

Multi-Parameter Operation Method for Robust Disparity Plane

Hyun-jung Kim[†] · Il-yong Weon^{**} · Chang-hun Lee^{***}

ABSTRACT

Although many different methods have been used to solve stereo correspondent problems, the deviation of accuracy is too big. Among those many methods, the one that uses segmentation information of input image has received high attention in academic field since it is very close to vision recognition. In this thesis, the existing method of acquiring a single value by using the segment information and initial disparity value was viewed in NP-hard problem to propose a new method. In order to verify the validity of the proposed method, well-known data were used for experiment and the resulted data was analyzed. Although there were some disadvantages in the time aspect, it showed somewhat useful results in the accuracy aspect.

Keywords : Stereo Matching, Color Segmentation, Disparity Plane Fitting, SPPM, MPPM, NP-Hard

강건한 시차 평면을 위한 다중 파라미터 연산 기법

김현정[†] · 원일웅^{**} · 이창훈^{***}

요약

스테레오 대응 문제(Stereo Correspondent Problem)를 해결하기 위해 다양한 방법들이 시도되고 있지만 정확도의 편차가 심하다. 이 중 입력영상의 세그먼테이션 정보를 이용하여 접근하는 방법은 인간의 인식과 유사하여 많은 연구가 진행되고 있다. 세그먼트 정보와 초기 시차(disparity)값을 이용하여 단일한 해만을 구하는 기존 방법을 본 논문에서는 NP-hard 문제로 시각을 전환하여 해결하는 새로운 방법으로 제안하였다. 제안한 방법의 유용성 검증을 위해 잘 알려진 실험 데이터로 실험하고 그에 따른 결과를 분석하였다. 기존 방식에 비해 제안된 방법은 시간에서는 불이익이 있지만 정확도에서는 어느 정도 유용한 결과를 보여주었다.

키워드 : 스테레오 매칭, 컬러 세그먼테이션, 시차 평면 적합, SPPM, MPPM, NP-Hard

1. 서론

스테레오 대응 문제(Stereo Correspondence Problem)는 컴퓨터 비전 분야에서 가장 중요한 주제 중의 하나이다. 이 문제를 해결하기 위해 다양한 스테레오 매칭 연구들이 지속적으로 발표되어왔고, 어느 정도 성능을 가진 알고리즘들이 알려졌다. 그러나 이러한 알고리즘의 성능은 대상 영상의 도메인에 따라 정확도의 편차가 심하다[1, 2].

기존 알고리즘들 중 지역적 방법을 이용한 알고리즘들[3, 4]은 연산 속도가 빠르지만 정확도가 높지 않고, 전역적인 방법을 이용하는 알고리즘들은 비교적 정확도는 높지만, 처리 시간이 길다는 것이 문제이다. 이러한 두 가지 접근법의

한계를 극복하기 위해 여러 가지 방법들이 시도되고 있는데, 특히 입력영상의 세그먼테이션 정보를 이용하는 방법은 형태와 색의 정보를 적극 이용한다는 측면에서 인간이 사물을 인식하는 방법과 유사하여 많은 주목을 받고 있다[5, 7].

영상의 세그먼테이션을 이용하는 알고리즘의 핵심 아이디어는 스테레오 대응 문제를 동일 세그먼트 내의 모든 픽셀을 포함하는 평면의 방정식을 구하는 문제로 모델링하여 접근한다는 것이다[8-10]. 그러나 동일한 세그먼트를 구성하는 모든 점들이 동일한 평면을 보장하지 않기 때문에 기존 알고리즘을 이용하여 구한 시차값을 적극 이용해야 한다. 이러한 접근법은 세그먼트의 정보와 초기 시차값의 정확도에 따라 구한 값이 원하는 해의 근사값이라는 문제가 있다. 따라서 이러한 조건을 만족시키는 1개의 해만을 구하는 기존의 방법은 한계가 있다[6].

본 논문에서 우리는 세그먼트 정보와 초기 시차값을 이용하여 스테레오 대응 문제를 해결하는 기존의 단일 해만을 구하는 방법이 가지고 있는 근사해의 문제를 좀 더 효율적

[†] 준회원: 건국대학교 컴퓨터공학과 박사과정
^{**} 정회원: 서울호서전문학교 사이버해킹보안과 교수
^{***} 종신회원: 건국대학교 컴퓨터공학과 교수
Manuscript Received: March 4, 2015
First Revision: April 8, 2015
Accepted: April 16, 2015
* Corresponding Author: Hyun-jung Kim(nygirl@konkuk.ac.kr)

으로 구하는 방법을 제안하였다. 우리의 접근법은 평면의 방정식을 구하는 문제가 NP-hard 문제이므로 기존의 NP-hard 문제를 해결하는 방법을 적용하여 제한된 조건 내에서 다양한 후보 해를 구하여 가장 효율적인 후보를 선택하여 전체적인 효율을 높이는 방법이다.

본 논문의 구성은 다음과 같다. 2절에서는 이미지 세그먼트이션 및 초기 시차에 대한 내용을 소개하고, 3절에서는 이렇게 얻어진 값을 통해 본 논문에서 제안하는 강건한 시차 평면 파라미터 방법에 대한 내용을 설명한다. 4절에서는 3절에서 제안한 방법을 증명하기 위해 실험 및 분석을 한다. 5절에서는 결론 및 향후 과제에 대한 내용을 제시하였다.

2. 이미지 세그먼트와 초기 시차 획득

2.1 컬러 이미지 세그먼트를 위한 기준

세그먼트기반 스테레오 대응 문제 해결의 첫 단계는 참조 이미지(reference image)에 대한 객체별 세그먼트이션을 얻는 것이다. 이 단계에서 객체를 어떻게 세그먼트이션 하느냐에 따라 이후 정확도에 많은 영향을 주게 된다. 세그먼트의 수가 지나치게 많게 되면 계산량이 많아지고, 세그먼트의 수가 너무 적으면 객체를 명확하게 구분하지 못하게 되는 문제가 있다. 이 단계의 주요 목표는 각 영역이 동등(homogeneous)한 영역들로 균일하게 되도록 이미지를 잘 나누는 것이다[6].

본 논문에서 우리는 동일한 색을 기반으로 하는 클러스터링 알고리즘을 적용하여 세그먼트를 나누었는데, k-평균(k-means) 알고리즘과 평균이동(mean-shift) 알고리즘을 적용하였다.

k-평균 알고리즘[5]은 d-차원 공간상의 점으로 이루어진 입력 집합을 필요로 하는데, 목표는 주어진 데이터에서 k개의 군집 중심(centroid)을 찾고, 입력 집합을 나누는 것이다. 이것을 식으로 표현하면 Equation (1)과 같다. 즉 Equation (1)을 최소화하는 ω_i 를 찾는 것이 목표이다. 이를 위해 먼저 μ_i 를 임의로 설정한다. 다음 단계로 각 점에 대해 그 점에서 가장 가까운 클러스터를 찾아 할당하고, 다시 점들의 평균값으로 클러스터 중심을 재조정한다. 만약 클러스터가 변하지 않으면 반복 과정을 중지한다.

$$J_{MSE} = \sum_{i=1}^k \sum_{x \approx \omega_i} |x - \mu_i|^2 \quad \text{where } \mu_i = \frac{1}{N} \sum_{x \approx \omega_i} x \quad (1)$$

k-평균의 핵심 장점은 각 클러스터와 거리 차이의 분산을 최소화하는 방식이기 때문에 가장 단순하고, 계산 속도가 빠르다는 것이다. 이러한 이유로 스테레오 비전에서 객체 특징을 추출하는 데 많이 사용된다. 그러나 단점은 사용자가 미리 군집의 개수를 설정해야 하고, 예외값을 다루기 어렵다는 점이다.

평균이동은 어떤 데이터 분포의 중심점 또는 무게의 중

심을 찾는 한 방법으로, 현재 자신의 주변에서 가장 데이터가 밀집된 방향으로 이동하여 분포 중심을 찾는 방법이다[16]. 이것을 식으로 표현하면 Equation (2)와 같다.

식에서 n은 특징 벡터 X의 전체 측정 개수이고, n_k 는 k번째 특징 벡터값 x_k 를 갖는 측정값의 개수를 의미한다.

$$p_x(x_k) = \frac{n_k}{n} \quad (2)$$

$$0 \leq p_x(x_k) \leq 1, \sum_{k=0}^{L-1} p_x(x_k) = 1$$

평균이동 방법을 영상에 적용하면 데이터 집합의 밀도분포 점인 특징점, 코너 등을 기반으로 관심영역 객체를 고속으로 추적할 수 있다. 따라서 색상을 기반으로 알고리즘을 적용하면 원하는 객체와 비슷한 색상을 가지고 있는 영역을 찾기에 유리한 점이 있다. 그러나 배경화면이 추출하고자 하는 객체와 색상이 유사하면 문제가 발생한다[6].

2.2 초기 시차 획득

초기 시차를 얻기 위해 사용되는 알려진 알고리즘들에는 PW(Pixel Window), FW(Fixed Window), AW(Adaptive Window) 등이 있다. 각각의 알고리즘들은 계산량이나 정확도에 커다란 차이를 보인다. 이 중 본 논문에서 우리는 FW를 사용하였다. FW는 지역적 접근법으로 승자독식(winner-takes-all)을 이용하여 이미지의 특정 영역을 찾는 방식이다. Equation (3)은 FW가 시차를 얻기 위해 사용하는 비용(cost) 계산식이다.

$$c(x, y, d) = \frac{1}{N_i} \sum_{i=-1}^1 \sum_{j=-1}^1 |I(x+i, y+i) - I(x+j+d, y+j)| \quad (3)$$

FW는 영상에 깊이 불연속부분이 포함되어있는 경우 결과가 좋지 못하다. 특히 텍스처가 없는 영역(textureless)에서는 성능의 저하가 뚜렷하다. 그러나 매칭 비용을 추출하는 과정이 빠르고, 단순하며, 초기 시차의 정확도가 비교적 높기 때문에 세그먼트이션 기반에서 초기 평면을 얻기에는 적합하다는 특징이 있다.

3. 강건한 시차 평면 파라미터 방법

3.1 시차 평면

시차는 참조 이미지에서 한 점을 선택했을 때, 이 점과 대응되는 대상 이미지에서의 점을 구한 후, 이 두 점 사이의 거리값으로 정의할 수 있으며, 스테레오 시각의 시차에 의해서 발생한다. 이 값은 해당 물체까지의 거리나 해당 물체의 입체감을 느끼게 하는 근거가 되기도 한다. 영상에서 x, y축을 픽셀의 위치로 z를 관찰 지점에서 객체까지의 거리로 정의한다면, 어떤 물체의 시차는 결국 z축에 평행한 평면의 방정식의 부분집합으로 대응시킬 수 있다. 그리고 이러한 평면을 시차 평면(disparity plane)이라고 정의한다. 일

반적으로 동일한 객체의 작은 입체적 차이는 동일한 평면으로 처리하는 경우가 많다. Equation (4)와 Fig. 1은 이러한 시차 평면 개념을 표현한 것이다. Equation (4)에서 x, y 는 이미지의 좌표값을 의미하며, a, b, c 는 평면 파라미터, $d(x, y)$ 는 해당 점에서의 시차 값을 의미한다.

$$d(x, y) = ax + by + c \quad (4)$$

이러한 관점에서 본다면 시차를 구한다는 것은 각각의 점에서 Equation (4)의 조건을 만족하는 평면의 방정식을 구하는 문제로 단순화시킬 수 있다. 그리고 시차 평면을 구하기 위해 우리가 얻을 수 있는 값은 영상에 대한 세그먼트 자료와 초기에 얻은 기초적인 시차이다. 즉 x, y 값의 집합과 $d(x, y)$ 를 얻을 수 있다. 그러나 $d(x, y)$ 의 값과 세그먼트를 구성하는 픽셀의 집합은 사용하는 알고리즘에 따라 얼마든지 그 정확도가 바뀌기 때문에 초기 입력값에는 많은 노이즈 데이터가 포함되어있다고 볼 수 있다.

3.2 SPPM

Equation (4)의 해를 구하기 위해 SPPM(Single Plane Parameter Method)의 관점으로 접근하면 주어진 문제는 Equation (5)와 같이 표현된다. 여기서 A 는 세그먼트를 구성하는 점들의 집합이며 i 번째 열의 집합은 $[x_i, y_i, 1]$ 로 표현할 수 있다. 또 B 는 $d(x, y)$ 를 의미한다.

$$A[a, b, c]^T = B \quad (5)$$

Equation (5)를 만족하는 a, b, c 를 구하는 문제는 최소제곱해(least square solution)[17, 18]의 경우로 SVD(Singular Value Decomposition)를 사용하여 해결할 수 있다[18].

이 방법의 특징은 1개의 해만을 구하기 때문에 연산 속도가 빠르다는 장점이 있다. 그러나 구해진 해가 지역해일 가능성이 크고, 포함된 초기 노이즈 데이터에 의한 해의 왜곡을 피할 수 없다는 단점을 가지고 있다. 즉, 조건을 만족하는 시차 평면을 1개의 세그먼트당 1개밖에 구할 수 없기 때문에 구해진 평면이 최적의 해인지는 확인할 수 없다.

3.3 MPPM

본 논문에서 제안하는 MPPM(Multi Plane Parameter Method)은 Equation (4)를 만족하는 평면 파라미터를 구하는 문제를 NP-hard문제로 접근한다. 이 접근법은 SPPM과는 다르게 제한된 시간 내에서 가능성이 있는 후보해를 여러 개 구하고 이 중 가장 우수한 해를 선정하는 방법이다. 후보 평면 파라미터를 구하기 위해 우리는 메타휴리스틱 알고리즘을 사용하였다. 다양한 메타휴리스틱 방법 중 본 도메인에 필요한 조건은 시간의 제약이 적으면서 유용한 결과를 어느 정도 보장해야 하는데 이러한 조건을 만족시키는 알고리즘으로 PSO(Particle Swarm Optimization)[11-13]를 적용하였다. 제안한 MPPM의 전체 과정은 Fig. 1과 같다.

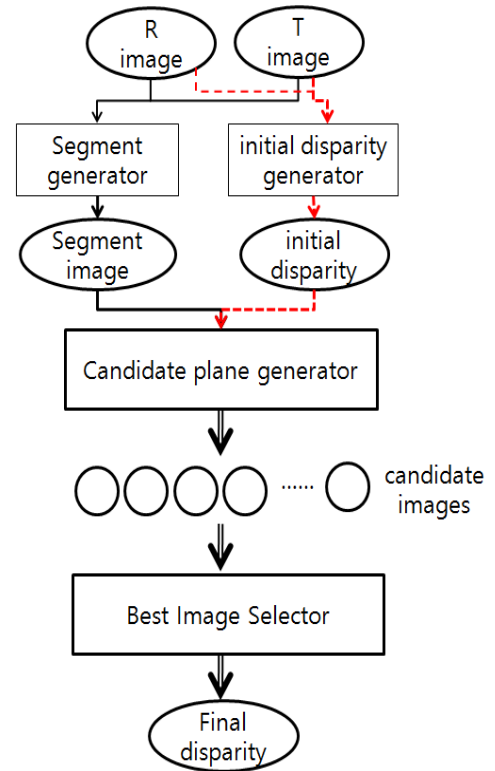


Fig. 1. MPPM Process

한 개의 세그먼트를 대표하는 적절한 평면을 구하기 위해 PSO는 다음과 같이 적용한다. 먼저 평면의 방정식 파라미터 a, b, c 를 원소로 하는 초기 파티클을 랜덤하게 생성한다. 해당 파티클의 i 번째 원소를 S_i 라고 하면 각 파티클의 다음 위치 $S_i^{(k+1)}$ 은 Equation (6), (7)을 이용하여 계산한다.

$$S_i^{k+1} = S_i^k + V_i^{k+1} \quad (6)$$

$$V_i^{k+1} = wV_i^k + c_1rand_1(pb_{est_i}^k - S_i^k) + c_2rand_2(g_{best_i}^k - S_i^k) \quad (7)$$

여기서 V_i 는 해당 평면의 속도 벡터를 의미하며 각각의 파티클마다 최적의 속도벡터를 구하기 위해 자신이 경험한 최고의 위치인 pb_{est} 와 해당 집단이 경험한 최고의 위치인 g_{best} 를 기록하여 적용한다.

해 탐색과정에서 가중치 함수인 w 는 Equation (8)에 따라 선형적으로 변화되며 계산된다. Equation (8)에서 $iter$ 는 현재 탐색 횟수이며, W_{iter} 는 최대 탐색 횟수를 의미한다.

결과적으로 최종적으로 생성된 g_{best} 가 최적의 위치정보를 가진 최적해가 되며, g_{best} 를 이루는 a, b, c 의 값이 최종적으로 구하고자 하는 평면의 파라미터가 된다.

$$W = W_{max} - \left(\frac{W_{max} - W_{min}}{W_{iter}} \right) * iter \quad (8)$$

PSO를 이용하여 얻어진 여러 개의 평면에서 최적의 평

면을 구하기 위해, 후보 평면 파라미터를 에너지 최적화 문제[14, 15]로 해석한다. 즉 해당 평면의 에너지 함수를 Equation (9)와 같이 정의하고, 전체 에너지 E(f)를 최소화시키는 평면 f를 최고의 해로 선택하는 방법이다.

$$E(f) = E_{data}(f) + E_{smooth}(f) \tag{9}$$

Equation (9)에서 E_{data}는 세그먼테이션을 위해 각각의 평면 비용으로 표현한 에너지값으로 Equation (10)으로 정의한다.

$$E_{data}(f) = \sum_{s \in R} C(S, f(s)) \tag{10}$$

$$C(S, P) = \sum_{(x,y) \in S} |ax_i + by_i + d|$$

또한, E_{smooth}는 서로 다른 시차 평면이 인접한 세그먼트와 겹치거나 일치할 경우 이에 따른 값을 적용한 것으로 Equation (11)로 정의한다.

$$E_{smooth}(f) = \begin{cases} \sum_{(s,s')} D(f(s), f(s')), & \text{if } f(s) = f(s') \\ 0, & \text{otherwise} \end{cases} \tag{11}$$

4. 실험 결과

제안된 방법의 유용성을 검증하고자 본 논문에서는 Middlebury dataset[2] 중 가장 대표적인 Tsukuba, Teddy, Cones, Venus를 이용하여 실험하였다. 이 데이터세트는 동일한 대상에 대하여 좌우 영상을 제공하며, 좌우 영상은 조정(rectification)된 상태로 제공된다. Fig. 2는 입력 원 영상의 일부이다.




Fig. 2. Original Images - (a)Tsukuba, (b) Teddy, (c) Cones, (d) Venus

입력영상 세그먼테이션 단계에서 사용한 알고리즘은 k-평균, 평균이동이다. Fig. 3은 평균이동을 사용하여 세그먼테이션 한 결과이다.

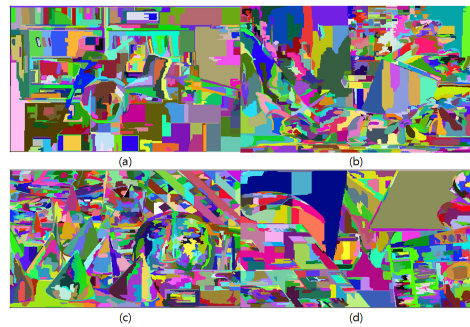


Fig. 3. Segmentation Result using Mean-shift

원 영상에서 초기 시차를 얻기 위해 우리가 사용한 방법은 FW이고, 윈도우 크기는 3×3, 5×5, 7×7, 9×9 등을 사용하였다. Fig. 4는 5×5로 구한 초기 시차 이미지이다.




Fig. 4. Initial Disparity(5×5)

세그먼트 영상과 초기 시차 이미지를 이용하여 SPPM과 MPPM을 실험하였다. MPPM의 제한 연산 시간은 SPPM의 시간을 기준으로 상대적으로 증가시키면서 수행하였다. Fig. 5는 SPPM과 MPPM을 이용한 최종 결과 영상이다. 왼쪽부터 SPPM, MPPM, ground truth 순서이다. 각각의 결과에 대한 특징 분석은 이어지는 단락에 서술하였다.

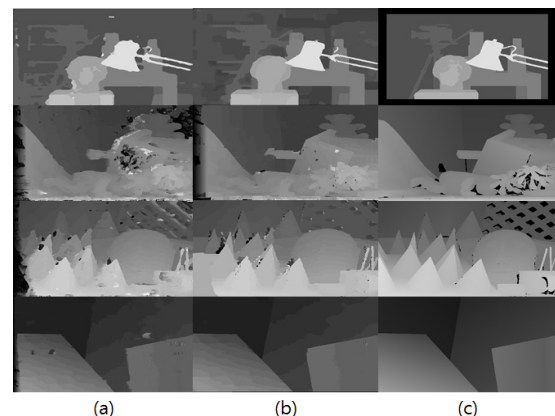




Fig. 5. Result of (a) SPPM, (b) MPPM, (c) ground truth


Fig. 6은 SPPM과 MPPM의 결과를 비교하여 그래프로 표시한 것이다. 그래프에서 x축은 SPPM의 연산시간 a를 기준으로 상대적 단위 시간으로 표시하였으며, y축은 percentage of bad matching pixels의 값을 표시하였다.




(a) Tsukuba



(b) Teddy



(c) Cones



(d) Venus

Fig. 6. Error Comparison Graph

Fig. 6을 보면 Tsukuba가 다른 3개의 영상에 비해 비교적 양호한 성능을 보이고 있는데 이는 초기 시차값이 다른 영상에 비해 단순한 면이 있었기 때문으로 예상된다. Venus의 경우는 세그먼트가 비교적 단순하고 초기 시차값도 어느 정도 확보되어 있으나, 동일 객체에 대하여 세그먼트가 세세하게 나누어져 있어 Tsukuba보다 성능이 좋지 못하다. Teddy나 Cones은 영상 자체 소스가 복잡하여 세그먼트가 많이 나타나고 굴곡 부분이 많아서 수행 시간도 상대적으로 많이 소모되고 성능도 떨어지는 특징을 보여준다. SPPM과 MPPM을 비교해보면 초기에는 SPPM이 MPPM에 비하여 좋은 성능을 보였지만, 일정 시간이 지나면 MPPM이 대체로 좋은 성능을 보여주었다. 그러나 Cones나 Teddy처럼 세그먼트 영상이 많은 경우는 MPPM의 성능 향상이 시간에 비례하여 크게 증가하지 않는 결과를 보여주었는데 이는 세그먼트의 수가 일정 수를 넘어서면 계산 시간이 기하급수적으로 증가하여 많은 후보 영상을 만들지 못했기 때문으로 예측된다.

5. 결 론

본 논문에서 우리는 스테레오 대응 문제를 해결하기 위해 세그먼트 정보와 초기 시차값을 이용하여 단일한 해만을 구하는 기존 방법을 NP-hard 문제로 시각을 전환하여 해결하는 새로운 방법을 제안하였다.

제한한 방법의 유용성을 위하여 Middlebury dataset를 이용하여 실험하고 기존 알고리즘과 비교하였다. 초기 데이터의 유용성을 고려하여 적절한 후보 해를 여러 개 구하고 각 후보들에 대한 에너지 함수를 정의하고 에너지가 최소가 되는 해를 최종 해로 선택하였다. 기존 SPPM의 방식이 새로운 MPPM에 비하여 시간이라는 장점은 있지만 제한된 시간이 어느 정도 주어지는 환경이라면 MPPM이 정확도 면에서 유용성이 높았다. 그러나 실험 영상의 환경에 따라 초기 세그먼트나 시차값이 사용하는 알고리즘에 민감한 관계로 모든 환경에서 동일하게 안정된 성능을 보장하기는 어려운 점이 있었다.

향후 과제는 MPPM을 가장 잘 적용할 수 있는 환경을 찾고 지정된 환경에서 실제 적용해보는 연구가 필요하다. 또한, MPPM의 전체 연산 시간을 좀 더 줄일 수 있는 최적화 방법에 대한 연구가 필요하다.

References

[1] D. Scharstein, R. Szeliski, "A taxonomy and evaluation of dense two-frame stereo correspondence algorithms," *IJCV*, Vol.47, No.1-3, pp.7-42, Apr., 2002.
 [2] <http://vision.middlebury.edu/stereo>
 [3] L. Shafarenko, M. Petrou, and J. Kittler, "Automatic watershed

segmentation of randomly textured color images,” *IEEE Trans. on Image Processing*, Vol. 6, No.11, pp.1530-44, 1997.

[4] Heng-Da Cheng, Ying Sun, “A hierarchical approach to color image segmentation using homogeneity, Image Processing,” *IEEE Transactions on*, Vol.9, Issue.12, pp.2071-2082, 2000.

[5] Yun-Suk Kang, Yo-Sung H, “Foreground Segmentation and High-Resolution Depth Map Generation Using a Time-of-Flight Depth Camera,” *The Journal of Korea information and communications society*, Vol.37C, No.09, 2012.

[6] Daolei Wang, Kah Bin Lim, “A New Segment-based Stereo Matching using Graph Cuts,” *Computer Science and Information Technology (ICCSIT)*, 3rd IEEE International Conference on, Vol.5, 2010.

[7] Z. Wang, Z. Zheng, “A region based stereo matching algorithm using cooperative optimization,” *CVPR*, 2008.

[8] Arti Khaparde, Apurva Naik, Manini Deshpande, Sakshi Khar, Kshitija Pandhari, and Mayura Shewale, “Performance Analysis of Stereo Matching Using Segmentation Based Disparity Map,” *ICDT*, 2013.

[9] Li Hong, Chen, George, “Segment-based stereo matching using graph cuts,” *CVRP*, IEEE, Vol.1, 2004.

[10] A. Klaus, M. Sormann, and K. Karner, “Segment-based stereo matching using belief propagation and a self-adapting dissimilarity measure,” *ICPR*, 2006.

[11] Uyeol Park, Sunghoon An, “A study on Optimization Model of Time-Cost Trade-off Analysis using Particle Swarm Optimization,” *Journal of The Korea Institute of Building Construction*, Vol.8, No.6, 2008.

[12] Youngho Lee, “Design of Multiplier-less 2D State Space Digital Filters Based on Particle Swam Optimization,” *The Korean Institute of Communications and Information Sciences*, Vol.17, No.4, 2013.

[13] A. Khaparde, A Naik, M. Deshpande, S. Khar, K. Pandhari, and M. Shewale, “Performance Analysis of Stereo Matching Using Segmentation Based Disparity Map,” *ICDT 2013: The Eighth International Conference on Digital Telecommunications*, 2013.

[14] R. Szeliski, R. Zabih, D. Scharsein, O.Veksler, V. Komogorov, A. Agarwala, M. Tappen, and C. rother, “A comparative Study of Endergy Minimization Methods for Markov Random Fields whtith Smoothness-Based Priors,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.30, No.6, pp.1068-1080, Jun., 2008.

[15] Xiaofei Huang, “Cooperative Optimization for Energy Minimization: A Case Study of Stereo Matching,” [Internet] <http://arxiv.org/abs/cs/0701057v1>, 2007.

[16] D. Comaniciu, P. Meer, “Mean shift: a robust approach toward feature space analysis,” *PAM IEEE Transaction*, Vol. 24, pp. 603-619, 2002.

[17] H. Tao, H. S. Sawhney, and R. Kumar, “A Global Matching Framework for Stereo Computation,” *Proc. Int'l Conf. Computer Vision*, 2001.

[18] Kah Bin Lim, Daolei Wang, “A New Segment-based Stereo Matching using Graph Cuts,” *Computer Science and Information Technology(ICCSIT)*, IEEE International Conference, Vol.5, pp.410-416, 2010.



김 현 정

e-mail : nygirl@konkuk.ac.kr

2000년 건국대학교 전산학과(학사)

2002년 건국대학교 컴퓨터공학과(석사)

2002년 정보보호기술 R&D팀 근무

2006년 포스데이터 보안운영팀 근무

2010년~현 재 건국대학교 컴퓨터공학과

박사과정

관심분야: 인공지능, 정보보안, 영상처리



원 일 용

e-mail : clccclcc@naver.com

1998년 경원대학교 전자계산학과(학사)

2000년 건국대학교 컴퓨터공학과(석사)

2007년 건국대학교 컴퓨터공학과(박사)

2008년~현 재 서울호서전문학교 사이버

해킹보안과 교수

관심분야: 인공지능, 정보보안, 영상처리



이 창 훈

e-mail : chlee@konkuk.ac.kr

1977년 연세대학교 수학과(학사)

1980년 한국과학기술원 전산학과(석사)

1993년 한국과학기술원 전산학과(박사)

1996년~2002년 건국대학교 정보통신원장

1980년~현 재 건국대학교 컴퓨터공학과

교수

관심분야: 인공지능, 정보보안, 운영체제