

第4章 回転磁束型磁気センサによる欠陥属性の自動推定

第4. 1節 緒言

発電所の蒸気発生管や化学プラントの熱交換機などの配管の検査には、以前から渦電流探傷用磁気センサなどが用いられている。磁気センサからの信号をペンレコーダなどで記録し、技術者が蓄積した経験や勘に頼りながら欠陥の有無やその属性の判定を行っていた^[4]。この方法では、高度の技術を持った技術者の確保やその技術の維持が経済性などの関係で問題となっていた。

一方、最近のパーソナルコンピュータやワークステーションを中心とする個人で占有して使用できるコンピュータの高度な発達は、従来、大型コンピュータを備えた計算機センターで順番を待ってできなかつたような大容量の計算を身近なものとしている。有限要素法や境界要素法による構造解析や磁界解析などは、そのよい例である。また、機器組込型のコンピュータ、たとえば、化学計測装置や電子測定器などできその高度な計算能力と大きな記憶容量を利用して、その機器本来の測定機能以外の機能をたくさん備えている。たとえば、オシロスコープのFFT解析機能やホストコンピュータとの通信機能、大量のデータの蓄積機能などである。さらに、最近、医療の現場で頻繁に使用されるようになっている超音波やX線断層診断装置は、大量で高速な演算を要求される逆問題の代表であるComputed Tomographyをコンピュータの力で成功させたよい例である^[89-90]。

広い意味で非破壊評価技術を構成し、最近特に注目されている技術の中に、磁気センサからの出力を利用して欠陥の有無だけではなく欠陥属性（位置、幅、深さ、形状など。）を自動的に推定するという技術がある^[8]。この欠陥属性自動推定問題は、結果から原因を求める逆問題の典型例の一つである。このような、逆問題を解くには、まず最初に問題となっている現象を数式で表し、入力と出力の関係を規定し、逆マトリクスを求め、出力から入力を求める方法で解決する方法が基本である。磁気センサで言えば系の支配方程式は、マックスウェルの電磁方程式である。しかし、この支配方程式は、ごく特殊な場合以外は解くことができず、まして、逆マトリクスを求めることは一般に不可能である。さらに、逆問題では、方程式を解くための既知数や方程式数が不足する場合がほとんどである。たとえば、磁気センサによる欠陥属性自動推定問題では、一般に、被検査材に磁界を印可し、被検査材表面の磁界の分布を測定する。このことは、3次元に広がる電磁現象を2次元の観測データで推定することになり、既知数や方程式数が圧倒的に不足する。そこでこの問題を解決するためには、なんらかの仮定や近似、既知条件を導入しその答えを求める方法がとられる。それでも、いつも最適な解が得られるとは限らない。このように磁気センサによる欠陥形状推定問題は多くの難しい問題を含んでいる。一方、上記のようないわば正攻法で逆問題を解くのではなく、知識データベースを構築しAI的に解決する方法^[51]やパターン認識能力に優れるニューラルネットワークを用いる方法^[53]、広い解探索能力を持つジェネティカルゴリズムを用いる方法^[68]、これらを組み合わせて用いる方法などが研究され、一定の成果をおさめている。さらに、知識データベースの構築やニューラルネットワークの学習、ジェネティカルゴリズムの訓練には、大量のデータが必要とされ、データを蓄積するためには一般に、実験によってデータを蓄積する方法が取られてい

る。しかし、このような方法でもコンピュータの計算能力は、問題解決のためには不可欠である。また、コンピュータの発達と有限要素法などの数値解析法の発達によって、シミュレーションでこれらのデータを準備する方法^[90]も可能となってきているが、この場合には、さらに大きなCPUパワーが必要となる。

そこで、本論文では、欠陥属性推定問題に対しても回転磁束型磁気センサの優位性を示すことを目的として、欠陥に関する情報収集能力に優れる回転磁束型磁気センサに、パターン認識能力に優れるニューラルネットワークを組み合わせ、欠陥属性推定問題に適用した^[91-92]。ニューラルネットワークの学習は、実験によって準備したデータを主に使用した。

第4. 2節は、ニューラルネットワークを逆問題に適用する場合の注意点や問題点を整理し、誤差逆伝搬型階層構造ニューラルネットワークを回転磁束型磁気センサと組み合わせ欠陥属性推定問題に適用するための訓練法などを示す。第4. 3節は、空心蝶型磁気センサや3軸差動ピックアップコイル回転磁束型磁気センサと組み合わせ、軟鋼板裏側欠陥の位置や深さ、欠陥の方向角 ϕ などを自動推定した例を示し、この方法の有効性を明らかにする。第4. 4節では、3軸差動ピックアップコイル回転磁束型磁気センサと組み合わせ、ステンレス板裏側欠陥の形状推定や形状と深さの同時推定の結果を示し、この方法がよく欠陥の形状などを自動推定することを示す。第4. 5節では、第4章で得られた成果を総括する。

次に、欠陥属性推定問題へニューラルネットワークを用いる手順を示す。

- 1) 実験や有限要素法などを用いる計算力学シミュレーションによってニューラルネットワークに学習させる学習データを準備する。
- 2) 準備した学習データと対をなす教師信号を用意し、両データをペアで提示し、ニューラルネットワークに学習させる（訓練する。）。
- 3) 学習の終了したニューラルネットワークに未知の欠陥を持つ被検査材を測定することにより得たデータを与え欠陥の属性の推定を行う。

ここで用いたニューラルネットワークは、慣性項付き誤差逆伝搬型 3 層構造ニューラルネットワークである。Fig. 4-1 に実験に用いたニューロンを示す。なお、Fig. 4-1 に示すニューロンの数理モデルは、1943 年に W. S. McCulloch と W. H. Pitts が提案したものである。このニューロンの入出力関係を(4-1)式と(4-2)式に示す。

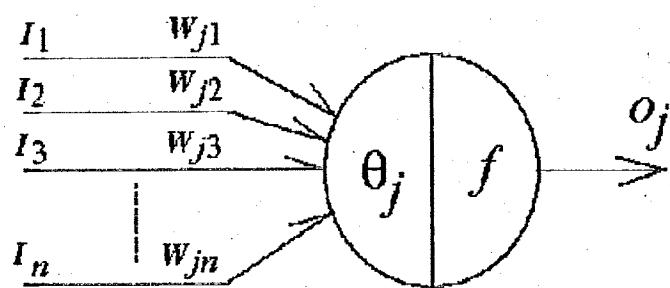


Fig. 4-1 Signal processing unit of the neural network.

$$o_j = f(U_j) = 1 / \left\{ 1 + \exp (-2U_j / U_0) \right\} \quad (4-1)$$

$$U_j = \sum_{i=1}^l w_{ji} \cdot I_i + \theta_j \quad (4-2)$$

o_j : j 番目のユニットの出力。

U_j : j 番目のユニットの内部ポテンシャル。

$f(x)$: 応答関数。ここでは、シグモイド (Sigmoid) 関数。

U_0 : シグモイド関数の温度。

w_{ji} : i 番目のユニットから j 番目のユニットへの結合係数。

I_i : i 番目のユニットから j 番目のユニットへの入力。

θ_j : j 番目のユニットのオフセット。

ここで、入出力データは、0から1[0, 1]に規格化する。 U_0 は、シグモイド関数の温度と呼ばれるシグモイド関数の傾きを変化させるパラメータである。 U_0 が大きいと傾きが急で出力はデジタル的になり、 U_0 が小さいと傾きが緩かになり出力は、アナログ的に変化する。

また、ここでは、ニューラルネットワークの構造は、欠陥属性推定問題のような定量的なマッピング問題に適している Feedback 結合を含まない(Feedforward 型)階層型ニューラルネットワークを採用した。階層型ニューラルネットワークは、1958年に F. Rosenblatt が提唱した Perceptron 型のニューラルネットワークである。さらに、1986年に D. E. Rumelhart らが考案した誤差逆伝播学習則(Error Back Propagation: EBP)を組み合わせた。

また、我々の目的である回転磁束型磁気センサによる欠陥属性推定問題においては、入力層(Input layer)、隠れ層(中間層、Hidden layer)、出力層(Output layer)の3層構造を使用した。Fig. 4-2 に3層構造の階層型ニューラルネットワークの概略図を示す。

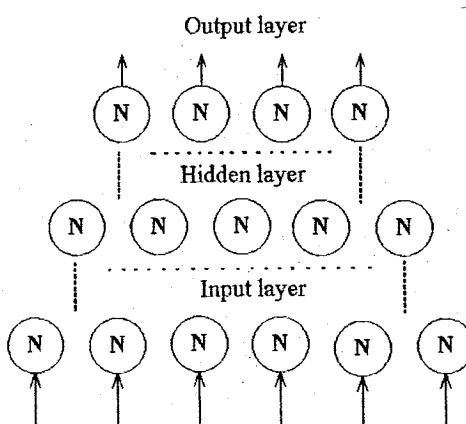


Fig. 4-2 Hierarchical neural network architecture.

学習アルゴリズムとしては、教師信号と出力信号の2乗誤差が最小となるように、最急降下法を用いて出力層と隠れ層間、隠れ層と入力層間の結合係数 W を順次変更し学習させてゆく誤差逆伝播学習則である。誤差修正法は、逐次型を採用した。よって、誤差 E は、(4-3)式で表される。

$$E_p = \sum_{k=1}^n \frac{1}{2} (T_{pk} - O_{pk})^2 \quad (4-3)$$

E_p : p 番目の学習データに対する2乗誤差。

T_{pk} : p 番目の学習データにおける k 番目の出力ユニットの教師信号。

O_{pk} : p 番目の学習データにおける k 番目の出力ユニットの出力信号。

n : 出力ユニットの数。

錯誤が必要である。しかし、ある程度の指針は存在する。本研究では、以下の点を考慮して各パラメータを仮定しながら実験を行った。

- 1) ニューラルネットワークの層数、各種ユニット数
ニューラルネットワークの層数は、一般に2層から4層がよく用いられているが、3層でほとんどの用途に応用することが可能である。
- 2) 繰り返し学習回数
繰り返し学習回数とは、パターンを何度も提示しても2乗誤差がある値よりも小さくならない場合に学習を打ち切るために設定する値である。一般に問題の初期の場合は十分大きな値を設定する。
- 3) 興奮性の信号値、抑制性の信号値
興奮性の信号値、抑制性の信号値とは、入力信号や教師信号の最大値、最小値のことである。シグモイド関数を用いる場合には、プログラム内で型宣言された変数の扱える数値の範囲を超えないように決定される。また、教師信号は0や1に近い0.1や0.9を用い出力層の入力値が $-\infty$ や ∞ にならないようにする。
- 4) BP学習法の学習係数 (α)
一般に、 α は大きい方が学習回数が少なくなるが発散や振動が起こる可能性がおおきい。そこで、問題の初期の段階では、小さい値を設定する。
- 5) 慣性項の係数 (m)
これも問題の初期の段階では、小さい値を設定する。
- 6) シグモイド関数の傾き (ϵ)
 ϵ は、出力がデジタル的な場合は大きくし、アナログ的な場合は小さくする。
- 7) 初期結合荷重の乱数値幅
一般に、小さい値の乱数で設定される。ここで用いたプログラムでは2とした。

以上が、回転磁束型磁気センサの欠陥検出信号を利用して欠陥の属性を推定する場合に用いた階層型ニューラルネットワークの概略である。

また、3軸差動ピックアップコイル回転磁束型磁気センサとニューラルネットワークを組み合わせた実験装置をFig. 4-3に示す。ニューラルネットワークは、プログラムで実現した。プログラミング言語は、Windows NT上のVisual Basic Ver. 5.0である。

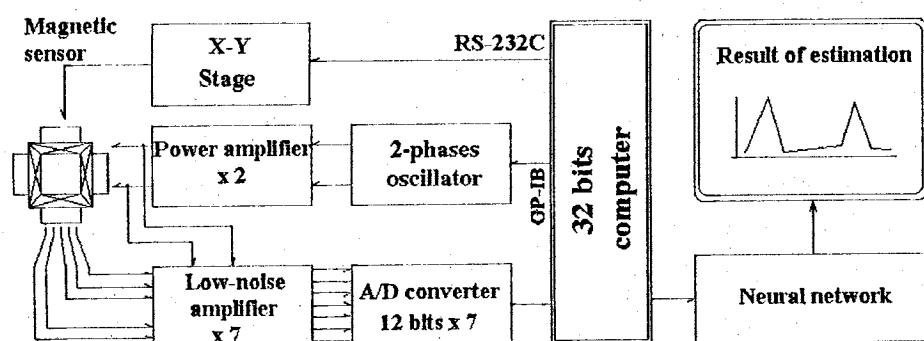


Fig. 4-3 Measurement system with neural network.

第4. 3節 軟鋼板裏側欠陥の属性推定

4. 3. 1 概要

第4. 3節では、空心蝶型磁気センサや3軸差動ピックアップコイル回転磁束型磁気センサとニューラルネットワークを組み合わせて、軟鋼板裏側欠陥の属性を自動推定した結果を示し、回転磁束型磁気センサが欠陥属性推定問題に対しても従来の磁気センサに比べて優位であることを示す。

回転磁束型磁気センサは、被検査材表面の磁束密度の分布を3軸方向に分離してその大きさや位相の変化を測定できることから、欠陥に関する情報が多く得られる。この多数の情報を利用すれば、溝型欠陥の場合、欠陥の上を1回だけ走査することで位置、深さ、方向角などを同時に推定することができる。位置や深さは、従来の磁気センサでも推定は可能だが、方向角 ϕ は、1回の走査での推定は無理である。もし、従来の磁気センサで欠陥の方向角 ϕ を推定しようとすれば、最低2回の走査が必要である。この走査回数が減少することは、欠陥の探傷時間を短縮することになる。これは、経済的観点から迅速さを要求される非破壊評価技術にとって大きな利点である。

4. 3. 2 欠陥の位置と深さの推定

(1) 有限要素法を使用した深さ推定

ニューラルネットワークを希望の入出力関係を得るために学習させる学習データは、実験で用意するのが一般的である。学習データを実験で用意するには多大の時間を必要とするのみならず、実験では物理的に測定困難で必要なデータを準備できない場合も少なくない。しかし、近年のコンピュータの発達により計算力学シミュレーションが盛んに行われ、実験では、準備しがたい学習データなどを計算力学シミュレーションを用いて準備することも可能となっている。ここでは一例として、空心蝶型磁気センサの有限要素法を使った欠陥検出特性のデータを学習データとしてニューラルネットワークを訓練し、実験で得た未知データによる欠陥の位置と深さの推定結果を示す。

学習データは、第2. 2. 5項のFig. 2-38に示したメッシュを用いて同様の条件下計算した $B_{x\max}$ の値を0から1に規格化して使用した。計算結果の $B_{x\max}$ と規格化した $B_{x\max}$ のグラフをFig. 4-4とFig. 4-5に示す。また、未知データとなる実験による $B_{x\max}$ のデータをFig. 4-6に示し、Fig. 4-7に規格化したデータを示す。さらに、Fig. 4-8に教師データ(教師信号)として用意したデータを示す。ここでは、欠陥の位置($x=0$ mm)に、欠陥の深さが4 mmであれば、0.9を、3 mmであれば、0.7を、2 mmであれば、0.5を、1 mmであれば、0.3を、0 mmであれば、0.1をそれぞれ与えた。このように教師信号の大きさを決めたのは、前節で述べたように入出力関数として用いているシグモイド関数の出力値である0から1との整合をとったためである。

入力層のニューロンの数は、41、隠れ層のニューロンの数は、41、出力層のニューロンの数は、21である。入力層のニューロンの数は、 $B_{x\max}$ を測定した点の数と同じとしている。このように出力層のニューロンの数を多くし、欠陥の位置とニューロン

の番号が対応するようしている。これは、推定値を出力したニューロンの位置が直接欠陥の位置を表すことになり推定結果の判定が容易に行える利点があるからである。また、測定点の数と入力層のニューロンの数を等しくすることによって、測定したデータをすべて有効に活用するためである。以後の欠陥属性の推定問題でも同様の理由でニューラルネットワークの入力層のニューロンの数や出力層のニューロンの数を決定している。ここで用意した学習データの数は、5であり、未知データの数は、5である。

このときのニューラルネットワークの学習は、次の条件で行った。学習係数 α は、0.8、シグモイド関数の傾き ε は、0.1、モーメント係数 β は、0.9とし、誤差 0.001 を目標に 10,000 回学習した、10,000 回の学習の後でも、誤差は、0.001 には達しなかつたが、0.01 は充分下回っていた。

Fig. 4-9 に推定結果を示す。欠陥の位置については、4 mm から 1 mm の傷までよく推定している。また、欠陥の深さについては、4 mm の場合と 3 mm の場合は、ほぼ正しく推定している。しかし、2 mm、1 mm の場合は実際より大きく推定し、欠陥なしの場合も 1 mm と推定し多少誤差が大きい結果となっている。これは、学習データを作成した有限要素法による空心蝶型磁気センサのシミュレーションが 2 次元で行っているなどのためである。以上の結果より、計算力学シミュレーションで学習データを作成する方法は、より厳密なシミュレーションを行う必要があることが分かったが、ここで用いた方法でも欠陥の深さがある程度深ければよい推定結果がえられ、計算力学シミュレーションで学習データを作成する方法は、簡単な準備で欠陥の深さや位置の推定を行うことができる有効な方法である。

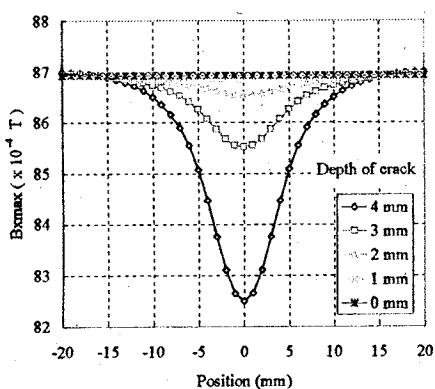


Fig. 4-4 $B_{x\max}$ (F.E.M.).

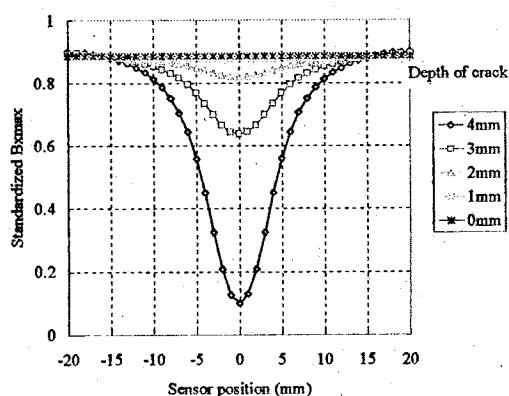


Fig. 4-5 Standardized $B_{x\max}$ (F.E.M.).

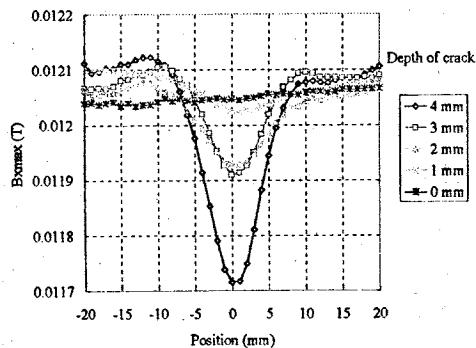


Fig. 4-6 $B_{x\max}$ (Exp.).

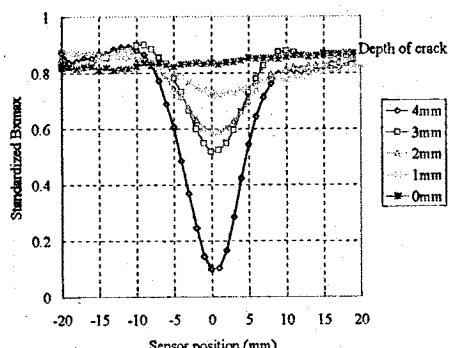


Fig. 4-7 Standardized $B_{x\max}$ (Exp.).

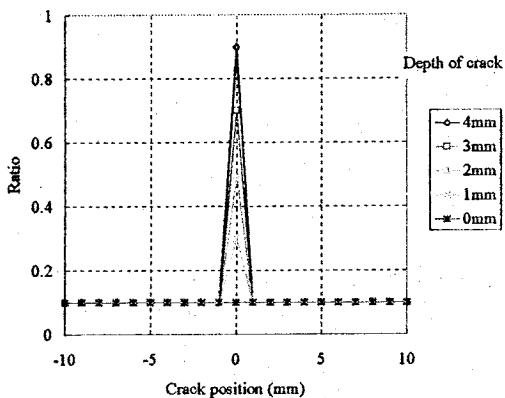


Fig. 4-8 Teaching Data.

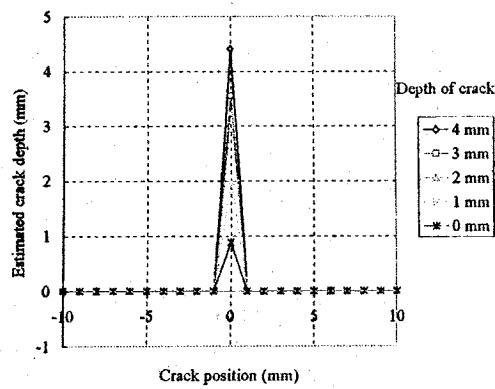


Fig. 4-9 Results of estimation.

(2) 位置と深さの同時推定

次に、3軸差動ピックアップコイル回転磁束型磁気センサをニューラルネットワークと組み合わせ、軟鋼板裏側欠陥属性の自動推定に適用した結果を示す^[28]。ここで推定した欠陥の属性は、欠陥の位置と深さである。欠陥の深さについては、4 mmから2 mmを対象にし1 mmの場合は除いた。

入力層のニューロンの数は、243、隠れ層のニューロンの数は、42、出力層のニューロンの数は、21である。入力層のニューロンの数は、 $\delta B_{x\max}$ 、 $\delta B_{y\max}$ 、 $\delta B_{z\max}$ のすべてのデータを利用して欠陥を推定するため、測定点の数(81) × 3としている。出力層のニューロンの数は、被検査材の中央 ± 10 mmを1 mmステップで表示することにし、21としている。このときのニューラルネットワークの学習は、次の条件で行った。学習係数 α は、1、シグモイド関数の傾き ϵ は、0.3、モーメント係数 m は、0.8とし、誤差0.0001を目標に20,000回学習するように設定した。5,886回の学習の後に誤差は、0.0001に達し、学習を終了した。なお、隠れ層の数と各係数は、予備実験により経験的に求めた。

Fig. 4-10からFig. 4-18に欠陥の位置と深さの同時推定問題に用いた学習データを示す。Fig. 4-10からFig. 4-12は、欠陥の深さ2 mmのデータ、Fig. 4-13からFig. 4-15は、欠陥の深さ3 mmのデータ、Fig. 4-16からFig. 4-18は、欠陥の深さ4 mmのデータである。これらのデータは、欠陥の位置を1 mm間隔で移動しながら測定を行った結果である。また、未知データは、各深さの欠陥について任意の位置に欠陥を移動し2箇所測定したデータとした。学習データの数は、63であり、未知データの数は6である。Fig. 4-19からFig. 4-21に各深さの欠陥と位置に対応した教師データを示し、Fig. 4-22に位置と深さの同時推定に用いた未知データを示す。Fig. 4-23に位置と深さの同時推定の結果を示す。3 mmの深さの欠陥の場合が多少の誤差を含んだ推定結果となっているが、おおむねよくその位置や深さを推定しており、3軸差動ピックアップコイル回転磁束型磁気センサをニューラルネットワークと組み合わせる方法が有効であることを示している。

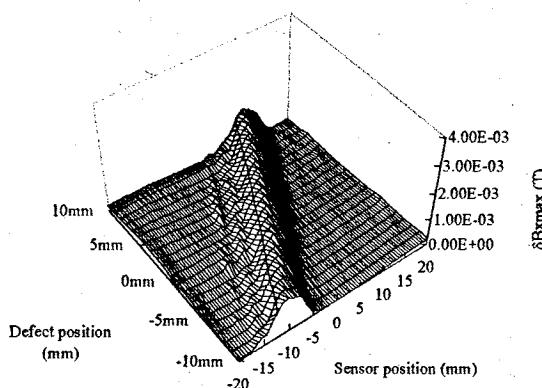


Fig. 4-10 Learning data
($\delta B_{x\text{max}}$, Crack depth = 2 mm).

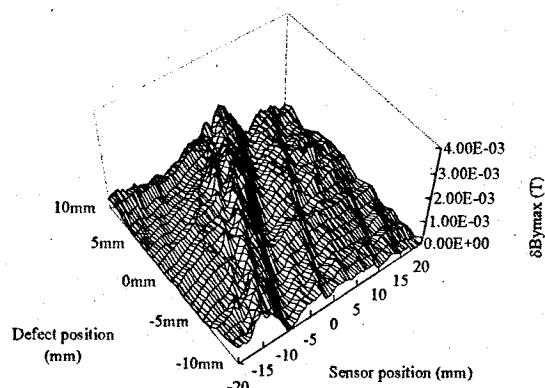


Fig. 4-11 Learning data
($\delta B_{y\text{max}}$, Crack depth = 2 mm).

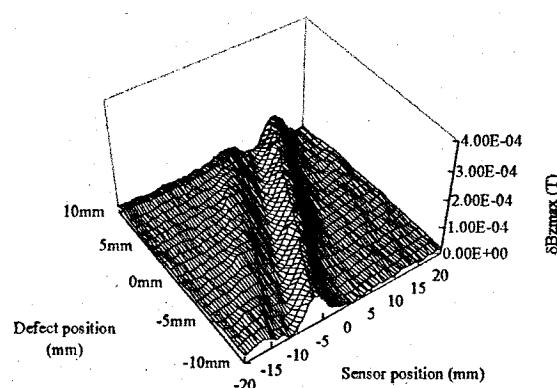


Fig. 4-12 Learning data
($\delta B_{z\text{max}}$, Crack depth = 2 mm).

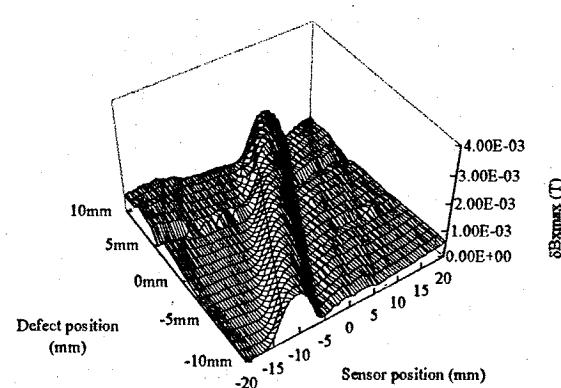


Fig. 4-13 Learning data
($\delta B_{x\text{max}}$, Crack depth = 3 mm).

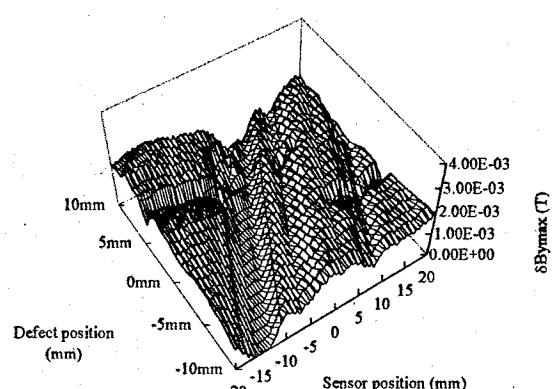


Fig. 4-14 Learning data
($\delta B_{y\text{max}}$, Crack depth = 3 mm).

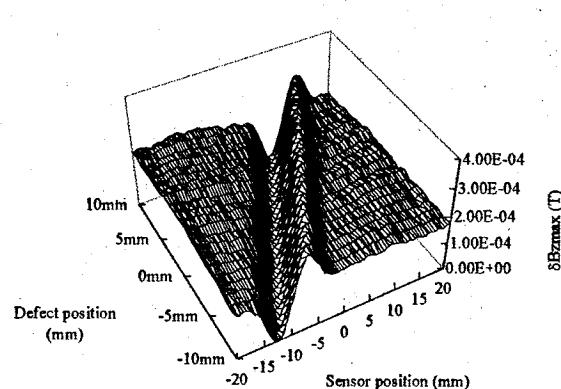


Fig. 4-15 Learning data
($\delta B_{z\text{max}}$, Crack depth = 3 mm).

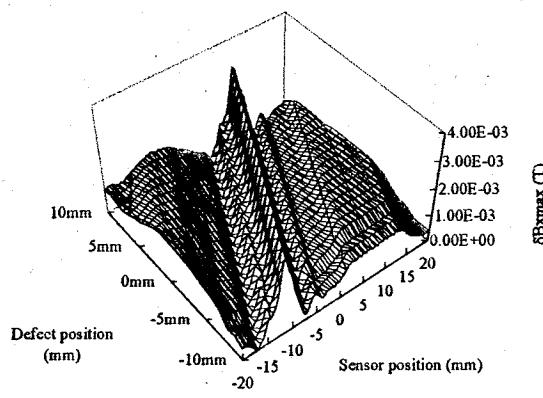


Fig. 4-16 Learning data
($\delta B_{x\text{max}}$, Crack depth = 4 mm).

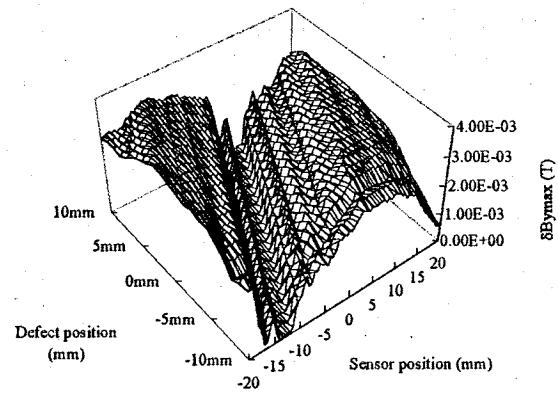


Fig. 4-17 Learning data
($\delta B_{y\text{max}}$, Crack depth = 4 mm).

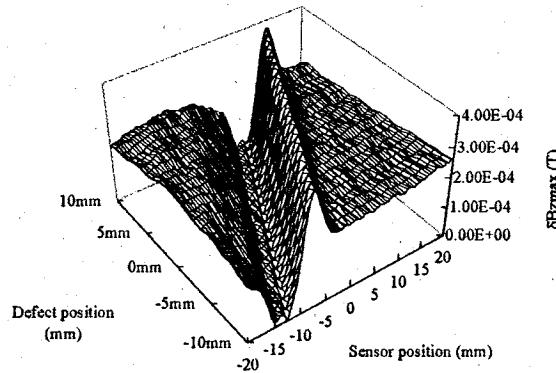


Fig. 4-18 Learning data
($\delta B_{z\text{max}}$, Crack depth = 4 mm).

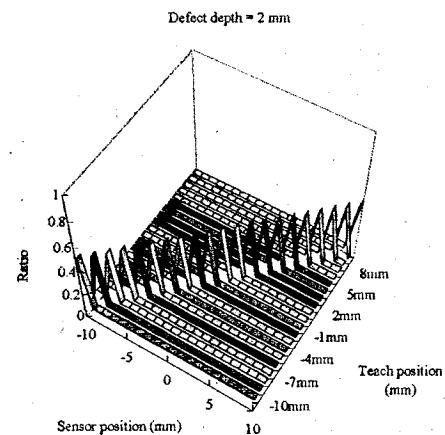


Fig. 4-19 Teaching data
(Crack depth = 2 mm).

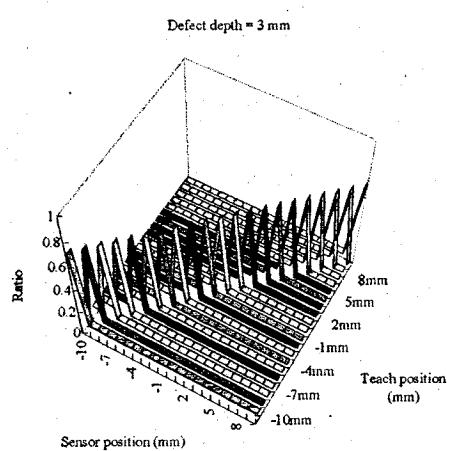


Fig. 4-20 Teaching data
(Crack depth = 3 mm).

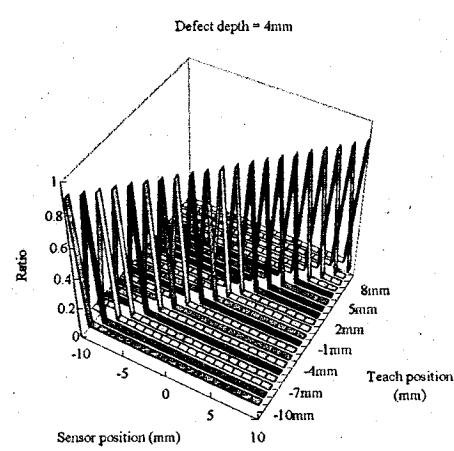


Fig. 4-21 Teaching data
(Crack depth = 4 mm).

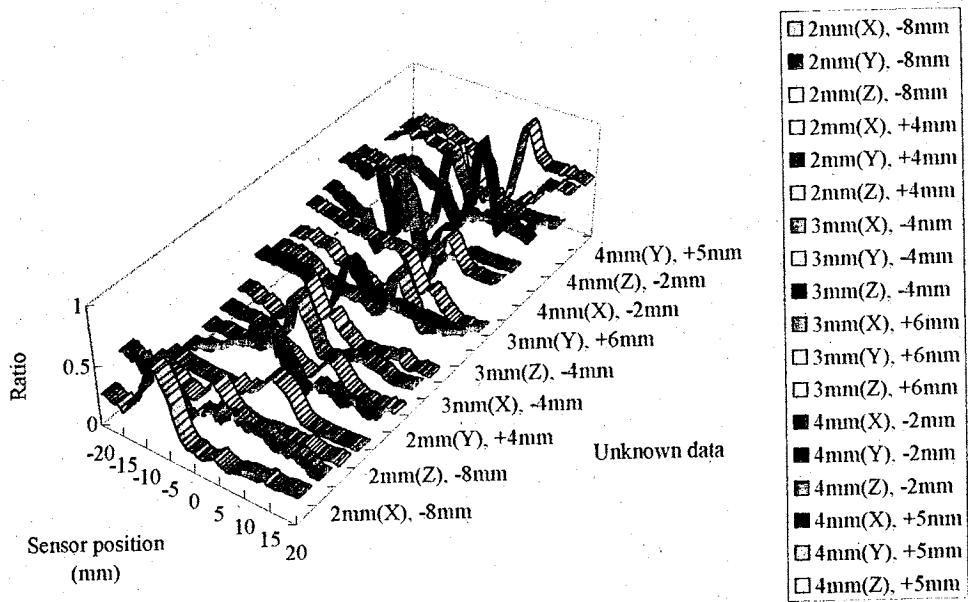


Fig. 4-22 Unknown data.

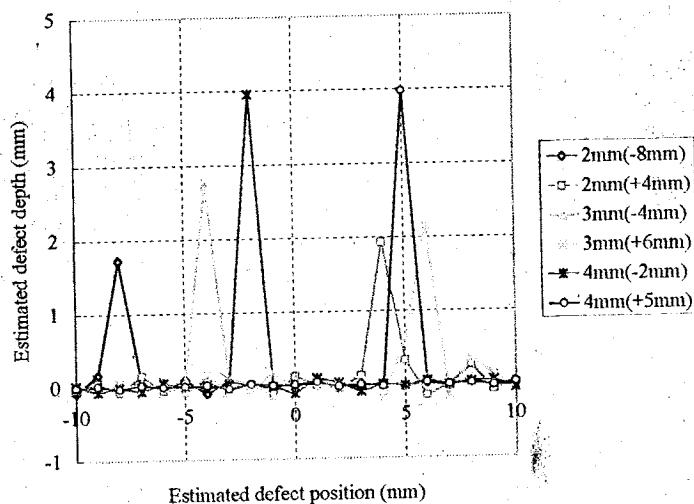


Fig. 4-23 Results of estimation.

4. 3. 3 欠陥の深さと方向角の同時推定

次に、3軸差動ピックアップコイル回転磁束型磁気センサをニューラルネットワークと組み合わせ、欠陥の方向角 ϕ を自動推定した結果を示す^[28]。ここで推定した欠陥の属性は、欠陥の方向角 ϕ である。欠陥の深さについては、4 mmと3 mmを対象にし2 mmと1 mmは除いた。

入力層のニューロンの数は、243、隠れ層のニューロンの数は、76、出力層のニューロンの数は、19である。入力層のニューロンの数は、 $\delta B_{x\max}$ 、 $\delta B_{y\max}$ 、 $\delta B_{z\max}$ のすべてのデータを利用して欠陥を推定するため、測定点の数(81) × 3としている。出力層のニューロンの数は、欠陥の方向角 ϕ を10度刻みで表示できるように19とした。こ

のときのニューラルネットワークの学習は、次の条件で行った。学習係数 α は、1、シグモイド関数の傾き ε は、0.3、モーメント係数 m は、0.8 とし、誤差 0.0001 を目標に 20,000 回学習するように設定した。9,218 回の学習の後に誤差は、0.0001 に達し、学習を終了した。なお、隠れ層の数と各係数は、予備実験により求めた。

Fig. 4-24 から Fig. 4-29 に欠陥の深さと方向角 ϕ の同時推定問題に用いた学習データを示す。これらのデータは、欠陥の方向角 ϕ を 10 度間隔で変えながら測定を行った結果である。また、未知データは、各方向角 ϕ について任意の方向に欠陥を傾けて測定したデータとした。学習データの数は、38 であり、未知データの数は 4 である。Fig. 4-30 と Fig. 4-31 に各深さの欠陥と方向角 ϕ に対応した教師データを示し、Fig. 4-32 に深さと方向角 ϕ の同時推定に用いた未知データを示す。Fig. 4-33 に同時推定の結果を示す。多少の誤差を含んだ推定結果となっているが、いずれの場合もほぼその深さや方向角 ϕ を推定している。

以上の結果から、3 軸差動ピックアップコイル回転磁束型磁気センサとニューラルネットワークと組み合わせた欠陥属性自動推定システムは、欠陥上を 1 回走査するのみで欠陥に関する多く属性を推定でき、この方法が有効であることを示している。特に、他の方式の磁気センサとニューラルネットワークの組み合わせた場合の自動推定結果にこのような報告がないことから、回転磁束型磁気センサの利用は、有効である。

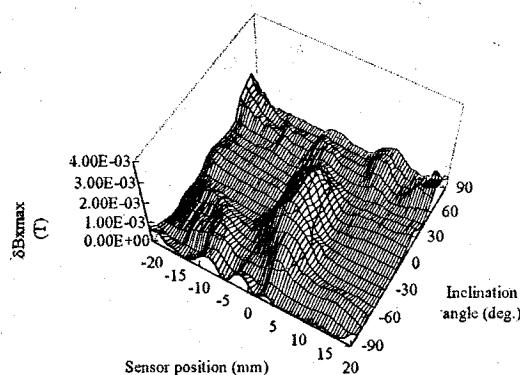


Fig. 4-24 Learning data
($\delta B_{x\text{max}}$, Crack depth = 3 mm).

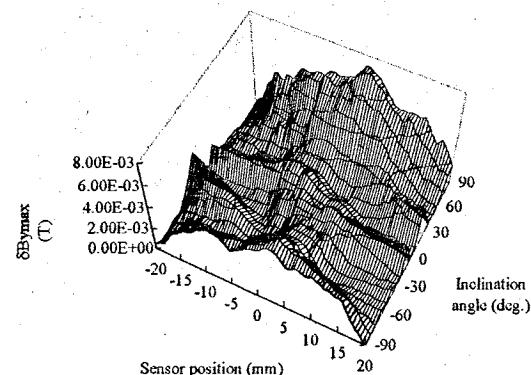


Fig. 4-25 Learning data
($\delta B_{y\text{max}}$, Crack depth = 3 mm).

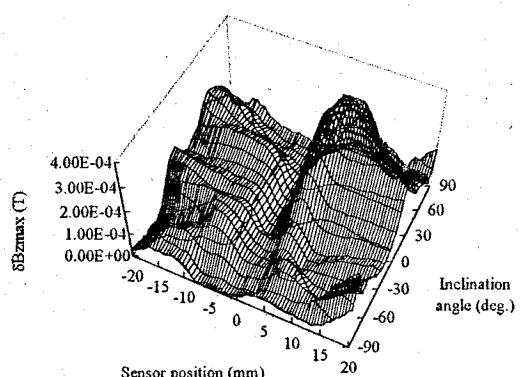


Fig. 4-26 Learning data
($\delta B_{z\text{max}}$, Crack depth = 3 mm).

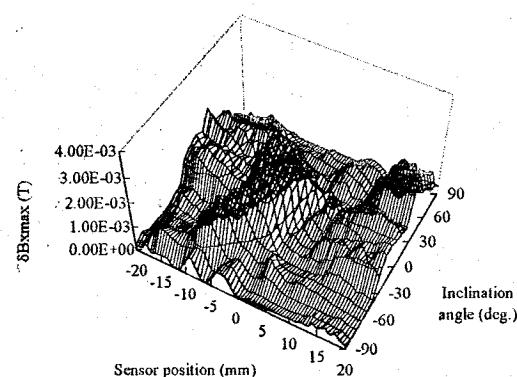


Fig. 4-27 Learning data
($\delta B_{x\text{max}}$, Crack depth = 4 mm).

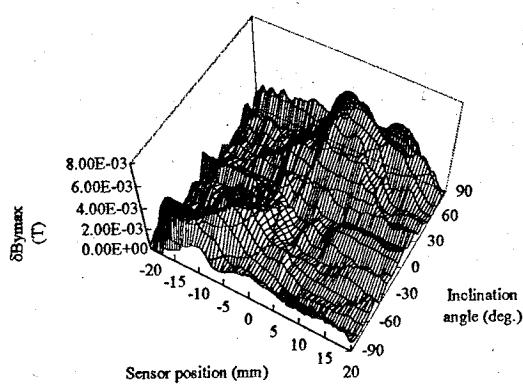


Fig. 4-28 Learning data.
($\delta B_{y\max}$, Crack depth = 4 mm)

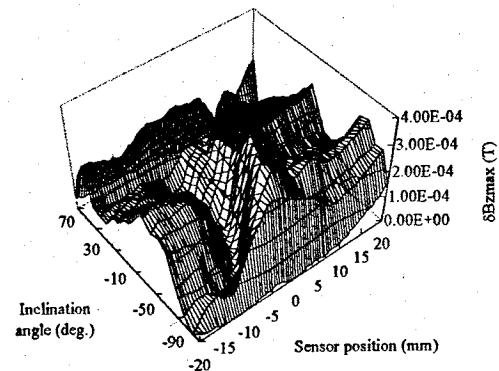


Fig. 4-29 Learning data
($\delta B_{z\max}$, Crack depth = 4 mm).

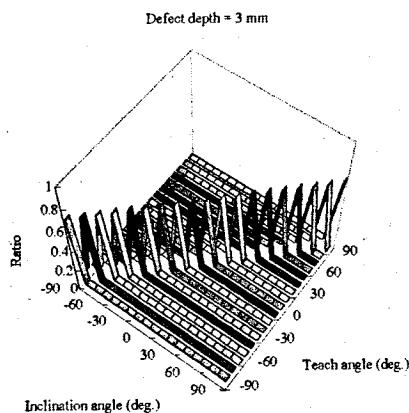


Fig. 4-30 Teaching data
(Crack depth = 3 mm).

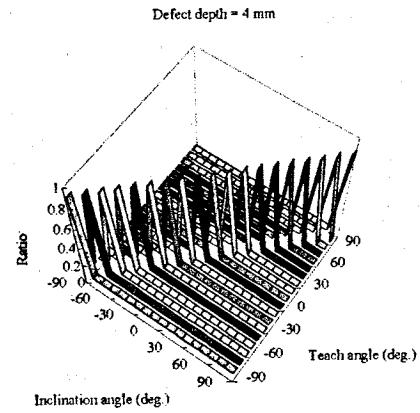


Fig. 4-31 Teaching data
(Crack depth = 4 mm).

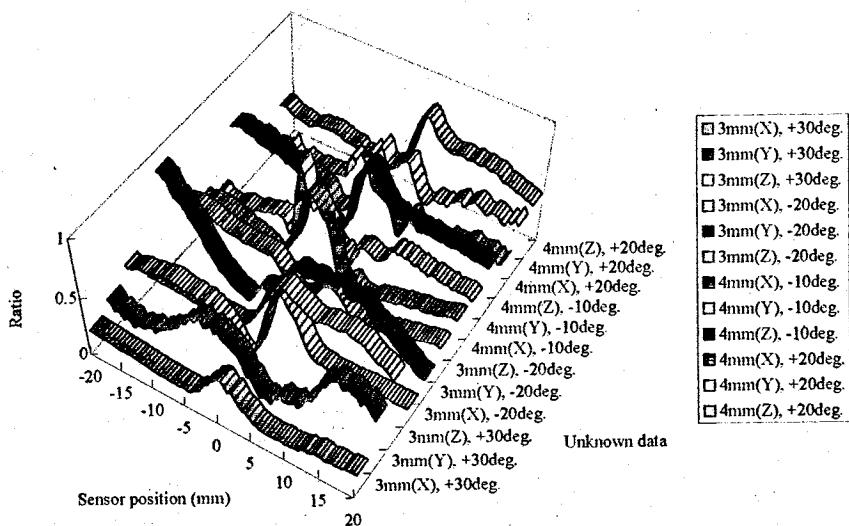


Fig. 4-32 Unknown data.

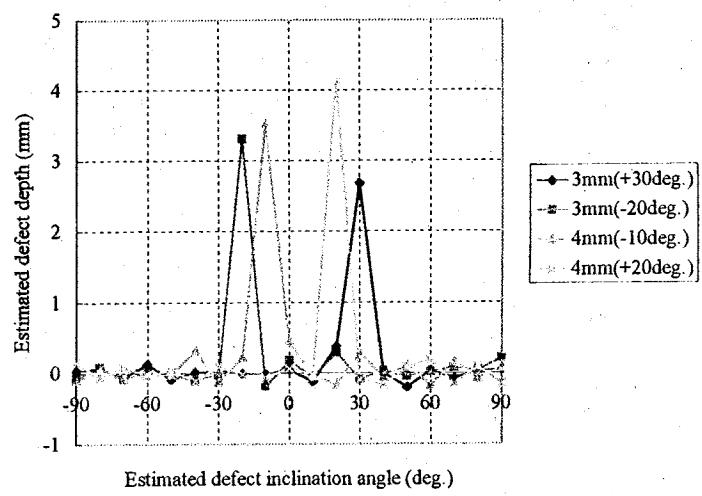


Fig. 4-33 Results of estimation.

第4. 4節 ステンレス板裏側欠陥の形状推定

4. 4. 1 概要

非破壊検査用磁気センサが対象としなければならない欠陥は、疲労などで発生するクラックだけではなく、エロージョンなどのようにある形状を持つ欠陥もある。そこで、本研究では、ステンレス板裏側に発生した欠陥の形状を検出・判定することを目的にした回転磁束型磁気センサを2種類提案している。ここでは、ステンレス板裏側の欠陥の形状の自動推定に対しても回転磁束型磁気センサの有効性を示すために、3軸差動ピックアップコイル回転磁束型磁気センサをニューラルネットワークと組み合わせて、欠陥の形状の自動推定を行った。第3. 4節で述べた「欠陥形状評価指標 χ 」を利用した欠陥の形状の自動推定は、よい結果を示し、形状のような2次元の欠陥属性を推定する場合もニューロンの数が少なくてすむなどこの方法が有効であることがわかった。以下、ステンレス板裏側欠陥の形状の自動推定に適用した結果を示す。

4. 4. 2 各種データ

ここで用いている3軸差動ピックアップコイル回転磁束型磁気センサは、従来の磁気センサに比べて多くの欠陥に関する情報を一度に収集することができることは先に述べた。しかし、収集した各軸のデータを無加工でニューラルネットワークに入力することは入力層ばかりではなく隠れ層のニューロンの数を増加させることになる。文献によると^[91, 92]、ニューラルネットワークは、構成するニューロンの数が多くなると誤差の収束に時間がかかったり、最悪の場合は収束しない事態が生ずる可能性が高くなる。このような場合、入力データを減らすことがニューロン数を減少させ、ニューラルネットワークを早く学習させる効果が大きい。収集したデータを捨てることなく圧縮できればこの問題は解決する。

欠陥形状推定問題においては、欠陥の周囲 50 mm × 50 mm の範囲 ($X = -25 \text{ mm}$ から $X = 25 \text{ mm}$ 、 $Y = -25 \text{ mm}$ から $Y = 25 \text{ mm}$ 。51点 × 51点) を 1 mm ステップで欠陥形状推定のためのデータを収集し、その中で、欠陥に直接関係する 20 mm × 20 mm (21点 × 21点) の範囲をニューラルネットワークに入力した。そのため、データ数は、441点分となる。よって、XYZ 軸の規格化した最大値である $(\delta B_{x\max})$ 、 $(\delta B_{y\max})$ 、 $(\delta B_{z\max})$ をそのままの形で用いる場合、 $441 \times 3 = 1323$ だけの入力層のニューロンが必要になる。その上、 $\Phi_{x\max}$ 、 $\Phi_{y\max}$ 、 $\Phi_{z\max}$ の情報を捨てる事になる。そこで、(3-19)式で示す「欠陥形状評価指標 χ 」を用いて3軸方向の欠陥に関する情報をなるべく多く含みながら($\Phi_{z\max}$ は含んでいない。)入力データを圧縮することとした。これによって入力層の数が、各軸のデータを別々に入力する場合に比べて3分の1とすることができ、ニューラルネットワークを用いる際に大きな利点となった。

Fig. 4-34 から Fig. 4-37 に各形状の欠陥の欠陥形状評価指標 χ を用いた欠陥形状推定問題に用いた学習データ示す。ただし、欠陥形状評価指標 χ の変化がごく小さい欠陥については、4から20倍したものを表示した。ここで、Fig. 4-34 から Fig. 4-37 よ

り欠陥形状評価指標 χ の欠陥による変化は、 $20\text{ mm} \times 20\text{ mm}$ の範囲に集中しており、欠陥献上の推定には、この範囲のデータを用いれば十分であることが分かる。

欠陥の形状の推定は、つぎの3種に分けて行った。第1は、欠陥深さを4mmと3mmに限定し、欠陥の形状のみを推定した場合である。これを欠陥形状推定問題1とする。第2は、欠陥深さを4mm、3mm、2mmとし、欠陥の形状のみを推定した場合である。これを欠陥形状推定問題2とする。第3は、欠陥深さを4mmと3mmに限定し、欠陥の形状と深さを同時推定した場合である。この場合には、出力を工夫し、欠陥の形状をグラフィック的に表示できるようにした。これを欠陥形状推定問題3とする。

欠陥形状推定問題1、2、3の各層のニューロンの数を、Table 4-1に、学習に関する各係数をTable 4-2、学習データの数や未知データの数をTable 4-3に示す。

Table 4-1 Number of neuron.

Problem	Number of layer		
	Input	Hidden	Output
No. 1	441	14	7
No. 2	441	14	7
No. 3	441	441	441

Table 4-2 Constants of learn.

Problem	Constants of learn		
	α	ϵ	m
No. 1	0.6	0.2	0.2
No. 2	0.4	0.1	0.6
No. 3	0.3	0.1	0.8

Table 4-3 Number of data.

Problem	Number of data	
	Learning data	Unknown data
No. 1	13	13
No. 2	19	19
No. 3	13	13

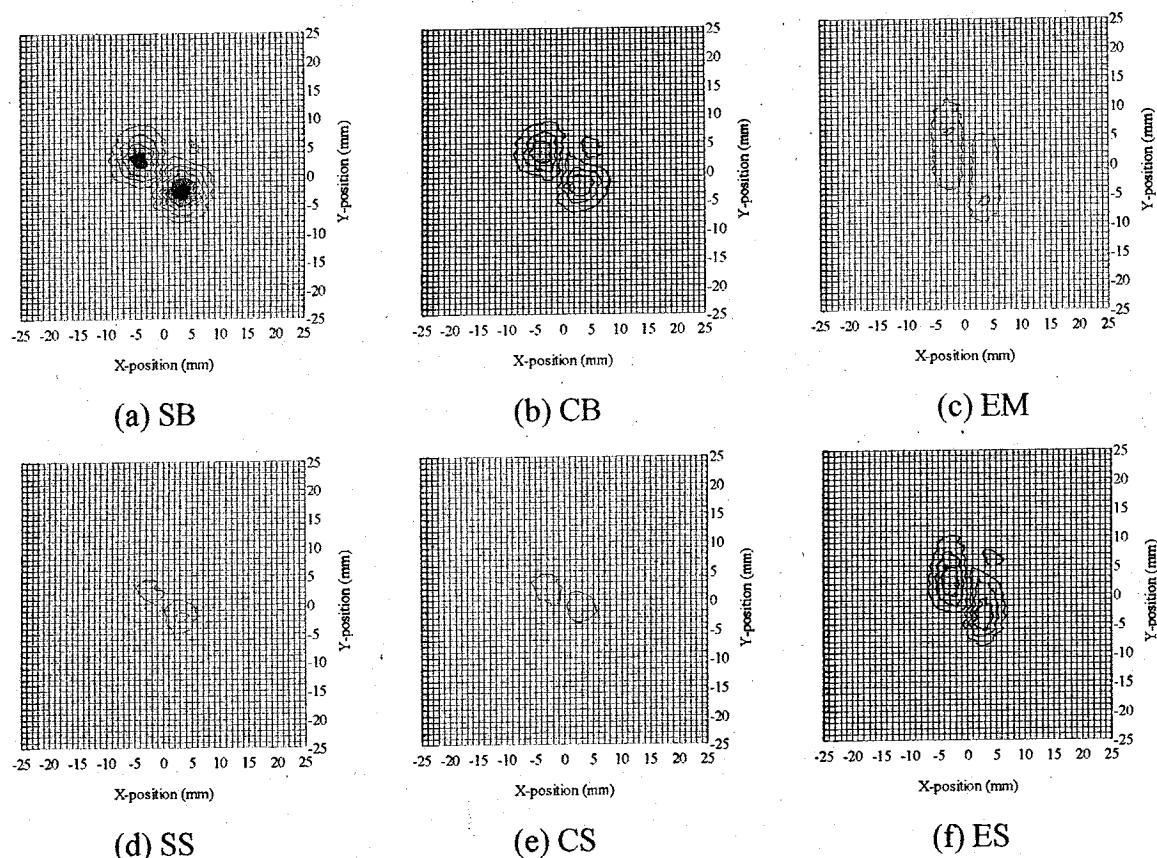


Fig. 4-34 χ vs. the sensor position (Learning data, Defect depth = 4 mm).

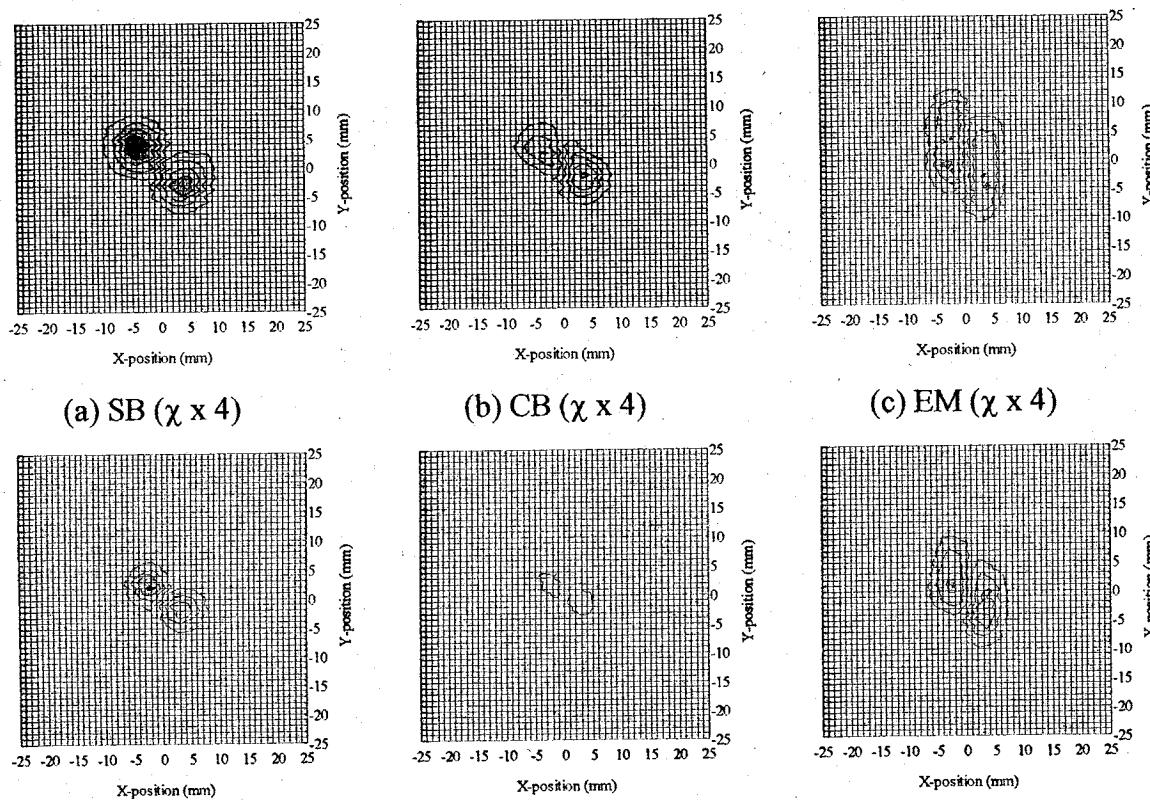


Fig. 4-35 χ vs. the sensor position (Learning data, Defect depth = 3 mm).

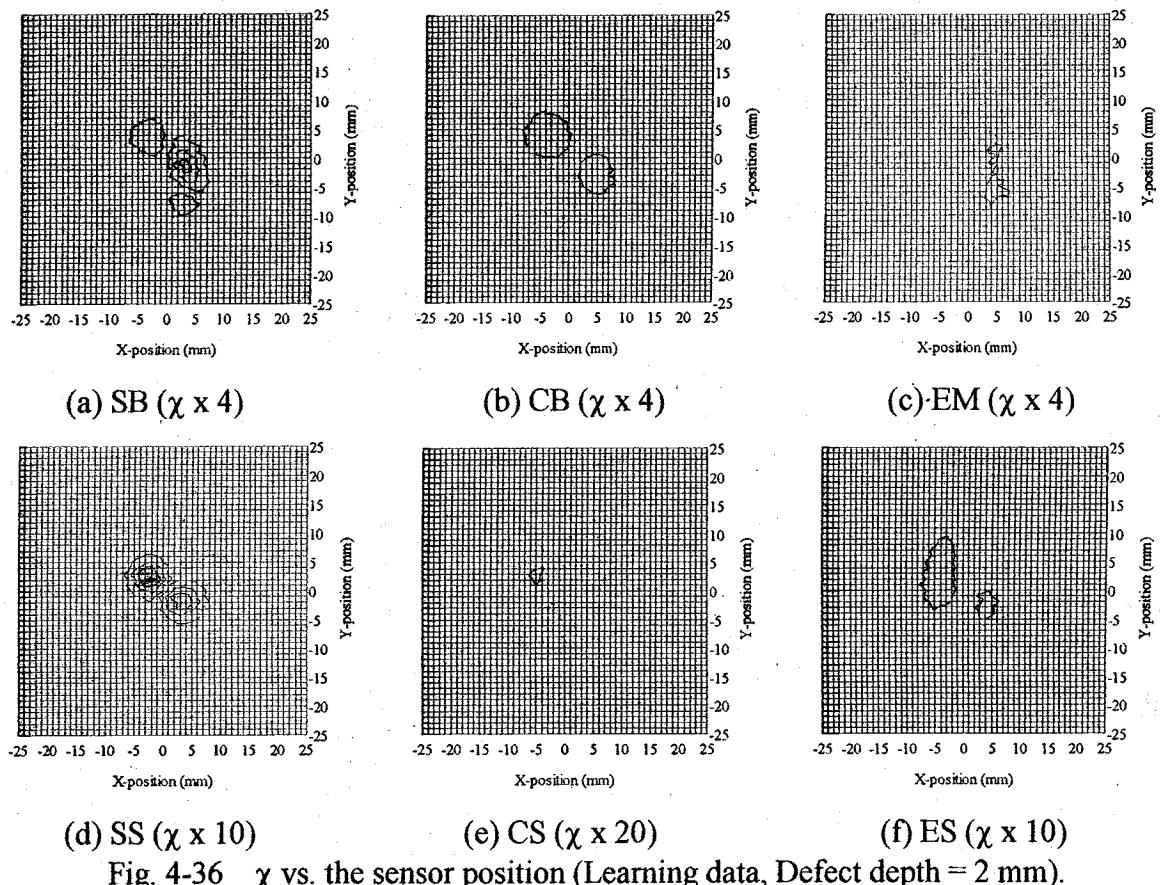
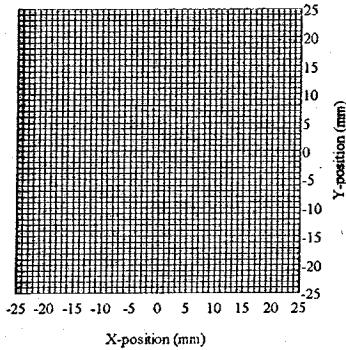


Fig. 4-36 χ vs. the sensor position (Learning data, Defect depth = 2 mm).



Without a defect.

Fig. 4-37 χ vs. the sensor position (Learning data,).

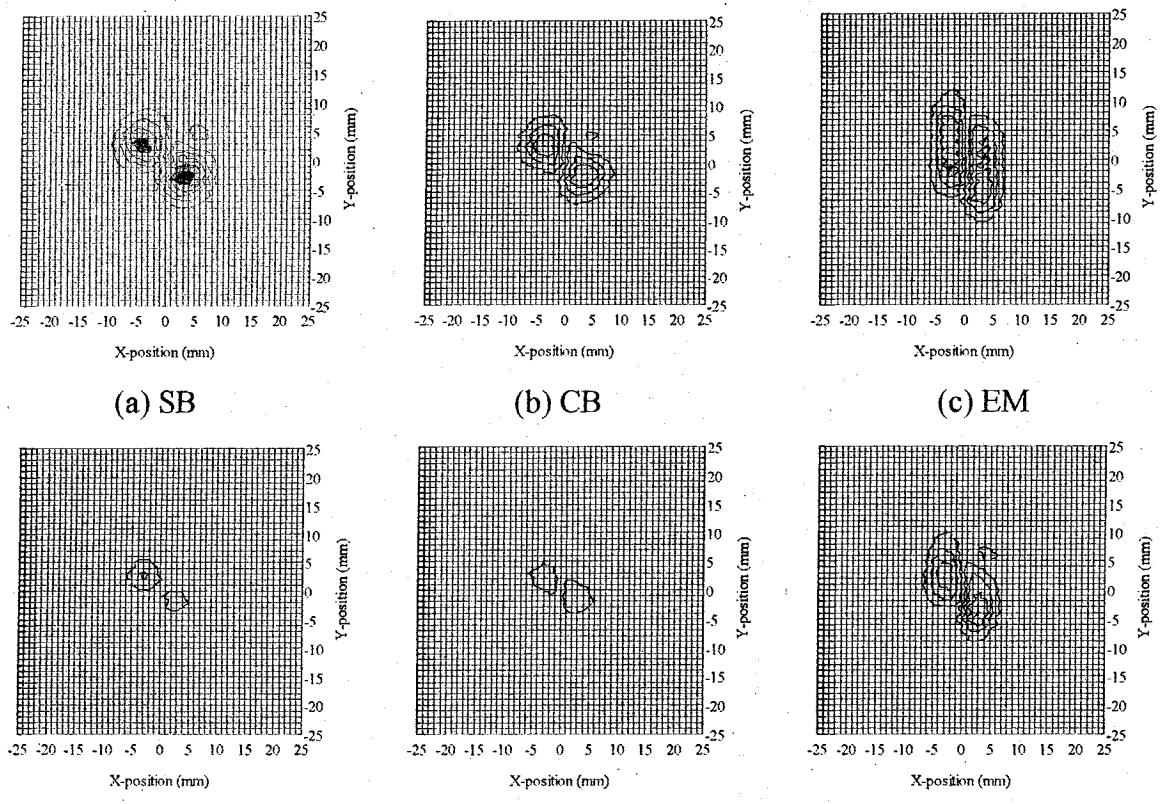


Fig. 4-38 χ vs. the sensor position (Unknown data, Defect depth = 4 mm).

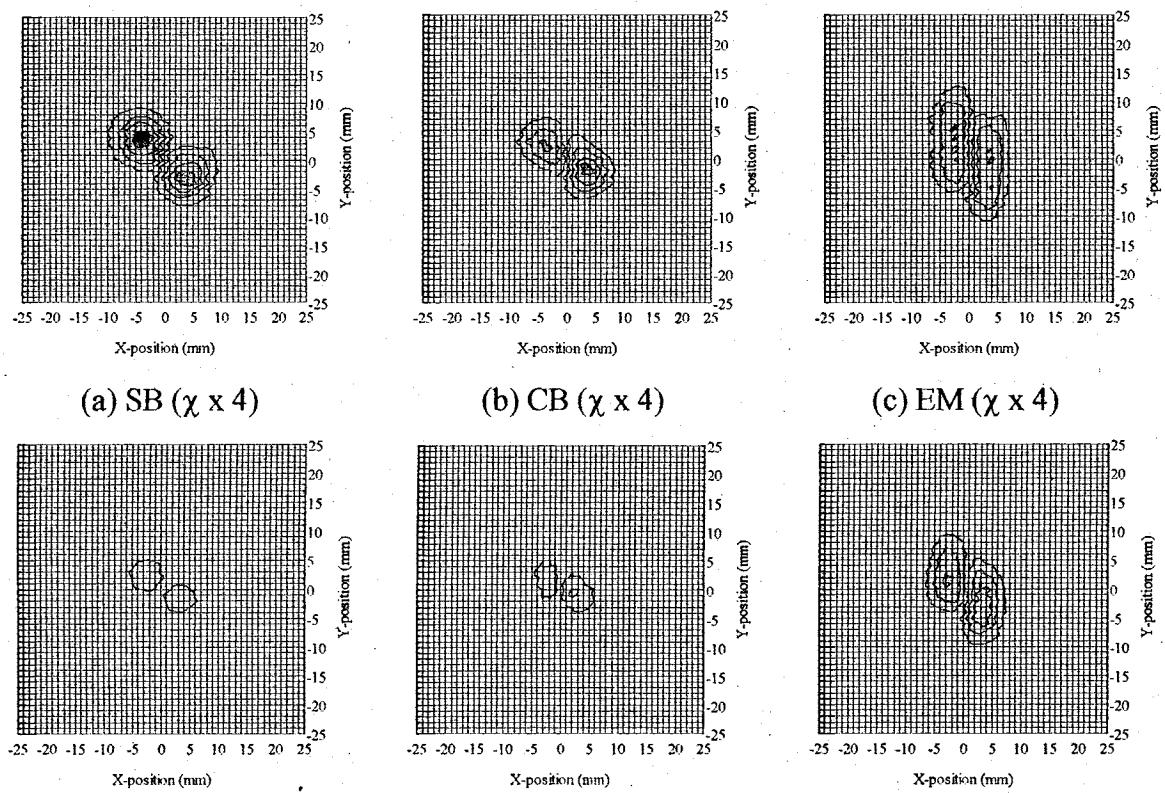


Fig. 4-39 χ vs. the sensor position (Unknown data, Defect depth = 3 mm).

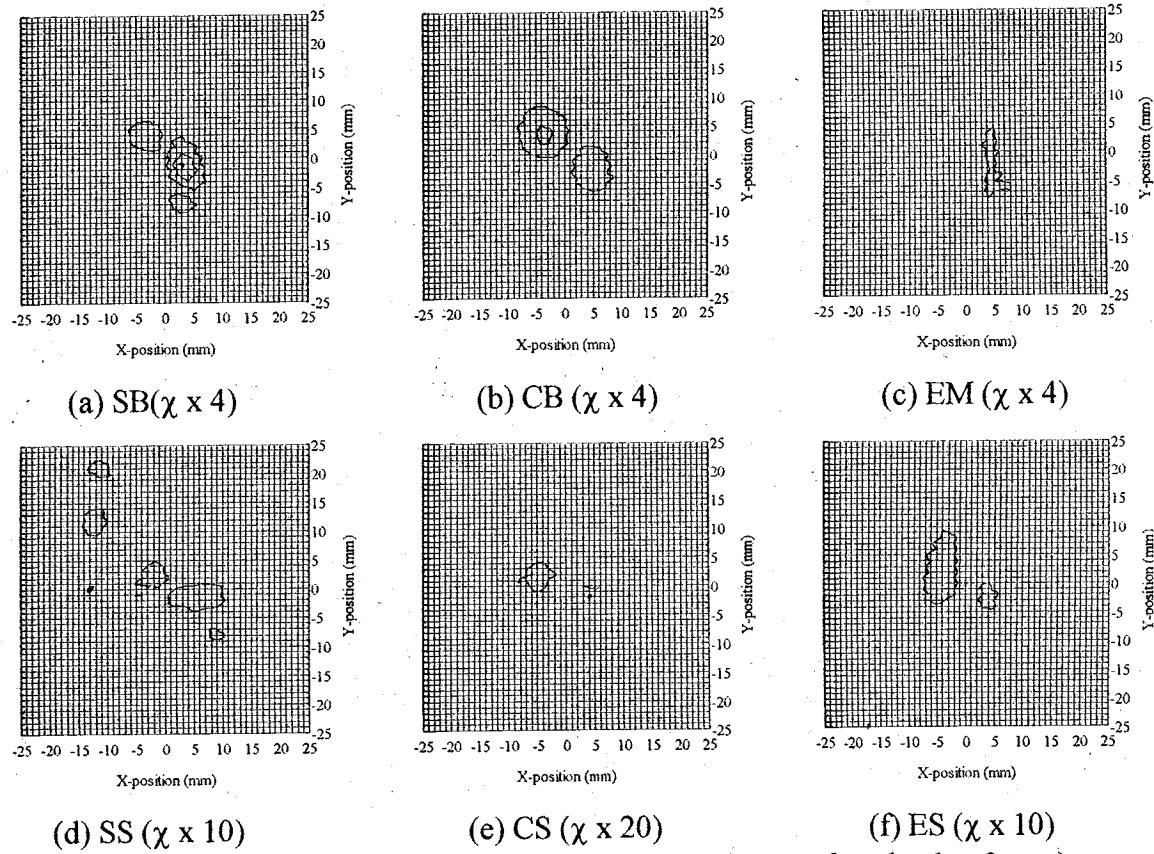


Fig. 4-40 χ vs. the sensor position (Unknown data, Defect depth = 2 mm).

4. 4. 3 欠陥形状推定

(1) 欠陥形状推定問題 1

Fig. 4-41 に教師データを、Fig. 4-42 に推定結果を示す。学習回数は、50,000 回である。目標誤差である 0.0001 には到達しなかった。しかし、0.001 には達した。EM-4mm (15 mm long track shape defect, depth = 4 mm) の場合に、大きい長円形だけではなく大きい円形や大きい正方形の可能性もあるという結果がでているがその他の場合は、確実に欠陥の形状を推定している。このようにこの問題では、3 軸差動ピックアップコイル回転磁束型磁気センサとニューラルネットワークの組み合わせは欠陥の形状をよく推定できる。

(2) 欠陥形状推定問題 2

Fig. 4-43 に教師データを、Fig. 4-44 に推定結果を示す。学習回数は、100,000 回である。目標誤差である 0.0001 には到達しなかった。しかし、0.01 には達した。欠陥の深さ 4 mm の場合は、おおむねよく欠陥の形状を推定している。また、欠陥の深さ 3 mm の場合は、大きな欠陥ではよく推定しているが、小さい欠陥で誤差が目立つ。さらに、欠陥の深さ 2 mm の場合は、3 mm よりもなお誤差が目立つ。このようにこの問題では、3 軸差動ピックアップコイル回転磁束型磁気センサとニューラルネットワークの組み合わせは、欠陥の深さや大きさによって推定結果が異なり、欠陥が浅くなるに従って、また、小さくなるに従って誤差が大きくなつた。

(3) 欠陥形状推定問題 3

Fig. 4-45 に教師データを、Fig. 4-46 に推定結果を示す。学習回数は、136,906 回である。最終誤差は、目標誤差である 0.01 に到達した。10 mm 角の正方形欠陥では、深さ 4 mm の場合は、正確に推定しているが、深さ 3 mm の場合は、形状についてはほぼ正しい結果を得ているが、深さについては 4 mm に近い推定結果が出ている。5 mm 角の正方形欠陥では、深さ 4 mm の場合は、形状はほぼ正しい結果を得ているが、深さ 3 mm の場合は、半径 5 mm の円形欠陥に近い結果が出ている。さらに、半径 10 mm の円形欠陥については、10 mm 角の正方形欠陥とほぼ同様な結果である。半径 5 mm の円形欠陥でも深さ 4 mm の場合はほぼ正しいが、深さ 3 mm の場合は形状的には正しいが深さは正しくない結果となっている。長さ 15 mm の長円形欠陥についても同様に深さ 4 mm の場合はほぼ正しいが、深さ 3 mm の場合は形状的には正しいが深さは正しくない結果となっている。長さ 10 mm の長円形欠陥については、深さ 4 mm の場合は長さ 15 mm の長円形欠陥と推定しており、深さ 3 mm の場合は形状的には正しいが深さは正しくない結果となっている。また、傷無しの場合は、3 mm 以上の欠陥がないことを正しく推定している。以上のように、3 軸差動ピックアップコイル回転磁束型磁気センサとニューラルネットワークの組み合わせは、すべての欠陥についてその形状を多少の誤差を含んではいるが、ほぼ正しく推定することができたが、深さとの同時推定は、誤差が目立つ結果となつた。

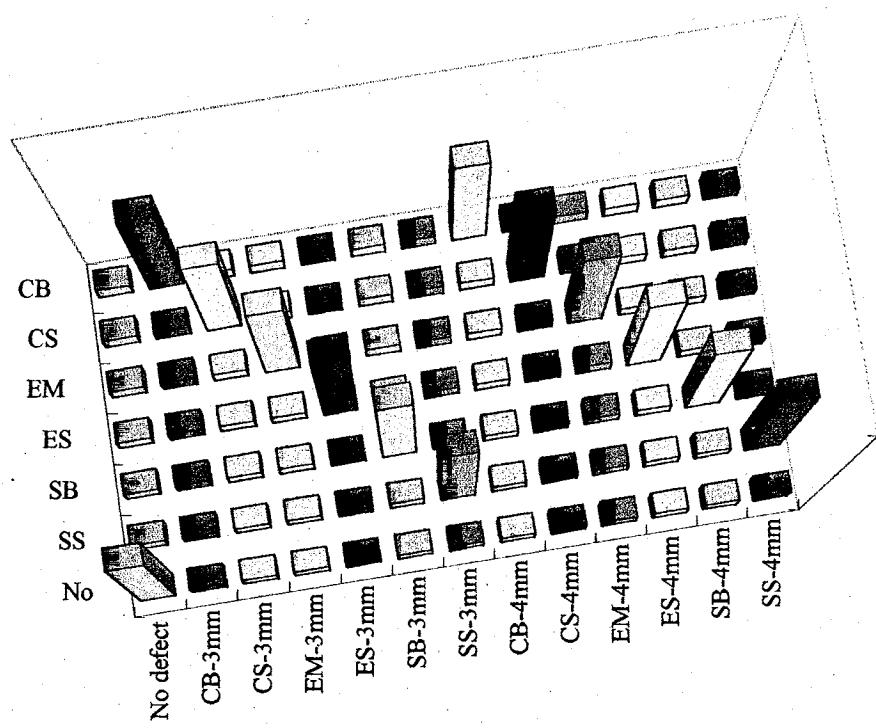


Fig. 4-41 Teaching data.

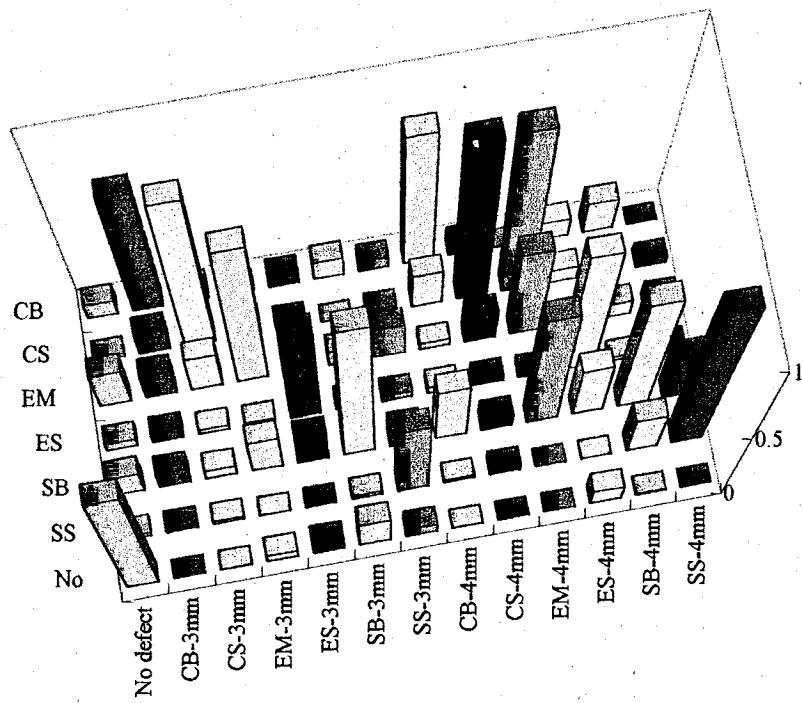


Fig. 4-42 Results of estimation.

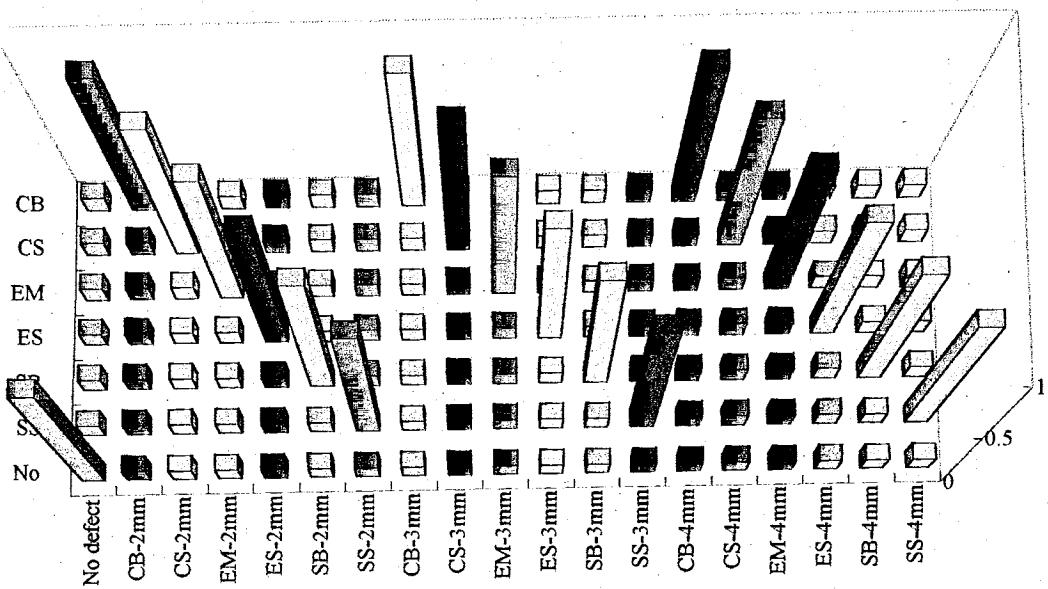


Fig. 4-43 Teaching data.

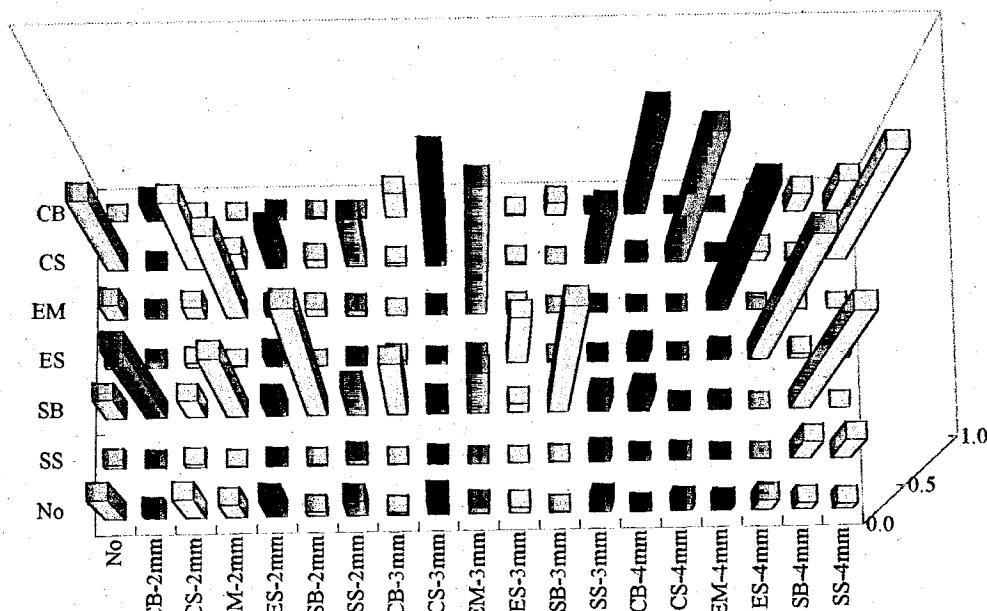
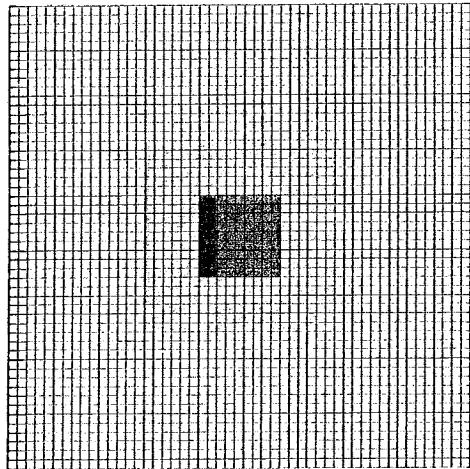
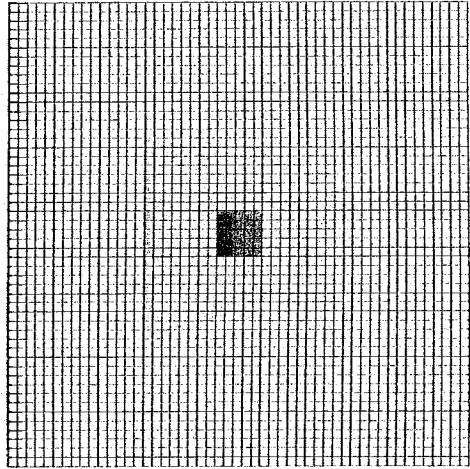


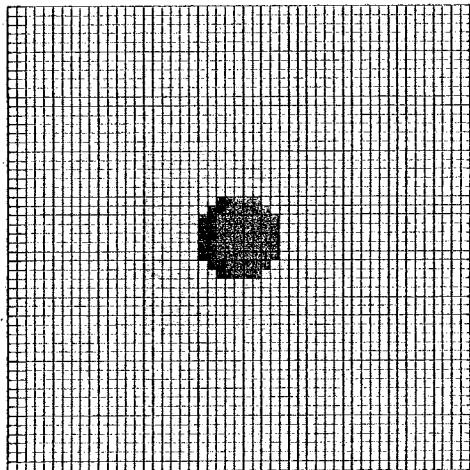
Fig. 4-44 Results of estimation.



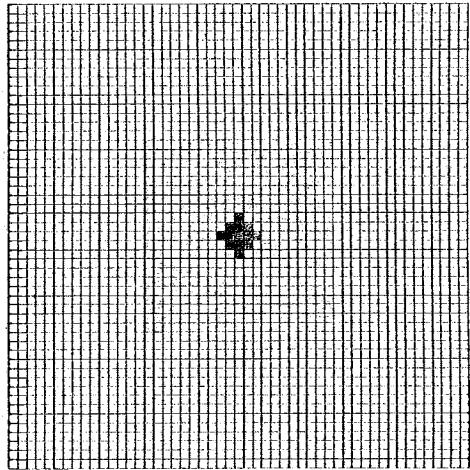
(a) SB



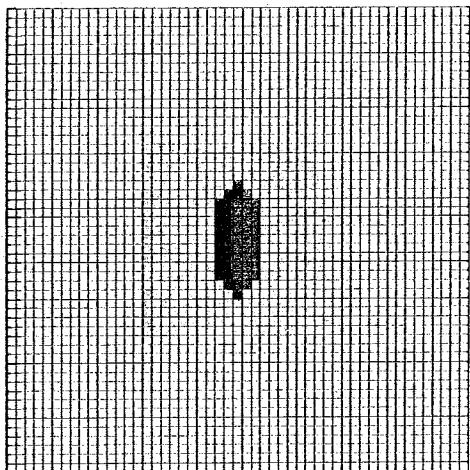
(b) SS



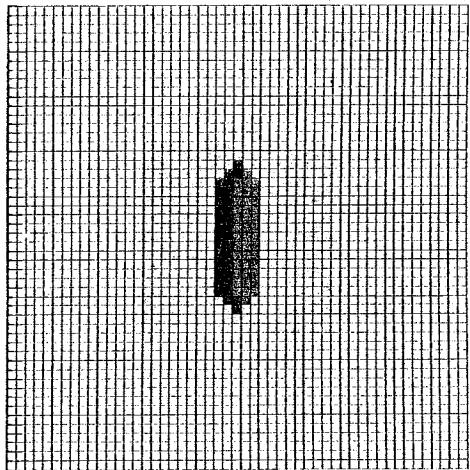
(c) CB



(d) CS

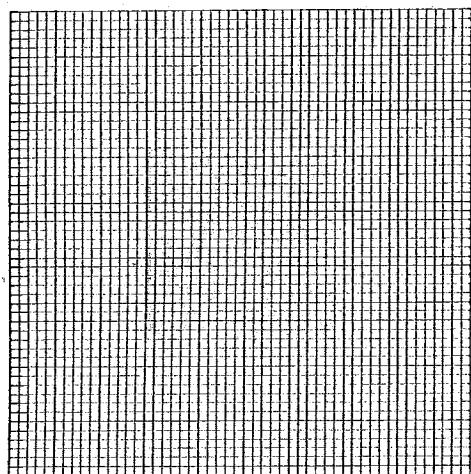


(e) ES

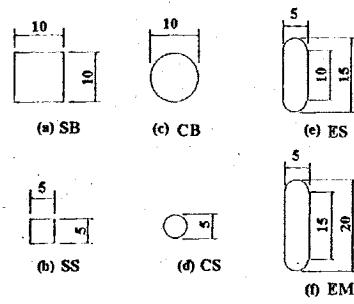


(f) EM

Fig. 4-45 Teaching data.

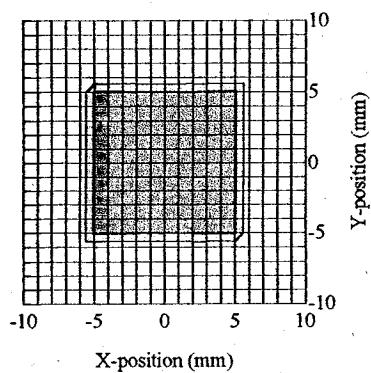


(g) No defect

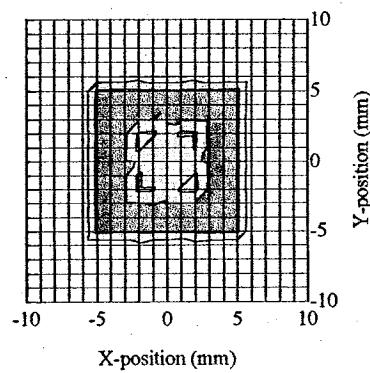


(h) Given defect shapes

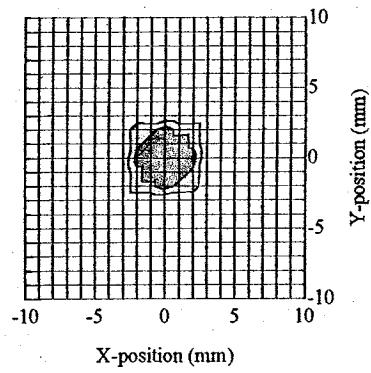
Fig. 4-45 Teaching data.



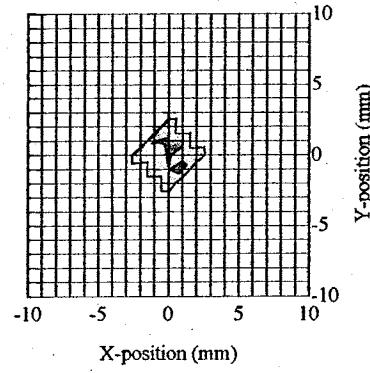
(a) SB - 4 mm



(b) SB - 3 mm

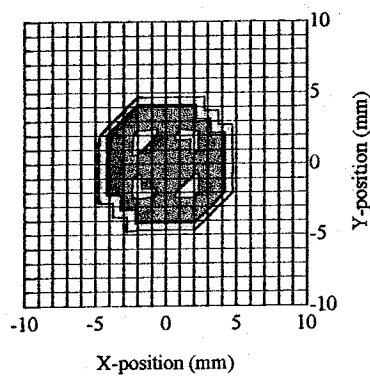


(c) SS - 4 mm

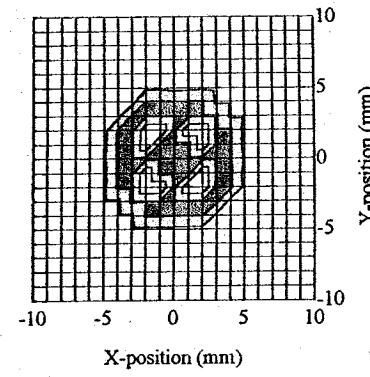


(d) SS - 3 mm

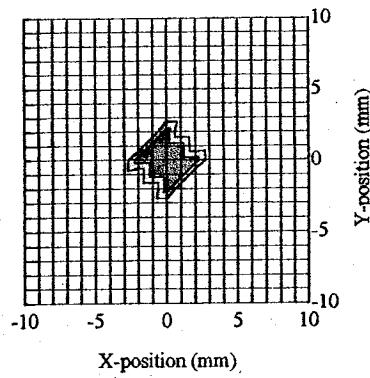
Fig. 4-46 Results of estimation.



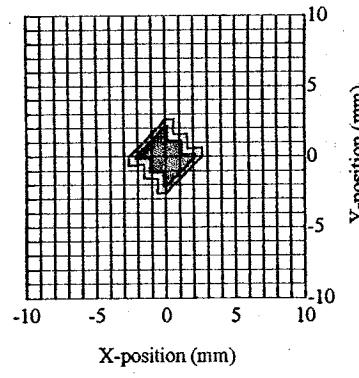
(e) CB - 4 mm



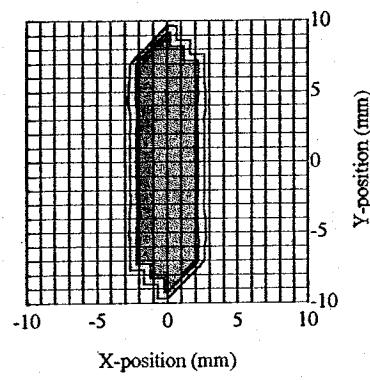
(f) CB - 3 mm



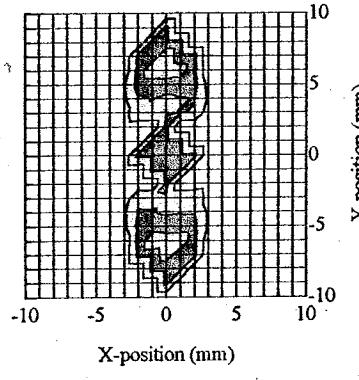
(g) CS - 4 mm



(h) CS - 3 mm

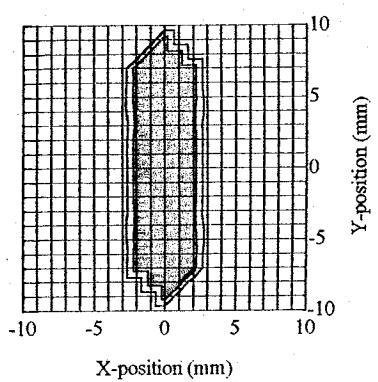


(i) EM - 4 mm

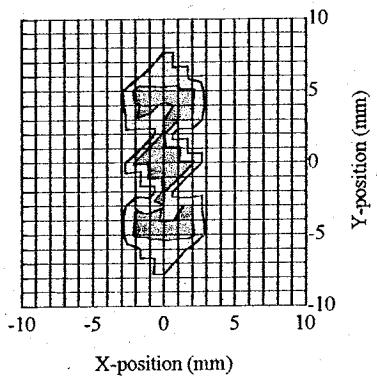


(j) EM - 3 mm

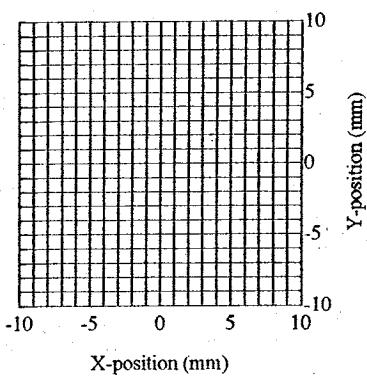
Fig. 4-46 Results of estimation.



(k) ES - 4 mm



(l) ES - 3 mm



(m) No defect

Fig. 4-46 Results of estimation.

第4. 5節 結言

誤差逆伝搬階層型ニューラルネットワークを用いた欠陥属性の推定法については、各種報告されているが、回転磁束型磁気センサ以外の場合は、欠陥に関する情報収集能力が低いため、欠陥属性推定結果は満足のいくものではなかった。そこで、第4章においては、回転磁束型磁気センサが欠陥属性推定問題に対しても他の方式の磁気センサと比べて優位であることを示す目的で、回転磁束型磁気センサと誤差逆伝搬階層型ニューラルネットワークを組み合わせて欠陥属性自動推定問題に適用した。回転磁束型磁気センサと誤差逆伝搬階層型ニューラルネットワークを組み合わせた欠陥属性自動推定法は、従来の磁気センサとニューラルネットワークの組み合わせによる欠陥属性推定法に比べて多くの利点があることを確認した。以下、この非破壊評価システムの優位性を示す。

(1) 軟鋼板裏側欠陥の属性推定について

- a. 空心蝶型磁気センサの欠陥検出信号を2次元有限要素法によって用意し、そのデータを学習データとして訓練したニューラルネットワークによる欠陥深さと位置の同時自動推定問題では、4, 3, 2 mm の深さの欠陥については、その深さや位置をよく推定した。また、欠陥の位置については、1 mm の深さの欠陥についてもよく推定した。
- b. 3軸差動ピックアップコイル磁気センサの実験による欠陥検出信号を学習データとした欠陥位置と深さの同時自動推定問題では、4から2 mm の深さの欠陥についてその位置や深さをほぼ正確に自動推定した。
- c. 3軸差動ピックアップコイル磁気センサの実験による欠陥検出信号を学習データとした欠陥深さと方向角 ϕ の同時自動推定問題では、4 mm と 3 mm の深さの欠陥についてよくその深さと方向角 ϕ を推定した。
- d. 欠陥の方向角 ϕ の自動推定問題において3軸差動ピックアップコイル磁気センサは、欠陥の上部を1回走査するのみで欠陥の方向角 ϕ を推定できた。

(2) ステンレス板裏側欠陥の形状推定について

- a. 「欠陥形状評価指標 χ 」は、3軸差動ピックアップコイル磁気センサをニューラルネットワークを用いた欠陥属性推定に適用する際にも、欠陥に関する情報を失うことなくニューロン数の削減をはかることができる有効なパラメータであった。
- b. 欠陥の深さ 4 mm と 3 mm の場合の欠陥形状のみの推定問題では、20 mm の長さのトラック型欠陥の深さ 4 mm の場合を除いてよくその形状を推定した。20 mm の長さのトラック型欠陥の深さ 4 mm の場合も、ほぼ妥当な結果を得た。
- c. 欠陥の深さ 4 mm, 3 mm, 2 mm の場合の欠陥形状のみの推定問題では、欠陥の深さが浅くなるに従って、また、欠陥が小さくなるに従って推定結果の誤差が増えているが総じて妥当な推定結果を示した。
- d. 欠陥の深さ 4 mm と 3 mm の場合の欠陥形状および欠陥深さの同時推定問題では、学習に時間がかかるものの欠陥の形状に関しては総じてよい推定結果を示した。しかし、欠陥の深さについては多少誤差が目立った。

(3) 欠陥属性推定に関して

- a. 回転磁束型磁気センサの情報収集能力の高さから、ニューラルネットワークと組み合わせた欠陥属性推定法は、ほぼ欠陥属性を推定できた。
- b. 他の形式の磁気センサと同様に、回転磁束型磁気センサの欠陥検出信号は、欠陥が浅くなると急激に小さくなるので浅い欠陥の属性推定に困難が伴う場合があった。