

円形単板圧電素子を分割した多素子超音波トランスデューサとニューラルネットワークによる水中物体の3次元画像化

竹谷 尚[†] 大多和 寛^{††}
岡崎 耕 三^{†††} 田村 進 一^{††}

3次元血管内超音波内視鏡の基礎実験として円形単板圧電素子を36分割した多素子超音波トランスデューサによる水中物体の画像化手法を提案する。画像化には階層型ニューラルネットワークを用い、バックプロパゲーションアルゴリズムにより学習を行った。ネットワークの入力は受信した超音波エコーのエコーピーク時間を用いた。3次元形状を持つ未知パターンに対して画像化実験を行い、本手法の有効性を確認した。その際、ネットワークの構成方法に関して情報量基準による評価を行い、与えられた学習パターンセットに対する入力パターンベクトルの圧縮法の検討を行った。最後に本システムを拡張したより実用的な3次元超音波画像化システムについて検討を行った。

3-D Object Imaging in Water by Multi-element Ultrasound Transducer on Single Circular Chip and Neural Network

HISASHI TAKETANI,[†] HIROSHI OTAWA,^{††} KOZO OKAZAKI^{†††}
and SHINICHI TAMURA^{††}

In this paper, we propose a method of imaging 3 dimensional object in water by multi-element transducer that is made of a single circular chip divided into 36 elements. This is a basic experiment of a 3 dimensional ultrasonic endoscope in the blood vessel. In order to make the image, we use and train a neural network by back propagation algorithm. As the input of the neural network echo peak time of the received ultrasound echo is used. The experiment of reconstructing unknown 3 dimensional shape only by two dimensional learning was done, and the effectiveness of this method was confirmed. In this case we examined how much we can reduce the input dimension from the point of information criterion as well as square error of the output. Finally, 3 dimensional ultrasonic imaging system that is more practical and enhancing the system was examined.

1. はじめに

近年、人間の脳の神経回路を模擬した人工ニューラルネットワークを用いた研究がさかに行われている。我々は多素子超音波センサを試作し、これを用いて得られたエコー信号をニューラルネットワークに入力することにより、センサの前方に置いた3次元物体形状の学習・認識をすることを試みてきた^{1),2)}。その際に2次元物体に対する未学習物体の認識については形状のおよび面積的に挟んだ物体で学習を行うと未学習物

体の画像化が行えることが分かった¹⁾。また3次元形状物体の画像化ではニューラルネットワークの内挿能力を利用して、未学習の距離(奥行き方向)に設置された対象物体を画像化できることを示した²⁾。

固定した超音波アレイセンサを用いて前方物体の画像化を行う研究には次のようなものがある。

- (1) 1次元フェーズドアレイを2次元に拡張したものの;すなわち格子状トランスデューサアレイの位相制御により細い走査ビームを得るもの³⁾⁻⁵⁾,
- (2) 指向性を持ったトランスデューサを平面状に並べることにより、画像化を行う;たとえば格子状配置指向性トランスデューサアレイの個々のエコー遅延時間データ(3次元画像)をニューラルネットワーク処理により修復画像化する方法⁶⁾,
- (3) 音響ホログラム手法;これには同心円状に配置し

[†] 津山工業高等専門学校

Tsuyama National College of Technology

^{††} 大阪大学医学系研究科

Medical School, Osaka University

^{†††} 福井大学大学院工学研究科

Graduate School of Engineering, University of Fukui

たトランスデューサを直交関数で駆動・受信し、相関を利用して画像化を行うもの^{7),8)}、同様のトランスデューサを用いて、球面状反射波を考慮した一種の時空間的逆投影法により3次元物体形状の復元を試みたもの⁹⁾、固定した超音波源から放射された超音波の反射波面をトランスデューサアレイで観測し、逆フーリエ変換手法により粗い物体像を得た後、ニューラルネットワーク処理により、修復するもの¹⁰⁾、

などが提案されている。

しかしながら、これらについては次のような問題がある。(1)は2次元走査に時間を要し、動物体の実時間観測に不利である。(2)は空間的に分離された超音波ビームの独立性を利用して画像化を行うので、処理自体は簡単であるが、小型化が難しい。(3)は複雑な処理を必要とする。またこれらの手法は同一のトランスデューサ素子を並べることを一応の前提としている。そのため、単板分割により得た形状が異なる(したがって指向性などの特性が異なる)複数のトランスデューサ素子を用いた場合、その補正が必要となってくる。ただし、ニューラルネットワークを利用するものについては、その段階で差異を吸収できる可能性がある。本研究では、そのような柔軟性・適応性に加えて、実時間処理、小型化および処理の簡略化を目指して、ニューラルネットワークを利用することにした。ニューラルネットワークを利用する場合には、広い範囲の対象に対して適用可能とするため、汎化能力の検討を行う必要がある。そこで本稿では、これを中心に述べる。

一般に超音波はX線やMRI画像に比べてスペックルノイズの影響などにより画質が劣るが、非観血的・非侵襲的に体内の組織・器官の状態をリアルタイムに映し出せることから、臨床では胎児診断や心臓内の血流分布などの観察・計測によく用いられている。最近問題になっている成人病の原因の1つに動脈硬化がある。この治療法には、大きく分けて内科的および外科的の2つがある。我々が本研究を始めた目的は、このうちの外科的治療に属するバルーン血管形成術において、心臓および血管内に置いたトランスデューサの前方対象物の画像化を行うことである。そのため超小型トランスデューサおよびそのデータ処理法を開発し、最終的には血管内に挿入して3次元な超音波内視鏡としての臨床応用を行うことを目標としている。

本稿ではこれらの結果より未学習の3次元物体を対象にした画像化について述べる。2章では3次元物体画像化システムについて述べ、次に超音波信号の観測

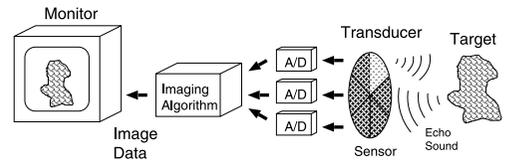


図1 システム概要

Fig. 1 Overview of the experimental system.

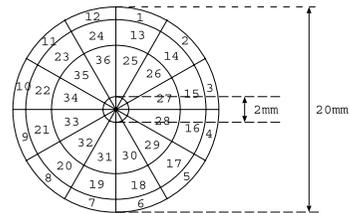


図2 トランスデューサの正面図

Fig. 2 Front view of the transducer.

モデルを示し、本研究で対象としている問題が不良設定問題であることを述べる。続いてニューラルネットワークを用いた超音波信号の画像化手法を提案し、実験的に有効であることを示す。

2. 3次元物体画像化システム

図1に本システムの概要を示す。超音波の送信-受信は、複数個の素子を持った1個の単板小型トランスデューサを用いて行う。トランスデューサの正面像は図2に示すように、円形mmmm単板圧電素子を円周方向に12分割、半径方向に3分割したもので、全部で36素子ある。形状は外径が20mm、内径は2mm、各素子の共振周波数は約9.67MHz(標準偏差:0.096MHz)、表面は共通電極で、各素子の表面積は 8mm^2 程度でどの素子も同じ面積になるように分割してある。図に示すように各素子には1~36の番号が振られている。また各素子の形状は異なるため、各素子の放射特性は異なっていることが予想される。本研究ではトランスデューサの小型化よりもデータ処理法の研究に主眼を置いたため、製作と実験の容易さを考えて36素子20mm径(中心部12素子は約11mm径)のトランスデューサを使用した。全体形状は内視鏡に適した円形とした。この際、異形状素子のデータを処理するため、ニューロ処理のような適応的処理が必要となってくる。なおWatanabeら¹⁰⁾は、ニューラルネットワークを用いた超音波3次元物体認識法を開発しているが、画像復元は主としてフーリエ逆変換法により行っており、ニューラルネットワークは復元画像の修正と認識に用いているのみである。

トランスデューサは直方体のプラスチック容器

(220 mm(L)×150 mm(W)×90 mm(H))の側面(W)中央部に取り付け、ターゲットはトランスデューサの前方18 mm(第1面), 20 mm(第2画), 22 mm(第3面)の3平面内においた。データ入出力はパーソナルコンピュータに接続されたデジタル入出力ポートから行う。

パルス発生部で発生させたパルスを用いて、トランスデューサのどの素子を駆動するか、また各素子に入ってきた受信エコーのうちどの素子のエコーを計測するかは、重複しないように順番にリレーによるマルチプレクサおよびマルチプレクサで選択する。駆動には高速パルスをを用い、70 V幅0.5 μsecの狭い単一パルスを順番に各素子に送り、他の分割素子35個で個別に受信し、1つのターゲットに対して1260組(=36×35)のエコーデータを取得する。

実験に用いたターゲットまでの距離、18, 20, 22 mmは、トランスデューサ前面に施した厚さ約1.5 mmの耐水樹脂面からの距離である。樹脂内部の伝搬速度を水中の3倍とすれば、実際のトランスデューサからターゲットまでの超音波の往復時間はそれぞれ最短距離に対して24.6, 27.3, 29.9 μsecとなる。そこでそれぞれのデータについては、1個の素子にパルスを印加してから、23 μsec後に選択された受信素子出力のサンプリングを開始し、43 μsec後まで20 μsec間行う。サンプリング速度100 MHz(サンプリング間隔10 nsec)で、サンプリング点数2048点で行う。A/D変換にはデジタルオシロスコープを用い、デジタル化されたエコーデータはオシロスコープのGPIBインタフェースを通してパーソナルコンピュータに転送される。

2.1 画像化対象

今回、画像化を行う対象は矩形を組み合わせたものに限定した。実験に用いたターゲットは、厚さ約3 mmのアクリル製の板を加工したもので、その形状を図3(a)~(g)に示す。最小のターゲットAは4 mm×4 mmの大きさで、他はそれを矩形に連結したもので、たとえばFは12 mm×16 mmの大きさである。

ターゲットの位置は、トランスデューサの前方18, 20, 22 mmのトランスデューサの中心軸に垂直な3つの平面(第1面, 第2面, 第3面)上で、図3に示すように16 mm×16 mmの正方形の領域内に置く。縦横の1目盛りは4 mmで16個の小正方形から構成されており、ターゲットA~Gを学習用ターゲットとする。本研究ではこのように限られた種類のパターンを学習し、凹凸のある未知対象物体の画像化を試みる。

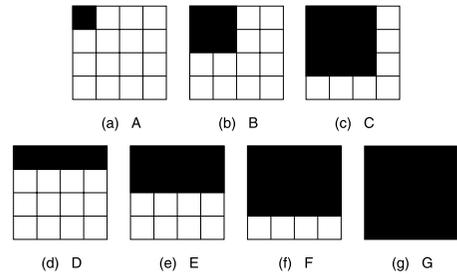


図3 学習に用いたターゲット

Fig. 3 Target for neural network trainig.

各平面におけるターゲットの配置は、ターゲットAについては、図3(a)に示すように、16個のそれぞれの小正方形の16カ所に置いた。B, C, Gについては、図3(b), (c)の大きさの正方形を、図3の16個の小正方形からなる面上で、縦横に順番に基本単位ずつずらしていき、それぞれ9, 4, 1カ所に置き、正方形パターンでは合計30個(=∑_{i=1}⁴ i²)を観測した。D, E, Fについては、16個の小正方形からなる正方形内で水平および垂直方向に順番に基本単位ずつずらし、さらに90度回転した8, 6, 4カ所にそれぞれ配置し、合計18個(=2∑_{i=2}⁴ i)のターゲットを観測した。

2.2 受信エコーと前処理

ターゲットCをトランスデューサの正面前方18 mmに置き、ある素子(No.1)を駆動して、別の素子(No.2)で受信したエコーの波形例を図4に示す。図4において、1 μs付近でパルスを発射している。25 μs付近の高周波振動を第1エコー、28 μs付近の高周波振動を第2エコーとすると、第1エコーはターゲット前面で反射したもので、第2エコーはターゲットの背面部分で反射したものである。図4の全体にわたる低周波振動は、本実験で用いたトランスデューサが単板を分割しただけのものであるため、駆動素子の振動が円形の素子全体に伝わったものと考えられる。すなわち高周波振動は素子の厚み(0.4 mm)方向の振動であり、低周波は直径(20 mm)方向の振動であると仮定すれば直径方向の周波数は約193 kHzとなり、低周波振動の周波数と一致する。また低周波振動は高周波振動に比べて振幅が小さいため反射波は観測されていないと考えられる。

これらのデータに対してバンドパスフィルタ処理を施すことによりエコーから不要な低周波成分を除去する(図5)。図中の高周波成分は送受信素子の組合せによっては観測されないものもある。図5の24 μsecから20 μsec間サンプリングを行い、2048点のデータ

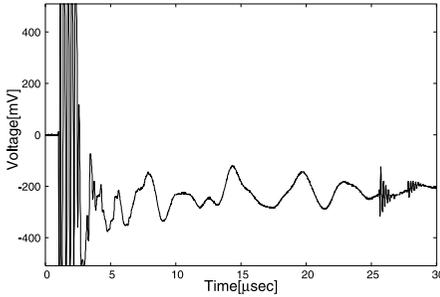


図 4 ターゲット C に対する受信エコー例 (発射素子: No.1, 受信素子: No.2)

Fig. 4 Example of received echo for target C (Transmitted: No.1, Received: No.2).

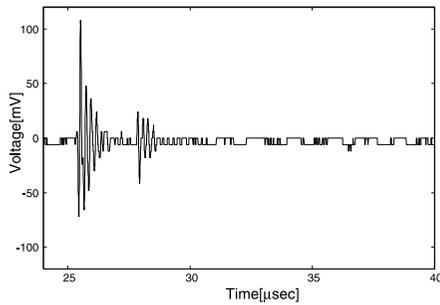


図 5 図 4 に対する低周波成分を除去した受信エコー

Fig. 5 Ultrasound echo with low frequency component reduced for Fig. 4.

を得る。これらのデータを用いて対象物体の 3 次元形状の復元を行った。

3. 超音波信号を用いた 3 次元画像化

3.1 観測モデル

図 6 において原点上に receiver, Y 軸上の距離 d 離れた位置に transmitter, Z 軸方向に距離 l 離れた位置に target を配置する。ただし送受信を行う素子は指向性¹¹⁾を持ち、伝達経路において信号は減衰しないものとする。時刻 $t = 0$ において信号 $f(t)$ が transmitter より発射されたとすると, target 上の点 a で観測される信号 $g(t)$ は指向特性 $D_T(\theta_T)$ に従い減衰し, 伝播経路の距離に比例した時間遅れを生じ, 次式で表される。

$$g(t) = f\left(t - \frac{l \cos \theta_T}{c}\right) D_T(\theta_T)$$

ただし c は水中での超音波の伝播速度である。また, 点 a から発射される信号を $G(t)$ とすると receiver で観測される信号 $h(t)$ は

$$h(t) = G\left(t - \frac{l \cos \theta_S}{c}\right) D_S(\theta_S)$$

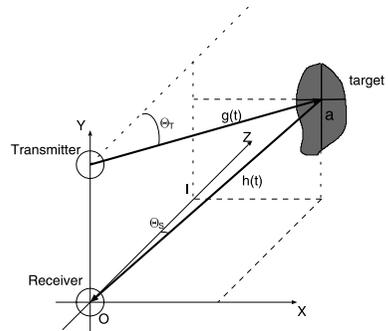


図 6 超音波信号観測モデル

Fig. 6 Model observed ultrasonic echo.

となる。 $g(t)$ が点 a で乱反射すると仮定すると点 a から発射される信号は $G(t) = g(t)$ となり $h(t)$ は

$$h(t) = f\left(t - \frac{l \cos \theta_T + l \cos \theta_S}{c}\right) D_T(\theta_T) D_S(\theta_S)$$

となる。最終的に receiver において観測される信号 $H(t)$ は次式により示される。

$$H(t) = \iint_{\text{target}} h(t) dx dy \quad (1)$$

となる。式 (1) より target の形状を求めることが可能となれば対象物体の画像化が可能となる。しかし, 上式では

- (1) 本質的に式 (1) は複数の解を持つ (不良設定問題),
- (2) $f(t)$, $D_S(\theta)$ および $D_T(\theta)$ はトランスデューサの形状などの特性に依存しているため, 実測する必要がある,

などの問題点があげられる。上記の問題点に対応するためニューラルネットワークによる適応型処理により画像化を行った。

3.2 ニューラルネットワークによる超音波信号の画像化学習

本研究では, RF レベルの信号を直接用いて対象物体の形状を推定することはデータ数の増加により困難と考え, 最大エコーピーク時間を特徴量として抽出し, 画像化を行うことを検討した。

図 7 にエコーピーク時間を 2 次元状に配置したものの (エコーピーク時間図と称する) の例を示す。水平方向は超音波パルスを発射した素子の番号, 垂直方向は受信した素子の番号に対応し, 各点の画素値はエコーピークが受信された時間に比例する (エコーピークが早く観測されるほど値が大きく, 図では明るく表現されている)。エコーが観測されない場合は値を 0 とし, 図では黒とした。対角成分は送受信の素子の番号が同

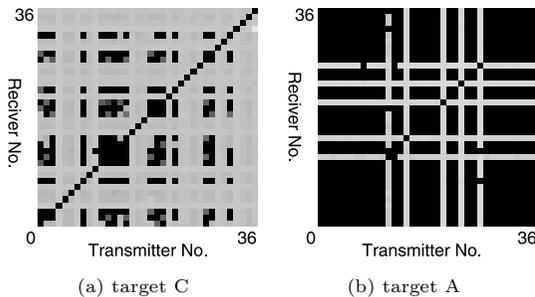


図7 各ターゲットの36×36エコーピーク時間図例

Fig.7 Examples of 36×36 echo peak time array of each target.

一であるため、データを得ていない。図7の水平・垂直方向の線分は分割した圧電素子の形状に関する指向性によるもので、観測するセンサの正面付近にターゲットがあればエコー信号が観測され、エコーピーク時間図中の濃淡値として表現される。

画像化には3層構造のフィードフォワードネットワーク(中間層ユニットおよび出力層ユニットの入出力関数にはシグモイド関数を使用)を使用し、学習にはバックプロパゲーションアルゴリズムを用いた。入力層のユニット数は1,296(36×36)とし、エコーピーク時間図の次元数と一致させた。すなわち1つの受信サンプリング値系列データに対して、サンプリング開始点からエコー信号の最大振幅位置までの時間を1個の入力データとしている。中間層のユニット数は10~200ユニットとし、出力層のユニット数は16ユニットで4×4の2次元行列表示である。学習には、ターゲット種別(括弧内は移動力所/1面)、A(16カ所)、B(9カ所)、C(4カ所)、D(8カ所)、E(6カ所)、F(4カ所)、G(1カ所)の合計48パターンとし、これらを

- (1) 第1面のみで提示した48パターンを学習パターンとしたもの(2次元情報の学習)、
- (2) 第1, 2, 3面の3カ所に提示した48×3=144パターンを学習パターンとしたもの(3次元情報の学習)、

の2通りについて学習を行った。なお教師信号の値は第1面、第2面および第3面でそれぞれ0.95, 0.65, 0.35とし、その画素に対象物体がない場合は0.05とした。学習は出力層ユニットあたりの平均2乗誤差が閾値(=0.0001)以下になれば学習終了とした。ニューラルネットワークの重みは[-0.1, 0.1]の一樣乱数で初期化し、シグモイド関数の傾き係数0.75, 学習パラメータは荷重修正係数0.001, 荷重忘却係数1.0とした。これらのパラメータを用いて、1000万セットの

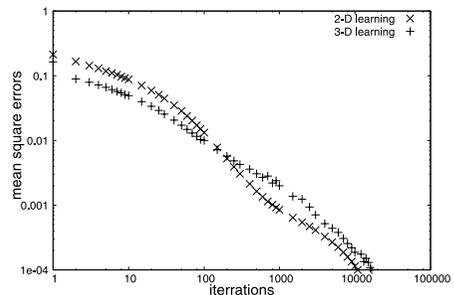


図8 エコーピーク時間図による画像化の学習状況(中間層ユニット=100の場合)

Fig.8 Learning process of the imaging using echo peak time array (number of hidden units = 100).

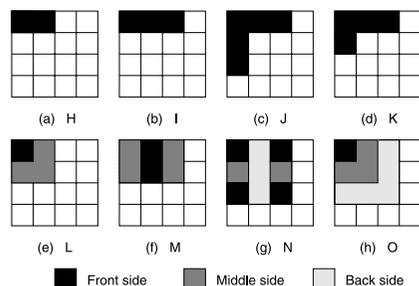


図9 画像化実験に用いたターゲット

Fig.9 Target for test with trained neural network.

提示を上限として学習を行った。図8に学習状況を示す。中間層ユニット数を変更した場合も同様の曲線が得られているが、中間層ユニット数によっては閾値に到達しないものもある。

3.3 未知ターゲットの画像化

図9に学習済みネットワークに提示した未学習パターンを示す。ターゲットの最小単位は2.1節と同様に4mm×4mmとし、穴などがない単純連結形状のターゲットを対象とした。図9(a)-(h)をターゲットの最前部が第1面として観測空間内で平行移動させたものを3.2節の学習済みネットワークに提示し、画像化実験を行った。ただし(e)および(f)についてはターゲットの最前部を第1面および第2面にセットしたのも未知ターゲットとして使用した。パターン数はそれぞれH(24カ所)、I(16カ所)、J(4カ所)、K(6カ所)、L(18カ所)、M(24カ所)、N(4カ所)、O(4カ所)である。

図10に提示したターゲットモデルを示す。図中の左の円形の物体はトランスデューサを示し、左の矩形物体が画像化を行った物体である。図11にニューラルネットワークによる画像化を行った例を示す。図12、図13に別の例を示す。

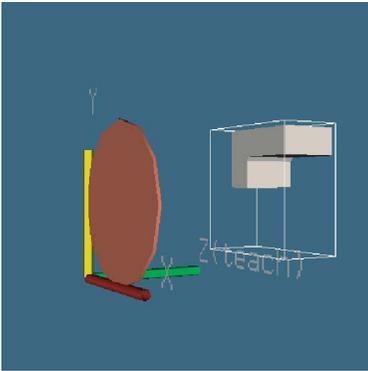


図 10 ターゲット “K” のモデル
Fig. 10 Model for target “K”.

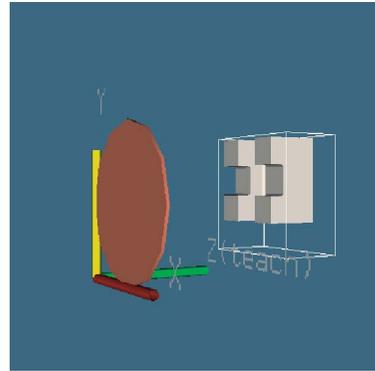


図 12 ターゲット “N” のモデル
Fig. 12 Model for target “N”.

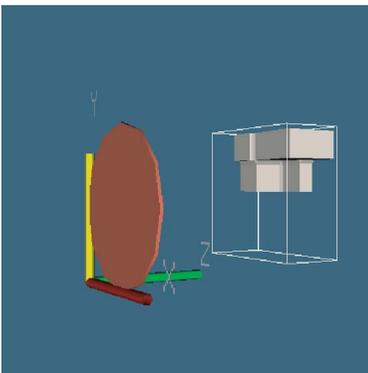


図 11 ターゲット “K” の画像化例
Fig. 11 Output result for target “K”.

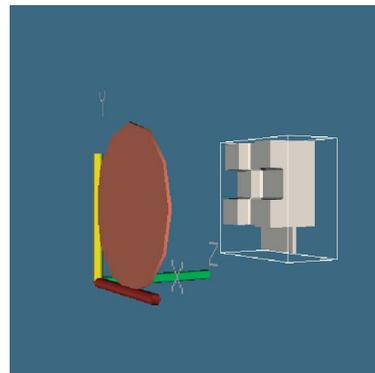


図 13 ターゲット “N” の画像化例
Fig. 13 Output result for target “N”.

図 11, 13 の例では X-Y 平面内での物体の大きさ、位置および形状ともに良好に画像化されているのが確認できる。しかし Z 方向に関しては十分に復元できているとまではいえない。この理由として X, Y 方向に関しては独立した個別の入力素子で受信されるのに対して、Z 方向の画像化に使用される情報がエコーピーク時間という同一素子上での連続値として用いられているため十分な分離精度が得られていないことがあげられる。

また図 13 より複数の矩形により構成されたターゲットに対しても画像化が行われていることが確認できる。特徴量として採用したエコーピーク時間図はターゲットに対して必ずしも線形性を有しておらず、3次元画像を再構成する場合に非線型処理が必要となる。本研究では特に困難であるエコーピークの情報把握についても、ある程度はニューラルネットワークの非線型性により対応可能になると考えられる。本研究で採用したターゲットより複雑な形状（たとえば穴を持つ形状や穴を多数持つ網状形状およびそれらに奥行きを加えたもの）を持つターゲットにおいては、複数面で反射

したエコーが受信素子上で指向性に従い合成され、エコーピークが観測される。これはかなり非線型な合成となり、学習の困難さが増すが、3次元情報の獲得に奥行き情報を持つ学習パターンを加えることにより対応できたのと同様に、複雑な形状を一部に持つパターンを加えて学習を行うことにより、ある程度は本提案手法で対応可能であると考えられる。

4. 特徴の縮約化

3.3 節の実験では入力データは 36 素子を個々に用いているが、ターゲットの複雑さに対して多すぎる可能性がある。そこで受信素子 35 個のピーク時間を平均したデータ（投影データと称する）を作成し、これを用いて学習および未学習パターンによるテストも行った。

図 14 に中間層ユニット数を変化させた場合の未学習パターンに対する平均 2 乗誤差を示す。ただし、中間層ユニット数が 30 以下では学習時の平均 2 乗誤差が閾値以下にならなかったが 1000 万セットの学習で打ち切り用いている。平均 2 乗誤差 E は次式を用いた。

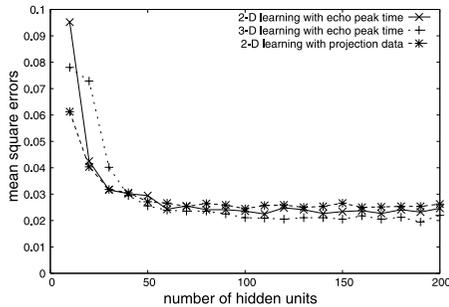


図 14 3次元パターンを含む未学習パターンに対する平均2乗誤差
Fig. 14 Mean square errors for unknown targets including 3-D patterns.

$$E = \frac{1}{NK} \sum_{i=1}^N \sum_{k=1}^K (O_{ik} - t_{ik})^2 \quad (2)$$

ただし、 N はパターン数、 K は出力層ユニット数、 O_{ik} はパターン i を提示した場合の出力層ユニット k からの出力、 t_{ik} はパターン i の出力層ユニット k の教師信号である。

図 14 より、エコーピーク時間図を用いるネットワークに関しては、2次元情報のみを学習したネットワークと3次元情報を学習したネットワークが同等の汎化能力を有していることが確認できる。

階層型ニューラルネットワークでは中間層ユニット数を多くすると学習パターンについて任意の関数を任意の精度で近似可能である¹²⁾ことが知られているが、本稿で用いた学習データは雑音をともなう実測データでS/N比が低いため、再構成された画像の精度には限界があることが考えられる。この改善策として

- (1) 同じターゲットに対して多数回観測し、これらを用いて学習を行う、
- (2) 式(1)より理論的にシミュレートした人工的な観測データを作成し、これを用いて学習を行う、などが考えられる。

一般に次元数の異なる学習パターンセットに同等の情報量がある場合、次元数が少ない方が入力パターン空間に対する学習パターンの相対密度が上昇するためネットワークの内挿(汎化)能力が向上すると考えられる。そこで本研究では上記のように各受信素子のエコーピーク時間の平均値を特徴量として使用することを試みたのである。その際の未学習パターンに対する平均2乗誤差が図14に示されている。パターンは48種とし、第1面のみにターゲットをおいた場合を学習セットとした。図より投影データを用いて2次元情報を学習したネットワークがエコーピーク時間図で学習を行ったものとはほぼ同等の汎化能力を持つことが確認

される。これは入力層ユニット数が1296から36へ減少したにもかかわらず、入力パターンに含まれる情報量が減少していないことが示唆される。

5. 考 察

ニューラルネットワークを使用する場合、汎化能力が問題となる。ここでは今回取り扱った超音波の3次元画像化の複雑さおよびネットワークの汎化能力を情報量基準に基づくAIC¹³⁾およびMDL¹⁴⁾を適用して評価を行った。

$$AIC = -2\tilde{l}(\{t_i\}) + 2F \quad (3)$$

$$MDL = -\tilde{l}(\{t_i\}) + \frac{F}{2} \log N \quad (4)$$

ただし、 F はモデルの自由度とする。最大尤度 $L(\{t_i\})$ および最大対数尤度 $l(\{t_i\})$ は次式¹⁵⁾で近似している。

$$L(\{t_i\}) \approx \frac{\exp\left[-\sum_{i=1}^N \sum_{k=1}^K O_{ik}(1-t_{ik})\right]}{N^K \prod_{i=1}^N \prod_{k=1}^K \{1 + \exp(-O_{ik})\}} \quad (5)$$

$$l(\{t_i\}) \approx -\sum_{i=1}^N \sum_{k=1}^K O_{ik}(1-t_{ik}) - \sum_{i=1}^N \sum_{k=1}^K \log(1 + \exp(-O_{ik})) \quad (6)$$

本稿ではこれらの評価基準を入力パターンの次元数の評価に用いた。エコーピーク時間図を使用した場合は入力パターン空間の次元が多すぎるため、学習において適切な入出力関係を獲得するため無駄な労力を用いている可能性が強い。これは図14において平均値による圧縮(投影データ)を用いても出力の平均2乗誤差はほとんど変わらないことからいえる。今の場合、 36×36 エコーピーク時間図を用いるニューラルネットワーク構成に対しては相対的に学習パターン種数が少なかったともいえる。しかしながら、より多くのパターン種を学習してより汎用的な画像化を行うためには、ネットワークを構成する必要最小限の次元数を知る手法を確認してが必要である。

図15に入力データの次元数を変化させた場合にモデルの自由度 F (重みの数) に対するAIC, MDL および $l(t_i)$ を示す。ここでは以下の特徴量を用いた構成方法について比較を行った。

mean36 各受信素子でのエコーピーク時間の平均 (36次元入力)

mean36x3 各受信素子でのエコーピーク時間の円周方向での平均 (36x3次元入力)

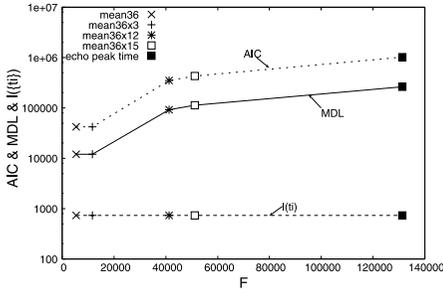


図 15 2次元パターンを学習したネットワークの情報量基準による比較 (中間層ユニット数=100 の場合)

Fig. 15 Comparison between AIC, MDL and $l(t_i)$ with network trained with 2D targets.

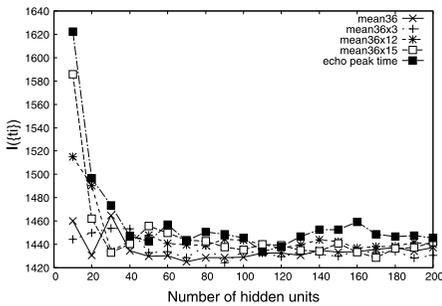


図 16 中間層ユニット数の変化に対する $l(t_i)$ (学習: 2次元パターン, テスト: 3次元パターン)

Fig. 16 Comparison between $l(t_i)$ for increasing number of hidden units (training: 2D target, test: 3D target).

mean36x12 各受信素子でのエコーピーク時間の半径方向での平均 (36×12次元入力)

mean36x15 “mean36x3” と “mean36x12” を足し合わせたもの (36×15次元入力)

echo peak time エコーピーク時間図 (36×36次元入力)

図 16 には中間層ユニット数を変化させた場合の未学習パターンに対する AIC のうちの $l(t_i)$ を示す。図より中間層ユニット数が 40 以上では各構成方法とも同程度の値を示しており、本実験で使用したテストパターンに対する同程度の汎化能力を有していることが確認できる。図 15 で厳密には “mean36x3” が AIC および MDL と “mean36x36” と比較してわずかに小さい値を示しているが、これは図 16 において中間層ユニット数 100 のときの各方式の変動による差と考えられ、有意な差とはいえない。しかし全体として入力データの次元数は “mean36” および “mean36x3” でも十分であることが確認できる。

AIC および MDL を使用したネットワークの評価では、ネットワークの規模が小規模な場合は問題ない

が、本研究で使用する規模のネットワークでは第 2 項の影響が非常に強い。本来評価基準はネットワークの規模に左右されないものが望ましく新しい基準が必要である。

本研究ではデータの前処理、ニューラルネットワークの構築および 3 次元表示にパーソナルコンピュータ (CPU: AthlonXP2800+, OS: Linux) を用いた。実験システムの都合上、現在は 1,260 組のデータを取得するのに約 17 分必要であるが、35 力所同時にエコーを取得することができれば撮影時間の短縮が可能である。信号がターゲットで反射し、観測されるまでの時間を約 $40 \mu\text{sec}$ と仮定すると、 $40 \mu\text{sec} \times 36 = 2.52 \text{ msec}$ となる。各処理時間は前処理: 5.11 sec, ニューラルネットワークによる画像化処理 (中間層ユニット数=100): 1.24 msec であった。ただし前処理は 1260 組のデータに対して独立した処理であるため、並列化することにより 4.06 msec で処理することが可能となる。よって A/D 変換と画像の 3 次元表示を除くシステム全体の処理時間は 7.82 msec となり、これはフレームレート 128.9 fps に相当し、心臓などの拍動する臓器を対象とした計測に適応可能であると考えられる。

また本システムをより実用的なものへ拡張する場合について検討を行った。設計値として解像度 100×100 , フレームレート 30 fps, 計測範囲をセンサの前方 20 mm 付近と仮定すると超音波エコーの往復時間から送受信素子数が $833 (=1/(40 \mu\text{sec} \times 30 \text{ fps}))$ となる。入力層ユニット数 833, 出力層ユニット 10,000 とすると、入出力層のユニット数の比より現在のシステムでは解像度 21×21 ($\approx 36 \times 10000/833$) と同等になる。本研究で使用した計測システムは 1 辺が 4 mm の矩形を基本単位とし $16 \text{ mm} \times 16 \text{ mm}$ を計測空間としたが、同空間で $21 \times 21 \text{ pixel}$ の解像度が必要となり、矩形の基本単位を 0.76 mm に縮小することに相当する。このとき、 $3772 (=21^2 + 20^2 + \dots + 1^2 + 2(21 + 20 + \dots + 2))$ パターン種の学習が必要となるが、実現性についてはさらに議論する必要がある。使用する特徴量としてはさらに検討する必要があるが、ニューラルネットワークの規模が大きくなるにつれて学習に係るコストは膨大になり、サブネットに分割するなどの工夫が必要となるであろう。

6. む す び

本研究では、 4×4 のターゲットに対し、9.67 MHz/36 素子を持つトランスデューサにおける各素子を順次駆動し、それ以外のすべての素子で受信することにより、1,260 個の時系列 RF (高周波) データを得た。時系

列データ自体は情報量が多いため、エコーの最大ピーク位置を1つの特徴としてとして圧縮・表現した。したがって、ニューラルネットワークではRFレベルでのホログラム的、もしくは開口合成的な処理ではなく、振幅・包絡線レベルでの処理がなされている。秋山ら¹⁶⁾は同相加算による画像化を行っているが、本研究では各素子の送受信特性が異なるため適応が困難である。今後、開口合成的な処理を可能な限り取り入れることができるならば、走査時間短縮などの性能向上につなげることができるであろう。すなわち、位相制御で2次元の走査を行うフェーズドアレイ方式では、1画面の走査にターゲットの分解能数×エコー時間かかる。それに対して本方式でRF信号をそのまま、もしくはそれからの抽出特徴を取り入れ、ホログラム的処理を行うことができるならば、通常のフェーズドアレイのような送信時のビーム形成ではなく、受信後の後処理で反射波面の形状から対象を再構成することになり、基本的には1素子の駆動だけでよく、1×エコー反射時間で撮像が可能である(現在は素子数×エコーの反射時間で行っている)。眞溪ら¹⁷⁾は8分割された直径2mmのリングアレイ(振動子中心周波数10MHz)を試作し、プローブ前方の画像化を行っている。本研究で同様のプローブを使用した場合、56組(=8×7)のデータを取得することが可能となるが、5章より十分な次元数であると考えられる。

我々は前方の3次元像を実時間で得る超音波画像診断装置の基礎的な考察を行った。前報では、興行きを持つターゲットの3次元像について考察を行ったのに対して、本稿ではより実用的な画像化手法について提案し、実験により有効性を確認した。その際、実験システムに依存した入力パターンの特徴を利用することにより、ニューラルネットワークの汎化能力を保ったまま、入力パターン空間の次元数を大幅に減少させたネットワークの構築が可能となった。また各構成方法について情報量基準に基づく評価を行った。加えてより実用的なシステムについて検討を行った。

以上、任意の環境と対象に対して使える広い汎化性を得るという最終目標に対し、ある程度の汎化能力は得られることが確認できた。しかしながら、もっと別の特徴抽出も考慮して、よりいっそうの性能向上を図りたいと考えている。たとえば正方形だけではなく、生体の目における $\nabla^2 G$ のように、負の反応を持った基本パターンなども考えておく必要がある。これらを含め、任意の3次元形状がより正しく復元できるようなできるだけ少数の基本パターンを探す必要がある。

参考文献

- 1) 大多和寛, 河合秀夫, 佐藤嘉伸ほか: ニューラルネットワークと多素子超音波トランスデューサによる水中物体の映像化, *Med. Imag. Tech.*, Vol.13, No.5, pp.753-761 (1995).
- 2) 大多和寛, 河合秀夫, 佐藤嘉伸ほか: ニューラルネットワークと多素子超音波トランスデューサによる水中物体の3次元画像化, *Med. Imag. Tech.*, Vol.14, No.5, pp.561-570 (1996).
- 3) Pilkington, T.C., Ideker, R.E. von Ramm, O.T.: National Science Foundation/Engineering Research Center of Emerging Cardiovascular Technologies, *Proc. IEEE*, Vol.81, No.1, pp.79-94 (1993).
- 4) Oralkan, O., Ergnum, A.S. and Cheng, C.-H., et al.: Volumetric Ultrasound Imaging Using 2-D CMUT Arrays, *IEEE Trans. Ultrasonics, Ferroelectrics, and Frequency Control*, Vol.50, No.11, pp.1581-1594 (2003).
- 5) Fronheiser, M.P. and Light, E.D., et al.: Real-Time, 3-D Ultrasound with Multiple Transducer Arrays, *IEEE Trans. Ultrasonics, Ferroelectrics, and Frequency Control*, Vol.53, No.1, pp.100-105 (2006).
- 6) 吉澤信幸: 超音波センサとニューラルネットワークを用いた三次元物体認識, *EMC on.*, Vol.53, pp.98-104 (1992).
- 7) 湯浅 肇, 石原知明, 高野 幸ほか: 波面符合化送信方式による水中撮像装置, *信学技法 US*, 94-7, pp.45-52 (1994).
- 8) 田村安孝: 計算機処理による超音波イメージング, *Med. Imag. Tech.*, Vol.17, No.1, pp.26-33 (1999).
- 9) Nambu, M., Doi, M., Matani, M., Oshiro, O. and Chihara, K.: A High-Speed Image Acquisition using Ultrasonic Ring Array Probe, *Computers in Cardiology*, Vol.26, pp.355-358 (1999).
- 10) Watanabe, S. and Yoneyama, M.: An Ultrasonic Visual Sensor for Three-Dimensional Object Recognition Using Neural Networks, *IEEE Trans. Robotics Automation*, Vol.8, No.2, pp.240-249 (1992).
- 11) 城戸健一ほか: 基礎音響工学, pp.84-97, コロナ社 (1990).
- 12) 船橋賢一: ニューラルネットワークの Capabilities について, *信学技法*, MBE88-52 (1998).
- 13) Akaike, H.: A new look at the statistical model identification, *IEEE Trans. Automatic Control*, Vol.19, No.6, pp.716-723 (1974).
- 14) Rissanen, J.: A universal prior for integers and estimation by minimum description length, *The Annals of Statistics*, Vol.11, No.2, pp.416-

431 (1983).

- 15) 栗田多喜男：情報量基準よる3層ニューラルネットワークの隠れ層のユニット数の決定法，電子情報通信学会論文誌 D-II，Vol.J73-D-II，No.11，pp.1872-1878 (1990).
- 16) 秋山いわき，矢野喜代志：開口合成と逆投影による半球面の映像化，日本超音波医学会基礎技術研究部会資料，BT96-4，pp.9-12 (1997).
- 17) 眞溪 歩，藤本直登志，南部雅幸ほか：超音波マイクロリングアレイプローブを用いた前方3次元可視化，電気学会誌論文集，117-E-7，pp.359-363 (1997).

(平成 18 年 8 月 24 日受付)

(平成 19 年 3 月 20 日採録)

(担当編集委員 眞鍋 佳嗣)



竹谷 尚

昭和 41 年生。昭和 63 年鳥取大学工学部電気工学科卒業。平成 2 年同大学大学院工学研究科電気工学専攻課程修了。平成 4 年津山工業高等専門学校電子制御工学科助手。平成 11 年津山工業高等専門学校電子制御工学科講師。画像処理，パターン認識，ニューラルネットワークの研究に従事。電子情報通信学会会員。



大多和 寛

昭和 31 年生。昭和 56 年大阪市立大学理学部物理学科卒業。昭和 58 年大阪府立大学大学院修士課程修了。平成 3 年大阪大学歯学部卒業。平成 9 年同大学大学院医学研究科博士課程修了博士(医学)。ニューラルネットワークの研究に従事。



岡崎 耕三

昭和 42 年広島大学工学部卒業。昭和 44 年同大学大学院修士課程修了。同年宮崎大学工学部助手，昭和 45 年鳥取大学工学部助手，現在福井大学大学院工学研究科教授。工学博士。この間，疑似ランダム系列のその応用，画像処理，医用画像処理等の研究に従事。昭和 58 年 Pattern Recognition Society 論文賞受賞。計測自動制御学会，日本音響学会，電気学会等各会員。



田村 進一 (正会員)

昭和 19 年生。昭和 41 年大阪大学基礎工学部電気工学科卒業。昭和 46 年同大学大学院博士課程修了。同年同大学基礎工学部助手，現在同大学医学部教授。工学博士。この間，通信方式，パターン認識，画像処理，人工知能等の研究に従事。電子情報通信学会，日本認知科学会，日本 ME 学会，人工知能学会，Pattern Recognition Society，IEEE 等各会員。