

論文97-34S-3-7

# Mesh 그룹화 방법을 이용한 EIT 정적 영상 복원의 고속화 (Fast EIT Static Image Reconstruction using the Recursive Mesh Grouping Method)

趙慶鎬\*, 禹應濟\*\*, 高誠澤\*\*\*

(Kyung Ho Cho, Eung Je Woo, and Sung Tack Ko)

## 요 약

기존의 전기 임피던스 단층촬영(EIT) 기술의 실용화에 있어 가장 큰 어려움은 고해상도의 정적 영상을 얻기 위해서는 컴퓨터 처리시간이 기하급수적으로 증가함에도 불구하고 해의 수렴성은 극도로 악화되어 수렴된 복원 영상을 얻기가 매우 어렵다는 데 있다. 본 연구에서는 이러한 문제를 해결하기 위한 방안의 하나로 Fuzzy-GA 에 기초한 mesh 요소 분류 방법을 개발하여 주기적으로 mesh를 구성하는 요소들을 분류, 그룹화하여 처리되어야 할 요소의 개수를 감소시키는 방법을 개발하였다. 이를 이용하여 기존의 대표적인 EIT 정적 영상복원 방법인 개선된 Newton-Raphson 법을 보완하여 수행한 전산실험 결과, 제안된 요소 그룹화 방법은 EIT 정적 영상복원 시간을 단축하고 해의 수렴성을 크게 향상시켜서 개인용 컴퓨터 상에서도 적절한 수행시간으로 EIT 정적 영상복원이 가능함을 확인하였다.

## Abstract

For the practical applications of the EIT technology, it is essential to reconstruct static images with a higher spatial resolution in a reasonable amount of processing time. Using the conventional EIT static image reconstruction algorithms, however, the processing time increases exponentially with poor convergence characteristics as we try to get a higher spatial resolution. In order to overcome this problem, we developed a recursive mesh grouping method based on the Fuzzy-GA like algorithm. Computational simulation using the well-known Improved Newton-Raphson Method with the proposed recursive mesh grouping algorithm shows a promising result that we can significantly reduce the processing time in the reconstruction of EIT static images of a higher spatial resolution.

## I. 서 론

전기 임피던스 단층촬영기(EIT, electrical impe-

dance tomography)는 인체 표면에 부착한 여러 개의 전극을 사용하여, 수십 kHz의 전류를 주입하고 전압을 측정하여, 인체 단면의 임피던스 분포를 영상화 하는 의료 영상장치이다<sup>[1]</sup>. 최근에는 전류를 주입하는 주입 전류법 대신에 자장을 발생시켜 인체 내부에 전류가 유기되도록 하고, 이에 의해 발생하는 전압을 인체 표면에서 측정하는 유도전류법이 시도되고 있다<sup>[2]</sup>.

EIT에서는 임피던스 분포의 생리현상에 의한 시간적 변화만을 영상화하는 동적 영상법(dynamic imaging) 과 한 순간의 임피던스 분포를 그대로 영상화하는 정적 영상법(static imaging)이 있다. 동적 영상법에 의한 EIT는 영국 Sheffield 대학의 Brown 박사 팀에

\* 正會員, 濟州大學校 에너지工學科

(Dept. of Nuclear and Energy Eng. Cheju National Univ.)

\*\* 正會員, 建國大學校 醫學工學科

(Dept. of Biomedical Eng. Konkuk Univ.)

\*\*\* 正會員, 濟州大學校 電子工學科

(Dept. of Electronics Eng. Cheju National Univ.)

接受日字:1996年10月16日, 수정완료일:1997年2月24日

의해 개발된 Applied Potential Tomography (APT) 시스템이 대표적이다<sup>[3]</sup>. 한편, 정적 영상법에 의한 EIT는 단층 영상의 복원(image reconstruction)이 비선형 문제의 해를 요구하므로 아직 초보적인 연구 단계에 있으나, 생체 조직의 임피던스 값 자체를 복원하기 위해서는 정적 영상법에 의한 EIT의 개발이 긴요하다.

개선된 Newton-Raphson 법(Improved Newton-Raphson Method)과 2차원 FEM 프로그램을 사용하여 대상의 전체 크기의 5% 정도의 크기를 갖는 조직의 저항률을 알아내기 위하여 소요되는 정적영상 복원 시간은 개인용 컴퓨터로는 수 시간 이상이 소요된다<sup>[4]</sup>. 영상 복원 시간을 수분 이내로 단축하기 위해서 supercomputer를 이용한 분산처리 방식이 연구되기도 하였으나<sup>[5]</sup>, EIT가 가지는 장점을 살리기 위해서는 개인용 컴퓨터만으로 영상 복원이 가능한 것이 바람직하여 영상 복원 시간의 단축과 알고리즘의 안정성 확보가 가장 중요한 문제로 대두되고 있다.

인체의 각 기관들은 서로 다른 모양을 가지나 특정 기관은 거의 같은 값의 저항률을 가진다는 점에 근거하여 유한요소 모델을 실제의 인체 장기 형태와 유사하게 설정하고 각각의 장기를 묘사하는 요소들을 한 그룹으로 묶어서 동일한 저항률을 가지도록 하는 mesh 그룹화 방법이 Woo 등<sup>[4]</sup>, Cheney 등<sup>[7]</sup>, Glidewell과 Ng<sup>[8]</sup>, Paulsen 등<sup>[9]</sup>에 의해 연구되었고, 적절한 그룹화 방법은 변수의 개수를 줄일 수 있어서 계산량의 감소와 영상복원 알고리즘의 안정성 향상에 큰 기여를 할 수 있다는 것을 보였다. 그러나, 지금까지 제안된 알고리즘에서는 사용자에게 미리 결정된 그룹화 방법이 사용되었다. 이러한 방법들은 EIT에서 구하고자 하는 대상의 내부 구조에 왜곡을 초래할 수 있다. 따라서 영상복원을 수행하는 도중에 내부 구조에 대한 정보를 수집하고 이를 활용하여 체계적으로 그룹화를 수행하는 알고리즘이 필요하다.

본 논문에서는 퍼지-유전알고리즘(Fuzzy-Genetic Algorithm, Fuzzy-GA)과 Newton-Raphson 법을 혼용한 새로운 정적 임피던스 영상복원 알고리즘을 제안한다. 이 새로운 영상 복원 알고리즘에서는, EIT 영상복원 과정 중 mesh 모델을 적절하게 탄력적으로 변화 운용하는 적응적 요소 그룹화 방법(adaptive mesh grouping method)을 사용함으로써, 해상도의 향상과 영상복원의 고속화라는 상반된 두 목표를 동시에 추구

하였다. 이를 위하여 다음의 제 2 절에서는 본 연구에서 수행하는 EIT 정적 영상 복원의 이론적 배경이 되는 개선된 Newton-Raphson 법을 소개하고, 제 3 절에서 본 연구에서 제안하고 있는 Fuzzy-GA 에 기초한 요소 그룹화 방법을 기술한다. 제 4 절 및 제 5 절에서는 제안된 방법의 적용 예와 결론이 다루어 진다.

## II. EIT 정적 영상 복원의 이론적 배경

경계 전압으로부터 내부 저항률 분포를 구하는 정적 영상의 복원 문제(inverse problem)에 있어서는, 주입 전류와 모델의 내부 저항률 분포가 주어졌을 때 경계에서의 전압을 계산할 수 있는 컴퓨터 모델(forward solver)이 필요하다. 본 논문에서는 이를 위해서 Woo 등<sup>[10]</sup>에 의해 개발된 2차원 FEM 프로그램을 사용하였다. 이 프로그램은 개선된 Newton-Raphson 알고리즘<sup>[4]</sup>에 의거하여 다음과 같은 방법으로 영상 복원 작업을 수행한다.

현재 모델의 저항률 분포를  $\rho$ 로 가정할 때, 유한요소 모델에서 FEM의 해로 계산된 경계전압  $f(\rho)$ 와 측정된 경계전압  $\mathbf{v} = [v_1 \ v_2 \ \dots \ v_M]^T$  사이의 차(residual 또는 difference vector)를  $\mathbf{r} = [r_1 \ r_2 \ \dots \ r_M]^T$ 라고 하면, 개선된 Newton-Raphson 법에서의 영상복원 작업은 다음의 식 (1)의 목적함수가 최소화되는 모델의 저항률 분포  $\mathbf{r}$ 를 구하는 것이다<sup>[11]</sup> [4].

$$\Phi(\rho) = \frac{1}{p} \sum_{i=1}^M w_i r_i^p = \frac{1}{p} \sum_{i=1}^M w_i \{f_i(\rho) - v_i\}^p \quad (1)$$

이때,

$$M = E * P$$

$$E = \text{no. of electrodes}$$

$$P = \text{no. of injection current patterns}$$

본 논문에서는 차수  $p$ 는 2, 가중치  $w_i$ 는 1로 한다. 위의 목적함수의 변화를  $\mathbf{g}$ 와 Jacobian 행렬  $\mathbf{J}$ 는 다음의 식 (2)와 (3)으로 표현할 수 있고 그 계산 방법은 Webster<sup>[11]</sup>과 Yorkey 등<sup>[11]</sup>에서 기술된 바와 동일하다.

$$\mathbf{g} \nabla_{\rho} \Phi = \mathbf{J}^T \mathbf{W} \mathbf{r} = \tilde{\mathbf{J}}^T \tilde{\mathbf{r}} \quad (2)$$

$$\mathbf{J}_{mn} = [\nabla_n r_m]$$

$$\mathbf{W} = \text{diag} [w_1 w_2 \dots w_M]$$

$$\mathbf{r} = [r_1 \ r_2 \ \dots \ r_m]^T$$

$$\tilde{\mathbf{J}} = \mathbf{J} \mathbf{W}^{1/2}$$

$$\tilde{\mathbf{r}} = \mathbf{W}^{1/2} \mathbf{r} \quad (3)$$

Hessian 행렬  $H$  및 그 근사치  $\hat{H}$ 의 계산은 다음의 식 (4)와 (5)로 표현된다.

$$H = \nabla_{\rho}(\nabla_{\rho}\Phi) \approx J^T W J \quad (4)$$

$$\hat{H} = \hat{J}^T \hat{J} \quad (5)$$

각 iteration에서 저항률  $\rho^{k+1}$ 과 수정량  $\Delta\rho^k$ 은 다음의 식 (6)과 (7) 또는 식 (8)의 해로서 구해진다. 이때 상수  $\lambda, \alpha$  및  $\nu$ 들은 행렬  $H$ 의 ill-conditioning 문제를 해결하기 위하여 도입된 것이다<sup>[41][42]</sup>.

$$\rho^{k+1} = \rho^k + \Delta\rho^k \quad (6)$$

$$(\hat{H} + \lambda I)\Delta\rho^k = -g = -\hat{J}^T \hat{r} \quad (7)$$

또는

$$\begin{bmatrix} \alpha I & \hat{J} \\ \hat{J}^T & -\nu S \end{bmatrix} \begin{bmatrix} \Delta\rho^k \\ \hat{r} \end{bmatrix} = \begin{bmatrix} -\hat{r} \\ 0 \end{bmatrix} \quad (8)$$

이때, 이론적으로는 동일한 기관에 속하는 요소들은 모두 같은 값의 저항률로 복원되어야 하나, 어느 요소들이 동일한 기관에 속하는 지를 판단할 수 없으므로 미지의 저항률 벡터  $\rho$ 의 차수  $R = \dim(\rho)$ 는 일반적으로 최적의 값보다 큰 상태이다. 또한, 물체 중앙의 작은 부위의 저항률 변화는 경계전압의 변화에 미치는 영향이 매우 작기 때문에 대상의 중심 부위에 있는 작은 요소는 그 저항률의 값을 정확히 복원하기가 매우 어렵다. 그러나, 특정 기관을 구성하는 요소들이 적절히 그룹화되면, 그 유효한 크기가 커지므로 이러한 민감도의 문제가 완화되어서, Hessian 행렬의 ill-conditioning이 완화되며, 알고리즘의 안정성이 향상되고 정확도가 증진된다. 또한,  $R$ 의 감소에 따라 알고리즘의 고속화가 가능해진다.

### III. Fuzzy-GA 에 기초한 Mesh 그룹화 방법

#### 1. Mesh 그룹화의 기본 사상

Newton 계열의 EIT 정적 영상 복원 방법에서의 가장 큰 문제점은 처리될 요소 수 (혹은 미지 저항률 벡터  $\rho$ 의 차수  $R$ )의 증가와 더불어 영상복원 알고리즘의 계산량은 기하급수적으로 증가<sup>[41]</sup>함에도 불구하고 해의 수렴성은 급격히 감소하는 데 있다. 그러나, 일반적으로 Newton 반복 연산이 발산하지 않고 어느 정도 진행된 경우 각 반복 연산 단계에서의 저항률 분포는

실제 해와는 크게 차이가 있다라도 이들 저항률 분포는 실제 저항률 분포에 대한 여러 가지 주요한 정보를 제공하고 있다. 예컨대, 물체의 개략적인 외곽 형상과 위치, 어느 요소들이 확실한 배경 요소 (background elements 또는 base elements) 인가 하는 정보는 Newton 반복 연산의 초기 몇 단계에서 충분히 파악이 가능하다. 본 연구에서는 이점에 착안하여 Newton 반복 연산의 수렴성을 크게 향상시키고 실행 시간을 획기적으로 단축시킬 수 있는 방법을 개발하였다.

즉, Newton 반복 연산 시 저항률의 크기 뿐만 아니라 그들의 수렴 성향도 동일 하거나 비슷한 요소들을 한데 묶어 위상학적으로 마치 한 요소처럼 다룸으로써 (동일 그룹으로 묶여진 요소들은 모두 동일한 저항률과 동일한 수렴 성향을 갖도록 함으로써) Newton법에서의 Jacobian 및 Hessian 등의 계산 시간을 대폭 단축할 수 있도록 하였다. 다시 말해서, 그룹화를 통한 미지 저항률 개수의 감소는 단순한 연산 시간의 단축 뿐만 아니라, Newton의 수렴성이 전체적으로 크게 향상되는 부대 효과를 가져온다. 수렴성의 개선은 그룹화 정보를 보다 나은 방향으로 다시 개선할 수 있게 하고, 이렇게 개선된 그룹화 정보는 차후 수행될 Newton 연산의 미지수 개수를 더욱 줄일 수 있게 한다. 이처럼 순환적으로 Newton 연산  $\rightarrow$  그룹화 정보 개선  $\rightarrow$  Newton 연산  $\rightarrow$  그룹화 정보 개선  $\rightarrow$  ...의 과정을 반복하여 그룹화를 진전시키면 시킬수록 미지수 개수가 줄어들어 Newton 반복 연산시간은 단축되고 해의 수렴성은 향상되어 궁극적으로는 수렴된 해에 도달할 가능성을 크게 한다.

#### 2. Mesh 요소의 세가지 그룹

본 연구에서는 mesh 모델의 모든 요소들을 배경 요소 그룹(BaseEL), 물체 요소 그룹(ObjectEL) 및 미확정 요소 그룹(AdjustEL)의 세가지 그룹으로 분류한다. 배경 혹은 물체 요소 그룹이란 궁극적으로 배경 혹은 물체 요소가 될 것으로 평가되는 요소들의 모임을 의미한다. 이러한 평가가 불분명한 요소들의 모임을 미확정 요소 그룹이라 한다. Newton 반복 연산 중에는 배경 요소 및 물체 요소 그룹 내의 모든 요소들은 각기 해당 그룹 내의 다른 요소들과 동일한 저항률을 갖는 것으로 가정한다. 반면에, 미확정 요소 그룹 내의 각 요소들은 서로 다른 저항률을 가질 수 있다. 이들 그룹에 속한 요소 수를 각각  $n_{BaseEL}$ ,

nObjectEL 및 nAdjustEL 이라 할 때, Newton 반복 연산에서의 미지수 개수는 nAdjustEL + 2이다. 이는 그룹화가 없는 종래의 Newton 법에 비하면 nBaseEL + nObjectEL - 2 만큼의 미지수가 감소된 것을 의미한다. 이들 요소 그룹들의 그룹화 위상 정보 (grouping topology)는 Newton 반복 연산 중에는 변하지 않지만, Newton 반복 연산이 종료되면 다음 절에서 기술될 요소 분류법에 따라 재 수정될 수 있다.

3. 배경 요소 및 물체 요소에 대한 퍼지집합

물체의 형상, 위치 및 개략적인 저항률의 분포 등에 대한 사전 정보가 전혀 없는 상태에서 출발하여 mesh 모델의 각 요소들이 어느 그룹에 속할 것인가를 과연 어떻게 분류할 것인가 하는 문제와, 그렇게 분류된 각 그룹의 대표적인 저항률은 어떻게 결정할 것인가 하는 문제가 대두된다. 이러한 문제의 해결을 위해 본 연구에서는 일정 횟수의 Newton 반복 연산 결과 얻어진 각 요소의 저항률 분포로부터 요소 분류 정보 및 각 그룹의 대표 저항률 값을 다음에 기술되는 퍼지 집합 [13] [14] 및 유전 알고리즘 [15] [16] 을 이용하여 결정한다.

퍼지집합  $\tilde{A}_1 =$  “BaseEL 그룹에 가까운 저항률”

퍼지집합  $B_1 =$  “BaseEL 그룹에 가까운 저항률 표준편차”

퍼지집합  $\tilde{A}_2 =$  “ObjectEL 그룹에 가까운 저항률”

퍼지집합  $\tilde{B}_2 =$  “ObjectEL 그룹에 가까운 저항률 표준편차”

본 연구에서는 그림 1로 표현된 간단한 형태의 소속함수로 이들 퍼지집합을 다음과 같이 정의한다.


$$\tilde{A}_1 = \{(\rho, \mu_{\tilde{A}_1}) | \rho \in R\} \tag{9}$$

$$B_1 = \{(\sigma, \mu_{B_1}) | \sigma \in R\} \tag{10}$$


$$\tilde{A}_2 = \{(\rho, \mu_{\tilde{A}_2}) | \rho \in R\} \tag{11}$$

$$\tilde{B}_2 = \{(\sigma, \mu_{\tilde{B}_2}) | \sigma \in R\} \tag{12}$$

이때 소속함수  $\mu_{\tilde{A}_1}(\rho), \mu_{B_1}(\sigma), \mu_{\tilde{A}_2}(\rho)$  및  $\mu_{\tilde{B}_2}(\sigma)$ 에 시 필요로 하는  $\rho_{base}, \rho_{obj}, \sigma_{base}$  및  $\sigma_{obj}$ 의 결정 방법에 대해서는 다음 절에서 상세히 기술된다.



(a)



(b)

그림 1. 소속함수  $\mu_{\tilde{A}_1}(\rho)$  및  $\mu_{B_1}(\sigma)$

Fig. 1. Membership function  $\mu_{\tilde{A}_1}(\rho)$  and  $\mu_{B_1}(\sigma)$ .

퍼지집합  $\tilde{A}_1, \tilde{B}_1, \tilde{A}_2$  및  $\tilde{B}_2$ 가 위와 같이 결정 되면 “BaseEL 그룹에 속할 요소” 및 “ObjectEL 그룹에 속할 요소”에 대한 퍼지집합  $\tilde{G}_1$  및  $\tilde{G}_2$ 를 다음과 같은 퍼지집합의 연산으로 결정한다. 즉,

퍼지집합  $\tilde{G}_1 =$  “BaseEL 그룹에 속할 요소”

퍼지집합  $\tilde{G}_2 =$  “ObjectEL 그룹에 속할 요소”

라 하면,

$$\tilde{G}_1 = \tilde{A}_1 \cap \tilde{B}_1 = \{(i, \mu_{\tilde{G}_1}(i)) | i \in I\} \tag{13}$$

$$\tilde{G}_2 = \tilde{A}_2 \cap \tilde{B}_2 = \{(i, \mu_{\tilde{G}_2}(i)) | i \in I\} \tag{14}$$

퍼지집합  $\tilde{G}_1, \tilde{G}_2$ 의 소속함수  $\mu_{\tilde{G}_1}(i), \mu_{\tilde{G}_2}(i)$ 는 위에서 정의된 소속함수  $\mu_{\tilde{A}_1}(\rho), \mu_{B_1}(\sigma), \mu_{\tilde{A}_2}(\rho)$  및  $\mu_{\tilde{B}_2}(\sigma)$ 을 이용하여 다음과 같이 결정된다.

$$\mu_{\tilde{G}_1}(i) = \min(\mu_{\tilde{A}_1}(\rho_i), \mu_{B_1}(\sigma_i)), \rho_i, \sigma_i \in R, i \in I \tag{15}$$

$$\mu_{\tilde{G}_2}(i) = \min(\mu_{\tilde{A}_2}(\rho_i), \mu_{\tilde{B}_2}(\sigma_i)), \rho_i, \sigma_i \in R, i \in I \tag{16}$$

이상으로부터 배경 요소 그룹 및 물체 요소 그룹에 해당하는 보통 집합  $G_{base}$ 와  $G_{obj}$ 는 각각 퍼지집합  $G_1$  및  $G_2$ 의  $\alpha_1$  cut 및  $\alpha_2$ -cut으로 다음과 같이 구성된다.

$$G_{base} = \alpha_1\text{-cut of } \tilde{G}_1 = \{i \mid \mu_{G_1}(i) \geq \alpha_1, i \in I\} \quad (17)$$

$$G_{base} = \alpha_2\text{-cut of } \tilde{G}_2 = \{i \mid \mu_{G_2}(i) \geq \alpha_2, i \in I\} \quad (18)$$

4. Genetic Algorithm을 이용한  $\hat{\rho}_{base}$ ,  $\hat{\rho}_{obj}$ ,  $\hat{\sigma}_{base}$  및  $\hat{\sigma}_{obj}$ 의 결정

Newton 반복 연산이 발산하지 않고 어느 정도 수렴이 진전된 경우, Newton 연산의 각 미지수(각 요소의 저항률)의 수렴 성향은 문제의 성격에 따라 다소 다를 수 있으나, 크게 나누어 다음과 같은 두 가지의 수렴 성향을 보인다. 즉, 어느 미지수들은 비교적 쉽게 참값에 수렴되거나 거의 수렴되어 가는 상태인 반면에, 나머지 다른 미지수들에서는 참값과는 매우 동떨어진 값으로 수렴, 발산 혹은 진동하는 성향을 보인다. 따라서, 비록 수렴되지는 않은 Newton 연산 결과이더라도 이로부터 크기 순으로 재 정렬하여 얻은 저항률 분포를  $S_j$ 라 하면,  $S_j$ 의 일반적인 분포 곡선은 대략 그림 2와 비슷한 형상이 된다. 여기서, 영역 II 및 IV에서는 여러 요소가 비교적 고르게 일정한 저항률을 갖도록 수렴되었음을 보인다. 따라서, 영역 II 및 IV에 속하는 저항률을 갖는 요소들은 각각 BaseEL 그룹 및 ObjectEL 그룹에 속할 가능성이 크다고 가정한다. 반면에, 영역 I, III, 및 V은 천이 영역(transient region)으로 이에 속하는 저항률을 갖는 요소들은 AdjustEL 그룹에 속할 가능성이 크다고 가정한다.




그림 2. 크기 순으로 정렬된 저항률의 일반적인 분포 곡선과 5 영역  
Fig. 2. A typical distribution curve of the sorted resistivities and 5 regions.

여기서, 전체 저항률 분포곡선에서 과연 어떻게 위의 다섯 영역을 적절하게 구분해 낼 것인가 하는 문제에 다다르게 된다. 그러나, 크기 순으로 재 정렬된 저항률  $S_j$ 의 분포가 항상 그림 2와 같은 이상형이 되지는 않기 때문에 각 영역의 대표적인 저항률의 값  $\rho_i, i=1,2, \dots, 5$  및 각 영역의 경계  $k_i, i=1, 2, \dots, 4$ 의 초기치 부여가 쉽지 않다. 따라서, 최소자승오차법 등과 같은 여타의 curve fitting 방법으로는 적절한 결과를 기대하기 어렵다. 반면에, 최근 여러 분야에서 좋은 효과를 보이고 있는 유전 알고리즘(Genetic Algorithm, GA) [14]은 비교적 구현이 용이하고 초기치에 크게 의존하지 않으며, 쉽게 적정 수준의 해에 수렴할 수 있기 때문에, 본 연구에서는 위의 다섯 영역 구분을 위하여 GA를 이용하였다. 다음은 위에서 제기된 문제를 GA를 이용하여 정식화한 것이다.

$$\text{Find } X = \{ \rho_1, \rho_2, \rho_3, \rho_4, \rho_5, k_1, k_2, k_3, k_4 \} \quad (19)$$

$$\text{to maximize fitness } (X) = 1/D \quad (20)$$

$$\text{subject to } D = \sum_{i=1}^5 \sum_{j=k_{i-1}}^{k_i} (s_j - \rho_i)^2, k_0=1, k_5=n \quad (21)$$

여기서

$X$  : 개체 혹은 후보 해

$\rho_i, i=1, 2, \dots, 5$  : 각 영역의 저항률의 대표값

$k_i, i=1, 2, \dots, 4$  : 각 영역의 경계

$n$  : 전체 요소 수

niter : Newton 법에서의 반복 횟수

$\rho_j$  :  $j$  번째의 Newton 연산에서 요소  $i$  의 저항률

$\hat{\rho}_i = \frac{1}{\text{niter}} \sum_{j=1}^{\text{niter}} \rho_j^i$  : 전체 Newton 연산 결과 요소  $i$  의 평균 저항률

$s_j (s_j \leq s_{j+1}, j=1, 2, \dots, n)$  :  $\hat{\rho}_i$ 의 크기 순 정렬이다.

위와 같은 GA 탐색 결과 최적의 영역 분류 방법이 얻어지면,  $\hat{\rho}_{base}$ ,  $\hat{\rho}_{obj}$ ,  $\hat{\sigma}_{base}$  및  $\hat{\sigma}_{obj}$ 는 해당 영역에 속하는 저항률들의 평균 및 표준편차로 계산된다.

5. 그룹 위상구조의 수정과 저항률의 초기화

위의 Fuzzy GA 분류 방법에 의거하여 배경 요소 그룹  $G_{base}$ 와 물체 요소 그룹  $G_{obj}$ 이 결정된 후에는 mesh 모델의 그룹 위상 구조를 수정하고 Newton 법의 재 실행을 위하여 각 요소의 저항률을 다음과 같이 초기화 해야 한다:

1) 그룹  $G_{base}$  중의 임의의 요소를 'parent' 요소로 선

정하고, 나머지 요소들을 'child'로 하여 'parent' 요소의 하위 그룹으로 이들의 위상구조를 변경한다.

- 2) 같은 방법으로, 그룹  $G_{obj}$  중의 임의 요소를 'parent' 요소로 선정하고, 나머지 요소들을 'child'로 하여 'parent' 요소의 하위 그룹으로 이들의 위상구조를 변경한다.
- 3) 배경 요소 및 물체 요소의 'parent'에 대하여 그 저항률들을 각각  $\bar{\rho}_{base}$  및  $\bar{\rho}_{obj}$ 로 초기화 한다.
- 4) 모든 배경 요소 및 물체 요소의 저항률들은 항상 그들의 'parent' 요소의 저항률과 같도록 한다.
- 5)  $G_{base}$  혹은  $G_{obj}$ 의 어느 그룹에도 속하지 않는 요소(AdjustEL) 들에 대해서는 그들의 저항률을 기 수행된 Newton 반복 연산의 평균값  $\bar{\rho}_i$ 로 초기화 한다. 이때 이들 요소들의 저항률은 서로 같을 필요가 없다.

#### 6. 기타 고려 사항

##### • 퍼지 집합의 저장과 재사용

각 요소에 대한 퍼지 분류 결과를 저장하였다가 다음 번의 퍼지 분류 결과와 함께  $\alpha$ -cut 을 완화시켜서 고려한다. 이 방법은 너무 tight 한  $\alpha$ -cut을 사용한 퍼지 분류에서 약간의 확률 차이로 그룹화에서 제외되었던 일부 요소를 구제하는 데 목적이 있다.

##### • 고립 요소의 제거

그룹화에 심각한 오류가 있을 경우에는 Newton 반복 연산은 발산한다. 여기서, 그룹화의 심각한 오류라 함은 실재는 BaseEL 인 요소가 ObjectEL 로 분류되었거나, 이와는 반대로, 실재는 ObjectEL 인 요소가 BaseEL로 분류된 경우를 일컫는다. 이러한 오류는 경험적으로 볼 때 주위의 다른 요소들과는 다르게 분류된 고립된 요소(예컨대, BaseEL로 분류된 어느 요소를 둘러싸고 있는 모든 요소들이 ObjectEL 로 분류되거나, 이와 반대의 경우) 들에서 발생하는 것으로 파악되었다. 따라서, 본 연구에서는 퍼지 분류가 종료된 직후 이러한 고립 요소들을 찾아서 이들의 분류 코드를 모두 AdjustEL 로 바꾸어 사전에 이러한 문제가 가능한 발생하지 않도록 하였다.

참고로, 본 연구에서는: 기하학적 정보를 가능한 한 적게 사용하는 알고리즘 개발에 주력하여 시스템의 측정 대상물의 형상에 대한 의존도를 원천적으로 봉쇄하

고자 노력하였다. 이러한 관점에서 상기의 고립 요소의 탐색이 본 요소 분류 알고리즘에서 기하학적 정보를 유일하게 이용하는 부분이다.

##### • 영상 복원 작업의 진동 현상 해소

위의 고립 요소의 제거 조치에도 불구하고 잘못 분류된 요소가 존재할 가능성이 있다. 이런 현상은 경험적으로 볼 때, 물체 중심부에 위치한 작은 요소들 사이의 저항률 차이가 클 때 나타난다. 이에 대한 대응책으로 본 연구에서는 다음과 같은 방법을 사용하였다. 일정 주기로 모든 BaseEL 만 남기고 모든 ObjectEL 의 분류 코드를 AdjustEL 로 바꾸어 Newton 반복 연산을 재 실행하거나, 모든 ObjectEL 만 남기고 모든 BaseEL 의 분류 코드를 AdjustEL 로 바꾸어 Newton 반복 연산을 재 실행한다. 전자는 ObjectEL 로 잘못 분류된 요소들이 존재할 경우 이를 바로잡기 위함이고, 후자는 BaseEL로 잘못 분류된 요소들이 존재할 경우 이를 바로잡기 위함이다. 만약, 실질적으로는 잘못 분류된 것이 없을 때에는 위의 작업은 당연히 불필요한 over head로 작용할 것이다. 따라서, 이 작업 수행의 필요성을 사전에 적절한 방법으로 검토한 후 실행하는 것이 효과적이다. 본 연구에서는 Newton 반복 연산 (소프트웨어적으로) 관찰(monitoring) 하여 Newton 반복 연산이 진동한다고 판단되면 위 작업을 수행토록 하였다. 여기서, Newton 반복 연산이 진동한다는 것의 판단은 1) 퍼지 분류 결과 그룹화 위상(grouping topology) 의 변화가 거의 없거나, 2) Newton 반복 연산에서의 목적함수가 진동하는 상황이 수회 이상 반복되는 것을 기준으로 하였다.

## IV. 전산 실험

이상에서 제시된 요소 그룹화 방법을 이용한 EIT 영상복원 알고리즘은 C-언어로 구현되어 개인용 컴퓨터 (Macintosh LC475) 상에서의 전산실험을 통해 그 작동성을 확인하였다. 본 전산실험에서는 측정오차가 없는 경우로 가정한다. 그림 3은 제안된 EIT 영상복원 알고리즘의 개괄적인 작업 흐름도이다. 본 연구에서는 측정 대상에 대한 사전 정보가 전혀 없는 것으로 가정하기 때문에 그룹화에 필요한 초기정보 추출을 위한 첫번째의 Newton 반복연산은 mesh 모델의 전체 요소수로 수행된다.

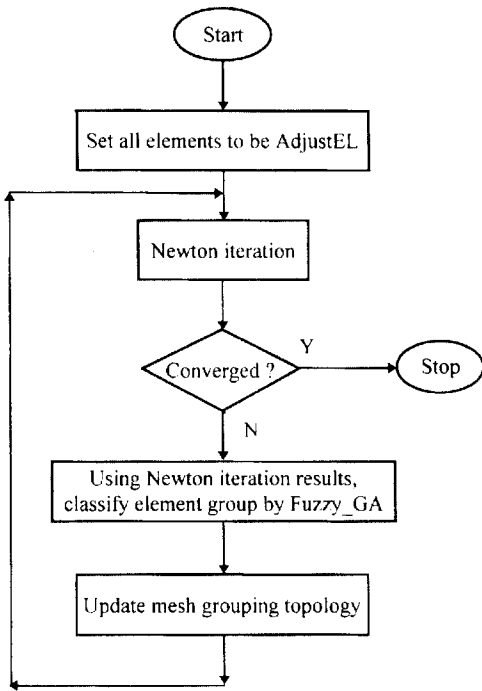


그림 3. 개략적인 작업 흐름도  
Fig. 3. Schematic working procedure.




그림 4. Improved Newton Raphson 법에 의해 복원된 EIT 정적영상  
Fig. 4. EIT static images reconstructed by the Improved Newton Raphson Method.

그림 4는 미지 저항물의 개수가 112인 모델에 대하여 그룹화 없이 개선된 Newton Raphson 법에 의거한 기존 프로그램으로<sup>[4]</sup> EIT 정적 영상을 재 구성한 예이다. 그림 4(a)의 초기 해에서 시작하여 그림 4(c)까지는 비교적 작은 반복 연산(5 iterations)으로 물체

의 윤곽을 파악할 수 있을 정도의 정보 획득이 가능함을 보인다. 그러나, 이후의 반복 연산 결과는 그림 4(d)~(f)에서도 볼 수 있듯이 소요된 실행시간(총 50 iteration에 약 2082 sec 소요)에 비하여 해의 개선효과가 극히 미미함을 알 수 있다. 이러한 현상은 본 예제와 같은 다소 복잡한 물체에 대한 EIT 정적 영상을 기존의 개선된 Newton Raphson 법만으로 재구성하고자 할 때 일반적으로 나타나는 심각한 문제점으로 실행 시간 및 해의 수렴성 모두가 EIT 기술의 실용화를 위해서는 크게 개선되어야 함을 보인다.

그림 5는 그림 4와 같은 방법으로 수행된 5 번의 Newton 반복 연산 결과를 토대로 앞 절에서 기술된 바와 같이 요소의 그룹화를 수행하여 미지 저항물의 개수를 줄인 후 Newton 반복 연산을 10회 재 수행한 결과이다(10 iteration에 237sec 소요, 표 1 참조). 그림 4의 그룹화 없이 수행된 Newton 결과와 비교하여 볼 때 그림 5는 요소의 그룹화가 연산 시간의 단축은 물론 영상복원 상태를 크게 진전시켰음을 보인다.




그림 5. 본 연구결과 : (a) 1차 Fuzzy-GA 분류결과와 이에따른 (b)~(d) 2차 Improved Newton-Raphson 결과  
Fig. 5. Results of this study : (a) 1st Fuzzy-GA classification result and (b)~(d) 2nd Improved Newton-Raphson results.

그림 6~8에서는 앞서 수행된 Newton 결과를 이용하여 그룹화 정보가 단계적으로 개선되어 점차적으로 물체의 윤곽이 구체화되고 있는 것을 볼 수 있다. 또한, 개선된 그룹화 정보에 의거하여 재 수행된 Newton 연산 결과들에서도 점차적으로 수렴성이 향상되고 있음을 알 수 있다. Newton 연산의 수렴성을 각 요소 별로 좀더 살펴보면, mesh 모델 경계에 가깝게 위치한 요소일수록 해의 수렴성이 양호하여 퍼지 분류에서 일찍 ObjectEL 그룹으로 분류된다. 반면에, 경계에서 멀리 위치한 물체 내부의 요소들은 상대적으로 열악한 수렴성을 보여 ObjectEL 그룹으로 분류되기가 어려움을 알 수 있다.




그림 6. 본 연구결과 : (a) 2차 Fuzzy GA 분류결과와 이에 따른 (b)~(d) 3차 Improved Newton Raphson 결과

Fig. 6. Results of this study : (a) 2nd Fuzzy GA classification result and (b)~(d) 3rd Improved Newton-Raphson results.




그림 7. 본 연구결과 : (a) 3차 Fuzzy-GA 분류결과와 이에 따른 (b)~(d) 4차 Improved Newton-Raphson 결과

Fig. 7. Results of this study : (a) 3rd Fuzzy-GA classification result and (b)~(d) 4th Improved Newton-Raphson results.







그림 8. 본 연구결과 : (a) 4차 Fuzzy GA 분류결과와 이에 따른 (b)~(d) 5차 Improved Newton-Raphson 결과

Fig. 8. Results of this study : (a) 4th Fuzzy GA classification result and (b)~(d) 5th Improved Newton-Raphson results.

그림 9는 그림 5~8의 결과를 얻기 위해 Fuzzy GA 분류를 반복 적용하는 과정에서 크기 순으로 정렬된 저항률  $\rho_i$ 의 분포곡선과, 저항률  $\rho_i$ 를 갖는 요소  $i$ 가 퍼지집합  $G_1, G_2$ 에 속할 확률  $\mu_{G_1}, \mu_{G_2}$ 를 식 (15), (16)에 따라 계산한 결과를 나타낸 것이다. 그림 9(b)의  $\mu_{G_1}, \mu_{G_2}$  그래프는 저항률 표준편차가 큰 경우에는 퍼지 분류 결과의 명확성이 다소 훼손될 수 있음을 보인다. 이러한 퍼지분류 결과의 불명확성은 앞 절에서 언급되었던 요소분류의 오류 혹은 고립요소의 발생의 주요 요인이 된다. 표 1은 그림 9의 4 차례의

Fuzzy-GA 분류 과정에서의 요소 분류 결과와 이를 바탕으로 수행된 Newton-Raphson 반복연산에서의 매 iteration에 소요되는 평균 연산시간을 정리한 것이다. 또한 그림 10은 목적함수 값의 실행 시간대 별 변화 추이를 나타낸 것이다. 그림 9~10 및 표 1에서 볼 수 있듯이 그룹화가 진전될수록 미확정 요소의 개수는 점차적으로 감소하여 Newton Raphson에서의 평균 반복연산 시간은 크게 감소하고 있음을 보인다. 참고로 그룹화 없이 수행된 그림 4에서 총 2082 sec의 수행 시간으로도 해가 수렴되지 못했음에 비추어 볼 때, 본 연구에서 제안된 연속적인 그룹화 정보의 개선은 수행 시간의 단축뿐만 아니라 해의 수렴성에도 기여하는 바가 큼을 알 수 있다.





V. 결 론

전기 임피던스 단층촬영 기술의 실용화에 있어 가장 큰 어려움은 고해상도의 정적 영상을 얻기 위해서는 컴퓨터 처리시간이 기하급수적으로 증가함에도 불구하고 해의 수렴성은 극도로 악화되어 수렴된 복원 영상을 얻기가 매우 어렵다는 데 있었다. 본 연구에서는 이러한 문제를 해결하기 위한 방안의 하나로 Fuzzy-GA 에 기초한 요소분류 방법을 개발하여 일정 횟수의 Newton 반복연산 결과를 주기적으로 검토하여 mesh 요소들을 재분류, 그룹화하여 Newton 법에서 처리되어야 할 요소의 개수를 감소시키는 방법을 개발하였다. 이를 이용하여 기존의 대표적인 EIT 정적 영상복원 방법인 개선된 Newton-Raphson 법을 보완하여 전산실험을 수행한 결과, 제안된 요소 그룹화 방법은 영상복원 시간의 단축과 해의 수렴성 향상에 크게 기여하여 개인용 컴퓨터 상에서도 적절한 수행시간으로 EIT 정적 영상복원이 가능함을 확인하였다.

그러나, 현재의 프로그램에서는 크게 나누어 다음과 같은 두가지의 개선되어야 할 점이 있다. 즉, 첫번째의 문제점은 현재는 대상 물체에 대한 초기 그룹화 정보가 전혀 없다는 가정하에 영상복원 작업을 시작하기 때문에 그룹화를 위한 정보 추출 초기 단계에서 비교적 많은 시간을 소요한다는 점이다. 둘째 문제점은 저항률이 다른 여러 물체가 있을 때 이들 사이의 저항률 차가 작을 경우는 영상복원 작업이 쉽게 참영상에 수렴되나 그들 사이의 차가 비교적 클 때는 참영상을 복원하는 것이 현재의 프로그램으로는 용이치 못하다는 점이다.

이러한 관점에서 신체 각 부위에 대해 이미 구축된 CT, X ray, MRI 혹은 초음파 영상 자료로부터 그룹화에 필요로 하는 기초 정보를 추출하여 이를 본 연구에서 제안된 Fuzzy-GA 분류를 위한 초기 그룹화 정보로 이용하는 방법의 개발을 위해 열거된 두가지 문제점을 크게 개선시킬 수 있을 것으로 기대된다.

참 고 문 헌

[1] J. G. Webster, ed., Electrical Impedance Tomography, Bristol, Adam Hilger, 1990.  
 [2] N. G. Gencer, Y. Z. Ider, and S. J. Williamson, Electrical impedance tomography: induced current imaging achieved




그림 9. 그림 5~8의 Fuzzy-GA 분류를 위해 크기 순으로 정렬된 저항률 분포곡선과  $\mu_{G_1}, \mu_{G_2}$  계산결과

Fig. 9. Distribution curves of the sorted resistivities and the calculated  $\mu_{G_1}, \mu_{G_2}$  for Fuzzy GA classifications performed in Fig. 5~8.

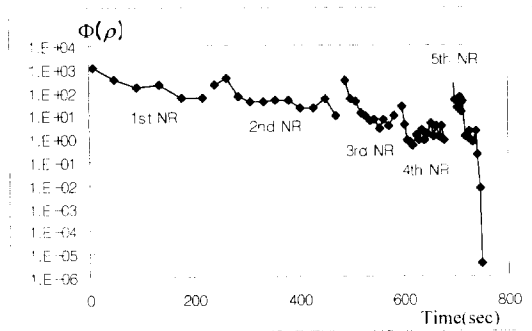


그림 10. 연속적인 Newton-Raphson 반복연산에서 목적함수의 수렴곡선

Fig. 10. Convergence curves of the objective function through out the consecutive Newton Raphson iterations.

표 1. Fuzzy-GA 분류결과

Table 1. Summary of the Fuzzy-GA classifications.

Classify	No. of BaseEL	No. of ObjectEL	No. of AdjustEL	Time/iter* [sec/iter]
not classified	0	0	112	41.64
1st	36	0	76	23.70
2nd	41	37	34	9.30
3rd	49	44	19	5.47
4th	53	47	12	3.86

\* CPU time for one iteration in the Newton Raphson iterations after the classification on Macintosh LC475 machine.

- with a multiple coil system, *IEEE Trans. Biomed. Eng.*, Vol. 43, No. 2, pp. 139-149, 1996.
- [3] D. C. Barber and B. H. Brown, Applied potential tomography, *J. Phys. E: Sci. Instrum.*, Vol. 17, pp. 723-733, 1984.
- [4] E. J. Woo, P. Hua, J. G. Webster, and W. J. Tompkins, A robust image reconstruction algorithm and its parallel implementation in electrical impedance tomography, *IEEE Trans. Med. Imaging*, Vol. 12, No. 2, pp. 137-146, 1993.
- [5] J. C. Goble and T. D. Gallagher, A distributed architecture for medical instrumentation: an electrical current computed tomograph, *Proc. Annu. Int. Conf., IEEE EMBS*, Vol. 10, pp. 285-286.
- [6] J. Woo, P. Hua, J. G. Webster, and W. J. Tompkins, Measuring lung resistivity using electrical impedance tomography, *IEEE Trans. Biomed. Eng.*, Vol. 39, No. 7, pp. 756-760, 1992.
- [7] M. Cheney, D. Isaacson, E. J. Somersalo, E. L. Isaacson, and E. J. Coffey, A layer-stripping reconstruction algorithm for impedance imaging, *Proc. Annu. Conf. IEEE Eng. Med. Biol. Soc.*, Vol. 13, pp. 3-4, 1991.
- [8] M. Glidewell and K. T. Ng, Anatomically constrained electrical impedance tomography for anisotropic bodies via a two-step approach, *IEEE Trans. Med. Imaging*, Vol. 14, No. 3, pp. 498-503, 1995.
- [9] K. D. Paulsen, P. M. Meaney, M. J. Moskowitz, and J. M. Sullivan, Jr., A dual mesh scheme for finite element based reconstruction algorithm, *IEEE Trans. Med. Imaging*, Vol. 14, No. 3, pp. 504-514, 1995.
- [10] E. J. Woo, P. Hua, J. G. Webster, and W. J. Tompkins, Finite element method in electrical impedance tomography, *Med. Biol. Eng. Computing*, Vol. 32, No. 5, pp. 530-536, 1994.
- [11] T. J. Yorkey, J. G. Webster, and W. J. Tompkins, Comparing reconstruction algorithms for electrical impedance tomography, *IEEE Trans. Biomed. Eng.*, Vol. BME-34, pp. 843-852, 1987.
- [12] D. W. Marquardt, An algorithm for least-squares estimation of nonlinear parameters, *SIAM J. Appl. Math.*, Vol. 11, pp. 431-441, 1963.
- [13] H. J. Zimmermann, *Fuzzy Set Theory and its Applications*, Kluwer Nijhoff Publishing, Boston, 1986.
- [14] 이광형, 오길록, *FUZZY 퍼지이론 및 응용* · I 권: 이론, 홍릉과학출판사, 1991
- [15] D. E. Goldberg, *Genetic Algorithm in search, optimization & machine learning*, Addison Wesley Publishing Co., NY, 1989.
- [16] J. R. Koza, *Genetic Programming on the programming of computers by means of natural selection*, MIT Press, 1992.

## 저 자 소 개

## 趙慶鎬(正會員)

1955년 8월 15일생. 1979년 2월 서울대학교 공과대학 기계설계학과 졸업, 공학사. 1981년 2월 동 대학원 졸업, 공학석사. 1993년 2월 동 대학원 졸업, 공학박사. 1986년 3월 ~ 현재 제주대학교 기계-에너지-생산공학부, 부교수. 주 관심분야는 CAD/CAM, 최적화 알고리즘, EIT Static Image Reconstruction 등



## 禹應濟(正會員)

1961년 2월 26일생. 1983년 2월 서울대학교 전자공학과 졸업, 공학사. 1985년 5월 서울대학교 전자공학과 졸업, 공학석사. 1990년 University of Wisconsin Madison 전기공학과 졸업, 공학박사. 1990년 ~ 현재 건국대학교 의학공학과, 조교수, 부교수. 주 관심분야는 의용계측 및 의료기기, 임피던스 및 생체신호 측정과 응용

## 高誠澤(正會員)

1955년 1월 12일생. 1980년 2월 인하대학교 전자공학과 졸업. 공학사. 1984년 5월 Hampton University 물리학과 졸업, 이학석사. 1989년 5월 Old Dominion University, Research Assistant Professor. 1990년 3월 ~ 1991년 2월 경남대학교 전자공학과, 전임강사. 1991년 3월 ~ 현재 제주대학교 전자공학과, 부교수. 주 관심분야는 컴퓨터이용 설계, EIT, 광전자