

# 弾性体の部分観測による ニューラルネットワークを用いた変形推定

山本 詩子<sup>1,a)</sup> 中尾 恵<sup>1</sup> 大関 真之<sup>2</sup> 松田 哲也<sup>1</sup>

**概要：**本研究では、内視鏡手術時に臓器を鉗子で把持し力を加えて変形させる状況を想定し、計算機内で変形をシミュレーションした3次元弾性体の変形推定を行った。初期形状が既知の条件下で、作用点に与える力の方向と大きさを様々なに変化させて変形した弾性体形状を非線形有限要素法で時間をかけて高精度に計算してデータ取得し、部分観測点における初期形状からの変位と弾性体全体の非観測点変位との関係をニューラルネットワークにより学習した。事前に学習したニューラルネットワークを新たな変形に適用し、非常に少ない部分観測から全体の変位を推定できることを示した。

**キーワード：**変形推定、ニューラルネットワーク、部分観測、非線形有限要素法

## Shape Estimation of Elastic Object by Partial Observation with Neural Network

UTAKO YAMAMOTO<sup>1,a)</sup> MEGUMI NAKAO<sup>1</sup> MASAYUKI OHZEKI<sup>2</sup> TETSUYA MATSUDA<sup>1</sup>

**Abstract:** In this study, we estimated the deformation of three-dimensional elastic body simulating the deformation in the computer, assuming the situation of gripping organs with forceps and applying force to deform in endoscopic surgery. Under the condition where the initial shape is known, we prepared data of elastic body shape deformed by changing the direction and magnitude of force applied to the contact point about 8,500 times with high accuracy by nonlinear finite element method over time. The relationship between the displacement from the initial shape at the partial observation point and that of the non-observation point of the entire elastic body was learned by the neural network. We showed that the total displacement can be estimated from a very small part observation by applying the learned neural network to the new deformation.

**Keywords:** Shape estimation, Neural network, Partial observation, nonlinear finite element method

## 1. はじめに

臨床では医療技術の高度化により治療可能な疾患が増えているが、治療計画の複雑化により、コンピュータによる事前の治療計画シミュレーションや治療中のナビゲーション、また経験を積む段階の医師のトレーニングの必要性が高まっている。生体に対する処置をコンピュータの中で構築するためには、処置に応じた生体の変形を高速に高精度に推定することが重要である。モデルに基づいて生体の変形を計算する方法として有限要素法が一般的に用いられている。生体の力学特性を既知と仮定し、物体を均一性が仮

<sup>1</sup> 京都大学 大学院情報学研究科 システム科学専攻  
〒 606-8501 京都府京都市左京区吉田本町  
Department of Systems Science, Graduate School of Informatics, Kyoto University  
Yoshida-honmachi, Sakyo-ku, Kyoto-city, Kyoto, 606-8501,  
Japan

<sup>2</sup> 東北大大学 大学院情報科学研究科 応用情報科学専攻  
〒 980-8579 宮城県仙台市青葉区荒巻字青葉 6-3-09  
Department of Applied Information Sciences, Graduate School of Information Sciences, Tohoku University  
6-3-09 Aoba, Aramaki aza, Aoba-ku, Sendai-city, Miyagi,  
980-8579, Japan

a) utako@i.kyoto-u.ac.jp

定できる要素へと分割したメッシュ構造に有限要素法を適用することで、生体の変形をシミュレートすることができる。

ヒトの臓器のような生体は剛体ではなく弾性体である。剛体は関節の無い一繋がりの物体であれば平行移動や回転といった線形の動きをするのみであるが、弾性体は一塊の物体であっても物体内の一部が伸びたり他の場所は縮んだりという非線形の変形をする。有限要素法は弾性体の非線形変形をシミュレートすることが可能であるが、物体全体の変形を求めるためには、物体に加えた力の大きさと位置を知る必要があり、力の情報が無い場合には対象物表面が全て観測可能であったり、物体の形状に関する特性が変形前後で不变であるとの仮定を置く必要がある。

これまで有限要素法に基づいて生体の変形を推定し、臓器の可視化や、医師のトレーニングや手術計画に応用する試みが多くなされている。術前に撮像した患者固有の CT (Computed Tomography) データを用い、外科手術時の臓器の把持や切開などの操作をシミュレートし可視化する試み [10] や、手術の際の縫合処置を医師がトレーニングするために構築されたシミュレータ [2] 等に関して報告がある。放射線治療での動態照射のプランニングに向けて、呼吸に合わせて臓器が変形するモデルを有限要素法ベースで構築した研究 [9] も報告されている。

有限要素法による変形推定の精度向上や、計算の高速化を目指した手法として、変形から物体の回転要素を抽出し回転以外の要素のみで計算することで高速化する手法 [8] や、物体を分割する要素を要素間で共有するエッジのペアとエッジで表すことによって形状を単純化する手法 [6] が提案されている。また、手術支援のために力学変形モデルベースの形状マッチングを目指した報告が成されている [12] が、いずれも変形を推定するために物体の硬さなどの力学特性を事前に知る必要がある。

一方、蓄積した変形データに基づいて変形を推定する手法として、臓器に力を印加して操作した時の変形をニューラルネットワークを用いてシミュレートした研究 [13] がある。諸岡らの報告では事前に多くの種類の力を印加して変形した物体の変形データを有限要素法を用いて求め、臓器に加えた外力とメッシュの頂点座標を圧縮したものとの関係をニューラルネットワークで学習することで、変形推定の際に臓器の力学特性を事前に知る必要が無いという利点があるが、力を印加した頂点座標と力の方向と大きさを入力する必要がある。

また、外科手術では開腹手術よりも内視鏡による腹腔鏡手術の方が、患者への負担が少なく回復も早いと言われているが、内視鏡手術は見える視野も狭く、手術器具を自由に動かすことが出来ない等の制約から、医師にとっては開腹手術よりも難しくなる。内視鏡手術時のナビゲーションを目指して内視鏡画像から臓器の 3 次元形状を再構成する

手法開発についてまとめた報告 [7] があるが、いずれも撮像視野の狭さや、観測可能な領域から変形前後に対応する特徴点を高精度に抽出することが問題となっている。治療時に部分的にしか観測できない問題に対して、部分観測に基づいて物体に加えられた外力の推定を行う研究 [16] や、物体から得た数枚のシルエット画像から臓器変形を推定しようとする試み [11] が報告されているが、変形を決定付ける情報が少なく推定精度に限界がある。

ニューラルネットワークを用いて変形させた弾性体の画像から弾性体に加えられた力を推定する報告 [1], [4] もあるが、物体の全体が見えている必要がある。またニューラルネットワークを用いて物体の外形を推定する研究 [3] では、事前に有限要素法などでシミュレーションするための物体の 3 次元形状が必要無いという利点があるが、物体を変形させている力の大きさと作用点の位置を取得する必要があり、器具が臓器に印加している力の大きさを計測することが困難な外科手術には向きである。

本研究では初期形状が既知という条件下で、事前に有限要素法により計算した変形データをニューラルネットワークを用いて学習することで、非常に少ない観測点における変位から弾性体全体の変位を推定する手法を提案する。

本稿では、まず 2 章で変形させた弾性体の 3 次元形状を非線形有限要素法によって計算する手法、および 3 章でニューラルネットワークを用いた変形推定のアルゴリズムについて述べ、4 章で対象とする弾性体の非線形有限要素法による実験データの取得方法、5 章でニューラルネットワークによる変形推定をデータに適用した結果と考察について報告し、6 章でまとめる。

## 2. 非線形有限要素法による弾性体変形

有限要素法は節点を介して部材が繋がったトラス構造物に力が加わった時の力と変位の関係を、剛性マトリックスを用いることにより行列式で書き下し、構造物の変形を計算機内で表す方法である [14]。連続体である弾性体を 2 次元なら三角形、3 次元なら四面体の要素へと隙間無く分割し、要素同士の接続点を節点としてトラス構造物と同様に扱うことで、変形の様子を行列式で表すことができる。

### 2.1 非線形有限要素法

3 次元の弾性体を四面体メッシュに分割し、メッシュの頂点にかかる力を  $f$ 、頂点ごとの変位を  $u$  とすると、力と変位の関係は剛性マトリックス  $K$  を用いて

$$f = Ku \quad (1)$$

という剛性方程式により記述できる。

剛性マトリックス  $K$  は弾性体の形状と力学特性によって決まる行列であり、非線形有限要素法では、弾性体を微小変形するごとに形状に合わせて  $K$  を更新する。メッシュ

全体の剛性マトリックス  $K$  は、異なるメッシュが共有する頂点に対応して、メッシュ一つ一つの要素剛性マトリックス  $K_e$  の重ね合わせで出来ており、一つのメッシュの形状を表す行列  $B$ 、力学特性を表す行列  $D$ 、およびメッシュの体積  $\Delta$  から以下のように定義される。

$$K_e = \Delta B^T D B \quad (2)$$

変形によって弾性体の力学特性が変化しないとすると、 $K_e$  はメッシュの変形により  $\Delta$  と  $B$  が変わることで更新される。初期形状が既知であるメッシュ構造に対して初期の  $K$  を式(2)より求め、微小力または微小変位をメッシュに与えた際に発生する微小変形を式(1)を用いて計算し、微小変形後の  $K$  を式(2)で求めるということを繰り返すことで、大きな変形をした変位や力を求める。

## 2.2 強制変位境界条件による変形

弾性体を変形させるためには、まずメッシュの全頂点  $N_a$  個の中から  $N_f$  個の頂点を力を加えても動かない固定点に設定する拘束条件が必要である。固定点の無い構造物に力を加えても、全体形状は変わらず平行移動や回転をするのみになってしまふからである。式(1)の行列式で、固定点部分に相当する行または列を除いても、行列式の特性による式(1)が成り立つ。固定点を除いた  $N$  個の頂点の中で、全体を変形させるために操作する  $N_c$  個の頂点を選択し作用点とする。

強制変位を変形の境界条件として用いる場合、まず変位  $\mathbf{u}$  を与えることによる有限要素法を計算するため、 $L$  を  $K$  の逆行列として式(1)を以下のように書き換える。

$$\mathbf{u} = K^{-1} \mathbf{f} = L \mathbf{f} \quad (3)$$

作用点の変位  $\mathbf{u}_c$  は境界条件として与えられるため既知であるが、固定点を除いた頂点の中で作用点以外の頂点の変位  $\mathbf{u}_n$  は未知である。ベクトル  $\mathbf{u}$  を既知量と未知量に分割すると、式(3)は以下のように書き直せる。 $L$  は微小変形前のものを用いるため全て既知である。

$$\begin{pmatrix} \mathbf{u}_c \\ \mathbf{u}_n \end{pmatrix} = \begin{pmatrix} L_{cc} & L_{cn} \\ L_{nc} & L_{nn} \end{pmatrix} \begin{pmatrix} \mathbf{f}_c \\ \mathbf{f}_n \end{pmatrix} \quad (4)$$

ここでまず既知の  $\mathbf{u}_c$  に関する部分のみを用いて全頂点にかかる力  $\mathbf{f}$  を以下により求める。

$$\mathbf{u}_c = \begin{pmatrix} L_{cc} & L_{cn} \end{pmatrix} \begin{pmatrix} \mathbf{f}_c \\ \mathbf{f}_n \end{pmatrix} \quad (5)$$

求められた力  $\mathbf{f}$  を用いて、未知の頂点変位  $\mathbf{u}_n$  を以下により求める。

$$\mathbf{u}_n = \begin{pmatrix} L_{nc} & L_{nn} \end{pmatrix} \begin{pmatrix} \mathbf{f}_c \\ \mathbf{f}_n \end{pmatrix} \quad (6)$$

以上により作用点に与えた強制変位境界条件から、作用点以外の全体の頂点変位を求めることができる。

## 3. ニューラルネットワークを用いた変形推定

### 3.1 ニューラルネットワーク

ニューラルネットワークでは、入力層から出力層に向けて層を進む際に特徴量に重みを掛けて足し合わせ、活性化関数と呼ばれる非線形変換をすることで、入力された特徴量を出力に合わせて変換する[15]。

図1のように中間層を2層持つニューラルネットワークを考える。各層のノード数を入力側からそれぞれ  $M_1$ ,  $M_2$ ,  $M_3$ ,  $M_4$  個とし、各層でのノードの値を  $a_h$ ,  $a_i$ ,  $a_j$ ,  $a_k$  とする。 $a_0$  はバイアス項で1である。次の層へ進む時に特徴量を変換する重みを  $w_{ih}$ ,  $w_{ji}$ ,  $w_{kj}$  とし、活性化関数としてシグモイド関数

$$g(z) = \frac{1}{1 + \exp(-z)} \quad (7)$$

を用いると、各層での値は以下のように表せる。

$$a_i = g(z_i), z_i = w_{i1} + \sum_{h=1}^{M_1} w_{ih} a_h \quad (8)$$

$$a_j = g(z_j), z_j = w_{j1} + \sum_{i=1}^{M_2} w_{ji} a_i \quad (9)$$

$$a_k = g(z_k), z_k = w_{k1} + \sum_{j=1}^{M_3} w_{kj} a_j \quad (10)$$

出力層における活性化関数としてシグモイド関数を用いているので、コスト関数にクロスエントロピー関数を用いた。さらに過学習を防ぐため、重みに L2 ノルムによる正則化を課した。ここで、 $m$  はトレーニングデータ数、 $d$  はデータ番号、 $y$  は正解データとする。

$$\begin{aligned} J(w) = & -\frac{1}{m} \left[ \sum_{d=1}^m \sum_{k=1}^{M_4} \left\{ y_k^{(d)} \log a_k^{(d)} + (1 - y_k^{(d)}) \log(1 - a_k^{(d)}) \right\} \right] \\ & + \frac{\lambda}{2m} \left\{ \sum_{h=0}^{M_1} \sum_{i=1}^{M_2} (w_{ih})^2 + \sum_{i=0}^{M_2} \sum_{j=1}^{M_3} (w_{ji})^2 + \sum_{j=0}^{M_3} \sum_{k=1}^{M_4} (w_{kj})^2 \right\} \end{aligned} \quad (11)$$

上記のコスト関数を最小化するように誤差逆伝播法[5]により各層での誤差を求め、層間を結合する重み  $w$  の最適化を行った。

### 3.2 学習フェーズ

固定点を除いた  $N$  個の頂点中、 $N_o$  個の頂点を変位の観測が可能な観測点とする。観測点は作用点を含む必要は無い。弾性体を変形させたときに観測点の変位のみ既知とし、ニューラルネットワークの入力層に観測点変位の3次元軸方向成分を入力する。すなわち  $N_o \times 3$  が、図1における  $M_1$  である。観測点変位とは別にバイアス項の1を入れるノードを追加する。

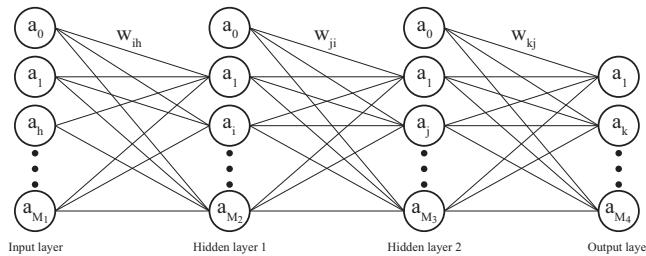


図 1: 中間層が 2 層のニューラルネットワーク

Fig. 1 Newral network with input and output layers and two hidden layers

トレーニングの際には  $N$  個の頂点中の観測点以外である  $N_u$  個の非観測点変位も既知とし、ニューラルネットワークの出力層に対する正解データとして与える。非観測点変位についても 3 次元軸方向成分を与えるため、 $N_u \times 3$  が、図 1 における  $M_4$  である。

### 3.3 推定フェーズ

推定フェーズでは観測点の変位は既知とし、非観測点の変位は未知とする。学習フェーズでトレーニングしたニューラルネットワークに、既知の観測点変位を入力とし、出力層に現れるものが非観測点の推定値である。

トレーニングしたニューラルネットワークの性能を評価するためには、観測点変位も非観測点変位も両方含むトレーニングデータ以外のテストデータで、観測点変位から非観測点変位を推定し、テストデータに含まれる正解の非観測点変位との差を見る。

## 4. 実験データの取得

### 4.1 対象とする弾性体

本研究では最初の試みとして図 2 のように四面体メッシュに分割された直方体形状を持つ弾性体を扱った。直方体の長辺を 10 cm、短辺をそれぞれ 2 cm, 2 cm とし、四面体メッシュの最近傍頂点間隔を 1 cm とした。四面体メッシュは表面だけではなく、弾性体の内部にも均等に配置している。弾性体の力学特性を表すヤング率とポアソン比は全てのメッシュで同様に、それぞれ 1.0 MPa, 0.40 と固定した。全頂点数は 99 点であり、図 2 左端の面にある 9 頂点（赤色）を固定点、右端の面にある下端 3 頂点（黄緑色）を作用点とした。

### 4.2 データのサンプリング

対象とする弾性体を 2 章で述べたように、強制変位境界条件を用いた非線形有限要素法により変形することで、実験に用いる頂点変位データを取得した。図 3 のように作用点の初期位置を中心として  $8 \text{ cm} \times 8 \text{ cm} \times 4 \text{ cm}$  の直方体の範囲で作用点に変位を与えて変形させた。図 3 では右方向を  $x$  軸、紙面奥行き方向を  $y$  軸、上方向を  $z$  軸と定義する。最近傍サンプル点間隔を 2 mm として、合計 8851

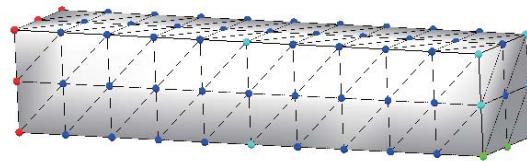


図 2: 四面体メッシュで表した弾性体形状

Fig. 2 Elastic object represented by tetrahedral mesh

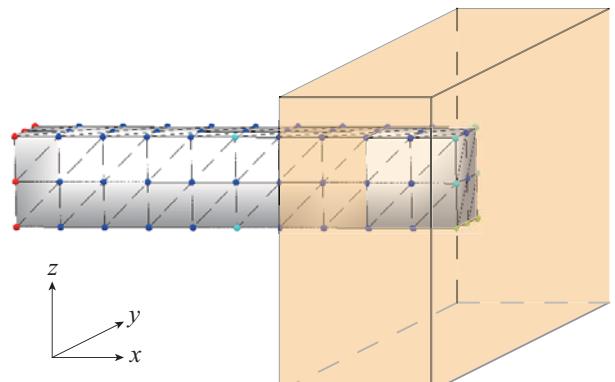


図 3: 変位データのサンプリング範囲

Fig. 3 Target area of forced displacement for data sampling

パターンに変形させた場合の変位データを取得した。変位データは、固定点以外の頂点数の 3 倍の次元を持つベクトルとして得られる。

非線形有限要素法により弾性体全体の変形を求めるためには、剛性方程式による変位と作用点にかかる力の計算を、大きく変形させて行うと計算誤差が大きくなる。そこで目的とするサンプル点まで作用点を動かす際、初期位置からサンプル点までの距離を 1000 分の 1 ずつに分けて微小変位を与えるごとに力と剛性マトリックスを計算し、最終的に大きく変形させた後の計算誤差が無視できるほど小さくなるようにした。1 種類の変位を与えて大きく変形させるのに要する時間は約 1 分である。

## 5. 実験結果と考察

ニューラルネットワークの中間層のノード数、トレーニングの繰り返し回数、観測点の数が推定性能に及ぼす影響について検討した。いずれも全データの中からランダムに 95% (8408 個) を選んでトレーニングデータとし、残りの 5% (443 個) をテストデータとして用いた。最適化する重みに設定する正則化係数  $\lambda$  は 0.1 とし、学習する重みの初期値は毎回ランダムに決定した。ニューラルネットワークの実装はパーソナルコンピュータで MATLAB (R2014b, MathWorks) によって行い、最適化手法には共役勾配法を用いた。

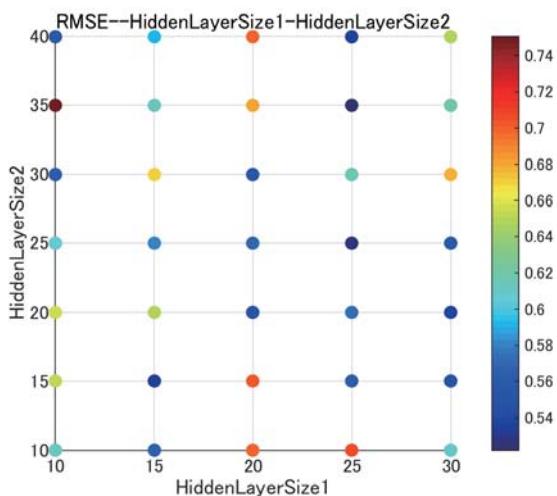


図 4: 中間層ノード数と推定精度の関係

Fig. 4 RMSE corresponding to hidden layer size

### 5.1 中間層ノード数の検討

まず観測点を図 2 に水色で示した 6 点とした。観測点としては画像から特徴点を検出しやすい物体の端や角を観測することを想定した。観測点が 6 点であるので、ニューラルネットワークの入力層でのノード数  $M_1$  は  $6 \times 3 = 18$  であり、出力層でのノード数  $M_4$  は  $(99 - 9 - 6) \times 3 = 252$  である。

中間層の 1 層目のノード数を 10 から 30 まで 5 置きに、中間層の 2 層目のノード数を 10 から 40 まで 5 置きに変化させて、トレーニングを実行しテストデータで推定した際の平均平方誤差 RMSE (mm) を色表示したものを図 4 に示す。誤差が小さく推定精度の高いものを青色、誤差が大きく推定精度の低いものを赤色とする。RMSE は固定点以外の非観測点全てに対し、全テストデータから計算した。トレーニングの繰り返し回数は予備実験で RMSE が 0.6 mm を下回った 2434 回とした。一つのノード数の組み合わせについてのトレーニングに要する時間は約 70 分、推定に要する時間はテストデータ 443 個全てに対して一度に行うと約 0.0455 秒、一つのテストデータに対して行うと約 0.0381 秒であった。

図 4 に示す 35 通りの組み合わせの中で、最も RMSE が小さかったものは中間層 1 層目のノード数が 25、2 層目のノード数が 35 の場合、次に RMSE が小さかったものは 25、25 の組み合わせであった。ノード数が多く最適化する重みの要素数が多い方がニューラルネットワークの表現力が高まりデータに合わせる能力が高くなるが、実験では実応用を考慮して 8500 個弱という比較的少ないデータセットによるトレーニングを行ったため、必ずしもノード数が多い方が推定精度が良くならなかった。中間層の 1 層目 2 層目のノード数の組み合わせが 25、35 の場合、重みの要素数は  $19 \times 25 + 26 \times 35 + 36 \times 252 = 10457$ 、25、25 の場合は  $19 \times 25 + 26 \times 25 + 26 \times 252 = 7677$  であり、重みの

要素数がトレーニングデータ数に匹敵する。従ってニューラルネットワークの表現力が比較的高く、かつ重みの要素数がトレーニングデータ数に匹敵する程度のノード数の時に、推定精度の良い結果が出たと考えられる。

### 5.2 トレーニング繰り返し回数の検討

トレーニングの繰り返し回数に対する推定精度の変化について調べた。中間層のノード数を 節で良好な結果の得られた 25、35 とした。最大繰り返し回数を 50000 回とした場合の、繰り返し回数に対するコスト関数の変化および RMSE の変化を図 5 に示す。コスト関数 (a) はトレーニングデータについて計算したものであり、RMSE(b) はトレーニングデータとは別のテストデータを用いて計算したものである。図中に繰り返し回数が 1000 回までのグラフを拡大表示した。トレーニングの繰り返し回数が増加するにつれて、トレーニングデータに対する重みの最適化が収束していく様子が図 5 (a) のコスト関数から分かる。各図の繰り返し回数が 1000 回までの拡大図を見たところ、いずれも 400 回ほどで大きな誤差変化は落ち着くが、その後も緩やかに減少を続けた。400 回、1000 回、4000 回、10000 回、49955 回の時点での RMSE はそれぞれ 0.9422 mm, 0.7315 mm, 0.4997 mm, 0.4652 mm, 0.3695 mm であり、望ましい推定精度である 0.5 mm 以内の誤差を得るために 4000 回ほどの繰り返しが必要であった。

また収束の早さを比較するため、重みの要素数の少ない中間層ノード数が 10、10 の場合についても最大繰り返し回数を 10000 回として、コスト関数と RMSE の変化を調べた結果の 1000 回までの拡大図を図 6 に示す。400 回、1000 回、4000 回、10000 回の時点での RMSE はそれぞれ 2.8724 mm, 0.7593 mm, 0.5414 mm, 0.4971 mm であった。大きな誤差変化が落ち着くまでの回数は、中間層ノード数が 25、35 の場合とあまり変わらず、必ずしも重みの要素数が少ない方が収束が早いわけではないことが分かった。

中間層ノード数が 25、35 の場合の最終的なトレーニング後のニューラルネットワークの重みを用いてテストデータにおける推定形状を図 7 に示す。表面上に各頂点の局所位置誤差をカラーマップとして表示している。白色がエラー無し、青色が誤差 1 mm を最大としたエラーに対応する。固定点付近は移動距離が短いため総じてエラーが少ない傾向にあったが、固定点から離れるに従ってエラーが大きい場合が多くなった。作用点には力をかけて引っ張るため作用点付近は形状が複雑になり推定が難しいと考えられるが、十分に収束するまでトレーニングを繰り返すと作用点の変位を観測していない作用点で RMSE が 0.5946 mm の推定精度を得られるた。

### 5.3 観測点数の検討

観測点を 1 頂点～10 頂点まで 1 刻みに、80 頂点まで 10

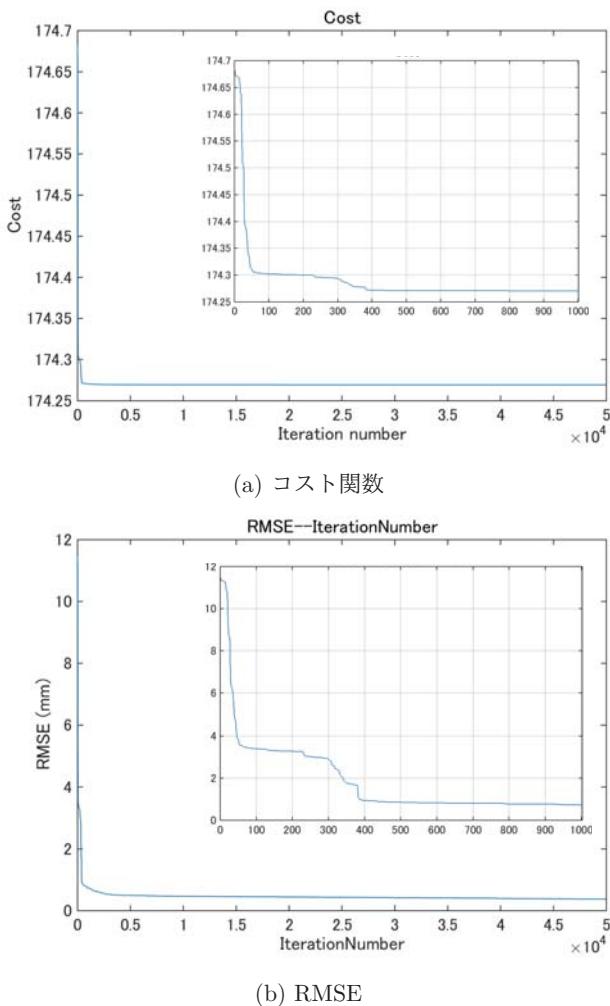


図 5: 中間層ノード数が 25, 35 のときのトレーニングの繰り返し回数に対するコスト関数の変化 (a) と RMSE の変化 (b)

**Fig. 5** Cost function and RMSE corresponding to iteration number

刻みに変化させて推定精度の検討を行った。1番目から10番目までの観測点は図8のように設定し、20点以上の観測点については固定点と作用点以外の頂点からランダムに選択した。10点までは物体の角や辺の特徴点として得やすいと考えられる点を観測点として選んだ。ただし一旦観測点と設定した頂点は観測点から除かず追加するのみとし、観測点数が6点の場合は前節までと同じ観測点とした。

トレーニングの繰り返し回数を4000回とし、中間層ノード数を25, 35として、テストデータで推定を行った観測点数とRMSEの関係を図9に示す。それぞれの場合で初期値が異なるためかなりぎざぎざしているが、3点以上の観測で推定精度が大幅に良くなる様子が見られた。これは2点までは固定点から遠い物体の端のみ観測しているのに対して、3点目からは物体の中央付近も観測しているためであると考えられる。また、観測点数が60点以上と多いときよりも比較的少ないときの方がエラーが少ない傾向に

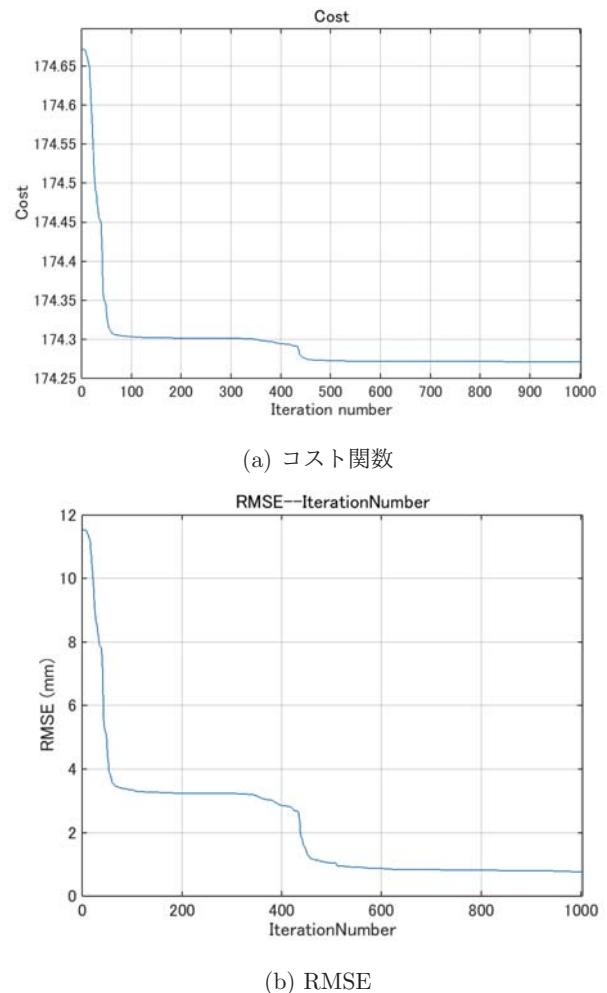


図 6: 中間層ノード数が 10, 10 のときのトレーニングの繰り返し回数に対するコスト関数の変化 (a) と RMSE の変化 (b)

**Fig. 6** Cost function and RMSE corresponding to iteration number

あった。この理由として考えられるのは、観測点数が多くなるとニューラルネットワークの入力層でのノード数が出力層でのノード数よりも多くなり、中間層ノード数の25, 35がデータのバリエーションを表すのに適さないサイズとなってしまうからではないかと考えられる。従ってニューラルネットワークの中間層ノード数に推定精度が依存する問題があるため図9から観測点が多くても推定精度が良くならないという結論を導くことは出来ない。

## 6. おわりに

本研究では、部分観測による弾性体の変形後の全体形状推定をニューラルネットワークを用いて行う手法を提案した。初期形状が既知の弾性体を対象として、少ない部分観測点における弾性体が大きく変形したときの変位を入力とし、非観測点の変位を出力としてニューラルネットワークのトレーニングを行い、テストデータでの推定性能について検討した。ニューラルネットワークの中間層ノード数、

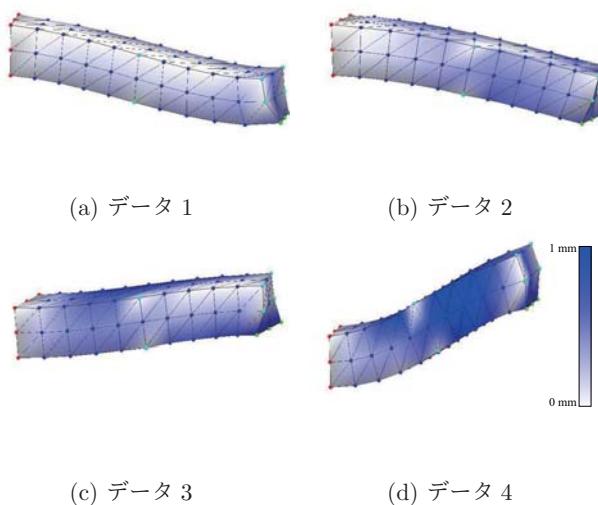


図 7: テストデータに対して推定した形状の局所位置誤差

Fig. 7 Local position error on estimated shape

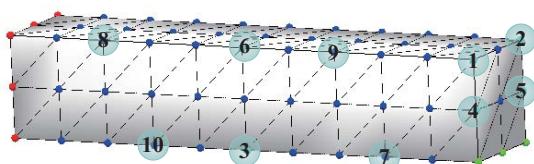


図 8: 観測点数を変化させた場合の観測順

Fig. 8 The order of observed points

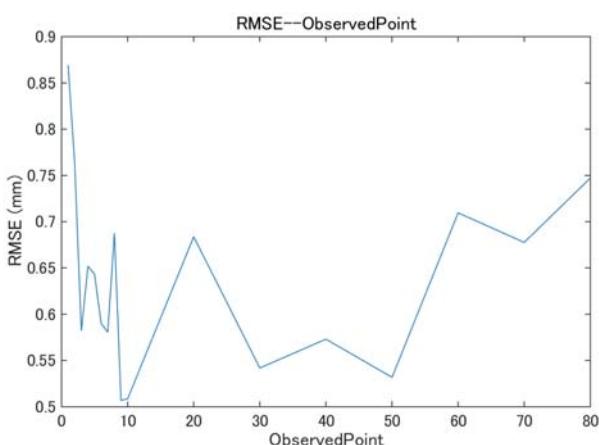


図 9: 観測点数を変化させた場合の RMSE

Fig. 9 RMSE corresponding to number of observed points

トレーニングの繰り返し回数、観測点数が推定性能に与える影響について調査した。観測点・非観測点数に適した中間層ノード数を設定し、十分に収束するまでトレーニングを繰り返すことで、0.4 mm 程度の誤差の推定精度を得ることができることが分かった。

謝辞 本研究は京都大学 COI STREAM 「活力ある生涯のための Last5X イノベーション拠点」及び日本学術振興会科学的研究費 若手研究 B JP16K16407 の助成による。

## 参考文献

- [1] Aviles, A. I., Marban, A., Sobrevilla, P., Fernandez, J. and Casals, A.: A recurrent neural network approach for 3D vision-based force estimation, *2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA)*, pp. 1–6 (2014).
- [2] Berkley, J., Turkiiyah, G., Berg, D., Ganter, M. and Weghorst, S.: Real-time finite element modeling for surgery simulation: an application to virtual suturing, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 10, No. 3, pp. 314–325 (2004).
- [3] Cretu, A. M., Petriu, E. M., Payeur, P. and Khalil, F. F.: Estimation of deformable object properties from shape and force measurements for virtualized reality applications, *2010 IEEE International Symposium on Haptic Audio Visual Environments and Games*, pp. 1–6 (2010).
- [4] Greminger, M. A. and Nelson, B. J.: Modeling elastic objects with neural networks for vision-based force measurement, *Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)*, Vol. 2, pp. 1278–1283 (2003).
- [5] Kecman, V.: *Learning and Soft Computing: Support Vector Machines, Neural Networks, and Fuzzy Logic Models*, MIT Press, Cambridge, MA, USA (2001).
- [6] Kikuwe, R., Tabuchi, H. and Yamamoto, M.: An Edge-based Computationally Efficient Formulation of Saint Venant-Kirchhoff Tetrahedral Finite Elements, *ACM Transactions on Graphics*, Vol. 28, No. 1, pp. 8:1–8:13 (2009).
- [7] Maier-Hein, L., Mountney, P., Bartoli, A., Elhawary, H., Elson, D., Groch, A., Kolb, A., Rodrigues, M., Sorger, J., Speidel, S. and Stoyanov, D.: Optical techniques for 3D surface reconstruction in computer-assisted laparoscopic surgery, *Medical Image Analysis*, Vol. 17, No. 8, pp. 974–996 (2013).
- [8] Müller, M., Dorsey, J., McMillan, L., Jagnow, R. and Cutler, B.: Stable Real-time Deformations, *Proceedings of the 2002 ACM SIGGRAPH/Eurographics Symposium on Computer Animation, SCA '02*, New York, NY, USA, ACM, pp. 49–54 (2002).
- [9] Nakao, M., Kawashima, A., Kokubo, M. and Minato, K.: Simulating lung tumor motion for dynamic tumor-tracking irradiation, *2007 IEEE Nuclear Science Symposium Conference Record*, Vol. 6, pp. 4549–4551 (2007).
- [10] Nakao, M. and Minato, K.: Physics-Based Interactive Volume Manipulation for Sharing Surgical Process, *IEEE Transactions on Information Technology in Biomedicine*, Vol. 14, No. 3, pp. 809–816 (2010).
- [11] Saito, A., Nakao, M., Uranishi, Y. and Matsuda, T.: Deformation Estimation of Elastic Bodies Using Multiple Silhouette Images for Endoscopic Image Augmentation, *2015 IEEE International Symposium on Mixed and Augmented Reality*, pp. 170–171 (2015).
- [12] Suwelack, S., Röhl, S., Bodenstedt, S., Reichard, D., Dillmann, R., dos Santos, T., Maier-Hein, L., Wagner, M., Wünscher, J., Kenngott, H., Müller, B. P. and Speidel, S.: Physics-based shape matching for intraoperative image guidance, *Medical Physics*, Vol. 41, No. 11, p. 111901 (2014).

- [13] 諸岡健一, 陳 献, 倉爪 亮, 内田誠一, 原 健二, 砂川 賢二, 橋爪 誠: 非線形有限要素解析を模したニューラルネットワークを用いた軟性臓器ボリュームモデルの変形シミュレータ, 電子情報通信学会論文誌. D, 情報・システム, Vol. 93, No. 3, pp. 365–376 (2010).
- [14] 三好俊郎: 有限要素法入門 (改訂版), 培風館 (1994).
- [15] 大関真之: 機械学習入門 ボルツマン機械学習から深層学習まで, オーム社 (2016).
- [16] 坂田良平, 中尾 恵, 松田哲也: 弹性体の局所的な変位観測に基づく外力の推定, 電子情報通信学会技術研究報告, Vol. 115, No. 301, pp. 43–48 (2015).