발생하는 교통사고의 발생 가능성을 감소시킨다. 이러한 능동적 안전 기술을 구현하기 위해서는 주변의 환경 정보를 정확하게 인식하고 분석하는 것이 필수적인데, 주변의 차량과 자차량간의 충돌 위험도를 판단하는 것도 그중 하나이다. 하지만 충돌이 발생하기 이전에 충돌 가능성을 판단하는 것은 일반적인 방법으로는 불가능하기 때문에 몬테 카를로 모의실험을 통하여 이를 해결한다. 하지만 몬테 카를로 모의실험은 연산시간이 길기 때문에 실시간으로 동작해야하는 충돌 경고 시스템에는 적합하지 않다. 이때 신경회로망을 이용하면 이러한 문제를 해결 할 수 있으며, 본 논문에서는 자차량과 주변 차량간의 상태정보에서 충돌에 영향을 주는 충돌 특징점을 추출하여 신경회로망의 성능을 높이는 방법을 제안한다. 제안된 알고리즘은 시나리오 기반으로 Tass사의 PreScan을 이용하여 생성된 충돌 실험데이터에 적용하여 성능을 평가한다.

키워드 : 충돌 위험도 판단, 몬테 카를로 모의실험, 신경회로망, 충돌 예상 시간

Abstract

Recently, there are many researches on active safety system of intelligent vehicle. To reduce the probability of collision caused by driver's inattention and mistakes, the active safety system gives warning or controls the vehicle toward avoiding collision. For the purpose, it is necessary to recognize and analyze circumstances around. In this paper, we will treat the problem about collision risk assessment. In general, it is difficult to calculate the collision risk before it happens. To consider the uncertainty of the situation, Monte Carlo simulation can be employed. However it takes long computation time and is not suitable for practice. In this paper, we apply neural networks to solve this problem. It efficiently computes the unseen data by training the results of Monte Carlo simulation. Furthermore, we propose the features affects the performance of the assessment. The proposed algorithm is verified by applications in various crash scenarios.

Key Words : Collision Risk Assessment, Monte Carlo Simulation, Neural Networks, Time-to-Collision(TTC)

1. 서 론

미국 도로교통안전국(NHTSA, National Highway

접수일자: 2014년 4월 22일

심사(수정)일자: 2014년 4월 25일

게재확정일자 : 2014년 4월 28일

† Corresponding author

본 연구는 지식경제부 산업융합원천기술개발 사업 - 사고 예방 및 승객 상해 경감을 위한 능동 및 수동 안전 통합 시스템 개발(과제번호 : 10042676)에 의해 수행되었습니다. 연구비 지원에 감사드립니다.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Traffic Safety Administration)의 2010년 통계를 보면, 대부분의 교통사고는 운전자의 과실 및 부주의(과속, 차선 이탈, 음주, 운전자 주의산만 등)로 인하여 발생하는 것을 확인할 수 있다[1]. 또한 유럽 신차평가프로그램(EURO NCAP, European New Car Assessment Programme)에서는 긴급 자동 제동 장치가 27%까지 교통사고를 감소시킬 것으로 예측된다고 보고했다[2].

이를 기반으로 유럽에서는 2014년부터 긴급 자동 제동 장치에 대한 등급 평가를 시작할 계획이며[2], 국내에서는 국토해양부가 2015년부터 긴급 자동 제동 장치, 차로 이탈 경고장치를 의무화하는 법안을 검토하고 있다[3]. 이러한 긴급 자동 제동 장치, 차로 이탈 경고 장치는 교통사고가 발생할 가능성이 있는 위험 상황을 운전자에게 경고 하거나 교통사고를 회피하는 방향으로 차량 제어의 일부분을 도와 주어 교통사고 발생 가능성을 낮추는 운전자 보조 시스템의 대표적인 예이다.

운전자 보조 시스템을 구현하기 위해서는 주변의 환경 정보를 정확하게 인식하고 분석하는 것이 필수적이다. 자차량과 주변의 차량간의 충돌 가능성을 판단하는 것도 그중 하나이다[4]. 하지만 충돌 이전에 충돌 가능성을 판단하는 것은 일반적인 방법으로는 불가능하기 때문에 몬테 카를로 모의실험[5], 퍼지 기법[6] 등의 방법이 사용된다. 이때 사용되는 몬테 카를로 모의실험 방법은 반복적인 수행으로 긴 연산시간이 단점이기 때문에 실시간으로 동작해야하는 충돌 경고 시스템에는 적합하지 않다. 따라서 우리는 몬테 카를로 모의실험으로 구한 충돌 위험도로 신경회로망을 학습하고 이를 이용하여 실시간으로 충돌 위험도를 계산한다. 하지만 자차량과 주변 차량의 상태정보만으로는 신경회로망의 성능이 떨어지기 때문에 본 논문에서는 자차량과 주변 차량의 상태정보에서 충돌에 영향을 주는 충돌 특징점을 추출하여 신경회로망의 성능을 높이는 방법을 제안한다.

2장에서는 몬테 카를로 모의실험을 이용한 충돌 위험도 판단 방법에 대하여 설명하고, 3장에서는 신경회로망에 대하여 설명한다. 4장에서는 제안된 충돌 특징점을 설명하고 이를 이용하여 신경회로망의 성능을 향상시키는 구조에 대하여 설명한다. 5장에서는 제안된 신경회로망의 성능 비교 및 시나리오 기반 실험에 제안된 알고리즘을 적용하여 성능을 평가하고 6장에서 결론에 대하여 설명한다.

2. 몬테 카를로 모의실험

2.1 차량 운동 모델

도로상에서 이동하는 차량은 각각의 위치정보와 운동정보를 갖는다. 시간 t 에서 자차량의 x 좌표, y 좌표, 진행방향, 속도, 각속도는 $x_h(t)$, $y_h(t)$, $\theta_h(t)$, $v_h(t)$, $w_h(t)$ 로 나타내고, 시간 t 에서의 상대 차량의 x 좌표, y 좌표, 진행방향, 속도, 각속도는 $x_o(t)$, $y_o(t)$, $\theta_o(t)$, $v_o(t)$, $w_o(t)$ 로 나타낸다.

시간 Δt 이후의 자차량의 위치 및 진행방향은 식(1) ~ 식(3)을 이용하여 구할 수 있다.

$$x_h(t + \Delta t) = x_h(t) - \frac{v_h(t)}{w_h(t)} \sin(\theta_h(t)) + \frac{v_h(t)}{w_h(t)} \sin(\theta_h(t) + w_h(t) \times \Delta t) \quad (1)$$

$$y_h(t + \Delta t) = y_h(t) + \frac{v_h(t)}{w_h(t)} \cos(\theta_h(t)) - \frac{v_h(t)}{w_h(t)} \cos(\theta_h(t) + w_h(t) \times \Delta t) \quad (2)$$

$$\theta_h(t + \Delta t) = \theta_h(t) + w_h(t) \times \Delta t \quad (3)$$

Δt 시간 이후의 자차량의 속도와 각속도는 식(4), 식(5)와 같이 운전자의 속도 조작 u_v 와 각속도 조작 u_w 에 따라서 변화한다.

$$v_h(t + \Delta t) = v_h(t) + u_v(t) \times \Delta t \quad (4)$$

$$w_h(t + \Delta t) = w_h(t) + u_w(t) \times \Delta t \quad (5)$$

상대 차량의 위치정보 및 운동정보 또한 같은 식에 의하여 계산되는데, 자차량과 상대차량이 같은 위치를 동시에 점유하게 되는 경우 충돌이 발생한다.

2.2 몬테 카를로 모의실험

충돌이 발생하기 이전 시점에서 충돌이 발생할 가능성을 판단하는 것은 일반적인 방법으로는 불가능하다. 동일한 상황에서 실차 실험을 여러번 반복하는 방법은 사실상 불가능하기 때문이다. 따라서 모의실험의 반복을 통하여 확률을 계산하는 몬테 카를로 모의실험을 이용하여 충돌 가능성을 계산할 수 있다[4].

본 논문에서는 운전자의 조작에 대한 정보가 전무하기 때문에 운전자의 조작이 0의 평균과 σ 의 분산을 가지는 정규 분포를 따른다고 가정한다. 정규 분포에 따라 운전자의 조작 $u_v(t)$, $u_w(t)$ 를 식(6), 식(7)을 이용하여 설정하고 이를 위의 식(4), 식(5)의 운동정보 갱신에 사용한다. 운전자의 조작은 Δt 마다 변경되며 갱신된 운동정보는 자차량의 앞으로의 위치 및 각도에 영향을 미친다.

$$u_v(t) = N(0, \sigma_v) \quad (6)$$

$$u_w(t) = N(0, \sigma_w) \quad (7)$$

이러한 방법을 이용하면 자차량과 상대 차량의 이동 궤적을 Δt 간격으로 설정할 수 있으며, 단 한 순간이라도 두 차량이 동일 공간을 점유하고 있으면 충돌이 발생했다고 판단한다. 만약 설정한 시간 간격까지 충돌이 발생하지 않으면 충돌이 발생하지 않는 사건으로 분류한다. 이 과정을 N 번 반복하여 식(8)과 같이 충돌이 발생한 경우를 총 실험 횟수로 나누면 충돌이 발생할 가능성을 구할 수 있다.

$$\text{충돌 위험도} = \frac{\text{충돌 발생 사건수}}{\text{총 실험 수}} \quad (8)$$

이러한 방법을 이용하면 충돌이 발생하기 이전에 충돌이 발생할 가능성인 충돌 위험도를 구할 수 있다.

3. 신경회로망

몬테 카를로 모의실험을 이용하면 충돌이 발생하기 이전의 상황에서도 충돌 위험도를 계산할 수 있다. 하지만 몬테 카를로 모의실험은 모의실험을 반복적으로 수행하는 방법을 사용하기 때문에 연산 시간이 오래 걸린다. 따라서 차량에 장착되어 실시간으로 동작해야하는 상황에서는 적합하지 않다.

이런 문제를 해결하는 방법으로는 신경회로망[7], SVR(Support Vector Regression)[8], ELM(Extreme Learning Machine)[9] 등이 대표적으로 존재한다. 위 방법들은 연속된 입력과 출력 사이의 상관관계를 수학적 모델로 구하여 어떤 입력이 주어졌을 때 이에 따른 출력을 예측하는 방법이다.

본 논문에서는 신경회로망을 이용한다[10]. 신경회로망은 그림 1과 같이 입력과 출력 사이에 은닉 노드(hidden node)들을 만들어 입력과 은닉 노드, 은닉 노드와 출력 사이의 가중치를 학습하는 방법이다.




그림 1. 다층 퍼셉트론 신경회로망의 구조.

Fig. 1. Structure of Multi-layer Perceptron Neural Networks

$$z_i = f_i \left(\sum_{k=1}^K w_{x_k i} \times x_k \right) \quad (9)$$

$$y_j = f_j \left(\sum_{i=1}^D w_{z_i j} \times z_i \right) \quad (10)$$

x 는 입력 값, z 는 은닉 노드의 값, y 는 출력 값을 각각 나타낸다. K 는 입력 층의 차원 개수이고 D 는 은닉 층의 노드 개수를 나타낸다. w 는 각 층과 층 사이의 가중치를 나타내는데 $w_{x_k i}$ 는 k 번째 입력 x_k 와 i 번째 은닉 노드 사이의 가중치를 나타내고 $w_{z_i j}$ 는 i 번째 은닉 노드와 j 번째 출력 y_j 사이의 가중치를 나타낸다. 은닉 노드의 값 z_i 는 식 (9)와 같이 입력과 가중치의 곱들의 합을 전달함수를 통하여 계산하며, 출력 값은 이와 비슷하게 식 (10)을 통하여 계산된다.

신경회로망 학습은 동일한 입력에서 신경회로망의 출력 값과 학습 데이터의 결과 값의 차이를 줄이는 과정이다. 차이를 줄이기 위하여 두 값의 사이의 오차를 역전치(back propagation) 방법을 통하여 가중치를 갱신하는 방법으로 학습이 진행된다. 본 논문에서는 하강 기울기 갱신 공식 (gradient descent update equation)을 이용하여 가중치를 갱신한다.

4. 충돌 특징점

신경회로망의 성능은 신경회로망의 출력 값과 검사 데이터의 결과 값과 차이가 작을수록 좋아진다. 하지만 신경회로망의 성능은 입력 차원 수, 은닉 노드의 수, 출력 차원의 수 등 많은 변수에 따라서 크게 변화한다. 이러한 성능을 향상시키는 방법으로는 여러 개의 신경회로망을 사용하거나[11] 결과 값에 영향을 미치는 특징을 추가하는 방법[12] 시간에 따른 결과를 누적시키는 방법[13] 등이 있다. 본 논문에서는 운동 정보를 이용하여 충돌에 영향을 미치는 특징점을 추가하여 신경회로망의 성능을 높여 전체 시스템의 안전성을 높인다.




그림 2. 충돌 특징점

Fig. 2. Collision Feature

그림 2는 충돌에 영향을 미치는 특징점을 나타낸 것이다. 위에서부터 순서대로 충돌까지의 시간, 충돌 시 너비, 충돌 시 각도를 나타낸다. 세가지의 특징점은 두 차량이 현재와 동일한 운동 상태를 유지했을 경우를 가정하여 계산하기 때문에 운전자의 조작이 영향을 미치는 실제 상황과는 다른 결과가 나올 수 있다. 하지만 현재 두 차량의 상태가 얼마나 충돌 위험성이 있는지 확인하는 좋은 특징점이 된다. 본 논문에서는 자차량과 상대 차량 사이의 x 축 거리차, y 축 거리차, 각도 차이, 자차 속도, 상대차 속도, 이외 에도 위에 설명한 3개의 충돌 특징점을 추가하여 신경회로망의 입력으로 사용한다.

5. 시뮬레이션 및 결과

본 논문에서는 자차량이 전면에 장착된 센서를 통하여 상대 차량의 정보를 인식한다고 가정하였다. 센서의 인식 범위는 자차량의 전면 방향으로 30m이고 시야각은 120°이다. 먼저 입력 데이터는 자차량과 상대 차량의 상대 위치, 상대 각도, 자차량 속도, 상대 차량 속도이다. 이 정보를 바탕으로 충돌 특징점을 계산하여 두 정보를 합쳐 학습 데이터의 입력을 만든다. 그리고 자차량과 상대 차량의 상태정보를 바탕으로 몬테 카를로 모의실험을 수행하여 충돌 위험도, 즉 학습 데이터의 출력을 만든다. 이렇게 만들어진 학습 데이터를 이용하여 초기화된 신경회로망을 학습시킨다. 본 논문에서는 하강 기울기 갱신 공식을 이용한 역전치 방법을 학습에 사용하였다.

그림 3은 신경회로망을 학습하는 과정이다. 본 논문에서는 인식 범위 내에 존재하는 두 차량의 정보를 일정 간격으

로 샘플링 하여 총 6000개의 연속된 입력 데이터를 생성하고 각 샘플들의 충돌 특징점을 추출하였다. 그리고 몬테 카를로 모의실험의 수행 횟수를 500번으로 설정하여 충돌 위험도를 계산하고, 은닉 노드를 200개 갖는 신경회로망을 학습하였다.

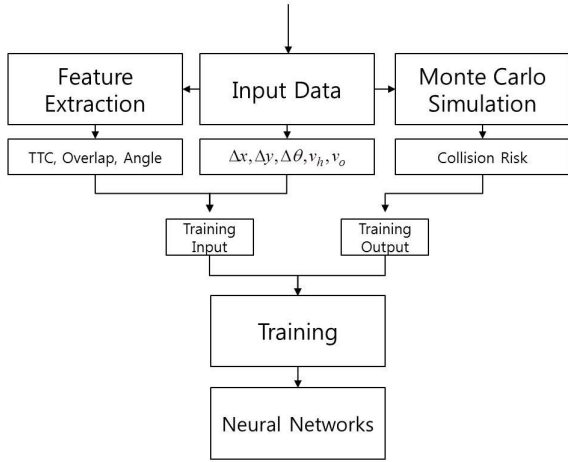


그림 3. 신경회로망 학습 과정
Fig. 3. Process of Neural Networks Training

그림 4는 신경회로망을 이용하여 충돌 위험도를 판단하는 과정이다. 입력 데이터를 이용하여 충돌 특징점을 계산하고, 입력 데이터와 충돌 특징점이 학습된 신경회로망의 입력으로 사용되어 충돌 위험도를 판단한다. 이 방법은 단순 계산의 반복이기 때문에 몬테 카를로 모의실험을 이용한 방법보다 매우 빠르게 계산이 가능하다.

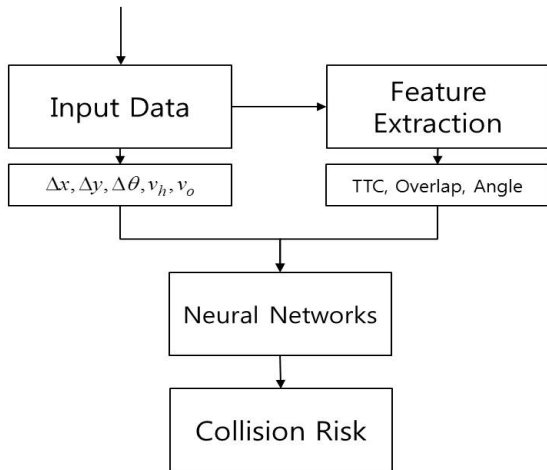


그림 4. 신경회로망을 이용한 충돌 위험도 판단
Fig. 4. Collision Risk Assessment using trained Neural Networks

표 1은 몬테 카를로 모의실험 방법과 신경회로망을 사용한 방법의 평균 연산 시간을 나타낸 표이다. 몬테 카를로 모의실험을 사용했을 때는 평균적으로 1.0928초의 연산시간이 필요하여 실시간 구현이 불가능하다. 하지만 신경망을 이용한 방법의 경우 연산시간이 0.0067초로 몬테 카를로 모

의실험에 비하여 0.6%의 연산시간으로 계산이 가능하다.

표 1. 몬테 카를로 모의실험과 신경회로망 연산시간
Table 1. Operation time of Monte Carlo Simulation and Neural Networks

Method	Error
Monte Carlo Simulation	1.0928s
Neural Networks	0.0067s

표 2은 자차량과 상대 차량의 상태 정보만을 이용한 [8]에서 제안된 방법과 본 논문에서 제안된 방법의 성능을 비교한 표이다. 본 논문에서는 이전 방법에서 사용할 차량들의 상태 정보를 차량의 x 축 거리차, y 축 거리차, 각도 차이, 자차 속도, 상대차 속도 이렇게 5개를 사용했다. 본 실험에서는 자차의 각속도와 상대차량의 각속도는 입력 데이터에 포함하지 않는다. 제안하는 방법은 이전의 5개의 입력 값에 충돌 예상 시간, 충돌 너비, 충돌 각도 이렇게 충돌 특징점 3개를 추가하여 총 8개의 입력 값을 갖는다. 여기서 오차라는 것은 몬테 카를로 모의실험에의 결과로 나온 충돌 위험도와 신경회로망을 통하여 계산된 충돌 위험도간의 차이의 절대값의 평균이다. 신경회로망에서 오차 값이 작을수록 좋은 결과이다. 따라서 표에서 볼 수 있듯이 충돌 특징점을 추가한 본 논문에서 제안된 방법이 이전 방법에서 성능 향상이 이뤄진 것을 확인할 수 있다.

표 2. 충돌 특징점 추가에 따른 성능 비교
Table 2. Results of previous and proposed method

Method	Error
Previous Method	0.2458
Proposed Method	0.2182

본 논문에서는 충돌 위험도 판단 시스템을 현대 모비스에서 제공한 시나리오에 적용하였다. 제안된 시나리오는 충돌이 발생한 환경에 따라서 후면 충돌, 교차로 충돌, 차선 이동 충돌, 전면 충돌 이렇게 네가지 유형으로 나뉘며 같은 충돌 유형에서도 자차량과 상대 차량의 속도 및 이동 거리 간격 등이 서로 다른 여러개의 시나리오가 존재한다. 후면 충돌이 21개, 교차로 충돌이 4개, 차선이동 충돌이 15개, 전면 충돌이 8개로 총 48개의 시나리오가 존재한다.



그림 5. PreScan을 이용한 차량 데이터 생성
Fig. 5. Generate vehicle data using PreScan

각각의 시나리오는 그림 5와 같이 PreScan을 이용하여 차량의 상태 정보를 생성하였다[14]. 충돌 위험도가 70%가 넘는 경우 충돌 경고가 발생하며, 충돌 경고가 충돌 발생보다 1초 이전에 알람한 경우 충돌 경고가 성공했다고 설정하였다.

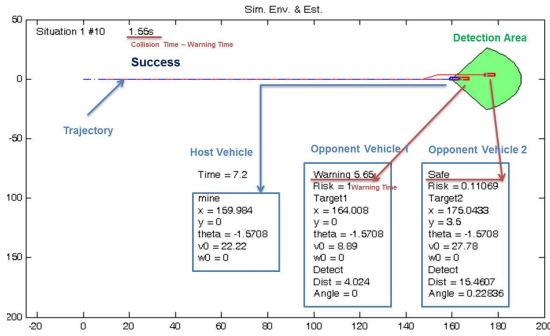


그림 6. 후면 충돌 시나리오의 실험 결과
Fig. 6. Result of rear collision scenario

그림 6는 시나리오 기반 충돌 경고 시스템의 실험화면이다. 파란색 사각형은 자차량의 위치를 나타내고 빨간색 사각형은 상대 차량의 위치를 나타낸다. 그리고 파란색과 빨간색 선은 각각 자차량과 상대 차량의 이동 궤적을 나타낸다. 녹색 부채꼴 영역은 센서의 인식 범위를 나타내고 아래쪽에는 자차량과 상대 차량들의 정보가 순차적으로 나타난다. 충돌이 발생한 직후 경고시각과 충돌 시각의 차이를 계산하여 1초가 넘는 경우 성공한 시나리오라고 판단한다.

표 3. 시나리오에 따른 충돌 경고 성공률
Table 3. Result of Collision Warning

Type	N	S	F	Ratio
Rear Collision	21	19	2	90.5%
Intersection	4	4	0	100%
Lane Change	15	12	0	80%
Front Collision	8	3	5	37.5%
Total	48	38	10	79.2%

표 3는 시나리오 유형에 따른 충돌 경고 성공률을 나타낸 것이다. N은 유형별 시나리오 개수를 나타내고 S는 성공한 시나리오 개수, F는 실패한 시나리오 개수를 나타낸다. 후면 충돌과 교차로 충돌, 차선 이동 충돌의 경우 차량의 인식부터 충돌까지 시간이 충분하기 때문에 충돌 경고가 성공적으로 이루어졌지만 반대 차선에서 다가오는 차량과의 전면 충돌의 경우 차량의 인식 후에 얼마 지나지 않아 충돌하기 때문에 충돌 경고와 충돌 시간의 차이가 적어서 충돌 경고에 실패하는 경우가 많이 발생하였다. 이를 위해서는 센서의 인식 범위를 넓게 설정하는 방법으로 해결할 수 있을 것이다. 또한 후면 충돌에서는 충돌시 너비가 매우 작아 스치는 듯이 충돌하는 상황에서는 알람이 정확히 발생하지 못하였으며, 차선 이동 충돌의 경우 1초 이내에 운전자의 조작으로 인하여 급격하게 차량의 움직임이 변하는 경우에도 1초 이전에 경고하는 것에 실패하였다.

6. 결론 및 향후 연구

본 논문에서는 충돌 위험도 판단을 통한 충돌 경고 시스템을 제안하였다. 몬테 카를로 모의실험을 통하여 충돌 위험도를 계산하고 신경회로망을 이용하여 실시간으로 충돌 위험도 계산이 가능하도록 하였다. 또한 충돌 특징점을 추가하여 신경회로망의 성능을 향상시켰다. 제안된 시스템은 모비스에서 제공한 충돌 시나리오에 적용하여 성능을 평가했다.

향후 연구에서는 신경회로망의 오차를 줄이는 연구가 필요할 것으로 보인다. 또한 센서의 인식 영역을 넓게 설정하여 충돌 경고가 가능한 시간을 앞당기면 시나리오 유형별 충돌 경고 성공률을 높일 수 있을 것이다.

References

- [1] National Highway Traffic Safety Administration (www.nhtsa.gov)
- [2] European New Car Assessment Programme (www.euroncap.com)
- [3] Ministry of Land, Infrastructure and Transport (www.molit.go.kr)
- [4] B. Kim, B. Choi, J. An, H. Lee, and E. Kim, "Prediction of Centerlane Violation for vehicle in opposite direction using Fuzzy Logic and Interacting Multiple Model," *Journal of The Korean Institute of Intelligent Systems*, vol.23, no.5, pp.444-450, 2013. (In Korean)
- [5] Giuseppe De Nicolao, Antonella Ferrara, Luisa Giacomini, "Onboard sensor-based collision risk assessment to improve pedestrians' safety," *IEEE Transactions on Vehicular Technology*, Vol. 56, No. 5, 2007.
- [6] H. Jung, S.-G. Kim, and Y.-G. Kim, "Use of Fuzzy technique for Calculating Degree of Collision Risk in Obstacle Avoidance of Unmanned Underwater Vehicles," *Journal of The Korean Institute of Intelligent Systems*, vol.21, no.1, pp.112-119, 2011. (In Korean)
- [7] Specht, Donald F., "A general regression neural networks," *IEEE Transactions on Neural Networks*, Vol. 2, No. 6, 1991.
- [8] Alex J. Smola, Bernhard Scholkopf, "A tutorial on Support vector Regression," *Statistics and computing*, 2004.
- [9] G.B. Huang, and Q.Y. Zhu, "Extreme learning machine: a new learning scheme of feedforward neural networks," *In Proc. IEEE International Joint Conference on Neural Networks*, vol. 2, pp. 985-990, 2004.
- [10] B. Kim, S. Park, B. Choi, E. Kim, H. Lee, H. Kang, "Collision risk assessment for pedestrians' safety using neural network," *Journal of Institute of Control, robotics and Systems*, vol. 17, no. 1, pp. 6-11, 2011. (In Korean)
- [11] B. Kim, S. Park, B. Choi and E. Kim, "Intelligent collision risk assessment based on neural network ensemble"

ble," *In Proc. of The Society of Instrument and Control Engineers Annual Conference (SICE2010)*, pp. 2893-2895, Taipei, Taiwan, August 2010

[12] B. Kim, B. Choi, E. Kim, C. Ko, J. Hwang, "Collision risk assessment algorithm using front-view vehicle information," *In Proc. of Korean Society of Automotive Engineers*, pp. 925-927, 2013. (In Korean)

[13] S. Park, B. Kim, E. Kim, H. Lee, and H. J. Kang, "Recursive probabilistic approach to collision risk assessment for pedestrians' safety," *Journal of The Korean Institute of Intelligent Systems*, vol.21, no.4, pp.475-480, 2011. (In Korean)

[14] PreScan, Tassinternational (www.tassinternational.com/prescan)

관심분야 : State Estimation, Intelligent vehicle system.
E-mail : choibae@yonsei.ac.kr



안종현(Jhonghyen An)

2013년 : 연세대학교 전기전자공학부 졸업 (공학사)
2013년~현재 : 동 대학원 전기전자공학과 석박사통합과정

관심분야 : State Estimation, Intelligent vehicle system.
E-mail : jhonghyen@yonsei.ac.kr

저 자 소개



김범성(Beomseong Kim)

2009년 : 연세대학교 전기전자공학부 졸업 (공학사)
2009년~현재 : 동 대학원 전기전자공학과 석박사통합과정

관심분야: Computational Intelligence, Intelligent vehicle system
E-mail : battlebs@yonsei.ac.kr



최배훈(Baehoon Choi)

2010년 : 연세대학교 전기전자공학부 졸업 (공학사)
2010년~현재 : 동 대학원 전기전자공학과 석박사통합과정

황재호(Jaeho Hwang)

현재 : 현대모비스 주식회사 선행연구팀 책임연구원



김은태(Euntai Kim)

1992년 : 연세대학교 전자공학과 졸업 (공학사)
1994년 : 연세대학교 전자공학과 석사과정 졸업(공학석사)
1999년 : 연세대학교 전자공학과 박사과정 졸업(공학박사)

1999년 3월~2002년 2월 : 국립한경대학교 제어계측공학과 조교수

2002년 3월~현재 : 연세대학교 전기전자공학부 교수

2003년 : University of Alberta, visiting researcher

1998년~현재 : IEEE TFS, IEEE T SMC, IEEE T CAS, FSS 등에서 심의위원 활동 중

2003년 : 대한 전자공학회 해동상 수상

관심분야 : Computational Intelligence, 지능형 로봇
Phone : +82-2-2123-7729
E-mail : etkim@yonsei.ac.kr