

시각장애인을 위한 딥러닝기반 심볼인식

박상헌*, 전태재**, 김상혁**, 이상윤**, 김주완*

Deep learning based symbol recognition for the visually impaired

Sangheon Park*, Taejae Jeon**, Sanghyuk Kim**, Sangyoun Lee**, Juwan Kim*

요약 최근 시각장애인 및 교통약자의 자유로운 보행을 보장하기 위한 많은 기술들이 연구되고 있다. 자유로운 보행을 위한 장치로는 영상카메라, 초음파센서 및 가속도 센서 등을 이용하는 스마트 지팡이와 스마트 안경 관련 기술이 있다. 대표적인 기술로는 물체를 식별하여 장애물을 검출하고 보행 가능 영역을 추출하는 기술, 랜드마크 심볼 정보를 인식하여 주위 환경 정보를 주는 기술 등 여러 가지 기술이 개발되고 있다. 본 논문에서는 시각장애인에게 필요한 시설의 대표 심볼을 선정하여 착용한 영상 장치의 정보로부터 심볼을 인식하는 알고리즘을 딥러닝 기술을 이용하여 연구하였다. 그 결과로 딥러닝 영상처리 분야에서 사용되는 CNN(Convolutional Neural Network)기법을 사용하여 서로 다른 딥러닝 구조를 실험을 통하여 비교하고 분석하였다.

Abstract Recently, a number of techniques to ensure the free walking for the visually impaired and transportation vulnerable have been studied. As a device for free walking, there are such as a smart cane and smart glasses to use the computer vision, ultrasonic sensor, acceleration sensor technology. In a typical technique, such as techniques for finds object and detect obstacles and walking area and recognizes the symbol information for notice environment information. In this paper, we studied recognition algorithm of the selected symbols that are required to visually impaired, with the deep learning algorithm. As a results, Use CNN(Convolutional Neural Network) technique used in the field of deep-learning image processing, and analyzed by comparing through experimentation with various deep learning architectures.

Key Words : Convolutional neural network, Deep learning, Deep neural network, Machine learning, Symbol recognition

1. 서론

현재 스마트폰 이후 많은 분야에서 웨어러블 디바이스에 대한 연구가 진행되고 있다. 이전 기술의 발전방향은 단순한 액세서리형, 직물/의류 일체형, 신체부착형, 생체 이식형으로 일반인을 위한 기술 정립 단계였다면 앞으로의 발전방향은 시각장애인, 청각장애인, 신체장애인, 어린이, 노약자를

대상으로 한 제품 연구가 크게 증진될 전망이다. 교통약자의 보행 보조를 위한 기술로는 스마트폰 케이스, 스마트 지팡이와 스마트 안경 관련 기술이 대표적이고, 본 장치들을 이용해 물체를 식별하고 위치를 검출하는 기술 개발이 진행되고 있으며, 초음파 및 가속도 센서를 이용한 방법, 시각장애인들이 보다 안전하고 편리한 보행이 가능하도록 사물 지능통신(M2M : Machine-to-Machine)기반의 지

This research was supported by a grant (Research Project ID-79209, 15TLRP-B079209-02) from Transportation & Logistics Research Program funded by Ministry of Land, Infrastructure and Transport Affairs of Korean government.

* Corresponding Author : Electronics and Telecommunications Research Institute(shpark12@etri.re.kr)

** School of Electrical and Electronic Engineering, Yonsei University

Received April 04, 2016

Revised April 25, 2016

Accepted May 10, 2016

능형 보행보조 시스템 등도 개발되고 있다[1,2]. 최근에는 단순히 교통약자가 보행하는 데 방해가 되는 장애물을 검출하는 것을 넘어서서 교통약자의 보행에 필요한 상세 정보를 제공하는 안내보행에 대한 요구가 증가되고 있고 이에 따라 보행상세정보 데이터베이스의 생성이 필요하다. 따라서 보행상세정보 데이터베이스 생성을 위한 랜드마크를 검출 및 인식 기술 개발에 대한 필요성이 대두되고 있다. 안내보행을 위한 보행상세정보 데이터베이스 생성은 기존의 영상 기반 객체 검출 및 인식 알고리즘으로부터 응용할 수 있는 많은 분야 중 하나로 판단할 수 있으며, 시각장애인이나 노인의 보행을 보조할 수 있는 시각보조 장치를 연구할 필요성이 있다. 비전 정보를 활용한 랜드마크 검출 및 인식 기술은 교통약자를 위한 보행환경에 변화와 개선을 가져올 것이고, 이는 궁극적으로 교통약자가 비 교통약자인 일반인과 동일한 공평하고 편리한 교통권을 영위하는데 일익을 담당할 것이다.

본 연구에서는 시각장애인을 위한 랜드마크 심볼을 비전시스템을 이용하여 얻은 영상으로부터 인공신경망을 이용하여 시각장애인에게 정보를 전달하기 위한 인식 방법을 설명하고자 한다.

2. 심볼 인식 기술

비전시스템으로부터 얻은 원본 영상에서 랜드마크 영역을 검출하여 얻은 ROI에서 랜드마크 영역을 인식 및 분류 시키는 시스템이다. 심볼 인식 분야와 유사한 기준에 연구분야는 교통 표지판 인식(Traffic Sign Recognition)이다. 인식 기술의 대표적인 방법인 인공 신경망을 이용한 인식 방법은 기계학습의 대표적인 기술로 사전에 검출한 표지판DB 및 랜드마크DB 영상을 신경망을 통해 특징 벡터를 추출하고 신경망의 계층 구조를 통해 학습 및 분류 시키고 인식하는 방법이다. 인공 신경망은 생물학적 시신경 원리에 착안하여 구조를 이루는데 다층 구조를 이루어, 각 층을 거침으로써 최종적으로 변화에 강한 특징을 추출하여 영상을 인식 및 분류하는 시스템이다. 인공 신경망 중에서

영상처리 분야에서 많이 쓰이는 회선 신경망(CNN; Convolutional Neural Network)의 일반적인 다층 구조는 그림 1에 묘사되어 있다[3].




그림 1. 회선 신경망 구조
Fig. 1. An illustration of the architecture of convolutional neural network

또 다른 심볼 인식 방법으로는 특징 매칭을 이용한 인식 기술이 있다. 기본적인 특징 매칭 방법으로는 SIFT가 많이 사용되었는데 가장 일반적인 방법이지만 많은 계산량을 필요로 한다. 또한 Hu, Tchebichef, Zernike 등의 불변 모멘트방식에 비해 좋은 인식률을 보여준 CPT(Central Projected Transformation) 기반의 도형 특징을 추출하여 식별하는 방식이 있다. 이외에도 고속으로 매칭을 할 수 있는 SURF(Speed Up Feature Transform)와 ORB(Oriented FAST and Rotated BRIEF)를 이용한 특징점 생성과 DB의 템플릿과 매칭을 이용한 방식이 있다[4]. 그림 2는 이중에 SURF와 ORB를 이용한 교통표지판 식별 과정을 보여준다.




그림 2. SURF와 ORB를 이용한 교통표지판 식별
Fig. 2. Traffic sign recognition with SURF and ORB

3. 인공신경망을 이용한 인식 기술

인공 신경망은 인간의 중추 신경계 구조에 착안하여 물체를 인식하는데, 데이터를 입력 받고 조정 가능한 가중치의 집합인 학습 알고리즘에 의해 학습한다. 인공 신경망으로 분류 또는 예측된 데이터는 변화에 강인하고, 강한 식별력을 가져, 교통 산업 또는 보행지원 산업에서 널리 사용되어 오고 있다. 교통 표지판 및 랜드마크 인식의 기본 단계는 영상 획득, 관심 영역 검출, 인식으로 나누어지는데, 위의 기술을 사용해 검출된 영역을 올바르게 식별 하는 게 매우 중요한 인자이다.

3.1 Convolutional Layer

인공 신경망 알고리즘은 크게 Convolutional Layer, Pooling Layer, Fully-Connected Layer로 구성되어 하나의 구조를 이룬다. 여기에서 Convolutional layer는 필터를 이용해 전체 입력 영상에 convolution 연산을 수행하여 feature map을 만든다. 보통 필터는 5x5 또는 3x3과 같은 작은 영역에 대해 적용을 하며, 필터에 사용되는 계수들의 값에 따라 각각 다른 특징을 얻을 수 있다. Convolutional layer를 사용하면 얻을 수 있는 장점은 크게 두 가지로 구분 된다. 첫 번째로 영상이 갖는 공간적인 특성을 최대한 활용할 수 있다. 이를 Sparse connectivity라 하는데 모든 가능한 connection을 사용하는 것 보다 훨씬 적은 표현형을 학습하는 단점이 있지만, 반대로 복잡도가 낮아지는 장점이 있다. 두 번째로는 전체 영상에 대해 가중치 및 바이어스를 공유하여 자유 변수 개수와 CNN 학습 시간을 줄이고, 과적합을 줄일 수 있다[5]. 그림 3에서 Convolutional layer의 연산을 시각적으로 묘사하고 있는데, 영상을 입력 받은 뒤 필터를 이용해 feature map을 형성하는 것을 나타낸다.

3.2 Pooling Layer

Convolutional layer를 거친 뒤 더 차원이 낮은 feature map을 얻기 위해 subsampling을 거쳐 feature map을 줄여준다. 이 과정을 거치면 강한 신호만 전달하고 나머지 약한 신호는 무시할 수

있게 된다. 이동이나 변형 등에 강인 하려면 좀 더 강하고 전역적인 특징을 추출해야 하는데 Convolutional layer와 Pooling layer를 여러 번 거치면 가능하다. 그림 3은 이 Pooling layer의 연산을 묘사하고 있는데, Convolutional layer에서 나온 feature map에서 가장 강한 신호만 선별하여 다시 feature map을 형성하는 max-pooling 과정을 보여준다[5].




그림 3. Convolutional layer와 Pooling layer의 원리
Fig. 3. The principle of convolutional layer and pooling layer

3.3 Fully-Connected Layer

Convolutional layer와 Pooling layer를 여러 번 거친 뒤 Fully-Connected layer에서 최종적으로 1 차원 특징 벡터로 구성된다. 인식 단계에서 마지막 layer의 역할은 각 클래스의 뉴런 값으로 표현해준다. 교통 표지판 및 랜드마크 인식 연구에서는 최종적으로 softmax 함수를 이용해 각 뉴런의 값이 특정 클래스에 속할 확률을 계산 해 분류 과정에 사용된다. 그림 4는 Fully-Connected Layer가 어 feature map을 클래스의 개수만큼 뉴런으로 출력하는 모습을 큰 그림으로 보여주는데, 이는 Convolutional Layer, Pooling Layer를 앞 단계에 두고 Fully-Connected Layer를 이용해 최종 뉴런으로 출력하는 인식의 전 과정을 뜻 한다[6].




그림 4. 심층 인공 신경망의 구조
Fig. 4. An illustration of the architecture of deep neural network

3.4 Dropout 알고리즘

교통 표지판 및 랜드마크 인식 연구에서 과적합 문제를 피하기 위해 Dropout 알고리즘[7]이 사용되었다. Dropout 알고리즘은 모든 layer에 대해 학습을 수행하는 것이 아니라 망에 있는 입력 layer나 hidden layer의 일부 뉴런을 생략하고 줄어든 신경망을 통해 학습을 수행한다. 그림 5는 일부 뉴런을 생략하고 줄어든 신경망을 학습하는 모습을 그림으로 나타낸다. Dropout을 하는 이유는 크게 두 가지로 볼 수 있다. 첫 번째로 투표 효과이다. Dropout을 통해 여러 개의 다른 망에 대해 학습을 하게 되면, 그 망에 대해서 과적합이 발생하고 이런 과정이 무작위로 반복 되면 과적합된 망이 늘어나 투표에 의한 평균 효과를 얻을 수 있다. 두 번째로는 동조화를 피하는 효과이다. 특정 뉴런의 바이어스나 가중치가 큰 값을 갖게 되면 다른 뉴런들의 학습 속도가 느려지거나 학습이 제대로 안 되는 경우가 있는데 Dropout을 이용하면 가중치나 바이어스가 특정 뉴런의 영향을 받지 않기 때문에 동조화를 피할 수 있다.




그림 5. Dropout 신경망 모델
Fig. 5. Dropout neural network model

4. 심층 인공 신경망을 이용한 랜드마크 심볼 인식 방법

시각장애인을 위한 랜드마크 심볼 인식을 위하여 심층 인공 신경망 알고리즘을 사용하였다. 3가지의 심층 인공 신경망을 이용하여 취득한 랜드마크 심볼 DB를 이용하여 학습하여 사용하였다. 랜드마크 인식의 순서는 다음과 같다. 영상 전처리, 인공 신경망 구축, 학습의 구조로 진행 된다.

4.1 영상 크로핑(Cropping)

영상 크로핑을 하는 목적은 그래픽 처리 장치(GPU)의 제한된 메모리 양을 고려함과 동시에 연산량의 감소시키기 위함이다. 원본 영상은 랜드마크를 담고 있는 영상이고, 여기에 배경을 제외한 랜드마크 부분을 크로핑 하여 크로핑 된 영상을 얻는다. 마지막으로 영상의 크기를 48 x 48로 크기 조절하여 정사각형이 되게 하였다. 그리고 크기 조절 된 영상을 학습용 및 실험용 영상으로 사용하였다. 본 실험에 사용한 랜드마크 데이터베이스는 총 10,368 장이고, 학습용 영상은 총 8,525 장, 실험용 영상은 총 1,843 장으로 구성하였다. 그림 6은 영상 크로핑의 예를 보여준다.




그림 6. 랜드마크 심볼 크로핑 예
Fig. 6. An example of landmark symbol cropping

4.2 심층 인공 신경망 구축

랜드마크 인식에 사용한 인공 신경망 구조는 9개의 레이어로 구성된 DNN이며 표1, 표2, 표3과 같은 세 가지의 신경망 구조의 심층 인공 신경망을 구축하였다. 표1과 표2의 차이는 Dropout 알고리즘의 ratio 수치이며 표3은 Dropout 알고리즘을 사용하지 않을 때이다. 세 신경망 모두 동일하게


Input, Convolutional, Pooling, Fully-Connected의 계층 구조를 띄는 인공 신경망을 사용 하였는데 모두 공통적으로 Layer 0에서 영상을 입력 받는 Input layer로 시작한다. 랜드마크 심볼DB가 색상 정보가 있는 영상이기 때문에 Input layer에서 3개의 map을 형성하며 뉴런의 크기는 영상의 크기와 동일하다. 심볼DB를 48 x 48로 크로핑 시켜 입력하였기 때문에 48 x 48 크기의 뉴런이 되는 것이다. Layer 1, Layer 3, Layer 5는 인공 신경망에서 convolution 연산을 수행 해 feature map을 형성하는 단계이며 map의 개수는 곧 Convolutional layer의 필터 개수를 뜻한다. 필터 개수는 Convolutional layer를 거칠 수록 점점 증가하도록 설계하여 최종적으로 Fully-Connected Layer에서 심볼 클래스의 총 개수 N개 만큼 출력되도록 설계하였다. Convolutional layer의 뉴런 개수는 $X = \text{Input layer의 neuron 크기}$, $Y = \text{Convolutional layer의 filter 크기}$, $Z = \text{neuron의 크기 일 때, } Z = X - Y + 1$ 로 정해 진다. Layer 2, Layer 4, Layer 6은 Pooling layer로써 앞의 Convolutional layer에서 얻은 feature map의 차원 수를 줄여 변형에 강한 회선 신경망을 이루도록 설계하였으며, kernel의 크기는 2 x 2를 사용하였다. Pooling layer의 kernel 크기는 일반적으로 영상의 가로, 세로 크기가 100 pixel 이하일 때 2 x 2크기를 많이 사용하며 그 이상을 넘을 때 더 큰 kernel 크기를 사용하기 때문에 본 신경망 구조에서는 2 x 2 크기를 사용하였다.

표 1. 인공 신경망 구조 1
Table 1. Deep neural network architecture 1



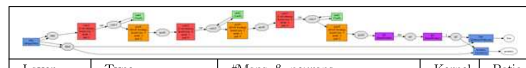
Layer	Type	#Maps & neurons	Kernel	Ratio
0	Input	3 maps of 48 x 48 neurons		
1	Convolutional	100 maps of 42 x 42 neurons	7 x 7	
2	Max pooling	150 maps of 21 x 21 neurons	2 x 2	
3	Convolutional	150 maps of 18 x 18 neurons	4 x 4	
4	Max pooling	150 maps of 9 x 9 neurons	2 x 2	
5	Convolutional	250 maps of 6 x 6 neurons	4 x 4	
6	Max pooling	250 maps of 3 x 3 neurons	2 x 2	
7	Fully connected	300 neurons	1 x 1	
	Dropout			0.5
8	Fully connected	5 neurons	1 x 1	

표 2. 인공 신경망 구조 2
Table 2. Deep neural network architecture 2



Layer	Type	#Maps & neurons	Kernel	Ratio
0	Input	3 maps of 48 x 48 neurons		
1	Convolutional	100 maps of 42 x 42 neurons	7 x 7	
2	Max pooling	150 maps of 21 x 21 neurons	2 x 2	
3	Convolutional	150 maps of 18 x 18 neurons	4 x 4	
4	Max pooling	150 maps of 9 x 9 neurons	2 x 2	
5	Convolutional	250 maps of 6 x 6 neurons	4 x 4	
6	Max pooling	250 maps of 3 x 3 neurons	2 x 2	
7	Fully connected	300 neurons	1 x 1	
	Dropout			0.8
8	Fully connected	5 neurons	1 x 1	

표 3. 인공 신경망 구조 3
Table 3. Deep neural network architecture 3



Layer	Type	#Maps & neurons	Kernel	Ratio
0	Input	3 maps of 48 x 48 neurons		
1	Convolutional	100 maps of 42 x 42 neurons	7 x 7	
2	Max pooling	150 maps of 21 x 21 neurons	2 x 2	
3	Convolutional	150 maps of 18 x 18 neurons	4 x 4	
4	Max pooling	150 maps of 9 x 9 neurons	2 x 2	
5	Convolutional	250 maps of 6 x 6 neurons	4 x 4	
6	Max pooling	250 maps of 3 x 3 neurons	2 x 2	
7	Fully connected	300 neurons	1 x 1	
8	Fully connected	5 neurons	1 x 1	

5. 실험 결과

5.1 심층 인공 신경망 학습

실험 구성은 표4와 같다. 실험1은 표지판 DB인 GTSRB DB에서 5개의 클래스와 랜드마크 심볼DB의 1개 클래스를 합쳐 총 클래스를 합쳐 총 6개의 결과를 출력하도록 학습하여 실험 하였고, 실험 2는 GTSDB DB 배경 영상 1개 클래스와 랜드마크 심볼DB의 1개 클래스를 합쳐 총 2개의 클래스를 이루며 2개의 결과를 출력하도록 실험하였다. 마지막으로 실험 3은 모든 랜드마크 심볼DB를 이용해 실험을 진행하였다. 표5는 3개의 실험에서 사용한 데이터베이스를 클래스 별로 예를 들어 정리하여 나타낸 것이다.

표 4. 실험 Dataset
Table 4. The dataset of experiments

	실험 1	실험 2	실험 3
클래스 수	6	2	6
데이터베이스	GTSRB+ 랜드마크	GTSDB+ 랜드마크	랜드마크

표 5. 학습 및 실험 Dataset 영상
Table 5. Train and test dataset images

	실험 1	실험 2	실험 3
클래스 0			
클래스 1			
클래스 2			
클래스 3			
클래스 4			
클래스 5			

실험 환경은 표6과 같다. 그래픽 처리 장치를 이용해 연산을 수행하기 위해 GTX Titan X 그래픽 처리 장치를 사용 하였으며, 사용한 인공 신경망 툴은 Caffe framework[8]이다. Caffe는 Windows 7 64 bit에서 Visual Studio 2013을 사용해 구동하였다.

표 6. 실험 환경
Table 6. An experiment environment

프로세서	i7-4790 (3.60 GHz)
메모리	10GB DDR3
그래픽 처리 장치	GTX Titan X
운영체제	Windows 7 64 bit
도구(Tool)	Caffe/Visual Studio 2013

5.2 인식 실험 결과

실험DB에 따라 실험을 3개로 나누고, 인공 신경망 구조에 따라 신경망 구조를 3개로 나누어 실험 한 결과는 표7과 같다. 인식 실험 결과, Dropout을 사용한(신경망 구조1, 신경망 구조2) 경우가 사용하지 않은(신경망 구조 3) 보다 실험 1은 0.52 %, 실험 2는 0.16 %만큼 실험 3은 0.39%

만큼 성능 향상을 보였다. 또한 학습과 테스트 속도를 측정 하였는데, 데이터베이스를 학습한 뒤 10,000장의 테스트 셋을 이용해 학습과 테스트하였을 때 소요되는 시간을 측정하였다. 그 결과는 표8과 표9와 같다. 결과적으로 Dropout을 이용한 신경망 구조가 인식결과 더 좋은 성능을 내고 학습 시간도 더 줄여주는 효과를 내는 것을 보여주었다.

표 7. 랜드마크 심볼 인식을
Table 7. Landmark symbol recognition rate

	실험 1	실험 2	실험 3
신경망 구조 1	99.5536%	98.8487%	97.1174%
신경망 구조 2	99.3304%	98.8487%	97.2954%
신경망 구조 3	99.0327%	98.6842%	96.9039%

표 8. 랜드마크 심볼 인식 알고리즘 학습 수행 속도
Table 8. Excution time of Landmark symbol recognition algorithm for train

	실험 1	실험 2	실험 3
신경망 구조 1	0.0046 s/image	0.0047 s/image	0.0045 s/image
신경망 구조 2	0.0045 s/image	0.0045 s/image	0.0046 s/image
신경망 구조 3	0.0046 s/image	0.0046 s/image	0.0046 s/image

표 9. 랜드마크 심볼 인식 알고리즘 테스트 수행 속도
Table 9. Excution time of Landmark symbol recognition algorithm for test

	실험 1	실험 2	실험 3
신경망 구조 1	34min	15min	28min
	57sec	55sec	46sec
신경망 구조 2	33min	15min	25min
	46sec	43sec	36sec
신경망 구조 3	34min	16min	30min
	44sec	1sec	55sec

6. 결론

본 논문에서는 교통약자에게 보행편의를 제공하기 위해 영상에서 교통약자에게 필요한 시설의 심볼을 가리키는 인식하는 기술을 연구하였다. 최근 이슈가 되고 있는 웨어러블 디바이스에 탑재가 되며 교통약자를 위해서 쓰이는 기술로서 궁극적으로 교통약자의 보행편의에 큰 도움을 줄 수 있는 기술을 연구했다. 생성된 데이터베이스는 교통약자의 보행안내를 위한 교통 인프라를 갖추는 데 이용될 수 있다.

하지만 반사가 심한 물체, 역광 또는 날씨 등 외부요건들로 인해 영상 취득이 용이하지 못한 상

황일 경우 랜드마크 심볼 인식에 문제가 생길 수 있다. 따라서, 향후에는 외부 환경적인 요소에 의한 시스템 민감도를 최소화 할 수 있는 최적화에 대한 연구 개발이 지속적으로 이루어져야 한다고 판단된다.

REFERENCES

[1] J. Choi, G. Jeong, "Development of Walking Assist Smartphone Case for Blind People", The Journal of Korea Institute of Information, Electronics, and Communication Technology, Vol.8, No.3, pp.239-242, 2015.

[2] C. Kang, H. Jo, B. Kim, "A Machine-to-machine based Intelligent Walking Assistance System for Visually Impaired Person", The Journal of The Korean Institute of Communication Sciences, Vol.36, No.3, pp.287-296, 2011.

[3] P. Sermanet, K. Kavukcuoglu, S. Chintala and Y. LeCun, "Pedestrian detection with unsupervised multi-stage feature learning", Proc. IEEE Conference on Computer Vision Pattern Recognition (CVPR), pp.3626-3633, 2013.

[4] D. Dajun and C. Lee, "Fast algorithm for Traffic Sign Recognition", Journal of IKEEE, Vol.16, No.4, pp.356-363, December 2012.

[5] W. W. Zhu, et al, "Searching for Pulsars Using Image Pattern Recognition", The Astrophysical Journal, Vol.781, No.2, pp.117-128, 2014.

[6] A. Krizhevsky, I. Sutskever, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. In Advances in Neural Information Processing Systems 25, pages 1106-1114, 2012.

[7] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting", The Journal of Machine Learning Research, Vol.15, Issue.1, pp.1929-1958, 2014.

[8] Y. Jia, et al. "Caffe: Convolutional architecture for fast feature embedding", Proceedings of the 22nd ACM International Conference on Multimedia, pp. 675-678, 2014.

저자약력

박 상 현(Sangheon Park)

[정회원]



- 2010년 2월 : 연세대학교 전기전자공학과 (학사)
- 2012년 2월 : 연세대학교 전기전자공학과 (석사)
- 2012년 3월 ~ 현재 : 한국전자통신연구원 스마트모빌리티연구부 연구원

<관심분야>

컴퓨터비전, 영상인식, 기계학습

전 태 재(Taejae Jeon)

[학생회원]



- 2014년 2월 : 연세대학교 전기전자공학과 (학사)
- 2014년 3월 ~ 현재 : 연세대학교 전기전자공학과 석박사통합과정

<관심분야>

심층 인공 신경망, 컴퓨터비전

김 상 혁(Sanghyuk Kim)

[학생회원]



- 2015년 2월 : 중앙대학교 융합공학부 디지털이미징학과 (학사)
- 2015년 3월 ~ 현재 : 연세대학교 전기전자공학과 석사과정

<관심분야>

심층 인공 신경망, 영상인식

이 상 윤(Sangyoung Lee)

[정회원]



- 1987년 2월 : 연세대학교 전자공학과 (학사)
- 1989년 2월 : 연세대학교 전자공학과 (석사)
- 1999년 12월 : Georgia Tech. 전기 및 컴퓨터공학과 (박사)
- 1989년 4월 ~ 2004년 2월 : KT 선임연구원
- 2004년 3월 ~ 현재 : 연세대학교 전기전자공학과 교수

<관심분야>

컴퓨터비전, 영상인식, 영상부호화

김 주 완(Juwan Kim)

[정회원]



- 1993년 2월 : 부산대학교 컴퓨터공학과 (학사)
- 1995년 2월 : 부산대학교 컴퓨터공학과 (석사)
- 2004년 2월 : 충남대학교 컴퓨터공학과 (박사)
- 1995년 1월 ~ 현재 : 한국전자통신연구원 우정물류공간정보연구부 책임연구원

<관심분야>

컴퓨터비전, 영상인식, 기계학습