

# 유전자알고리즘을 이용한 영상분할 문턱값의 자동선택에 관한 연구

## Automatic Thresholding Selection for Image Segmentation Based on Genetic Algorithm

이 병 룡\*, Quoc Bao Truong, Van Huy Pham, 김 형 석  
(Byung-Ryong Lee<sup>1</sup>, Quoc Bao Truong<sup>1</sup>, Van Huy Pham<sup>1</sup>, and Hyoung-Seok Kim<sup>1</sup>)  
<sup>1</sup>University of Ulsan

**Abstract:** In this paper, we focus on the issue of automatic selection for multi-level threshold, and we greatly improve the efficiency of Otsu's method for image segmentation based on genetic algorithm. We have investigated and evaluated the performance of the Otsu and Valley-emphasis threshold methods. Based on this observation we propose a method for automatic threshold method that segments an image into more than two regions with high performance and processing in real-time. Our paper introduced new peak detection, combines with evolution algorithm using MAGA (Modified Adaptive Genetic Algorithm) and HCA (Hill Climbing Algorithm), to find the best threshold automatically, accurately, and quickly. The experimental results show that the proposed evolutionary algorithm achieves a satisfactory segmentation effect and that the processing time can be greatly reduced when the number of thresholds increases.

**Keywords:** image segmentation, automatic threshold, otsu's method, valley-emphasis method, genetic algorithm

### I. 서론

문턱값(thresholding)을 선정하는 것은 영상분할(image segmentation)의 중요한 기술적 요소이다. 영상분할은 글자인식[1], 머신비전에 의한 불량검사[2-4], 시각적인 변화를 인식[5], 움직이는 물체의 분할[6] 등에 중요하게 사용되고 있다. 자동으로 문턱값을 선정하는 방법은 전역문턱값(global thresholding)과 지역문턱값(local thresholding)으로 구분될 수 있다. 전역문턱값 방식은 전체 영상의 히스토그램으로부터 한 개의 문턱값을 선정하는 것을 말하며, 지역문턱값 방식은 여러 개의 문턱값을 선정하기 위해 지역적인 그레이 레벨(gray-level) 정보를 사용하는데 각각의 문턱값은 영상의 일정한 구간에서 최적화된 값을 가지게 된다. 전역문턱값 방식은 간단하고 구현하기도 쉽지만 조명의 영향을 많이 받게 되는 단점이 있다. 반면에 지역문턱값 방식은 비균질(non-uniform)의 조명을 사용해도 무방하지만 처리방법이 복잡하다.

전역문턱값 방법중에는 Otsu 방법[7]이 가장 많이 사용되고 있다. 하지만 Otsu 방법은 그레이 레벨 히스토그램에 대한 0차 및 1차 모멘트 값을 반복적으로 계산하기 때문에 여러 개의 문턱값을 결정하는 곳에는 비효율적이다. 여러 개의 문턱값을 효과적으로 결정하기 위해 Otsu 방법의 성능을 높이기 위한 연구들도 많이 수행되어 왔다. Liao 등[8]은 룩업테이블(look-up table)을 이용하여 미리 계산된 클래스 사이의 수정된 변이값(variance)을 찾는 방식으로 문턱값을 선정하였다.

최근에는 유전자알고리즘(genetic algorithm)[9,10]과 같은 진화론적인 방법을 이용하여 최적의 문턱값을 구하는 방법이 적용되어 영상분할의 성능을 높였다. 하지만 단순한 형태의 유전자알고리즘 만을 사용하여 정확한 최적해에 수렴시키는 것이 어렵고, 수렴속도도 늦은 편이다[11]. 이러한 문제점을 보완하기 위해 적응유전자알고리즘(adaptive genetic algorithm)[12-14]이 적용되기도 하였다. 하지만 이 방법도 2가지의 클래스에 대한 영상분할에 유효하며 2가지 이상의 클래스에 대한 영상분할은 어렵다. 여러 개의 문턱값을 구하기 위한 방법으로 양자입자최적화(quantum particle swarm optimization) 방법[15]을 사용하거나 2단계에 걸친 Otsu 최적화방법[16]을 사용한 연구도 수행되었지만, 이러한 방법들은 매우 복잡하면서도 영상분할을 자동적으로 수행할 수 있는 능력이 없다.

이상의 연구들을 관찰한 결과 주어진 영상을 2개 이상의 영역으로 영상을 분할할 수 있고 또 높은 성능을 유지하면서도 실시간 적으로 계산이 가능한 방법의 필요성을 인식하게 되었다.

본 연구에서는 최적의 문턱값들을 빠르고, 정확하게 자동으로 선정할 수 있도록 수정된 적응유전자알고리즘(MAGA: Modified Adaptive Genetic Algorithm)과 힐크라이밍 알고리즘(HCA: Hill Climbing Algorithm)을 결합한 문턱값 자동선정 알고리즘을 제안하였다. 본 논문의 II 장에서는 기존의 문턱값 자동선정기법인 Otsu 방법과 계곡강조(valley-emphasis) 방법을 소개하였다. III 장에서는 본 연구에서 제안한 문턱값 자동선정 기법에 대하여 기술하였다. 먼저, 피크값 탐지 알고리즘(peak detection algorithm)을 소개하였고, 제안된 알고리즘을 이용하여 여러 개의 문턱값을 계산하는 방법을 설명하였다. IV 장에서는 실험결과를 정리하였고, V 장에 결론을 정리하였다.

\* 책임저자(Corresponding Author)

논문접수: 2011. 1. 13., 수정: 2011. 3. 2., 채택확정: 2011. 3. 24.

이병룡, Quoc Bao Truong, Van Huy Pham, 김형석: 울산대학교 기계자동차공학부

(brlee@ulsan.ac.kr/baotruong@mail.ulsan.ac.kr/huydhct@gmail.com/khseog@mail.ulsan.ac.kr)

※ 이 논문은 2011년 울산대학교 연구비에 의하여 연구되었음.

**II. 기존의 문턱값 자동선정 기법**

**1. 일반적인 Otsu 방법**

하나의 영상은 2차원 평면에서 그레이 레벨의 강도함수  $f(x, y)$ 로 표현된다. 강도함수  $f(x, y)$ 는 0에서  $L-1$  사이의 그레이 레벨 값을 가진다. 그레이 레벨이  $i$  인 화소의 수를  $n_i$  라고 하고,  $n$ 은 주어진 영상의 전체 화소라고 하면 그레이 레벨이  $i$  인 확률은 다음과 같이 정의 될 수 있다.

$$p_i = \frac{n_i}{n}, \quad p \geq 0, \quad \sum_{i=0}^{L-1} p_i = 1 \quad (1)$$

한 개의 문턱값을 선정하는 경우 주어진 영상의 화소들은 2개의 클래스 즉  $C_1 = \{0, 1, \dots, t\}$ 과  $C_2 = \{t+1, t+2, \dots, L-1\}$ 로 구분된다. 여기서  $t$  는 문턱값을 말하며  $C_1$  과  $C_2$  는 각각 영상내의 관심목표물(object)과 배경(background)을 나타낸다. 두 클래스의 확률은 다음과 같다.

$$\omega_1(t) = \sum_{i=0}^t p_i \quad \text{and} \quad \omega_2(t) = \sum_{i=t+1}^{L-1} p_i \quad (2)$$

각 클래스의 그레이 레벨 평균값과 전체 영상의 그레이 레벨 평균값은 다음과 같다.

$$\mu_1(t) = \frac{\sum_{i=0}^t ip_i}{\omega_1(t)}, \quad \mu_2(t) = \frac{\sum_{i=t+1}^{L-1} ip_i}{\omega_2(t)}, \quad \mu_T = \sum_{i=0}^{L-1} ip_i \quad (3)$$

Otsu 방법[7]에서 문턱값의 최적값  $t^*$ 는 두 클래스 간의 변이값(variance)을 최대화 시키는 값이며 다음 식과 같이 정의 된다.

$$t^* = \text{Arg Max}_{0 \leq t \leq L-1} \{ \sigma_B^2(t) \} \quad (4)$$

여기서 두 클래스 간의 변이값  $\sigma_B^2$ 는 다음과 같다.

$$\sigma_B^2(t) = \omega_1(t)(\mu_1(t) - \mu_T)^2 + \omega_2(t)(\mu_2(t) - \mu_T)^2 \quad (5)$$

위의 개념은 다수의 문턱값을 선정하는 경우에도 쉽게 확장될 수 있다.  $M-1$  개의 문턱값을 고려하면 즉 원래의 영상을  $M$ 개의 클래스  $\{C_1, C_2, \dots, C_M\}$ 로 분할한다면 각 문턱값의 최적값  $\{t_1^*, t_2^*, \dots, t_{M-1}^*\}$ 은 다음 식과 같이 표현된다

$$\{t_1^*, t_2^*, \dots, t_{M-1}^*\} = \text{Arg Max}_{0 \leq t_1 < t_2 < \dots < t_{M-1} < L} \{ \sigma_B^2(t_1, t_2, \dots, t_{M-1}) \} \quad (6)$$

위 식에서  $\sigma_B^2 = \sum_{k=1}^M \omega_k (\mu_k - \mu_T)^2$ ,  $\omega_k = \sum_{i \in C_k} p_i$ ,  $\mu_k = \sum_{i \in C_k} \frac{ip_i}{\omega_k}$ .

**2. 수정된 Otsu 방법**

수정된 Otsu 방법은 Liao 등[8]에 의해 제안되었는데, 이 방법에서는 클래스 간의 변이값  $\sigma_B^2$ 가 식 (7)과 같이 수정된 형태로 정의되며 누적확률을 계산하는 시간을 줄이기 위해 미리 계산되어 룩업 테이블에 저장된다.

$$\sigma_B^2(t) = \sum_{k=1}^M \omega_k \mu_k^2 \quad (7)$$

따라서 각 문턱값의 최적값  $\{t_1^*, t_2^*, \dots, t_{M-1}^*\}$ 은 식 (8)과 같이 표현된다.

$$\{t_1^*, t_2^*, \dots, t_{M-1}^*\} = \text{Arg Max}_{0 \leq t_1 < t_2 < \dots < t_{M-1} < L} \{ \sigma_B^2(t_1, t_2, \dots, t_{M-1}) \} \quad (8)$$

클래스 간의 수정된 변이값  $\sigma_B^2$ 는  $w_k$ 와  $\mu_k$  항목을 포함하고 있는데, 변이값을 구하기 위해  $M$  회수를 반복해서 계산을 해야 한다. 이러한 계산시간을 줄이기 위해서 0차와 1차 모멘트 함수를 정의하면 다음 식과 같다.

$$P(u, v) = \sum_{i=u}^v p_i \quad \text{and} \quad S(u, v) = \sum_{i=u}^v ip_i \quad (9)$$

위 식에서  $u$  와  $v$  는  $1 \leq u \leq L, 1 \leq v \leq L$  사이 값이고  $P(u, v)$  와  $S(u, v)$ 는 재귀적(recursive)으로 계산되는 룩업 테이블이다. 그리고  $w_k$ 와  $\mu_k$  값은 룩업 테이블의 값을 이용하여 다음 식과 같이 계산된다.

$$\omega_k = P(1, t_k) - P(1, t_{k-1}) = P(t_{k-1} + 1, t_k) \quad (10)$$

$$\mu_k = S(1, t_k) - S(1, t_{k-1}) = S(t_{k-1} + 1, t_k) \quad (11)$$

따라서 클래스 간의 수정된 변이값  $\sigma_B^2$ 는 다음 식과 같이 나타낼 수 있다.

$$\sigma_B^2(t_1, t_2, \dots, t_i, \dots, t_{M-1}) = H(1, t_1) + H(t_1 + 1, t_2) + \dots + H(t_{M-1} + 1, L) \quad (12)$$

여기서 룩업테이블 함수  $H$ 는 다음과 같이 정의된다.

$$H(t_{i-1} + 1, t_i) = \frac{S(t_{i-1} + 1, t_i)^2}{P(t_{i-1} + 1, t_i)} \quad (13)$$

**3. 밸리 강조법(the valley-emphasis method)**

Otsu 방법은 영상 히스토그램이 뚜렷하게 피크(peak)와 밸리(valley)를 가질 때 영상분할이 잘 이루어진다. 하지만 영상을 이용하여 조그만 결함을 탐지하는 경우에는 그림 1(b)와 같이 영상 히스토그램의 피크와 밸리의 구분이 뚜렷하게 형성되지 않는다.

밸리강조법의 목적은 그림 1에서 보는 바와 같이 배경에서 목표물을 분리할 수 있도록 영상 히스토그램의 밸리를 찾는 것이다. 그림 1처럼 문턱값이 한 개인 경우는 그 문턱값은 두 개의 피크 사이의 밸리에 위치하거나(그림 1(a) 경우), 한 개의 피크만 있는 경우 그 피크의 가장자리에 위치하게 된다(그림 1(b) 경우). 여기서 알 수 있는 중요한 사실은 문턱값의 위치에 해당하는 그레이 레벨의 발생확률  $P_i$ 가 매우 낮아야 한다는 것이다.




그림 1. 그레이 레벨 히스토그램의 문턱값 형성 예.  
Fig. 1. Optimal threshold selection in gray-level histogram.

이러한 관찰을 바탕으로 Ng 등[2]은 Otsu의 방법을 개량하여 문턱값을 설정하도록 하였는데, 밸리강조법이라고 부른다. 밸리강조법은 선정되는 문턱값에서 그레이레벨 발생확률을 작게 만들어 주고 동시에 Otsu 방법에서와 같이 두 클래스 사이의 변이값을 최대화 시키도록 한다. 2 개의 클래스로 영상을 분할하는 경우에 밸리강조법을 적용하여 문턱값을 선정하는 식은 다음과 같다.

$$t^* = \text{Arg Max}_{0 \leq t \leq L-1} \left\{ (1 - p_t) (\omega_1(t) \mu_1^2(t) + \omega_2(t) \mu_2^2(t)) \right\} \quad (14)$$

위 식 (14)는 문턱값이 한 개인 경우이지만 문턱값이 M-1 (M개의 클래스 분할)인 경우도 다음 식과 같이 쉽게 확장할 수 있다. 해당되는 최적의 문턱값  $\{t_1^*, t_2^*, \dots, t_{M-1}^*\}$ 은 다음 식과 같이 구해진다.

$$\{t_1^*, t_2^*, \dots, t_{M-1}^*\} = \text{Arg Max}_{0 \leq t_1 < t_2 < \dots < t_{M-1} < L} \left\{ \left[ 1 - \sum_{j=1}^{M-1} p_{t_j} \right] \left( \sum_{k=1}^M \omega_k \mu_k^2 \right) \right\} \quad (15)$$

그림 2는 용액 내부에 있는 오염물질을 검출하는 예이다. 그림 2(a)는 원 영상이고, 그림 2(b)는 원 영상의 히스토그램이다. 원 영상에서 오염물질(검은 점)이 배경에 비해 상당히

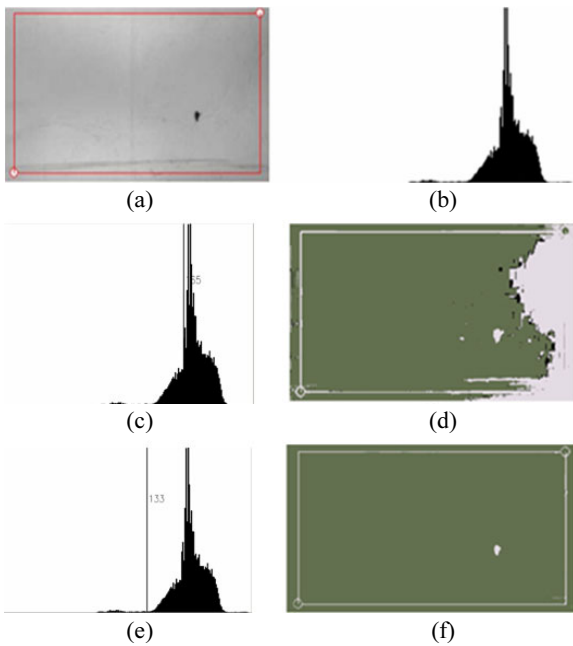


그림 2. 목표물이 작은 경우 밸리강조법과 수정된 Otsu 방법의 영상분할 결과 비교: (a)원 영상, (b) 히스토그램, (c) 수정된 Otsu 방법에서의 문턱값(=165), (d) 수정된 Otsu 방법에서의 영상분할 결과, (e) 밸리강조법에서의 문턱값(=133), (f) 밸리강조법에서의 영상분할 결과.

Fig. 2. Image segmentation comparison of valley-emphasis method and modified Otsu's method for small object: (a) original image, (b) histogram of image, (c) threshold value using modified Otsu's method(=165), (d) semented image using modified Otsu's method, (e), threshold value using Valley-emphasis method(=133), and (f) semented image using Valley-emphasis method.

작기 때문에 히스토그램은 피크가 한 개만 발생하는 유니모달(unimodal) 분포를 하고 있음을 알 수 있다. 적절한 문턱값은 배경으로부터 작은 오염물질을 분리할 수 있어야 한다. 그림 2(c)와 그림 2(d)는 Otsu 방법을 사용한 경우의 문턱값과 영상분할된 이미지를 나타내고 있다. 이 경우 문턱값의 선정이 잘못되어 있고, 결과적으로 영상분할도 실패하였다고 볼 수 있다. 반면에, 그림 2(e)와 그림 2(f)는 밸리강조법을 사용한 경우의 문턱값과 영상분할된 이미지를 나타낸다. 정상적으로 영상분할이 이루어졌다는 것을 알 수 있다.

### III. 제안된 문턱값 자동선정 기법

#### 1. 새로운 피크 검출 알고리즘의 제안

문턱값 선정과정이란 그레이 레벨 분포를 바탕으로 영상을 몇 개의 다른 구역으로 분리시키는 것을 말한다. 이를 위해 히스토그램을 사용한다. 일반적으로 영상이 배경과 목표물로 양분되는 경우는 히스토그램도 2개의 피크를 가지고 그 사이 한 개의 밸리를 갖게 된다. 디지털 영상을 다룰 때 대부분의 영상에 있어서 명암강도의 변화가 연속적으로 이루어 지므로 단 한 개의 문턱값을 사용하게 되면 중요한 부분의 특징을 잃어버릴 수도 있다. 그림 3은 이 경우에 대한 예를 보여주고 있다.

그림 3의 영상 히스토그램은 3개의 피크를 가지고 있으므로, 3개의 클래스를 가지고 있다. 이 영상에 단지 2개의 클래스를 분할하도록 한 개의 문턱값을 선정해 보자. Otsu 방법에서는 문턱값이 141이고, 밸리강조법에서는 문턱값이 153이 되었다. 그리고 이 문턱값으로 영상을 분할 한 결과가 그림 3의 2번째 줄과 3번째 줄에 나타나 있다. 영상분할된 이미지가 제대로 분류되어 있지 않음을 확인할 수 있다. 따라서, 위




그림 3. 3개의 피크를 갖는 영상에서 2개의 클래스로 영상분할한 경우: 원 영상 및 히스토그램(a), 수정된 Otsu 방법-문턱값=141(b), 밸리강조법-문턱값=153(c).

Fig. 3. Image having three peaks into two classes segmentation: original images and image histogram (a), image segmentation using Otsu's method-threshold=141 (b), image segmentation using Valley-emphasis method-threshold=153(c).

와 같이 3개의 클래스를 갖는 영상을 정상적으로 분할하기 위해서는 2개의 문턱값이 필요하게 된다. 이와 같이 최적의 영상분할을 하기 위해서는 주어진 영상에 따라 적응적으로 문턱값의 개수 및 문턱값을 선정하는 것이 중요하다. 본 연구에서는 원 영상의 히스토그램으로부터 핵심적인 피크 (significant peak)의 수와 최적의 문턱값의 개수를 선정하는 방법을 다음과 같이 제안한다.

1) 그레이레벨 값을 입력하여 대응하는 히스토그램 주파수 값을 구하고 셋  $H_0$ 에 저장한다.

$$H_0 = \{i, hist(i)\} \tag{16}$$

여기서  $i$ 는  $i$ 번째 그레이 레벨을 말하며  $i \in [0, 255]$ 의 범위를 가진다.  $hist(i)$ 는  $i$ 번째 그레이 레벨에 대응하는 주파수 값이다.

2) 히스토그램을  $[0,1]$  범위로 정규화(normalization) 한다.

$$H_1 = Normalize\{i, hist(i)\} \tag{17}$$

여기서  $hist(i) \in [0,1]$ 과  $i \in [0,255]$ 의 범위를 가진다.

3) 아래 정의된  $H_2$  관계식을 이용하여 모든 지역최댓값을 찾는다.

$$H_2 = \{(i, hist(i)), hist(i) > hist(i-1) \text{ and } hist(i) < hist(i+1)\} \tag{18}$$

여기서  $(i, hist(i)) \in H_1$  이고  $i$ 는  $i \in [0, 255]$ 의 범위를 갖는다.

4) 모든 지역최댓값들을 가장 큰 지역최댓값과 비교한다. 지역최댓값이 가장 큰 지역최댓값보다 적으면 제거시킨 후 셋  $H_3$ 를 구한다. 아래 식에서 제거를 위한 결정상수  $C$ 는 실험적으로 구해지는 상수이다.

$$H_3 = \{(i, hist(i)), hist(i) > C * Max(hist(i))\} \tag{19}$$

여기서  $(i, hist(i)) \in H_2$  이고  $i$ 는  $i \in [0, 255]$ 의 범위를 갖는다.

5) 셋  $H_3$ 에서 두개의 인접한 피크의 값 차이가  $K$ 보다 적으면 적은 값의 피크를 제거하여 다음과 같이 셋  $H_4$ 를 계산한다. 아래 식에서 상수  $K$ 는 실험적으로 구해지는 상수이다.

$$H_4 = \{H_3 - (i, hist(i)) | (i > j, (i - j) < K) \text{ and } hist(i) = Min(hist(i), hist(j))\} \tag{20}$$

위 식 (19)와 (20)에서의 상수  $C$ 와  $K$ 는 본 연구의 실험에서 각각 0.025와 25가 사용되었다. 결과적으로 셋  $H_4$ 에 있는 요소의 개수가 히스토그램에서 핵심 피크의 개수가 된다. 위 알고리즘의 적용한 예를 그림 4에 나타내었다.

핵심 피크점들을 검출하는 본 연구의 알고리즘을 Otsu 방법과 밸리강조법에 적용하여 영상 분할한 결과를 그림 5에 나타내었다. 원 영상은 그림 3에서 사용하였던 영상을 사용하였다. 그림 5에서 영상 히스토그램은 3개의 피크를 가진다. 즉, 영상은 3개의 클래스로 분할이 될 수 있음을 의미한다. 먼저, Otsu 방법에서는 문턱값의 그레이레벨이 94와 169로 계산되었고, 밸리강조법에서는 문턱값의 그레이 레벨이 87과 175로 계산되었다. 두 결과를 비교해 보았을 때 밸리강조법을 적용한 경우 문턱값이 히스토그램의 지역최솟값에 가까운 것을 알 수 있고, 밸리강조법이 Otsu 방법보다 영상분할




그림 4. 제안된 알고리즘을 이용한 히스토그램 피크 검출: 원 영상(a), 히스토그램 피크검출-2 peak, 3 peak, 4 peak (b).  
 Fig. 4. Histogram peak detection by proposed algorithm: original images (a) and histogram peaks detection-2 peak, 3 peak, and 4 peak (b).




그림 5. 3개의 피크를 갖는 영상에서 3개의 클래스로 영상분할한 경우: 원 영상 및 히스토그램 (a), 수정된 Otsu 방법-문턱값=94, 169 (b), 밸리강조법-문턱값=87, 175 (c).  
 Fig. 5. Image has three peaks and three classes segmentation: original images and image histogram (a), image segmentation using Otsu's method-threshold=94, 169 (b), image segmentation using Valley emphasis method-threshold=87, 175 (c).

성능이 우수한 것을 알 수 있다.

2. 영상분할을 위한 진화론적인 방법의 제안

본 단원에서는 Otsu 방법과 밸리강조법을 기반으로 하여 영상분할의 성능을 높이기 위해 힐 크라이밍 알고리즘(HCA: Hill Climbing Algorithm)을 결합한 수정된 적응 유전자알고리

즘(MAGA: Modified Adaptive Genetic Algorithm)을 제안하였다. 보통의 유전자알고리즘에서 교배확률(cross-over probability)  $P_c$ 와 변이확률(mutation probability)  $P_m$ 을 경험적으로 결정하는데, 적당한 값을 정하기도 어렵고 또한 해석하는 대상이 달라지면 이 값도 다시 재선정 해야 한다. 이러한 문제점을 해결하기 위해 Srinivas 등 [17]은 적응유전자알고리즘(AGA: Adaptive Genetic Algorithm)을 제안하였다. 이 방법에서는  $P_c$ 와  $P_m$ 값이 다음의 관계식에 의해 자동적으로 조정 된다.

$$P_c = \begin{cases} k_1 \frac{f_{\max} - f'}{f_{\max} - f_{avg}}, & f' \geq f_{avg} \\ k_2, & \text{otherwise} \end{cases} \quad (21)$$

$$P_m = \begin{cases} k_3 \frac{f_{\max} - f}{f_{\max} - f_{avg}}, & f \geq f_{avg} \\ k_4, & \text{otherwise} \end{cases} \quad (22)$$

위 식에서  $f_{\max}$ 는 최대적합도값(maximum fitness value)이며,  $f_{avg}$ 는 개체들의 평균적합도값이며,  $f$ 는 교배작업을 하는 두 개체에서 큰 적합도값이며,  $f'$ 는 변이작업이 일어나는 개체의 적합도값이다.  $k_2$ 는 초기 교배확율이고,  $k_4$ 는 초기 변이확율이며, 위 식에 사용된 변수들은  $0 < k_1, k_2, k_3, k_4 \leq 1$ 의 범위를 갖는다.

식 (21)과 식 (22)에서 교배확률과 변이확률은 적합도값이 최대적합도값에 근접할수록 작은 값을 갖게 된다. 이러한 조정은 유전자알고리즘의 마지막 단계에서 수렴안정성을 높이기 한다. 하지만 초기단계에서는 최대적합도값에 가까운 개체는 바뀌지 않고 조기포화(premature)를 하기 때문에 이러한 접근은 바람직하지 않다. 따라서, 본 연구에서는 교배확률과 변이확률을 다음과 같이 수정하였다.

$$P_c = \begin{cases} P_{c1} - k_1 \frac{f_{\max} - f'}{f_{\max} - f_{avg}}, & f' \geq f_{avg} \\ P_{c1}, & \text{otherwise} \end{cases} \quad (23)$$

$$P_m = \begin{cases} P_{m1} - k_2 \frac{f_{\max} - f}{f_{\max} - f_{avg}}, & f \geq f_{avg} \\ P_{m1}, & \text{otherwise} \end{cases} \quad (24)$$

## 2.1 수정된 적응 유전자알고리즘(MAGA)의 제안

### 2.1.1 수정된 적합도 함수

유전자알고리즘에서 또 다른 중요한 문제는 적합도함수를 잘 조정하는 것이다. 이것은 AGA에서 성능향상과 매우 밀접하게 연관되기 때문이다. 유전자알고리즘을 진행하면 몇 세대가 지나자 마자 소수의 개체가 매우 높은 적합도 값을 가지는 경우가 있는데 슈퍼 수퍼 개체(super-chromosome)라고 한다. 슈퍼 개체들은 조기포화(premature)의 원인이 된다. 본 연구에서는 현재 세대의 모든 개체에 대한 적합도 값을 조정 하도록 선형조정 적합도(linear adjustment fitness)함수를 제안하고자 한다. 이 방법은 AGA 과정 중에 슈퍼 개체가 다른 개체를 당겨서 조기포화가 되게 하거나 지역극대값(local extrema)에 빠지는 것을 예방하도록 해 준다.

식 (25)에서  $G$ 는 현 세대의 개체에 대한 우량능력(goodness ability)를 나타내는 상수값이며 수정된 Otsu 방법에 기반한

MAGA 경우는 식 (12)에서의 최댓값을 이용하고, 벨리강조법에 기반한 MAGA 경우는 식 (15)에서의 최댓값을 이용하여 계산되는 값이다.  $f$ 는 조정된 적합도 함수이다.

$$f = a * G + b \quad (25)$$

위 식에서 계수  $a$ 와  $b$ 는 다음과 같이 계산된다.

$$\text{If } G_{\min} > 2G_{avg} - G_{\max} : \begin{cases} a = \frac{G_{avg}}{G_{\max} - G_{avg}} \\ b = a(G_{\max} - 2G_{avg}) \end{cases} \quad (26)$$

$$\text{If } G_{\min} < 2G_{avg} - G_{\max} : \begin{cases} a = \frac{G_{avg}}{G_{avg} - G_{\min}} \\ b = -aG_{\min} \end{cases} \quad (27)$$

$$\text{If } G_{\min} = 2G_{avg} - G_{\max} : \begin{cases} a = 1 \\ b = 0 \end{cases} \quad (28)$$

위 식에서  $G_{\max}$ ,  $G_{avg}$ ,  $G_{\min}$ 는 각각 최대우량값, 평균우량값 및 최소 우량값을 나타낸다.

### 2.1.2 수정된 재생산 오퍼레이터

다음 세대에서 더 우수한 개체를 재생산하기 위해 다음의 과정을 수행한다.

- 1) 이전 세대에서  $N$ 개의 개체를 선정하기 위한 선택연산(selection operator)을 수행한다.
- 2) 이전 세대의 25%인  $N/4$ 개의 우수개체들을 현 세대로 복제한다.
- 3) 25%인  $N/4$  개의 열등개체들을 현 세대로부터 제거한다.
- 4) 현 세대에서  $N/4$  개의 임의(random)개체들을 생성한다.
- 5) 적응교배(adaptive cross-over)연산을 수행한다.
- 6) 적응변이(adaptive mutation)연산을 수행한다.
- 7) 현 세대의 개체들을 적합도 값의 내림차순으로 정렬하고, 이것을 새로운 세대로 한다.

위 과정에서 단계2)와 단계3)은 새로운 세대의 우량능력을 증가시킨다. 단계4)는 개체들이 지역극대값에 빠지는 것을 방지하는 효과가 있다. 이러한 성능은 나중의 실험에서 알 수 있을 것이다.

### 2.1.3 다수의 문턱값 선정을 위한 알고리즘 제안

MAGA에 기반하여 다수의 문턱값을 선정하기 위한 알고리즘은 다음의 단계를 갖는다.

- 1) 개체의 코딩(coding): 두개의 연속된 피크 사이의 거리를 정한다. 1개 범위 안에서의 후보 문턱값을 나타내기 위해 8비트 이진코드가 사용된다. 그레이 레벨 히스토그램이  $M$ 개의 피크를 가지면 코딩은  $M-1$ 개로 구분되고 각각의 구분은 그림 6과 같이 8비트의 데이터로 구성된다.
- 2) 초기 개체집단: 초기 개체는 난수적으로 생성된다. 각 개체의 크기와 개체 수는 영상분할 할 클래스에 따라 달라진

8 bits	8 bits	⋯	8 bits	8 bits
For threshold $k_1$	For threshold $k_2$	⋯	For threshold $k_{M-2}$	For threshold $k_{M-1}$

그림 6. 각 개체의 이진코딩.

Fig. 6. Binary code scheme for one chromosome.



다. 일반적으로 분할할 클래스가 많아질수록 개체의 크기와 개체 수가 증가한다. 처음 세대에서 Gen=0으로 설정한다. 수정된 Otsu 방법을 적용하는 경우 개체의 크기와 개체 수는 다음과 같이 설정한다.

$$\begin{aligned} \text{Number of individuals} &= 10 * \text{Number of class} \\ \text{Number of generation} &= 10 * \text{Number of class} \end{aligned} \quad (29)$$

반면에 벨리강조법을 적용하는 경우 개체의 크기와 개체 수는 다음과 같이 설정한다.

$$\begin{aligned} \text{Number of individuals} &= 15 * \text{Number of class} \\ \text{Number of generation} &= 15 * \text{Number of class} \end{aligned} \quad (30)$$

여기서 그레이레벨값이 0~255 범위이므로  $i$ 번째 문턱값의 범위는  $0 \leq k_i \leq 255$ 이고, 인접한  $i, j$ 번째의 문턱값은  $k_i < k_j, i < j, i, j = 1, M - 1$  조건을 만족한다. 그러므로, 난수적으로 초기 세대를 생성한 후에 문턱값을 오름차순으로 정렬해야 하고, 각 개체 내의 비트를 위 조건에 맞게 재정렬해야 한다.

3) 적합도 함수: 적합도값은 각 개체의 우량능력을 나타낸다. 따라서 수정된 Otsu 방법이나 벨리강조법을 이용한 클래스의 최대변이값을 적합도 함수로 사용한다. 수정된 Otsu 방법을 사용하는 경우 식 (12)를 이용하고, 벨리강조법을 사용하는 경우 식 (15)를 이용한다.

4) 적합도 값의 조정: 5.2.1절에서 언급한 선형조정방법을 이용하여 각 개체에 대한 적합도 값을 조정한다.

5) 다음세대의 생성:

5.1) 개체의 선택: 개체선택의 목적은 우수한 개체를 선정하는 것이므로 우수한 부모의 형질이 다음세대의 개체로 전달될 기회가 높아진다. 이를 위해 본 연구에서는 룰렛휠 방법이 사용되며 N개의 개체로서 다음 세대를 구성한다. N 값은 식 (29)나 식 (30)에 의해 계산된다.

5.2) 이전 세대의 25%인 N/4 개의 우수개체들을 현 세대로 복제한다.

5.3) 25%인 N/4 개의 열등개체들을 현 세대로 부터 제거한다.

5.4) 현 세대에서 N/4 개의 임의(random)개체들을 생성한다.

5.5) 교배: 다점(multi-point) 교배 연산을 수행한다. 개체의 각 부분요소는 한 개의 교배점(cross-over point)를 갖는다. 이러한 작업으로 각 부분요소는 다른 요소와 균형적으로 교배할 기회를 갖게 되고 다음 세대에서 우수한 개체를 갖게 할 확률을 높게 된다. 적응 교배확률은 식 (23)에 정의되어 있다.


5.6) 변이: 교배연산과 같은 방법으로 변이연산을 수행한다. 개체의 각 부분요소는 한 번의 비트 변이과정을 겪는다. 적응 변이확률은 식 (24)에 정의되어 있다.

6) 종료조건: 한 세대 후 Gen = Gen + 1 이 되며 만약 Gen = Number of Generation 이면 알고리즘이 종료된다. 그 경우가 아니면 단계3)으로 되돌아 간다.


2.2 MAGA+HCA(hill-climbing algorithm) 방법의 제안

MAGA 방법은 최적화 문제에서 전역 최적값을 찾을 수 있게 해 준다. 하지만, 그 방법은 근사해를 제공하며 최적해에 도달하는데 꽤 많은 시간을 소모한다. 따라서, 이러한 문제점을 해결하기 위해 여러 개의 문턱값을 구하는 데에 MAGA+HCA 방법을 제안하고자 한다.


The first parent:



The second parent:



The first new children:



The second new children:




그림 7. 교배 연산의 수행 예.

Fig. 7. An example of cross-over operation.

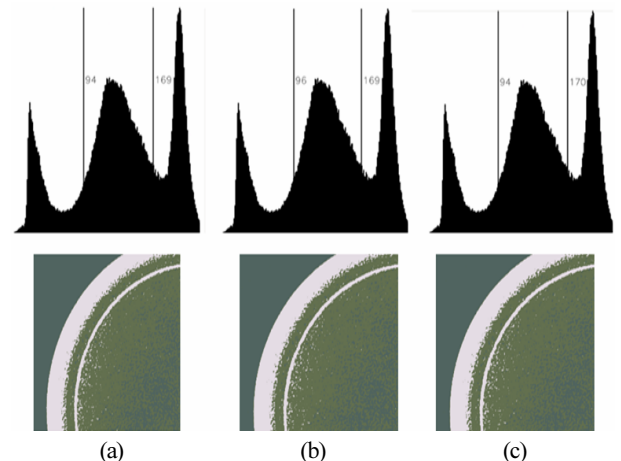


그림 8. 수정된 Otsu 방법에 근거한 각 알고리즘들의 성능 비교. (a) 수정된 Otsu 방법 (thresholds = {94, 169}; Maximum Sigma = 23620.725; Running time = 0.015s), (b) 수정된 Otsu 기반 MAGA (thresholds = {96, 169}; Maximum Sigma = 23620.459; Running time = 0.027s), (c) 수정된 Otsu 기반 MAGA+HCA (thresholds = {94, 170}; Maximum Sigma = 23620.560; Running time = 0.027s).

Fig. 8. Performance comparison of three approaches based on the modified Otsu's method. (a) Modified Otsu's method (thresholds={94, 169}; Maximum Sigma=23620.725; Running time = 0.015s), (b) MAGA based on Modified Otsu's method(thresholds = {96, 169}; Maximum Sigma = 23620.459; Running time = 0.027s), (c) MAGA+HCA based on Modified Otsu's method (thresholds = {94, 170}; Maximum Sigma = 23620.560; Running time = 0.027s).

1) MAGA 과정: 앞 절에서 설명한 MAGA 알고리즘을 종료조건까지 동작시킨다.

2) HCA 과정: MAGA 과정의 지난 세대에서 우수개체의 N/4를 선택하고 HCA과정의 첫 번째 포인트로 할당한다. 그

리고 반복값을  $Iter=0$ 으로 둔다.

2.1) 각 개체  $i=1...N/4$  에 대해 난수 정수값  $Val$ 를 생성한다. 수정된 Otsu 방법에는  $Val \in [1, \text{Number of class}]$ , 벨리강조범에는  $Val \in [1, 2 * \text{Number of class}]$ 와 같이 범위를 정한다.

2.2) 각 문턱값  $k=1...M-1$  에 대해

2.2.1) 난수정수값  $Rand \in [0,1]$ 을 생성한다.

+ 만약  $Rand = 0$ 이면 문턱값을  $threshold[k] = threshold[k] + Val$ 으로 수정한다.

+ 그 외는 문턱값을  $threshold[k] = threshold[k] - Val$ 으로 수정한다.

2.2.2) 다음 조건을 확인한다.

+ 만약  $threshold[k-1] < threshold[k] < threshold[k+1]$  (식에서  $k=2...M-2$ )이면, 식 (12)(수정된 Otsu 방법 기반인 경우) 혹은 식 (15) (벨리강조범 기반인 경우)를 이용하여 새로운 문턱값 결과를 평가한다. 새 문턱값 결과가 현재 결과보다 좋으면  $thresholds$  를 업데이트 한다.

2.3)  $Iter = Iter + 1$ 로 하고 단계 2.1로 돌아간다.  $Iter = T$  일 때 종료한다. 종료조건 T 다음과 같다.

+ 수정된 Otsu's method 방법:  $T=10 * \text{Number of class}$

+ 벨리강조범:  $T=15 * \text{Number of class}$

수정된 Otsu 방법에 근거한 각 진화론적 알고리즘들의 성능을 그림 8에 예시적으로 나타내었다.

같은 방법으로 벨리강조범에 근거한 각 진화론적 알고리즘들의 성능을 그림 9에 예시적으로 나타내었다.




그림 9. 벨리강조범에 근거한 각 알고리즘들의 성능 비교. (a) 벨리강조범 (thresholds = {87, 175}; Maximum Sigma = 23469.928; Running time = 0.016s), (b) 벨리강조범기반 MAGA (thresholds = {90, 175}; Maximum Sigma = 23469.654; Running time = 0.032s), (c) 벨리강조범 MAGA+HGA (thresholds = {87, 175}; Maximum Sigma = 23469.928; Running time = 0.032s).

Fig. 9. Performance comparison of three approaches based on the Valley-emphasis method. (a) Valley-emphasis method - thresholds = {87, 175}; Maximum Sigma = 23469.928; Running time = 0.016s, (b) MAGA based on Valley-emphasis method - thresholds = {90, 175}; Maximum Sigma = 23469.654; Running time = 0.032s, (c) MAGA+HCA based on Valley-emphasis method - thresholds = {87, 175}; Maximum Sigma = 23469.928; Running time = 0.032s.

위의 예시에서 보면 영상분할적인 면에서는 두드러진 차이점은 없다. 즉, 진화적인 방법에 의한 영상분할이 일반적인 Otsu 방법이나 벨리강조범에 비해 장점이 없는 것 처럼 보인다. 하지만, 클래스의 수가 증가함에 따라 MAGA+HCA 방법과 MAGA 방법의 계산시간이 훨씬 작다는 것을 다음 장에서 밝히고자 한다.

#### IV. 실험결과 및 고찰

실험에 사용된 영상은 3504\*2336 픽셀의 컬러 영상이며, 그림 10에서 보는 바와 같이 영상의 히스토그램은 6개의 피크를 가지고 있다. 사용된 영상은 2개에서 6개까지의 클래스로 분할하는 실험을 수행하였다. 사용된 알고리즘은 앞에서 소개한 바와 같이 수정된 Otsu 방법과 벨리강조범에 기반을 둔 확장 알고리즘이다. 그림 11은 수정된 Otsu 방법에 기반한 확장 알고리즘의 결과를 비교한 그림이다. 그림 11(a), (b), (c)는 각각 Otsu 방법만 사용한 경우, Otsu 기반 MAGA 알고리즘, 그리고 Otsu 기반 MAGA+HCA 알고리즘을 적용한 결과를 비교한 그림이다. 그림 12(a), (b), (c)는 각각 벨리강조범만 사용한 경우, 벨리강조범 기반 MAGA 알고리즘, 그리고 벨리강조범 기반 MAGA+HCA 알고리즘을 적용한 결과를 비교한 그림이다.

실험데이터는 5번 반복실험하여 얻은 결과를 평균하여 얻은 자료이며 다음 표와 같이 요약될 수 있다.

표 1은 수정된 Otsu 방법에 기반한 알고리즘을 사용하여




그림 10. 실험에 사용된 영상 및 히스토그램 피크값 (35, 82, 106, 153, 186, 246).

Fig. 10. The experiment image and the histogram peaks (35, 82, 106, 153, 186, 246).




그림 11. Otsu 방법에 기반한 6개 클래스 분할 결과 비교. (a) Otsu 방법만 사용한 경우, (b) Otsu 기반 MAGA 알고리즘 적용, (c) Otsu 기반 MAGA+HCA 알고리즘 적용.

Fig. 11. The comparison of 6- classe image segmentation methods based on Otsu's method. (a) Otsu method only, (b) MAGA algorithm based on Otsu method, (c) MAGA+HCA algorithm based on Otsu method.

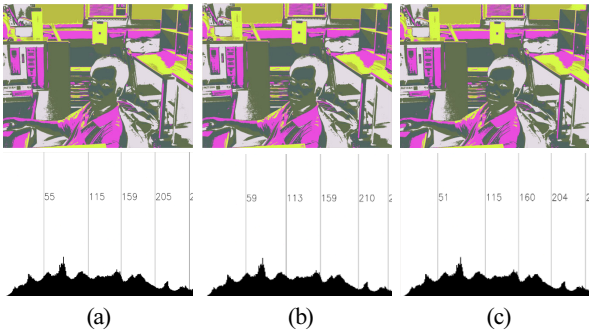


그림 12. 밸리강조법에 기반한 6개 클래스 분할 결과 비교. (a) 밸리강조법만 사용한 경우, (b) 밸리강조법기반 MAGA 알고리즘 적용, (c) 밸리강조법 기반 MAGA+HCA 알고리즘 적용.

Fig. 12. The comparison of 6- class image segmentation methods based on valley emphasis method. (a) valley emphasis method only, (b) MAGA algorithm based on valley emphasis method, (c) MAGA+HCA algorithm based on valley emphasis method.

표 1. 수정된 Otsu 방법에 기반한 알고리즘을 사용한 영상 분할 성능비교.

Table 1. Performance comparison of image segmentation using the algorithm based on modified Otsu method.

		Otsu	MAGA Otsu	MAGA+HCA Otsu
2 classes	Max Sigma	19137.325	19137.325	19137.325
	Thresholds	{132}	{132}	{132}
	Time (seconds)	0.031	0.032	0.032
3 classes	Max Sigma	19797.283	19796.715	19797.185
	Thresholds	{100, 179}	{98, 179}	{99, 179}
	Time (seconds)	0.031	0.032	0.047
4 classes	Max Sigma	20051.642	20051.236	20051.460
	Thresholds	{74, 131, 197}	{76, 133, 199}	{73, 131, 196}
	Time (seconds)	0.047	0.053	0.059
5 classes	Max Sigma	20177.415	20176.578	20176.578
	Thresholds	{64, 111, 158, 210}	{66, 111, 156, 210}	{66, 111, 156, 210}
	Time (seconds)	2.329	0.109	0.142
6 classes	Max Sigma	20239.887	20235.619	20239.409
	Thresholds	{54, 92, 130, 171, 218}	{49, 83, 124, 166, 216}	{53, 92, 131, 171, 216}
	Time (seconds)	150.86	0.156	0.178

영상의 분할 클래스를 2개부터 6개까지 분할한 경우의 결과를 비교하였다.

표 2에서는 밸리강조법에 기반한 알고리즘을 사용하여 영상의 분할 클래스를 2개부터 6개까지 분할한 경우의 결과를 비교하였다.

다음 실험결과로부터 얻어진 데이터 표를 보면 MAGA+HCA 방법이 MAGA 만을 적용했을 때 보다 성능이 약간 우수하다. 두 방법 모두 짧은 시간에 최적해에 도달하는 것을 관측할 수 있다. 두 방법 모두 영상분할 하는 클래스의 수가 높지 않을 때 즉 클래스의 수가 2-4개 정도일 때에는 기존의 Otsu 방법이나 밸리강조법 만을 사용한 경우에 비해 계산시간이 비슷했지만, 클래스의 수가 증가함에 따라 MAGA+HCA 방법과 MAGA 방법의 계산시간이 훨씬 작다는 것을 알 수 있다. 이러한 이유는 기존의 Otsu 방법이나 밸리강조

표 2. 밸리강조법에 기반한 알고리즘을 사용한 영상 분할 성능비교.

Table 2. Performance comparison of image segmentation using the algorithm based on valley emphasis method.

		Valley-emphasis	MAGA Valley-emphasis	MAGA+HCA Valley-emphasis
2 classes	Max Sigma	19047.375	19047.375	19047.375
	Thresholds	{134}	{134}	{134}
	Time (seconds)	0.046	0.047	0.047
3 classes	Max Sigma	19628.743	19627.072	19628.179
	Thresholds	{113, 198}	{114, 197}	{115, 198}
	Time (seconds)	0.031	0.052	0.055
4 classes	Max Sigma	19828.935	19826.581	19826.656
	Thresholds	{91, 159, 222}	{76, 133, 199}	{73, 131, 196}
	Time (seconds)	0.078	0.081	0.085
5 classes	Max Sigma	19886.290	19884.817	19884.817
	Thresholds	{65, 115, 159, 222}	{66, 117, 160, 224}	{66, 117, 160, 224}
	Time (seconds)	4.016	0.25	0.282
6 classes	Max Sigma	19889.489	19878.068	19881.215
	Thresholds	{55, 115, 159, 205, 251}	{59, 113, 159, 210, 250}	{51, 115, 160, 204, 250}
	Time (seconds)	259.986	0.442	0.453

법은 계산시간이 각각  $O(N)^M$ 과  $O(N)^{M-1}$ 수준인데 반해 MAGA+HCA 방법과 MAGA 방법은 두 경우 모두 계산시간이  $O(N)^3$ 수준으로 수렴되기 때문이다. 여기서 M은 클래스의 수를 나타내기 때문에 클래스의 수가 증가할수록 기존의 Otsu 방법이나 밸리강조법의 계산시간이 크게 늘어나는 것이다. 예를 들어 클래스의 수가 6개 일 때 Otsu 방법은 150초 이상의 시간이 소요되지만, MAGA+HCA 방법과 MAGA 방법에서는 0.2초 정도의 계산시간만 소요될 뿐이다. 마찬가지로 밸리강조법 기반에 있어서도 밸리강조법만 사용한 경우 260초 이상의 시간이 소요되지만, MAGA+HCA 방법과 MAGA 방법에서는 0.5초 정도의 계산시간만 소요되었다.

### V. 결론

본 문턱값(thresholding)을 자동적으로 선정하는 것은 영상 분할(image segmentation)의 중요한 기술적 요소이다. 영상분할은 글자인식, 기계부품이나 농산품의 불량검사, 시각적인 변화의 인식[5] 및 움직이는 물체의 분할 등에 중요하게 사용되고 있다.

본 논문은 영상분할에서 다수의 문턱값을 최적으로 선정하기 위해 먼저 대표적인 영상분할 방법인 Otsu 방법과 밸리강조법을 조사하였고, 이를 바탕으로 신뢰성이 있으면서도 효과적인 자동 문턱값 선정 알고리즘을 제안하였다. 제안된 알고리즘은 기존의 Otsu 방법과 밸리강조법에 변형된 적응 유전자 알고리즘(MAGA: Modified Adaptive Genetic Algorithm)과 HCA(Hill-Climbing Algorithm)를 결합한 형태이다.

제안된 알고리즘은 기존의 Otsu 방법과 밸리강조법에 비해 영상분할 성능과 계산시간 측면에서 현저한 장점을 보였다. 클래스의 수가 증가함에 따라 Otsu 방법과 밸리강조법에 MAGA+HCA나 MAGA를 접목한 경우가 단순히 Otsu 방법과 밸리강조법만 사용한 경우에 비해 계산시간이 월등하게 줄 수 있다는 점을 실험적으로 입증하였다. 향후 제안된 알고리즘을 이용해서 과일과 같은 농산품의 흠이나 손상 등을 판별하는데 적용하고자 한다.



**참고문헌**

[1] F. Yana, H. Zhanga, and C.R. Kube, "A multistage adaptive thresholding method," *Pattern Recognit. Lett.*, vol. 26, no. 8, pp. 1183-1191, June. 2005.

[2] H. F. Ng, "Automatic thresholding for defect detection," *Pattern Recognit. Lett.*, vol. 27, no. 14, pp. 1644-1649, Oct. 2006.

[3] J. Jin, Li, G. Liao, X. Yu, and L.C. Viray, "Methodology for potatoes defects detection with computer vision," *Proc. of International Symposium on Information Processing*, pp. 346-351, Aug. 2009.

[4] Y. C. Chiou, "Intelligent segmentation method for real-time defect inspection system," *Comput. Indust.*, vo. 61, no. 7, pp. 646-658, Sep. 2010.

[5] C. Su and A. Amer, "A real-time adaptive thresholding for video change detection," *Proc. of International Conference on Image Processing*, pp. 57-160, Oct. 2006.

[6] S. Y. Chien, Y. W. Huang, B. Y. Hsieh, S. Y. Ma, and L. G. Chen, "Fast video segmentation algorithm with shadow cancellation, global motion compensation, and adaptive threshold techniques," *IEEE Trans. Multi.*, vol. 6, no. 5, pp. 732-748, Oct. 2004.

[7] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Trans. Sys, Man and Cybernetics*, vol. 9, no. 1, pp. 62-66, Jan. 1979.

[8] P. S. Liao, T. S. Chen, and P. C. Chung, "A fast algorithm for multilevel thresholding," *J. Inform. Sci. Eng.*, vol. 17, pp. 713-727, Sep. 2001.

[9] H. Mo, Z. Li, J. B. Park, Y. H. Joo, and X. Li, "Fitness landscape for simple genetic algorithms supplied with adequate superior order-1 building blocks," *International Journal of Control, Automation, and Systems(IJCAS)*, vol. 8, no. 1, pp. 135-140, Feb. 2010.

[10] A. Tsukahara and A. Kanasugi, "Genetic algorithm with dynamic variable number of individuals and accuracy," *International Journal of Control, Automation, and Systems(IJCAS)*, vol. 7, no. 1, pp. 1-6, Feb. 2009.

[11] P. Kanungo, P. K. Nanda, and U. C. Samal, "Image segmentation using thresholding and genetic algorithm," CiteSeerx digital library, Jul. 2006.

[12] L. Hui, C. Shi, M. S. Ao, and Y. Q. Wu, "Application of an improved genetic algorithm in image segmentation," *Proc. of International Conference on Computer Science and Software Engineering*, pp. 898-901, 2008.

[13] X. Zhao, M. E. Lee, and S. H. Kim, "Improved image segmentation method based on optimized threshold using genetic algorithm," *Proc. of International Conference on Computer Systems and Applications*, pp. 921-922, Dec. 2008.

[14] L. Liu, Y. Liu, and Y. Lin, "An adaptive algorithm based on image segmentation," *Proc. of Second International Symposium on Electronic Commerce and Security*, pp. 78-80, May. 2009.

[15] H. Yourui and W. Shuang, "Multilevel thresholding methods for image segmentation with Otsu based on QPSO," *Proc. of Congress on Image and Signal Processing*, pp. 701-705, May. 2008.

[16] D. Y. Huang and C. H. Wang, "Optimal multi-level thresholding using two-stage Otsu optimization approach," *Pattern Recognit. Lett.*, vol. 30, no. 3, pp. 275-284, Feb. 2009.

[17] M. Srinivas and L. M. Patnaik, "Adaptive probabilities of crossover and mutation in genetic algorithm," *Proc. IEEE Trans. Sys., Man and Cybernetics*, vol. 24, no. 4, pp. 656-667, Apr. 1994.



**이 병 통**

1983년 부산대학교 기계공학과 졸업(학사). 1988년 동 대학원 기계공학과 졸업(석사). 1994년 North Carolina 주립대 대학원 기계공학과 졸업(공학박사). 1995년~현재 울산대학교 기계공학부 교수. 관심분야는 로봇 및 머신비전.



**Quoc Bao Truong**

1998년 Cantho 대학교(베트남) 컴퓨터학과 졸업(학사). 2003년 Hochiminh 국립대 대학원 컴퓨터학과 졸업(석사). 2007년~현재 울산대학교 기계공학부 박사과정. 관심분야는 머신비전 응용.



**Van Huy Pham**

2003년 Cantho 대학교(베트남) 수리정보학과 졸업(학사). 2007년 Hochiminh 국립대 대학원 컴퓨터학과 졸업(석사). 2009년~현재 울산대학교 기계공학부 박사과정. 관심분야는 인공지능 및 머신비전 응용.



**김형석**

2009년 울산대학교 대학원 기계자동차공학과 박사. 2009년~2010년 지능형자동차부품기술개발팀 전임연구원. 2010년~현재 울산대학교 기계기술연구소 위촉연구원. 관심분야는 물고기 로봇, 머신비전.