

特集 電磁非破壊検査工学の体系化

電磁非破壊評価における逆解析技術

Inverse analysis arising in electromagnetic nondestructive evaluation

小島 史男
陳 振茂(神戸大学)
(普遍学国際研究所)

遊佐 訓孝

(普遍学国際研究所)

Fumio KOJIMA
Noritaka YUSA
Zhenmao CHENMember
Member
Member

1 はじめに

複数の小型コイルプローブのアレイ化による高機能磁気プローブの開発や、超伝導量子干渉素子 (SQUID) 等の高感度磁気センサの開発、また計算機の大幅な性能向上を背景とした電磁場解析技術の進展に伴い、新しい逆解析技術の開発が進められている。本解説においては、渦電流探傷試験 (ECT) の高精度化を背景として開発中の逆解析技術のいくつかの取り組みを紹介し、今後の逆解析技術の動向を探る。本稿では、特に加圧水炉型原子炉における蒸気発生器伝熱管のきず形状の同定を対象とした。したがって、ここでいう逆解析とは、渦電流探傷法で取得されるデータから、伝熱管のきず形状を復元する計算法を意味する。通常の渦電流解析の計算モデルでは、きずに関する形状をパラメータで与え、そのときの渦電流探傷データを得る。これは順解析と呼ばれ、有限要素・境界要素併用法、辺要素有限要素法にもとづく優れた順解析モデルはすでに確立されている [1][2]。逆解析では、開発された順解析モデルが何らかの方法で援用されることが多い。ここでは、以下に示す3種類の逆解析法を紹介し、順解析モデルが逆解析にどのような役割を果たしているかを示し、それぞれの計算技法の有効性について検討する。最初に紹介するものは、ニューラルネットワークを用いた欠陥形状の再構成法である。この方法では、逆解析のもつ非線形写像をニューラルネットによる学習により構築していく。すなわち、写像そのものを取り扱うことになる。次に、パラメータ推定にもとづく欠陥形状の再構成手法について述べる。この方法では、順解析のモデル構造を逆解析の実行時にオンラインで使用して、欠陥形状のパラメータの最適化問題として逆

問題が解かれる。最後に計算知能技術をもちいた欠陥形状のプロファイリング手法について解説する。ここではファジィ推論機構に遺伝的プログラミングの前処理を加えた、計算知能技術にもとづく新しい計算法を紹介する。

2 ニューラルネットワークを用いた欠陥形状再構成

2.1 ニューラルネットワークとは

人間の脳の中には 100 億以上ものニューロン (神経細胞) が存在し、それらの大きさ、形はさまざまであるものの、外部よりの信号がある一定値以上になった場合にのみパルス状の電気波形を作り出し、他に信号を伝えるという共通の働きをもっている。ニューラルネットワークとは、生体内ニューロンの働きを数学的に模倣した人工ニューロンを多数組み合わせることで、任意の非線形写像を実現するというものであり [3][4]、その最も特徴的な点は、望ましい入力-出力関係を実現するように、与えられたデータを基にして自分自身を変化させてゆくことができるという点である (これを学習と呼ぶ)。ここではニューラルネットワークのこの特徴を利用し、数値解析によって得られた渦電流探傷信号と欠陥形状のデータベースからそれらの間に存在する写像をニューラルネットワークに学習させ、欠陥形状再構成に用いる試みを行う。なお、ニューラルネットワークとは本来生体内の神経回路網を指す言葉であるが、ここでは特に断りの無い限り、人工ニューロンを多数組み合わせた工学的応用技術を指すものとする。

2.2 再構成手法

2.2.1 欠陥モデル

用いたモデルを Fig.1 に示す. 対象とする領域を微小要素に分割し, 欠陥を構成する各要素にそれぞれ異なる導電率を与えることで内部導電率分布を持つ自然欠陥を模擬する. このような欠陥モデル—探傷信号の組み合わせをデータベースとして用いてニューラルネットワークに学習を行わせる.




Fig. 1 Crack model for neural network approach.

Fig.1 のような欠陥モデルを用いた場合, 欠陥を記述するパラメータの数はきわめて大きく, 欠陥パラメータ空間と探傷信号空間の間に存在する写像そのものをネットワークに学習させることはきわめて困難である. 現実の検査においては欠陥の大きさが重要であり, 内部導電率分布を知ることは必ずしも必要ではない. そのため, 探傷信号から再構成を行うのは欠陥形状, すなわち欠陥の境界線のみとする. 欠陥パラメータの一部のみを取り扱うことで, ネットワークが学習する写像そのものが簡単なものとなり, 学習が容易になることが期待される.

ECT の特徴を考慮し, ここで対象とするのは表面欠陥のみとし, また欠陥がどちらの面に発生したかということは信号の軌跡などからあらかじめ既知であるとした. このとき, 欠陥形状は表面からの深さをパラメータとする柱状領域の集合とみなすことが出来るため, ネットワークの出力としてはこれら各柱の深さをとるものとする. ただし, 深さは欠陥を構成する深さ方向の要素数を単位として表現する. 例えば, Fig.1 に示された欠陥であれば, 欠陥形状を表現するパラメータ c は $c = \{00543567776200\}$ となる.

2.2.2 データの前処理とネットワークの学習

実際にネットワークの学習時に問題となるのは, 学習データの量ではなく質であり, それゆえあらかじめデータに前処理を施し, 何らかの特徴量を抽出しておくことで学習の高効率化が望まれる場合が多い [5][6]. 本研究においては, 前処理として主成分分析を探傷信号に施している. これは古典的な統計処理手法の一つであり, データ空間に新たな座標軸を設定することで, わずかな損失で情報の圧縮を可能とするものである. これにより, 学習データに主成分分析を施すことによって, 99.9%の情報量を保存したままでデータの次元をおよそ 1/6 にまで圧縮することが可能であった.

本研究において用いたのは, ニューロンが層状に配置され, 情報はその中を一方向のみに伝達されるという特徴を持つ, 階層型のフィードフォワード型ニューラルネットワークである. 学習時には Backpropagation 法によって各ニューロンの結合強度および閾値についての勾配を算出し, 共役勾配法によって最適化を行うことになる. 学習の効率化という点ではネットワークを小型化することが望ましく, それゆえ隠れ層の数は 1 とし, また解析領域全体を一度に取り扱うのではなく, 複数の小型のネットワークによって解析領域の一部分ずつを再構成し, 最終的にそれらの重みつき重ねあわせを行うという手順をとる.

2.3 欠陥形状の再構成

2.3.1 解析体系

ここでは数値解析によってネットワークの学習用データベースを作成する. 解析体系図を Fig.2 に示す. インコネル 600 製 1/4 管モデルを解析体系として採用した. 使用したプローブは高機能 4 センサープローブ [7][8] であり, 励磁周波数は 400 kHz, リフトオフは 1 mm である.




Fig. 2 Numerical configuration of neural network approach.

欠陥直上の走査線からの信号を用いて欠陥形状の逆解析を行う。今回は軸方向、管内面に発生した欠陥のみを対象とする。なお、データーベース作成時には、パラメーター空間内における均一な分布を得るために欠陥形状、内部導電率分布ともに乱数を用いて決定している。なお、計算労力の低減のためデーターベースの作成には高速順問題解析法 [9] を適用した。

2.3.2 再構成結果

ネットワークの学習終了後、同じく数値計算によって得られた探傷信号より欠陥形状の再構成を行った。再構成の例を Fig.3 に示す。図中網掛の領域が真の欠陥形状を、太線が再構成された欠陥境界形状を示すものであり、要素内の数字はその要素が持つ導電率を試験片母材に対して百分率で表したものである。再構成誤差は、真の欠陥形状と再構成されたもののとのずれの要素数と定義した。検証のために用いた 200 組の逆解析結果に対して誤差の平均値は 15.03 と、きわめて良好な精度での再構成が行われていることが確認された。さらに、学習データ、検証用未知データの両方に 20% の人工白色ノイズを加えた場合でも誤差平均値は 16.38 であり、依然として良好であった。

2.4 まとめ

ここでは、ニューラルネットワークを用いて内部導電率分布を持つ欠陥の形状推定する手法を紹介した。

本手法の優れた特徴の一つは、再構成に要する計算時間の短さである。ニューラルネットワークを用いた逆解析時には反復計算を行う必要がないため、ほぼ瞬時に再構成を行うことが可能である。学習用のデーターベースの構築には数日程度の計算を要し、またネットワークの学習および構造の最適化にも半日程度は必要であるが、それらはオフライン時に行うことができるため、実用上問題とはならないと考えられる。また、雑音に対して強いというのも、注目すべき特徴である。

しかしながら、解析領域を厚さ方向に 1 要素のみで分割しているために、複数欠陥や体積型の欠陥を取り扱うことは困難である。また、現在は走査線は欠陥直上を通るという条件を課し、欠陥と走査線の位置関係は既知としている。データーベースの 3 次元化を行えば同様の手法が適用出来るようになるのだが、それに伴う必要なデーターベースの巨大化とネットワークの学習の困難さの増大は著しいものがあることが予想さ

れる。

最大の問題点は、全ての欠陥パラメータを陽に取り扱っていないために、得られた結果から信号を計算するということができないということである。ニューラルネットワークを用いた逆解析では、特に学習データと著しく異なった未知データに対しては、完全に正解と一致する出力を得ることは困難である。各再構成結果ごとの精度評価を行うことが困難というのは、非破壊検査の信頼性という観点からも無視することができない。

3 勾配法に基づく欠陥再構成

3.1 再構成手法

3.1.1 共役勾配法に基づく再構成アルゴリズム

前節において紹介した手法では、ニューラルネットワークを用いて渦電流探傷信号—欠陥パラメータ間の写像そのものを取り扱うことで形状の再構成を行った。ここでは、勾配法に基づく、パラメータ推定による再構成手法を紹介する。このような手法においては、欠陥を適当にパラメータ化し、再構成された欠陥からの探傷信号 Z と測定信号 Z^o に対して、総誤差関数

$$\varepsilon = \sum_{i=1}^N \omega_i |Z_i(\mathbf{c}) - Z_i^o|^2 \quad (1)$$

を最小化するような欠陥パラメータ $\mathbf{c}$ を求めることになる。ただしここで添え字の i は i 番目の信号測定点を表すものとし、 ω_i は適当な重み関数とする。

式 (1) はいわゆる非線形の最適化問題であるため、通常はパラメータ $\mathbf{c}$ に対する勾配 $\partial \varepsilon / \partial \mathbf{c}$ を求め、反復計算によって最適値を求めることになる。渦電流探傷法においては、文献 [10] により、欠陥パラメータベクトル $\mathbf{c}$ に対する総誤差関数の勾配は、 $\mathbf{E}$ を欠陥が存在する場合の電場、そして $\tilde{\mathbf{E}}$ をその随伴場としたときに、

$$\frac{\partial \varepsilon}{\partial c_i} = 2 \operatorname{Re} \left\{ \sum_{i=1}^N \{Z_i(\mathbf{c}) - Z_i^o\}^* \frac{\partial Z(\mathbf{c})}{\partial c_i} \right\} \quad (2)$$

$$\frac{\partial Z(\mathbf{c})}{\partial c_i} = -\sigma_0 \int_{flaw} \mathbf{E}(\mathbf{r}) \cdot \tilde{\mathbf{E}}(\mathbf{r}) \frac{\partial v(\mathbf{r})}{\partial c_i} d\mathbf{r} \quad (3)$$

$$v(\mathbf{r}) = \frac{\sigma_0 - \sigma(\mathbf{r})}{\sigma_0} \quad (4)$$




Fig. 3 Reconstruction results of conductive cracks from simulated signals.

と与えられることが示されている。これらに基づいて勾配を計算し、得られた値を用いて、ここでは共役勾配法を適用して最適解を求めた。計算の流れを Fig.4 に示す。

3.1.2 欠陥モデル

式 (2)-(4) はいかなる欠陥パラメータに対しても勾配値を与えることができるため、例えば文献 [11] にあるように、探傷信号からの複数の欠陥の同時再構成もほぼ同様な手法を用いて可能である。しかしながら、ここでは簡単のため、対象とする欠陥を単独で発生した平板状の表面欠陥に限定する。複雑な境界形状を取り扱うために境界は折れ線で表し、また実際の自然欠陥には内部接触などが存在するであろうことも考慮して、

内部導電率も 0 でない適当な均一値とした。用いたモデルの図を Fig.5 に示す。このような欠陥パラメータに対し、具体的に式 (2)-(4) に基づいて各パラメータの勾配値を算出する手法については、例えば文献 [9] に詳しい。

3.2 欠陥形状の再構成

3.2.1 解析体系

解析体系を Fig.6 に示す。厚さ 1.25 mm のインコネル 600 製平板に欠陥が発生し、標準パンケーキプローブ [12] を用いて探傷を行ったものとしている。パンケーキプローブの励磁周波数は 300 kHz であり、リフトオフは 0.5 mm とした。発生した欠陥は平板状の




Fig. 4 Inversion scheme of the gradient approach.




Fig. 5 Crack model for the gradient approach.

表面欠陥とし、走査線は欠陥と平行である。

3.2.2 再構成結果

数値解析の結果得られた信号を用いて、内部で一様な導電率 ($21\%\sigma_0$: σ_0 は母材の導電率) のを持つ半楕円形状欠陥の再構成を行った例を Fig.7 に示す。欠陥が探傷面側に発生したということは既知としており、欠陥は厚さ 0.2 mm の平板状としている。このとき再構成すべきパラメータは欠陥の境界形状及び走査線との位置関係 (すなわちそれぞれの境界離散点の座標), そして内部導電率である。境界線は 7 点で離散化を行った。再構成に用いたのは、欠陥と平行である 1.5 mm 間隔の 5 本の走査線上から得られた、1 本あたり 0.5 mm 間隔 41 点、計 205 点からの探傷信号である。実環境下では信号に何らかの雑音加わることが考えら

れるが、ここでは信号に雑音は加えず、数値解析によって得られたものをそのまま用いている。

Fig.7(a)(b)(c)(d) がそれぞれ初期推定形状、ステップ 50, ステップ 200, そして反復計算終了時の再構成形状を真の形状とあわせて示したものであり、図中太線が再構成された形状を、網掛けの領域が真の欠陥形状を示している。初期推定形状が真の欠陥形状とかなり異なったものにもかかわらず、真の欠陥形状に非常に近い再構成結果が得られていることがわかる。

Fig.7(e) に、欠陥位置、すなわち欠陥と走査線との位置関係の再構成結果を示す。5 本の走査線からの信号を用いたということもあり、計算のかなり早い段階で真の値へと収束している。Fig.7(f) は再構成時における総誤差関数の減少を表したものである。局所的最小値を避けつつ、大域的最小値の探索が行われていることが明確に現れた結果となっている。なお、収束条件 $\epsilon < 1.0 \times 10^{-6}$ が満たされるまでには 1178 回目の反復計算を要したが、これは同様な手法を用いて内部導電率が 0 である欠陥の再構成を行った場合 [9][11] と比較すると必要な計算量は大きく増加したものとなった。計算時間は VT-Alpha500DP2 workstation (Alpha 21264-500MHz $\times$ 2, 2.0G Memory) 上でおよそ 1 時間ほどであった。

3.3 まとめ

ここでは勾配法に基づくパラメータ推定により、探傷信号から欠陥形状の再構成を行う手法の一例とその結果を紹介した。このような手法の最大の特徴は、いかなる欠陥パラメータに対しても総誤差関数の勾配値を計算することが可能であるため、どのような欠陥に対しても適用が可能であるという点である。また、再構成のための反復計算の各ステップにおいて総誤差関数の値を計算しているため、得られた形状がどの程度真の形状と近いのかという推測が行えるということも、




Fig. 6 Configuration for the gradient approach.




Fig. 7 Reconstruction result of a semi elliptic crack with uniform conductivity.

前節のニューラルネットワーク法にはない、優れた特徴である。

しかしながら、計算時間に関する問題は小さくないといわざるを得ない。総誤差関数の評価および勾配値の算出のためには各ステップごとに順解析を行うことが必要であり、それゆえ毎回電磁場解析を行わねばならない渦電流探傷逆問題解析には、かなりの計算労力を要するものとならざるを得ない。近年開発された高速順解析手法 [9] の適用によって現実的な時間のうちに再構成を行うことが可能となったが、依然として検査時におけるオンラインの欠陥再構成への適用は困難といえる。

さらに、良好な収束を得るためには適当な初期値を与えることも重要である。真の欠陥形状と大きく異なる初期推定形状を用いた場合、収束が極めて遅いか、もしくはまったくしないという事態を招く可能性すらある。初期値依存性は多くの勾配法にとって避けて通ることのできない問題であり、実際には何らかの手法を用いておおよその欠陥形状を推定しておく必要がある。


4 計算知能技術を用いた欠陥形状再構成

4.1 はじめに

これまでに、ECT の検査信号から、伝熱管のき裂形状の推定を逆解析により行う手法を提案されてきた。これは検査手続きを数学モデルによって記述し、パラメータ推定問題を解くことにより、欠陥形状の幾何学的情報を取得する計算法である [13][14]。これらの手法により、精度の高い形状評価が可能となったが、膨大な計算量が必要という問題が生じた。検査時間の高速化・短縮化をはかるには、現場での通常の計算機資源による速やかな計算処理が必要であり、モデルに基づくパラメータ推定をそのまま利用することは現実的ではない。またモデルにもとづく非破壊評価では、検査環境の厳密な数学的記述が必要であるが、現場での作業環境は予測不可能であり、観測における数学的記述にはあいまいさが介入せざるをえない。このような検査環境および検査の高速化仕様を考慮して、筆者らは形状推定に簡略化ファジィ推論を適用し、き裂形状の暫定的推論を行うことにより、形状推定機構全体の高速化を図る方法を提案した [15]。提案した計算手法では、推定に要する時間や推定精度はファジィ推論への前件部への入力情報に依存しており、量的な情報としての計測情報から推定を行うに当たり、有効な情報を縮約し抽出する為の技術、即ち、熟練者の持つ傷形状と ECT 検査信号の関係に関する知識の獲得が必要となる。以下においては、この熟練者の持つ知識獲得の手段を、順解析モデルを通じて自動的に獲得する方法について解説する。具体的には、ファジィ推論の前件部への入力情報として、遺伝的プログラミング (Genetic Programming ; GP) によって生成された関数により量的情報から質的情報へと変換を行ったものを用い、推論に必要な特徴量の抽出の自動化を行う手法について紹介する。

4.2 遺伝的プログラミング

自然界における生物の遺伝と進化の過程を分子生物学の知見から模倣して、組み合わせ最適化における (準)最適解を比較的短時間の間に効率良く求めるための手法として、EC があり、その代表的なものが遺伝的アルゴリズム (Genetic Algorithm ; GA) である。GP は、EC という枠組みの中にあつて、この GA を拡張したものであるといえる。その大きな特徴は、Fig.8



infix notation : $(x + a) * y$

postfix notation : $xa + y*$

Fig. 8 A syntax tree based on postfix notation.

のごとく、遺伝子型 (Genotype) として、グラフや木のような構造的表現を扱うことが可能であるという点であり、主としてプログラムや関数の自動生成などに応用されている [16][17][18]。

その他の手法と異なり、GP は、基底関数を用いることなく、その関数そのものを生成することができるために、探索空間が広く、表現できるクラスが大きい。以下では、このような GP の特徴を活かし、量的な情報からの特徴抽出と特徴選択を行うことのできる関数を生成することを目的として GP を適用する。二項演算子、単項演算子、定数、変数から構成される関数 (数式) を、スタックを用いて計算が容易になるという点から、後置記法 (Postfix notation) に基づいて、Fig.9 のように、遺伝子へのコーディングを行うことが可能である。Table 1 に、関数を構成する為に用いた演算子の種類を挙げる。

さらに、これらの関数を複数組み合わせ、次に述べるファジィ推論で用いる validity も含めて、メタレベルでの組み合わせを行い、これを一つの個体とする。Fig.9 は各個体の表現方法の例を示したものであ




Fig. 9 A candidate solution including multiple functions.

Table 1 Genotype and operators.

Genotype	Operators	
1	+	Binary
2	-	
3	*	
4	max	
5	min	
6	sin	Unary
7	cos	

る。それぞれの関数の組み合わせは、validity によって決定される。即ち、特徴抽出はそれぞれの関数により、そして特徴選択は validity により行われる。この場合、遺伝的操作としては、二つのレベルから考えられる。一つは、関数の組み合わせを交換する交叉や、validity ラベルの変更による組み合わせの突然変異を行い、メタレベルから関数の組み合わせを変化させるものである。もう一つは、それぞれの関数に着目し、二つの関数の間でランダムに選んだ部分木を交換する交叉や、ノードのラベルを同種のもので置き換えるものの、関数の構造は変えずに定数のみを置換し、山登り的なフィッティングを行うもの、そして枝の挿入や圧縮といった関数の構造を変える突然変異を行うものである。選択方法としては、連続世代モデルであり、一世代における世代交代の少ない定常状態遺伝的アルゴリズム (Steady-State GA; SSGA) に基づいて行うことができる [20]。環境適応度に関して、以下の評価関数を導入する。

$$\text{fitness} = W_1 \cdot E + W_2 \cdot n_i + W_3 \cdot L_i \quad (5)$$

ここで、 E は、目標値と計算結果の誤差であり、 n_i はファジィ推論機構への入力次元、 L_i は各関数の長さを示している。これらの重み付けを考慮した和を、各個体の評価値とし、この最小化を行うものとする。 n_i の具体的な表現は次式のようになる。

$$n_i = \sum_{j=1}^m f_{i,j}^{\text{val}}, \quad \text{for } f_{i,j}^{\text{val}} = \{0, 1\} \quad (6)$$

この評価値を小さくすると、ファジィ推論機構への入力次元 n_i が少なく取るように働き、結果として、ファジィルールの数が少なくなり、その構造を簡潔なもの




Fig. 10 Block diagram of fuzzy learning mechanism with functions (T) generated by GP selection.

とする。また、各関数の長さ L_i の項を加えることにより、関数の表現が必要以上に冗長、複雑なものなることを抑制する働きをしている。

4.3 簡略化ファジィ推論による形状推定機構

き裂形状の特徴量 $\mathbf{q}$ に対応するコイルのインピーダンス変化の計算量 $\{\Delta Z_d\}(\mathbf{q})$ に関する変化の特徴量を $n(< p)$ 次元のベクトル量

$$\{\mathbf{u}\} = T \circ \{\Delta Z_d\}(\mathbf{q}) \quad (7)$$

を得るための変換 T を GP により行い、この特徴量をファジィ推論機構の入力変数にとる。Fig.10 は遺伝的プログラミングの前処理による簡略化ファジィ推論を用いた推定機構の学習フェーズを示したものである。

GP により生成された関数は、学習後のエラーを通して間接的に評価される。即ち、学習後のエラーが小さくなる場合には、GP により学習しやすい情報(特徴量)に変換されていると考えられる。その反対に、エラーが大きくなる場合は、その関数が変換前のデータから特徴をうまく抽出できていないためであると考えられる。推論機構の出力はき裂形状に関するパラメータベクトル $\mathbf{q} \in R_s$ である。ファジィ集合を $A_{i,j}$ ($i = 1, \dots, n; j = 1, \dots, m$) であらわすと、 k 番目のファジィルールは

IF u_1 is $A_{1,j(1,k)}$ and $\dots$
and u_n is $A_{n,j(n,k)}$

THEN q_1 is w_k^1 and $\dots$ and q_s is w_k^s

で記述できる。簡略化ファジィ推論においては、後件部 w_k^r ($r = 1, \dots, s$) が単なる実数値で与えられる。

前件部のファジィ集合 $A_{i,j}$ に関するメンバーシップ関数を $\mu_{i,j(i,k)}(u_i)$ で表記すると、ルール k に関する適合度 μ_k は各メンバーシップ関数による代数積

$$\mu_k(\mathbf{u}) = \prod_{j=1}^n \mu_{i,j(i,k)}(u_i). \quad (8)$$

で計算できる。このようにして推論機構の出力値 $\mathbf{q}$ は w_k^r の適合度に関する期待値

$$\hat{q}_r(\mathbf{u}) = \sum_{k=1}^{m^n} \mu_k(\mathbf{u}) \cdot w_k^r / \sum_{k=1}^{m^n} \mu_k(\mathbf{u}). \quad (9)$$

で与える。後件部の実数値の集合 $\{w_k^r\}$ は簡略化ファジィ推論の学習則 [21] に基づいて調整し、推論機構を構築する。即ち、形状パラメータ $\mathbf{q}$ とファジィ推論機構の出力値 $\mathbf{q}(\mathbf{w})$ との自乗誤差

$$E(\mathbf{w}) = \frac{1}{2} \sum_{r=1}^s |q_r - \hat{q}_r(\mathbf{u}; \mathbf{w}^r)|^2. \quad (10)$$

が最小となるように $\mathbf{w}^r = \{w_k^r\}$ を調整する。

4.4 計算機シミュレーション

蒸気発生器伝熱管に使用されているインコネル 600 による平板の中心部に放電加工による人工き裂が作成されているモデルについて計算シミュレーションをおこなった。ここでは、コイルのインピーダンス変化から試験材料に存在する欠陥の幾何学的情報を復元することを目的としているので、欠陥が試験材料の表に存在するか、裏に存在するか、また、その位置、幅、長さはあらかじめ分かっているものとする。これらは、インピーダンス変化の絶対値により、容易に判別可能である。また、き裂幅は視覚情報から捉えられない程に狭いものとした。EC においては、有限な時間の中で効率的な計算を行うためには、個体群の多様性を維持することが重要である。特に GP においては、構造の多様性を維持するため、多くの個体数と試行回数を必要とするため、しばしばその計算量が問題となる。そこでまず、個体数を決定するための予備シミュレーションを行った。数値実験においては、個体数は 150 が適当で、それ以上個体数を多くすると、進化の速度が遅くなり、収束がかえって遅くなるという結果が得られた。そこで、パラメータ設定条件として、個体数を 150、最大個体長を 600、そして評価回数を 5000 回としてシミュレーションを行った。メンバーシップ




Fig. 11 Experimental environment in Example.

関数数は 3、ファジィ推論への最大入力次元を 5 とし、ファジィ推論の出力は 6ヶ所についての、深さに関する形状情報をとった。これらの結果から、GP を適用することにより、教師データとして与えられた量的な計測データから、ファジィ推論システムが、推論・学習しやすいデータへと変換されており、それはテストデータに対しても有効であるということが確認された。最後に、この結果をもとに、検査環境に介入するあいまいさを考慮して、き裂方向に対し、計測時の走査方向がずれている場合の計測結果に対して、提案手法を適用した結果を示す。すなわち、実験環境として、Fig.11 に示されるように、走査方向が欠陥方向に対して斜めにずれている場合について、その推定性能を調べた。この実験環境における結果を Fig. 12 に示す。この結果から、走査方向にずれが生じている場合でも、良好な推論結果を得られている。

4.5 まとめ

本節では、熟練者の持つ、欠陥形状と ECT 検査信号との関係に関する知識の獲得を目指し、ファジィ推論への特徴量抽出に GP を適用し、その情報を用いることによりファジィ推論機構の学習が可能であることを示した。また、数値実験から測定時に生ずる誤差に関してロバストな推論機構であることを示した。ここで考えられている方法はきず形状の同定での高速化・高精度化をめざすというよりは、現実の検査環境下におけるあいまいさをどのように克服していくかが目的となる。熟練者は、検査データに埋もれている欠陥信号から欠陥情報に関する何らかの不偏量を抽出していると考えられる。この操作の過程を遺伝的プログラミングの特徴である数式による写像変換で構成してい




Fig. 12 Estimated results in Example.

けないかという試みである。いまのところ、この写像の適応度の評価は、ファジィ推論機構の出力を通じて間接的にしか最適化されないところに問題点がある。しかし、本稿で解説した他の2つの方法においては、検査環境の記述は最適化問題における制約として非明示的、明示的に与えねばならず、いわばハードな境界条件を有する。ここで考察した手法は今後の展開がまたれるが、問題の制約条件に柔軟に対応できる、いわばソフトな境界条件のもとで問題の可解性があり、今後の研究の進展がまたれる。

5 おわりに

本解説においては、渦電流探傷試験 (ECT) の高精度化を背景として開発中の逆解析技術のいくつかの取り組みを紹介し、それぞれの特徴および問題点について考察した。ここで取り上げた逆解析手法のほかにも多くの計算手法が提案されている。特に、遺伝的アルゴリズム (GA) を含む進化型計算手法をもちいた逆解

析の計算技法は多くの報告がある [22][23][24]。この方法では、欠陥に関する幾何学的形状を遺伝子情報に変換し、遺伝子操作により、多様な欠陥情報に関する環境適応度を通じて、もっとも検査データに近いきず形状を同定する計算手法である。この場合、多様な遺伝子情報に関する環境適応度の計算のため、順解析の計算をパラメータ推定の場合よりも多く繰り返し計算する必要がある。いまのところ、高速化に問題が残されている。しかしながら、蒸気発生器伝熱管の実際のきず形状は複雑であり、たとえば複数きずの同定などの従来解くのが困難であった問題に対して有効に働く可能性がある。本稿では、蒸気発生器伝熱管のきず形状に限定して議論したが、今後は材料の劣化評価などの高度な非破壊評価に関しては逆解析技術がより重要な位置を占めると考えられる。

謝辞

本稿に掲載された研究結果の一部は PWR5 電力会社と (株) 原子力エンジニアリングの委託により日本 AEM 学会内に設けられた「ECT による高精度欠陥診断技術に関する研究開発」分科会の成果の一部である。本稿をまとめるにあたり、この方面での逆解析技術の重要性をはやくから指摘され、常に活発な議論・激励を受けました AEM 学会会長の宮健三先生に深甚の謝意を表します。

参考文献

- [1] 坪井, 内藤 (編), 数値電磁界解析法の基礎, 養賢堂, (1994).
- [2] 坪井, 内藤 (編), 実践数値電磁界解析法, 養賢堂, (1995).
- [3] Sarle, W.S., ed. (1997), Neural Network FAQ, part 1 of 7, periodic posting to the Usenet newsgroup comp.ai.neural-nets, URL: <ftp://ftp.sas.com/pub/neural/FAQ.html>
- [4] 馬場, 小島, 小澤, ニューラルネットの基礎と応用, 共立出版株式会社, (1994).
- [5] Lalita Udpa and Satish S. Udpa, Application of signal processing and pattern recognition techniques to inverse problems in NDE. *Int. J. of Applied Electromagnetics and Mechanics*, Vol.8 (1997), pp.99-117.
- [6] R.C. Popa and K. Miya, A data processing and neural network approach for the inverse problem in ECT, *Electromagnetic Nondestructive Evaluation(II)*, IOS Press (1998), pp.297-304.

- [7] M. Kurokawa et al., New eddy current probe for NDE of steam generator tubes, *Electromagnetic Nondestructive Evaluation(III)*, IOS Press (1999), pp.57-64.
- [8] W. Cheng et al., Reconstruction of a Crack with a four sensor probe, *proc. of the eighth MAGDA conference*, (1999), pp.123-126.
- [9] 陳 振茂, 宮 健三, 高松 洋, 電磁非破壊検査の最近の進展 (2), 日本 AEM 学会誌, Vol.7, No.4 (1999), pp.382-392.
- [10] S.J. Norton and J.R. Bowler, Theory of eddy current inversion, *J. of appl. physics*, Vol.73, No.2 (1993), pp.501-512.
- [11] W. Cheng et al., Reconstruction of multiple crack from ECT signals using a database approach, *proc. of the second Asian Joint Seminar on Applied Electromagnetics*, JSAEM studies in Applied Electromagnetic and Mechanics 7 (1998), pp.169-174.
- [12] T. Takagi and K. Miya, ECT round-robin test for steam generator tubes, 日本 AEM 学会誌, Vol.8, No.1 (2000), pp.121-129.
- [13] 小島, 上坂 (編), 電磁現象と逆問題, 養賢堂, (1999).
- [14] 小島, 岡本, 大野, 有限要素境界要素併用法を用いた電磁場逆解析による蒸気発生器細管材料の亀裂形状推定に関する計算手法, 日本機械学会論文集 (C 編), Vol.63, No.612 (1997), pp.2650-2656.
- [15] 小島, 久保田, 谷口, 簡略化ファジィ推論を用いた原子炉蒸気細管内のき裂深さ推定に関する計算手法, 日本機械学会論文集 (C 編), Vol.65, No.637 (1999), pp.3614-3620.
- [16] J.R. Koza, Genetic Programming on the Programming by means of Natural Selection, The MIT Press, (1992).
- [17] J.R. Koza, Genetic Programming II: Automatic Discovery of Reusable Subprograms, The MIT Press, (1994).
- [18] 伊庭, 情報科学 遺伝的プログラミング, 東京電機大学出版局, (1996).
- [19] N. Kubota, F.Kojima, S.Hashimoto, and T. Fukuda, Information transformation by virus-evolutionary genetic programming, *Proc. 4th Int'l Symp. on Artificial Life and Robotics (AROB99)*, Vol.2 (1999), pp.504-507, to appear in Artificial Life Robotics.
- [20] G. Syswerda, A study on reproduction in generational and steady-state genetic algorithms, *Foundations of Genetic Algorithms*, Morgan Kaufmann Publishers, (1991).
- [21] 市橋, 渡辺, 簡略化ファジィ推論を用いたファジィ推論モデルによる学習制御, 日本ファジィ学会誌, Vol.2, No.3 (1990), pp.429-437.
- [22] N. Yusa, T. Uchimoto, Z. Chen and K. Miya, Application of genetic algorithm to ECT inversion problems, *Proc. the 4th Japan-Central Europe Joint Workshop on Energy and Information in Nonlinear Systems*, Brno (CR) to appear.
- [23] N. Kubota and F. Kojima, Coevolutionary optimization in uncertain environments *Proc. the 4th Japan-Central Europe Joint Workshop on Energy and Information in Nonlinear Systems*, Brno (CR) to appear.
- [24] 小島, 藪木, 久保田, 高木, 進化型計算による蒸気発生器伝熱管の IGA/SCC き裂のプロファイリング, 第 10 回 MAGDA コンフェレンス予稿集, (2001), pp.129-132.