

論文96-33B-4-10

전기적 임피던스에 의한 컴퓨터 단층촬영 영상의 재구성을 위한 새로운 방법의 제안

- 유전알고리즘과 뉴우튼-랩슨법을 이용한 복합방법 -

(A Proposal of New Method for EICT Image Reconstruction
- A Hybrid Approach Using Genetic Algorithm and
Newton-Raphson Method -)

趙慶鎬*, 高誠澤**, 高漢錫***

(Kyung Ho Cho, Sung Tack Ko, and Han Seok Ko)

요약

본 논문에서는 전기적 임피던스에 의한 컴퓨터 단층촬영 영상의 재구성에 대한 기존 연구의 한계를 극복하기 위한 기초 연구로서, 최근 최적화 분야에서 좋은 효과를 보이고 있는 Genetic Algorithm과 Newton-Raphson 법을 혼합한 새로운 방법이 제안되었다. 제안된 방법에 따라 측정오차가 없는 여러 모델에 대하여 전산실험을 한 결과, 기존 연구에서 정확한 수렴해를 보일 수 없었던 저항비가 큰 모델(resistivity ratio 1000:1)이나, 내부에 동공이 있는 모델에 대하여 EICT 영상의 완벽한 재구성이 가능함을 확인하였다. 향후 컴퓨터의 연산속도가 향상되면 본 논문에서 제시된 방법은 여러 분야에서 EICT 기술의 실용화를 촉진할 것으로 기대된다.

Abstract

A hybrid approach employing both the Genetic Algorithm and the Newton-Raphson Method is proposed for the electrical impedance computed tomography(EICT) image reconstruction. Computational experiments based on the new concept have shown promising results for several noise-free models. In particular, the resistance distribution of the tested models having resistivity ratio up to 1000:1 has been reconstructed successfully. Using the proposed method, it is also possible to get the reconstructed images for the models having various shapes of internal cavities that usually make the reconstruction by the conventional iterative approaches be difficult to converge to a robust solution. If the computing power is enhanced further, the proposed method is expected to stimulate the practical applications of the EICT technology in the near future.

* 正會員, 濟州大學校 에너지工學科

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

** 正會員, 濟州大學校 電子工學科

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

*** 正會員, 高麗大學校 電子工學科

(Dept. of Electronics Eng., Korea Univ.)

接受日字: 1995年6月29日, 수정완료일: 1996年3月20日

I. 서론

전기적 임피던스에 의한 컴퓨터 단층촬영(Electrical Impedance Computed Tomography, EICT)은 측정하고자 하는 물체에 매우 약한 전류를 흘려주고 물체 표면의 여러 위치에서 전압 혹은 저항을 측정하여 물체 내부의 임피던스 분포를 예측, 재구성하는 기술이다. EICT는 기존의 X-ray 단층촬영(CT)이나 자기공명 단층촬영(MRI)에 비해서 매우 안전하며, 앞으로 몇 가

지의 기술적인 문제점이 해결되면, 측정 물체의 단면 정보의 영상화가 저 가격, 소형화로 가능하기 때문에 차세대의 컴퓨터 단층 촬영법으로 의공학 분야의 주목을 받고 있다. 이뿐만 아니라, EICT는 지구과학이나 재료과학 등 여러 분야에 응용이 가능할 것으로 기대되어 최근 이에 대한 많은 연구 투자가 이루어지고 있다.

초기의 EICT 기술에 대한 연구는 코어샘플(core sample)의 내부 전도도 분포를 예측하기 위한 지구과학 분야에의 적용이었다^[1]. 의용전자 분야에서는 X-ray 컴퓨터 단층촬영에 사용하는 백프로젝션(back projection) 기법을 이용하여 인간 팔의 컴퓨터 단층촬영이 처음 시도되었다.^[2,3]

현재 EICT의 주된 문제점은 크게 두 가지로 나누어진다. 첫째는 측정용 전극과 물체 사이의 접촉 임피던스에 기인되는 하드웨어 문제이고, 두번째는 주로 소프트웨어적인 문제로서, 표면 측정 자료를 이용한 내부 영상(임피던스) 재구성에 있어서의 어려움이다.

EICT 이론, 측정기법, 전극 등의 하드웨어에 관한 연구로는 내부 전도도의 식별과 최적 전극의 크기에 관한 연구^[4], 전극의 물리적 특성 - 특히, 접촉 임피던스 센트(shunt) 및 이산화 효과 등을 다룰 수 있는 수학적 모델 개발^[5], 실제 전극의 적절한 모델링 기법에 관한 연구^[6] 및 최근의 접촉 임피던스가 저감된 복합 전극의 개발^[7] 등이 있어 EICT 기술의 진일보에 기여하였다.

한편, EICT 영상 재구성 문제를 소프트웨어적으로 해결하고자 하는 노력은 크게 동적 영상 재구성(dynamic image reconstruction)과 정적 영상 재구성(static image reconstruction)의 두 가지로 나눌 수 있다. 동적 영상 재구성이라 함은 주어진 시간 내에 물체의 저항률의 변화만을 추적하는 것으로 현재는 백프로젝션 법^[8,9] 등을 이용하여 비교적 빠른 시간 안에 개략적 영상의 재구성이 용이하며, 인체에서의 주용 적용 부분은 호흡에 따른 혀파의 저항률 변화를 감지하여 환자나 유아의 갑작스런 호흡정지를 감지하는 기구에 사용되고 있다. 정적 영상 재구성 문제는 물체 내부의 각 위치마다의 저항률의 차값과 그 분포를 알아내고자 하는 것으로 유한요소법(finite element method)^[10,11], 경계요소법(boundary element method)^[12] 및 Newton-Raphson 법^[13,14] 등을 이용하는 연구가 진행되고 있다. 그러나, 이문제의 고유

한 속성인 ill-condition 현상 때문에 현재까지의 연구는 동적 영상의 재구성 분야처럼 실용화할 수 있는 단계에 이르질 못하고 있는 실정으로 아직도 모델이 조금만 복잡하여도 정확한 영상에 수렴하기 위해 과도한 반복계산이 요구되거나, 해의 수렴성이 보장되지 않는 문제점들이 남아 있다.

반면에, EICT 영상 재구성의 문제는 미지의 내부 저항의 차값을 결정하는 문제로서 이러한 문제는 요즈음 최적화 분야에서 한창 관심을 끌고 있는 유전 알고리즘(Genetic Algorithm, 이하 GA)^[15-17]을 적용할 경우 효과적인 결과가 기대되는 문제이다.

따라서, 본 연구에서는 기존의 Newton-Raphson Method(이하 NRM)의 문제점을 보완할 수 있는 방법으로 GA와 NRM 각각의 장점을 살린 복합적인 방법을 사용하여 기존 연구들 보다 개선된 분해능과 안정성을 갖는 새로운 EICT 정적 영상 재구성 방법을 제안하고, 수차례의 전산실험을 통하여 제안된 방법의 강건성을 확인하였다. 본 논문의 구성은 NRM을 이용한 EICT 영상 재구성 문제의 개략적인 소개, GA의 소개, 제안된 알고리즘, 전산실험 예, 결론 순으로 되어 있다.

II. NRM을 이용한 EICT 영상 재구성

$G(\bar{R})$ 을 내부 저항 \bar{R} 에 의해 모델 경계의 임의의 두 전극 사이에서 측정될 저항 \bar{g} 를 일의적으로 결정할 수 있는 순방향 함수(forward function)라 할 때, EICT 영상 재구성 문제 (image reconstruction problem)란 측정된 저항 \bar{g} 로 부터 \bar{R} 를 역추적하는 문제로서, EICT 역변환 문제 (EICT inverse or backward problem)라고도 한다. 다시 말해서, 가정된 내부저항 \bar{R} 에 의해 경계의 임의의 두 전극 사이의 계산된 저항 $G(R)$ 과 측정된 저항 \bar{g} 간의 오차를

$$P(R) = \bar{G}(\bar{R}) - \bar{g} \quad (1)$$

라 할 때,

$$P(\bar{R}) = 0 \quad (2)$$

이 되는 \bar{R} 을 결정하는 문제이다.

NRM은 수치해법적인 반복 연산을 통하여 \bar{R} 을 구하는 방법 중의 하나로서, 그 기본 개념은 다음과 같다. 즉, $P(\bar{R})$ 을 가정된 초기해 \bar{R}_0 주위에서 Taylor 급수로 전개하면,

$$\overline{P}(\overline{R_0}) + \Delta \overline{R}) = \overline{P}(\overline{R_0}) + \nabla \overline{P}(\overline{R_0}) \cdot \Delta \overline{R} + O(\Delta \overline{R}^2) \quad (3)$$

여기서, $\nabla \bar{P}$ 는 \bar{P} 의 Jacobian Matrix이다.
 $\bar{R} = \bar{R}_0 + \Delta \bar{R}$ 이 식 (2)를 만족한다고 가정하고, 식
(3)을 $\Delta \bar{R}$ 의 일차항만으로 근사시켜 정리하면,

$$\nabla \bar{P}(\bar{R}_0) \cdot \Delta \bar{R} = -\bar{P}(\bar{R}_0) \quad (4)$$

$J = \nabla \bar{P}(\bar{R}_0)$ 라 하고 (4)의 양변에 J^T 를 곱하면,

$$[J^T J] \cdot \Delta \bar{R} = -J^T \cdot \bar{P}(\bar{R}_0) \quad (5)$$

$$\therefore \Delta \bar{R} = -[J^T J]^{-1} J^T \cdot \bar{P}(\bar{R}_0) \quad (6)$$

따라서, NRM에서는 초기 해 \bar{R}_0 로 부터 식 (6)에 의거하여 수렴된 해 \bar{R}_0 이 구해질 때까지 계산을 반복 한다.

이 방법은 적절한 초기해가 주어지면 정확한 최종해에 수렴하지만, 일반적으로 초기해를 적절히 설정해 주는 작업이 어려워 항상 최종해에 수렴한다는 보장이 없다^[14].

III. Genetic Algorithm

유전 알고리즘(Genetic Algorithm, GA)은 우수한 형질을 가진 개체가 자연계에 잘 적응하여 큰 생존 확률을 가지고 더 많은 교배에 참여하여 우수한 자손을 생성, 번성한다는 자연계의 적자생존의 법칙(survival of fittest)과 재생, 교배, 돌연변이의 과정을 통하여 개체의 우수한 형질이 유전되거나 진화해 가는 유전학에서 착상을 얻은 모의 진화형의 최적해 탐색 알고리즘이다. GA는 1975년 John Holland와 그의 연구진들이 기존의 GA에 대한 연구를 종합하여 체계화시켰으며, 공학분야에서는 최초로 Goldberg^[15]에 의해 가스 운송 관에 대한 최적설계에 적용된 이래 여러 분야에서 많은 발전이 있어 왔다.

그림 1은 GA에서의 최적해 탐색 과정을 개괄적으로 나타낸 것으로 다음과 같이 요약할 수 있다.

- 1) 최적화 하고자 하는 시스템 변수들에 대응되는 개체(individual)의 표현 방법(주로 이진수로 구성된 유전자형, binary string)을 정의한다.
 - 2) 1)에서 정의된 방법으로 개체를 무작위로 생성하여 초기 집단(initial population)을 구성한다.

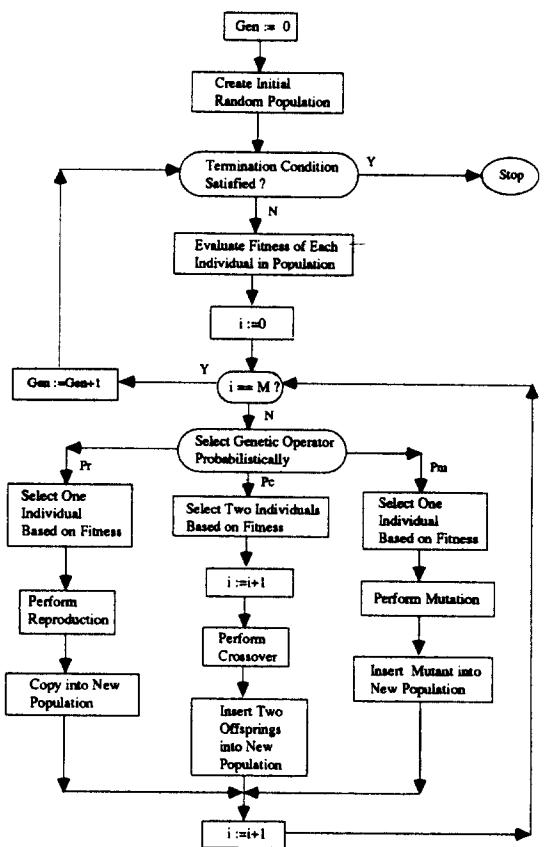


그림 1. 유전 알고리즘의 일반적인 흐름도

Fig. 1. Typical flowchart for the genetic algorithm.

- 3) 집단 내의 각 개체의 적응도(fitness)를 계산한다.
 - 4) 적응도에 따라 적응도가 높은 개체를 선택, 복사하여 자손(spring)을 생성하거나.
 - 5) 교배에 참가할 개체쌍(parents)을 적응도에 따라 선정하여 이들의 유전자형을 교차교배 (crossover) 시킴으로써 두개의 자손을 생성하거나,
 - 6) 일정한 돌연변이(mutation) 확률로 부모의 유전자형을 변화시켜 자손을 생성한다.
 - 7) 개체 집단의 크기만큼 자손을 생성하여 새로운 세대 집단(new population)을 구성할 때 까지 위 4)~6) 단계를 반복한다.
 - 8) 실행종료 조건이 만족될 때까지 위의 3)~7) 단계를 반복한다.

위의 최적화 과정을 효과적으로 수행하기 위하여 GA에서는 기본적으로 1) reproduction, 2) crossover 및

3) mutation과 같은 유전자 조작방법을 사용한다. 이들의 보다 상세한 작동원리들은 참고문헌 [15-17]에 소개되어 있다.

표 1. 최적화 문제와 GA 사이의 유사성

Table 1. Analogy between optimization problem and genetic algorithm.

Optimization Problem	Genetic Algorithm
Cost	Fitness
Solution Subspace	Population
Feasible Solutions	Individuals
Variables	String

표 1은 일반적인 최적화 문제와 GA 사이의 유사성을 정리한 것이다. 그러나, GA는 다음과 같은 측면에서 종래의 최적화 알고리즘과 다른 특성을 보인다.

- GA는 시스템 변수 사이의 coupling에 거의 무관하고, 목적함수의 변화율과 같은 정보를 필요로 하지 않는 직접 탐색법이다.
- GA에서의 해의 탐색은 해집단(population) 내에서의 여러 해에 대한 동시탐색 (concurrent multi-point search)으로 내재적인 병렬탐색 (implicit parallel search)의 속성을 갖고 있어 현 탐색 단계 까지의 누적된 정보를 이용한다.
- GA는 결정론적 탐색법(deterministic search)이 아닌 확률론적 탐색법 (probabilistic search)을 사용한다.
- GA에서의 탐색은 목적함수가 악화되는 방향으로의 해의 천이도 확률적으로 허용하기 때문에 국시해 (local optima)를 탈출할 가능성이 상대적으로 크다.

IV. EICT 영상 재구성을 위한 새로운 알고리즘

EICT 영상 재구성에서의 기존 연구의 문제점을 보면 혹은 해결할 수 있는 새로운 알고리즘에서 궁극적으로 해결되어야 할 사항은

- 1) 내부에 동공이 있거나 저항비(resistivity ratio)가 큰 모델에 대해서도 안정적으로 작동하며,
- 2) 잡음이 없는 이상적인 측정 데이터에 대해서는

- 영상 재구성이 항상 가능해야 하며,
- 3) 마이크로 컴퓨터 상에서 적절한 실행시간으로 구현 가능하며,
 - 4) 측정 데이터에 어느 정도의 오차가 있더라도 작동의 안정성이 확립되어야 한다.

이를 위하여 본 연구에서는 일차적으로 위의 1)~3) 항의 요구 조건을 충족시킬 수 있는 다음과 같은 새로운 알고리즘을 개발하였다.

1. 유전 알고리즘과 뉴우튼-랩슨법을 이용한 복합법 앞에서 고찰된 바와 같이 GA 및 NRM은 각기 고유한 장·단점을 갖고 있음을 알 수 있다. 즉, GA는 시스템의 변화율과 같은 주요 정보 없이도 점진적으로 개선되는 해를 탐색할 수 있다. 반면에, GA는 자체적으로 최종해를 결정짓기 어렵고, 최종해 근처에서 배회

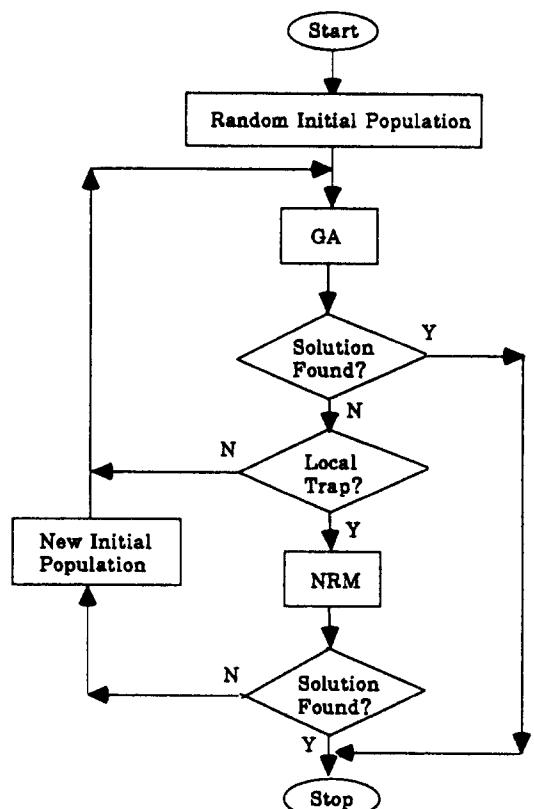


그림 2. 제안된 GA-NRM 복합 방법의 흐름도

Fig. 2. Flowchart of the proposed GA-NRM hybrid approach

하기 쉽다. 반면에, NRM은 초기해의 질에 따라 해의 수렴여부가 크게 좌우되는 단점이 있지만, 일단 적절한 초기해가 주어지면 최종해를 정확히 결정지을 수 있다.

본 연구에서는 이들 두 방법의 장점을 살리고 단점을 서로 보완할 수 있는 다음과 같은 새로운 접근 방법을 제시하고자 한다. 즉, 그림 2에서 보는 바와 같이, 임의로 선정된 후보해 집단의 속성을 GA를 이용하여 우수한 형질로 진화, 개선시킨다. GA를 통한 형질개선이 더이상 기대되지 않을 정도로 수렴되면, 다시 말해 GA가 국지해(local optima)에 빠졌다고 평가되면 이 때의 해를 NRM의 초기해로 사용하여 NRM을 이용하여 최종해를 결정하고자 하는 방법이다. Han^[14]의 연구에서는 NRM가 수렴하지 않을 경우 초기해를 재구성하는 데 상당한 어려움이 있는 반면에 본 연구에서 제안된 방법에 의하면 이러한 난점을 쉽게 해소될 수 있다.

2. EICT 영상 재구성에서의 유전알고리즘

EICT 영상 재구성 문제를 GA로 풀기 위해선 가정된 내부저항 \bar{R} 에 대한 적합성 평가가 필요하다. 이를 위해 본 연구에서는 다음과 같이 적응도를 정의하여 사용하였다. 즉, \bar{R} 에 의해 모델 경계의 임의의 두 전극 사이의 계산된 저항($G_i(\bar{R})$)과 측정된 저항(g_i) 간의 상대오차 백분율의 총합을 \bar{R} 의 오차(error(\bar{R}))로, 이의 역수를 \bar{R} 의 적응도($f(\bar{R})$)로 정의하여, 이 적응도를 최대로 하는 해 \bar{R} 을 찾는 문제로 접근하였다. 이를 정식화하면 다음과 같다.

$$\text{Find } \bar{R} = (r_1, r_2, \dots, r_n)$$

$$\text{to maximize } f(\bar{R}) = \frac{1}{\text{error}(\bar{R})} \quad (7)$$

$$\text{subject to } \text{error}(\bar{R}) = \sum_{i=1}^{m} \frac{|G_i(\bar{R}) - g_i|}{g_i} \times 100 \quad (8)$$

where,

\bar{R} : an individual or a candidate solution

$r_i, i=1, 2, \dots, n$: assumed interior resistance

$g_j, j=1, 2, \dots, m$: resistance measured at j -th exterior electrode pair

$G_i(\bar{R})$: resistance calculated at j -th exterior electrode pair with \bar{R}

$f(\bar{R})$: fitness of the individual \bar{R}

앞에서도 언급된 바와 같이 GA에서는 거듭되던 해의 개선이 궁극에는 어느 국지해에 빠져 GA 자체로는 더이상의 해의 개선을 기대하기가 어렵게 된다. 이때의 국지해가 전역 최적해(global optima)일 수도 있지만 일반적으로 그럴 확률은 매우 작다. GA가 국지해에 빠졌는가의 여부를 평가하는 데는 여러 방법이 가능하나, 본 연구에서는 수차례의 실험을 통하여 각 세대의 가장 좋은 해의 오차 $\text{min}(\text{error})$ 는 국지해에 도달하기 전까지는 대체적으로 지수 합수적으로 감소하는 추세를 보임을 확인하였던 바, 다음과 같은 간단한 방법으로 국지해 여부를 평가하였다. 즉, $\text{min}(\text{error})_o$ 와 $\text{min}(\text{error})_n$ 을 각각 기준 시점 및 n 회의 세대교체 후의 가장 좋은 개체들의 오차라 할 때, 이들이

$$\text{min}(\text{error})_n < r \cdot \text{min}(\text{error})_o, r = 0.5 \sim 0.9$$

를 만족하지 못하면 국지해에 빠졌다고 평가한다. GA의 수렴성은 실질적으로 해결하고자 하는 문제의 난이도(분해능의 크기 및 저항률의 차)에 따라 크게 변하기 때문에, 난이도가 높은 문제에 대해서는 n 과 r 이 너무 작게 설정되지 않도록 하여야 한다.

V. 전산실험 예

본 연구에서는 $n \times n$ ($n \leq 8$)의 분해능을 갖는 정방형 모델에 대한 다음과 같은 전산 실험을 통하여 제안된 방법의 강건성을 평가하였다.

- 1) 여러 가지 형태의 내부 임피던스 분포에 대한 순방향 해석(forward analysis)을 이용하여 물체 경계에서의 측정 저항을 대신할 수치적인 데이터를 작성하고,
- 2) 제안된 알고리즘을 사용하여 입력된 측정 데이터에 대한 원래 영상의 영상(내부 임피던스 혹은 저항 분포도)을 재구성할 수 있음을 보인다.
- 3) 이때 측정 데이터에는 잡음(noise)이 없다고 가정한다.

그림 3 (a)는 본 연구에서 제안된 방법에 의한 EICT 재구성 문제 해결의 개략적인 진행상황을 보기 위한 모델이다. 먼저 GA를 기동하기 위하여 내부저항 분포를 가정된 내부저항의 최대, 최소값 사이의 임의의 값으로 초기 개체 집단을 구성한다. 본 연구에서는 개체 집단의 크기, 즉, 한 세대에서의 candidate

solution 수를 20으로 하였고, 그림 3 (b)는 이렇게 무작위로 구성된 초기 집단 내의 가장 좋은 해이다. 초기 집단내의 개체들은 GA에 의해 여러 세대의 진화를 거

1	1	50	1	1	1
1	100	100	100	1	1
150	150	200	150	150	1
1	250	250	250	1	1
1	1	300	1	1	1
1	1	1	1	1	1

(a) EICT model (true images)

385.60	105.90	520.30	417.90	172.50	351.60
59.00	260.50	629.70	59.50	610.10	153.50
160.10	561.70	260.70	471.10	212.30	86.50
104.10	694.60	488.00	702.20	534.80	76.90
80.10	297.50	470.00	353.60	453.00	58.30
6.50	138.40	84.60	314.70	69.50	164.90

(b) best solution in initial population

1.10	42.80	8.00	1.20	1.10	1.10
1.40	262.60	257.60	623.70	1.50	1.30
136.80	49.20	484.30	514.20	770.20	1.10
1.10	264.60	624.50	516.50	383.00	1.00
1.10	55.10	648.30	624.50	1.00	1.20
1.00	1.10	1.30	1.10	1.00	1.00

(c) locally-trapped 1st GA solution

1.00	1.00	50.03	0.99	1.00	1.00
1.00	103.29	91.57	102.75	0.98	1.00
149.99	146.14	143.24	515.12	76.85	1.00
1.00	260.05	64.97	64.38	0.75	1.00
1.00	1.00	244.37	0.76	1.01	1.01
1.00	1.00	1.00	1.00	1.01	1.00

(d) result of 1st NRM (not converged)

1.00	1.00	50.00	1.00	1.00	1.00
1.00	52.10	46.30	102.80	1.00	1.00
150.00	73.50	143.20	515.10	38.90	1.00
1.00	130.50	33.00	32.70	1.00	1.00
1.00	1.00	244.40	0.90	1.00	1.00
1.00	1.00	1.00	1.00	1.00	1.00

(e) best solution in 2nd initial population

1.00	1.00	50.50	1.00	1.00	1.00
1.00	120.80	94.10	102.80	1.00	1.00
150.00	147.30	143.20	32.70	76.80	1.00
1.00	335.30	3.40	107.90	1.70	1.00
1.00	1.00	256.70	1.00	1.00	1.00
1.00	1.00	1.00	1.00	1.00	1.00

(f) locally-trapped 2nd GA solution

1.00	1.00	50.00	1.00	1.00	1.00
1.00	100.00	100.00	100.00	1.00	1.00
150.00	150.00	200.00	150.00	150.00	1.00
1.00	250.00	250.00	250.00	1.00	1.00
1.00	1.00	300.00	1.00	1.00	1.00
1.00	1.00	1.00	1.00	1.00	1.00

(g) final solution converged in 2nd NRM

그림 3. EICT 영상 재구성을 위한 모델과 GA-NRM에 의한 해의 수렴 상황

Fig. 3. EICT image reconstruction model and interim solutions obtained by GA-NRM.

쳐 결국에는 어느 국지해 주위에 수렴되고 그림 3 (c)는 그 상황에서 가장 좋은 해이다. 이 해를 NRM의 초기해로 사용한 1차 NRM 결과는 그림 3 (d)처럼 수렴하지 못하였다. 이때의 NRM 정보를 토대로 재구성된 개체집단 속에서 가장 우수한 해가 그림 3 (e)이다. 그림 3 (f)는 2차 GA 수렴결과이고 이를 토대로 2차 NRM 결과 그림 3 (g)처럼 최종해에 수렴되었다.

Han^[14]의 NRM에 의하면 그림 4와 같은 모델에 대하여 저항비가 10:1인 경우는 해를 구할 수 있었으나, 저항비가 400:1 이상인 경우에 대해서는 해를 구하지 못함을 보였다. 그림 5는 그림 4의 모델에 대하여 NRM을 적용시켜 해를 구하고자 할 때의 해의 수렴 상황을 나타낸 것이다. 그림에서도 볼 수 있듯이 여러 개의 최적해가 시도되었으나 결국은 수렴된 해를 구하는 데 실패하여 NRM의 한계성을 확인할 수 있다. 이 때 사용된 NRM의 초기해들은 다음과 같은 것이었다.

- 모든 내부저항을 가정된 최소저항 (background resistivity) 값으로 설정
- 모든 내부저항을 가정된 최대저항 값으로 설정
- 모든 내부저항을 가정된 최소, 최대의 평균저항 값으로 설정
- 모든 내부저항을 가정된 최소, 최대 사이의 임의의 저항 값으로 설정

반면에, 그림 6은 본 연구에서 제안한 GA-NRM으로 그림 4의 해를 구할 경우의 해의 수렴상황을 나타낸 것으로서, 1차 NRM에서는 최종해에 수렴하지 못하여 2차 GA에서 재구성된 초기해로 2차 NRM에서 최종해에 수렴하였음을 보인다.

1	1	1	1	1	1
1	1	1	1	1	1
1	1	400	1	1	1
1	400	1	400	1	1
400	1	1	1	400	1
1	1	1	1	1	400

그림 4. EICT 영상 재구성을 위한 저항비 400:1의 모델

Fig. 4. EICT image reconstruction model of resistivity ratio 400:1.

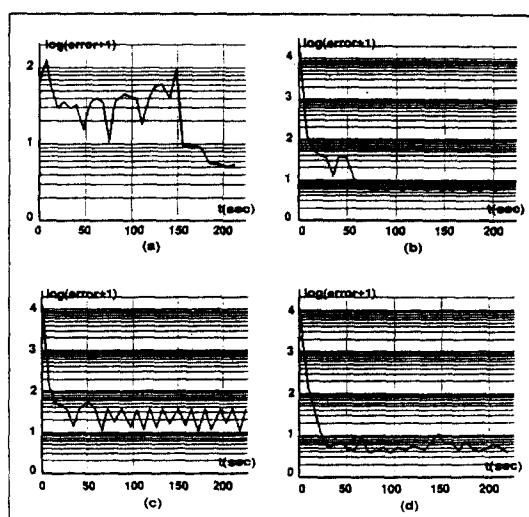


그림 5. 그림 4.의 모델에 대한 NRM 해의 수렴상황
Fig. 5. Convergence status of the solutions by NRM for the model shown in Fig. 4.

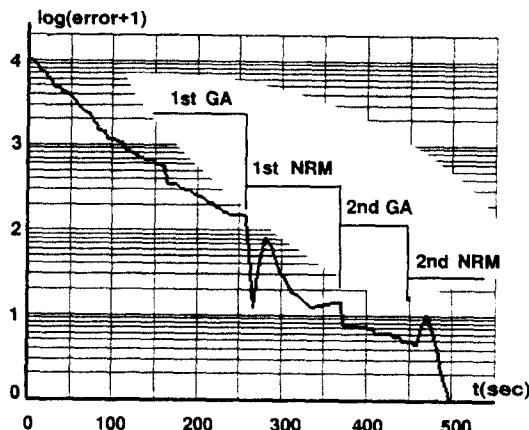


그림 6. 그림 4.의 모델에 대한 GA-NRM 해의 수렴상황
Fig. 6. Convergence status of the solution by GA-NRM for the model shown in Fig. 4.

EICT 영상 재구성 문제에서 가장 어려운 점은 내부 임피던스(저항)의 급격한 변화를 정확히 감지해내기가 어렵다는 데 있다. 본 연구에서는 저항비 200:1의 그림 7 (a)의 모델뿐만 아니라, 그림 7 (b)처럼 1000:1 이면서 내부에 통공이 있는 경우에도 내부저항을 소수점 이하 두자리까지 정확히 재구성할 수 있었다.

그림 8 (a)는 현재 정적 영상 재구성 분야에서 가장

앞서 있다고 평가되는 Wisconsin 대학 연구그룹^[7,13]의 개선된 Newton 법을 이용하여 그림 7 (b) 모델의 정적 영상을 재구성할 때 얻어지는 중간 영상 및 최종 결과로서 물체 내부 저항분포의 윤곽은 비교적 빠른 시간에 정확하게 추출하고 있으나, 결국은 국지해에 빠져 50회의 Newton 반복 연산 후에도 참 저항값으로의 수렴에는 실패하였다. 이에 반하여, 그림 8 (b)는 동일 모델에 대하여 본 연구에서 제안된 방법으로 얻은 중간 영상 및 최종 결과로서 참 저항값을 정확히 재구성해내고 있음을 보인다.

100	1	100	1	100
1	100	1	100	1
100	1	200	1	100
1	100	1	100	1
100	1	100	1	100

(a)

1	1	1	1	1	1	1	1	1
1	100	100	100	1	1	1	1	1
1	100	0.1	100	1	1	1	1	1
1	100	0.1	100	100	100	1	1	1
1	100	100	100	0.5	100	1	1	1
1	1	1	100	0.5	100	1	1	1
1	1	1	100	100	100	1	1	1
1	1	1	1	1	1	1	1	1

(b)

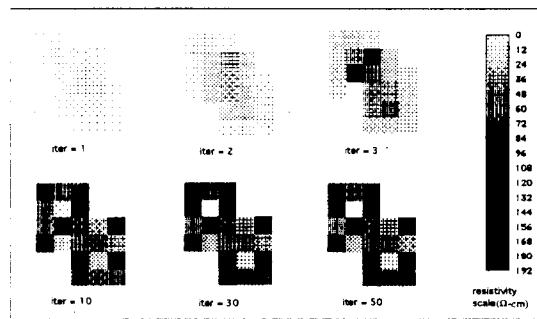
그림 7. EICT 영상 재구성을 위한 모델 (a) 저항비 200:1 (b) 저항비 1000:1

Fig. 7. EICT image reconstruction models (a) resistivity ratio 200:1 (b) resistivity ratio 1000:1.

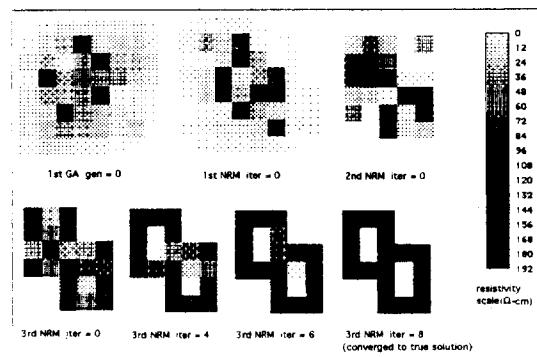
VI. 결 론

전기적 임피던스를 이용한 컴퓨터 단층촬영법(EICT)에서 난제가 되어온 단면영상의 재구성(저항분포도 작성) 문제를 유전 알고리즘(Genetic Algorithm)과 뉴턴-랩슨법(Newton-Raphson Method)을 혼합하여 해결하고자 하는 노력은 본 연구가 처음으로 기존의 여러 연구에서 다루어졌던 여러 모델 뿐만 아니라 보다 복잡한 모델에 대해서도 주어진 문제

능에서 정확히 영상을 재구성할 수 있었다. 즉, 기존 연구에서는 저항비가 큰 모델이나 내부에 동공이 있는 모델에 대해서는 수렴된 해를 보이지 못하고 있으나, 본 연구에서 제안된 방법으로는 최대 1000:1의 저항 차가 있는 경우와 내부에 동공이 있는 모델 모두에 대해서 정확한 내부 저항분포를 재구성할 수 있었다.



(a)



(b)

그림 8. 그림 7 (b) 모델에 대한 재구성 영상의 비교 :
(a) 개선된 Newton법에 의한 영상들 (b) 제
안된 방법에 의한 영상들

Fig. 8. Comparison of the reconstructed images for the model in Fig. 7 (b) : (a) images obtained by the improved Newton method (b) images obtained by the proposed method

앞으로 동 분야에서는 GA의 실행시간 단축을 위한 병렬처리 (parallel processing) 기법의 도입과, 측정 오차의 허용범위 설정을 위한 민감도 해석문제를 Maximum Likelihood Method 등의 추정 통계론적으로 접근하는 연구 및 EICT 영상 재구성 문제를 2~3 차원의 임의 형상으로 확장하는 연구 등이 기대된다.

참 고 문 헌

- [1] K. A. Dine and R. J. Lytle, "Analysis of

- electrical conductivity imaging," Geophysics, Vol. 46, pp. 1025-1036, 1981.
 [2] C. C. Barber and B. H. Brown, "Imaging spatial distributions of resistivity using applied potential tomography," Electronics, Vol. 19, pp. 933-935, 1983.
 [3] C. C. Barber and B. H. Brown, "Applied potential tomography," *J. Phys. E : Sci. Instrum.*, Vol. 17, pp. 723-733, 1984.
 [4] D. G. Gisser, D. Isaacson and J. C. Newell, "Electric current computed tomography and eigenvalues," *ISAM J. Appl. Math.*, Vol. 52, pp. 1623-1634, 1990.
 [5] K. Cheng, D. Isaacson and J. C. Newell and D. G. Gisser, "Electrode models for electric current computed tomography," *IEEE Trans. Biomed. Eng.*, Vol. BME-36, pp. 918-924, 1989.
 [6] K. Paulson, W. Breckon and M. Pidcock, "Electrode modelling in electrical impedance tomography," *SIAM J. Appl. Math.*, Vol. 52, pp. 1012-1022, 1992.
 [7] P. Hua, E. J. Woo, J. G. Webster and W. J. Tompkins, "Using Compound Electrodes in Electrical Impedance Tomography," *IEEE Trans. on Biomed. Eng.*, Vol. 40, pp. 29-34, 1993.
 [8] F. Santosa and M. Vogelius, "A back-projection algorithm for electrical impedance imaging," *SIAM J. Appl. Math.*, Vol. 50, pp. 216-243, 1990.
 [9] R. Guardo, C. Boulay, B. Murray and M. Bertrand, "An experimental study in electrical impedance tomography using back-projection reconstruction," *IEEE Trans. Biomed. Eng.*, Vol. BME-38, pp. 617-627, 1991.
 [10] B. F. Wexler and M. R. Neuman, "Impedance-computed tomography algorithm and system," *Applied Optics*, Vol. 24, pp. 3985-3992, 1984.
 [11] M. Murai and Y. Kagawa, "Electrical impedance computed tomography based on a finite element model," *IEEE Trans. Biomed. Eng.*, Vol. BME-32, pp. 177-184, 1985.

- [12] M. Murai and Y. Kagawa, "Boundary element iterative technique for determining the interface boundary between two Laplace domains-a basic study of impedance plethysmography as an inverse problem," *Int. J. Numer. Methods Eng.*, Vol. 23, pp. 35-47, 1986.
- [13] T. Yorkey, J. G. Webster and W. J. Tompkins, "Comparing reconstruction algorithms for electrical impedance tomography," *IEEE Trans. Biomed. Eng.*, Vol. BME-34, pp. 843-901, 1987.
- [14] D. K. Han, Electrical impedance computed tomography applied to the imaging of two-phase gas-liquid flows, MS Thesis, Johns Hopkins University, 1993.
- [15] D. E. Goldberg, Computer-aided gas pipeline operation using genetic algorithms and rule learning, Doctorial dissertation, University of Michigan, 1983.
- [16] D. E. Goldberg, *Genetic Algorithm in search, optimization & machine learning*, Addison-Wesley Publishing Co., NY, 1989.
- [17] J. R. Koza, *Genetic Programming on the programming of computers by means of natural selection*, MIT Press, 1992.

저자 소개

趙慶鎬(正會員)



1955년 8월 15일 생. 1979년 2월 서울대학교 공과대학 기계설계학과 졸업, 공학사. 1981년 2월 동 대학원 졸업, 공학석사. 1993년 2월 : 동 대학원 졸업, 공학박사. 1986년 3월 ~ 현재 :

제주대학교 에너지공학과, 부교수. 주관심분야 : CAD/CAM, 최적화 알고리즘, EIT 등.

高誠澤(正會員)



1955년 1월 12일 생. 1980년 2월 인하대학교 전자공학과 졸업, 공학사. 1984년 5월 Hampton University 물리학과 졸업, 이학석사. 1989년 5월 Old Dominion University 전기 및 컴퓨터공학과 졸업, 공학박사. 1979년 12월-1982년 1월 Texas Instruments, Engineer. 1983년 9월-1985년 8월 NASA, Research Assistant. 1989년 5월-1990년 1월 Old Dominion University, Research Assistant Professor. 1990년 3월-1991년 2월 경남대학교 전자공학과, 전임강사. 1991년 3월-현재 제주대학교 전자공학과, 부교수. 주관심분야는 컴퓨터이용 설계, EIT, 광전자

高漢錫(正會員)



1960년 8월 10일 생. 1982년 Carnegie-Mellon University 전자공학과(공학사). 1986년 Johns Hopkins University 전자공학과(공학석사). 1986년 University of Maryland 시스템공학과(공학석사). 1992년 Catholic University of America 전자공학과(공학박사). 1982년 ~ 1994년 Naval Surface Warfare Center 책임연구원. 1992년 ~ 1994년 University of Maryland Baltimore County 객원조교수. 1995년 3월 ~ 현재 고려대학교 전자공학과 조교수. 주관심분야는 Data fusion, 신호처리, Tracking, 통신, 및 지능정보처리