

유전자 알고리즘을 이용한 에지추출

正會員 金秀謙*, 趙範俊**

Edge Detection using Genetic Algorithm

Su Gyeam Kim*, Bum Joon Cho** Regular Members

要 約

에지검출은 영상인식의 첫단계이며 동시에 영상인식의 성능을 좌우하는 아주 중요한 단계이다. 기존의 기율기연산자나 표면집합에 의한 에지추출과 달리 본논문에서는 에지평가함수 최대화 문제로 다루었다. 이것은 에지형상의 질을 평가하는 비용함수를 어떻게 구성하느냐에 크게 좌우된다. 총 비용함수는 각 에지픽셀에 대한 비용함수의 선형합이고 각 에지픽셀에 대한 비용함수는 3×3 윈도우 안에 존재하는 에지픽셀의 연속성과 굵기 그리고 에지의 길이를 기본으로 하여 구성하였다. 총 비용함수가 최대가 되는 에지영상을 찾음으로서 해를 구하게 되는 것이다. 본 논문에서 제안한 에지평가함수는 사전지식이 필요하지 않으며 여러가지 종류의 에지형상을 평가하는데 사용할 수 있다. 총 비용을 최대화 시키는데 유전자 알고리즘을 사용하였고 유전자 알고리즘을 적용한 후 향상된 비용함수와 시각적으로 더 좋은 에지영상을 구할 수 있었다.

ABSTRACT

Edge detection is the first step and very important step in image analysis. We cast edge detection as a problem in cost maximization. This is achieved by the formulation of a cost function that evaluates the quality of edge configurations. This function is a linear sum of cost factors. The cost factors capture desirable characteristics of edges such as accuracy in continuity, thinness and length. Edges are detected by finding the edge configurations that maximize the cost function. The cost function that proposed in this paper is developed based solely on the criterion of good edge formation without using any prior knowledge of ideal edge formation. It can be used as a basis for comparing the performances of different detectors. We used Genetic Algorithm for maximizing cost function.

*목포해양대학교 기관공학과
Department of Marine Engineering, Mokpo
National Maritime University

**조선대학교 컴퓨터공학과
Department of Computer Engineering,
CHOSUN University
論文番號 : 95171-0510
接受日字 : 1995年 5月 10日

I. 서론

컴퓨터 비전(Computer vision)의 궁극적인 목표은 컴퓨터 또는 로봇에 인간과 같이 시각적으로 물체를 인식할 수 있는 능력을 부여하는 것이다^(1,3). 이러한 물체인식 능력은 영상해석의 하위단계에서 얼마만큼 정확하고도 유용한 정보를 찾아주느냐에 따라 크게 영향을 받는다^(2,4). 에지는 주어진 영상내의 물체를 인식하는 데 있어 영상해석의 하위단계에서 얻을 수 있는 중요한 정보로 취급된다.

에지란 두 영역사이의 경계에 위치한 점들을 말하며, 에지 검출은 영상속에 위치한 이런 경계점들을 찾는 작업을 말한다. 주어진 영상의 각 화소의 밝기의 동일성을 근거로 개발된 영역분할(region splitting)이나 영역통합(region growing) 방법과는 달리 에지검출은 각 픽셀에서의 밝기의 불연속성을 이용하여 에지를 찾는다^(2,8).

영상인식에서 에지검출이 중요한 이유는 인간의 시각 시스템이 물체를 인식하는 데 있어서 대강의 윤곽선만으로 인식이 가능하듯이 영상에서의 대부분의 유용한 정보는 서로 다른 영역간의 경계선에 위치하기 때문이다⁽⁵⁾. 또한 영상을 에지로 표현하면 영상속의 물체의 형태에 관한 정보를 그대로 유지하면서 영상인식의 상위 단계에서 처리해야 할 자료의 양을 많이 줄일 수 있고⁽⁶⁾ 많은 물체인식 알고리즘과 쉽게 결합 가능하다는 장점이 있다.

지금까지 에지검출방법에 대하여 많은 연구가 되어 왔음에도 불구하고 물체의 실제 경계선에 해당되는 에지를 정확히 검출하는 것은 여전히 어려운 문제로 남아있다. 영상내에 존재하는 에지는 다양한 형태로 표현될 수 있기 때문에 에지의 정의를 정확하게 규명하기가 어렵다. 따라서 대부분의 에지검출은 특정 응용분야의 특성에 맞게 에지를 정의하고 이를 이용하여 에지를 검출하는 실정이다. 또한 한 픽셀에 대한 에지픽셀이 여부가 영상내의 픽셀간의 위치 관계나 이웃하는 에지들의 형태와는 무관하게 명암의 변화만으로 결정되어지기 때문에 노이즈(Noise)등의 영향을 받기가 쉽다.

일반적으로 에지픽셀의 존재를 결정하는 과정에서 이웃하는 에지픽셀에 대한 국부적정보를 이용하면 매우 효율적이다. 예를 들면, 영상에 포함된 노이즈는 조각에지를 생성한다. 즉 에지의 국부적 연속성에 대한 정보를

이용하여 조각난 에지를 연결시켜 조각난 에지의 양을 줄일 수 있다는 것이다.

본 논문에서는 에지추출 문제를 비용의 최대화의 문제로 다룬다. 비록 다른 추출 알고리즘에서도 비용 최대화 알고리즘을 이용하지만 본 논문의 방법은 비용함수를 정의하는 방법에 있어서 독특하다. 즉, 비용함수는 국부적 에지구조의 연속성과 굵기 그리고 길이에 대한 정보를 이용한다. 본 논문에서 제안한 에지추출 비용 최대화 알고리즘의 가장 큰 장점은 비용함수를 계산하는데 있어서 에지의 사전정보를 요구하지 않는다는 것이다. 그렇게 하므로서 여러가지 종류의 에지를 추출하는데 유연성을 부여할 수 있다.

에지추출 알고리즘의 첫 단계인 영역의 영역특성불일치를 강조하는 단계에서 좋은 에지 후보 픽셀은 강조된다. 이 단계에서 적용대상에 따라 적합한 불일치 측정함수를 사용한다. 그리고 강조된 영상에 임계값을 적용하여 유전자알고리즘의 Individuals인 후보에지영상을 생성한다. 후보에지영상의 각각의 에지픽셀에 대하여 비용함수 E_Q 를 계산한다. 총 비용함수는 각 에지픽셀에 대하여 적용한 비용함수의 선형합이다. 유전자 알고리즘으로 그와같은 총 비용함수가 최대가 되는 에지영상을 생성시키므로써 해를 얻게되는 것이다.

본 논문은 2장에서 후보에지영상의 생성과 비용함수 구성에 적합한 에지정의를 제시하고 3장과 4장에서는 2장에서 정의한 에지정의를 기본으로 구성한 후보에지영상 생성알고리즘과 에지평가함수를 제안한다. 마지막으로 5장과 6장에서 유전자 알고리즘과 실험결과를 제시하겠다.

II. 에지의 정의

에지의 정확한 정의는 에지추출알고리즘에 많은 영향을 미친다. 그러나 물리적으로는 존재하지 않지만 시각적으로 에지로 인식되는 많은 시각적 오류가⁽⁹⁾ 있기 때문에 영상에서 에지를 구성하고 있는 것이 무엇인지를 정확히 정의하는 것은 매우 어려운 일이다. 일반적으로 모든 사람이 에지에 대한 직관적인 정의를 가지고 있지만 이와같은 에지의 정의는 사람에 따라 다소 다를 수 있다. 예를 들면, 어느 두 사람에게 동일한 영상을 주고 그 영상에서 에지를 추출하라고 하였다면 비슷하지만 똑같은 에지는 아닐것이다. 결론적으로 완전히 동일한 에

지는 존재하지 않으며 에지추출알고리즘은 에지의 정의에 크게 영향을 받는다는 것이다.

영상의 에지는 일반적으로 농도에지와 텍스춰에지 두 가지의 큰 부류로 나눌 수 있다. 농도에지는 영상농도의 갑작스런 변화로부터 생기는 경계라고 할수 있으며 이와같은 에지는 일반적으로 그림 1과 같은 계단에지, 경사에지, 지붕에지등이 있다.

텍스춰에지는 빛의 조건에 따라 변하는 텍스춰 영역에 존재하는 경계다. 일반적으로 텍스춰에지는 에지 모델에 따라 정의된다⁽¹⁰⁾. 많은 에지추출 알고리즘은 그 알고리즘을 적용하는 분야에 한정하여 에지를 정의하기 때문에 그 정의를 벗어나는 에지를 추출하는데에는 효과적이지 못한 약점을 안고 있다.

본 논문에서는 이와같은 단점을 보완하고 여러 종류의 에지를 포함할 수 있도록 에지를 정의한다.

정의 1: 에지는 영상에서 특성이 일치하지 않는 두영역을 분리하는 경계다.

여기에서 두 영역은 에지의 양쪽에 위치하여야 한다. 그리고 두 영역에 존재하는 영역특성불일치의 원인은 물체의 기하학, 표면반사, 조도등 여러 요소의 조합이다. 영역특성불일치라는 용어는 영역의 농도값의 차 또는 농도의 표준편차 등을 포함하여 다른 여러가지 의미를 담고 있다. 물론 영역특성불일치는 농도나 텍스춰에지 모두에 사용된다. 예를들면 농도에지는 농도값이 다른 영역을 분리하는 경계이고 텍스춰에지는 다른 텍스춰 특성을 가진 영역을 분리하는 경계이다.

정의 2 : 에지가 특성이 일치하지 않는 두영역을 분리한다는 기본적인 성질외에 에지의 구조적 특성에 따라 다르게 에지를 정의할 수 있다. 이와같은 에지의 구조적 특성은 영상의 에지위치와 모양을 결정하는 중요한 요인이 된다. 에지는 다음과 같은 4가지의 구조적특성을 지

녀야한다.

(1) 정확한 위치

에지는 공간적으로 정확한 위치에 놓여야하고 가장 적합한 방법으로 영역특성불일치의 영역을 분리하여야 한다. 실제적으로 영상에서 에지의 위치는 부정확한 경우가 많다. 모든 에지는 오직 하나의 공간적인 위치를 가지고 있기 때문에 분리되는 영역사이의 영역특성불일치의 정도는 에지의 위치에 따라 변한다. 따라서 영역특성불일치의 정도가 최대가 되는 위치에 에지가 놓일때 에지의 위치가 정확하다고 할 수 있다.

(2)두께

에지는 영상의 영역특성불일치 영역을 분리하는 경계이기 때문에 가는선이 바람직하다. 가장 이상적인 에지는 오직 한 픽셀의 두께를 가진 에지이어야 한다.

(3)연속성

물리적 환경에서 경계는 연속성을 나타내는 특성을 지니고 있기 때문에 역시 에지도 연속성을 지니고 있어야 한다. 자연현상에서 대부분의 물리적 경계는 연속적이다. 따라서 정확한 에지는 이와같은 특성을 가져야 한다는 것이다.

(4)길이

노이즈는 하나 또는 두개의 픽셀로 이루어진 짧은 에지로 나타날 수 있다. 그래서 본 논문에서 의미하는 에지는 3×3배열 윈도우에서 3픽셀의 길이로 이루어진 에지를 가장 이상적인 에지로 정의한다.

실질적으로, 위와같은 에지의 구조적특성은 서로 서로 결합하기 때문에 동시에 2개 혹은 그 이상의 구조적특성




그림 1. 일반적인 농도에지. (a)계단에지, (b)경사에지, (c)지붕에지.

Fig. 1. Examples of intensity edges. (a)Step edge, (b)Ramp edge, (c)Roof edge.

을 취할 수 없는 경우가 있다. 예를 들면 영상의 모든 에지가 길어야하고 연속적이어야 하는것은 에지 위치에 서의 부 정확함과 거트 경계를 나타낼 수도 있다는 것이다. 그러므로 추출하고자하는 에지특성을 구조적특성과 적절이 연관시키므로서 여러가지 구조적특성의 요소를 포함하는 에지를 추출할 수 있다.

Ⅲ. 후보 에지영상(Individual) 생성

본 논문의 에지추출 알고리즘의 목적은 2장에서 언급한 에지의 정의를 만족시키는 픽셀을 찾는 것이다. 그와 같은 에지를 발견하기 위하여 전체 또는 국부적 에지픽셀구조에 대한 정보를 이용한다. 3장에서는 후보 에지영상을 생성하는 알고리즘과 에지평가함수의 구성에 기본이되는 적합한 에지픽셀구조와 그리고 후보 에지영상 생성알고리즘에 대하여 설명하겠다

1. 적합한 에지픽셀 구조

후보 에지영상 생성알고리즘과 에지평가함수의 구성에 필요한 적합한 에지픽셀구조에 대하여 알아보자. 3×3 배열에서, 중앙 에지픽셀은 최대 8개의 이웃에지픽셀을 갖게된다. 이와같은 3×3 배열의 에지픽셀구조에서 적합한 에지픽셀구조를 다음과 같이 정의한다.

정의 3 : 1개 또는 0개의 이웃 에지픽셀을 가진 에지픽셀구조는 적합한 에지픽셀구조다.

정의 4 : 2개의 이웃에지픽셀을 가진 에지픽셀구조인 경우 이웃픽셀의 회전각이 45도 이상이 아니고 연속이면 적합한 에지픽셀구조로 정의한다. 이와같은 에지픽셀구조를 적합한 2-Neighbors 에지픽셀구조라고 한다. 그림 2는 4개의 기본적인 2-Neighbors 에지픽셀구조를 보여준다. 그리고 그림 3은 오른쪽으로 회전각 90도를 구성하기 때문에 부 적합한 에지픽셀구조가 된다. 그




그림 2. 적합한 기본 2-Neighbors 에지픽셀구조
Fig. 2. The 4 basic valid edge structures with 2-neighbors.




그림 3. 부 적합한 2-Neighbors 에지 픽셀구조
Fig. 3. An invalid 2-Neighbors edge structure

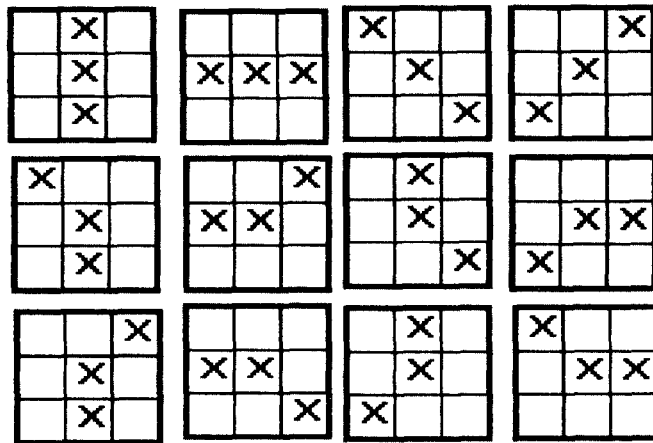


그림 4. 12개의 적합한 2-Neighbors 에지픽셀구조
Fig. 4. The 12 valid thin edge structures with 2-neighbors.

림 2와 같은 기본적인 2-Neighbors 에지픽셀구조의 에지픽셀위치를 변경하면 그림 4와같은 총 12개의 적합한 2-Neighbors 에지픽셀구조를 구성할 수 있다.

정의 5: 3개 이웃픽셀을 가진 에지픽셀구조는 에지픽셀구조가 그림 5와 같은 구조면 적합한 에지픽셀구조가 된다. 3개이웃픽셀을 가진 에지 픽셀구조는 총 56개의 다른 에지 픽셀구조를 구성할 수 있지만 그림 5와 같은 8개 만을 적합한 에지 픽셀구조로 한다.

정의 6 : 4개이상의 이웃에지픽셀을 가진 에지픽셀구조는 적합한 에지픽셀구조가 아니다.

2. 후보 에지영상 생성 알고리즘

그림 6은 본논문에서 제안한 에지추출 알고리즘의 블록다이어그램이다. 이 알고리즘의 첫번째 단계는 영역의 영역특성불일치영역을 강조하는 것이다. 후보 에지영상을 생성하기 위하여, 전장의 적합한 에지픽셀구조를 기본으로하여 구성된 그림 7과 같은 영역특성불일치영역 강조윈도우를 제안한다. 이 윈도우는 영상의 특성이 다

른 영역을 강조하고 그리고 강조된 영상 픽셀에 임계값을 적용하여 후보 에지영상(Individuals)의 픽셀을 생성하게 되는 것이다.

본 논문의 에지추출 알고리즘은 오리지날 영상에 직접 에지평가함수를 적용하는 것이 아니고 영역특성불일치영역을 강조하는 알고리즘에 의해 생성된 후보 에지영상(Individual)에 에지평가함수를 적용한다. 이때 에지평가함수가 최대가되는 에지영상을 찾음으로서 해를 구하게 되는 것이다. 이와같은 에지평가함수가 최대가 되는 에지영상을 찾는데 유전자 알고리즘을 이용한다.

그림 7은 다른 에지추출 연산자와는 달리 에지형상을 기준으로 하여 구성된 영역특성불일치 강조 윈도우로서 영역의 영역특성불일치를 어떻게 정의하느냐에 따라 윈도우에 유연성을 부여할 수 있는 장점을 가지고 있다. 이와같은 영역특성불일치 강조윈도우는 그림 4와 그림 5의 적합한 에지픽셀구조를 기본으로 구성하였으며, 이 윈도우를 적용하여 얻은 픽셀의 집합을 D라 하면 $D=\{d(i,j); 1 \leq i,j \leq N\}$ 로서 픽셀농도 값이 영역특




그림 5. 8개의 유효한 기본 3-Neighbors 에지픽셀구조
Fig. 5. The 8 valid basic edge structures with 3-neighbors




그림 6. 에지추출 알고리즘 블록다이어그램.
Fig. 6. The block diagram for edge detection.

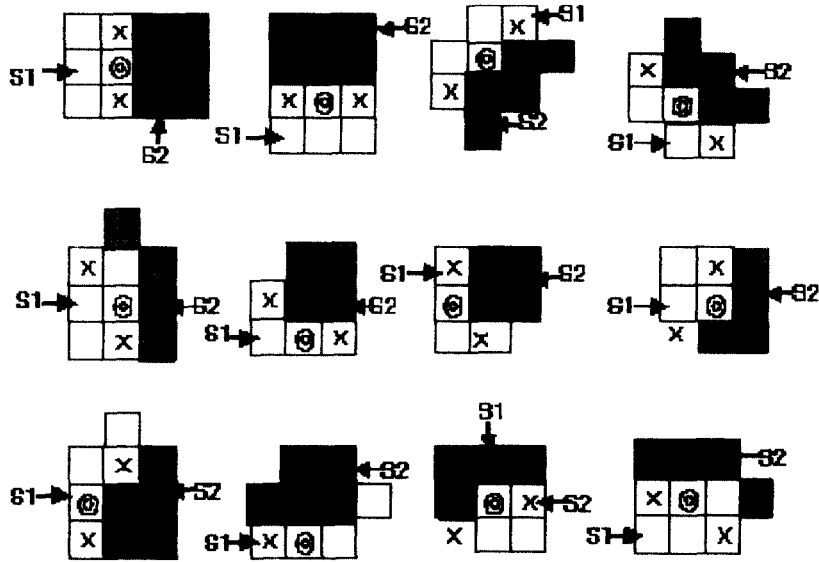


그림 7. 12개 영역특성불일치 강조 윈도우
 Fig. 7. The 12 basic windows to enhancement dissimilarity regions.

성불일치에 비례하는 집합이 된다. 픽셀의 농도값 $d(i, j)$ 는 $0 \leq d(i, j) \leq 255$ 이고 임계값보다 큰 농도 값을 가진 픽셀은 좋은 에지 픽셀 후보로서 값 1을 지정하고 그렇지 않으면 0을 지정한다. 이와같은 1 또는 0으로 된 후보 에지영상 생성과정에는 다음과 같은 두가지 사항을 고려하여야 한다.

- (1) 에지에 대하여 잘 정의된 양 영역
- (2) 양 영역의 불일치의 정도를 측정할 수 있는 영역 특성불일치 측정함수.

에지의 양 영역은 그림 4, 5와 같은 적합한 에지픽셀 구조에 따라 다르다. 이와같은 적합한 에지픽셀구조를 기본으로 한 영역특성강조윈도우는 3×3 윈도우에 포함되는 에지로서 굵기는 1픽셀이고 길이는 3픽셀인 에지픽셀구조를 기본으로한다. 그림 7과 같은 영역특성불일치 강조윈도우의 S1과 S2는 각각의 영역특성불일치 강조윈도우에 대한 양 영역을 나타내며 $f(S1, S2)$ 는 양 영역 S1과 S2 사이의 영역특성불일치도를 측정하는 함수다.

함수 $f(S1, S2)$ 의 측정값은 양 영역의 평균농도나 농

도의 구조적 특성 또는 통계적 특성을 기본으로한 복잡함 측정값일 수도 있다. 즉, 적용대상에 따라 함수값에 유연성을 부여할 수 있다는 것이다. 본 논문에서는 평균 농도 값으로 함수 $f(S1, S2)$ 값을 측정하였다. 오리지널 영상로부터 후보 에지영상 D를 얻는 과정은 다음과 같다.

A. 12개의 영역특성불일치 강조윈도우 각각을 오리지널 영상의 각 픽셀 (i, j) 에 적용한다. 각 영역특성불일치 강조윈도우에 대한 영역 S1, S2에 대하여 영역 특성불일치 측정함수 $f(S1, S2)$ 을 계산한다. 가장 큰 함수값을 나타내는 영역특성강조윈도우 하나를 최적에지픽셀구조로 선택한다. 이때 최적에지픽셀구조는 3개의 에지픽셀을 갖게되며 에지픽셀의 위치를 $(i, j), (i1, j1), (i2, j2)$ 로 한다.

B. 최적에지픽셀구조를 이동하여 함수값 $f(S1, S2)$ 을 다시 계산한다. 즉, 수직, 수평, 대각선 에지픽셀구조에 대해서는 에지픽셀구조에 대해 직각방향으로 1픽셀 이동하여 최적에지픽셀구조의 영역특성불일치 함수값 $f(S1, S2)$ 을 다시 계산한다. 그리고 나머지 에지픽셀구조에 대해서는 위, 아래, 왼쪽, 오른쪽으로 이동하여 최적에

지픽셀구조의 영역특성불일치 함수값 $f(S1, S2)$ 을 계산하고 다음 단계를 수행한다.

a. 이동하여 계산한 최적에지픽셀구조의 함수값이 기본 픽셀위치 (i, j) 에서의 함수값보다 더 큰값이 없으면 픽셀위치 (i, j) 에서의 최적에지픽셀구조의 함수값을 다음식과 같이 계산한다.

$$\Delta = \text{Alpha} \times f(S1, S2).$$

최적에지픽셀구조의 에지픽셀위치의 픽셀값 $d(i, j)$, $d(i1, j1)$, $d(i2, j2)$ 을 값 Δ 로 치환한다.

위식에서 가중치인 Alpha를 사용함으로써 적용 대상에 따라 유연성을 부여할 수 있다.

b. 만약 이동하여 계산한 함수값이 에지픽셀 위치 (i, j) 에서의 함수값 보다 큰 값이 있으면 최적에지픽셀구조의 에지픽셀위치의 픽셀값을 변경시키지 않는다.

c. 마지막으로 임계값을 적용하여 임계값보다 큰 픽셀값은 에지픽셀값을 1로 작으면 0으로 치환하여 후보에지영상(Individual)를 생성한다.

IV. 에지평가 비용함수.

에지를 평가하는 비용함수는 2장에서 정의한 에지정의와 에지의 구조적 특성에 근거한 에지의 연속성과 두께 그리고 에지의 길이를 기준으로하여 구성하였다. 에지평가함수 측정방법은 강조된 영상 D에 여러 임계값을 적용하여 추출한 각각의 후보 에지영상(Individual)에 3×3 윈도우를 적용하여 측정한다. 에지평가함수의 연속성에 대한 비용은 2개의 이웃 에지픽셀이 중앙픽셀과 기울기방향이 같고 연속성을 유지하면 큰값을 부여한다. 두께에 대한 비용은 3×3 윈도우의 2-neighbors 에지픽셀구조이면서 가내에지픽셀구조이면 큰값을 부여하고 두꺼운 에지픽셀구조이면 작은값을 부여한다. 그리고 에지길이에 대한 비용함수는 3개의 픽셀로 이루어진 에지픽셀 구조면 큰값을 부여하고 2개의 에지픽셀로 된 끝점이거나 또는 1개의 에지픽셀로 된 동떨어진 에지픽셀이면 작은값을 부여한다. 연속성에 대한 비용함수의 계산은 다음과 같다.

$$\Lambda(a, b) = \frac{\pi - |a - b|}{\pi}$$

$|a - b|$ 는 2개의 에지 기울기방향 a와 b의 절대차

3	2	1
4		0
5	6	7

그림 8. 이웃에지에 대한 번호 K.
Fig. 8. The numbering for neighbor edges.

를 나타낸다. $|a - b|$ 의 범위는 0에서 π 까지다. 에지 연속성을 평가하는 비용함수는 2개의 에지 기울기방향에 대한 방향일치의 정도를 나타내는 함수로 a와 b가 동일한 기울기방향일 때에는 값 1을 갖고 그리고 반대 방향을 나타내는 반 회전의 기울기방향에 대해서는 값 0을 지정한다. 기준이되는 중앙에지픽셀에 대한 이웃 에지픽셀의 관계를 나타내는 번호는 그림 8과 같다.

d는 중앙 에지픽셀의 기울기방향이고 $d_0, d_1, d_2, \dots, d_7$ 은 8개의 이웃픽셀에 대한 에지 기울기방향을 나타낼때 중앙에지픽셀에 대한 왼쪽 에지픽셀에 대한 기울기방향을 조화 정도를 나타내는 식 $L(k)$ 는 다음과 같다.

$$L(k) = \Lambda(d, d_k) \times \Lambda\left(\frac{\pi \times k}{4}, d + \frac{\pi}{2}\right)$$

이웃픽셀 k가 에지픽셀이면
0, 이웃픽셀 k가 에지픽셀이 아니면

비용함수 $L(k)$ 는 왼쪽방향에 대한 중앙 에지픽셀 d와 이웃 에지픽셀 d_k 와의 조화정도를 나타낸다. 이웃픽셀이 에지픽셀이 아니면 에지 연속성이 존재하지 않기 때문에 값 0을 지정한다. 이웃픽셀이 에지픽셀이면 그 평가는 두개의 요소로 구성된다. 첫번째 요소 $\Lambda(d, d_k)$ 는 기울기방향에 대한 중앙에지픽셀과 이웃에지픽셀의 조화의 정도를 나타낸다. 그리고 두번째 요소 $\Lambda(\pi k / 4, d + (\pi/2))$ 는 중앙 에지픽셀과 k번째 이웃에지픽셀의 왼쪽방향에 대한 조화의 정도를 나타내는 요소이다. $(\pi k / 4)$ 는 k번째 이웃 에지픽셀의 기울기 방향이고 $d + (\pi/2)$ 는 중앙에지픽셀 d를 오른쪽에서 본 정 왼쪽 기울기방향을 나타낸다. 같은 방법으로 $R(k)$ 를 계산한다.

$$R(k) = \Lambda(d, d_k) \times \Lambda\left(\frac{\pi \times k}{4}, d - \frac{\pi}{2}\right)$$

이웃픽셀k가 예지픽셀면

0 이우픽셀 k가 예지픽셀이 아니면

R(k) 역시 오른쪽 방향에 대한 중앙 예지픽셀 d와 k 번째 이웃예지픽셀 d_k 와의 조화의 정도를 나타낸다. 중앙예지픽셀의 기울기 방향에서 왼쪽으로 놓여 있는 3개의 이웃픽셀중 가장 높은 값을 가지는 한 L(k)을 왼쪽 예지연속성 비용함수로 취하고 그리고 오른쪽 3개의 픽셀중 가장 높은 값을 가지는 한 R(k)값을 오른쪽 예지연속성 비용함수로 취한다. 모든 이웃예지에 대한 예지연속성 비용함수 C는 이와 같은 2개의 예지연속성 비용함수의 평균으로 계산한다. 예지두께에 대한 비용함수 T는 8개 이웃픽셀중 예지픽셀이 아닌 픽셀수를 나타내는 값으로 2개의 이웃픽셀로 된 가는 예지픽셀에 대하여는 1을 배정하고 3개 이상의 이웃픽셀로 된 예지픽셀에 대하여는 0에 가까운 값을 배정한다. 예지 길이에 대한 비용함수 L는 예지픽셀의 갯수에 따라 주어지는 값으로 이웃픽셀이 2개인 경우에는 역시 1을 1개 또는 이웃픽셀이 없는 경우에는 0에 가까운 값을 배정하도록 하였다. 이와같은 예지평가함수의 3개 요소는 어느것도 독립적으로 작용하지않고 조화를 잘 이루어야한다. 각각의 요소가 조화를 잘 이루도록 다음과 같은 식으로 예지평가함수를 구성한다.

$$E_Q = LMC + (1 - M)T.$$

국부적 비용함수 E_Q는 M의 선택에 따라 많은 영향을 받는다. M를 잘 조정하면 비용함수를 적용하는 각각의 예지영상에 대한 적절한 예지평가함수를 얻을 수 있다.

V. 유전자알고리즘을 이용한 예지평가함수의 최대화.

전산학 및 여러학문 또는 공장의 생산계획등에 있어 주어진 문제나 상황에서 최적화된 해를 구하는 것은 매우 중요하다. 많은 사람들이 여러가지 상황에서 여러가지 방법으로 최적화된 해를 구하려고 노력하였다. 그러나 기존의 정형화되고 기계화된 알고리즘으로는 시간적인 문제등으로 인해 해결하기 힘든 문제가 많이 있어 두 가지 새로운 방법이 제시되고 있다. 유전자 알고리즘과

Simulated annealing⁽¹¹⁾알고리즘이 그것이다. 이 두 방법은 모두 자연환경에 근거한 개념을 가지고 있는 확률적 탐색방법이다.

유전자 알고리즘은 John Holland^(12, 13)에 의해 창시된 것으로 “적자 생존(survival of the fittest)”의 법칙과 같은 자연 생태계에서 일어나는 현상에 근거한 알고리즘이다. 이 유전자 알고리즘에 의한 탐색은 Point 중심 탐색이 아닌 세대 중심 즉, Population 중심 탐색을 한다. 이 알고리즘의 가장 큰 장점은 어떤 주어진 상황에 적응적(adaptive)으로 대처해 탐색을 한다는 것이다. 또한 이 알고리즘은 어떤 특정 문제에만 적용된다고 보다는 여러가지 문제에 대해 일반적으로 적용될 수 있다는 것이다. 어떠한 문제를 해결하기 위한 유전자 알고리즘은 다음과 같은 다섯 가지⁽¹⁴⁾가 필요하다.

- (1)문제의 해를 표현할 Individual의 표현.
- (2)초기 Population의 생성.
- (3)각 Population의 Fitness를 결정할 평가함수.
- (4)Reproduction과정에서 적용할 여러가지 유전자. 연산자. (Selection, Crossover, Mutation등)
- (5)유전자 알고리즘이 사용하는 Parameter 값. (Parameter : Population size, Crossover Probability, Mutation Probability등)

일반적인 유전자 알고리즘⁽¹⁵⁾은 그림 9와 같다.

Procedure GA:

```

begin
    initialize population P(0);
    evaluation P(0);
    t=1;
    repeat
        select P(t) from P(t-1);
        crossover P(t);
        mulate P(t);
        evaluate P(t);
    until (termination condition);
end.
```

그림 9. 유전자 알고리즘
Fig. 9. Genetic Algorithm.

1. Individuals(후보 애지영상)의 표현

Population의 각 Individual은 하나의 애지영상이다. Individual의 각 Cell은 애지영상의 각 픽셀로서 애지픽셀이면 1이고 Non-애지픽셀이면 0으로 나타내었다. 각 Individual을 이와같이 표현하는 것은 효과적인 bit-wise 연산을 수행하기 위해서이다.

2. 초기 Population의 생성

2장에서 제시한 후보 애지영상 생성알고리즘과 각종 기율기 연산자를 사용하여 생성한 48개의 후보 애지영상으로 초기 Population를 구성하였다.

3. Fitness를 결정할 평가함수

유전자알고리즘에 필요한 Fitness는 2장에서 제시한 애지의 연속성과 굵기 그리고 애지길이를 기본으로 구성된 애지평가함수 E_Q 를 사용하였다.

$$\text{Fitness} = E_Q$$

4. Reproduction.

이 절에서는 Selection, Crossover, Mutation등의 유전자 연산자들이 적용되는 방법에 대해 설명하였다. 이러한 유전자 연산자들을 수행시킴으로서 새로운 세대를 생성하게 된다.

①. Selection.

유전자 알고리즘에서 Selection 방법에는 Deterministic sampling, Remainer stochastic sampling without replacement, Stochastic sampling without replacement, Stochastic tournament등 여러가지 방법이 있다¹⁷⁾. 본 논문에서는 그림 10과 같은 Deterministic sampling방법¹⁷⁾을 이용하여 Selection을 구현하였다. 이 방법은 Roulette wheel 방법이라고도 하는데 전체 Fitness에 대한 각 Individual의 Fitness의 상대적인 크기가 확률로 결정되고 그 확률만큼 선택되게 하는 방법이다.

본 논문에서는 이 방법을 약간 변형시켜 그 전 세대에서 가장 Fitness가 높은 1개 또는 2개의 Individuals을 반드시 다음 세대에 포함되도록 하였다. 이렇게 하면 그 세대에서 최적자는 반드시 생존하게 되고, 그 외에는 Fitness가 높을 수록 생존할 가능성이 크게 된다.




그림 10. Fitness에 따라 할당된 확률.

Fig. 10. The roulette wheel with slots sized according to Fitness.

②. Crossover.

근본적으로 Crossover는 거의 모든 생물체가 부모의 두 염색체로부터 새로운 하나의 염색체를 생성시킴으로 인해 발생한다는 개념에 근간을 두고 있다. Crossover도 Selection에서처럼 여러가지 방법으로 구현이 될 수 있다. 일반적인 방법인 One point crossover¹⁸⁾가 있다. 그리고 이것의 변형인 Multipoint crossover^{15, 16)}는 Bitstring으로 Individual이 표현되는 문제에서 많이 다루어진다. 또한 Individual이 어떻게 표현되는가에 따라 다른 방법의 Crossover도 가능하다.

본 논문에서는 그림 11과 같이 100×100 배열로 표현되는 각 Individual의 Points (x_1, y_1) , (x_2, y_2) , (x_3, y_3) , (x_4, y_4) 를 Random하게 선택하여 사각형 형태가 Crossover되도록 하였다.

③. Mutation.

자연생태계에서 Mutation은 돌연변이를 발생시키는 것이다. 돌연변이에 의해서 적자가 발생할 수도 있다는 점을 유전자 알고리즘에서 응용한 것이 Mutation 연산이다. 이 Mutation 연산은 낮은 Fitness에 의해 평균화 되어 있는 세대에서 보다 높은 Fitness를 가진 Individual을 생성시킬 수 있다는 데 중요한 의미가 있다. 수렴속도가 너무 빠르지는 좋지 않지만 어느 정도 속도로 수렴하는것은 Local Minima에 빨리 수렴하는 것을 방지하는 효과가 있다. 그래서 Mutation을 얼마

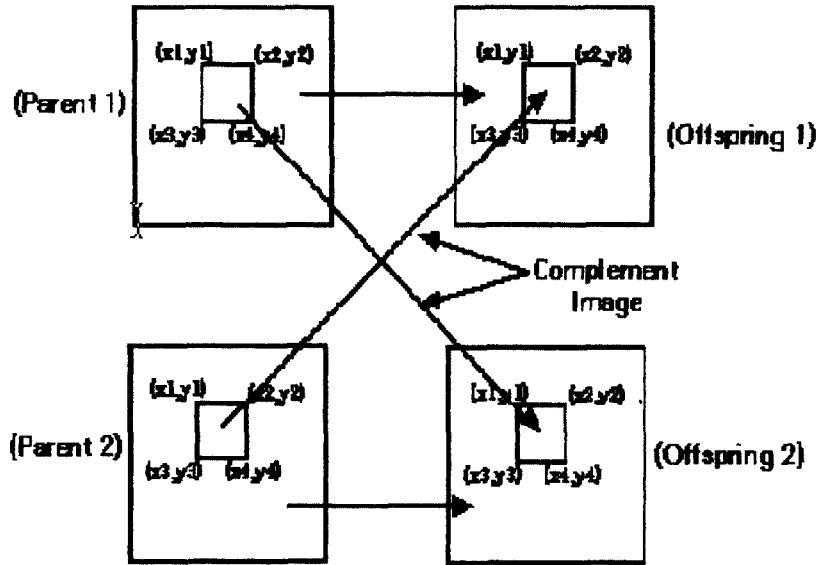


그림 11. 무작위로 생성된 4개 포인트로 구성된 교환연산자.
Fig. 11. Crossover operators with four random points

로 할 것인가를 결정하는 것은 수렴 속도에 영향을 준다. 본 알고리즘에서는 Mutation 확률을 0.2%로 일어나게 했다. 자연계에서도 돌연변이가 일어날 확률은 극히 적기 때문이다.

④. Reproduction 종결 조건

Reproduction 종결 조건도 문제의 특성에 맞게 여러가지 방법이 있을 수 있다. 세대의 수를 제한할 수도 있고 또는 평균 Fitness의 변화정도에 따라 종결조건을 정할 수도 있다. 본 논문에서는 제한된 세대까지 Reproduction을 하도록 하였다.

VI. 실험결과

주어진 조건하에서 몇개의 에지추출 연산자의 실험 결과를 제시한다. 실험 대상으로 원 형태의 영상과 대각선 형태의 영상인 2개의 영상을 사용하였고 그리고 시각적인 성능향상을 보이기 위하여 위험영상을 사용하겠다. 크기가 100×100픽셀 영상로서 배경은 100그레이 농도값, 물체는 130그레이 농도값 가진 영상으로 이와같은

영상들을 “원영상”과 “대각선영상”이라고 부르겠다. 노이즈에 대한 성능을 실험하기 위하여 원영상과 대각선영상에 표준편차 σ 가 5, 10, 25, 30이고 평균이 0인 Gaussian 노이즈를 첨가하였다. 그리고 위험영상은 150 × 150 크기의 영상으로서 역시 노이즈의 효과를 조사하기 위하여 오리지널 위험영상에 $\sigma=25$ 인 Gaussian 노이즈를 첨가하였다.


후보 에지영상 생성에 사용한 연산자는 Sobel, Prewett, Kirsh, Robert 기울기 연산자와 본문에서 제안한 영역특성불일치 강조 연산자를 사용하였다. 총 후보에지영상(Individual)은 48개로 구성하였고 Selection은 Deterministic sampling(roulette wheel)방법을 이용하여 구현하였다. 본문에서는 이 방법을 약간 변경시켜 전 세대에서 가장 높은 Fitness(비용함수)을 가진 2개의 individual을 다음세대에 꼭 포함 되도록 하였다. Mutation은 0.02%의 확률로 나타나게 하였다.

그림 12는 실험에 사용된 오리지널 영상으로 (a)는 오리지널 원영상, (b)는 오리지널 대각선영상이고 (c), (d)는 오리지널영상에 $\sigma=30$ 인 가우시안 노이즈를

첨가시킨 영상을 보여준다. 표 1는 $\sigma=30$ 인 경우 총 비용함수와 비용함수의 평균, 최대 비용함수를 갖는 Individual의 비용함수의 발달과정을 보여주고 그림 13과 14는 10세대, 20세대, 30세대, 40세대 그리고 마지막 세대 때의 최대 비용함수를 갖는 Individual의 에지영상을 보여준다. 표1과 그림 13과 14에서 알 수 있듯이 세대가 진행됨에 따라 비용함수의 증가와 함께 에지영상의 질이 향상됨을 알 수 있다.

표1에서 세대가 진행할 수록 총비용함수와 평균비용함수는 큰폭으로 향상되었다. 그러나 최대 비용함수를 갖는 Individual의 비용함수는 총 비용함수와 같이 개선되지 않았다. 10세대 진행하였을 때 원영상에거 최대 비용함수를 갖는 Individual의 비용함수의 비용함수는

10포인트 정도 개선되었고 대각선영상에서 최대비용함수를 갖는 Individual의 비용함수는 5포인트 정도 개선되어었다. 세대가 진행하면서 두 영상에서 Individual의 비용함수는 약간씩 개선되어 60세대에서 원영상은 17포인트 정도, 대각선 영상에서 16포인트 정도 개선되었다. 그러나 에지영상은 가는 선으로 그리고 노이즈로 끝어진 부분이 이어진 에지영상으로 개선되었으나 E_Q 값의 개선폭 만큼 개선되지는 않았다. 이것은 에지의 주위에 있는 노이즈가 작은 원 또는 작은 사각형을 형성하여 물체의 에지로 인식되었기 때문이다. 이와같은 현상은 후보 에지영상(Individuals)의 구성에 많은 영향을 받았다. 후보 에지영상을 잘 구성하면 더 좋은 에지영상을 얻을것으로 생각한다.



(a) (b) (c) (d)

그림 12. 유전자 알고리즘에 사용된 오리지날 영상. (a) 오리지날 원영상. (b)오리지날 대각선 영상. (c) $\sigma=30$ 인 원영상. (d) $\sigma=30$ 인 대각선영상.

Fig. 12. Original image for genetic algorithm. (a)Original Ring image. (b)Origina Diagonal image. (c)Ring image($\sigma=30$). (d)Diagonal image($\sigma=30$).

표 1. 에지영상의 비용함수 E_Q의 발달과정(M=0.8). (a)원영상($\sigma=30$). (b)대각선영상($\sigma=30$).
Table 1. E_Q of edge image(M=0.8). (a) Ring image($\sigma=30$). (b) Diagonal image($\sigma=30$).

(a)				(b)			
세대	총비용	평균비용	최대비용요소	세대	총비용	평균비용	최대비용요소
1	1581.91	32.9	53.23	1	1497.73	31.2	51.82
10	1981.45	41.28	63.01	10	2083.06	43.39	56.08
20	2312.81	48.18	65.11	20	2464.03	51.33	58.86
30	2541.01	52.94	65.12	30	2694.89	56.14	61.03
40	2712.67	56.51	65.12	40	2867.28	59.73	64.26
50	2843.75	59.24	67.57	50	3006.45	62.63	65.97
60	3019.94	62.91	70.53	60	3150.21	65.63	67.96




그림 13. $\sigma=30$ 인 경우의 세대별 원에지영상($\sigma=30$). (a)1세대. (b)20세대. (c)30세대. (d)40세대. (e)60세대.
 Fig. 13. Proceeding of Ring Edge image($\sigma=30$). (a)1 generation, (b)20 generations, (c)30 generations, (d)40 generations, (e)60 generations.




그림 14. $\sigma=30$ 인 경우의 세대별 대각선 에지영상($\sigma=30$). (a)1세대. (b)20세대. (c)30세대. (d)40세대. (e)60세대.
 Fig. 14. Proceeding of Diagonal edge image($\sigma=30$). (a)1 generation, (b)20 generations, (c)30 generations, (d)40 generations, (e)60 generations.

표 2. σ 에 대한 최대 비용함수의 발달. (a)원 영상. (b)대각선 영상.
 Table 2. E_Q of best individual. (a)Ring image. (b)Diagonal Image.

(a)

세대	$\sigma=5$	$\sigma=10$	$\sigma=20$	$\sigma=25$	$\sigma=30$
1	139.39	134.65	123.54	64.21	53.23
5	139.39	134.99	126.11	64.21	62.91
10	140.12	135.89	129.62	64.21	63.01
20		138.37	131.57	65.21	65.11
30			133.97	71.79	65.12
40			135.64	74.01	65.12
50					67.57
60					70.53

(b)


세대	$\sigma=5$	$\sigma=10$	$\sigma=20$	$\sigma=25$	$\sigma=30$
1	117.25	117.91	114.49	58.92	51.82
5	118.24	117.91	116.68	59.08	54.51
10	118.34	118.17	117.32	61.83	56.08
20		119.02	118.51	62.48	58.86
30			122.21	64.48	61.03
40			124.21	66.71	64.26
50					65.97
60					67.96




(a)




(b)




(c)




(d)



(e)



(f)



(g)

그림 15. 위험 에지영상. (a)오리지날 영상. (b) $\sigma=25$ 인 노이즈를 첨가한 영상. (c)Sobel 연산자(142). (c)Prewett(124). (d)Kirsh 연산자(320). (e)Log 연산자(220). (f)유전자 알고리즘(60세대 후).

Fig. 15. Danger Edge Image. (a)Original Image. (b)Noise Image($\sigma=25$). (b)Sobel(142). (c)Prewett(124). (e)Kirsh(320). (f)Log(220). (g)Genetic Algorithm(343, 60Generations).

표 2는 σ 에 대한 최대비용함수의 진행과정을 보여준다. 표 2에서 σ 가 5, 10, 20인 경우에는 비용함수 E_Q 계산에서 M를 0.7로 하였고 σ 가 25와 30인 경우에는 M를 0.8로 하였다. 표 2에서 알 수 있듯이 $\sigma=5$ 와 $\sigma=10$ 인 노이즈 첨가가 적은 경우에는 E_Q의 증가가 매우 느리고 세대 진행따라 E_Q가 거의 증가 되지 않아 20세대에서 중지시켰다. 그리고 $\sigma=20$ 와 $\sigma=25$ 인 경우는 $\sigma=5$ 와 $\sigma=10$ 인 경우보다 20세대를 더 진행시켜 비용함수 E_Q가 증가되는 것을 알 수 있었다. 노이즈가 가장 많은 $\sigma=30$ 인 경우는 세대수를 더 늘려 E_Q값이 증가되는 것을 알 수 있다. 표 2에서 알 수 있듯이 노이즈가 많이 첨가된 영상에서 E_Q의 증가가 크고 그리고 빠르게 증

가되는 것을 알 수 있다. 이것은 유전자 알고리즘을 노이즈가 많은 영상에서 더 좋은 효과를 얻을 수 있다는 것을 보여준다.

그림 15는 위험영상에 노이즈를 첨가한 영상과 60세대를 진행시킨 후의 에지영상을 보여준다. (a)는 오리지날 위험영상이고 (b)는 $\sigma=25$ 인 노이즈를 첨가한 영상이다. (c), (d)와 (e)는 기울기 연산자인 Sobel 연산자와 Prewett연산자 그리고 Kirsh를 사용하여 추출한 에지영상이다. (f)는 Log연산자를 사용하여 추출한 에지영상을 그리고 (f)는 60세대의 유전자 알고리즘을 진행시킨 후의 에지영상을 보여준다(괄호안의 숫자는 비용함수를 나타낸다). 기울기 연산자인 Sobel과 Prewett

연산자를 사용하여 추출한 에지영상은 에지두께가 두꺼워 간격이 좁은 에지부분이 훼손되는 경향이 있고 Kirsh연산자는 비록 두께가 가늘지 만은 주위에 많은 노이즈를 에지로 추출하였다. Log연산자 역시 두께는 가늘지만 에지로 추출하여야 할 많은 부분을 잃어버리는 에지영상을 보였다. 그러나 유전자 알고리즘을 적용한 후의 에지영상은 비용함수 E_Q 의 증가와 함께 에지의 두께가 가늘고 그리고 끊어진 에지 부분을 이어주며 주위에 있는 노이즈도 많이 제거된 에지영상을 보여준다.

Ⅶ. 결 론

에지추출 문제를 에지평가함수 최대화 문제로 다루었다. 이것은 에지형상의 질을 평가하는 비용함수를 어떻게 구성하느냐에 크게 좌우된다. 3×3 윈도우 안에 존재하는 에지픽셀이 형성하는 에지형상을 기본으로 한 후보 에지영상을 구성하는 알고리즘과 에지의 연속성과 굵기 그리고 길이에 근거한 정보를 이용하여 에지평가함수를 구성하였다. 비용함수를 최대화 시키는데 유전자 알고리즘을 사용하였다. 이 유전자 알고리즘을 적용한 후 향상된 비용함수를 가지는 에지영상을 생성할 수 있었고 가울기 연산자나 Log 연산자 보다 더 낮은 에지영상을 구성할 수 있었다. 이와같은 비용 최대화 방법은 여러가지 형태의 에지를 추출하는데 사용할 수 있을 것이다. 그러나 본 논문에서 제시한 에지평가함수가 에지의 질을 평가하는데 완벽한 것은 아니다. 에지의 질을 평가하는 에지평가함수의 구성에 에지 연속성과 굵기 그리고 길이외에 다른요소를 추가한 비용함수를 구성한다면 더 낮은 에지를 추출할 수 있을 것이다. 따라서 이에대한 연구가 더 보완되어야 할 것으로 사료된다.

참고문헌

1. L.S. Davis. "A Survey of Edge Detection Techniques." Computer Graphics and Image Processing 4, pp.248-270, 1975.
2. K. S. Fu and J. Mui. "A Survey on Image Sementation," Patern Recognition 13, pp.3-16, 1981.
3. R. M. Haralic and L. G. Shapiro. "Image Segmentation Technique." Computer Vision,

Graphics, and Image Processing 29, pp.100-132, 1985.

4. Sung-kee Lee "Adaptive Image Segmentation." Ph.D. Thesis, Department of computer science, University of Utah, 1990.
5. D. H. vallard and C. M. Brown, *Computer Vision*, Prentice-Hall, pp.119-122, 1982.
6. John Canny, "A Computational Approach to Edge Detection," IEEE Transaction on Pattern Analysis and Machine Intalligence, Vol. PAMI-8, NO. 6, 1986.
7. R. Nevatia, "A color edge detector and its use in scene segmentation," IEEE transaction systems, Man and Cybernetics, vol. SMC-7, NO. 11, pp.222-241, 1980.
8. D. Marr and E. Hildreth, "Theory of edge Detection." Proc. Roy. Soc. London b. vol. 207, 1980.
9. D. Marr, *Vision*. New York: W. H. Freeman and Company, pp.51, 1982.
10. A. Rosenfeld, *Image Modeling*. New York: Academic Press, pp.51, 1981.
11. J. Lam and J. Delosme, "Simulated Annealing. A Fast Heuristic for some Genetic Layout Problems." Proc. Int. Conf. on Computer-Aided Design, pp. 510-513, 1988.
12. B. Kernigham and S. Lin, "An Efficient Heuristic Procedure for Partitioning Graphs," Bell Systems Technical Journal, Vol. 49, pp.291-307, Feb. 1970.
13. Holland, J. H. "A new kind of turnpike theorem," Bulletin of American Mathematical society, 75, pp.1311-1317, 1969.
14. Holland, J. H. *Processing and Processors for Schemata*, In E. L. jacks(Ed), Associative information processing. New York, pp.127-146, American Elsevier, 1971.
15. K. A. DeJong, "Addaptive System Design: a Genetic approach", IEEE Trans. SMC-10(9), pp.566-574(Sept. 1980).
16. K. DeJong, "Analysis of the behavior of a

class of Genetic Adaptive System.” Ph. D. Thesis, University of Michigan, 1975.

17. D. E. Goldberg. *Genetic Algorithm in Search, Optimization, and Marchine Learning*, Addison-Wesley Publishing Comp. Inc. pp.121-

122, 1989.

18. D. E. Goldberg. *Genetic Algorithm in Search, Optimization, and Marchine Learning*. Addison-Wesley Publishing Comp. Inc. pp.10-11, 1989.



金秀謙(Su Gyeam Kim) 정회원

1954년 7월 26일생

1986년 2월 : 광주대학교 전산학과 이학사

1988년 9월 : 조선대학교 전산학과 이학석사

1989년 9월~현재 : 조선대학교 컴퓨터공학과 박사과정

1990년 7월~현재 : 목포해양대학교 기관공학과 조교수

*주관심 분야 : 화상처리, 인공지능, 컴퓨터비전



趙範俊(Bum Joon Cho) 정회원

1953년 2월 28일생

1980년 : 조선대학교 졸업

1988년 : 한양대학교 대학원 졸업(공학박사)

1989년~1991년 : University of Connecticut(Post-Doc)

1993년~현재 : 조선대학교 전자계산소장

현재 : 조선대학교 공과대학 컴퓨터공학과 부교수

*주관심 분야 : 패턴인식, 컴퓨터비전, 인공지능