

# 모바일 스테레오 비전 시스템을 위한 다양한 스테레오 정합 기법의 오차율 비교

## Comparison of error rates of various stereo matching methods for mobile stereo vision systems

이 주 영\*, 이 광 엽\*\*★

Joo-Young Lee\*, Kwang-yeob Lee\*\*\*★

### Abstract

In this paper, the matching error rates of modified area-based, energy-based algorithms, and learning-based structures were compared for stereo image matching. Census transform (CT) based on region and life propagation (BP) algorithm based on energy were selected, respectively. Existing algorithms have been improved and implemented in an embedded processor environment so that they can be used for stereo image matching in mobile systems. Even in the case of the learning base to be compared, a neural network structure that utilizes small-scale parameters was adopted. To compare the error rates of the three matching methods, Middlebury's Tsukuba was selected as a test image and subdivided into non-occlusion, discontinuous, and disparity error rates for accurate comparison. As a result of the experiment, the error rate of modified CT matching improved by about 11% when compared with the existing algorithm. BP matching was about 87% better than conventional CT in the error rate. Compared to the learning base using neural networks, BP matching was about 31% superior.

### 요 약

본 논문에서는 스테레오 영상정합을 위하여 개선된 영역기반, 에너지 기반 알고리즘, 학습기반 구조의 정합 오류율을 비교하였다. 영역기반으로 census transform(CT), 에너지 기반으로 belief propagation(BP) 알고리즘을 선정하였다. 기존 알고리즘을 개선하고 모바일 시스템에서 스테레오 영상정합에 활용가능 하도록 임베디드 프로세서 환경에서 구현하였다. 비교 대상이 되는 학습기반의 경우에도 적은 규모의 파라미터를 활용하는 신경망 구조를 채택하였다. 세 가지 정합방법의 오류율 비교를 위해 테스트 이미지로 Middlebury 데이터 세트 가운데 Tsukuba를 선정하고 정합 성능의 정확한 비교를 위해 비폐색, 불연속, 시차 오류율 등으로 세분화하였다. 실험 결과 CT 매칭의 오차율은 기존 알고리즘과 수정된 알고리즘으로 비교하였을 때 약 11% 성능 개선되었다. BP 매칭은 오류율에서 기존 CT 에 비하여 약 87% 우수하였다. 신경망을 이용한 학습기반과 비교 하였을 때 BP 매칭이 약 31% 우수함을 보였다.

*Key words : stereo matching, census transform, belief propagation, neural network disparity map*

\* Dept. of Electronics Eng.

\*\* Dept. of Computer Eng., Seokyeong University

★ Corresponding author

E-mail : jylee@skuniv.ac.kr, Tel : +82-2-940-7735

※Acknowledgment

This work was supported by Seokyeong University in 2021.

Manuscript received Dec. 12, 2022; revised Dec. 16, 2022; accepted Dec. 20, 2022.

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.

### 1. 서론

스테레오 비전을 통한 실시간 공간 거리 영상의 생성 기술은 자동차, 로봇 자율주행 및 장애물 인식 분야의 응용뿐만 아니라 얼굴인식, 사람 인식 및 환경 인식 분야의 기술을 통하여 영화, 애니메이션, 가상현실, 방송 등의 여러 분야에 요소 기술로 응용될 수 있다. 특히 시각 센서를 두 개 이상 사용하여 물체의 실시간 3차원 영상 정보를 추출하는 연구는 오랫동안 진행되고 있다.

스테레오 비전을 구성하는 핵심 기술로 스테레오 정합(matching)이 있다. 인간의 좌, 우 시각을 대신하여 카메라로 물체의 좌, 우 이미지를 입력받아 시차 정보를 알아내는 기법이다. 시차 정보는 기준 영상의 한 점(pixel)과 목적 영상에서 같은 점의 x축 거리를 말하며 시차 정보를 영상으로 표현한 것을 시차 영상(disparity image) 혹은 깊이 영상(depth map)이라 한다. 스테레오 정합 기술은 특징 기반, 영역기반 그리고 에너지 기반 정합으로 나누어진다.

특징 기반은 모서리나 경계선 정보를 통하여 두 영상의 동일한 점들을 찾아내는 방법으로 특징을 갖는 대응 점을 제외한 정보는 제공하지 못하는 단점이 있다. 영역 기반은 일정 영역(window)의 픽셀 정보로 정합 점을 찾기 때문에 깊이 정보의 정확도가 상대적으로 낮지만 연산과정이 단순한 장점이 있다. Census Transform[1], SAD[2], SSD[3], NCC[4] 등이 여기에 속한다. 에너지 기반은 매우 정확한 깊이 영상을 추출할 수 있으나 연산과정이 복잡한 단점이 있다. Belief Propagation(BP) [5], semi-global matching[6], graph-cut[7] 등의 방법이 있다.

위와 같은 방법은 폐색(occlusion), 특징이 없는(featureless) 영역, 반복 패턴을 사용하는 텍스처 영역에서는 정확도가 떨어지기 때문에 최근에는 학습을 이용하여 이러한 문제점을 해결하기 위하여 MC-CNN[8], LW-CNN[9], FED-D2DRR[10] 등 다양한 스테레오 기반 딥러닝 기술이 사용되고 있다[11].

그러나, 딥러닝 기술은 고성능 GPU(Graphics Process Unit) 연산을 요구하며 표 1에서 보듯이 가중치를 비롯한 하이퍼 파라미터 양이 많아 VGG-16 CNN의 경우 파라미터 저장에 552MB의 메모리가 요구되어 소모전력과 실행시간 지연 등 많은 문제점을 보인다. 따라서 로봇, 자율 차량 등 이동형 임베디드 시스템에서 스테레오 비전을 활용하는 데는 딥러닝 기반 스테레오 방법과 더불어 기존의 스테레오 매칭 방법을 지속적으로 연구할

필요가 있다.

본 논문에서는 영역기반의 스테레오 매칭으로 대표적인 Census Transform의 효율성을 개선하는 방법과 에너지 기반의 매칭에서 성능이 뛰어난 BP를 구현한 결과와 딥러닝 기반 스테레오 매칭의 선행 연구 결과와 비교하여 기존의 매칭 방법의 활용 가능성을 제시한다.

다양한 매칭 방법의 연구 결과를 비교하기 위해 딥러닝 학습에도 사용되고 있는 Middlebury image data set[12]으로 선택하였다.

Table 1. Number of CNN's Parameters

표 1. 합성곱 신경망의 파라미터 수

Network Architect.	# of Convolutional Layers	# of Fully Connected Layers	# of Parameters
AlexNet	5	3	61 Million
GoogleNet	21	1	40 Million
ResNet	49	1	50 Million
VGG-16	13	3	138 Million

### II. Census Transform 스테레오 매칭 설계

#### 1. Census Transform 알고리즘

CT(Census Transform)는 스테레오 영상 정합 및 특징점 추출에 사용되는 알고리즘으로 주변 픽셀과 강도를 비교하여 영상을 변환한 후 좌, 우 영상을 비교하게 된다.

CT 알고리즘은 중앙 픽셀을 기준으로 이웃 픽셀을 Bit string으로 나열하여 비교한다. 이때, Bit string으로 나열하는 값은 다음 식 (1)과 같이 표현된다[1].

$$P_{xy} = \begin{cases} 0 & \text{if } P_{center} \geq P_{xy} \\ 1 & \text{if } P_{center} < P_{xy} \end{cases} \quad (1)$$

Census Transform Window




Fig. 1. Hamming Distance for CT algorithms. 그림 1. CT 알고리즘의 Hamming Distance 연산

식 (1)의  $P_{xy}$ 는 서브 윈도우 범위 내의 픽셀의 밝기값을 의미하고,  $P_{center}$ 는 기준이 되는 중앙 픽셀의 밝기값을 의미한다. 검출된  $P_{xy}$ 를 이용해 Bit String으로 변환하여 그림 1과 같이 Hamming distance를 수행한다.

이 때 검출된 Hamming Distance의 값이 가장 작은 픽셀 위치를 기준으로 스테레오 정합을 수행한다.

### 2. 제안하는 Census Transform 알고리즘

제안하는 알고리즘은 CT 알고리즘에서 표현하는 커널 인덱스의 경우의 수를 증가시켜 더욱 정확한 스테레오 정합이 이루어지도록 한다[13].

기존의 CT 알고리즘은 식 (1)과 같이 중앙 픽셀을 기준으로 이웃 픽셀값을 0과 1로 표현하여 총 0부터 255까지 256가지의 커널 인덱스를 구성한다. 하지만 제안된 알고리즘은 식 (2)와 같이 구성하여 커널 인덱스의 경우의 수를 다양하게 표현한다.

$$P_{xy} = \begin{cases} 2 & \text{if } P_{center} \geq P_{xy} - c \\ 1 & \text{if } P_{center} < P_{xy} + c \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

식 (2)의  $c$ 는 분류 범위의 세분화를 위한 파라미터이며, 본 논문에서는 2를 적용하여 결과를 출력하였다. 기존의 CT 알고리즘과 비교하여 본 논문에서 제안하는 알고리즘은 커널 인덱스의 경우의 수가 기존  $2^8$ 에서  $3^8$ 로 증가한 것을 알 수 있다. 픽셀의 값을 기존의 CT 알고리즘에서는 그림 2의 상단과 같이 중앙 픽셀의 밝기값과 비교하여 작은 것과 큰 것으로 분류하였지만, 제안된 알고리즘에서는 그림 2의 하단과 같이 중앙 픽셀의 밝기값과 비교하여 비슷한 것과 큰 것, 그리고 작은 것으로 분류하여 정확도를 높였다.




Fig. 2. Kernel index of CT(a) and proposed CT algorithm(b).  
그림 2. CT(a)와 제안된 알고리즘(b)의 커널 인덱스

## III. Belief Propagation 스테레오 매칭 설계

### 1. Belief Propagation 알고리즘

Belief propagation(BP) 알고리즘은 스테레오 정합에서 대응점들은 비슷한 밝기값을 가지고, 변위 값은 물체의 경계 부분을 제외하고는 대체로 연속적인 성질을 가진다. 따라서 BP 알고리즘은 식 (3)의 에너지 함수를 이용하여 나타낼 수 있으며, 에너지 함수를 최소화하는 변위 값을 찾아서 스테레오 정합을 수행한다.

$$E(d_i) = \sum_{i \in I} U(d_i) + \lambda \sum_{(i,j) \in N} V(d_i, d_j) \quad (3)$$

식(3)의  $E(d_i)$ 를 최소화한다는 것은 정합 되는 화소는 좌우 서로 유사한 밝기 값을 가지면서 그 인근 화소의 시차와 유사한 값을 가져야 한다는 가정을 두고 있다. BP 알고리즘은 bit string description으로 구성된다.

$$\tau(\mathbf{p}; \mathbf{x}, \mathbf{y}) := \begin{cases} 1 & : \mathbf{p}(\mathbf{x}) < \mathbf{p}(\mathbf{y}) \\ 0 & : \mathbf{p}(\mathbf{x}) \geq \mathbf{p}(\mathbf{y}) \end{cases}, \quad (4)$$

$\mathbf{p}$ 는 smoothed image patch를 나타내고, binary test  $\tau$ 는 식 (4)와 같이 정의된다. 여기에서  $\mathbf{p}(\mathbf{x})$ 와  $\mathbf{p}(\mathbf{y})$ 는  $\mathbf{x}$ ,  $\mathbf{y}$ 의 위치한 픽셀의 밝기값을 나타낸다.

$$f_n(\mathbf{p}) := \sum_{1 \leq i \leq n} 2^{i-1} \tau(\mathbf{p}; \mathbf{x}_i, \mathbf{y}_i) \quad (5)$$

식(5)의  $n$ 은 vector length로써 본 논문에서는 이 값을 256 설정하여 실험하였다. 기존 논문에서는 256개의 vector length를 char형으로 설정하여 32개의 descriptor를 형성하였지만 본 논문은 int 형으로 8개의 descriptor를 형성하였다.

### 2. 제안하는 매칭 최적화

BP 알고리즘으로 생성된 스테레오 좌, 우 서술자 정보는 매칭 단계에서 비교할 경우, 비교 대상이 많아 매칭 단계의 성능이 하향되는 단점이 있다. 이러한 단점을 보완하기 위해 그림 3과 같이 비슷한 데이터 끼기 묶어 놓고, 그 부분만을 비교하면 전체를 비교하는 것보다 성능을 향상시킬 수 있다.

부분만을 비교하면 매칭개수가 적어질 수 있기 때문에 정렬 알고리즘을 사용하여 비슷한 부분만을 비교할 수 있도록 정렬한다. 즉, 총 8개의 32bit register로 구성된




Fig. 3. Left, Right BP descriptor comparison by parts.  
그림 3. 부분별로 좌, 우 BP 서술자 비교

256-bit string descriptor 정보과 다른 256-bit string descriptor 정보를 비교하여 작은 서술자부터 큰 서술자로 정렬하면 근처에 있는 데이터들만 가지고 비교를 해도 일치하는 부분을 찾을 수 있어 매칭속도가 향상된다. 또한, Hamming Distance의 기본 알고리즘을 사용할 경우, 반복문을 많이 쓰는 경우가 발생한다. 두 개의 서술자 데이터를 XOR 연산 후, 다른 비트 수를 계산하는데 반복문을 사용하지 않고 테이블 방식을 사용함으로써 수행 성능을 향상 시켰다.

#### IV. Deep Learning 기반 스테레오 매칭과 설계된 스테레오 매칭 비교 실험

##### 1. Deep Learning 기반 스테레오 매칭

스테레오 알고리즘은 첫 단계로 스테레오 영상의 모든 시차값 d에 대해 좌, 우 영상 위치 p에서 식(6)과 같이 매칭 cost를 계산한다. 오른쪽 영상 patch의 중심점 p에 왼쪽 영상 patch의 연관성의 합을 계산 결과값이다.

$$C_{SAD}(p, d) = \sum_{q \in N_p} |I^L(q) - I^R(q-d)| \quad (6)$$

식(6)의 매칭 cost에 딥러닝 기술을 적용하여 최적의 매칭을 이루는 것이 딥러닝 기반 스테레오 매칭이다[15].

지도학습 방법을 이용하여 매칭 문제를 판단하기 위해서는 공개적으로 사용되는 KITTI[14], Middlebury[12] 스테레오 데이터 세트가 주로 사용된다.

데이터 세트에서 ground truth disparity를 이용하여 각 위치 p에서 negative와 positive 학습 데이터를 추출한다. Positive는 중심점이 같은 좌, 우 영상이며 그렇지 않으면 negative가 된다.

딥러닝을 실행하는 신경망의 구조는 그림 4와 같이 구성하게 되면 학습 속도를 빠르게 할 수 있다. 신경망의 결과값으로 similarity score가 출력되는데 좌, 우 영상

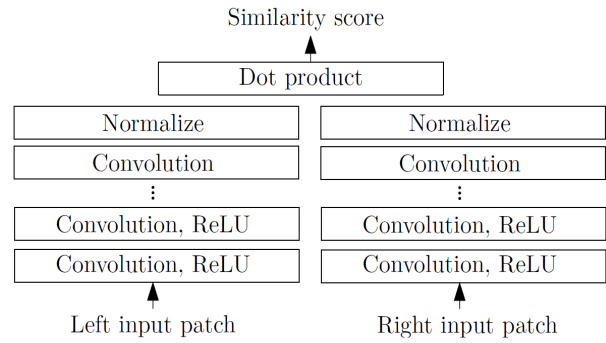


Fig. 4. The fast architecture of neural network for a stereo matching.

그림 4. 스테레오 매칭을 위한 고속 신경망 구조

patch를 입력으로 좌, 우 합성곱 신경망(CNN)과 정규화 과정을 통하여 마지막에 좌, 우 값을 합쳐 similarity score를 결정한다. 일반적으로 좌, 우 신경망 출력값을 합칠 때 cosine 연산을 사용하는 것보다 그림 4와 같이 dot product를 사용하면 연산 복잡도를 크게 단순화할 수 있다. 신경망을 이용하여 계산하는 matching cost 식은 식(5)을 바탕으로 좌측 patch  $P^L(p)$ 과 우측 patch  $P^R(p-d)$ 가 주어지면 식(6)과 같이 표현하게 된다.

$$C_{CNN}(p, d) = -s(\langle P^L(p), P^R(p-d) \rangle) \quad (6)$$

본 논문의 실험에 사용된 신경망 구조는 빠른 학습과 테스트를 목적으로 하는 WNN(Weightless Neural Networks)으로 신경망 node에 있는 RAM에 가중치를 synapse에 두지 않는 방법으로 학습 속도를 높일 수 있다[16].

##### 2. 실험 영상

실험에 사용된 입력 이미지는 Middlebury College의 stereo vision research page의 Tsukuba로 각 영상에 대한 실제 시차 지도(disparity map)와 폐색 영역(occlusion region)을 그림 5와 같이 사용할 수 있다[16].

그림 5에서 왼쪽 상단은 좌측 카메라 영상, 오른쪽 상단은 우측 카메라 영상, 왼쪽 하단은 비폐색 마스크, 오른쪽 하단은 깊이 불연속 마스크를 보여 준다.

##### 3. 실험 환경

ARM11 MP-Core 시스템은 ARM사의 ARM11 MP-Core 로직 타일과 에몰레이션 보드를 결합하여 함께 동작하도록 되어있다. ARM11 MP-Core는 200MHz ARM11 프로세서 4개와 32Kb L1 명령어 캐시, 32Kb L1 데이




Fig. 5. Tsukuba Image.

그림 5. Tsukuba 이미지

터 캐시, 1Mb L2 공유 캐시, 인터럽트 분배기를 내장하고 있다. 4개의 프로세서들이 개별적으로 가지고 있는 L1 캐시의 일관성은 SCU(Snoop Control Unit)가 관리한다.

ARM11 MP-Core 에서는 OpenMP를 지원하여 사용자가 디렉티브의 삽입만으로 순차적인 코드를 병렬적인 코드로 변경할 수 있다는 장점을 가지고 있다.

#### 4. 실험 및 비교 결과

그림 6은 기존의 Census Transform 스테레오 정합을 수행한 결과와 제안된 알고리즘의 결과를 비교하였다. 상단은 기존 알고리즘을 적용한 시차 지도와 시차 지도의 Bad Pixel을 나타내고 하단은 제안된 알고리즘의 시차 지도와 Bad Pixel 이다.




Fig. 6. Results of Census Transform Stereo Matching.

그림 6. Census Transform 스테레오 매칭 결과

그림 7은 BP 알고리즘을 실험한 결과로 왼쪽은 시차 지도이며 오른쪽은 시차 지도의 Bad Pixel을 보여 준다. BP의 Bad Pixel 이미지는 그림 6의 Bad Pixel 이미지보다 흰색 영역이 많은 것은 그만큼 오차율이 작기 때문이다(표 2에서 근거를 제시한다).




Fig. 7. Result of Belief propagation Stereo Matching.

그림 7. Belief propagation 스테레오 매칭 결과

설계된 두 가지(CT, BP0 스테레오 매칭 방법과 신경망 구조의 매칭 방법의 성능 비교를 위해 시차 지도에서 오차율을 계산한다. 오차율은 비폐색구간의 오차율(non-occluded), 불연속점의 오차율(discontinuities) 그리고 시차 지도의 오차율(disparity error)로 세분화하여 측정 및 비교한다. 오차율은 다음 식(7)을 이용한다.

$$B = \frac{1}{N} \sum_{(x,y)} (|d_c(x,y) - d_T(x,y)| > \delta_d) \quad (7)$$

$d_c(x,y)$ 는 스테레오 정합의  $x,y$  위치에서의 변위 값이고  $d_T(x,y)$ 는 주어진 실제 변위 값이다. 임계값  $\delta_d$ 는 1로 둔다. 두 시차 지도의  $x,y$  위치에서 두 변위 값에 대한 차이의 절대 치 값이 임계치보다 크면 bad pixel로 놓고 그 개수를 전체 화소 수  $N$ 으로 나눈 값의 백분율 오차율로 계산한다.

비폐색 오차율은 비폐색 영역에서 매칭의 결과에 대한 불일치율이다. 이때 사용되는 비폐색 마스크는 좌, 우 카메라가 모두 볼 수 있는 부분은 흰색으로 한쪽 카메라에만 보이는 부분은 검은색으로 만든 이미지이다.

불연속점 오차율은 물체의 경계선 등에서 볼 수 있는 깊이 불연속(깊이의 급격한 변화)이 나타나는 곳의 근처에 있는 영역에서 매칭 결과의 불일치율이며 시차 지도

오차율은 시차 지도 전체에서 매칭 결과에 대한 불일치율이다.

세 가지 매칭 방법에 대한 세 가지 오차율의 측정 결과와 비교는 표 2와 같다. 측정에 사용된 이미지는 Middlebury's Tsukuba를 사용하였다.

Table 2. Comparison results of matching error rate by matching methods.

표 2. 매칭 방법별 매칭 오차율의 결과 비교

Matching Method		matching error rate		
		non-occl'	discont'	disparity
CT	CCT	38.2%	53.7%	39.6%
	our CT	32.8%	49.8%	34.4%
BP[18]		2.27%	10.4%	2.95%
our BP		1.8%	10.1%	3.8%
Learning WNN[19]		9.18%	10.7%	20.3%

\* CT : Census Transform, CCT : Conventional CT

\* BP : Belief Propagation

\* WNN : Weightless Neural Network

CT 매칭의 오차율은 기존 알고리즘과 수정된 알고리즘으로 비교하였을 때 약 11% 성능 개선되었다. CT와 BP 매칭의 경우 BP 매칭이 약 87% 우수하다. 기존 BP 매칭과 비교 하였을 때 비폐색과 불연속 영역에서 오차율이 낮다. 신경망을 이용한 학습기반과 비교 하였을 때 BP 매칭이 약 31% 우수함을 보였다.

## V. 결론

자율주행 시스템, 3차원 영상 시스템 등의 발달로 스테레오 비전의 필요성이 증가 하고 있다. 과거 영상 분야에서 많은 연구가 되어왔던 기존의 스테레오 매칭 방법과 최근 각광을 받는 딥러닝 기반의 매칭 구조를 실험적으로 비교하여 보았다. Middlebury's Tsukuba라는 동일한 테스트 이미지를 비교자료로 사용하기 위해 WNN [17] 측정치를 이용하였으나 보다 진보한 딥러닝 구조도 향후 비교 대상 연구로 진행계획이다. 본 논문의 기여하는 바는 기존 스테레오 매칭 방법도 개선하여 효율성을 높이면 최근의 딥러닝 기반 매칭 방법보다 우수하거나 근접한 결과를 얻을 수 있으며 고성능 GPU와 대규모 메모리 용량을 요구하는 딥러닝매칭에 비하여 소규모의 하드웨어로 모바일 시스템에 기존 매칭 방법이 갖는 장점을 제시하였다.

## References

- [1] Ramin Zabih, John Woodfill, "Non-parametric local transforms for computing visual correspondence," *Eccv'94*. LNCS, vol.801, pp.151-158, 2005. DOI: 10.1007/BFb0028345
- [2] Aditya Rachman Putra, Fadhil Mochammad, Hans Herdian, "FPGA implementation of template matching using binary Sum of Absolute Difference," *International Conference on System Engineering and Technology*, 2016. DOI: 10.1109/ICSEngT.2016.7849615
- [3] M. B. Hisham, Shahrul Niam Yaakob, R. A. A Raof, A. B. A. Naren, N. M. Wafi, "Template Matching using Sum of Squared Difference and Normalized Cross Correlation," *IEEE Student Conference on Research and Development*, 2015. DOI: 10.1109/SCORED.2015.7449303
- [4] J. N. Sarvaiya, Suprava Ptnaik, Salman Bombaywala, "Image Registration by Template Matching Using Normalized Cross-Correlation," *International Conference on Advances in Computing, Control, and Telecommunication Technologies*, 2009. DOI: 10.1109/ACT.2009.207s
- [5] Chunsheng Guo, ShuoShuo Gao, Dazhuang Zhang, "Belief propagation algorithm for background estimation based on local maximum weight matching," *International Congress on Image and Signal Processing*, 2012. DOI: 10.1109/CISP.2012.6469678
- [6] Ekaterina Mezenceva, Sergey Malakhov, "The study of the Semi-Global Block Matching Algorithm Implementing Parallel Calculation with GPU," *International Conference on Problems of Infocommunications, Science and Technology*, 2021. DOI: 10.1109/PICST54195.2021.9772166
- [7] Zhao wei, Lian xiaofeng, Liu Zaiwen, "Panoramic image matching based on graph cuts algorithm," *2012 9th International Conference on Fuzzy Systems and Knowledge Discove*. 2012. DOI: 10.1109/FSKD.2012.6234298
- [8] J. Zbontar and Y. LeCun, "Stereo matching by training a convolutional neural network to compare

image patches,” *Journal of Machine Learning Research*, vol.17, no.1-32, pp.2, 2016.

DOI: 10.5555/2946645.2946710

[9] H. Park and K. M. Lee, “Look wider to match image patches with convolutional neural networks,” *IEEE Signal Processing Letters*, vol.24, no.12, pp.1788-1792, 2017.

DOI: 10.1109/LSP.2016.2637355

[10] X. Ye, J. Li, H. Wnag, H. Huang, and X. Zhang, “Efficient stereo matching leveraging deep local and context information,” *IEEE Access*, vol.5, pp.18745-18755, 2017.

DOI: 10.1109/ACCESS.2017.2754318

[11] Hamid Laga, Laurent Valentin Jospin, Farid Boussaid, Mohammed Bennamoun, “A Survey on Deep Learning Techniques for Stereo-based Depth Estimation,” *IEEE Tran. on Pattern Analysis and Machine Intelligence*, vol.44, no.4, pp.1738-1764, 2022. DOI: 10.1109/TPAMI.2020.3032602

[12] “Middlebury Stereo Datasets,” <http://vision.middlebury.edu/stereo/data/>

[13] Jong il Park, Kyoung gyu Taek, Kwang yeob Lee, “Parallel Implementation of Improved Census Transform Stereo Matching algorithm with OpenMP,” *IEIE conference*, vol.35, no.1, 2012.

[14] Jure Zbontar, Yann LeCun, “Stereo Matching by Training a Convolutional Neural Network to Compare Image Patches,” *The Journal of Machine Learning Research*, vol.17, no.1, pp.2287-2318, 2016. DOI: 10.48550/arXiv.1510.05970

[15] “KITTI Stereo Data Set,” <http://https://www.cvlibs.net/datasets/kitti/>

[16] I. Aleksander, “From WISARD to MAGNUS: A Family of Weightless Virtual Neural Machine,” *RAM-Based Neural Networks*, *World Scientific*, pp.18-30, 1998.

DOI: 10.1142/9789812816849\_0002

[17] Martull Sarah, P. Martin, Fukui Kazuhiro, “Realistic CG Stereo Image Dataset With Ground Truth Disparity Maps,” *Computer Science, Environmental Science*, 2012.

[18] Qian. Zhang, Shaomin Li, Y. Zhang, P. Wang, and JF. Huang, “New Stereo Matching Method

based on Improved BP algorithm,” *International Journal on Smart Senging and Intelligent Systems*, vol.8, no.1, 2015. DOI: 10.21307/ijssis-2017-767

[19] Lucas de Paula Veronese, Lauro Jose Lyrio Junior, Filipe All Mutz, Jorcy de Oliveira Neto, Vitor Barbirator Azevedo, Mariella Berger, Alberto Ferreira De Souza and Claudine Badue, “Stereo Matching with VG-RAM Weightless Neural Networks,” *Internaltional Conference on Intelligent Systems Design and Applications*, pp.27-29 2012.

DOI: 10.1109/ISDA.2012.6416556

## BIOGRAPHY

### Joo-young Lee (Member)



1990 : BS degree in Electronics Engineering, Hanyang University.  
1992 : MS degree in Electronics Engineering, Hanyang University.  
2001 : PhD degree in Electronics Engineering, Hanyang University.

2002~presently : Professor, Dept of Electronics Engineering, Seokyeong University

### Kwang-yeob Lee (Life Member)



1985 : BS degree in Electronics Engineering, Sogang University  
1987 : MS degree in Electronics Engineering, Yonsei University.  
1994 : PhD degree in Electronics Engineering, Yonsei University.  
1989~1995.2 : Senior Researcher, Hyundai Electronics Inc.

1995.3~present : Professor, Dept. of Computer Engineering, Seokyeong University