

Vision 시스템을 이용한 차량 위험운전 인식

I. 서론

현재 교통안전향상을 위해 첨단 차량 전자제어 시스템의 발달과 더불어 다양한 운전자 지원 시스템이 실용화 되고 있다. 운전자 지원 시스템이란 운전자 상태, 차량 상태, 주변 환경을 인식하여, 운전자의 부담을 줄여주고 운전의 편의를 증대시키기 위하여 다양한 정보를 제공하거나 시스템 스스로 적절한 시기에 능동적으로 제어에 참여하는 시스템을 말한다. 이러한 시스템은 지능형 자동차개발의 한 분야로서 차량에 적용 가능한 하드웨어의 가격하락과 센서 및 프로세서의 고성능화에 따라 레이더, 카메라, 레이저와 같은 다양한 센서를 적용한 사례가 늘고 있다. 이렇듯 빠르게 발전하는 운전자 지원 시스템에 부응하기 위하여 본 연구의 카메라를 이용한 차량인식 Vision 시스템을 개발하였다. Vision 시스템은 차량의 전방 및 후방, 측방을 감시할 수 있으며, 차량의 주행 영상을 취득하게 된다. 취득된 영상은 이미지 알고리즘을 통하여 차선과 차량으로 구분되며, 후 처리를 통해 차선의 위치, 차량의 위치 및 거리 등을 계산할 수 있다. 이렇게 계산된 차선 및 선행 차량의 위치를 통하여 운전자의 위험운전에 대한 원인을 정확히 분석할 수 있다. 또한, 본 연구에서는 밝기 대응 알고리즘을 개발하여 Vision 시스템에 적용함으로써 터널, 일조, 일몰시에 대한 차선 및 차량 인식율을 향상시켰고, 차량의 위험운전을 실시간 판단하여 운전자의 안전운전관리에 기여하고자 하였다.




오 주 택
한국교통대학교
도시공학과

II. 선행연구

지능형 자동차는 현재 자동항법제어, 차선이탈경고, 차선 유지 보

조, 사전 충돌 예방 등의 시스템 개발이 이루어지고 있다. 이런 시스템을 구성하기 위해서는 주행 차량 관점에서 차선의 위치 및 곡률, 대향차/선행차 구분, 도로의 경사도 등을 인식 할 수 있어야 하며, 이러한 기능을 구현하기 위하여 가장 중요한 역할을 하는 것이 바로 사람의 눈 역할을 하는 카메라 센서이다. 현재 주변 상황(선행차량, 차선 등)을 인식하기 위한 센서로는 초음파, Vision 센서, 레이저 센서, 그리고 레이더 센서를 사용하는 기술이 있으며, 이와 같은 기술을 토대로 PCS(Pre-Crash Safety system), LKA(Lane Keeping Assistance System), ACC (Adaptive Cruise Control system)등에 적용하고 있다. 카메라 센서는 다른 센서에 비해 저렴한 가격과 활용범위가 넓기 때문에 폭넓게 사용되고 있지만 다른 센서와 달리 날씨 및 시간 등 주위 환경 변화에 대해 민감하게 영향을 받기 때문에 이러한 문제점을 해결하기 위하여 많은 연구가 진행되고 있다.

유럽에서는 운전자의 운전행태와 차량의 거동 및 주변 환경을 실시간으로 분석하여 운전자에게 다양한 정보를 제공해 주는 첨단 운전자지원시스템의 연구가 진행되고 있으며, 특히 차선과 차량, 교통신호와 같은 주변 환경을 인식하기 위하여 Vision 센서, 초음파 센서, 레이더 센서, 레이저 센서 등과 같은 다수의 다양한 센서를 차량에 접목시키고 있다. 일본의 Denso社は ADAS(Advanced Driver Assistance System)을 구현하기 위하여 <그림 1>과 같은 Sensing System을 제안하고 있다. ADAS 시스템 중 ACC(advanced cruise control), SCC(smart cruise system)는 라이다 센서를 이용하여 전방의 차량을 검출하는데 이용되고 있으



<그림 1> Denso 센싱 시스템 구성도

나, 센서가 매우 고가이므로 현재 고급차량에만 적용되고 있는 실정이다. 따라서 본 연구의 CCD 카메라를 통한 선행 차량을 검출할 수 있는 기술을 이용한다면 모든 차종에서 첨단 시스템을 적용할 수 있을 것으로 판단된다.

Ⅲ. Vision 시스템

본 연구에서 개발된 Vision시스템의 메인 알고리즘인 차선 및 선행차량 인식 알고리즘은 크게 차량 및 차선의 정보를 취득할 수 있는 차선 및 차량인식 모듈(Processed image)과 선행차량 인식을 통한 차량 추적 모듈(Detected vehicle information)로 구성되어 있으며, 위험운전 판단 알고리즘은 실험차량의 데이터를 취득할 수 있는 데이터 취득 모듈(Vehicle dynamic data)과 운전자의 위험운전을 판단할 수 있는 위험운전 판단 모듈(Dangerous driving case)로 구성되어 있다.

1. 데이터 취득 모듈

실험차량은 기아자동차의 그랜드 카니발 2007년형으로 차량 내부 통신 네트워크와 CAN (Controller Area Network) 인터페이스 장치를 이용하여 차량 주행 데이터를 취득할 수 있도록 구성 하였다. 병진 가속도와 회전 각속도, 차량 내부 통신 네트워크를 이용하여 취득할 수 없는 운전자 조작관련 데이터는 AD(Analog to digital conversion), DA(Digital to analog conversion), DIO(Digital input and output) 및 PWM(Pulse width modulation) 기능을 갖는 다기능 USB 제어 장치를 이용하여 DAQ 시스템을 구성하였으며, Gyro 센서로는 Crossbow社(미국)의 6축 Gyro 센서로 온도 변화에 따른 보정 기능을 갖춘 IMU440CA-200을 사용하였다. USB 인터페이스를 지원하는 GPS 19" Rack 시스템은 두 대의 산업용 컴퓨터가 설치되어 있으며 다기능 USB 제어기 등 데이터 취득용 차량 내부 모든 배선이 완성되며, 탈부착이 용이하도록 하였으며, 주행 중 노면으로부터의 진동을 흡수 할 수 있도록 제작하였다. 엔진룸의 배터리와 보

조 배터리를 병렬로 처리하여 1kw급 정현파 인버터에 연결하여 컴퓨터 및 각종 센서에 전원을 안정적으로 공급할 수 있는 전원 공급 장치와 seeingmachines社(호주)의 faceLAB 4.5(운전자 머리 및 눈동자 측정을 위한 운전자 인지 검출 시스템)를 설치하였다.

2. 차선 및 차량인식 모듈

Vision 시스템의 차선 및 차량인식 모듈은 CCD 카메라로부터 취득된 영상을 이용하여 차선 및 주변 차량에 대한 영상을 인식하기 위하여 LabVIEW를 사용하였으며, LabVIEW vision builder AI 3.0을 사용하여 실제 영상의 이미지 처리 알고리즘을 구현하였다.

3. 위험운전 판단 모듈

메인 프로그램에서 위험운전을 실시간으로 구분하기 위하여 선행연구에서 분류하고 있는 위험운전 유형을 적용하였다. 또한, 「위험운전 유형 분류 및 데이터 로거개발, 한국ITS학회지 제7권, 제3호, 2008, 6」 논문에서 분류한 위험운전 유형에 대하여 시뮬레이션 및 실차 실험을 통하여 임계값을 설정하였다.

4. 차량 추적 모듈

차량추적 알고리즘은 근거리에 위치한 3대의 차량까

〈표 1〉 위험운전 유형 및 임계값

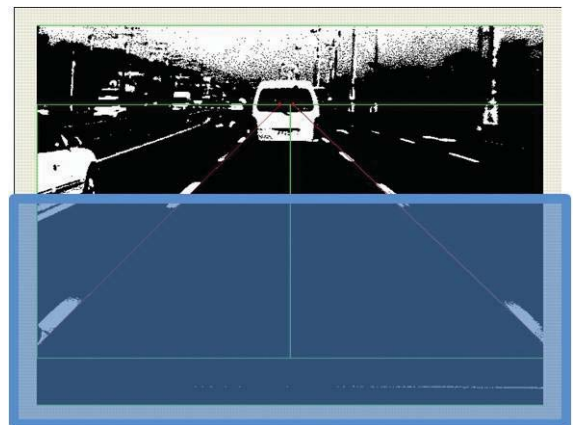
위험운전 유형		임계값 (Ki)	
		시뮬레이션 임계값	실차 실험 임계값
선회구간 과속	ay	0.2 G	0.22 G
	yaw rate	8.6 deg/sec	9.48 deg/sec
급출발	ax	0.2 G	0.14 G
급가속	ax	0.1 G	0.06 G
급정지	ax	-0.4 G	-0.32 G
급감속	ax	-0.4 G	-0.34 G
급차선변경	주기	4초	5.8초
	ay	0.2 G	0.21 G
	yaw rate	5.0 deg/sec	5.34 deg/sec
연속적인 급차선변경	주기	10.0초	8.25초
	ay	0.2 G	0.31 G
	yaw rate	5.0 deg/sec	7.4 deg/sec

지 추적이 가능하며, 인식된 차량은 고유의 아이디인 식별자를 부여하여 각각의 아이디를 통해 다수의 차량에 대한 주행 정보를 분석할 수 있다. 차량의 추적은 2개의 프레임간 위치 정보를 분석하여 차량을 추적할 수 있다.

IV. 차선 및 차량인식에 따른 밝기변화 대응 알고리즘 개발 및 실차 실험

1. 밝기변화 대응 알고리즘 개발

선행연구에서 개발된 Vision 시스템은 노면과 차선, 차량의 구분에 있어 도로환경 변화(날씨, 시간, 기후 등)를 고려하지 않고 단순 노면의 밝기 정도로 구분하여 인식률이 떨어지는 것으로 분석되었다. 이에 본 연구는 햇빛의 반사량, 건물 그림자 및 터널 등에서 노면의 밝기가 변화되는 것에서 착안하여 ROI(Region of interest)의 노면 밝기에 따른 기준을 실제 도로 주행 실험을 바탕으로 설정하여 차량인식률을 향상시키고자 실차 실험을 기반으로 한 밝기 변화 대응 알고리즘을 개발하였다. 밝기 변화 알고리즘은 노면의 밝기를 적용하기 위하여 〈그림 2〉와 같이 차선 및 차량 인식에 영향을 미치는 부분을 ROI로 설정하고 실제 도로 노면의 밝기 변화 프로파일 데이터를 획득하였다. 여기서 ROI란 카메라의 영상 중 차량을 인식하거나 차선인식을 위한 설정한 영상 범위를 말한다.



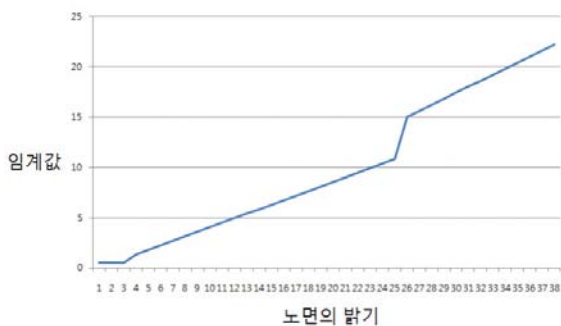
〈그림 2〉 ROI 설정

〈그림 3〉는 상암동 도로변을 주행하면서 측정한 밝기 데이터로서 〈그림 3〉의 ㉠는 노면 밝기가 일반적인 경우로 주변 환경은 단순하나 구름의 유무 및 햇빛의 방향에 따라 노면의 밝기가 변화하여 차량의 그림자에 영향을 주는 상황이며, ㉡는 도로 주변의 큰 건물에 의하여 그림자가 노면에 크게 드리워져 도로 전체의 이미지가 어둡게 나타날 수 있는 일출, 일몰시의 상황을 말한다. 마지막으로 ㉢는 터널 내를 주행하여 광량이 극히 적어지는 상황으로 구분 할 수 있다. 따라서 동일 시간에 주행하더라도 구름의 유무, 햇빛의 방향, 터널 내 주행, 도로주변의 높은 빌딩, 노면의 상태 등이 노면의 밝기에 많은 영향을 주는 것으로 분석되었다. 이에 본 연구에서는 노면의 밝기에 가장 큰 영향을 주는 요소를 바탕으로 주행 환경의 일반적인 경우, 주변의 큰 건물의 그림자가 드리워질 경우, 터널 내의 3가지 경우로 구성하였다.

〈그림 4〉은 〈그림 3〉에서 설정한 ROI의 영역인 노면의 밝기를 취득하여 노면과 차량으로 분류하기 위한 임계값이다. 노면의 밝기 24에서의 임계값은 10이므로



〈그림 3〉 ROI 데이터



〈그림 4〉 노면 임계값

10이하인 경우는 노면으로 인식하고, 10초과인 경우를 차량으로 인식할 수 있는 것이다. 결론적으로 차량 인식을 위한 차량의 그림자 그레이 레벨과 도로의 그레이 레벨 사이의 경계처리를 위한 임계값을 나타내고 있다.

실제 도로상의 좌표 R0, R1, R2는 카메라 좌표계에서 center point, P1, P2로 각각 픽셀단위로 표현된다. 이때 R0은 카메라 중심축이 지면과 만나는 점의 좌표이며 R1과 R2는 도로위에 위치한 임의의 오브젝트 좌표이다. 월드좌표계의 Rn(x1, y1)은 다음과 같은 간단한 역원근변환식으로 나타낼 수 있다.


$$Rn_yn = H \times \tan \left(\alpha - \tan^{-1} \left(\frac{Pn_yn \times k_p}{F} \right) \right)$$

$$Rn_xn = \frac{\sqrt{H^2 + (Rn_yn \times k_p)^2} \times (Pn_xn \times k_p)}{\sqrt{F^2 + (Pn_yn)^2}}$$

이때 H는 도로면에서 카메라 렌즈의 중심까지의 거리(mm)이며 alpha는 도로와 카메라 사이의 기울기(degree), F는 카메라 초점거리(mm)를 나타낸다. 본 실험에 사용된 CCD 센서의 Cell 크기는 7.4μm×7.4μm로서 좌표변환에 사용된 상수 kp는 0.0074mm/pixel이다.

2. 밝기 변화에 따른 Vision 시스템 실차 실험

본 연구에서는 밝기 대응 알고리즘을 평가하기 위하여 Vision 시스템에 적용하여 일출, 일몰, 터널, 평상시로 구분하여 차로(4차선)에 따라 3차례를 반복 주행하여 밝기변화 대응 알고리즘 적용 전·후의 데이터를 취득하였다. 〈그림 5〉는 밝기변화 대응 알고리즘을 적용하여 차량검출 테스트를 실시한 모습을 보이고 있으며, 차량속도 90km/h에서 위험상황 발생시 운전자에게 경고음을 제공하기 위한 최소 거리인 25m를 기준을 실험을 진행하였다. 실험은 총 120회(적용 전 60회, 적용 후 60회)를 실시하였으며, 각 실험 25m이상의 거리에서 차량을 검출할 경우 만점인 1.0점을 부여하였으며, 25m이하의 거리에서 검출될 경우 0.5점, 전혀 검출되지 않을 경우 0점을 부여하여 알고리즘 적용 전과 적용 후에 따른 향상도를 평가하였다.



〈그림 5〉 밝기 대응 알고리즘 적용 후 차량인식화면


실험 결과 일조와 일몰시 알고리즘 적용 전 4.5점, 4점으로 분석되었으며, 밝기 대응 알고리즘 적용 후 일조, 일몰 모두 12점으로 분석되었다. 터널의 경우 1차 실험에서 적용 전 3.5점에서 적용 후 10점으로 향상되었으며, 2차 실험에서 적용 전 2.5에서 적용 후 12점으로 향상되었다. 마지막으로 평상시와 같이 맑은 날의 경우 알고리즘 적용 전 9.5점에서 적용 후 12점으로 분석되었다. 따라서 노면의 밝기 또는 그림자 등이 차량 인식률에 큰 영향을 미치는 것으로 분석되었으며, 전체 실험 결과 밝기 대응 알고리즘 적용 전 평균 점수는 0.4점(24.5/60), 알고리즘 적용 후 평균점수는 0.97점(58.6/60)으로 본 연구에서 개발된 밝기대응 알고리즘 적용에 따른 차량 인식률이 241.67% 향상 되는 것으로 분석되었다.

3. 위험운전판단을 위한 Vision 시스템 실차 실험

급정지 실험 및 급차선 변경실험은 선행 차량의 이상 행동으로 인하여 실험 차량이 급정지 또는 급차선 변경을 시행 하는 경우, 위험운전판단 알고리즘은 차량의 종 방향 가속도, 횡방향 가속도, Yaw-rate를 계산하여 그 때의 운전상황을 위험운전으로 분류하게 되지만 실험차량의 위험운전을 발생시킨 원인에 대한 정보까지는 위험운전 판단 알고리즘에서는 제공할 수 없다. 이에 본 연구에서 개발된 위험운전 판단알고리즘과 차선 및 차량 인식 프로그램의 통합 프로그램을 이용하여 위험 운전에 대한 원인을 분석하였다.

〈그림 6〉은 급정지 실험의 시나리오이며, 시나리오 발생순서는 다음과 같다.


- ① 실험차량은 주행 차선을 따라 정상적인 운전 시행



〈그림 6〉 급정지 시나리오

- ② 선행 차량의 급정지 시행

③ 실험차량은 선행차량의 급정지로 인한 급정지 시행
실험 결과 〈그림 7〉과 같은 결과가 도출되었다. 〈그림 7〉의 첫 번째 그래프는 실험 차량의 종 방향 속도이며, 두 번째 그래프는 Vision 시스템에서 인식한 선행차량과 실험 차량의 상대거리, 세 번째 그래프는 실험차량의 종 방향 가속도, 네 번째 그래프는 실험차량



〈그림 7〉 급정지 실험 결과


의 위험운전 상황을 판단한 결과이다.

두 번째 그래프에서 나타나듯이 선행차량이 시간 t_1 을 기점으로 속도를 줄이면 실험차량과의 거리가 급격히 줄게 되는 것을 알 수 있으며, 이에 대한 대응방안으로 실험차량은 시간 t_2 를 기점으로 차량 속도를 급격히 감속시킨 것을 첫 번째 그래프를 통해 알 수 있다. 이때 세 번째 그래프를 보면 실험 차량의 종 방향 가속도는 약 $-0.7g$ 로서 위험운전으로 분류되는 것을 네 번째 그래프를 통해 알 수 있다. 그러나 실험차량 운전자가 실시한 급격한 정지 상황은 두 번째 그래프에서 나타나듯이 운전자의 부주의 또는 운전 미숙으로 인한 위험운전 상황이 아닌 선행 차량의 급감속에 따른 정당한 대처임을 Vision 시스템을 통하여 알 수 있어 운전자의 위험운전 상황에 대한 원인을 명확히 파악할 수 있다.

〈그림 8〉는 본 연구의 급차선 변경 실험을 위한 시나리오를 보이며, 시나리오의 발생순서는 다음과 같다.

- ① 실험차량은 주행 차선을 따라 정상적인 운전 시행
- ② 실험차량의 선행차량이 가속을 시행
- ③ 실험차량의 우측 차선의 선행차량이 실험차량 진행 차선으로 차선변경 시행
- ④ 실험차량은 우측에서 차선변경을 시행한 선행 차량을 피하기 위하여 우측차선으로 차선변경 실시

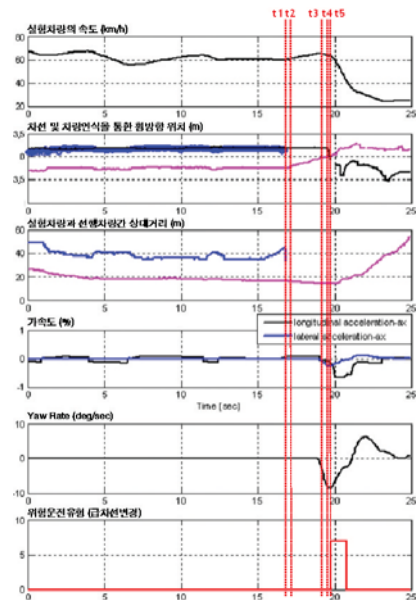
급차선 변경 실험 결과 또한 급정지 실험과 같이 〈그림 9〉와 같은 결과 그래프가 도출되었다. 실험 결과의 첫 번째 그래프는 실험 차량의 종 방향 속도이며, 두 번째 그래프는 동일 차선의 선행 차량과 우측 차선의 선행 차량을 Vision 시스템에서 인식하여 실험차량의 주행 차선에서 선행 차량과 우측차선의 차량의 횡 방향 위치를 계산한 결과이다. 세 번째 그래프는 동일 차선의 선행 차량과 실험 차량 사이의 상대거리와 우측 차



〈그림 8〉 급차선 변경 시나리오

선 차량과 실험 차량 사이의 상대거리를 Vision 시스템을 통해 계산된 결과이다. 네 번째와 다섯 번째 그래프는 각각 실험 차량의 가속도와 Yaw-rate를 보이며, 여섯 번째 그래프는 실험 차량의 위험운전 여부를 판단한 결과이다.

첫 번째 그래프에서 나타나듯이 실험 차량은 lane 1 에서 약 60km/h로 주행하고 있으며, 동일 차선 약 40m 전방에 주행 중인 선행 차량과 우측 차선인 lane2의 약 18m 전방에서 주행 중인 또 하나의 차량이 검출되는 것을 두 번째 그래프를 통해 알 수 있다. 두 번째 그래프에서 나타나듯이 시간 t_1 을 기점으로 실험 차량과 동일한 차선에서 주행 중인 선행 차량이 가속하여 차량인식 범위를 벗어나자, t_2 를 기점으로 실험 차량이 가속을 시작하는 것을 첫 번째 그래프를 통해 알 수 있으며, 실험차량이 가속을 시작함과 동시에 lane 2에서 주행 중인 차량이 t_3 을 기점으로 실험 차량의 주행차선으로 차선을 변경하기 시작하는 것을 세 번째 그래프를 통해 확인 할 수 있다. 이때 실험 차량은 차선변경을 시행한 선행차량을 피하기 위하여 핸들을 크게 조작하여 lane 1에서 lane 2로 차선 변경을 실시한 것을 두 번째 그래프를 통해 알 수 있으며, 이



〈그림 9〉 급차선 변경 실험 결과

때 실험 차량의 Yaw-rate과 ay는 약 -9deg/sec와 약 0.5G로 분석되어 위험운전으로 분류되는 것을 세 번째, 네 번째, 다섯 번째 그래프를 통해 알 수 있다. 그러나 급정지 실험과 마찬가지로 실험차량이 실시한 급차선 변경은 근거리에서 옆 차선을 주행 중이던 차량의 차선 변경으로 인해 발생한 위험 상황을 피하기 위한 실험 차량 운전자의 적절한 대처임을 Vision 시스템을 통하여 분석되었다.

V. 결론

교통안전을 향상시키는 효과적인 방법 중 하나는 차량의 이상행위를 실시간으로 판단하는 시스템의 개발일 것이다. 본 연구에서는 Vision 시스템을 기반으로 차량의 움직임을 실시간 모니터링할 수 있는 알고리즘을 개발하고자 하였다. 본 연구에서 개발된 Vision 시스템은 차로 및 주변 차량과의 거리를 인식하여 운전자의 위험운전상황을 실시간으로 분석할 수 있으며, 특히 위험운전이 발생된 원인을 운전자차량의 거동분석과 주변차량의 거동분석을 통하여 위험상황이 포함된 다양한 주행상황에서의 위험운전 판단의 정확도를 향상시킬 수 있다. 그러나 본 연구에서는 선행차량의 기준 거리를 25m로 설정하여 실험을 진행하였으며, 또한 환경적인 요인 즉, 비, 눈, 안개 등의 기후변화에 따른 차량인식에 대한 연구가 제외되어있으므로 향후 연구에서는 선행차량의 거리에 따른 정확성과 구체적인 기후조건이 반영된 추가적인 연구를 진행하여 보다 향상된 알고리즘을 개발하여야 할 것이다.

참고 문헌

[1] 오주택, 이상용, "Vision 시스템을 이용한 위험운전 원인 분석 프로그램 개발에 관한 연구," 한국 ITS학회 논문지, 제8권, 제6호, pp.150-162, 2009. 12.
 [2] 김홍룡, 카메라 기반 야간 차선 인식을 개선 위한 최적 알고리즘 연구, 계명대학교 지능형 자동차 대학원, 2009
 [3] <http://www.globaldanso.com>

[4] M. Betke, E. Haritaoglu, and L. S. Davis, "Real-time multiple vehicle detection and tracking from a moving vehicle," Machine Vision and Applications, vol. 12, no. 2, pp. 69-83, Sept. 2000.
 [5] L. Fletcher, L. Petersson, and A. Zelinsky, "Driver assistance systems based on vision in and out of vehicles," Proc. IEEE Intelligent Vehicles Symp., pp. 323-327, June. 2003.
 [6] S. Tokoro, K. Moriizumi, T. Kawasaki, T. Nagao, K. Abe, and K. Fujita, "Sensor fusion system pre-crash safety system," Proc. IEEE Intelligent Vehicles Symp., pp. 14-17, June 2004.
 [7] S. Nedeveschi, R. Danescu, and T. Marita, "A sensor for urban driving assistance systems based on dense stereovision," Proc. IEEE Intelligent Vehicles Symp., pp. 276-283, June. 2007.
 [8] 오주택, 조준희, 이상용, 김영삼, "위험운전유형 분류 및 데이터로거 개발," 한국ITS학회 논문지, 제7권, 제3호, pp. 15~28, 2008. 6.
 [9] 오주택, 이상용, 김영삼, "위험운전 유형에 따른 임계값 개발," 한국도로학회지, 제11권, 제1호, pp.69-83, 2009. 3.



오 주 택

2002년 12월 Georgia Institute of Technology, 교통공학, 박사
 1998년 5월 Rutgers, The State University of New Jersey, 도시 및 지역계획, 석사
 1995년 2월 한양대학교 도시공학, 학사
 2011년 9월~현재 한국교통대학교 도시공학과 교수
 2003년 5월~2011년 8월 한국교통연구원 연구위원
 2002년 6월~2003년 5월 University of Arizona, Research Associate

<관심분야>
 교통공학