

論文98-35C-9-10

## 서로 다른 진화 특성을 가지는 부집단들을 사용한 새로운 하이브리드 진화 프로그래밍 기법과 카메라 보정 응용

(A New Hybrid Evolutionary Programming Technique  
Using Sub-populations with Different Evolutionary  
Behaviors and Its Application to Camera Calibration)

趙顯中\*, 吳世泳\*, 崔斗鉉\*\*

(Hyeon-Joong Cho, Se-Young Oh, and Doo-Hyun Choi)

### 요약

실수형 최적화 문제의 전역 최적해를 빠르고 정확하게 찾을 가능성을 높이기 위해, 서로 다른 진화특성을 가지는 여러 부집단들을 사용한 새로운 하이브리드 기법이 제안된다. 제안된 알고리듬은 세 개의 부집단을 사용하는데, 복잡한 적합도 함수를 가지는 문제에서 좋은 성능을 보이는 NPOSA 알고리듬이 두개의 부집단에 적용되고, 진화 방향과 크기가 조절되는 자기 적응 진화 알고리듬이 나머지 하나의 부집단에 적용되었다. 각 부집단들은 서로 다른 방법으로 진화하며 부집단들간의 상호교류를 통해 전역 최적해로 빠르게 도달하게 한다. 이 기법의 효율성은 몇 개의 표준 테스트 문제들을 사용하여 검증하였다. 마지막으로, 제안한 알고리듬이 실제 문제에 적용 가능함을 보이기 위해 카메라 파라메터의 최적값을 찾는 문제에 적용하였다. 보정 블럭에서 측정된 특징점들을 사용하여 오차 함수를 정의한 후, 하이브리드 방법이 그 오차 함수를 최소화하는 카메라 파라메터의 값을 찾을 수 있음을 보였다.

### Abstract

A new hybrid technique using several sub-populations having completely different evolutionary behaviors is proposed to increase the possibility to quickly find the global optimum of continuous optimization problem. It has three sub-populations. Two NPOSA algorithms showing good performance in the problem having a rugged fitness function are applied to two sub-populations and a self-adaptive evolutionary algorithm to the other sub-population. Sub-populations evolve in different manners and the interaction among these sub-populations lead to the global optimum quickly. The efficiency of this technique is verified through benchmark test functions. Finally, the algorithm with three sub-populations has been applied to seek for the optimal camera calibration parameters. After an error function has been defined using measured feature points of a calibration block, it has been shown that the algorithm searches for the camera parameters that minimize the error function.

\* 正會員, 浦項工科大學校 電子電氣工學科  
(Dept. of Electronic and Electrical Engineering,  
Pohang University of Science and Technology)  
\*\* 正會員, 慶北大學校 電子電氣工學部  
(School of Electronic and Electrical Engineering,

Kyungpook National University)  
※ 본 논문은 1997년 서울대학교 제어 계측 신기술 연구  
센터의 연구 기금에 의해 연구되었음.  
接受日字: 1998年3月23日, 수정완료일: 1998年8月24日

## I. 서 론

강건한 성능을 발휘하는 최적해 탐색 알고리듬에 대한 연구는 계획(planning), 설계(design), 모사(simulation and identification), 제어(control), 분류(classification) 등의 다양한 분야에서 원하는 목적을 만족하기 위해 꾸준히 계속되어 왔다<sup>[1]</sup>. 많은 다양한 탐색 알고리듬 중 진화 알고리듬은 전통적인 방법에 비해 비선형적이고, 미분이 불가능하거나 힘들며, 많은 극값을 가지는 문제에 좋은 성능을 보여왔으며, 특정 문제에 대한 사전 지식을 필요로 하지 않으므로 많은 문제에 효과적이고 일반적으로 적용될 수 있는 장점을 가지고 있다. 그러나, 진화 알고리듬 역시 초기 수렴 등의 문제점을 안고 있으며 이를 해소하고 좀 더 최적해에 가까운 해를 빠르고 정확하게 찾으려는 많은 시도가 있었다. 진화 연산이 생물의 진화 과정을 모방한 것과는 달리 시뮬레이티드 어닐링(SA; Simulated Annealing)은 고체의 응고 과정을 모델링하여 이를 최적화 문제에 응용한 것으로 진화 알고리듬(GA; Genetic Algorithm)과 함께 조합형 최적화 문제나 실수형 최적화 문제에서 많이 사용되고 있다. 시뮬레이티드 어닐링은 진화 연산에서는 찾아볼 수 없는 온도 파라미터를 이용하여 개체의 선택 확률을 제어함으로써 문제 환경에 유연히 적용될 수 있게 한 것이 큰 특징이다. Cho<sup>[2]</sup> 등은 일반적인 진화 연산(EC; Evolutionary Computation)의 성능을 개선하기 위해 어닐링 알고리듬의 온도(temperature) 개념과 진화 연산의 집단(population) 개념을 사용한 NPOSA (New Population Oriented Simulated Annealing) 알고리듬을 제안한 바 있다. NPOSA 알고리듬은 시뮬레이티드 어닐링의 느린 수렴 속도를 개선할 뿐만 아니라 시뮬레이티드 어닐링에서 항상 외부 사용자가 설계해 주던 냉각 계획(cooling schedule)을 자동적으로 문제에 따라 유연하게 생성함으로써 최종해의 성능을 높일 수 있다.

다양한 모양을 지닌 모든 문제에 최적으로 적용될 수 있는 알고리듬은 존재하지 않는다. 이 때문에 여러 알고리듬의 장점을 취하고 서로의 단점을 보완하며 이를 알고리듬의 적절한 합성으로 상승효과를 기대할 수 있는 하이브리드(hybrid) 방법은 탐색 알고리듬(search algorithm) 뿐만 아니라 다른 여러 분야에서도 문제 해결의 좋은 방법이 된다. 본 논문에서는 서

로 다른 진화 형태를 가지는 알고리듬의 하이브리드를 위해 병렬 유전 알고리듬(PGA; Parallel Genetic Algorithm)의 부집단(sub-population) 개념을 도입한 부집단을 이용한 하이브리드 방법을 제안한다. 이를 위해 부집단마다 다른 진화 형태를 가지는 알고리듬을 적용하고 독립적으로 진화시키며 서로의 진화정보를 개체 이주(migration)를 통해 공유하게 한다. 이와 같이 부집단을 이용하는 하이브리드 방법은 다른 진화 형태를 가지는 부집단을 정의, 삽입함으로써 쉽게 구현할 수 있어 알고리듬의 확장이 용이한 장점이 있다.

제 2장에서는 기존의 탐색 알고리듬 중 본 논문과 관련이 있는 진화 연산과 시뮬레이티드 어닐링을 살펴보고, 부집단을 사용하는 다른 알고리듬도 살펴본다. 제 3장에서는 새로운 하이브리드 EP(Hybrid EP) 알고리듬을 제안한다. 제 4장에서는 카메라 파라메터의 보정에 대해서 설명하고, 제 5장에서 제안 알고리듬의 효용성을 보이기 위한 다양한 실험 및 그 결과를 설명한다.

## II. 탐색 알고리듬

자연의 진화 모습을 모방한 대표적인 알고리듬인 진화 알고리듬과 시뮬레이티드 어닐링 알고리듬에 대해 기술하고 이들의 장단점과 성능에 대해 간단히 살펴본다.

### 1. 진화 연산

진화 연산은 개체의 표현방법, 진화 연산자(mutation and/or recombination)의 종류, 그리고 선택(selection) 방법과 재생산 과정(reproduction mechanism)에 따라 구분할 수 있다. 미국의 Holland는 1960년대에 유전 알고리듬(genetic algorithm)을 제안하였고, De Jong은 처음으로 유전 알고리듬을 변수 최적화 문제(parameter optimization)에 적용할 수 있음을 주장하였다. 이외는 별도로, 60년대 독일에서는 Rechenberg에 의해 소개되고 Schewefel에 의해 개선, 발전된 진화 전략(ES; Evolution Strategy)이 알려지고, Fogel에 의해서 진화 프로그래밍(EP; Evolutionary Programming)이 제안된다<sup>[3]</sup>. 이를 알고리듬들은 문제의 해(solution)를 표현하는 수단으로 많은 수의 개체(individual)로 구성된 집단(popula-

tion)을 이용하고, 좀더 적합한 개체를 탐색하기 위해 확률적인 연산자를 이용한다는 점에서 공통점을 가진다. 간결하게 말하면 진화는 새로운 유전 정보의 발생과 그 정보의 평가(evaluation), 선택의 상호 결과이다. 집단 중 하나의 개체는 다른 개체와 주위 환경의 영향을 받으며, 이런 조건에서 더 우등한 개체일수록 오랜 세대동안 살아 남아 부모의 유전정보를 계승하는 자손(offspring)을 생성할 수 있는 기회를 더 많이 가지게 된다. 이는 진화과정을 통해 결국 평균 이상의 적합도를 갖는 개체들의 집단을 양성시킨다.

전형적으로 최적화 응용 문제는 주어진 조건(criterion)  $f: M \rightarrow R$  (objective function, fitness function or cost function)을 최대 또는 최소화하는 대상 시스템의 변수(free parameter)  $x \in M$ 을 찾아내는 것이 목적이다. 즉, 전역 최적해(global optimum)를 구하는 문제는  $\forall x \in M : f(x) \leq f(x^*) = f^*$ 를 만족하는 뼈터  $x^*$ 를 찾아내는 것을 그 목적으로 한다. 최적화 문제는 많은 공학, 경제, 과학 분야에서 흔히 일어나는 테 코스트, 시간, 위험도의 최소화, 또는 품질, 이익, 효율성을 최대화하는 등 여러 다른 형태를 띠게 된다. 따라서 이들의 정확한 해를 능률적으로 탐색할 수 있는 일반적인 기술 개발은 큰 의미를 지닌다.

## 2. 시뮬레이티드 어널링

1953년 Metropolis는 주어진 온도에서 원자들의 평형 상태를 모의 실험하기 위한 몬테카를로 방법(Monte Carlo method)을 제안하였다<sup>[4]</sup>. 이 방법은 임의의 온도에서 원자 구성(atomic configuration)이 볼쓰만 분포(Boltzmann distribution)를 따른다는데 기초하고 있다. 원자들의 평형 상태를 결정하는 과정은 최적화 문제에도 응용할 수 있다. 1980년대 초기에 Kirkpatrick 등은 조합형 최적화(combinatorial optimization)문제를 풀기위해 어널링의 개념을 소개하였다<sup>[5]</sup>. 이런 개념은 고체의 물리적인 어널링 과정과 조합형 최적화 문제 사이의 유사성에 그 기반을 두고 있다. 기저 상태에서 고체 입자는 매우 구조화된 격자 구조로 배열되는데, 이 상태가 바로 고체의 최소 에너지 상태이자 가장 높은 밀도 상태이다. 기저 상태는 최대 온도가 충분히 높아야 하고 냉각 속도는 충분히 느려야 한다. 냉각 속도가 충분히 늦지 않으면 즉, 급격한 고체의 냉각은 고체의 입자가 규칙적이고 견고하게 배열할 시간적 여유를 주지 못하므로 결국

고체는 비결정질의 높은 에너지 상태로 응고하게 된다. 시뮬레이티드 어널링 알고리듬은 온도를 낮추어 가면서 해에 대해 평가하는 Metropolis 알고리듬의 반복이라고 생각할 수 있다.

## 3. PGA(Parallel GA)와 CoPDEB (Co-operating Populations with Different Evolution Behavior)

PGA는 진화를 독립적으로 하는 여러 부집단을 두고 이들 사이의 통신방법을 정의한다. 격리 시간(isolation time)은 부집단이 서로 정보의 교환없이 독립적으로 진화하는 시간(generation)을 말하며, 개체 이주(migration)는 정해진 격리 시간이 지난 후, 몇 개의 개체를 부집단들이 서로 분배하는 것을 말한다. 개체의 이주에서 서로 분배할 개체의 갯수, 이주율(migration rate)과 이주 대상 개체의 선택, 그리고 개체 이주의 방법은 유전적인 다양성에 영향을 미친다. 개체 이주 모델은 계산 시간에서의 단축 뿐만 아니라 하나의 부집단을 쓰는 경우에 비해 비교적 적은 목적 함수 평가 과정을 거친다. 그래서 하드웨어적인 구현이 뒤따르지 않고 하나의 프로세서를 사용한 직렬적인 구현(pseudo-parallel)으로도 좋은 결과를 얻을 수 있다. 가장 일반적인 이주 방법으로 무제한적인 이주 방법(unrestricted migration)이 있다. 이 방법에서는 임의의 부집단으로부터 개체가 다른 모든 부집단으로의 이주가 가능하다.

유전 알고리듬(genetic algorithm)은 다른 진화 알고리듬과 마찬가지로 자연의 진화 메커니즘을 본 편 확률적인 탐색 기술이며, 많은 응용 영역에서 그 강점과 효율성을 인정받고 있다. 진화 집단은 최적값을 찾기 위해 높은 적합도를 가지는 탐색 영역을 집중적으로 탐색하며(exploitation), 재결합 연산과 돌연변이 연산으로 다른 영역의 탐색(exploration)을 위해 각 개체를 변이시킨다. 그러나, 유전 알고리듬의 경우 일반적으로 어떻게 유전 파라미터들을 정해야 하는가에 대한 명확한 설명 없이, 많은 다른 경험이나 실험으로 알고리듬의 기본 연산자나 선택 연산자들이 다양하게 제안되어왔다. 보통의 경우 유전 알고리듬의 연산자들은 적용할 문제의 요구사항이나 사용자의 경험, 또는 먼저 실험된 연구를 참조하여 결정되어지지만, Adamidis 등은 PGA의 부집단 개념을 이용하여 다양한 유전 연산자를 사용하는 여러 부집단을 독립적으로 진화시키고, 이를 사이에 유전 정보의 통신 방법을 정해

중으로써 힘든 파라메터의 결정문제를 해결하는 Co-PDEB를 제안하였다<sup>[6]</sup>. 본 논문에서는 진화 특성이 각각 다른 부집단들을 도입하여, 각각의 특성을 확인하고 이들을 통합한 새로운 알고리듬을 제안한다.

### III. 제안된 탐색 알고리듬

본 논문에서 제안하는 하이브리드 방법은 세개의 부집단을 사용한다. 각 부집단들은 다른 진화 알고리듬을 사용하는데, 이를 살펴보자. 먼저 시뮬레이티드 어널링의 독특한 파라메터인 온도를 주어진 문제에 적절하게 계획하기 위해 제안되었던 NPOSA 알고리듬을 간단히 소개한다. 실수형 최적화 문제를 풀기위해 몇 가지 돌연변이 연산자를 살펴보고 NPOSA 알고리듬에 적용하기 위한 돌연변이 연산자를 소개한다. 또한 다른 진화 특성을 보이는 탐색 알고리듬의 합성을 위해 부집단을 이용한 하이브리드 방법을 제안한다.

#### 1. NPOSA

Cho 등은 SA에 EC의 집단개념을 가미한 NPOSA (New Population-Oriented Simulated Annealing) 알고리듬을 제안한 바 있다<sup>[2]</sup>. NPOSA 알고리듬에서는 여러 개체를 이용해 SA의 탐색 시간을 더 빠르게 할 뿐 아니라, 일반적인 SA 알고리듬과는 달리, 각 개체마다 각각의 온도를 둘으로써 각 개체의 온도를 개체 스스로 판단해 적합한 자신의 온도를 결정하는 방법으로 SA에서 힘들게 여겨지던 냉각 계획의 설계를 용이하게 한다. NPOSA에서 각 개체의 온도는 지역 온도(local temperature)라고 부르는데, 이는 해당 개체의 적합도에 따라 주어지는 개체 순위(rank)를 참조하여 내부적으로 결정되어지며, 다음 세대의 선택 과정에서 선택확률을 정하는데 이용된다. 다른 개체의 적합도보다 더 낮은 적합도를 가진 개체의 경우, 그 자신의 지역 온도를 높임으로써 적합도 공간에서 더 낮은 적합도를 가지는 해로 전이할 가능성을 높인다. 그외는 반대로 상대적으로 적합도가 다른 개체보다 높은 개체의 경우, 자신의 지역 온도를 낮춘다. 이로써 높은 온도 조건에 있는 개체는 낮은 온도 조건의 개체 보다 지역 최적점로부터 벗어날 수 있는 기회가 더 많아 주어질 뿐 아니라, 개체의 높은 운동성(mobility)으로 인해 더 넓은 주위 영역을 탐색할 수 있다. NPOSA의 가장 주요한 장점은 흔히 SA 알고리듬에

서 외부적으로 사용자가 온도의 냉각속도를 정해주는 것과는 달리 주어진 문제에 따라 조직적, 내부적으로 지역 온도를 높이거나 낮춘다는 점이다. 개체의 적합도에 따라 주어지는 개체 순위에 따라 냉각 계획이 정해지므로 알고리듬 사용자가 직접 냉각 속도를 결정할 필요는 없다. 때때로 개체는 자신의 적합도에 따라 온도를 높여주기 때문에 해의 다양성을 늘리는 효과도 가진다. 각 세대마다 낮은 온도에서 탐색을 벌이는 개체가 있는 반면, 높은 온도를 가지는 개체도 항상 존재하므로 자연스럽게 자기 적응 EP에서 흔히 발생하는 조기수렴 현상(premature convergence)을 억제시켜 준다.

#### 2. 실수형 최적화 문제를 위한 돌연변이 연산자

진화 프로그래밍의 돌연변이 연산자는 개체의 진화 방향과 진화 크기를 결정해 주는 역할, 즉 스텝 사이즈  $\sigma_i$ 를 정하는 역할을 한다고 볼 수 있다. 일반적으로 진화의 초기에는 스텝 사이즈를 크게 함으로써 넓은 영역의 탐색을 가능하게 하고, 진화가 거듭될수록 스텝 사이즈의 크기를 줄임으로써 최종 결과의 미세한 조정을 도모한다. 이를 위해 전통적으로 스텝 사이즈를 코스트 함수  $f$ 에 비례하게 아래 식과 같이 결정하기도 한다<sup>[7]</sup>.

$$x'_i = x_i + N_i(0, \beta \cdot f(x) + z) \quad (1)$$

여기서  $N(m, \sigma)$ 는 평균치가  $m$ 이고 표준편차가  $\sigma$ 인 정규 확률 분포를 가지는 난수이다. 대부분의 경우 탐색영역의 전체적인 모양과 적합도 함수의 최소값과 최대값을 미리 알 수 없으므로, 돌연변이를 위한 난수의 표준편차로 사용하기 위해서는 개체 변수  $x_i$ 의 단위에 맞게 적합도 함수의 스케일링(scaling)이 필요하다. 그러나 스케일링 파라메터  $\beta$ 와  $z$  값은 알고리듬이 적용될 최적화 문제에 따라 다르므로 경험적으로 정해질 수밖에 없다. 이런 문제는 자기적응 알고리듬을 이용해 모든 문제에 일반적으로 적용할 수 있으므로 해결이 가능하다.

Reynolds 등은 cultural 알고리듬을 이용한 지식 기반 자기적응(knowledge-based self-adaptation) EP 알고리듬을 제안하여 EP의 성능 개선을 꾀하였다<sup>[8]</sup>. 이들은 개체들로 구성된 진화 집단의 지난 경험을 축적하여 이를 최적값으로 유도하기 위한 정보로 이용한다. 축적된 지식을 사용하는 여러가지 방법을

제안하였는데 그 중 CAEP(Sd) (Cultural Algorithm with EP(situational knowledge to select the direction))라는 이름으로 다음과 같은 돌연변이의 과정을 사용하였다.

$$x_{i,j}' = \begin{cases} x_{i,j} + |\sigma_{i,j} \cdot N(0, 1)| & \text{if } x_{i,j} < s_j \\ x_{i,j} - |\sigma_{i,j} \cdot N(0, 1)| & \text{if } x_{i,j} > s_j, \\ x_{i,j} + \sigma_{i,j} \cdot N(0, 1) & \text{otherwise} \end{cases} \quad (2)$$

여기서  $x_{i,j}$ 는  $i$ 번째 개체의  $j$ 번째 변수이며,  $\sigma_{i,j}$ 는  $x_{i,j}$ 를 변이시키기 위한 스텝 사이즈이다.  $s_j$ 는 그 이전의 모든 세대동안 가장 우등했던 개체의  $j$ 번째 변수이다. 즉, 자기적응 EP (Self Adaptive EP; SAEP)<sup>[1,3]</sup>로 정해진 스텝 사이즈를 그대로 유지하면서 단지 진화 방향만을 가장 우등했던 개체쪽으로 정해주는 방법이다.

진화 알고리듬에서 돌연변이의 양을 모든 최적화 문제에 적용할 수 있는 일반적인 방법을 정하기란 쉽지 않다. 자기 적응 EP 알고리듬 또한, 완만한 경사를 이루는 모양의 적합도 함수에서나 전역 최적해에 이르기 전, 지역 최소값에서 스텝 사이즈가 모두 0이 되어버리는 조기수렴 현상이 가장 문제가 된다. 조기수렴 현상을 극복하기 위해 개체 사이의 거리에 기반을 둔 돌연변이의 방법을 두가지 제안한다.

#### 방법 1.

$$x_{new,i} = x_{k,i} + |x_{k,i} - x_{j,i}| \cdot N_i(0, 1). \quad (3)$$

#### 방법 2.

$$x_{new,i} = x_{k,i} + |x_{k,i} - x_{best,i}| \cdot N_i(0, 1). \quad (4)$$

방법 1에서  $k$ 번째 부모 개체  $x_k$ 의 새로운 자손 개체  $x_{new}$ 의  $i$ 번째 값은,  $x_{k,i}$ 와 랜덤하게 선택된  $x_{j,i}$  사이의 거리를 스텝 사이즈로 하고 이에 비례하는 난수로 발생시킨다. 방법 2에서는 랜덤하게 선택하는  $x_{j,i}$  대신, 세대에서 가장 우등한 개체를 선택하여 가장 좋은 성능을 가지는 개체와의 거리에 비례하도록 돌연변이의 양을 정한다. 가장 우등한 개체의 경우에는 식 (4)를 따를 경우 아무런 돌연변이의 양이 없으므로 방법 2를 사용하는 집단에서도 우등한 개체만은 방법 1을 따른다. 위 식에서 보듯이 방법 2는 가장 적합한 개체와의 거리로 진화양이 결정되므로 방법 1에 비해 수렴

속도면에서 효율적이며, 이에 반해 방법 1은 해의 다양성 면에서 좋은 성능을 가지리란 것을 예측할 수 있다. 이는 뒤에서 실험을 통해 확인된다.

#### 3. 부집단을 이용한 하이브리드 방법

진화 알고리듬의 방법과 연산자는 매우 다양하고 연산자에 따라 그 진화특성이 다르다. 최적화 문제의 최종 결과해를 빠르고 정확하게 찾기 위한 많은 다양한 진화 알고리듬이 존재하지만 이들 각각이 모든 문제를 잘 해결한다고 보기是很困难的(no-free-lunch theorem)<sup>[11]</sup>. 따라서 알고리듬마다의 특징을 잘 살려 서로의 장점만을 취해 좋은 성능을 얻고자 하는 하이브리드 방법도 EP의 성능을 개선하기 위한 좋은 수단이다.

본 논문에서는 여러 진화 부집단을 두고 이를 독립적인 다른 방법으로 진화시키는 방식으로 부집단마다의 다양한 진화 알고리듬의 장점을 취하며, 이들 사이의 개체 이주를 통해 서로의 단점을 보완하고자 한다. 부집단으로는 여러 알고리듬의 특성을 규명하여 해의 다양성면에서 좋은 특성을 가지는 부집단(부집단 C)과 수렴 속도면에서 탁월한 부집단(부집단 A), 그리고 이들 두 부집단의 중간정도의 성질을 가지는 부집단(부집단 B) 등 세종류의 부집단이 사용된다. 아래에 사용된 각 부집단의 특성을 나타내었다.

##### A. 부집단 A :

- 자기 적응 진화 알고리듬을 사용한 스텝 사이즈 결정
- CAEP(Sd)를 이용한 진화방향 결정

##### B. 부집단 B:

- NPOSA 알고리듬
- 식(5)의 돌연변이 방법 사용

##### C. 부집단 C:

- NPOSA 알고리듬
- 식(4)의 돌연변이 방법 사용

이들 부집단 사이의 개체 이주 방식은 무제한적인 이주 방법을 사용하고, 이주 개체의 선택은 적합도 함수값에 따라 세 부집단의 가장 우등한 개체들 중 가장 적합도 함수값이 높은 개체를 다른 두 부집단의 가장 열등한 개체 대신 삽입하는 방법을 택한다. 이로써, 비교적 넓은 탐색 영역을 가지고 조기수렴 현상이 거의 없는 부집단 C가 해의 다양성을 보장하고, 근처 최적해로의 수렴속도가 가장 빠른 부집단 A가 최적해로

빠르게 수렴한다. 이들 세 부집단과 아주 방식을 사용함으로써 부집단A의 조기수렴 현상은 부집단 B, 또는 부집단 C에서 아주해 오는 개체로 인해 해결되고 부집단 C의 느린 수렴속도 또한 부집단 A 또는 B에 의해 보완된다.

#### IV. 카메라 보정

센서를 사용하려면 우선 보정이 필요하고 이 과정의 정확도에 따라 센서의 성능이 좌우된다. 3차원 비전에서의 카메라 보정이란 컴퓨터 영상 좌표계에서 3차원 정보를 추출하거나 3차원 정보로부터 2차원 컴퓨터 영상 좌표계의 추출을 위해, 카메라의 내부적인 기하학적, 광학적인 파라미터들과 절대 좌표계(world coordinate)에 대한 카메라의 위치와 회전(position and orientation)을 결정하는 과정을 말한다.

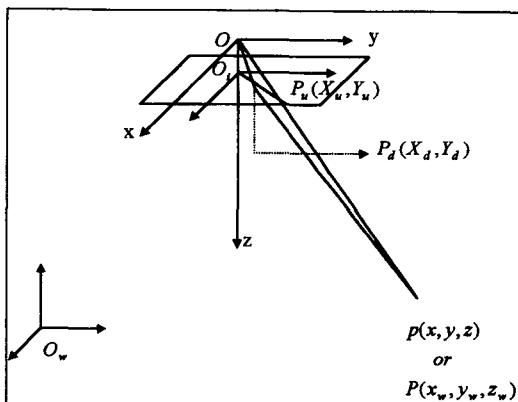


그림 1. 렌즈 왜곡을 고려한 카메라의 수학적 모델  
Fig. 1. Mathematical model of camera considering lens distortion.

##### 1. 카메라의 수학적 모델

기본적인 카메라 보정의 방법으로는 카메라의 물리적인 파라미터들을 고려한 수학적 모델로부터의 보정법과 영상과 실제 물체사이의 변환 관계를 나타내는 변환 행렬을 구하는 방법이 있다. 실제로 수학적 모델을 이용할 경우 카메라의 파라미터들이 비선형적인 식으로 이루어져 있어서 그 결정이 쉽지 않을 뿐더러 정확한 수학적 모델이 필요하다. 반면 변환 행렬을 이용하는 경우에는 카메라 파라미터의 복잡한 비선형식을 풀 필요없이 단지 몇 개의 점만으로 변환 행렬의 원소를 구해낼 수 있다. 그러나, 변환행렬의 차원이 시스템의 자유도(degree of freedom)보다 크므로 최적의

해가 아닌 다른 지역 최적해를 구할 가능성이 있고, 렌즈의 내부적인 왜곡(distortion) 파라미터를 구할 수 없는 단점이 있다. 그럼 1은 렌즈 왜곡이 가미된 카메라의 기하학적 모델이다<sup>[9]</sup>.

$(x_w, y_w, z_w)$ 는 대상 물체  $P$ 의 원점  $O_w$ 에 대한 3차원 좌표이다.  $(x, y, z)$ 는 대상 물체  $P$ 의 광축  $z$ 축의 원점이기도 한 점  $O$ 를 원점으로 하는 카메라 좌표계에서의 위치이다.  $(X, Y)$  좌표계는  $x, y$ 축과 평행인  $O_i$ 를 원점으로 하는 영상 좌표계이며,  $(X_u, Y_u)$ 는 완벽한 바늘구멍(pinhole) 카메라를 가정할 때의  $P$ 의 이미지 좌표( $P_u$ )이다.  $(X_d, Y_d)$ 는 렌즈 왜곡(lens distortion)으로 인해 생기는 실제 이미지 좌표이며  $(U, V)$ 는 픽셀 단위로 표현되는 컴퓨터 영상 좌표계이다.

정리하면 카메라 보정과정은 좌표계의 변환을 위한 카메라의 파라미터를 결정하는 작업이다. 카메라의 파라미터는 외부적인 파라미터(extrinsic parameter)와 내부적인 파라미터(intrinsic parameter)로 나눌 수 있다. 오일러 각(yaw, pitch, roll)과 평행 이동 벡터가 외부적 파라미터에 해당되고, 초점거리  $f$ 와 렌즈 왜곡 계수  $k_1, k_2$ , 그리고 컴퓨터 영상 좌표계의 중심점  $(C_x, C_y)$ 와 TV 카메라의 스캐닝 등의 시간적인 오차로 인한 불확실성 스케일 요소  $s_x$  등이 내부적인 파라미터에 해당된다. 본 논문에서는 카메라 시스템의 자유도와 같은 수의 미지수를 사용하여 카메라의 수학적 모델식을 정의하고 복잡한 비선형 식으로 주어지는 카메라 파라미터를 찾기 위해 진화 알고리듬을 이용한다. (좌표 변환식은 참고문헌 [9]를 참조바람)

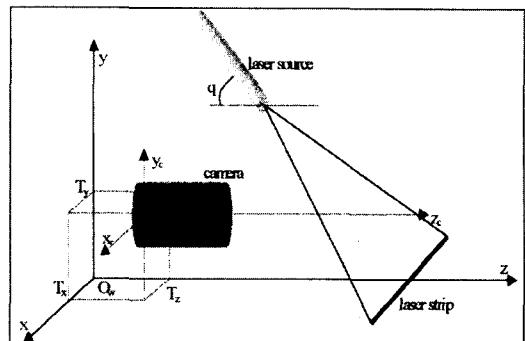


그림 2. 레이저 카메라의 구조  
Fig. 2. The structure of a laser camera.

## 2. 레이저 카메라의 보정

영상으로부터 3차원 정보를 추출해 내는 방법으로 스테레오 카메라, 또는 구조화된 광을 많이 이용한다. 스테레오 카메라의 경우에는 대응점 일치 문제의 해결이 수월치 않기 때문에 실제로 용접이나 3차원 형상 복원 문제 등에서는 구조화된 광을 많이 사용한다<sup>[10]</sup>. 본 논문에 쓰이는 레이저 카메라의 구조는 그림 2과 같다. 카메라의 보정을 위해 사용되는 보정 블록은 그림 3(a)에 나타내었다. 보정 블록에 레이저 광으로 인한 레이저 스트립이 생기고 이는 카메라를 통해 그림 3(b)와 같은 형태의 영상으로 나타나는데 이를 특징점들의 3차원 위치  $(x, y, z)$ 와 영상 이미지 좌표  $(U, V)$ 들을 얻어 이들 특징점들의 대응 관계로부터 카메라 보정 파라미터들을 추출한다.

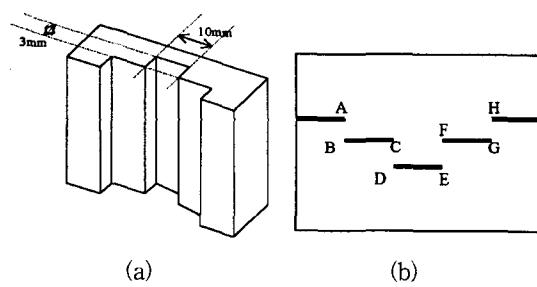


그림 3. (a) 보정 블록과 (b) 레이저 카메라에 의한 레이저 스트립 영상

Fig. 3. (a) Calibration block (b) Laser strip image taken by the laser camera

## 레이저 평면광 식은

$$f_i(x_w, y_w, z_w) = ax_w + by_w + cz_w + 1 = 0 \quad (5)$$

으로 쓸 수 있다. 또한 카메라 보정 단계에 따른 변환 관계는

$$\begin{aligned} U &= f_U(x_w, y_w, z_w) \\ V &= f_v(x_w, y_w, z_w) \end{aligned} \quad (6)$$

로 표현되고,  $(U, V)$ 는 특징점의 영상 좌표이다. 따라서 다음의 오차값,

$$\begin{aligned} error &= \sum_{k=1}^M ((U_k - f_u(x_{w,k}, y_{w,k}, z_{w,k}))^2 \\ &+ (V_k - f_v(x_{w,k}, y_{w,k}, z_{w,k}))^2 + (f_i(x_{w,k}, y_{w,k}, z_{w,k}))^2) \end{aligned} \quad (7)$$

을 최소로 하는 파라미터가 바로 카메라의 보정 파라

미터이다. 위 식에서  $M$ 은 특징점의 개수이며,  $k$ 번째 특징점의 공간 좌표는  $(x_{w,k}, y_{w,k}, z_{w,k})$ 이고, 이 점의 이미지 좌표는  $(U_k, V_k)$ 이다.

## V. 실험 결과

본 절에서는 앞에서 제안한 이질적인 특성을 가지는 부집단을 이용한 하이브리드 방법을 표준 테스트 함수에 적용한 실험 결과와 실제적인 응용으로서 카메라 보정에 적용해 본 결과를 보이겠다.

### 1. 부집단을 이용한 하이브리드 방법

실험 결과는 크게 세가지로 구분하여 보일 것이다. 우선 세가지 부집단의 특성을 각각의 문제에 대한 실험 결과로부터 파악할 것이며 여기서 그 결과가 우리가 의도했던 바와 어느 정도 부합함을 알 수 있을 것이다. 두번째는 부집단에 개체이주를 도입함으로써 부집단의 단순합 이상의 효과가 나타남을 확인할 것이며 마지막으로 부집단을 사용한 하이브리드 방법을 기존의 SAEP와 성능 비교할 것이다.

실수형 최적화 문제를 풀기위해 사용되는 많은 진화 알고리듬의 성능을 정확하게 비교하기 위해 자주 사용하는 테스트 함수들이 여러가지 있다. 실험에 앞서 아래에 본 논문에서 사용된 테스트 함수들을 나열한다.

#### Problem 1. Sphere (DeJong F1)

$$f_1(x) = \sum_{i=1}^n x_i^2, n = 10. \quad (8)$$

#### Problem 2. Rosenbrock (DeJong F2)

$$f_2(x) = 100(x_1^2 - x_2)^2 + (1 - x_1)^2. \quad (9)$$

#### Problem 3. Foxholes (DeJong F5)

$$f_3(x_1, x_2) = \frac{1}{500 + \sum_{j=1}^2 (x_j - a_{ij})^6}, -65 \leq x_i \leq 65, i = 1, 2. \quad (10)$$

$$a_{j1} = \{-32, -16, 0, 16, 32, -32, -16, 0, 16, 32\}$$

$$-32, -16, 0, 16, 32, -32, -16, 0, 16, 32, -32, -16, 0, 16, 32\}$$

$$\begin{aligned} a_{j2} &= \{-32, -32, -32, -32, -16, -16, -16, -16, -16, -16, \\ &0, 0, 0, 0, 16, 16, 16, 16, 32, 32, 32, 32\} \end{aligned}$$

#### Problem 4. Bohachevsky

$$f_4(x_1, x_2) = \frac{(x_1^2 + x_2^2)}{2} - \cos(20\pi x_1) \cos(20\pi x_2) + 2. \quad (11)$$

### Problem 5. Colville

$$\begin{aligned} f_5(x) = & 100(x_1^2 - x_2)^2 + (1 - x_1)^2 90(x_4 - x_3^2)^2 + (1 - x_3)^2 \\ & + 0.1((x_2 - 1)^2 + (x_4 - 1)^2) + 19.8(x_2 - 1)(x_4 - 1). \end{aligned} \quad (12)$$

### Problem 6. Rastrigin

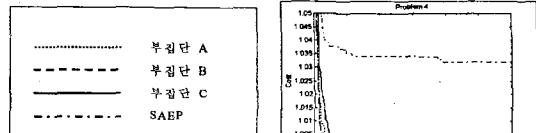
$$f_6(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10], \quad n=10. \quad (13)$$

### Problem 7. Griewangk

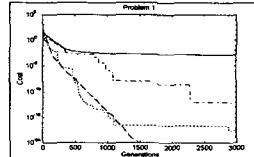
$$f_7(x) = \frac{1}{4000} \sum_{i=1}^n x_i^4 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1, \quad n=30 \quad (14)$$

위 함수 중  $f_1$ 은 단 하나의 전역 최적해를 가지는 가장 기본적인 테스트 함수로 알고리듬의 수렴속도를 시험할 수 있고,  $f_2$ 의 경우도 역시 오직 전역 최적해 하나만을 가지나 완만한 기울기를 가지는 모양으로 조기 수렴 현상 여부의 시험이 가능하다. 나머지 함수들은 지역해가 많이 존재하는 다양한 테스트 함수이다. 따라서 위의 테스트 함수들로 제안된 알고리듬의 대략적인 성능을 알아볼 수 있다.

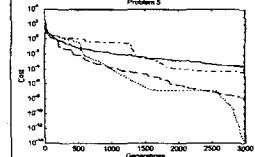
부집단을 이용한 하이브리드 방법을 위해 부집단 A, B, C를 선택해야 한다. 부집단 A, B, C는 각각 다른 진화 방법, 즉 다른 부집단과 구분되는 진화 연산자를 사용하게 된다. 다른 진화적 행동을 하는 각 부집단의 장점을 취합으로써 수렴 속도와 해의 다양성을 동시에 향상시키고자 하는 것이 목적이다. 제안된 알고리듬은 세개의 부집단을 사용하였다. 각 부집단의 특성을 알아보기 위해 사용한 각 부집단의 개체 수를 20으로 하고, 테스트 함수를 사용하여 20개의 개체 수를 가지는 자기적용 EP와 진화 성능을 비교 분석하였다. 그림 4에 각 테스트 함수에 대해 10번의 시험을 거친 후 가장 우수한 개체의 코스트 값을 평균한 것을 나타내었다. 각 테스트 함수에서 랜덤한 초기값에 의한 영향은 여러 번의 시험을 통한 평균 성능을 비교함으로써 어느 정도 배제된다. 그림 4의 각 그래프에서 점선(dotted line)은 부집단 A, 대시선(dashed line)은 부집단 B, 실선(solid line)은 부집단 C, 대시점선(dash-and-dot line)은 SAEP를 나타낸다. 주어진 함수에 대해 10회 시험 후의 최소 코스트를 같이 나타내어 각 알고리듬의 특성을 비교할 수 있게 하였다.



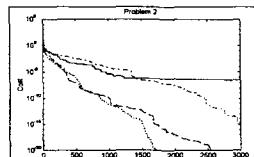
(d)



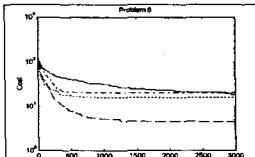
(a)



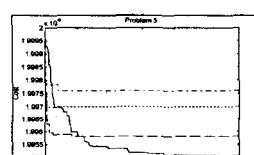
(e)



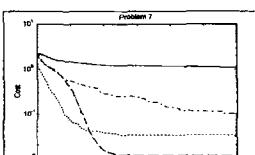
(b)



(f)



(c)



(g)

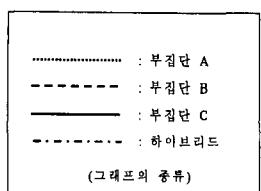
그림 4. 각 테스트 함수에 대한 10회의 시험 후의 최소 코스트의 평균 그래프

Fig. 4. The plots of minimum cost values averaged over 10 trials for each test function.

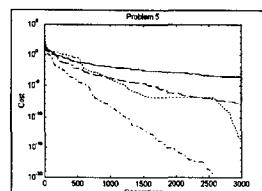
그림 4(a)의 Sphere 함수에서는 부집단B가 가장 빨리 전역 최적해에 수렴하며 해의 다양성 측면을 강조한 부집단 C가 가장 느린 수렴속도를 보인다. 그림 4(b)의 Rosenbrock 함수에서도 역시 돌연변이의 방향까지도 어느 정도 정해주는 부집단 B와 부집단 A가 빠른 수렴속도를 보인다. 그림 4(c)와 (d)의 Foxholes와 Bohachevsky 함수는 많은 지역해를 가지고 있으며 자기 적응 알고리듬을 사용하는 비교집단의 경우는 조기수렴 현상을 일으키는 반면 부집단 C는 정확한 전역 최적해를 찾아낸다. 그림 4(e)의 Colville 함수에서는 돌연변이의 방향이 고려된 부집단 A가 최적해로 빠르게 수렴하고, 그림 4(f)와 (g)의 Rastrigin, Griewangk 함수에서는 부집단 B가 가장 좋은 성능을 보인다. 위의 결과를 보면 지역해가

없을 경우 수렴속도가 빠른 부집단 A가 가장 좋은 성능을 보이고 지역해가 많아질수록 부집단 B, C 순으로 좋은 성능을 보인다는 것을 알 수 있다.

진화 알고리듬 성능은 해의 다양성과 수렴 속도에 의해 좌우된다. 단 하나의 진화 알고리듬이 이 두 가지 모두를 향상시키는 것이 가장 이상적이겠지만 트레이드 오프(trade-off) 관계의 이 둘을 동시에 고려하기란 쉽지가 않다. 따라서 다른 진화 특성을 가지는 개체나 집단을 사용하고 이들간의 진화 정보를 교환함으로써 해의 다양성과 수렴속도를 개선하는 것이 바람직하다. 부집단을 이용한 하이브리드 방법은 세 부집단 A, B, C를 독립적으로 진화시키고, 매 세대 후에 각 집단의 가장 우등한 개체의 정보를 공유하게 하여 진화 정보를 교환함으로써 부집단 B, C로 찾아진 전역 최적해에 부집단 A가 빠르게 수렴할 수 있도록 한다. 하이브리드 방법은 단순히 세 부집단의 성능을 합친 것만은 아니다. 그림 5에서 보듯이 부집단 간의 진화 정보 교환으로 성능의 상승효과를 얻을 수 있다. 그림 5는 세 부집단의 성능과 이들의 하이브리드 방법의 성능을 나타내고 있다. 점선은 부집단 A, 대시선은 부집단 B, 실선은 부집단 C, 대시점선은 하이브리드 방법을 나타낸다. 각 부집단의 개체 수는 20이고, 이들의 하이브리드 방법의 전체 개체는 60이다.



(b)



(c)

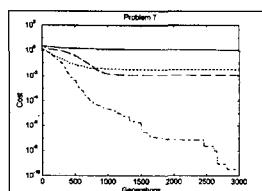
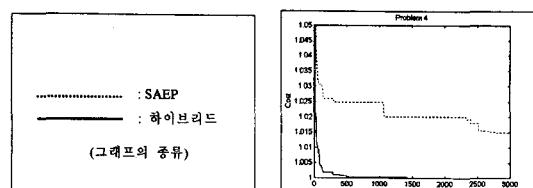
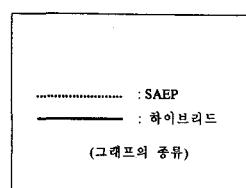


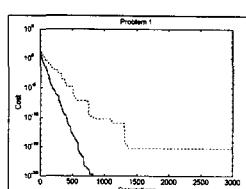
그림 5. 하이브리드 방법을 10번 시행한 후의 최소 코스트의 평균 그래프

Fig. 5. The plots of minimum cost values averaged over 10 trials for (a) Problem 3 (b) Problem 5 (c) Problem 7.

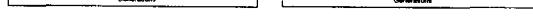
위의 결과 그림 5를 보면 세 부집단의 진화 성능이 하이브리드 방법을 통해 서로를 보완하여 상당히 개선된 성능을 발휘함을 쉽게 볼 수 있다. 특히 그림 5(a)의 경우 급격한 수렴속도를 보이는 부집단 B, 부집단 C가 전역해 근처의 값을 빠르게 찾아내고 그뒤 부집단 B, 부집단 C로부터 진화 정보를 받은 부집단 A에 의해 지역 최적해를 피하면서 정확한 전역 최적해에 도달하는 것을 볼 수 있다. 그림 5(b)에서도 하이브리드 방법이 우수한 성능을 보임을 쉽게 알 수 있다. 또한, 그림 5(c)의 경우 세 부집단의 성능은 코스트 값이  $10^{-2}$  이하의 해를 찾을 수 없지만 하이브리드 방법은 3,000세대 후 코스트값  $10^{-10}$ 까지 도달하는 해를 찾아 낸다.



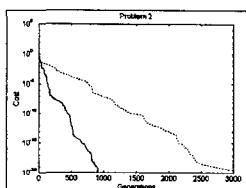
(d)



(a)



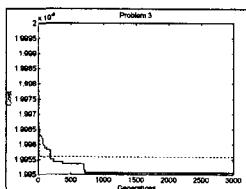
(e)



(b)



(f)



(c)



(g)

그림 6. 제안된 하이브리드 방법과 SAEP의 성능 비교

Fig. 6. Performance comparison: Proposed hybrid technique vs. SAEP.

다음에는 제안된 하이브리드 방법과 실수형 최적화 문제에 일반적으로 흔히 사용되는 SAEP의 성능을 비교하였다. 두 진화 알고리듬의 개체수는 60이다. 그림 6에 두 알고리듬의 성능을 비교하여 나타내었다. 여기서 점선은 SAEP를 나타내고, 실선은 하이브리드 방법의 결과를 나타낸다. 그래프를 통해 하이브리드 방법의 개선된 성능을 쉽게 확인할 수 있다.

아래의 표 1은 위의 SAEP와 하이브리드 방법(HEP)의 성능 비교 실험에 덧붙여 각 알고리듬의 세 대당 소요 시간을 측정하여 기록한 것이다. 결과를 보면 하이브리드 방법이 SAEP보다 세대당 보다 적은 시간이 걸린다는 것을 알 수 있다. 이것은 본 논문에서 제안한 하이브리드 방법이 많은 시간을 필요로 하는 연산을 수행하는 것이 아니며, 더욱이 하이브리드 방법의 경우에는 각 개체를 평가한 후 정렬(sorting) 할 때 비교되는 개체들의 개수가 SAEP보다 적으므로 이렇게 보다 적은 시간이 걸리는 것으로 생각된다. 따라서 그림 6과 표 1의 결과로부터 하이브리드 방법의 유통함을 알 수 있다.

표 1. SAEP와 HEP의 세대당 소요시간 비교

Table 1. Time per generation of SAEP and HEP.

Problem No.	Algorithm	Time per Generation (msec)
1	SAEP	9.300
	HEP	5.267
2	SAEP	4.967
	HEP	2.133
3	SAEP	4.667
	HEP	3.500
4	SAEP	3.467
	HEP	1.867
5	SAEP	5.900
	HEP	3.133
6	SAEP	9.267
	HEP	5.633
7	SAEP	23.600
	HEP	15.533

## 2. 카메라 보정에의 응용

마지막으로, 제안된 하이브리드 방법을 실제 문제인 카메라 보정에 적용하여 보았다. 실제로 카메라와 영상 시스템을 이용하여 얻은 영상은 그림 7과 같은 모양이다. 이 영상에서 특징점은 간단한 영상 처리 방법으로 얻을 수 있다. 보정 블록이 카메라 광 축에 대해

수직이므로 영상에 나타난 레이저 스트립은 영상 축  $U$ 에 평행이라고 가정한다. 영상을  $U$  축 방향으로 사영(projection)시키면 세 개의 피크(peak)가 나타나는데 이들의 위치가 특징점들의  $V$  좌표값이다. 보통의 경우 영상에서 레이저 스트립은 5~10 픽셀의 굵기이므로 피크 위아래 10 픽셀 정도를  $V$  축 방향으로 사영시킨 뒤 윤곽선 추출 연산으로 특징점의  $U$  좌표를 얻는다. 그림 8에 영상에 나타난 레이저 스트립과 간단한 영상 처리를 거친 후 찾아진 특징점을 함께 나타내었다.

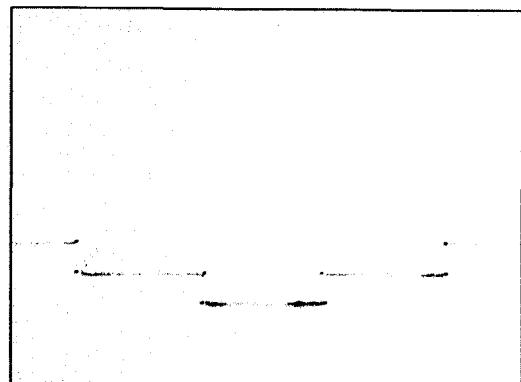


그림 7. 반전된 레이저 스트립 영상과 특징점들

Fig. 7. Inverted laser strip image and feature points.

표 2. 특징점들의 영상 좌표와 3차원 좌표의 예

Table 2. Examples of image coordinates of feature points and their corresponding 3D coordinates.

	(U,V)	(x_w,y_w,z_w)
P <sub>1</sub>	(48,66)	(-10,60,160)
P <sub>2</sub>	(579,66)	(20,60,160)
P <sub>3</sub>	(397,117)	(10,58,163)
P <sub>4</sub>	(577,117)	(20,58,163)
P <sub>5</sub>	(225,165)	(0,55,166)
P <sub>6</sub>	(404,165)	(10,55,166)

표 2에 실제 실험에서 찾아진 몇 개의 특징점( $P_k$ )들의 영상 좌표와 3차원 좌표를 나타내었다. 실험에서는 모두 12개의 특징점들로 식 (7)을 구성하였다( $M=12$ ). 각 개체는 카메라 보정 파라메터 각(angle)  $\theta$ ,  $\psi$ ,  $\phi$ 와 평행 이동량  $T_x$ ,  $T_y$ ,  $T_z$  초점거리  $f$ , 레이저 평면광의 계수  $a$ ,  $b$ ,  $c$ 로 10개의 변수를 가진다. 식 (7)

을 최소로 하는 보정 파라메터들을 부집단을 이용한 하이브리드 방법으로 찾았다. 카메라의 수학적인 모델을 이용하여 보정을 행하므로 대략적인 개체의 초기값을 정해줄 수 있다. 이는 실제의 경우에도 대략적인 수치를 알 수 있으므로 현실성이 있는 가정이다. 3,000세대를 거친 후 찾아진 최적의 보정 파라메터들을 표 3에 나타내었다.

표 3. 카메라 보정의 결과

Table 3. The result of camera calibration.

Calibration parameters	Value found by HEP
$\theta$ (rad)	-0.0075
$\gamma$ (rad)	0.0044
$\phi$ (rad)	0.0342
$T_x$ (mm)	4.6031
$T_y$ (mm)	46.9955
$T_z$ (mm)	58.2022
$f$	1822.7607
a	0.0001
b	-0.0061
c	-0.0040

$f$ 의 값은  $U, V$ 를 mm단위로 바꾸기 위한 mm/pixel의 스케일 계수를 1로 보고 계산되어진 값이다. 실제로는 스케일계수가 1보다 작으므로  $f$ 의 값은 위 표의 수치보다 작은 값이 될 것이다. 진화 알고리듬을 이용한 카메라 보정은 본 논문에 고려하지 않은 다른 여러 카메라 파라메터들을 적합도 함수에 정의함으로써 이들도 쉽게 최적화시킬 수 있는 장점을 지닌다. 하지만 실시간 카메라 보정에의 사용에는 진화 알고리듬의 특성상 무리가 있다.

## VI. 결 론

다양한 진화 알고리듬의 진화 특징들을 잘 조합하여 좋은 특성을 얻기 위해 부집단을 이용한 하이브리드 방법을 제안하였다. 제안된 하이브리드 방법으로 여러 테스트 함수를 통해 정확하고 빠른 수렴 성능을 얻을 수 있음을 보였고 각 부집단 간의 상호 작용에 의한 상승효과도 확인했다. 아울러 각 부집단 및 SAEP의 특성을 비교 분석하였다. 또한, 제안된 하이브리드 방법은 새로운 진화 특성을 가지는 알고리듬을 부집단

형태로 추가함으로써 그 집단의 진화 특성을 쉽게 기존의 알고리듬에 추가할 수 있는 장점을 지닌다. 하이브리드 방법을 실제 문제에 적용할 수도 있음을 보이기 위해 카메라 파라메터 보정에 응용하였다. 수학적인 카메라의 모델을 사용하였고, 제안된 방법으로 카메라 모델의 비선형식의 파라메터들을 구할 수 있음을 보였다.

앞으로 부집단을 이용한 하이브리드 방법에서 최종 결과 해에 영향을 미치는 개체 이주 방법, 이주 개체의 수, 그리고 부집단의 진화 특성과 전체 알고리듬의 성능 사이의 관련성에 대한 연구가 필요하리라 본다. 카메라 보정에 있어서는 본 논문에서 고려하지 않은 렌즈의 왜곡 등 다양한 파라메터들의 보정을 위해 좀 더 정밀한 실험 환경의 구축과 영상처리 기술의 확보도 필요하다. 그리고 본문에서도 언급했듯이 많은 시간을 요하는 알고리듬의 실시간 처리를 위한 병렬 하드웨어에 의한 구현에 관한 연구도 행해져야 할 것이다.

## 참 고 문 현

- [1] T. Back, D. B. Fogel, and Z. Michalewicz, *Handbook of Evolutionary Computation*, Oxford University Press, 1997.
- [2] H. J. Cho, S. Y. Oh, and D. H. Choi, "A New Evolutionary Programming Approach Based on Simulated Annealing with Local Cooling Schedule", *IEEE Int. Conf. on Evolutionary Computation*, pp. 598-602, 1998.
- [3] T. Back and H. P. Schwefel, "Evolutionary Computation: An Overview", *IEEE Int. Conf. on Evolutionary Computation*, pp. 20-29, 1996.
- [4] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, MIT Press, 1986.
- [5] S. Kirkpatrick Jr., C. D. Gelatt, and M. P. Vecchi, "Optimization by Simulated Annealing", *Science*, vol. 220, pp. 671-680, 1983.
- [6] P. Adamidis and V. Petridis, "Co-operating populations with different

- evolution behaviours”, *IEEE Int. Conf. on Evolutionary Computation*, pp. 188-191, 1996.
- [ 7 ] Z. Michalewicz, *Genetic Algorithms Data Structures = Evolution Programs*, Springer-Verlag, 1996.
- [ 8 ] R. G. Reynolds and C. Chung, “Knowledge-based Self-adaptation in Evolutionary Programming using Cultural Algorithm”, *IEEE Int. Conf. On Evolutionary Computation*, pp. 71-76, 1997.
- [ 9 ] R. Y. Tsai, “A Versatile Camera Calibration Technique for High-Accuracy 3D Machine Vision Metrology Using Off-the-Shelf TV Cameras and Lenses”, *IEEE J. of Robotics and Automation*, vol. RA-3, no. 4. pp. 323-343. 1987.
- [ 10 ] B. K. P. Horn, *Robot Vision*, MIT Press, 1986.

## 저자소개

## 趙顯中(正會員)

1973년 4월 23일생. 1996년 2월 경북대학교 전자공학과 졸업(공학사). 1998년 2월 포항공과대학교 전자전기공학과 졸업(공학석사). 1998년 3월 ~ 현재 삼성전자 근무. 주관심분야는 신경망, 퍼지논리, 진화 알고리듬, 로보틱스, 자율 주행 로봇 등임

## 吳世泳(正會員)

1952년 9월 18일생. 1974년 2월 서울대학교 공대 전자공학과(공학사). 1974년 1월 ~ 1976년 2월 한국원자력 연구원. 1978년 8월 Case Western Reserve University 전기공학 석사. 1981년 5월 同大學 박사. 1981년 9월 ~ 1984년 12월 일리노이대 조교수. 1985년 1월 ~ 1988년 4월 플로리다대 조교수. 1988년 5월 ~ 현재 포항공과대학교 전자전기공학과 교수. 주관심분야는 Neural Network의 로보트 및 자동화 응용, 자율주행차 동차의 vision 기반 제어

## 崔斗鉉(正會員)

1967년 12월 15일생. 1991년 2월 경북대학교 전자공학과 졸업(공학사). 1993년 2월 포항공과대학교 전자전기공학과 졸업(공학석사). 1996년 8월 포항공과대학교 전자전기공학과 졸업(공학박사). 1997년 ~ 현재 경북대학교 전자전기공학부 조교수. 주관심 분야는 신경망, 퍼지논리, 진화 알고리듬, 로보틱스, 자율 주행 로봇 등임