

자율주행차를 위한 장애물 탐지 및 인식 시스템

한주찬, 구본철, 최경주*
 충북대학교 소프트웨어학과

Obstacle Detection and Recognition System for Autonomous Driving Vehicle

Ju-Chan Han, Bon-Cheol Koo, Kyung-Joo Cheoi*
 Department of Computer Science, Chungbuk National University

요약 최근 물체를 인식하기 위해 많은 데이터를 기반으로 학습하여 인식하는 연구가 활성화 되고 있다. 본 논문에서는 도로주행 영상에서 장애물이라고 생각되는 객체를 추출하여 자동차, 사람, 오토바이로 구분하여 인식하는 시스템을 제안한다. 이동한 방향과 크기를 고려한 상태에서 광류 추정 알고리즘을 이용하여 객체를 추출하였으며, 추출한 객체를 CNN(Convolutional Neural Network) 인식 모델 중 하나인 AlexNet을 이용하여 인식하였다. 실험을 위해 도로 위의 다양한 영상을 블랙박스로 수집하여 실험하였고, 실험 결과 객체 추출 정확도는 92%, 객체 인식 정확도는 96%의 결과를 보였다.

키워드 : 도로주행, 광류 추정 알고리즘, 합성곱신경망, 알렉스넷, 블랙박스

Abstract In recent years, research has been actively carried out to recognize and recognize objects based on a large amount of data. In this paper, we propose a system that extracts objects that are thought to be obstacles in road driving images and recognizes them by car, man, and motorcycle.

The objects were extracted using Optical Flow in consideration of the direction and size of the moving objects. The extracted objects were recognized using Alexnet, one of CNN (Convolutional Neural Network) recognition models. For the experiment, various images on the road were collected and experimented with black box. The result of the experiment showed that the object extraction accuracy was 92% and the object recognition accuracy was 96%.

Key Words : Driving on the road, Optical Flow, CNN, AlexNet, Black Box

1. 서론

최근 미국, 유럽, 일본 등을 중심으로 2020년까지 차량 자동화 레벨 3에 해당하는 제한적 자율주행 차량의 양산 계획이 발표하고 있다. 레벨 3에 해당하는 제한적 자율주행 차량은 자동차 전용도로와 같이 인식 대상이 제한되어 있는 환경에서 자율주행을 통해 운전자에게 편의를 제공해준다. 미래의 자동차산업을 주도할 자율주행 차량

은 교통체증의 해소, 교통사고 절감, 산업융합의 촉진과 같은 효과가 클 것으로 기대하여 글로벌 자동차 시장에서 주목을 받고 있다. 국토교통부에서도 이를 위해 2020년까지 레벨 3에 해당하는 자율주행차가 고속도로를 달릴 수 있도록 자율주행 관련 기술개발과 스마트도로 인프라 확충에 나선다. 이미 2016년 2월부터 국토교통부에서는 자율주행차가 실제 도로를 달릴 수 있도록 임시운행 허가 제도를 도입하였다. 이렇게 자율주행의 개발을

위해 각 국가에서는 법적인 제도를 도입하여, 적극적인 제도 개선을 하고 있다. 또한, 이러한 제도와 함께 자율주행을 위한 연구도 활성화되고 있다.

법적인 연구로는 자율주행 자동차에 대한 법적 대응 방안에 대한 연구와 기술관련 연구로는 무인자율주행차량을 위한 분산제어시스템 설계 및 자율주행알고리즘에 대한 연구가 진행되었다[1,2].

기술관련 연구로 자율주행차량의 효과적 장애물 분류를 위한 카메라와 LRF 센서를 활용한 선행차량 검출 기법이 진행되었으며, 자율주행에 적용될 수 있는 인식 기술로 코너(Corner) 점을 이용하여 물체를 인식하는 연구[3,4], 객체 기반 영상 검색을 위한 중심 객체의 자동추출 관련 연구[5], 중요 특징점을 추출하고 영상 분할을 이용한 객체 추출 관련 연구 등 다양한 연구가 진행되고 있다[6]. 물체인식에 관해서는 2012년도 ILSVRC(Image Net Large Scale Visual Recognition Challenge)에서 높은 정확도로 우승한 Alexnet가 발표된 이후로 CNN에 대한 관심이 늘었다[7]. 현재는 Aelx Net뿐만 아니라 Google Net 등등 다양한 CNN모델이 등장했다.

또한, 객체분류 뿐만 아니라 객체 추출에 있어서도 다양한 연구가 진행되고 있다. 현재는 R-CNN (Region convolution neural network), faster R-CNN등등 다양한 객체 추출 및 분류하는 CNN모델이 있다. 하지만 R-CNN같은 경우 객체를 추출하고 분류하기 까지 1~2초 정도의 시간이 소요가 된다. 이러한 시간은 자율주행 자동차의 카메라 인식에 있어서 너무나 긴 시간이다. 따라서 자율주행에 R-CNN은 적합하지 않다. 관련 연구로 Faster R-CNN 기법을 이용한 옥외 영상 차량 번호판 검출 시스템[8], 차량용 영상인식을 위한 프로그래머블(Programmable) CNN 연산기 설계[9], Faster R-CNN을 이용한 갓길 차로 위반 차량 검출[10], 영역 기반 Deep CNN을 사용한 농지에서의 잡초 식별 등 다양한 연구가 진행되고 있다[11].

이러한 논문을 바탕으로 본 논문에서는 영상을 실시간으로 입력받으면서 프레임의 격차 간 특징 점의 위치를 비교하여 특징점이 이동한 방향과 크기를 고려하여 객체를 추출하고, 추출된 객체를 CNN(Convolution neural network)학습모델인 AlexNet을 이용하여 자동차, 사람, 오토바이, 그 외의 경우로 분류하는 시스템을 제안하고자 한다. 제안하는 시스템은 영상에서 10프레임 간격으로 입력을 받으며, OpenCV, Tensorflow 라이브러리

를 사용하여 구현하였다.

2. 제안하는 장애물 탐지 및 인식 시스템

2.1 광류 추정 알고리즘을 이용한 객체 탐지

자율주행 차량 앞에 있는 장애물(객체)을 인식하려면 먼저 인식하고자 하는 객체를 추출해야 한다. 제안하는 시스템에서는 영상을 입력받으면서 프레임 간 특징점이 이동한 방향과 크기를 고려한 상태에서 광류 추정 알고리즘을 이용하여 객체를 추출하였다.

광류(Optical Flow)는 Fig. 1과 같이 인접한 두 영상의 명암 변화를 분석하여 움직임 정보를 추정한다. t 라는 순간의 프레임 영상(Fig. 1의 왼쪽 영상) $t+1$ 이라는 짧은 시간이 흐른 후의 인접영상(Fig. 1의 오른쪽 영상)이 주어졌을 때 광류 추정 알고리즘이 추정해야 할 것은 Fig. 1의 오른쪽 영상에서 화살표로 보이는 모션벡터(Motion vector)이다.




Fig. 1. Motion vector

본 시스템에서는 광류 추정 알고리즘으로 Shi-Tomasi 알고리즘을 사용한다[12]. Shi-Tomasi 알고리즘은 특징점 윈도우에서 발생하는 이동을 포함한 회전 및 크기 변환과 탐색 영역 설정에 따른 문제점들을 보완하기 위해서, 아핀 변환을 고려한 유사도 비교에 기반하여 반복적 최소화 기법을 이용한 대응 위치 탐색방안이다.

특징점이 움직인 방향은 상, 하, 좌, 우로 4 방향으로 설정하여 같은 방향일 때 객체를 추출하도록 하였다. Fig. 2는 보행자가 횡단보도를 왼쪽에서 오른쪽으로 건너고 있는 장면이다. 이 장면에서는 특징점이 오른쪽으로 이동한 방향이 같고, 크기가 같기 때문에 하나의 객체로 추출한다. 또한, 벡터 크기의 경우는 픽셀 값을 기준으로 100, 200, 300의 크기 변화에 따라 객체를 다르게 추출하도록 설정하였다. 이렇게 추출된 이미지는 AlexNet을

이용하여 인식하는 과정을 거친다.




Fig. 2. Example of object extraction result

2.2 조정된 AlexNet을 이용한 객체 분류 및 인식

윗 절에서 추출된 객체는 4가지로 분류되도록 조정된 AlexNet에 입력되어 분류과정을 고친다. 추출된 객체를 인식하기 위해 ILSVRC(Image Net Large Scale Visual Recognition Challenge)에서 2012년도에 우승한 CNN 모델인 AlexNet을 조정하여 사용하였다[7]. AlexNet은 5개의 Convolution layer, 3개의 Max-pooling layer, 3개의 Fully-connected layer로 구성되어 있으며 1000개의 라벨로 분류한다. 다음절에서 CNN에 대한 기본 소개와 실제로 본 시스템에서 사용한 조정된 AlexNet을 자세히 소개한다.

2.2.1 CNN(Convolutional Neural Network)

CNN은 인간의 시신경 구조를 모방한 기술로 기존의 완전결합망(Fully-connected network)은 인식하고자 하는 영상의 특성을 고려하지 않아 훈련 영상(Training image)에서 물체의 위치만 살짝 다르게 바뀌어도 전혀 다른 사진으로 인식하던 문제가 있었는데, CNN은 이 문제를 효과적으로 해결하여 영상 데이터, 음성 데이터(Spectrogram)과 같이 각 특징(Feature)들간의 위상적, 기하적 구조가 있는 지역(ILocal)적인 패턴을 학습하는 것이 효과적임이 판명되었다. 특히 CNN은 2012 ImageNet 대회에서 CNN을 사용한 AlexNet이 우승하면서 그 성능이 검증되었다.

CNN을 통해 학습을 거치면서 컨볼루션(Convolution)과 풀링(Pooling)을 반복하여 상위 특징들을 구성하는 특징추출기가 구성된다. 여기서 컨볼루션은 로컬한 영역에서의 특징 특징을 얻는 과정이고, 풀링은 차원(Dimension)을 줄이면서도 이동변화에 불변한 특징(Translation-invariant feature)을 얻는 과정이다. 이러한 컨볼루션과 풀링을 여러 층을 두어서 픽셀의 조합

으로부터 윤곽선을, 윤곽선의 조합으로부터 도형을, 도형의 조합으로부터 물체를 단계적으로 찾아낼 수 있다.

이러한 학습은 층이 깊게 되면 기존의 완전 결합망에서 사용했던 오류 역전파 알고리즘만으로는 학습이 불가능하여 개선된 알고리즘으로 이를 해결하였다. 활성화 함수는 기존에 사용했던 시그모이드 함수 대신 ReLU(Rectified Linear Unit)를 사용함으로써 기존의 시그모이드 함수에서 많이 발생했던 학습이 진행되지 않는다는 오류에 빠지지 않게 하며, 학습을 하다 보면 가중치(Weight)들이 서로 동조화 되는 현상이 발생할 수 있는데, 이를 해결하기 위해 드롭아웃(Drop-out)기법을 사용하여 가중치를 무작위로 생략하여 학습에 참여시킴으로써 동조화 현상을 피할 수 있다. 실제로 이러한 기법을 사용하면 그렇지 않았을 때보다 더 선명한 특징을 얻을 수 있다.

컨볼루션 층에서 컨볼루션 연산을 수행하게 되면, 경계 처리문제로 인해 출력 영상인 Feature map의 크기가 입력 영상보다 작아지게 된다. 따라서 경계 바깥부분을 '0'으로 채워 넣는 0-패딩(Zeropadding)을 수행하여 원본의 크기를 유지할 수 있을 뿐만 아니라 경계면의 정보까지 살린다.

2.2.2 장애물 인식을 위한 조정된 AlexNet

(1) 특징 추출 및 학습 모델

광류 추정 알고리즘을 이용하여 추출된 객체는 장애물 여부를 인식을 위해 AlexNet을 사용하여 인식하고자 하는 대상의 특징을 학습을 통해 먼저 자동추출하고, 이렇게 학습을 통해 만들어진 특징추출기를 통해 인식하고자 하는 대상에 대해 특징 추출과 인식이 진행된다. AlexNet의 구조는 Fig. 3과 같으며, 실제 ILSVRC에서는 1000개의 라벨로 구성되어 있었는데, 제안하는 시스템에서는 '차', '오토바이', '사람', '그 외'의 4가지 경우로 인식해야 하므로 4개 출력노드를 가진다.




Fig. 3. AlexNet tuned for obstacle recognition

학습영상은 224 x 224 x 3의 크기로 정규화된 영상이고, 컨볼루션을 수행하기 위해 이미지 바깥 영역에 특정 값을 채우는 연산은 0-패딩으로 설정하였다. 첫 번째 컨볼루션 층(컨볼루션-맥스풀링)에서 11 x 11 x 3의 크기의 컨볼루션 커널(Kernel) 96개를 사용하여 55 x 55 x 96의 특징맵(Feature map)을 얻고, 2번째 컨볼루션 층에서는 5 x 5 x 96 크기의 컨볼루션 커널 256개를 사용하여 27 x 27 x 256크기의 특징맵을 얻는다. 또한, 3번째 컨볼루션 층(컨볼루션-컨볼루션-맥스풀링)에서는 첫 번째 컨볼루션 연산시 3 x 3 x 256 크기의 컨볼루션 커널 384개를 사용하여 13 x 13 x 384개의 특징맵을 얻고, 4번째, 5번째 컨볼루션 연산시 3 x 3 x 384 크기의 컨볼루션 커널을 사용한 결과 완전 결합층에 입력되기 전 13 x 13 x 256개의 특징맵을 얻는다.

각 층에서 풀링을 할 때는 맥스 풀링(Max-pooling) 방법으로 3 x 3 크기의 풀링 윈도우에 stride를 '2'로 설정하였다. Fig. 4는 맥스 풀링 과정을 보여준다.

완전결합층은 분류를 위해 사용되며, Fig 5와 같이 구성된다. 첫 번째와 두 번째 완전 결합층의 노드 수는 4096개이고, 분류 라벨은 4개이다. 또한, 소프트 맥스(Softmax) 함수를 사용하여 라벨에 대한 값이 확률로 계산되어 나온다. 여기서 분류되는 4가지 라벨은 '차', '사람', '오토바이', '그 외'이다.

(2) 장애물 인식

장애물 인식은 학습되어진 신경망의 가중치를 통한 연산을 거쳐 최종적으로 4가지 부류 중 자동차, 사람, 오토바이, 그 외의 모양과 일치하는 정도를 출력함으로써 물체의 여부를 판단한다. 시스템이 구별하는 부류의 종류는 Fig. 6과 같다. 그 외의 경우에는 나무, 건물에 대한 이미지를 학습하였다.




Fig. 4. max-pooling result




Fig. 5. Fully-connected layer for classification



Fig. 6. Four types to be recognized

3. 실험 및 결과

제안하는 시스템의 성능을 평가하기 위하여 다양한 영상을 대상으로 실험하였다. 실험의 환경설정으로는 그래픽카드 Titan X Pascal 2대와 RAM 16G와 64비트 운영체제의 사양인 PC를 사용하였다. 실험 영상은 12시부터 16시 사이의 맑은 날씨일 때의 주행 중인 자동차에 장착된 블랙박스 카메라를 통해 촬영하였으며, 총 68장의 비디오로 구성하였다. 실험영상은 추출되어야 할 객체인 자동차, 사람, 오토바이의 경우 장애물의 수가 총 5개 이하로 존재하는 장면인 경우로 제한하였다. Fig. 7은 실험영상의 예로 주행 중인 자동차에 장착된 블랙박스에 찍힌 장면이다.



Fig. 7. A road image on a black box mounted on a running vehicle

3.1 객체 추출 실험 및 결과

객체 추출 실험 결과, 68장의 실험영상 중 객체를 추출한 이미지는 250장이며 추출하지 못한 이미지는 20장으로 객체 추출에 대한 정확도는 92%의 결과를 얻었다. Fig. 8은 객체를 추출한 이미지를 표시한 것이다.



Fig. 8. Some examples of object extraction result

실제 실험 영상에서 객체를 추출할 때 인식하고자 하는 물체가 아닌 것을 추출하면 인식할 때 걸러낼 수 있지만, 인식하고자 하는 물체를 추출하지 못하면 아예 인식조차 못하는 문제가 발생한다. 따라서 객체추출의 결과는 매우 중요하다. Fig. 9는 왼쪽에서 오른쪽으로 이동하고 있는 차량에 장착되어 있는 블랙박스에서 촬영된 도로 영상이다. 카메라가 왼쪽에서 오른쪽으로 이동하면서 화면 전체에서의 각 특징점이 모두 왼쪽으로 이동한 것을 볼 수 있다. 이렇게 화면 전체가 하나의 객체로 추출되어 인식하는 경우 자동차로 인식하지 못하는 경우도 발생한다. 이유는 영상을 학습할 때 자동차가 아닌 경우로 나무, 건물에 대한 영상을 학습하였기 때문에 추출한 영상에서 나무, 건물이 있는 경우 자동차가 아닌 것으로 결과가 나오기 때문이다. 촬영하고 있는 자동차가 과속 방지턱을 넘는 경우이거나, 좌회전이나 우회전을 하는 경우에 이미지 전체가 추출된다. 그 외의 경우로 직진을 할 때에는 화면 전체가 움직이는 것이 아니기 때문에 주변에 움직이는 객체를 추출할 수 있다. 다음과 같이 화면 전체가 하나의 객체로 추출되는 경우는 추출된 객체의 크기와 화면의 비율을 고려하여 70%를 초과할 경우 화

면 전체를 추출한 것으로 판단하여 추출하지 않도록 설정하였다.



Fig. 9. Road image taken from a moving camera

객체를 추출할 때, 영상에서 객체의 위치가 어디에 있는지에 따라 특징 점 벡터의 크기가 달라진다. Fig. 10의 왼쪽 영상은 추출된 객체의 위치를 보여주고, Fig. 10의 오른쪽 영상은 추출된 객체의 이미지를 나타낸다. 추출된 객체에서 특징 점의 변화를 확인하면 벡터의 크기가 같은 것을 알 수 있다. 이렇게 벡터의 크기가 대체로 비슷하면 하나의 객체로 추출할 수 있다. 또한, Fig. 11과 같이 바깥쪽으로 많이 치우치지 않은 경우에도 벡터의 크기가 대체로 비슷하기 때문에 객체를 추출할 수 있으며, 본 연구에서는 벡터의 크기는 100픽셀 간격으로 크기가 같은 것으로 추출하기 때문에 하나의 객체로 추출한다. 하지만 Fig. 12와 같이 객체가 화면 바깥쪽으로 치우친 경우에는 하나의 객체로 추출할 수 없다. 특징 점의 움직임 방향은 같지만 벡터의 크기가 다르기 때문인데, 이러한 경우는 크기가 같은 벡터와 서로 분리되어 객체가 추출된다. 이와 같이 한 이유는 같은 방향으로 다른 두 물체가 이동하면 하나의 물체로 추출하는 것을 방지하기 위함이다. 이렇게 추출한 객체는 변형된 AlexNet을 이용하여 인식하는 과정을 거친다.

3.2 객체 인식 실험 및 결과

추출된 객체를 인식하기 위해 128 x 128 크기의 학습 영상 2,563장을 만들어 사용하였다. ‘차’ 영상으로는 843장, ‘사람’ 영상으로는 660장, ‘오토바이’ 영상으로는 369장, 그 외 영상 691장을 인터넷을 통한 수집 또는 직접 촬영하여 사용하였다. ‘그 외’의 라벨로 분류되는 경우, 특히 구름, 도로와 같이 특별한 특징점이 없는 영상을 학습할 경우에는 과적합(Overfitting)이 발생하여 낮은 인식률의 결과가 나오기 때문에 특징점이 있는 차선, 나무, 건물과 같은 영상으로 학습하였다.

실제로 추출된 객체에 대해 인식한 결과 인식률은 96.4%로 높은 인식률의 결과를 얻음을 확인 할 수 있었다.



Fig. 10. Change of feature point according to object position1




Fig. 11. Change of feature point according to object position2




Fig. 12. Change of feature point according to object position3

4. 결론

본 논문에서는 자율주행 시 영상을 입력받아 객체를 추출하여 해당 객체가 ‘차’, ‘사람’, ‘오토바이’인지 인식하는 시스템을 제안하였다. R-CNN을 이용하여 객체를 추출하는 경우 실시간으로 영상을 입력받으면서 연산하는 속도가 한 프레임 당 1초를 초과한다. 이러한 이유로 더 빠른 속도로 객체를 추출하기 위해 본 논문에서는 광류 추정 알고리즘을 이용하여 객체를 추출하였다. 움직임 방향이 같은 특징 점을 군집화 하여 4 방향인 상, 하, 좌, 우로 나뉘었으며, 벡터의 크기를 픽셀 값 기준으로 100, 200, 300의 크기 변화에 따라 객체를 다르게 추출하도록 설정하였다.

제안하는 시스템에서 객체 추출에 대한 정확도는 92%

이며, 객체 인식에 대한 정확도는 96.4%의 결과를 얻을 수 있었다. 객체 추출에 대한 정확도를 개선하기 위해서는 특징 점의 방향을 상, 하, 좌, 우로 4 방향이 아닌 상, 하, 좌, 우에서 대각선 4 방향을 추가한 8 방향으로 나눠서 추출하고, 날씨에 따라 객체를 분류하는 기준이 다르기 때문에 날씨에 따른 객체 인식에 대한 정확도를 높이기 위해서는 각 날씨에 따른 학습을 따로 진행하여 날씨에 맞게 가중치가 조정된 분류기를 사용해야 할 것이다. 또한 보다 더 많은 학습영상을 수집하여 이를 학습하면 인식률이 높아질 것이다.

ACKNOWLEDGMENTS

본 논문은 과학기술정보통신부 및 정보통신기술진흥센터의 서울어코드활성화지원사업(IITP-2017-2012-0-00598)의 연구결과로 수행되었음.

이 논문은 2017년 추계학술대회 학부생 발표 논문 중 우수논문으로 선정되었습니다.

REFERENCES

- [1] S. J. Choi. (2017). *Utilization of Insurance System as a Legal Response to Autonomous Vehicles*. Graduate School of Gachon National University, Gyeonggi.
- [2] K. I. Lim. (2009). *Design of Distributed Control System and Development of Autonomous Driving Algorithm for Unmanned Ground Vehicle*. Graduate School of Kookmin National University, Seoul.
- [3] S. Y. Han. (2015). *The Research of Autonomous Vehicle of Preceding Vehicle Detection Technique using the LRF Sensor and Camera for Effective Obstacle Classification*. Graduate School of Kookmin National University, Seoul.
- [4] M. C. Kim. (2008). *A Vehicle Detection Using Optical Flow At Corner Point of Image*. Graduate School of Kyungpook National University, Seoul.
- [5] S. Y. Kim. (2003). *Automatic Extraction of Central Objects for Object-Based Image Retrieval*. Graduate School of Pusan National University, Pusan.
- [6] J. H. Kim. (2007). *Object based image retrieval using extraction of salient points and image segmentation*. Graduate School of Hanyang National University, Seoul.

[7] A. Krizhevsky, I. Sutskever & G. E. Hinton. (2012). Imagenet classification with deep convolutional neural networks. *In Advances in neural information processing systems*, 1106-1114.

[8] B. J. Kim. (2017). *License Plate Detection System Using Faster R-CNN method for Outdoor Images*. Graduate School of Chonbuk National University, Chonbuk.

[9] J. H. Kang. (2017). *Design of Programmable CNN Accelerator for Vehicular Image Recognition*. Graduate School of Soongsil National University, Seoul.

[10] M. J. Go. (2017). *Detecting vehicles that are illegally driving on road shoulders using faster R-CNN*. Graduate School of Yonsei University, Seoul.

[11] M. I. Sarker. (2017). *Farm Land Weeds Detection with Region-based Deep Convolutional*. Chonbuk National University, Chonbuk.

[12] J. Shi & C. Tomasi. (1994). *Good features to track*, 593-600. USA : IEEE.
DOI : 10.1109/CVPR.1994.323794

구 본 철(Bon-Cheol Koo)

[학생회원]



▪ 2012년 3월 ~ 현재 : 충북대학교
소프트웨어학과 학사과정

<관심분야> : 영상처리, 컴퓨터비전

저 자 소 개

최 경 주(Kyung Joo Cheoi)

[정회원]



▪ 1996년 2월 : 충북대학교 컴퓨터
과학과 학사
▪ 1999년 2월 : 연세대학교 대학원
컴퓨터과학과 석사
▪ 2002년 2월 : 연세대학교 대학원
컴퓨터과학·산업시스템공학과 박사

▪ 2002년 ~ 2005년 : LG CNS 연구개발센터
▪ 2005년 ~ 현재 : 충북대학교 소프트웨어학과 교수
<관심분야> : 컴퓨터비전, 뇌과학, 기계학습 등

한 주 찬(Juchan Han)

[학생회원]



▪ 2012년 3월 ~ 현재 : 충북대학교
소프트웨어학과 학사과정

<관심분야> : 영상처리, 컴퓨터비전