積層材料の超音波探傷に対するニューラルネットワークの応用*

本 間 恭 二^{*1}, 宮 下 敏 雄^{*2}Application of Neural Network to Ultrasonic Flaw Detection
in Layered Media

Kyoji HOMMA and Toshio MIYASHITA

Classification of the ultrasonic wave signals emitted from defects such as delamination and inclusions in layered media has been attempted using the neural network technique. In providing both reflected waveform from defects to the input and information of defect type, as well as location to the output, the relationships between the input and the output were learned beforehand by the neural network. In the system, the network learned in terms of detected waveform, however, could not infer correct information of defects for a waveform of a different phase. Therefore, appropriate parameters sampled from the detected waveform were added to the network. Locally connected networks restricting the connection between input layer and output one were proven in a highly precise estimation. It was revealed that the locally connected network is an effective technique to estimate the location of each defect, types of defect, and the amount of defects, within the range of the application of the model.

Key Words: Neural Network, Ultrasonic Inspection, Layered Media, Delamination, Defect Classification

1. 緒 言

近年, 異種材料積層板や c/c コンポジットなどの先進複合材料の開発が進み, 材料の信頼性向上の要求がこれまで以上に増大している。これらの材料内部の欠陥の検出のために超音波探傷法が利用されているが, 波形が複雑で欠陥の判別は困難を伴う。従来の超音波探傷試験は, 熟練した検査技術者の経験と勘によるところが大きい。しかしながら, 検査技術者の育成の困難さから, 経験を必要としない, より高度な超音波探傷法の確立が必要とされている。

自動化の試みとして, ゲート探傷法が最も一般的である^{(1)~(3)}。しかし, 従来のこの方法は, さまざまなタイプの波形の変化や微妙な波形の変化に対応することが難しく, 欠陥の種類までを判別することは困難である。

一方近年, 超音波探傷に対しニューラルネットワークのパターン認識機能を利用した研究例がいくつか見られる^{(4)~(11)}。これらの研究では, 等方性材料を対象としており超音波反射波形も比較的単純である。異種材

料積層板はその音響的異方性のため, 欠陥のない健全材であっても積層界面からの反射波や, 多重エコーが存在するため検出波形は複雑であり, パターン認識機能をそのまま利用することは困難と思われる。そこで本研究では, ニューラルネットワークの構成にあたり, まず, 異種材料積層板の欠陥位置とその種類を同時に推定するための適切な入出力情報を選定したのち, ネットワークの結合形態を変化させ, 推定精度に与える影響について考察した。

2. 超 音 波 探 傷

2・1 探傷に用いた試験片 試験片は, はく離位置, 介在物混入位置, および接着部が目視できるように, 透明な PMMA 板(厚さ 1 mm)と ABS 樹脂板(厚さ 1 mm)を用いた。その構成は, 図 1 のように上から PMMA 2 枚, ABS 2 枚の順に合計 10 枚を接着積層したもので, 全部で九つの界面をもつ。なお, 外形寸法は 50 mm×30 mm で, 全体の厚さは 10 mm となる。各層は市販のエポキシ系接着剤を用いて圧着し, 同種界面, 異種界面を含む種々の位置(第一界面から第九界面)に, はく離および介在物を入れた。はく離は 2 枚の板の面の周囲に接着剤を薄く塗布し, バイスを用いて圧着することで接着剤の浸透しない部分を作ったもの

* 原稿受付 平成 6 年 5 月 20 日。

^{*1} 正員, 電気通信大学 (〒182 調布市調布ヶ丘 1-5-1)。^{*2} 電気通信大学大学院。

である。介在物も同様で接着剤の量のみを増やした。また、音響インピーダンスの異なる介在物として、銅はく、セラミック (PZT) 薄板、ステンレスはく、真ちゅうはくの4種類 (厚さ $10\ \mu\text{m}$ から $50\ \mu\text{m}$) を用い、未学習のはく状介在物に対する推定結果について考察した。なお、これらのはく離および介在物はほぼ円形で $10\ \text{mm}$ から $20\ \text{mm}$ の範囲にある。

2・2 探傷法 ここでは、水浸垂直反射法を用いた (図2)。探触子は中心周波数 $5\ \text{MHz}$ 、収束ビーム幅 $0.5\ \text{mm}$ の広帯域形 (パナメトリクス V 309-SU) を用い、水中に沈めた試験片に超音波を垂直入射し、反射エコーを超音波探傷器 (クラウトクレマ USIP 12) により検出した後、RF 出力を分解能 9 bit、サンプリング間隔 $10\ \text{ns}$ で波形記憶装置 (理研電子 TCL-001-32 k) に記録した。その後、データを EWS (サン SS 2) に転送した。なお、解析には試験片の表面エコーから底面エコーまでのすべての反射波形を用いた。また、

図1 試験片

図2 計測系

図3 参照材からの反射波形

X-Y テーブルを動かすことにより試験片全体を探傷した。

2・3 探傷結果 図3は欠陥のない参照材からの反射波形である。原点付近での表面エコーと $8.2\ \mu\text{s}$ 付近での底面エコーが大きく検出され、それらの間にはそれぞれの接着界面からのエコーが検出されている。また、図4および図5はそれぞれ第四界面にはく離および銅はくを導入した試験片からの反射波形を示し、いずれも欠陥からのエコーが $3.2\ \mu\text{s}$ 付近で検出されている。これらの検出波形の特徴は、欠陥からのエコーの高さの変化以外にも、その位相の変化や多重エコー高さ、底面エコー高さの変化として現れる。

3. ニューラルネットワークによる 検出波形の学習

3・1 ネットワークの構成 使用したネットワークは図6に示す入力層、中間層、出力層の三層からなる階層形である。ここでは、ネットワークの入力として検出波形を用いる。ただし、サンプリングされた全点を入力とした場合ネットワークの規模が大きすぎて、学習およびその後の推定に必要な計算時間が膨大になるため、サンプリング間隔 $10\ \text{ns}$ に対し、 $100\ \text{ns}$ 区間における最大および最小振幅のみを入力とすることで、位相やピークの情報は残しながらデータ数を削減させる工夫をした。その結果、入力点数は200個まで減少した。なお、入力データは最大振幅で基準化し

図4 第四界面はく離材からの反射波形

図5 第四界面銅はく混入材からの反射波

た。これより、入力層ユニット数は200個、出力層ユニット数は、積層界面の位置を表す9個と欠陥の種類を表す2個（はく離または介在物）の合計11個とした。なお、中間層は4個から32個まで変化させて、推定精度に与える影響について考察した。

出力層ユニットは0～1の間の値を出力させた。学習に用いた教師データでは、表1のように、欠陥がある場合、その位置、種類に対応するユニットの出力値を1とする。また、欠陥がない場合にはすべてのユニットの出力値を0とする。したがって、末学習データの推定においては、欠陥の位置とその種類が1に近い出力値を示すユニットによってそれを特定することができる。

なお、学習アルゴリズムは誤差逆伝播則を採用し、出力ユニットの平均学習誤差が 1×10^{-4} に収束するまで学習を繰返した。

3・2 学習波形と推定に用いた波形 学習波形は欠陥のない参照材の界面2箇所と九つある積層界面にそれぞれはく離および銅はくを導入した試験片の各界面2箇所ずつの計36箇所、その総数は38個である。また、学習後のネットワークに末学習波形を入力することで推定を行い、出力結果からネットワークの推定精度を評価した。なお、推定精度の評価基準としては、式(1)で示す推定用データセットにおける二乗出力誤差の総和を用いる。

表1 正答パターン

	Output Unit Number(1~11)									
	Interface Location(1~9)									Inclusion
	1	...	n	...	9				10	
Material without Defect (Reference Material)	0	...	0	...	0				0	0
Material with Delamination in the nth Interface	0	0	1	0	0				1	0
Material with Inclusion in the nth Interface	0	0	1	0	0				0	1

図6 検出波形を入力としたネットワーク

$$E_{all} = \sum_k E_k = \sum_k \sum_i (y_i^{(k)} - y_i^{d(k)})^2 \dots\dots\dots (1)$$

ただし、 E_k はk番めの推定パターンに対する二乗出力誤差の総和、 y_i^k は推定パターンkに対する出力ユニットiの出力値、 $y_i^{d(k)}$ はその目標出力値である。なお、推定用データセットは、参照材、はく離材、介在物混入材からそれぞれ得られた55個の末学習波形から構成される。

3・3 結果と考察 収束までの学習回数は中間層の数にかかわらず、1学習波形当たりの学習回数はほぼ5000回であった。

3・3・1 中間層ユニット数の影響 ネットワークの学習や推定に費やす時間を考慮したとき、その規模は小さいほうが望ましい。そこで、適切なネットワークを構成するため、中間層ユニット数の変化が推定精度に与える影響について検討した。その結果、図7に示すように、中間層ユニット数を4から32までの間で変化させたところ、二乗出力誤差総和は大きな変化を示し、極小値があることがわかった。このネットワークにおいて中間層ユニット数が推定精度に大きな影響を与えているといえる。

3・3・2 推定例 推定のために用いたネットワークの中間層ユニット数は、図7において、最小誤差を示した16個とした。ここで、推定用データセットにおいてその推定結果が好ましくなかったものを調べると、以下の特徴をもつ末学習波形であることがわかった。まず第一に、試験片深部において接着剤厚さの微妙な差異のため、学習波形と比較して欠陥エコーの位相がずれたものが挙げられる。例えば、図8(a)は第九界面はく離材からの反射波で位相のずれたものを示すが、この波形に対する推定結果は図9(a)のような出力値を示し、第9出力ユニットは0.15程度となって正しく特定されていない。

また第二に、末学習な介在物からの反射波形が挙げられる。例えば、第一界面真ちゅうはく混入材からの

図7 推定精度に与えるネットワークの中間層数の影響

波形[図8(b)]に対しては、各出力ユニットの出力値は図9(b)のようになり第一出力ユニットの出力値は0.7程度である。

このように、検出波形のみで学習した場合、学習波形に過剰に反応してしまうため、ネットワークは正しい推定を行っていないといえる。これらの問題を解決する方法として、例えば、さまざまな位相やピークをもつ波形を揃えるといったように、バリエーションを増やすことが考えられる。しかし、これらの波形を増やすためには、より多くの試験片が必要となり、コストと時間がかかる。そこで、必要とされる学習用データセットの数は、これまでと同じで、推定精度の高いニューラルネットワークを構成することを考えた。

(a) 第九界面はく離材からの反射波

(b) 第一界面真ちゅうはく混入材からの反射波

図 8

(a) 図8(a)に対する出力結果

(b) 図8(b)に対する出力値

図 9

4. 検出波形と抽出パラメータによる学習

4.1 ネットワークの構成 ここでは、検出波形のみで学習したネットワークにおいて、大きな誤差要因となった位相のずれに影響されにくい三つのパラメータ⁽¹²⁾[位置エネルギー E_t 、エネルギーモーメント T_{em} 、二次エネルギーモーメント $E_{em}(2nd)$]を反射波形から抽出し、先のネットワークの入力層に付加したものを構成した。なお、出力の正答パターンは検出波形学習ネットワークと同じものを用いた。

これらのパラメータは次式で表される。

$$E_t = \sum_{i=0}^n a_i^2 dt \quad \dots\dots\dots (2)$$

$$T_{em} = \frac{1}{E_t} \sum_{i=0}^n a_i^2 t_i dt \quad \dots\dots\dots (3)$$

$$E_{em}(2nd) = \frac{1}{E_t} \sum_{i=0}^n a_i^2 t_i^2 dt - (T_{em})^2 \quad \dots\dots\dots (4)$$

ただし、 n は全サンプリング点数、 a_i は i 番めにサンプリングされた波形の振幅、 t_i は i 番めの時間、 dt はサンプリング間隔を示す。

ネットワークは入力層と中間層がすべて結合している全結合形ネットワーク[図10(a)]と入力層から中間層への結合が制限され、波形側とパラメータ側に結合が分離した局所結合形ネットワーク[図10(b)]の2種類を構成し、その推定精度について検討した。

4.2 結果と考察 三つのパラメータを付加した全結合ネットワークおよび局所結合ネットワークの収束性は優れ、学習回数は、検出波形のみの学習ネットワークと比較して、約1/2で済み、学習に費やす時間は大きく短縮された。

4.2.1 局所結合ネットワークにおける中間層比率の影響 局所結合形ネットワークに対して、波形側とパラメータ側への中間層ユニットの結合比率とその数を変化させたとき推定精度にどの程度影響を及ぼす

(a) 全結合形ネットワーク

(b) 局所結合形ネットワーク

図 10

かを検討した。図 11 は、中間層ユニットの総数を 16, 24, 32 の 3 パターンに選び、それぞれの結合比率を変化させたときの結果を示す。これより、推定精度は中間層の総数にはあまり関係なく、波形とパラメータの結合比率に大きく依存し、その値は 10 対 6 程度で最小となり最適なネットワークとなることがわかる。

また、図 12 は、これまでに構成した 3 種類のネットワーク (1. 検出波形のみで学習したネットワーク, 2. 検出波形と抽出パラメータで学習した全結合形ネットワーク, 3. 検出波形と抽出パラメータで学習した局所結合形ネットワーク) における二乗誤差総和を欠陥の位置と欠陥の種類に対するものに分けて表示し、比較したものである。波形とパラメータの中間層結合比率が 10 対 6 の局所結合ネットワークにおいて最も誤差が小さくなるとともに、欠陥の種類に対する誤差がほぼ零となることがわかる。なお、ここでは中間層ユニット数はすべて 16 個とした。

4.2.2 推定例 ここでは、検出波形のみの学習では推定結果が適当でなかったものについて、これらの全結合、局所結合ネットワークで再度推定した例を

図 11 中間層への結合比率の誤差に与える影響

図 12 ネットワークによる誤差変化

示す。

図 8 (a) における位相のずれた第九界面はく離材からのデータに対する全結合ネットワークの出力結果を図 13(a) に、局所結合ネットワークの出力結果を図 14(a) に示す。図 9 (a) に示したように第九出力ユニットの出力値は、波形だけでの学習では 0.15 と小さかったものが、波形とパラメータの全結合ネットワークでは 0.53, 局所ネットワークでは 0.81 と大きくなり、第八出力ユニットの出力値は低下した。

また、図 8 (b) に示した、未学習な介在物混入材からのデータに対して、全結合ネットワークでは、検出波形のみの学習ネットワークと比較して、出力値はほとんど変化しない。しかし、局所結合ネットワークにおいては出力値が 0.75 から 0.96 へと大きく変化した。なお、最も音響インピーダンスの低いアルミはくが推定不十分であった。介在物一つだけの学習では音響インピーダンスの影響を考慮する必要がある。

今回使用したモデルの場合、これより、位相のずれた波形や、未学習な介在物混入材からの波形に対して、局所結合形ネットワークがより有効であることがわかった。検出波形のみで学習したネットワークや波形とパラメータで学習した全結合ネットワークは、学習データに過剰に反応してしまい、波形やパラメータの特徴量を適切に表していないため、未学習データに対し

(a) 第九界面はく離材 (b) 第一界面真ちゅうはく混入材

図 13 全結合形ネットワークによる出力結果

(a) 第九界面はく離材 (b) 第一界面真ちゅうはく混入材

図 14 局所結合形ネットワークによる出力結果

図 15 境界付近から得られた反射波形の変化
(欠陥エコー拡大図)

図 16 境界付近のデータに対する出力値の変化

て、不安定な出力結果をもたらすようである。それに対し入力層と出力層の結合を制限した、局所結合形ネットワークは、波形とパラメータが中間層で独立しているため、出力に強い影響を与えて推定精度が高まるものと考えられる。

4・2・3 接着部と欠陥との境界付近での出力値
探傷においては、欠陥の寸法を正しく求めることが重要である。ここでは、欠陥の境界を探索し、得られたデータをネットワークに入力したときの出力結果について考察した。探触子を走査したとき、欠陥の境界付近では探触子から発した超音波のビーム幅の影響を受けて、反射波が図 15 のように連続的に変化していく。この波形は学習波形と比べ位相がずれているため、検出波形のみで学習させたネットワークに入力すると、はく離の内側であっても出力値が小さくなる[図 16 中の (a)]。しかし、局所結合ネットワークにおいては、その出力値は図 16 中の (b) のようになり、探触子の中心が欠陥の境界の直上付近にあるとき出力値は急激に変化する。これは、ユニットの出力に対してしきい値を設定して、最終的に欠陥の有無を判定するのに適した特性であり、欠陥の大きさの評価にもこの局所結合形ネットワークが有効であると考えられる。なお、検

出できる欠陥の最小寸法は探触子の収束ビーム幅(0.5 mm)程度とみられる。

5. 結 言

超音波探傷によって異種材料積層板の欠陥位置とその種類を推定するうえで、改良したニューラルネットワークが有効であることを示した。以下に具体的な結論を示す。

(1) 検出波形のみを入力とするネットワークでは、十分な推定が得られないはく離欠陥に対しても、波形と抽出パラメータを用いた推定方法によって改良される。

(2) 層間の結合に制限を加えた局所結合形ネットワークを利用するとさらに正しい推定が行える。

(3) 介在物の特徴を抽出したネットワークを構成すれば、1 種類の介在物混入材の学習のみによって、音響インピーダンスの近い異なる介在物を抽出することが可能である。

(4) 局所結合形ネットワークの中間層においては、波形側と抽出パラメータ側へのユニットの結合比率が、推定誤差に大きな影響を与える。

最後に、本研究を進めるに当たり、仁平正三氏[(株) マルトー]のご援助と、結城宏信氏(電通大)のご助力があつたことを記し、感謝の意を表す。

文 献

- (1) Porter, A. M. and Shune, J., *Pap Summ ASNT Conf, Fall*, (1990), 130-132.
- (2) Hillger, W., *Acoust. Imag.*, **19**(1992), 575-579.
- (3) Gordon, G. A., Canumala, S. and Tittmann, B. R., *Ultrasonics*, **31**-5(1993), 373-380.
- (4) Baker, A. R. and Windsor, C. G., *NDT Int.*, **22**-2(1989), 97-105.
- (5) 安達・ほか 4 名, 電子情報通信学会技術研究報告, **91**-4, US 91-2(1991), 9-14.
- (6) Thomsen, J. J. and Lund, K., *Mater. Eval.*, **49**-5(1991), 594-600.
- (7) Kitahara, M., ほか 5 名, *Review of Progress in Quantitative NDE*, **10A**(1991), 689-696.
- (8) Song, S. and Schmerr, L. W., Jr., *Review of Progress in Quantitative NDE*, **10A**(1991), 697-704.
- (9) Brown, L. M. and DeNale, R., *Review of Progress in Quantitative NDE*, **10A**(1991), 705-712.
- (10) Damarla, T. R., Karput, P. and Bhagat, P. K., *Ultrasonics*, **30**-5(1992), 317-324.
- (11) Windsor, C. G. and Anselme, F., *Brit J of NDT*, **35**-1(1993), 15-22.
- (12) 山口・ほか 2 名, 第 5 回 AE 総合コンファレンス論文集, (1985), 104-109.