

뉴로 퍼지를 이용한 포탈 영상의 개선 알고리즘의 연구

허수진 · 신동익

울산대학교 의과대학 의공학교실
(2000년 5월 22일 접수, 2000년 10월 5일 채택)

Enhancement Algorithm of Portal Image using Neuro-Fuzzy

S.J. Huh, D.I. Shin

Dept. of Biomedical Engineering, Asan Medical Center University of Ulsan, College of Medicine

(Received May 22, 2000, Accepted October 5, 2000)

요약 대부분의 포탈 영상이 그에 상응하는 시뮬레이터 영상을 참조 영상으로 하여 방사선치료 계획을 수행하고 있다 이것은 선형가속기의 높은 에너지 X선으로서 얻어지는 포탈 영상의 물리적 특성 때문에, 구조적으로 대단히 불량한 포탈 영상의 개선과 잃어버린 영상 정보의 복원에 시뮬레이터 영상 자체에서의 영상정보를 이용할 수 있다는 가능성을 보여주고 있는 것이다

본 연구에서는 최대 퍼지 엔트로피를 평가함수로 이용한 유전자 알고리즘을 사용하여 영상에서의 퍼지 영역을 자동적으로 결정하고, 그것을 멤버십 함수에 적용하여 퍼지영상 개선 기법으로서 포탈 영상과 시뮬레이터 영상을 개선한 후, 잡음이 증철된 시뮬레이터 영상들로서 연관기억장치를 학습시키고 여기에 퍼지 방법으로 개선시킨 포탈 영상을 입력하여 기존의 영상기법으로 처리된 영상보다 좋은 포탈 영상을 얻을 수 있었다

Abstract : For a reliable patient set-up verification, better portal films are needed to track relevant features. Simulator films are compared with portal films as a reference image in radiotherapy planning. This shows some possibilities of the use of image information of simulator images for enhancement and restorations of portal images which are very poor in quality compared with the simulator images.

This paper present an approach that combine an associative memory, a kind of artificial neural networks with fuzzy image enhancement technique using genetic algorithm which determines the fuzzy region of membership function by the use of maximum entropy principles. A higher portal image quality than conventional techniques is achieved.

Key words : Fuzzy image enhancement, Fuzzy region, Genetic algorithm, Membership function, Associative memory

서 론

의료용 선형가속기는 악성 종양을 치료하기 위해 선택된 부위에만 에너지를 조사(radiation)하는 치료기기이다. 방사선 치료에는 두개의 상반되는 치료목표가 있다. 첫째는 종양의 성장을 파괴하기 위해 치료부위에 충분한 에너지를 공급하는 것 둘째는 종양 주위의 정상 조직의 손상을 최소화하기 위한 에너지의 정확한 국소화(localization)이다. 환자의 장기(anatomy)에 대한 치료필드의 적절한 국소화는 방사선치료에서 필수

적이며 포탈 영상과 시뮬레이터 영상의 시각적인 비교로 확인된다[1]. 포탈 영상(PI, portal image)은 환자의 장기에 대해 치료 범의 위치와 모양을 확인하는 중요한 도구가 되고 있으며 일반적으로 치료계획 필드의 범에 대한 실제 환자 위치의 시각적인 비교가 수행된다. 이 치료 필드는 진단 및 치료계획 중에 정의된다. 이 목적으로 치료 시뮬레이션을 하며 그 결과로서 시뮬레이터 영상(SI, simulator image)이 얻어진다 선형가속기의 높은 에너지 X선으로 얻어지는 영상의 물리적 특성 때문에 PI는 보통 X선 영상인 SI에 비해 질적으로 매우 열악하다. 그러나 PI는 SI와 달리 치료중에 얻어지는 dynamic 데이터이다. 그러므로 환자와 그 장기의 실제 위치에 대한 유일하게 사용할 수 있는 정보이다. 기존의 PI는 뼈 조직에 관련된 환자의 위치의 대략적인 확인에 주로 사용되고 있으나 최신의 영상개선 기법을 PI에 적용하면 치료후의(off-line) 시각적 분석에도 많은 도움이 되고 있다[2].

영상개선의 목적은 원래의 영상을 인간이 좀 더 편안하게

이 논문은 1998년 한국학술진흥재단 학술연구조성비에 의하여 지원되었음

통신저자 허수진 (138-736) 서울시 송파구 풍납동 388-1, 울산의대 서울중앙병원 의공학과

Tel. 02-2224-5101, Fax. 02-2224-5290

E-mail. sihuh@www.amc.seoul.kr

인식할 수 있는 영상으로 변환하는 것이다. 의사에 의한 P1의 시각적 분석을 위해, 치료 필드 내부에 있는 환자의 장기 위치에 관한 확실한 정보가 중요하다. 이러한 영상개선 방법은 강건해야 하고 개선 효과가 쉽게 얻어지야 한다. 이러한 종류의 영상 개선을 위해 보통 사용되는 두가지의 point operation은 gray level modification과 히스토그램 평활화이다 [3]. 그러나 기존의 히스토그램 평활화는 영상의 빈화하는 제조도 dynamics 때문에 만족스럽지 않은 결과를 보일 때가 많아, 이 방법의 성능을 개선하기 위한 히스토그램 평활화의 변형들이 개발되었고 예를 들면 selective contrast limited adaptive histogram equalization 등이다[4]. 얼마전 까지만 해도 퍼지 집합이나 인공지능망의 사용이 영상 개선에 좋은 수단이라고는 생각하지 않았다. 즉 굳이 이러한 기법들을 사용하지 않아도 기존의 기법들을 이용하여 영상개선을 할 수 있다는 의견이 많았다. 그러나 최근 여러 퍼지 뉴로 기법을 이용하여 복잡한 비선형 영상 개선에 대한 많은 연구가 발표되고 있고 결과도 좋아 활발한 연구분야가 되고 있다[5]. 기존의 영상 개선 알고리즘에 비교하여 퍼지 방법의 이점은 불확실한 조건들 하에서의 안정성이고 다른 한편으로 결과 영상에서도 간단한 조정으로 또 다른 개선된 영상을 쉽게 얻을 수 있는 장점이 있다. 영상을 퍼지 영역으로 변환하기 위해, 퍼지 영역(region)의 선택이 중요하며, 이 퍼지 영역의 선택은 영상의 성질에 따라야 한다. 즉 특성이 다른 영상들은 다른 퍼지 범위 영역을 갖어야 한다. 대부분의 포탈 영상이 그에 상응하는 시뮬레이터 영상을 참조영상(reference image)으로 하여 방사선치료 계획을 평가한다는 것은 포탈 영상의 개선과 잃어버린 정보의 복원(resolution)에 시뮬레이터 영상 자체에서의 영상정보를 이용할 수 있다는 가능성을 암시하는 것이다. 이러한 연구 즉 인공지능망을 이용한 포탈 영상의 복원에 대한 연구 결과가 이미 발표되고 있다[2].

본 연구에서는 퍼지 방법에 의한 contrast adaptation 및 인공지능망(artificial neural network) 기법으로서 포탈 영상을 개선하였다. 즉 영상에서의 최대 퍼지 엔트로피를 평가함수로 이용한 유전자 알고리즘을 사용하여 퍼지 영역을 자동적으로 결정하고, 그것을 멤버십 함수에 적용하여 영상을 퍼지화(fuzzification)한 후에 퍼지 방법으로 포탈 영상과 시뮬레이터 영상의 제조도를 변경시켜 영상을 개선하였다. 다음 단계로서 잡음이 중첩된 시뮬레이터 영상들로서 연관기억장치(associative memory)를 학습시킨 후, 여기에 퍼지 방법으로 개선시킨 포탈 영상을 입력하여 더욱 개선된 포탈 영상을 얻었다. 이때 영상을 퍼지화하는 멤버십 함수로서 최대 엔트로피의 퍼지 영역을 갖는 램프함수를 사용하였다. 또한 포탈 영상의 복원시에 인공지능망의 학습 데이터들을 생성하는 방법과 인공지능망의 학습 시간을 단축하기 위한 영상의 샘플링 방법을 제안하고 이를 실제 영상에 적용하여 좋은 결과를 얻었다.

퍼지 영상 개선

대수학에서 정의된 고진 집합 A에서 가 요소 x는 집합에 포함되거나 이니거나 한다. 그러므로 집합 A에 포함된 요소는 멤버십 $\mu_A(x)$ 가 1이고 집합에 포함되지 않으면 0이 된다. 이 멤버십은 crisp하고 요소들의 부류(class)들의 경계가 hard하다. Zadeh는 1965년에 퍼지집합 논리를 발표하였다. 퍼지집합 이론은 페턴의 불확정성이 불규칙성보다는 내재하는 편이성이나 모호성(fuzziness)에 기인할 때 적절한 알고리즘을 제공한다. 퍼지 집합은 식(1)로 표현된다 [6].

$$A = \{ \mu_A(x_i), x_i | i=1,2,3,\dots,N \} \quad (1)$$

여기서 N은 집합에서 요소의 개수이고, $\mu_A(x_i)$ 는 x_i 를 퍼지 영역[0,1]으로 매핑하는 멤버십 함수이며 그 값은 요소들의 퍼지 집합에 속하는 정도를 표시한다. 이 값이 클수록 멤버십의 정도가 높아진다. 수학적인 면에서 고진 집합과 퍼지 집합의 차이는 멤버십 함수의 값의 차이이다. 예를 들면 제조도가 8인 영상의 퍼지 집합은 다음과 같이 표시할 수 있다.

$$\text{Bright} = \{ (\mu_{\text{Bright}}(\text{graylevel}), \text{graylevel}) | \text{graylevel}=0,1,\dots,7 \} \\ = \{ (0,0), (0.1,1), (0.2,2), (0.4,3), (0.6,4), (0.8,5), (0.9,6), (1,7) \}$$

영상의 제조도가 8 (0, 7)이던 0은 어두운 것이고 7은 밝은 것을 의미한다. 화소들의 멤버십 값을 화소의 제조도 0에서 7까지 변화에 따라 0에서 1까지 정할 수 있다. 제조도가 7에 가까울수록 멤버십 값은 높아진다. 제조도 3은 제조도 1보다 7에 가까우므로 $\mu_{\text{Bright}}(3)$ 은 $\mu_{\text{Bright}}(1)$ 보다 크다.

영상을 퍼지 개념으로 처리하기 위해 새로운 영상의 정의가 필요하다. 퍼지집합 이론에서 영상정보는 퍼지 영상의 형태에서 퍼지 집합으로 표현이 가능하다. 즉 제조도 영상은 화소가 여러 가지 레벨의 밝기를 가질 수 있으므로(즉 화소가 어떤 애매성(ambiguity)을 가지므로), 영상처리 문제에 퍼지 집합 개념을 적용할 수 있다. 전체집합 내에 유한개의 지지점(supporting point, x_1, x_2, \dots, x_l)을 갖는 퍼지집합 A는 다음과 같이 합집합 형태로 표시할 수 있다.

$$A = \cup \mu_A/x_i \quad i=1,2,\dots,N \quad (2)$$

$M \times N$ 차원과 레벨 L의 제조도를 갖는 영상 X는 퍼지 집합 개념으로 볼 때 단일 퍼지값(fuzzy singleton)들로 구성되는 하나의 2차원 배열로 볼 수 있다. 이 때 이들 각 퍼지 단일값은 어떤 밝기 레벨 $k(k=0,1,2, \dots,L-1)$ 에 대해 자신의 밝기 정도를 상대적인 값으로 나타내는 멤버십 함수값을 가지게 된다. 따라서 영상 X를 퍼지 집합의 기호로 표시하면 다음 식으로 나타낼 수 있다 [7].




그림 1. 퍼지 영상 개선도

Fig.1 Block diagram of the fuzzy image enhancement model

$$X = \bigcup_{mn} \mu_{mn}/X_{mn}, m=1,2,\dots,M \quad n=1,2,\dots,N \quad (3)$$

여기서 X_{mn} 은 영상내의 (m,n)번째 화소의 밝기를 나타내며 μ_{mn} 는 멤버십이며 μ_{mn}/X_{mn} 는 X_{mn} 이 어떤 특성 μ_{mn} 을 소유하는 정도로서 $0 \leq \mu(x_i) \leq 1$ 의 값을 갖는다.

퍼지 영상 개선의 절차는 그림 1과 같다. 퍼지 영상처리는 일반적으로 영상의 퍼지화(fuzzification, image coding), 멤버십 평면에서의 연산, defuzzification (decoding of results)의 3 단계로 구성된다. 퍼지화는 영상에서 관심있는 특성(예, brightness, edginess, homogeneity,...)에 관하여 하나 또는 그 이상의 멤버십 값을 할당하는 것을 의미한다. 영상을 멤버십 평면으로 변환 후, 적절한 퍼지 방법으로 멤버십 값을 수정한다. 화소값의 변경, 영역의 추출 등의 새로운 결과를 얻기 위해 멤버십 평면의 출력은 다시 decode된다. 이것은 멤버십 값들이 계조도 평면으로 재변환되는 것을 의미한다 [8] 이 논문에서의 퍼지 영상 개선절차는 다음과 같다.

- 1) 퍼지 영역을 갖는 멤버십 함수를 결정한다.
이때 최대 엔트로피와 유전자 알고리즘을 이용하여 퍼지 영역을 구한다.
- 2) 멤버십 함수로서 화소마다의 멤버십 값을 구한다
- 3) 적절한 퍼지 방법으로 멤버십 값을 수정한다.
- 4) 새로운 계조도(gray level)를 얻는다.

1. 멤버십 함수(Membership function)의 결정

멤버십 함수는 주어진 영상을 퍼지화하는데 일차적으로 사용된다. 퍼지 집합 이론의 적용을 제한하는 것 중의 하나가 주어진 영상에 대해 멤버십 함수를 결정하는 것이 어렵다는 것이다 [9]. 멤버십 함수는 영상의 darkness, textual property




그림 2. 퍼지 영역을 갖는 램프 함수

Fig 2 Ramp mapping function with fuzzy region

같은 특성을 특징화한다. 그리고 전체영상에 대해서는 전역적으로 또는 세그먼트에 대해서는 지역적으로 정의될 수 있다. 실제 문제들에서 퍼지 집합의 멤버십 함수를 나타내는데 많은 경우에서 사용되는 함수는 S-함수, π 함수, 램프함수 등이다. 이러한 일반적인 함수이외에도 영상의 특성을 더 잘 나타낼 수 있는 형태의 멤버십 함수를 만들어 사용할 수도 있다. 멤버십 함수를 임의로 결정하면 멤버십 함수가 포탈 영상의 성질을 제대로 반영하지 않을 수도 있다.

이 논문에서는 여러 종류의 멤버십 함수들을 조사한 후, 식 (4)로 표시되는 그림 2와 같은 퍼지 영역을 갖는 램프함수를 멤버십 함수로서 사용하였다. 퍼지 μ_{mn} 값은 영상의 화소 X_{mn} 이 최대 밝기 레벨 X_{max} 를 소유하는 정도를 나타낸다. 집합 X 의 요소를 $X_{mn} \in \{0,1,2,\dots,L-1\}$ 으로 표시할 때 이들 각 요소는 램프 함수에 의하여 퍼지 단일값으로 변환된다. 영상 X 에서 범위 $[a,b]$ 가 퍼지 영역(fuzzy region)에 해당되며 나머지 영역은 비퍼지 영역이나 퍼지 영역내에 있는 화소값에 대해서만 식(4)로서 멤버십을 계산한다. X 는 화상의 세기를 나타내는 변수이고 A, B 는 램프함수의 형태를 결정하는 파라메타들이다. 이 A, B 를 정하는 데 다음절의 유전자알고리즘을 이용한다.

$$\mu_{mn} = A \cdot X_{mn} + B \quad (4)$$

2. 최대 엔트로피(Maximum entropy principle)

영상을 세기(계조도) 영역으로부터 퍼지 영역(fuzzy domain)으로 변환하는데 있어서 문제들 중의 하나는 변환된 영역에서 얼마나 많은 정보를 갖고 있는가 이다. 정보이론에 따르면 엔트로피는 다음과 같이 정의된다[10].

$$H(A) = - \sum_{i=1}^N P(x_i) \log P(x_i) \quad (5)$$

여기서 $\sum_{i=1}^N P(x_i) = 1$

엔트로피의 값 $H(A)$ 가 클수록 A 가 더 많은 정보를 갖는다. 영상처리에서는 세기(intensity)를 출력으로 갖는 영상을 정보소스 A 로서, 히스토그램 분포를 확률분포 $P(x_i)$ 로서 생각할 수 있다. 기본적으로 식(5)는 공간 세기(intensity)영역에서 분포 P 만의 엔트로피를 나타낸다. 그러나 필요한 것은 영상이 퍼지 영역으로 변환되었을 때의 정보의 총량의 측정이다. 즉 멤버십 함수로서 영상을 세기 영역에서 퍼지 도메인으로 변환할 때 가능한 많은 정보를 갖도록 영역의 범위를 정하는 것이다. 이

러한 문제를 해결하기 위해 Cheng 등은 퍼지 집합 A의 엔트로피를 식(6)과 같이 새롭게 정의하였다[7].

$$H(A, N, M, \mu_A) = -1/\log N \sum_{i=1}^N Pp(A_i) \log Pp(A_i) \quad (6)$$

여기서 $Pp(A_i) = \sum_{\mu_A(x) \in A_i} P(x)$

A를 퍼지 이벤트라고 하고, N을 퍼지영역 A에서의 파티션의 수, 분할된 파티션을 A1, ..., AN으로 표시한다. 퍼지 영역의 파티션 방법 M이고 $\mu_A(x)$ 은 멤버쉽 함수이며 P(x)는 공간 영역에서의 x의 확률이다. Pj(Ai)는 멤버쉽 함수 μ_{A_i} 에 의해 퍼지영역 Ai로 매핑되는 공간영역에서의 x에 대한, 공간 영역에서의 합해진 확률이다. 멤버쉽 함수로서 램프 함수를 선택하고 파티션의 수 N과 파티션 방법 M을 결정하면 Pp()는 램프 함수의 (a,b) 파라메타들에만 의존한다. 그러므로 식(6)은 다음처럼 쓸 수 있다.

$$H(A, a, b) = -1/\log N \sum_{i=1}^N Pp(A_i, a, b) \log Pp(A_i, a, b) \quad (7)$$

퍼지영역(a1,b1)을 갖는 램프함수를 멤버쉽 함수로서 사용하여 영상을 퍼지 도메인으로 변환하였을 때, H1(A,a1,b1) > H2(A,a2,b2) 이라면 주어진 영상은 퍼지영역[a1,b1]에서 보다 [a2,b2]에서 더 많은 정보를 갖고 있다는 것을 의미한다. 따라서 문제는 H(A,a,b)가 최대 엔트로피가 되도록 영역(a,b)의 조합을 찾는 것이다. 이러한 문제를 해결하는 방법으로 heuristic 방법, 인공지능망, 유전자 알고리즘 등이 있다 이 논문에서는 멤버쉽 함수로서 식(4)의 램프함수를 사용하고, 파티션 수 2, 균일 파티션 방법으로 하여 유전자 알고리즘을 이용하여 퍼지영역을 구한다.

3. 유전자 알고리즘(Genetic algorithm)을 이용한 퍼지 영역의 결정

유전자 알고리즘을 사용하여 유전자 형태로 코드화된 해법들을 구할 수 있다 유전자 알고리즘은 생리학적인 현상과 같이 염색체 교차(cross over)와 돌연변이(mutation)를 통하여 다음 세대(population)를 생성한다 [11] 엔트로피 H(A,a,b)가 최대값을 갖는 퍼지영역 범위[a,b]를 찾기 위한 유전자 알고리즘과 그 파라메타 들에 대해 설명한다. 여러 종류의 포탈 영상에서 실험 후, 유전자 알고리즘의 파라메타들을 정하였다

1. Coding method : 코딩 방법은 보통 0 또는 1의 유한 스트링으로서 문제 파라메타들을 표현한다. 이 유한 스트링들을 유전자(chromosome)라고 부른다 각 유전자는 문제에 대한 해답이 된다. 각 파라메타의 값의 범위는 0부터 255까지이고 8비트 이진수로 코드화되며 각 유전자가 $0 \leq a < b \leq 255$ 가 되도록 2개의 파라메타 a,b를 생성한다

2. Evaluation function . 평가함수는 각 유전자가 제시하는 해답에 대한 적정치 척도(fitness measure)이다. 이 값은

유전자들이 최종 목적값을 얼마나 만족시키는가 하는 정도이다. 유전자를 입력으로 하여 유전자의 fitness 값을 생성한다. fitness 값에 대한 2가지 전제가 있다.

- 1) fitness 값은 음수가 아니다.
- 2) 유전자가 좋을수록 fitness 값은 크다.

퍼지 엔트로피의 정의는 위의 두 조건을 만족하므로 평가함수로서 직접 사용할 수 있어 식 (7)의 엔트로피 함수를 평가함수로 사용하였다. 한편 파라메타(a,b)의 조합은 $0 \leq a < b \leq 255$ 이라는 제약이 있으므로 유전자가 이를 만족치 못하면 fitness 값은 0이 된다

3. Selection fitness 값에 따라 알맞는 파라메타를 선택하기 위하여 roulette wheel selection 방법을 사용한다 children을 재 생성하는 parent의 확률은 fitness 값에 비례한다.

4. maximum generation number . 유전자 알고리즘은 이 최대 생성 횟수에 달할 때까지 연산된다. 이 논문에서는 최대 생성 횟수가 100이 넘으면 중지한다 이 횟수는 시행착오법으로 정했고, 알고리즘은 이 범위 내에서 가장 타당한 해답을 발견할 수 있어야 한다

5. population size 각 세대에서 유전자의 크기를 나타낸다. population 크기가 너무 작으면 gene pool의 diversity가 충분히 크지 않아 해답의 질이 나빠지고, 이 크기가 너무 크면 계산시간이 길어진다. 이 논문에서 population의 크기를 100으로 하였다.

6. Cross over and Mutation : selection 연산 후에 선택된 parent 들의 유전자를 재 조합하기 위해 crossover 연산이 수행된다. 두 개의 유전자를 교배시키는 확률이 cross over율이며, 이 값을 0.5로 하였다 crossover 연산 후에 두 개의 children에 mutation 연산을 수행한다. 이 연산은 비트 단위로 수행된다. 각 유전자에서의 요소가 0에서 1로, 1에서 0으로 변하는 돌연변이 확률인 mutation율은 0.01로 하였다.

이 논문에서는 식(7)을 평가함수로 하고 유전자 알고리즘의 파라메타들을 결정한 후에, 그림3과 같은 유전자 알고리즘으로서 최대 엔트로피 H(A,a,b)를 갖는 해(a,b)를 구하였다. 최종적으로 구해진 [a,b]로서 퍼지 영역이 결정된다.

```

Procedure GA
begin
  t=0;
  initialize P(t);
  evaluate P(t);
  While not finished do
  begin
    t=t+1;
    select P(t) from P(t-1);
    reproduce pairs in P(t);
    evaluate P(t);
  end
end
    
```

그림 3. 유전자 알고리즘의 예
Fig. 3. A simple genetic algorithm

4. 퍼지 영상개선 (Fuzzy image enhancement)

제안된 방법으로부터 얻은 결과로서 영상 화소의 멤버쉽 값을 구한 후 이를 영상개선에 적용하였다. 영상개선에 흔히 사용되는 방법은 대조도 강조법(contrast intensification, INT)이다. A를 퍼지 영역에서의 멤버쉽 값 $\mu_A(x)$ 를 갖는 영상이라고 하면 대조도 강조법 INT(A)는 아래와 같이 정의된다 [12].

$$\mu_{A'}(x) = \mu_{INT(A)}(x) = 2[\mu_A(x)]^2 \quad 0 \leq \mu_A(x) \leq 0.5 \quad (8)$$

$$= [1 - 2(1 - \mu_A(x))^2] \quad 0.5 \leq \mu_A(x) \leq 1.0$$

퍼지집합 A에서 INT 연산자는 다른 퍼지 집합 A'를 만들어 낸다. INT는 퍼지 집합에서의 fuzziness를 변경하는 효과를 보인다. 이 연산은 0.5이상의 $\mu_A(x)$ 의 값을 증가시키고 0.5 이하의 값을 감소시켜, 집합A의 퍼지성을 감소시킨다. 영상을 퍼지 도메인으로 변환 후에 새로운 멤버쉽 함수를 얻기 위해 INT 연산을 하였고 이를 다시 역변환하여 새로 얻은 멤버쉽을 화소의 계기로 변환하여 개선된 영상을 얻는 것이다.

$$x' = \mu_A^{-1}[\mu_{INT(A)}(x)] \quad (9)$$

그러나 흔히 사용되는 위의 방법을 포탈 영상에 적용하면 포탈 영상의 특수성으로 영상의 질이 더욱 나빠지는 경향이 있어, 이 논문에서는 FHH (Fuzzy histogram hyperbolization) 방법을 사용하여 영상의 계조도를 변경하였다. 이 기법은 퍼지 파라메터에 따라 단순한 대조도 증폭에서 부터 어떤 영역들의 분할까지 넓은 범위의 효과를 발휘한다. FHH에서 화소값의 변환은 다음 식으로 정의된다[13].

$$g_{mn} = F_1(L-1) 1/[e^{-1}-1] [e^{-\mu(g_{mn})^\beta} - 1] + F_2 \quad (10)$$

$F_1=1, F_2=0$ 으로 놓으면 FHH의 표준 버전을 얻을 수 있다. 인간의 밝기에 대한 비선형적인 인식 때문에 이 방법은 대수 함수로서 계조도의 멤버쉽 값들을 변경한다. 상수 L은 영상에서의 최대 화소값, $\mu(g_{mn})$ 은 화소값 g_{mn} 의 멤버쉽 값이다. $\beta \in [0.5, 2]$ 는 멤버쉽 값을 modify하는 계수이며 보통 fuzzifier라고 하며 결과 영상의 계조도 dynamics를 변경할 수 있다. 만일 $\beta=0.5$ 이던 dilation, $\beta=2$ 이면 concentration 연산이 된다 의학영상에서 fuzzifier의 사용의 예를 들면 의사에게 영상의 질에 대해 느낌을 물었을 때 영상이 너무 밝다거나, 좀 어둡다고 이야기한다면, 이러한 모호한 표현들을 영상의 복원이나 개선에서 fuzzifier의 값을 변경하여 극복할 수 있다.

일반적으로 많이 사용되는 멤버쉽 함수인 램프함수, 시그모이드 함수로서 얻어진 멤버쉽 값들과 최대 엔트로피 원리를 기반으로 유전자 알고리즘을 이용하여 구하여진 퍼지 영역을 갖는 램프 함수를 사용하여 얻어진 영상 화소의 멤버쉽 값들을 각각 FHH에 적용하여 얻어진 퍼지 영상개선의 예를 그림 4, 5에 보인다

그림 4a는 일반 영상이고 본 논문에서 제안한 방법으로 개선시킨 영상이 그림 4d이다. 미세한 선들과 보이지 않던 글자들도 선명히 보이고 있어 영상개선이 잘 되었음을 알 수 있다. 그림 4b, 4c는 각각 멤버쉽 함수로서 일반 램프함수와 시그모이드 함수를 사용한 결과이며 그림 4e는 히스토그램 평활화 기법으로 처리한 것이다 영상의 결과에서 대조도의 차이가 보이지만 제안된 방법이 뚜렷하게 우수하다고는 할 수 없을 것 같다.

그러나 우리가 개선하려고 하는 포탈영상은 일반 방사선 영상과는 달리 높은 에너지 방사선으로 촬영되어 영상의 관심 영역(방사선 치료 영역)이 겹쳐 보이는 특징이 있다 이러한 종류의 영상 개선을 위해 사용되는 point operation은 gray level modification과 히스토그램 평활화이다. 포탈 영상은 변화하며 달라지는 대조도 동적 특성(dynamics)을 갖기 때문에 기존의 히스토그램 평활화 기법으로서 만족스러지 않은 결과를 보이는 경우가 자주 있다.[2] 따라서 본 연구에서는 퍼지 기법




그림 4. 멤버쉽 함수에 따른 퍼지 영상 개선 알고리즘의 적용 결과(일반 영상)

- Fig. 4. Application of fuzzy image enhancement algorithm using various membership functions
- a. 영상 'Pout' (Image ' Pout')
 - b. 램프함수로 개선된 영상 (Image enhanced with fuzzy method using ramp function)
 - c. 시그모이드 함수로 개선된 영상 (Image enhanced with fuzzy method using sigmoid function)
 - d. 제안된 퍼지기법으로 개선된 영상 (Image enhanced with proposed fuzzy method)
 - e. 히스토그램 평활화 기법으로 개선된 영상 (Image enhanced with histogram equalization)




그림 5. 멤버쉽 함수에 따른 퍼지 영상 개선 알고리즘의 적용 결과(포탈 영상)

Fig. 5. Application of fuzzy image enhancement algorithm using various membership functions

- a. 포탈 영상 (Portal image)
- b. 램프함수로 개선된 영상 (Image enhanced with fuzzy method using ramp function)
- c. 시그모이드 함수로 개선된 영상 (Image enhanced with fuzzy method using sigmoid function)
- d. 제안된 퍼지기법으로 개선된 영상 (Image enhanced with proposed fuzzy method)
- e. 히스토그램 평활화 기법으로 개선된 영상 (Image enhanced with histogram equalization)

을 이용한 대조도 개선 기법을 사용하였다. 이 포탈 영상에 여러 가지 멤버쉽 함수를 적용한 결과가 그림 5이다. 그림 5a는 머리 부분의 포탈영상의 관심영역이고 여기에 멤버쉽 함수로서 일반 램프함수와 시그모이드 함수를 적용하여 처리한 것이 각각 그림 5b, 5c이다. 영상이 다소 개선되었으나 내역이 매우 흐리게 보이고 있어 식별하기가 어렵다. 그림 5d는 본 논문에서 사용한 방법으로 최대 엔트로피를 갖는 퍼지 영역($a=83, b=107$)을 구하고, 퍼지영역을 갖는 램프함수를 멤버쉽 함수로 처리한 것이며, 그림 5e는 histogram equalization 기법으로 처리한 것이다. 여기에서 일반적인 멤버쉽 함수의 사용이나 HE기법보다 본 논문에서 사용한 방법이 영상개선에 효과적임을 알 수 있다.

그림 6a는 가슴 부위의 시뮬레이터 영상이고 그림 6b는 그에 해당하는 포탈 영상이며 그림 6c는 제안된 퍼지 개선 방법을 적용하여 개선된 포탈 영상이다. 매우 어두워서 식별이 안 되는 포탈 영상이 많이 개선되었음을 알 수 있다. 포탈 영상들의 치료부위의 영상을 개선한 결과가 선명하게 보이지는 않는 것은 원래의 영상이 불량한 결과이다. 치료부위의 장기의 특징들이 잘 보이면 치료부위의 설정이 잘 되었는지를 쉽게 판별할 수 있고, 영상개선 후에도 장기의 특징이 잘 나타나지 않은 경우에는 전체적인 마스크의 윤곽의 결합상태 등으로 판별할 수 있다.




그림 6. 시뮬레이터 영상과 포탈영상 (가슴)

Fig. 6. Processing of portal and simulator image (Chest)

- a. 시뮬레이터 영상 (Simulator image)
- b. 포탈영상 (Portal image)
- c. 제안된 퍼지기법으로 개선된 포탈영상(Portal image enhanced with proposed fuzzy method)

시뮬레이터 영상과 포탈 영상은 동일 부위를 서로 다른 크기의 방사선 에너지로서 촬영하여 얻어진 영상들이므로 이들간에는 상관관계가 존재한다. 이들 영상을 개선하여 두 영상의 correlation을 향상시킨 후, 시뮬레이터 영상정보들로 학습시킨 연관기억장치를 사용하여 포탈 영상을 복원, 개선한다.

영상 복원을 위한 연관기억장치 (Associative memory)

일반적으로 연관기억장치(associated memory)는 특정 패턴의 인식이나 복원에 사용되며, 이러한 목적을 위해 연관기억장치는 물체의 형태(shape)들을 저장하고, 이러한 형태들의 관계를 interpolate 하여 원 물체의 형태를 복원해낸다. 이 논문에서 사용된 신경망은 그림 7과 같이 입력층, 은닉층 그리고 출력층으로 구성된 순방향 선형 신경망(linear neural network)으로서 modified associated memory가 사용된다. 그림 7에서 Z_i ,




그림 7. 연관 기억장치의 개념도

Fig. 7. Principle of a modified associative memory

Z_2, \dots, Z_n 은 입력 벡터의 요소들이고 $Z_1^*, Z_2^*, \dots, Z_n^*$ 은 주어진 입력 데이터가 수정된 출력값들이다 본 실험에서 입력값과 출력값의 수는 같고($l=n$) 선형 접속 신경망이므로 다음과 같은 단순한 관계가 성립된다 [14].

$$a=Wz \tag{11}$$

$$z:=Ga \tag{12}$$

$$z:=GWz \tag{13}$$

W와 **G**는 해당 neural layer의 가중치이며 출력 Z^* 는 매트릭스 **W**와 **G**로 계산되며 은닉층(hidden layer)의 neuron의 출력값이 **a**로 표시된다 여기서 **GW**는 square 매트릭스가 된다. 은닉층의 값들(벡터 **a**)에서 $m \ll n$ 이면 데이터의 많은 감소로서 원하는 스무딩 효과를 얻을 수 있다. 영상의 화소값들이 입력값($Z=Z_i:Z_j$)으로서 연관기억장치(modified associative memory)에 입력되며, 입력 데이터는 PI가 된다 $Z'=Z_i'Z_j^*$ 는 출력값(recall)이고 가중치가 결정된 후의 연관기억장치의 출력이다. 복원된 영상이 입력 영상과 동일한 수의 화소를 가져야 하므로 입력값과 출력값의 화소의 수는 같다 ($l=n$) 해당 neural layer의 가중치는 **W**와 **G**로 주어지므로 출력값 Z 은 입력값 Z 로부터 가중치 **W**와 **G**로 계산된다. 저장된 영상의 학습 정보는 은닉층 $a_i:a_m$ 의 출력에 집중되어 있으므로 연관기억장치의 모델링과 스무딩 능력은 hidden neuron들의 갯수에 의해 adapt 되는 정도가 달라진다. 보통 m 은 1보다 대단히 작으며 이것이 스무딩 효과를 보이고, recall 영상이 SI의 영상정보를 이용할 수 있도록 한다. 정확한 학습을 위해 orthogonal evaluation 함수들과 유사한 제한을 도입하여 적용하였다. 랜덤 에러가 감소해야 되므로 학습 데이터에 대한 복원 에러는 식(14)와 같고 학습 데이터에 대하여 최소가 되도록 식(15)과 같이 정한다 [14].

$$R = \sum_{v=1}^n (z_v - z_v')^2 \tag{14}$$

$$G = W^{-1} \tag{15}$$

연관기억장치의 가중치 계산방법에는 기존의 eigenvalue 문제 해결방법을 이용한 K-L expansion 방법[15]과 신경망 학습알고리즘인 Hebbian알고리즘이 있으며 이 논문에서는 Hebbian 알고리즘을 사용하여 신경망을 학습하였다.

인공신경망에서 가중치(weight) 매트릭스의 계산과 학습을 하기 위해 많은 학습 데이터들이 필요하게 된다. 이론적으로는 변화하는 모양들을 많이 만들어 그것들을 연관기억장치(associative memory)의 학습 데이터로서 사용하는 것이다. 그러나 물체의 인식을 위한 시스템의 학습에 충분한 수의 변화되는 형태들을 입력 데이터로서 수집하는 것은 비현실적이므로 다른 방법을 생각하였다 즉 기본적인 이상적인 물체의 형태를 가정하고 그 모양을 영상처리 기법을 이용하여 조금씩 변형시킨다. 결과적으로 물체의 형태는 적절한 크기의 band limited

잡음으로 중첩되는 것이네, 잡음의 대역폭(bandwidth)은 이상적인 원래의 형태로부터 신경망이 식별해 낼 수 있는 최소의 차이로 한다.

본 연구에서는 퍼지 방법으로 개선된 시뮬레이터 영상에 평균값과 분산값이 다른 가우시안 잡음을 가하여 만들어진 40개의 시뮬레이터 영상을 인공신경망의 학습 데이터로 사용하였다 또한 학습속도를 높이기 위하여 입력되는 포탈 영상을 3 x 3마스크로서 샘플링하여 영상의 크기를 1/9로 축소된 후 이를 연관기억장치로서 영상 복원한 후에 처리된 영상을 bilinear interpolation으로 원래의 영상을 만들어 내었고 이 영상과 축소하지 않고 처리한 영상과를 비교하였다.

실험 및 토의

뉴로 퍼지 영상개선 방법의 장점은 기존의 영상 개선 알고리즘에 비교하여 불확실한 조건들 하에서의 안정성과 결과 영상에서 간단한 조절로 원하는 영상을 얻을 수도 있다는 것이다. 그림 8a는 머리부위의 시뮬레이터 영상이며 그림 8b는 그 시뮬레이터 영상에 해당되는 포탈 영상이다. 시뮬레이터 영상의 질이 훨씬 좋은 것을 알 수 있다 그러나 이것은 치료중에는 얻을 수 없으므로 좋은 질의 포탈 영상을 실시간으로 얻는 것이 바람직하다. 포탈 영상으로는 배경과 물체 영상의 구별이 어렵고 시뮬레이터 영상과 비교 할 때 영상의 질이 매우 열악함을 알 수 있다. 포탈 영상에서 검게 보이는 부위가 방사선 치료를 받는 부위이고 밝게 보이는 부위가 방사선 차폐블록으로 차폐된 부위이다. 제안된 퍼지영상 개선기법을 적용하여 개선한 영상들이 각각 그림 8c, 8d이다 원래 질이 좋았던 시뮬레이터 영상은 크게 개선이 되지는 않았지만 포탈 영상은 뚜렷이 개선되었음을 알 수 있다.

개선된 시뮬레이터 영상과 포탈 영상에서 치료필드(관심영역)만을 추출[16]하여 그림 9a, 9b를 얻는다. 포탈 영상이 많이 개선되어 있음을 볼 수 있다. 치료필드를 45x45 화소들의 패치들로 분할하여 연관기억장치로 입력한다. SI 각각의 패치에서 associative memory의 가중치들이 계산되며, 이 때 미리 준비한 40개의 SI 학습데이터들이 사용된다 연관기억장치의 가중




그림 8. 시뮬레이터 영상과 포탈영상 (머리)
 Fig. 8. Processing of portal and simulator image (head)
 a 시뮬레이터 영상 (Simulator image)
 b 포탈영상(Portal image)
 c. 퍼지기법으로 개선된 시뮬레이터 영상 (Simulator image enhanced with fuzzy methods)
 d 퍼지기법으로 개선된 포탈영상 (Portal image enhanced with fuzzy methods)




그림 9 시뮬레이터 영상과 포탈영상의 관심영역 처리 (머리)

Fig. 9 ROI of portal and simulator image (head)

- a 퍼지기법으로 개선된 시뮬레이터 영상(Fuzzy enhanced Simulator image)
- b 퍼지기법으로 개선된 포탈영상(Fuzzy enhanced Portal image)
- c 연관기억장치로 개선된 포탈영상(Portal image enhanced with associative memory)
- d 샘플링방법과 연관기억장치로 개선된 포탈영상 (Portal image enhanced with sampling/interpolation methods and associative memory)

치들이 결정된 후에, 해당 데이터로 포탈 영상의 recall이 수행되고 개선된 결과가 그림 9c이다. 포탈 영상이 복원되고 있음을 알 수 있다. 그러나 이 방법은 인공신경망의 학습시간이 길어져 처리시간이 많이 걸렸다. 처리시간을 단축하기 위하여 영상을 샘플링하고 결과를 interpolation으로 처리하였다. 즉 포탈 영상을 3 x 3마스크로서 샘플링하여 영상의 크기를 1/9로 축소한 후 이를 연관기억장치로서 영상을 처리한 후에 결과 영상을 bilinear interpolation으로서 원래의 영상으로 복원한 것이 그림 9d이다. 그림 9a-9c의 PSNR은 18.1410, 그림 9a-9d의 PSNR은 17.9777, 그림 9c-9d의 PSNR은 30.8037로서 그림 9d를 그림 9c와 비교할 때 영상의 질에서도 차이가 없음을 알 수 있다. 즉 영상의 질을 훼손하지 않고서 입력층의 뉴런 수를 1/9로 줄일 수 있어 인공신경망의 학습속도를 향상시킬 수 있었다. 또한 그림 9a-9b의 PSNR 12.1781로서 그림 9c, 9d 영상이 그림 9b보다 영상개선이 작아졌음을 알 수 있다.

위와 동일한 방법으로 처리한 영상의 다른 예가 그림 10의 복부영상이다. 그림 10a는 SI영상이고 이를 퍼지 영상 개선한

것이 그림 10b이다. 동일한 부위에서 얻어진 포탈영상이 그림 10c이고 이를 퍼지 영상 처리한 것이 그림 10d이다. 그림 10d를 퍼지 기법으로 처리한 후 인공신경망을 이용한 연관기억장치를 사용하여 영상을 개선한 결과가 그림 10e이며, 그림 10f는 그림 10d의 영상을 1/9로 축소하여 연관 기억장치로서 처리한 후, 원래의 크기로 복원시킨 것이다. 그림 10b-10e의 PSNR은 15.3918, 10b-10f의 PSNR은 15.1691, 10e-10f의 PSNR은 32.1688로서 그림 10f를 그림 10e와 비교할 때 영상의 질이 비슷함을 알 수 있다. 또한 그림 10b-10d의 PSNR 9.3991로서 그림 10e, 10f 영상이 그림 10d보다 영상개선이 우수함을 알 수 있어 제안된 방법이 정량적으로 영상개선 분야에 적용됨을 알 수 있다.

그러나 본 연구에서 사용한 알고리즘이 입력 영상에 따라 퍼지 영역을 계산하고, 신경망을 학습시켜야 하므로, 영상 처리 시간이 길어지는 문제점은 앞으로 개선되어야 한다. 시뮬레이터 영상으로 부터 포탈 영상을 복원하기 위한 associative memory의 성능은 hidden 뉴런 수에 관계된다고 알려져 있다. 리콜에서 hidden 뉴런 수가 많을 수록, SI의 정보가 덜 관련되며 PI의 잡음도 덜 나타나므로 적당한 수의 hidden 뉴런 수를 선택 사용되어야 한다. 본 실험에서는 입력 뉴런수의 1/20을 사용하였다.

결 론

영상처리에서 뉴로 퍼지 방법은 기존의 방법들만큼 널리 연구되고 있지는 않지만 멤버쉽 함수의 위치, 형태, 수, 멤버쉽 변형(modification)에 대한 퍼지 방법과 집합 연산자 등을 진분가가 실제 요구에 맞게 선택할 수 있어, 실제 활용에서 좀더 자유롭다. 그러나 모든 영상처리를 뉴로 퍼지 기법으로 하는 것은 가능하지도 않으며 의미도 없다. 퍼지 영상처리는 컴퓨터 영상처리의 보조적인 역할을 주로 하지만, 그 역할은 많은 응용들 중에서 결정적일 수 있다. 기존의 방법에 비하여 뉴로 퍼지 방법은 새로운 개선 알고리즘을 개발하는데, 처리 단




그림 10. 시뮬레이터 영상과 포탈영상의 관심영역 처리 (복부)

Fig. 10. ROI of portal and simulator image (abdomen)

- a 시뮬레이터 영상 (Simulator image)
- b. 퍼지기법으로 개선된 시뮬레이터 영상 (Fuzzy enhanced Simulator image)
- c 포탈영상(Portal image)
- d 퍼지기법으로 개선된 포탈영상(Fuzzy enhanced Portal image)
- e. 연관기억장치로 개선된 포탈영상(Portal image enhanced with associative memory)
- f 샘플링방법과 연관기억장치로 개선된 포탈영상 (Portal image enhanced with sampling/interpolation methods and associative memory)

개에서 의사의 전문적인 지식을 응용할 수 있는 수학적인 수단을 제공한다.

포털 영상은 그에 상응하는 시뮬레이터 영상을 참조 영상으로 하여 방사선치료 계획을 수행하는데 사용되고 있다. 이것은 구조적으로 대단히 불량한 포털 영상의 개선과 잃어버린 영상 정보의 복원에 시뮬레이터 영상 자체에서의 영상정보를 이용할 수 있다는 가능성을 보여주고 있는 것이다. 본 연구에서는 최대 퍼지 엔트로피를 평가함수로 이용한 유전자 알고리즘을 사용하여 포털 영상에서 퍼지 영역을 자동적으로 결정하고, 그것을 멤버쉽 함수에 적용한 퍼지영상 개선 기법으로서 포털 영상과 시뮬레이터 영상을 개선한 후, 잡음이 중첩된 시뮬레이터 영상들로서 연관기억장치를 학습시키고 여기에 퍼지 방법으로 개선시킨 포털 영상을 입력하여 기존의 영상기법으로 처리된 영상보다 좋은 포털 영상을 얻을 수 있었다. 이때 포털 영상을 샘플링하여 영상의 크기를 1/9로 축소한 후 이를 연관기억장치로서 영상을 처리한 후에 결과 영상을 bilinear interpolation으로서 원래의 영상으로 복원하였다.

본 연구의 목적은 포털 영상을 개선함으로써 의사들에 의한 시뮬레이터 영상과의 시각적 비교 분석에 도움을 주려함이다. 영상을 퍼지화하기 위한 멤버쉽 함수의 결정, 인공신경망의 학습 데이터 생성과 학습시간 단축을 위한 방법 등은 포털 영상 개선에 좋은 결과를 보였다. 그러나 포털 영상의 대조도 개선은 가끔 만족스럽지 못하다. 이것은 개선할 수 있는 영상정보가 거의 없는 정도의 매우 나쁜 특성을 갖는 포털 영상의 물리적 특성 때문이라고 생각된다. 퍼지 알고리즘은 영상의 성능을 최적화하는 데 멤버쉽 함수의 파라메타들의 변경 같은 많은 기능성들을 제공하고 있어, 미래에 퍼지 영상개선은 의학 영상의 많은 분야에 적용할 수 있다고 기대할 수 있다.

본 연구에서 얻어진 결과는 방사선 치료확인장치의 영상처리부에서 사용되는 알고리즘 개발을 위한 활용될 수 있고 또한 영상장치들간의 영상 fusion 알고리즘 개발에 연구 결과를 응용할 수 있으며 최근 암치료에 많이 이용되고 있는 임체 조형치료장치(conformal therapy)에도 이용할 수 있다.

참 고 문 헌

- 1 R Wasserman and R. Acharya. "Multimodality tumor delineation via fuzzy fusion and deformable modeling", SPIE Medical Imaging 95, Image processing proceeding, vol. 2344, pp. 1333-1441, 1995
- 2 G.Krell, H.R Tizhoosh, T. Lilienblum, C.J. Moore and B Michaaelis, "Enhancement and Associative restoration of electronic portal image in radiotherapy", Int'l J of Medical Infomatics, 49, pp 157-171,1997
- 3 J.C.Russ, The Image Proccsing Handbook, CRC Press, 1999
- 4 K.W. Leszczynski, S. Shalev and N.S.Cosby, "The enhancement of radiotherapy verification images by an automated edge detection technuque", Med. Phys 19(3), pp. 611-622, 1992
- 5 J.M.Keller, "Fuzzy set theory in computer vision : A prospectus", Fuzzy sets and system, 90, pp. 177-182, 1997
- 6 H.D.Cheng, Y.H.Chen and Y.Sun, "Novel fuzzy entropy approach to image enhancement and thresholding", Signal Processing, 75, pp.277-301, 1999
- 7 S.K.Pal, R.A.King "Image enhancement using smoothing with fuzzy sets", IEEE Trans on System Man and Cybernetics, SMC-11, no. 7 494-501, 1981
- 8 H.R.Tizhoosh, "Fuzzy Image Processing : Potentials and State of the Art", Int'l Conf. on Soft Computing, Izuka, Japan, Vol. 1, pp. 321-324, 1998
- 9 H.D.Cheng, J.R.Chen, R.I.Freimanis and X.H.Juang, "A novel fuzzy approach to microcal-cification detection", Information Science, 111, pp 189-205, 1998
- 10 R.C.Gonzalez, R.E.Woods, Digital Image processing, Addison-Wesley, 1993
- 11 Z. Michalewicz, Genetic Algorithm + Data Structure= Evolution Programs, 3rd ed Springer, 1999
- 12 T.J.Ross, Fuzzy Logic with Engineering Applications, McGraw Hill, 1997
- 13 H.R.Tizhoosh, M.Fochem. "Fuzzy Histogram Hyperbolization for Image Enhancement", Proc of EUFIT '95, Aachen, Germany, vol. 3, pp. 1695-1698, 1995
- 14 T.Lilienblum, P.Albrecht and B. Michaelis, "Neural Networks for Optical 3-D Measurement of Shapes of Industrial Objects", 8th Int'l Conference on Neural Network and their Application, pp.1-8, Marseilles, Dec. 1995
- 15 T.Lilienblum, P.Albrecht and B. Michaelis, "Improvement of 3-D data by Neural Networks", Int'l Workshop on Neural Network, pp. 203-211, Venice, Aug. 1996
- 16 Soojin Huh, "Automatic Image Matching of Portal and Simulator Images Using Fourier Descriptors", J. of KOSOB. vol. 18, No. 1, pp.9-16, 1997