

논문 2011-48CI-2-6

이미지의 깊이 추정을 위한 유전 알고리즘 기반의 특징 축소

(Genetic Algorithm Based Feature Reduction For Depth Estimation Of Image)

신 성 식*, 권 오 봉**

(Sung-Sik Shin and Ou-Bong Gwun)

요 약

본 논문에서는 한 장의 이미지에서 학습을 통하여 영역 별 깊이 정보를 추정할 때 사용되는 특징 정보를 유전 알고리즘 (Genetic Algorithm)을 기반으로 축소하고 깊이 정보 추정 시간을 단축하는 방법에 대해서 기술 한다. 깊이 정보는 이미지의 에너지 값과 텍스처의 기울기 등을 특징으로 생성하여 특징들의 관계를 기반으로 추정 된다. 이 때 사용되는 특징의 차원이 크기 때문에 연산시간이 증가하고 특징의 중요성을 판단하지 않고 사용하여 오히려 성능에 나쁜 영향을 미치기도 한다. 이에 따라 중요성을 판단하여 특징의 차원을 줄일 필요가 있다. 본 논문에서 제안한 방법을 미국 스탠포드(Stanford)대학에서 제공하는 벤치마크 데이터로 실험한 결과, 특징의 추출과 깊이 추정 연산 시간이 모든 특징을 사용하는 방법에 비하여 약 60%정도 향상되고 정확도가 평균 0.4%에서 최대 2.5% 향상 되었다.

Abstract

This paper describes the method to reduce the time-cost for depth estimation of an image by learning, on the basis of the Genetic Algorithm, the image's features. The depth information is estimated from the relationship among features such as the energy value of an image and the gradient of the texture etc. The estimation-time increases due to the large dimension of an image's features used in the estimating process. And the use of the features without consideration of their importance can have an adverse effect on the performance. So, it is necessary to reduce the dimension of an image's features based on the significance of each feature. Evaluation of the method proposed in this paper using benchmark data provided by Stanford University found that the time-cost for feature extraction and depth estimation improved by 60% and the accuracy was increased by 0.4% on average and up to 2.5%.

Keywords : Depth Estimation, Feature Reduction, Genetic Algorithm, Learning

I. 서 론

본 논문은 학습을 통하여 정지 이미지의 영역 별 깊이를 추정하는데 사용되는 특징 벡터의 차원을 유전 알고리즘 기반^[2~3]으로 축소하는 방법에 대해서 기술한다.

정지 이미지에서 깊이 정보를 추정하는 연구는 로봇 비전, 컴퓨터 그래픽스^[4], 지능형 자동차^[5] 등 여러 분야에서 필요로 하는 기술로 다양한 연구가 이루어진다.

깊이 정보를 추정하는 방법은 이미지에서 물체의 꼭지점, 외부 외곽선 등의 정보를 수학적^[6]으로 계산하는 방법 및 이미지의 변화, 기울기와 같은 특징 정보를 이용하는 방법 등이 있다. 최근에는 영상의 특징 정보와 실제 깊이 정보를 이용한 학습 방법^[7]이 연구되고 있다.

학습 방법을 이용한 깊이 추정 방법은 다양한 필터를 통하여 추출된 많은 특징 정보들을 사용하지만 특징의 중요성을 판단하지 않고 사용 된다. 일반적으로 특징의 개수가 많아지면 정보가 많아 성능이 좋아진다고 생각할 수 있다. 하지만 특징의 개수가 많아지면 불필요한 특징 정보들로 인해 성능에 악영향을 미치기도 하고 연산에 필요한 시간이 증가한다.

* 학생회원, ** 정회원, 전북대학교 컴퓨터공학부
(Division of Computer Science and Engineering,
Chonbuk National University)
접수일자: 2010년11월16일, 수정완료일: 2011년3월4일

이러한 문제를 해결하기 위한 최적화 분석 방법 중 대표적으로 PCA(Principle Component Analysis)가 있다. PCA는 고차원의 정보를 최대한 유지하면서 저차원으로 차원을 축소하지만 모든 특징을 추출 한 후에 차원을 축소한다. 결과적으로 오차율을 줄일 수는 있지만 연산 시간을 단축 할 수는 없다.

본 논문에서는 유전 알고리즘(Genetic Algorithm)을 이용하여 특징을 축소하는 방법으로 이 문제를 해결 하는 방법을 제안한다. 스텐포드의 벤치마크 데이터를 이용하여 실험한 결과 특징 추출 시간 및 깊이 추정 시간이 단축 되고 PCA를 이용한 방법^[1, 8~9]과 유사한 성능을 얻을 수 있었다.

II. 특징 벡터 추출 및 생성

사람은 한 장의 정지 이미지를 보고 거의 완벽한 깊이 정보를 추정할 수 있다. 영상의 변화, 기울기, 물체의 조합^[10]과 미리 알고 있는 물체의 크기, 형태 등의 정보를 이용하기 때문이다.

하지만 컴퓨터는 사람과 같은 깊이 추정이 어려우며 이미지내의 특징 정보를 이용해야 한다. 물체의 윤곽선 같은 정보는 이미지를 작은 영역으로 분할하였을 때 존재하지 않은 영역이 발생 할 수 있으므로 본 논문에서는 작은 영역에서도 공통적으로 특징을 추출할 수 있는 이미지의 에너지 값과 텍스처 기울기 값을 이용 한다.

2.1 특징의 추출

이미지에서 특징을 추출하기 위해 색상 공간을 RGB에서 Y (Intensity Channel) $CbCr$ (Color Channel)로 변환한다. 이미지에서 특징을 추출 할 때 색상 정보는 대부분 사용하지 않기 때문이다.

변환 된 이미지의 Y 영역에서 Laws' 마스크 필터와 텍스처 기울기 필터^[12]를 이용하여 에너지 값들을 계산하여 특징으로 선택 한다.

Laws' 마스크는 이미지에서 특정 정보를 추출하기 위해서 만들어진 Laws' 벡터의 조합으로 생성하고 L




그림 1. Laws' 마스크와 텍스처 기울기 필터
Fig. 1. Laws' mask and texture gradient filters.

$L'_3 \times L_3$	$L'_3 \times E_3$	$L'_3 \times S_3$
$E'_3 \times L_3$	$E'_3 \times E_3$	$E'_3 \times S_3$
$S'_3 \times L_3$	$S'_3 \times E_3$	$S'_3 \times S_3$

그림 2. 2차원 Laws' 마스크
Fig. 2. 2-Dimensional Laws' Masks.

(Level), E (Edge), S (Spot), R (Ripple), W (Wave) 중에 L , E , S 만을 사용 했다. 또한 Laws' 벡터는 3차원 벡터를 사용 했다. ($L_3 = [1 \ 2 \ 1]$, $E_3 = [-1 \ 0 \ 1]$, $S_3 = [-1 \ 2 \ -1]$)

Laws' 마스크와 텍스처 기울기 필터를 이용하여 추출 된 특징에 첫 번째 Laws' 마스크 필터를 이용하여 $CbCr$ 영역의 에너지 값을 각각 추가 특징으로 추출하여 총 17개(Y 영역 : Laws' 마스크 9개, 기울기 필터 6개, Cb 영역 : $L'_3 \times L_3$ 마스크 1개, Cr 영역 : $L'_3 \times L_3$ 마스크 1개)의 특징 정보를 가진다.

이렇게 필터 처리 된 이미지를 305x55(실제 깊이 지도의 해상도)의 작은 영역(patch)단위로 분할하고 식(1)과 같이 각 영역 별 특징을 추출 한다.

$$E_i(n, k) = \sum_{(x, y) \in patch(i)} |F_n(x, y)|^k \quad (1)$$

$F_n(x, y)$ 는 n 번째 필터를 통해 구해진 에너지 값이고 $k = 1, 2$ 로 순수 에너지 값과 에너지 값의 제곱을 의미한다. 즉, 한 영역의 에너지 값은 필터를 적용하여 나온 결과에서 영역에 포함되는 픽셀 값들의 합이고 이 에너지 값이 특징이 된다.

2.1 특징의 추출

분할 된 각 영역에는 기본적으로 2.1절의 방법으로 추출 된 34개의 특징 존재한다.

34개의 특징은 작은 영역의 정보만을 포함하고 있기 때문에 전역적인 정보를 포함하기 위해 <그림 3>과 같이 영역의 크기(1x, 3x, 9x)를 달리한 이웃하는 영역(상, 하, 좌, 우)의 특징을 추가로 사용^[11]한다.

즉, 한 영역(A0)의 특징 정보는 A0영역의 특징 34개와 A1(상), A2(하), A3(좌), A4(우)영역의 특징 136개에 영역의 크기를 변경하여 다시 B0의 특징 및 B1, B2, B3, B4의 특징, 한 번 더 영역의 크기를 변경하여 C0, C1, C2, C3, C4의 특징을 포함하여 총 510개의 특징을 가지게 된다.

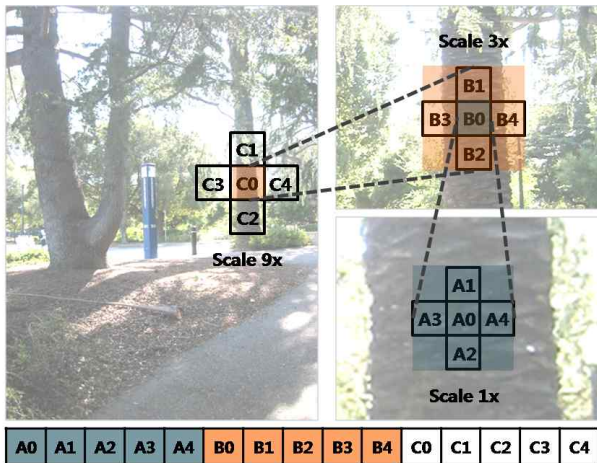


그림 3. 한 영역의 특징은 이웃영역의 특징을 포함
 Fig. 3. Features of a patch includes neighbors features.

III. 특징 공간 축소

3.1 유전 알고리즘

유전 알고리즘은 최적화 문제를 해결하는 기법의 하나로 전역 최적화 기법이다. 생물의 진화를 모방한 진화 연산의 대표기법으로 생명체에 적용되는 많은 방식을 차용하며 선택, 교차, 변이, 대치 등 몇 가지 주요 연산^[2]으로 구성 된다.<그림 4>

선택 연산은 자식해를 생성하기 위해 필요한 부모해를 선택 한다. 선택 방법에는 품질 기반, 균등 비례, 순

```

n개의 초기 염색체 생성;

repeat
{
    for i = 1 to k
    {
        부모 염색체 Parent1, Parent2선택;
        Childi = 교차( Parent1, Parent2 );
        Childi = 변이( Childi );
    }
    Childi ~ Childk를 k개의 염색체와 대치;
} until( 종료 조건 );

남은 염색체 중 최상의 염색체를 return;
    
```

그림 4. 유전 알고리즘의 일반적인 구조
 Fig. 4. General structure of Genetic Algorithm.

위 기반 선택 등이 있다. 교차 연산은 선택 되어진 부모해를 이용하여 자식해를 생성 한다. 일반적으로 두 개의 부모해를 교배하여 자식해를 생성하게 된다. 변이 연산은 유전자의 교배 뿐 아니라, 하나의 유전자가 직접적으로 변이를 일으켜서 주어진 환경에서 살아남을 확률을 높게 된다. 대치 연산은 교차, 변이 등의 연산을 거쳐 새롭게 생성 된 자식해를 기존의 해 중에서 품질이 좋지 않은 해와 대치한다.

3.2 유전 알고리즘의 적용

본 논문에서는 이미지의 깊이 추정에 순위 기반 선택 방법을 사용 한다. 품질 기반 선택 방법의 경우 시간이 지남에 따라 적합도가 거의 비슷해지므로 랜덤 기반 선택에 가까워지기 때문에 순위 기반 선택 방법을 이용하여 품질 순위를 기반으로 정렬하고 선택 적합도를 배정 한다. 품질은 4.2절의 오차율을 이용하였으며, 적합도 배정 방법은 식(2)와 같다.

$$f_i = \max + \frac{(i-1) \times (\min - \max)}{n-1} \quad (2)$$

f_i 는 i 번째 품질을 가지는 유전자의 적합도를 나타내며 \min 은 사용자 정의의 최소 적합도, \max 는 사용자 정의 최대 적합도, n 은 유전자의 개수를 나타낸다.

<그림 5>와 같이 \max 와 \min 값을 이용하여 선택 압을 조절하면 유전자들의 적합도는 \max 와 \min 사이에 균일한 간격으로 분포되고 품질이 좋을수록 높은 적합도를 가지게 된다.

각 유전자의 적합도가 결정되면 <그림 6>와 같이 교차 연산을 위한 부모 유전자를 선택 한다.

순위 기반 선택의 적합도 배정




그림 5. 순위 기반 선택의 적합도
 Fig. 5. Ranking selection based fitness.

```

position = random( 0, SumOfFitnesses );
sum = 0;
for i = 0 to n - 1
{
    sum = sum + fi;

    if( position < sum )
        return i;
}

```

그림 6. 교차 연산을 위한 부모 유전자의 선택 방법
Fig. 6. Method of parents selection for crossover.

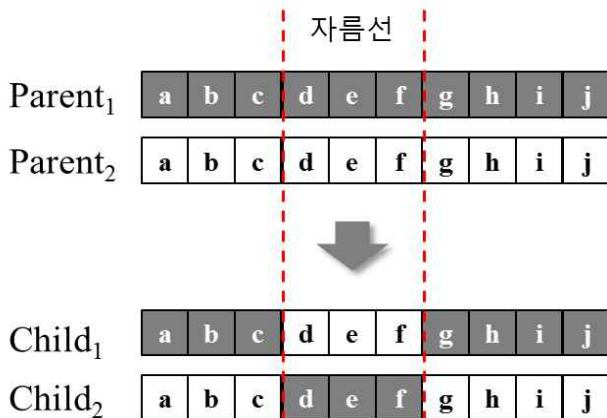


그림 7. 다점 교차 예제
Fig. 7. Example of multi-point crossover.

두 개의 부모 유전자 Parent₁, Parent₂가 선택되면 교차 연산을 한다. 교차 연산은 다점 교차 연산을 이용하여 자름선의 수는 1~4개를 각각 적용하여 실험 하였다.

다점 교차는 <그림 7>과 같이 자름선이 2개일 경우 Child₁의 첫 번째 영역은 Parent₁, 두 번째 영역은 Parent₂, 세 번째 영역은 Parent₁의 염색체를 가지고 Child₂는 그 반대의 염색체를 가지게 한다. 이 때, 자름선의 위치는 중복되지 않으면서 랜덤하게 생성 한다.

다점 교차를 통해 생성된 자식 유전자는 약 5~23% (1~4개 염색체) 확률로 염색체를 변이 한다. 교차 및 변이 연산을 거쳐 최종 생성된 자식 유전자는 초기 유전자 집단 내에서 품질이 좋지 않은 유전자와 대치^[2~3]한다.

여러 가지 방법의 대치 연산이 있지만 본 논문에서는 엘리티즘에 입각하여 품질이 좋지 않은 유전자와 대치 하였으며, 설익은 수렴이 발생하지 않도록 선택 연산과 교차 연산에 다양한 입력 파라미터를 통해 실험 했다.

3.3 특징 벡터 재생성

유전 알고리즘을 이용하여 특징을 분별 할 때 각 특징은 몇몇 특징들과 2.1절의 특징 생성 방법에 근거하여 상호 연관성을 가지고 있기 때문에 전체 510개의 특징을 알고리즘에 적용하면 효과가 미비하고 수렴 시간이 오래 걸리게 된다.

예를 들어 1번, 18번, 35번, ... , 494번 특징들은 같은 필터를 사용하여 추출된 특징이다. 이 중에 한 개의 특징이라도 포함되면 해당 필터 연산을 해야 하므로 유전 알고리즘의 효과를 극대화하기 힘들고 특징의 차원이 커지게 된다.

이러한 문제를 해결하기 위해 초기 17개의 필터를 사용하여 추출된 특징들에 유전 알고리즘을 적용하고 그 결과 특징들을 사용하여 2.2절과 같이 최종 특징 벡터를 생성 한다. 따라서 유전 알고리즘을 통해 하나의 특징이 선택되지 않으면 전체 특징 벡터에서 30개의 특징이 줄어들게 된다.

IV. 실험 및 결과

4.1 실험 데이터

실험 데이터는 미국 스탠포드(Stanford) 대학에서 제공하는 3차원 레이저 스캐너를 이용하여 생성한 깊이 데이터를 이용하였다. 데이터는 총 400개의 1704x2272 해상도를 가지는 이미지와 305x55 해상도를 가지는 깊이 지도의 쌍으로 이루어져 있다. 이 중 300개를 학습 데이터로 사용하고 100개를 테스트 데이터로 사용하여 실험 하였다.

4.2 오차율 비교

오차율은 실제 깊이 지도에서 추정된 깊이 정보를 비교하여 측정 하였으며, 모든 영역에서의 깊이 정보 차이의 합을 이미지 전체의 깊이 오차율로 사용 한다.

$$Error = \sum_{r=1}^{nrow} \sum_{c=1}^{ncol} |d_{rc} - w_r x_{rc}| \quad (3)$$

d_{rc} 는 영역의 실제 깊이를 의미하고 w_r 은 각 row별로 학습을 통해 구해진 변환 벡터를 의미한다. 그리고 x_{rc} 는 해당 영역의 특징 벡터를 의미하며 III장에서와 같이 유전 알고리즘을 사용하여 선택된 특징들을 이용하여 생성된 특징 벡터이다.

4.3 실험 방법

실험을 위하여 II장에서와 같이 이미지를 여러 개의 작은 영역으로 분할하였으며, 각 영역마다 Laws' 마스크와 텍스처 기울기 필터를 사용하여 특징을 추출한다.

초기에 생성된 17개의 특징들을 유전 알고리즘을 사용하여 중요 특징들을 선별 한다. 이 때, 유전 알고리즘은 초기 20개의 유전자를 랜덤으로 생성하고 평가를 통해 각각 품질 값을 갖게 하였다. 품질 평가를 하기 위하여 최소자승법(Iteratively Re-weighted Least Squares)을 이용한 학습 방법^[13]을 사용했다.

3.2절과 같이 부모 유전자를 선택하고, 자식 유전자를 생성, 변이시킨 후 최종 자식 유전자를 생성한다. 생성된 자식 유전자를 기반으로 특징 벡터를 생성한 후 4.2절과 같이 오차율을 비교하여 품질 값을 평가 한다.

만족할 만 한 품질이 나오면 프로세스를 종료하고 그렇지 않으면 자식 유전자를 부모 유전자들 중에 품질이 좋지 않은 유전자와 대치하고 반복하여 실행 한다.

실험 과정은 다양한 상황을 고려하기 위해 다음과 같은 입력 파라미터를 토대로 여러 번 실험 했다.



그림 8. 유전 알고리즘을 이용한 실험 과정
Fig. 8. Experiment process using Genetic Algorithm.




그림 9. 다양한 입력 파라미터
Fig. 9. Various input parameters.

4.4 결과

실험 결과 입력 파라미터를 다양하게 하였을 경우

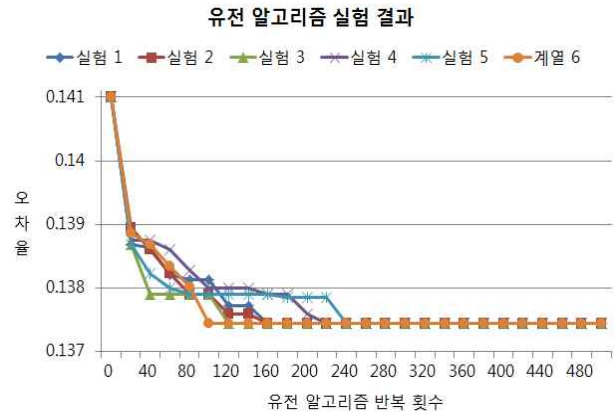


그림 10. 유전 알고리즘 실험 결과
Fig. 10. Experiment results of Genetic Algorithm.

표 1. 평균 오차율
Table 1. Average error rates.

	Error rate
Full Feature Vector	0.14109
PCA (200-FV)	0.13742
Genetic Algorithm	0.13745

표 2. 특징 추출 시간에 대한 연산 시간
Table 2. Time cost about extraction of feature vector.

	Time (Sec)
Full Feature Vector	1.809
PCA (200-FV)	2.571
Genetic Algorithm	0.702

표 3. 깊이 추정에 대한 연산 시간
Table 3. Time cost about estimation of depth.

	Time (Sec)
Full Feature Vector	0.1453
PCA (200-FV)	0.0615
Genetic Algorithm	0.0672

<그림 10>과 같이 수렴하는 시간의 차이만 있을 뿐 같은 구간에서 수렴하는 것을 확인 할 수 있었으며 수렴시 선택된 특징 값은 동일하였다.

최종 선택된 특징들을 바탕으로 생성한 특징 벡터를 이용하여 오차율, 특징의 추출 연산 시간, 깊이 추정 연산 시간을 각각 비교했을 때 오차율은 PCA방법과 유사

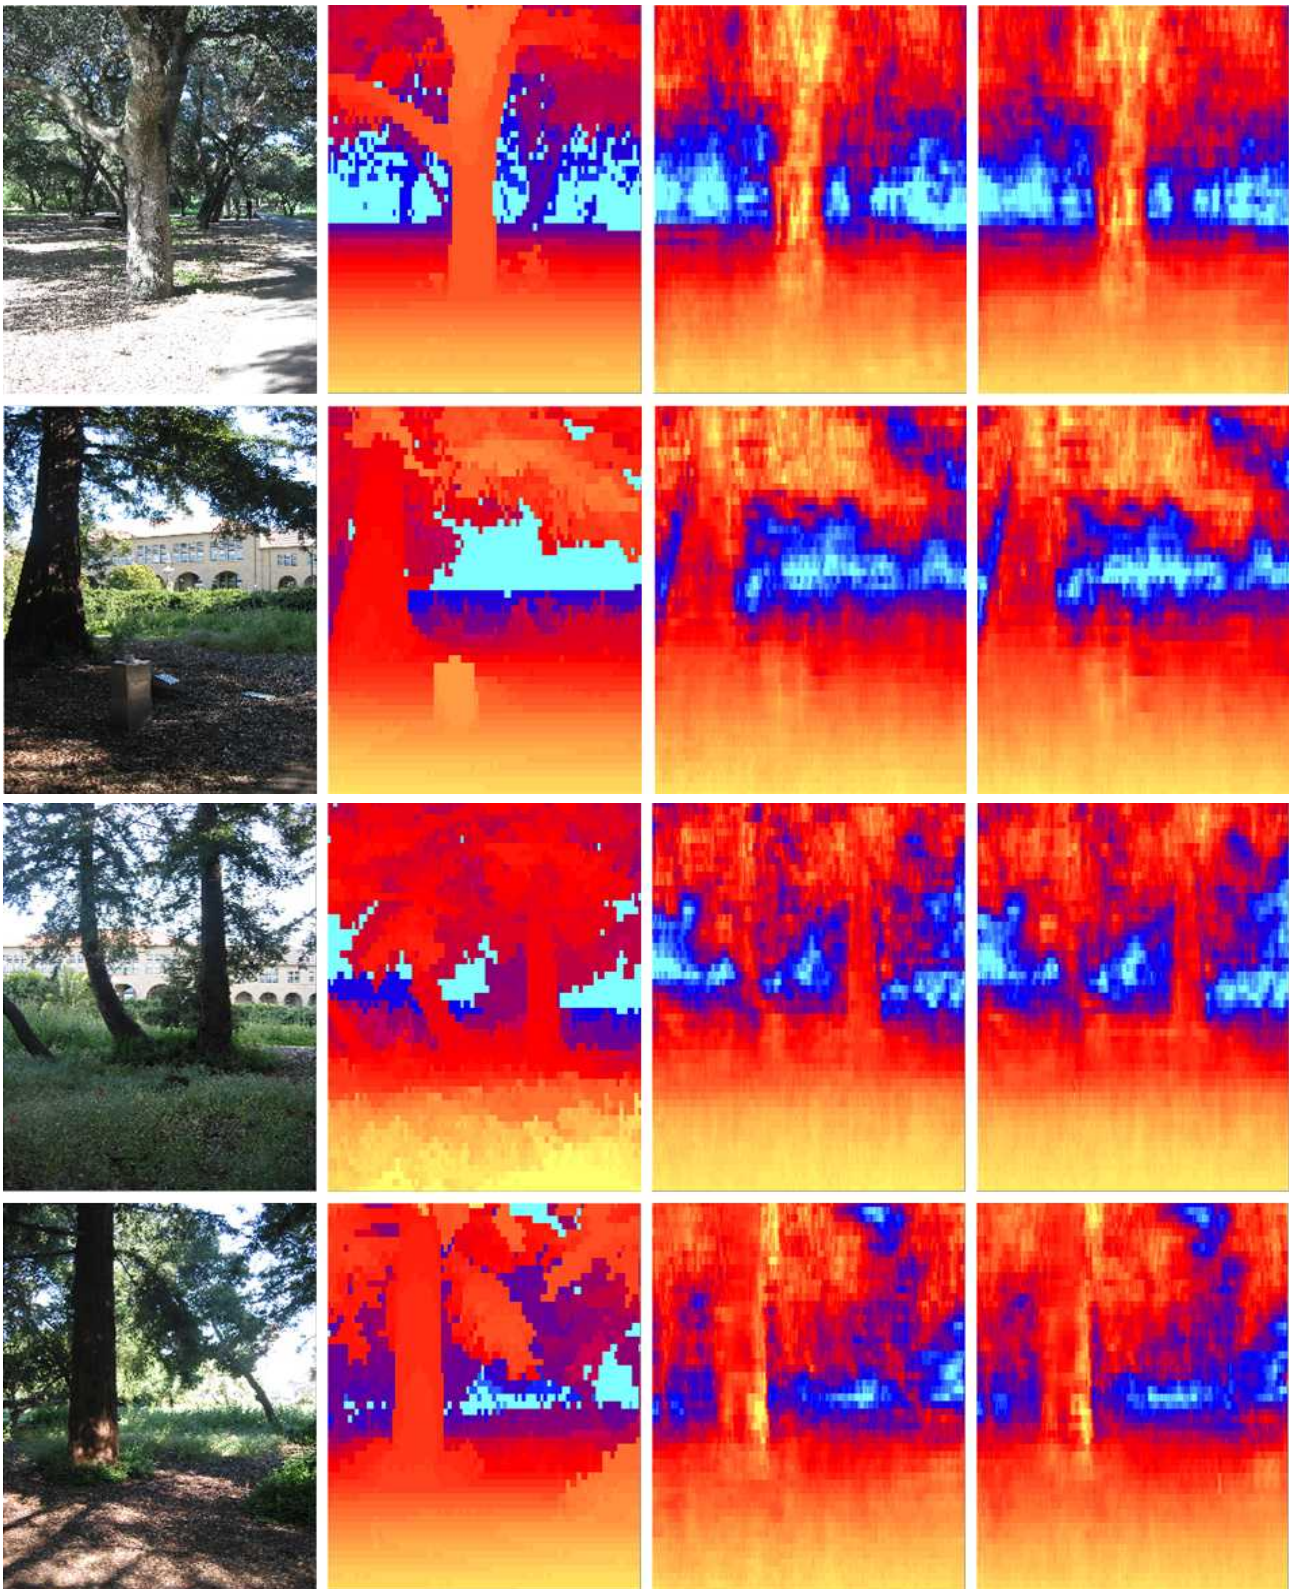


그림 11. 실험 결과 :

(첫 번째)원본 이미지, (두 번째)깊이 지도, (세 번째)PCA를 이용한 결과, (네 번째)유전 알고리즘을 이용한 결과

Fig. 11. A experiment results : (column 1)original image, (column 2)depthmap, (column 3)result using PCA, (column 4)result using Genetic Algorithm.

하게 평균 0.4%에서 최대 2.5%향상 되었다.

특징을 추출하는데 필요한 연산 시간은 모든 특징을 이용하는 기존의 방법과 PCA를 이용한 방법보다 약60~70% 단축되었으며, 깊이를 추정하는데 필요한 시간도 기존의 방법에 비해 60%정도 단축 되었다.<표2~3> 결과적으로 특징 공간을 510차원에서 210차원으로 줄이면서 오차율은 유지하고 연산 시간을 크게 단축 할 수 있었다.

V. 결 론

본 논문에서는 한 장의 이미지에서 깊이를 추정 할 때 사용되는 특징 공간의 차원을 유전 알고리즘을 통하여 축소하는 방법에 대하여 제안하고 실험을 통하여 평가하였다.

중요하지 않은 특징들을 사전에 파악하여 제거함으로써 모든 특징 벡터를 사용한 방법에 비하여 특징 추출에 필요한 연산 시간을 60% 단축하고, 깊이 추정 시간 또한 60% 단축 되었다. 또한, 오차율이 평균 0.4%에서 최대 2.5%가 향상되었음을 확인하였다. 오차율 결과는 PCA방법을 이용했을 때와 큰 차이는 없지만 연산 시간에서는 많은 차이가 있었다.

제안한 방법으로 연산 시간의 단축(자원 저사용)이 가능하여 모바일과 같은 저성능 기기에서의 활용이 가능할 것으로 기대 된다.

참 고 문 헌

- [1] 신성식, 권오봉, “깊이 추정을 위한 PCA기반의 특징 축소,” *전자공학회논문지*, 제47권 CI편, 제3호, 29-35쪽, 2010년 5월
- [2] 문병로, “*유전알고리즘*,” 두양사, 39-68쪽, 2003년.
- [3] D. E. Goldberg, “*Genetic Algorithms in Search, Optimization, and Machine Learning*,” Addison Wesley, 1989.
- [4] T. Nagai, T. Naruse, M. Ikehara, and A. Kurematsu, “HMM-based surface reconstruction from single images,” *In Proc IEEE Int’l Conf Image Processing*, Vol. 2, pp. 561-564, 2002.
- [5] J. Michels, A. Saxena, and A. Y. Ng, “High speed obstacle avoidance using monocular vision and reinforcement learning,” *International conference on Machine learning*, Vol. 17, pp. 593-600, Bonn, Germany, August 2005.
- [6] D. Scharstein and R. Szeliski, “A taxonomy and

- evaluation of dense two-frame stereo correspondence algorithms,” *International Journal of Computer Vision*, Vol. 47, pp. 7-42, 2002.
- [7] A. Saxena, S. H. Chung, and A. Ng, “Learning depth from single monocular images,” *Advances in Neural Information Processing Systems*, Vol. 18, pp. 1161-1168, 2006.
- [8] M. Tipping and C. Bishop, “Probabilistic principal component analysis,” *Journal of the Royal Statistical Society*, Vol. 61, No. 3, pp. 611-622, 1999.
- [9] A. V. D. Linde, “PCA-based dimension reduction for splines,” *Journal of Nonparametric Statistics*, Vol. 15, pp. 77-92, 2003.
- [10] B. Wu, T. L. Ooi, and Z. J. He, “Perceiving distance accurately by a directional process of integrating ground information,” *Letters to Nature*, Vol. 428, pp. 73-77, 2004.
- [11] X. He, R. S. Zemel, and M. A. Carreira-Perpinan, “Multiscale conditional random fields for image labeling,” *In Proc. CVPR*, Vol. 2, pp. 694-702, 2004.
- [12] S. Das and N. Ahuja, “Performance analysis of stereo, vergence, and focus as depth cues for active vision,” *IEEE Trans Pattern Analysis & Machine Intelligence*, Vol. 17, pp. 1213-1219, 1995.
- [13] R. Wolke, “Iteratively reweighted least squares : A comparison of several single step algorithms for linear models,” *BIT Numerical Mathematics*, Vol. 32, No. 3, pp. 506-524, 1992.

— 저 자 소 개 —



신 성 식(학생회원)

2006년 전주대학교 컴퓨터공학과
학사 졸업

2008년 전북대학교 컴퓨터공학과
석사 졸업

2008년 전북대학교 컴퓨터공학과
박사 재학

<주관심분야 : 컴퓨터그래픽스, 인공지능, 패턴인식, 소프트웨어공학, 시뮬레이션>



권 오 봉(정회원)

1980년 고려대학교 전기공학과
학사 졸업

1983년 고려대학교 전기공학과
석사 졸업

1993년 일본구주대학교
이공학연구과 박사 졸업

1992년~1993년 일본구주대학교 정보공학과 조수

1994년~현재 전북대학교 전자정보공학부 교수

<주관심분야 : 컴퓨터그래픽스, 사이언티픽 비주얼라이제이션>