

令和元年6月12日現在

機関番号：17102

研究種目：基盤研究(C) (一般)

研究期間：2016～2018

課題番号：16K00243

研究課題名(和文) 実時間多層有限要素解析と術中生体情報の融合による次世代低侵襲手術支援システム

研究課題名(英文) Support System for Minimally Invasive Surgery Using Real-time Finite Element Method and Organ Information During Surgery

研究代表者

諸岡 健一 (Morooka, Ken'ichi)

九州大学・システム情報科学研究所・准教授

研究者番号：80323806

交付決定額(研究期間全体)：(直接経費) 3,500,000円

研究成果の概要(和文)：当該研究は、腹腔鏡下手術を対象とし、申請者が有する実時間有限要素解析システム(neuroFEM)と、マルチモーダル内視鏡画像から術中組織情報を融合することで、患者組織固有の形状・運動的機能・見えを精緻に再現可能な人体組織モデリング法について研究を行った。その成果として、1) 節点の挙動解析をボトムアップ的に統合し組織全体の变形を推定する、実時間多層有限要素解析システム、2) 手術中の内視鏡画像から、術具をDeep Neural Networkによって自動的に検出するシステム、をそれぞれ構築した。

研究成果の学術的意義や社会的意義

本研究では、実時間有限要素解析システムと術中組織変形情報を組み合わせ、患者の状態に応じた適切な初期条件を設定し、その条件下での組織の振舞いを実時間で且つ非線形FEMと同等の解析精度で推定する、独創的な手法を開発する。これにより、他の研究機関と比べても突出した精度で、人体組織の見えと動きを再現する患者指向組織モデルと、それをを用いた手術計画や手術シミュレーションなどの次世代の低侵襲手術支援システムが構築できる。このシステムにより、医師は術中の視野を容易に想像でき、術中と同様の判断や手術手技の訓練を術前に行え、低侵襲手術の安全・正確性の飛躍的な向上に寄与できる。

研究成果の概要(英文)：The purpose of our research project is to construct support system for Minimally Invasive Surgery (MIS) using Real-time Finite Element Method and the information about a target organ acquired during surgeries. We studied the fundamental techniques of the support system:

- 1) a real-time finite element method for estimating the deformation of the target organ by deep neural networks;
- 2) a method for detecting surgical instruments from endoscopic images.

研究分野：医用画像情報処理

キーワード：低侵襲手術 実時間有限要素解析 臓器変形

1. 研究開始当初の背景

患者への侵襲が少ない低侵襲手術は、早期離床・早期退院が可能であり、患者の生活の質の向上に貢献している。超高齢社会へ向かいつつある日本の社会的背景を踏まえると、低侵襲手術への要望が更に高まることは容易に予想される。一方、通常の開腹手術と比べ、低侵襲手術では、術者は臓器を直視・触診できず、内視鏡画像のみで体内の3次元空間を推測し術具を操作する、などの高度な手技技術や立体感覚が要求され、術者への肉体的・精神的負担が大きい。また、術具の機能や術者の視野には制限があり、それらに起因する低侵襲手術特異な合併症や死亡事故が発生し、今春の群馬大のような社会問題に発展する場合もある。これらが要因で、内視鏡手術の症例数は年々増加していたが、2001年頃から頭打ちの状態である。

研究代表者である諸岡は、腹部軟性組織を対象とした内視鏡手術支援システムの研究を行っており、その成果として、重要な要素技術である、軟性組織変形を精緻に且つ実時間で推定するシステム **neuroFEM** を開発している(引用文献[1])。まず、非線形有限要素法(非線形 FEM) を用いて、術具等により組織に作用する様々な外力に対し、組織のボリュームモデル(以後、組織モデル) の変形パターンを多数作成する。このパターンを用いて、「外力に対する組織モデルの変形」という非線形関係を表すニューラルネットワーク(Neural Network: NN) 「**neuroFEM**」を構築する。

非線形 FEM による変形推定精度は高いが、膨大な計算時間を要する。従来、近似計算の導入で非線形 FEM を高速化しているが、それによる推定精度の低下は避けられない。特に、大変形を伴う軟性臓器では、その精度低下は致命的な問題となる。これに対し、**neuroFEM** は、肝臓などの実質臓器や、形状・体積共に変わる管腔臓器(胃など) の非線形変形も、非線形 FEM とほぼ同程度の推定精度を保ちつつ、実時間で推定可能である(図 1)。



図 1 開発したシステム (neuroFEM) で推定した肝臓(上)と胃(下)の変形例。

FE 解析は、物体の硬度を示す物性値や、周辺組織との接続関係により変形が拘束される条件(以後、拘束条件)などの初期条件を設定し、その条件下での組織変形を推定する。「健常者に比べ肝硬変の肝臓は硬い」のように、症例や脂肪のつき方など、患者の内部状態に応じて初期条件は異なる。ここで、図 2 左の肝臓モデルの初期条件と比べ、同図中では柔らかい物性値、同図右は変形が拘束される範囲(図中、黒太線部)が狭い、と異なる初期条件に対し、同一外力を与えた変形結果である。このように、初期条件は FE 解析に影響を及ぼし、したがって、組織変形の推定精度を保証するためには、患者に応じて適切な初期条件を設定すべきである。しかし、従来の組織変形解析では、医師の知見に基づき拘束条件を経験的に決めている。また、物性値には、献体組織や硬度が似た動物組織から得られた間接的な値を用いている。このような初期条件は、患者の状態に必ずしも適切とは限らず、そのため、FE 解析やそれに基づく **neuroFEM** による患者組織変形の推定精度には限界がある。




図 2 初期条件が異なる肝臓モデルに同一外力を加えたの変形例。

2. 研究の目的

上述の背景を踏まえ、本研究では、腹腔鏡下手術を対象とし、申請者が有する実時間有限要素解析システム **neuroFEM** と、マルチモーダル内視鏡画像から得られる術中組織情報を融合することで、患者組織固有の形状・運動的機能・見えを精緻に再現可能な人体組織モデリング法の開発を目的とする。これにより、人体組織の外観や振舞いを忠実に再現可能な次世代の低侵襲手術支援システムが実現でき、手術の安全性・確実性が飛躍的に向上できる。この実現のために、以下の項目について研究を行った。

1. **neuroFEM** を拡張し、ミクロレベルから組織全体までの物理的挙動を推定する、実時間多元有限要素解析システム **Multiscale neuroFEM(m-neuroFEM)** の開発
2. **m-neuroFEM** とマルチモーダル内視鏡画像の融合による人体組織モデル化法の構築

3. 研究の方法

【m-neuroFEM の構築】

対象組織の形状モデル (表面モデル・ボリウムモデルいずれも適用可能) が与えられると、それを構成する節点ごとに、その節点の挙動を推定する NN (以後、Nodal Behavior Estimator) を構築する。具体的には、注目節点の NBE は、ある時刻での注目節点とその周囲の連結節点の変位と応力が入力として与えられると、次の時刻における注目節点の変位と応力を出力する。また、各節点の NBE を統合することで、対象物全体の変形を大規模な NN で推定する。

NBE 構築において、我々は、節点間の隣接関係と、変形・応力の関係を考慮し、図 3 に示す NBE 構造を提案している。FEM では、対象体の形状モデルの各節点に、「隣接節点からの応力により、その節点が応力を周囲に発し移動する」物理現象を示す特性方程式をたて、全節点の特性方程式をまとめた行列式を解くことで、対象物の物理的挙動を解析する。この考えに基づき、入力層から M 番目の隠れ層までの各層間は、節点や要素の隣接関係を考慮した局所結合で接続されている。一方、M 層から出力層においては、その層間のニューロンは全結合で接続されている。以後では、局所結合層の構造について述べる。

図 3 に示すように、注目節点 a が 5 つの隣接節点 b, c, d, e, f と結合し、また注目節点 a を頂点として含む三角形要素 P, Q, R, S, T の例を考える。入力層の全ニューロンを、各節点に対応するニューロンセット $N_a, N_b, N_c, N_d, N_e, N_f$ に分ける。一方、第 2 層の全ニューロンは、各要素に関連するニューロンセット N_P, N_Q, N_R, N_S, N_T に分割する。ここで、節点 a, b, c からなる要素 P を考えると、そのニューロンセット N_P のニューロンは、入力層の a, b, c に関するニューロンセット N_a, N_b, N_c のニューロンのみと結合する。同様に、要素 Q の場合、そのニューロンセット N_Q のニューロンは、入力層の節点 a, c, d のニューロンセット N_a, N_c, N_d のニューロンと結合する。第 3 層では、隣接する二つの要素で一つのニューロンセットを構成する。つまり、第 3 層のニューロンは、エッジを共有する 2 つの要素ごとに $N_{P+Q}, N_{Q+R}, N_{R+S}, N_{S+T}, N_{T+P}$ と分割される。得られたニューロンセットのうち、 N_{P+Q} のニューロンは、第 2 層のニューロンセット N_P, N_Q のニューロンと全結合する。最後に、第 4 層では隣接する 3 つの要素で一つのニューロンセットを構成する。

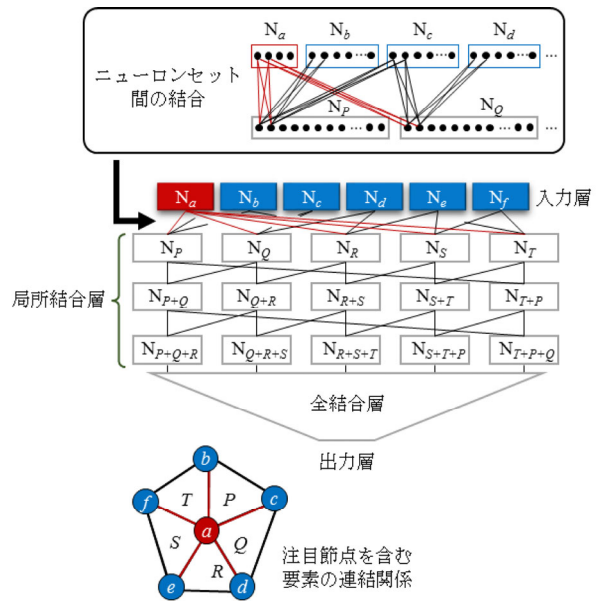


図 3 NBE の構造.

NN の構築は、結合するニューロン間の重み係数の最適値を学習することである。我々は、Stacked autoencoder (SAE) を用いて大規模 NN を構築している。Autoencoder (AE) とは、入力信号が与えられると、中間層を介して出力層から入力信号そのものを出力する 3 層 NN である (図 4)。中間層のニューロン数が入力層より少ない場合、中間層の出力は入力信号の次元圧縮表現となる。逆に、中間層のニューロン数が入力層より多い場合、中間層の出力は入力信号のスパース表現となる。

SAE では、入力信号を入力した AE の中間層データ h を、次の AE の入力データとして学習する (図 4)。これを大規模 NN の層数繰り返し、統合した多階層 NN に対し、入力層に再度学習データを入力し、誤差逆伝搬法による教師あり学習を行う。このように AE によって各層間の重み係数を事前に学習し、その係数値を大規模 NN の重み係数の初期パラメータとして用いることで、よい局所最適解を得ることが期待できる。




図 4 Stacked autoencoder.

モデルの節点ごとに生成した全ての NBE を結合することで、モデル全体の変形を推定する大規模 NN を構築する。この結合法は、図 1 に示す 5 つの隣接節点と接続する注目節点 a の場合、隣接節点の NBE の出力が節点 a の NBE の入力層と接続し、一方節点 a の NBE の出力がその隣接節点の NBE の入力層につながる(図 5)。このような構造を持つ大規模 NN は、あるタイムステップ t における注目節点と連結節点の挙動から、次のタイムステップ $t+1$ の注目節点の挙動が推定される。その推定結果は、各連結節点に送られ、同様に、各連結節点に連結している全ての節点から送られてくる新たな節点挙動パターンを結合し、各連結節点の NBE の入力信号とする。

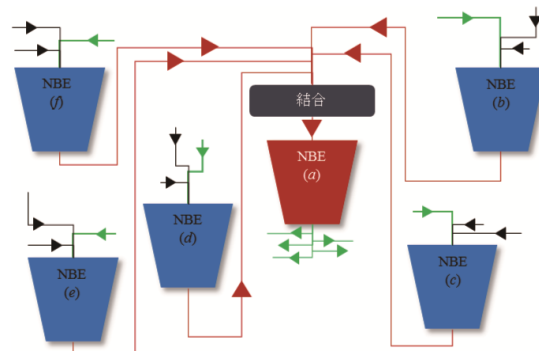


図 5 NBE の結合.

4. 研究成果

脳内部構造の一つである被殻の 2 次元メッシュモデル (図 6 左) に対し、その輪郭に外力を与えた時の被殻の変形を推定する大規模 NN を構築している。このモデルの大きさは幅 29[mm]、高さ 59[mm]であり、境界上の節点 42 個、内部にある節点 60 個からなる。FE 解析を実行するためには、境界上の節点から固定する節点を選ぶ必要があり、今回は 5 個を固定節点 (図 6 左の黒点) とした。また、固定節点以外の 37 個の境界節点 (図 6 左の緑点) を外力の作用点候補とし、各作用点候補に 48 種類の外力を与えて、変形パターンを作成した。したがって、計 33,744 個の学習データを使って、各節点の NBE で構築した。また、システムの汎化性能の検証では、学習データに含まれない 10 種類の外力を用いて、7,030 個のテストデータを作成した。




図 6 被殻の変形推定：(左) 被殻メッシュモデル；(右) 大規模 NN で推定した被殻の変形と、その時に生じた応力分布の推移。黄→緑→青の順で応力大きいことを示す。

表 1 に、外力の作用点となった節点と、モデル内部の節点における、挙動推定の汎化誤差を示す。ここで、FEM で推定した結果を真値とし、真値ベクトルと推定ベクトルの L2 ノルムを誤差とした。テストデータに含まれる変位と応力の値域 $[-2.1.E+00, 2.6.E+00]$, $[-2.5.E+05, 1.5.E+05]$ と比較すると、非常に小さな誤差で節点の挙動を推定できていることを確認している。また、NBE を用いた 1 タイムステップの推定に要する時間は $7.4.E-04$ [sec] であり、高速な節点挙動推定を実現した。

表 1 変位と応力の平均汎化誤差と標準偏差.

	変位[mm]	応力[N/mm ²]
輪郭上の節点	$3.0.E-02$ $\pm 1.7.E-02$	$1.8.E+02$ $\pm 9.3.E+01$
内部節点	$3.6.E-02$ $\pm 2.5.E-02$	$1.5.E+00$ $\pm 2.1.E+00$

また、開発した大規模 NN は変形だけでなく、変形により生じる応力分布の変化も推定可能である。図 6 右は、推定した比較の変形例であり、黄→緑→青の順で応力大きいことを示す。変形に伴い、応力分布の推移も推定できていることが分かる。

<引用文献>

[1] 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, Vol.J93-D, No.3, pp.365-376, 2010

5. 主な発表論文等

[雑誌論文] (計1件)

- ① 諸岡健一, 小林薫樹, 有限要素解析を模した深層なニューラルネットによる手術支援システムのための臓器変形推定, *Medical Imaging Technology*, 35 巻, 2017, 206-211
DOI: 10.11409/mit.35.206

[学会発表] (計3件)

- ① Kaoru Kobayashi, Ken'ichi Morooka, Yasushi Miyagi, Takaichi Fukuda, Tokuo Tsuji, Ryo Kurazume, Kazuhiro Samura, Simulation of Deforming Human Tissue by Multiple Deep Neural Networks, *The International Forum on Medical Imaging in Asia (IFMIA2017)*, 2017.
- ② 大山紗貴子, 諸岡健一, 小林薫樹, 久保田健介, 倉爪亮, 脊椎側彎症治療診断支援システムのための深層学習による脊椎変形・応力分布推定, 第18回計測自動制御学会 システムインテグレーション部門講演会, 2017年
- ③ Kaoru Kobayashi, Ken'ichi Morooka, Yasushi Miyagi, Takaichi Fukuda, Tokuo Tsuji, Ryo Kurazume, Kazuhiro Samura, A Method for Estimating Tissue Deformation by Deep Neural Network, *The 12th Asian Conference on Computer Aided Surgery (ACCAS2016)*, 2016.

[その他]

ホームページ等

http://robotics.ait.kyushu-u.ac.jp/morooka_lab/index-j.html

6. 研究組織

(1)研究分担者

研究分担者氏名：大内田 研宙

ローマ字氏名：Kenoki Ohuchida

所属研究機関名：九州大学

部局名：大学病院

職名：助教

研究者番号 (8桁)：20452708

(2)研究協力者

研究分担者氏名：倉爪 亮

ローマ字氏名：Ryo Kurazume

所属研究機関名：九州大学

部局名：システム情報科学研究院

職名：教授

研究者番号 (8桁)：70272672

※科研費による研究は、研究者の自覚と責任において実施するものです。そのため、研究の実施や研究成果の公表等については、国の要請等に基づくものではなく、その研究成果に関する見解や責任は、研究者個人に帰属されます。