

9th MAGDA CONFERENCE

第9回電磁現象及び電磁力に関する コンファレンス

Conference of Electromagnetic Phenomena and Dynamics

講演論文集

会期: 2000年 3月20日, 21日 March 20 and 21, 2000

会場: The Robertson Gardens Plaza Hotel, Brisbane, Australia



主催:日本AEM学会, Griffith University

協賛:日本機械学会, 日本応用磁気学会, 日本シミュレーション学会

日本生体磁気学会, 計測自動制御学会, システム制御情報学会

日本非破壊検査協会, プラズマ核融合学会, 日本原子力学会

電気学会, IEEE Magnetics Society(Tokyo Chapter)

非磁性鋼疲労診断のための磁化分布逆解析

Inverse analysis of magnetization distribution for diagnosis of non-ferromagnetic steel

高屋 茂
出町 和之
宮 健三

(東京大学)
(東京大学)
(東京大学)

Gabriel Preda (東京大学)
内一 哲哉 (東京大学)

Shigeru TAKAYA Student Member
Preda GABRIEL Member
Kazuyuki DEMACHI Member
Tetsuya UCHIMOTO Member
Kenzo MIYA Member

Inverse analysis of the magnetization distribution in the stainless steel is proposed in this paper as a future means to diagnose the degradation before the outbreak of cracks. Neural networks and regularization methods as Principal Component Analysis, Shifting Aperture are proposed for coping with the ill-posedness of the problem. We measured the magnetic flux density of a sample with cracks introduced by fatigue test, and reconstructed the magnetization distribution from that measurement results.

Key Words: Nondestructive testing, Magnetization, Inverse problem, Neural networks.

1 緒言

SUS304 のように機器の構造部材として用いられる金属材料のなかには、通常非磁性体であるが供用中の外荷重や変形、周囲環境の影響により応力集中部においてマルテンサイト変態を起こし、強磁性を示すようになるものがある。このことから、磁束密度分布の逆解析を行ない金属材料内部の磁化分布を再構成することによって、疲労などによる劣化、損傷の程度を推定することが可能であると考えられる。この新しい劣化診断手法が従来の方法より優れている点は、き裂ができる前の段階で非破壊的に材料劣化を調べることができるところにある。本研究では、ニューラルネットワークを用いて磁束密度分布から磁化分布再構成を行う手法を開発した[1]。ニューラルネットワークは、原因と結果の因果関係が明確な形で定義できない場合の情報処理に有効である。さらに、疲労損傷が与えられた SUS304 試験片の磁束密度測定結果から磁化分布の再構成を行い、得られた結果の考察を行う。

連絡先: 高屋茂,〒319-1106、那珂郡東海村白方白根2-22、東京大学大学院工学系研究科附属原子力工学研究施設, email: takaya@tokai.t.u-tokyo.ac.jp

2 計算手法

2.1 磁化の作る磁場

磁化 \mathbf{M} の分布から各測定点における漏洩磁束密度 \mathbf{B} は Biot-Savart の法則より次式を用いて求められる。

$$\mathbf{B}_i = \frac{\mu_0}{4\pi} \sum_{j=1}^{n_s} \int_{\Omega_j} \frac{(\nabla \times \mathbf{M}_j) \times \mathbf{R}}{R^3} dv_j, \\ \mathbf{R} = \mathbf{R}_{sj} - \mathbf{R}_{fi}, \quad i = 1, n_f \quad (1)$$

ここで、 \mathbf{B}_i は測定点 i における磁束密度、 \mathbf{M}_j 、 dv_j は n_s 個に分割した試験片の j 番目要素における磁化と要素体積、 \mathbf{R}_s と \mathbf{R}_f はそれぞれ各磁化、測定点の位置ベクトルであり、 n_f は測定点の数である。

2.2 磁化分布再構成のためのニューラルネットワークの学習

2.2.1 ニューラルネットワークの原理

漏洩磁束密度から磁化分布を再構成するために、入力層、中間層、出力層の3層からなる階層構造ニューラルネットワーク (Fig.1) を用いた[2]。このニューラルネットワークの大きな特徴は次の二つである。

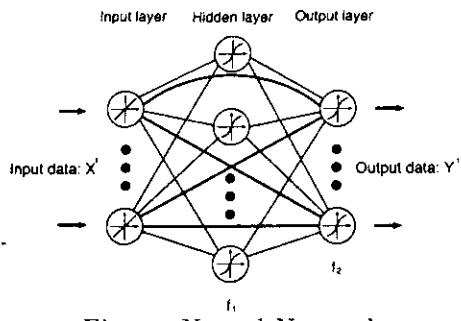


Fig. 1: Neural Network

まず、入力層が中間層だけでなく出力層にも直接つながっていること。これにより入力と出力を線形的な関係で扱う。二つ目は、中間層内のノード数は学習開始時には1つだけで、1セットの学習が終わる度に1ずつ増えてゆくことである。ちなみにこのノードと入力層間の結合荷重 W_{ih} はランダムに与えられる。中間層の増加により、非線形な問題への適用性が向上する。つまり、大雑把な再構成から徐々に精度を上げていくことになるため、ネットワークが局所的な解に収束することを防いでいる。また入力層-出力層間、中間層-出力層間の結合荷重 W_{io} 、 W_{ho} は、入力データ (X^i)、出力データ (Y^i) の間に成り立つ式において両辺の自乗誤差がもっとも小さくなるように決定される。

$$[X^i, f_1(X^i \cdot W_{ih})] \cdot \begin{bmatrix} W_{io} \\ W_{ho} \end{bmatrix} = f_2^{-1}(Y^i) \quad (2)$$

ここで、 f_1 、 f_2 は中間層、出力層においてデータ変換のために用いる非線形関数である。最終的に結合荷重は、直接学習には用いられていない確認用データについて(2)式両辺の自乗誤差が最も小さくなるものを採用する。これはネットワークが過学習により一般性を失うことを防ぐためである。

本研究では入力層への入力データ X は漏洩磁束 B 、出力層における出力データ Y は磁化 M である。

ニューラルネットワークは、入力層および出力層のノード数があまりに多いとその構造が複雑になるために、局所解にとどまるなどして学習が進まない。また、学習にも多くの時間を要する。そこで本研究では、Shifting Aperture 法および主成分分析を用い、ニューラルネットワークの簡素化を行なった。

2.2.2 教師データ

学習に用いた試験片の大きさは、縦、横が 16 mm、厚さ 3 mm である。また B の測定領域は試験片と同じく 16 mm × 16 mm の正方形で、リフトオフが

0.5 mm、測定ピッチは 1 mm とした。トレーニングセットは、学習用に 200 組、確認用に 50 組生成した。磁化分布は、半径 $R (= 2, 3, 4\text{mm})$ の円内で同心円状に分布していると仮定している。

2.2.3 検証データに関する誤差分布

100 組の検証データセットに対する誤差分布を Fig.2 に示す。

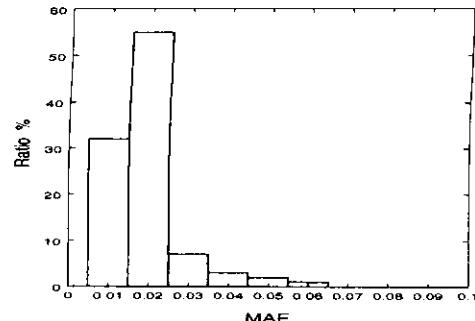


Fig. 2: Error distribution

ここで、横軸は格子点あたりの平均絶対誤差 (MAE)、縦軸はその割合である。MAE は次式で求められる。ただし、 $M_{t,i}$ 、 $M_{r,i}$ はそれぞれ格子点 i における期待される磁化および再構成により得られた磁化、また N は総格子点数である。

$$MAE = \sum_{i=1}^N \frac{|M_{t,i} - M_{r,i}|}{N} \quad (3)$$

誤差分布より、十分な学習が行われていることが確認できる。

3 測定データからの磁化再構成

3.1 磁束密度測定データ

試験片および測定装置の形状による制限から磁束密度の x 成分が測定不可能であったために試験片は Fig.3 に示す形状に切断された。Fig.4 が磁束密度測定データである。各図に試験片の形状を示してある。測定ピッチは 1mm、リフトオフは 0.5mm である。き裂部分で磁束密度が高い値を示しており、両者に強い相関があることが分かる。

3.2 き裂先端の塑性域

先に学習を行なったニューラルネットワークをこの試験片に適用することの妥当性を調べるために、き裂先端における塑性域を考える。多軸応力の降伏条件として知られる Mises 条件 (せん断ひずみエネルギー条件) は、次式で表される。

$$(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_3 - \sigma_1)^2 = 2\sigma_f^2 \quad (4)$$

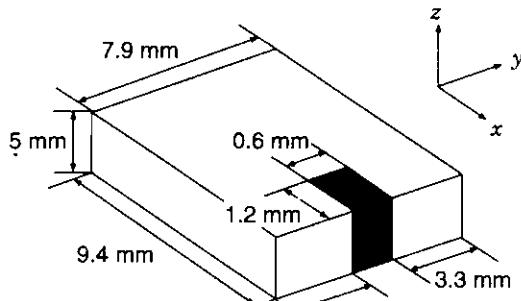


Fig. 3: Sample

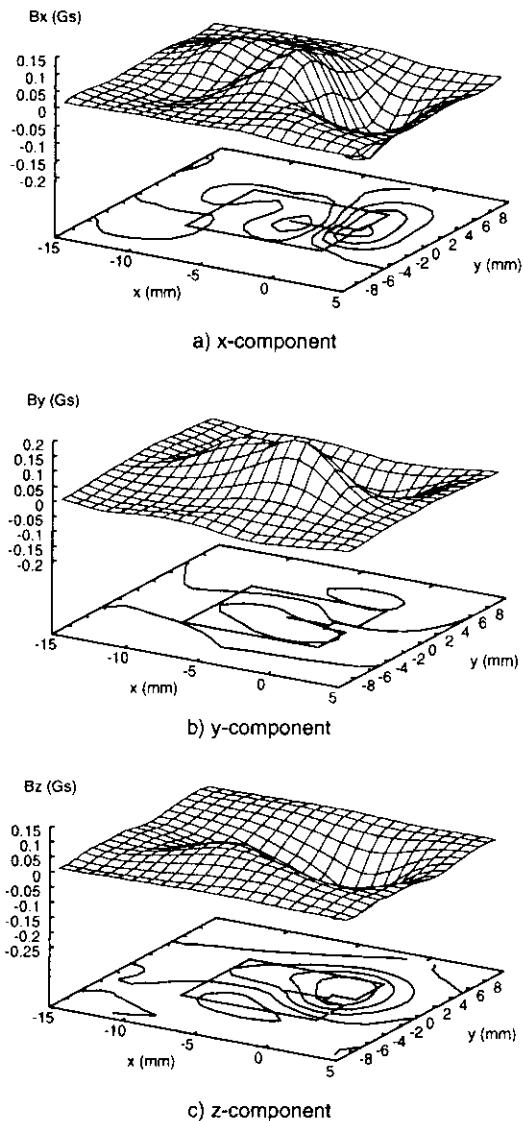


Fig. 4: Mesurement results of Magnetic flux density

但し、 σ_1 、 σ_2 、 σ_3 は主応力 ($\sigma_1 < \sigma_2 < \sigma_3$)、 σ_f は単軸応力の場合の降伏応力あるいは破壊応力である。

Mises 条件から、平面応力状態において、き裂近傍で降伏条件を満たす範囲は Fig.5 の曲線で囲まれる領域になることがわかる。ここで、 $X = x/[(K/\sigma)^2/2\pi]$ 、 $Y = y/[(K/\sigma)^2/2\pi]$ 、ただし、開口モードにおける応力拡大係数を K 、また単軸引張降伏応力を σ とする。

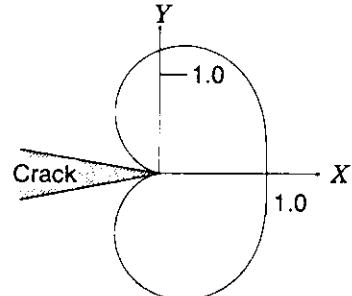


Fig. 5: The yeild region around the head of a crack

Fig.5より、疲労によるマルテンサイト変態領域が円状であると仮定した上のニューラルネットワークの本試験片への適用は妥当であると考えられる。

3.3 磁化分布再構成結果

Fig.6~8に磁化分布再構成結果を示す。Fig.6は磁化の絶対値である。き裂周辺および切断面の一部で高い値を示していることがわかる。Fig.7は磁化 x 、 y 成分のベクトル表示である。き裂の進展方向に関して線対称な分布となっているが、対称軸がき裂部分から y が正の方向に 2 mm 程離れたところにずれている。Fig.8は磁化の z 成分である。Fig.6と同じ傾向を示しており、き裂周辺および切断面の一部で高い値を示していることがわかる。以上のように、磁化分布再構成結果からき裂および切断面の一部で磁化している様子が確認できた。

3.4 磁化分布再構成結果の妥当性

得られた磁化分布再構成結果の妥当性を確かめるために、(1)式を用いてリフトオフ 0.5mm における磁束密度分布を求め、測定データとの比較を行った。 $y = 0\text{mm}$ における磁束密度分布の比較を行う。Fig.9a) が x 成分について、b) が y 成分について、そして c) が z 成分についての比較である。全成分とともに再構成結果から得られた磁束密度と測定データがよく一致していることがわかる。

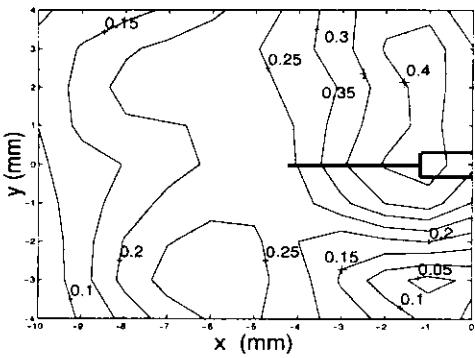


Fig. 6: Magnetization distribution : ($|M|$)

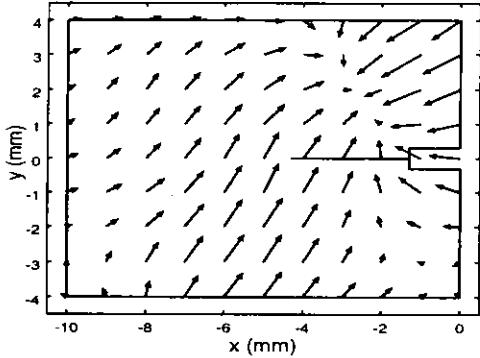


Fig. 7: Magnetization x, y components (M_x, M_y)

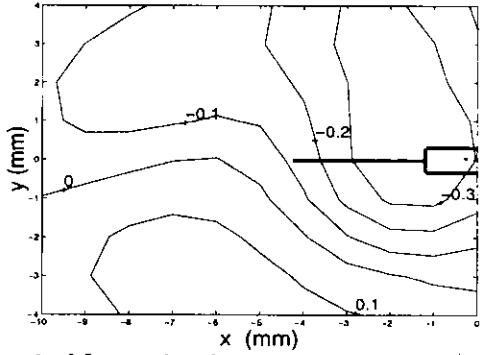
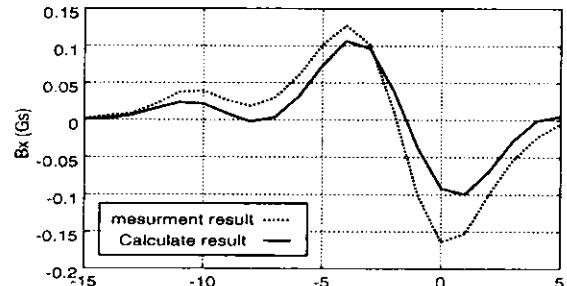


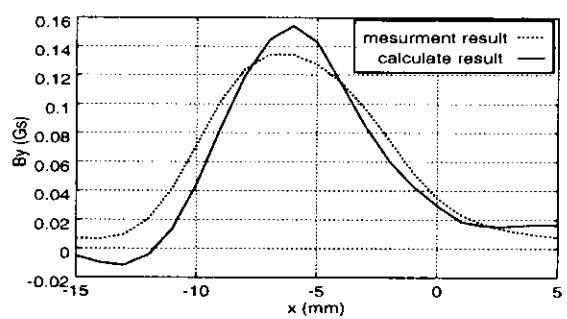
Fig. 8: Magnetization z component : (M_z)

4 結論

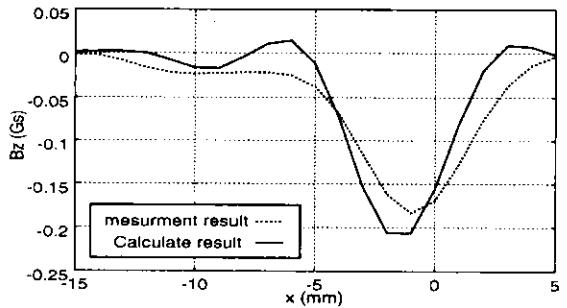
磁束密度分布から磁化分布再構成を行なう手法を開発した。さらに、疲労試験によりき裂が導入された試験片の磁束密度測定データから材料内部の磁化分布を求めた。磁化分布再構成結果からき裂および切断面の一部で磁化している様子が確認できた。また得られた磁化分布の妥当性を確かめるために、磁化分布再構成結果から求めた磁束密度分布と測定データとの比較をおこなったが、両者は良く一致した。今回はき裂が導入された試験片について磁化分布の再構成を行なったが、本手法はき裂発生以前においても有効な手段となるであろうと思われる。



a) x -component



b) y -component



c) z -component

Fig. 9: Comparing Mesurement results and calculation results using reconstructe magnetization distribution

参考文献

- [1] G. Preda, S. Takaya, K. Demachi and K. Miya, *Reconstruction of Magnetic Moments Distribution from 2D scan data using Neural Network*, 「電磁力関連のダイナミックス」シンポジウム講演集, 日本 AEM 学会, (1999), pp.618-622.
- [2] R. C. Popa and K. Miya, *Approximate inverse mapping in ECT, based on aperture shifting and neural network regression*, J. Nondestr. Eval., Vol. 17, No. 4, (1998), pp. 209-221.