

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

○大山 紗貴子 (九州大学), 諸岡 健一 (九州大学),
小林 薫樹 (日立製作所), 久保田 健介 (総合せき損センター), 倉爪 亮 (九州大学)

Estimation of Spinal Deformation and Stress Distribution by Deep Learning for Computer Aided Diagnosis for Spinal Scoliosis

○Sakiko OHYAMA (Kyushu Univ.), Ken'ichi MOROOKA (Kyushu Univ.),
Kaoru KOBAYASHI (Hitachi Ltd.), Kensuke KUBOTA (Spinal Injuries Center.),
and Ryo KURAZUME (Kyushu Univ.)

Abstract : We have been developing a system for estimating human tissue deformation by deep neural networks (DNNs)¹⁾. This paper presents an extension of our previous system¹⁾ by introducing a new design of the DNN of the node. From experimental results, our proposed system can improve the accuracy of estimating human tissue deformation compared with our previous system¹⁾.

1. 緒言

脊椎側彎症とは、背骨が側方へ彎曲・捻転する疾患であり、この治療法として、コルセットを用いた装具療法や、背骨の側彎を外科的に矯正する方法がある。しかし、側彎症発症・進行の原因は解明されていないため、患者に応じた効果的かつ確実な治療法が定量的に確立されておらず、現在の側彎症治療法は医師の経験や技量に依存している。これに対し、近年、呼吸時において、左右の肋骨から脊椎に不均衡な外力が働くことが、発症・進行の原因の一つであると報告されている²⁾。この研究では、左右肋骨からの外力の不均衡を治すことで、側彎症を治療できる可能性を示している。

そこで、我々は、この研究結果に基づき、呼吸時に脊椎にかかる応力分布を解析することで、患者の症状に適した側彎症治療を支援するシステムの開発を行っている。このシステムの要素技術として、患者の呼吸時の CT 画像から胸郭骨の 3 次元形状モデルを作成し、このモデルを使って、呼吸時での脊椎の応力分布を有限要素法 (Finite element method: FEM) により推定するものがある (Fig.1)。FEM は微分方程式を近似的に解くための数値解析法の一つであり、対象物体の変形を高精度で推定できる。しかし、その解析には膨大な計算時間を要するため、実際の診断に用いるには、有限要素解析 (Finite element analysis: FEA) の高速化が必要である。

これまで FEA の高速化法が提案されており、例えば、Francois ら³⁾ は変形前後の物体形状の間には線形の関係

があると近似し、変形推定中に用いる計算の一部を事前に求めることで、FEM による推定の計算量を削減する手法を提案した。また、Makiyama ら⁴⁾ は、Co-Rotated FEM⁵⁾ と呼ばれる線形 FEM の枠組みを導入し、回転成分のない変形のみを対象とすることで、計算コストを削減しつつ変形推定の精度を向上させた。このように、従来の高速化法の多くが、線形近似を導入しているが、それにより FEM と比べて推定精度が落ちる欠点がある。

この問題に対し、我々はこれまでに、Deep Neural Network(DNN) を使って 2 次元物体の変形を推定するシステムを開発してきた¹⁾。まず、解析対象である物体の 2 次元形状モデルを有限個の要素に分割し、要素を構成する節点ごとに、その節点の挙動を 1 つの Neural Network(NN) で推定する。そして、全節点の NN を統合した DNN により、対象物全体の変形を推定する。NN の計算は比較的単純な非線形関数の重み付き線形結合であるため、FEA と比べ計算量を飛躍的に削減でき、FEA の高速化を実現する。

本発表では、より高精度かつ高速な変形推定を実現するため、我々が開発したシステム (以後、従来システム)¹⁾ の DNN の構造について検討した。具体的には、従来システムでは変位と応力をまとめた一つのベクトルを入力として、注目節点の変位・応力を推定していた。一方、本発表で提案するシステム (以後、提案システム) では、変位・応力それぞれ個別の高次元空間に写像し、得られた各高次元ベクトルを統合したベクトルを使って注目節点の変位・応力を推定する構造を有す。これにより、従来システムと比べ、本手法は変位と応力それぞれに適した特徴ベクト

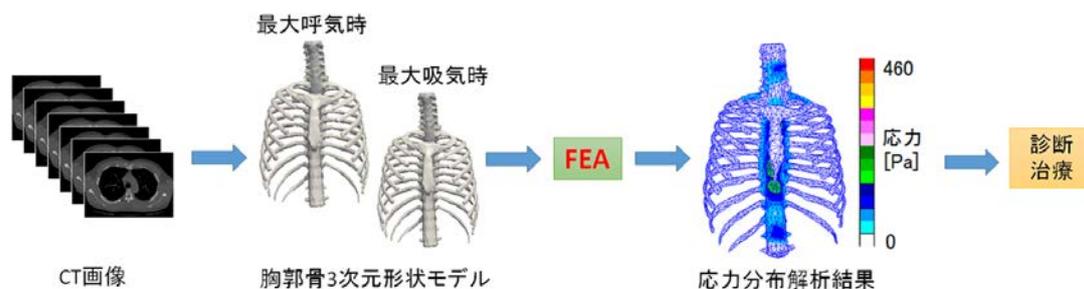


Fig. 1: Overview of analyzing spinal stress distribution in our new diagnosis and treatment for Spinal Scoliosis.

ルを抽出でき、それにより推定精度の向上が期待できる。この DNN の層数やニューロン間の結合を変えた様々な構造に対して、FEA によるシミュレーション値と変位・応力の推定値を比較することで、提案システムの精度を検証した。

DNN を用いた変形推定手法として、Conditional Generative Adversarial Network を用いた手法⁶⁾がある。この手法は、Spline 関数を用いた Thin Plate Splines(TPS)法を基にしている。TPS による変形では、まず、MR 画像から、複数の脳を比較するときに基準となる点であるランドマークをユーザが指定し、指定されたランドマークに基づいて変形を行う。ある注目点の変位は、全てのランドマークからの距離に応じて求められるため、ランドマークの設定の影響を受けやすく、局所的な細かな変形を制御することが難しい欠点がある。

2. DNN による物体変形推定

2.1 DNN の構造

FEA では、解析対象モデルを有限個の要素に分割し、その要素を構成する節点ごとに、以下の 3つの関係式からなる FEM 支配方程式をたてる：

- (1) 力と運動の関係を表す力-つりあい方程式
- (2) 運動と変形の間を表現するひずみ-変位関係式
- (3) 力と変形の間を表現する応力-ひずみ関係式。

各節点で支配方程式をたて、全節点の方程式をまとめた大規模方程式を解くことで、解析対象モデル全体の変形を推定する。

FEA において、各節点の挙動は、その節点に連結している節点の挙動にのみ依存して推定する。この考えに基づいて、各要素ごとにその挙動を推定する DNN を構築し、全 DNN を統合した大規模 DNN により物体全体の変形を

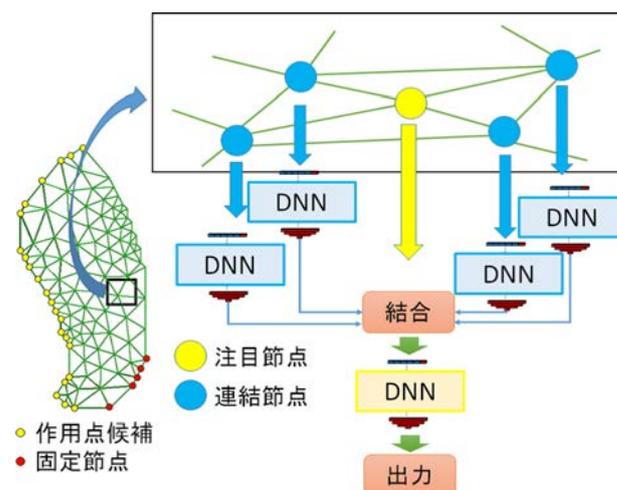


Fig. 2: Estimation of an object model deformation by integrating DNNs which simulate nodes in the model.

推定する (Fig.2)。以下では、各節点の DNN の構造について述べる。

注目節点の DNN は、Fig.3 が示すような局所結合層と全結合層からなる。前者では、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。局所結合層を通して、時刻 t での注目節点に関する入力情報から特徴ベクトルを抽出し、この特徴ベクトルを用いて、全結合層より時刻 $t+1$ での注目節点の変位と応力を出力する。以後では、局所結合層の構造について述べる。

2.1.1 局所結合層

入力層に、ある時刻 t における注目節点の変位と応力、注目節点に連結している各節点の変位、応力、注目節点に対する相対速度・相対加速度を入力情報として用いる。この入力情報は、変位・相対速度・相対加速度をまとめたベクトルと、応力情報からなるベクトルに分け、それぞれの

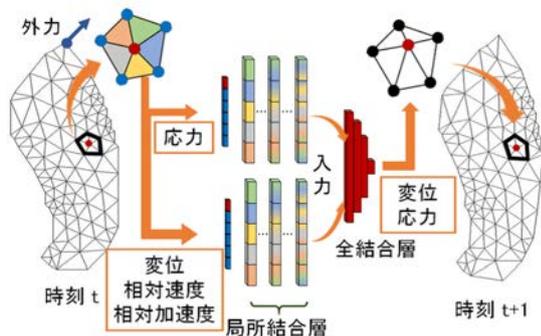


Fig. 3: Structure of DNN for estimating the nodal behavior.

局所結合層により各ベクトルから特徴ベクトルを抽出する。

局所結合層は、Fig.4 が示すように、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。

2.2 学習方法

本手法では、初期パラメータの最適化のために、全ての層について Autoencoder による事前学習を行い、各 Autoencoder を統合し、Stacked autoencoder を構築した。また、各ニューロンの出力は活性化関数を使って求められる。本研究では活性化関数としてシグモイド関数

$$\zeta(s) = \frac{1}{1 + e^{-x}} \quad (1)$$

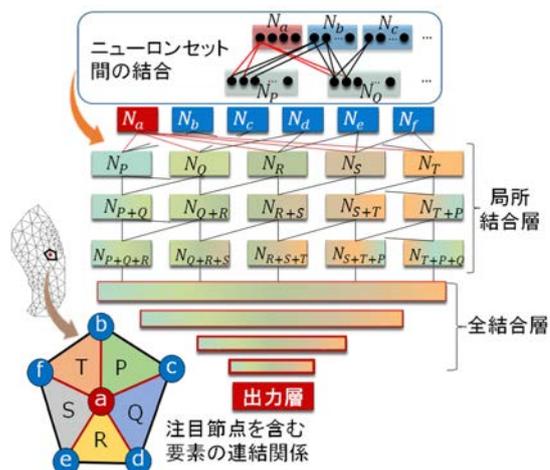


Fig. 4: Structure of locally connected layer in our proposed system.

を用いた。ここで x は、あるニューロンが、それと結合している全てニューロンから信号を受けた時、その信号の重み付き線形結合の値である。

各 Autoencoder と、構築した Stacked Autoencoder の重み係数は、誤差逆伝搬法によって繰り返し更新される。ここで、重み係数を更新する度合いは、学習率の値によって変わる。学習率の設定によっては、効率的に最適解を求めることができる、一方、局所解に陥る可能性もある。そこで、本手法では、以下に述べる方法で、重み係数の繰り返し更新における学習率を制御した。まず、初期値 0.30 とし、学習が 10 回進むごとに前の学習率に 0.90 かけることで、学習が進むにつれ、徐々に小さくなるように設定した。ここで、初期値と削減率は実験を通して決定した。

3. 実験

提案手法の有効性を検証するため、被殻の2次元メッシュモデル (Fig.2 左部) を用いて、その変形を推定する実験を行った。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。DNN の構築で用いる学習データは、被殻に力が作用したときの変形パターンであり、このパターンは非線形 FEM で求める。ここで、FEM 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 (Fig.2 左部の赤点) とした。また、固定節点以外の 37 個の境界節点 (Fig.2 左部の黄点) 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。1つの変形パターンは、19 時刻分の変形を表しており、したがって、計 33,744 個の学習データを使って、各節点の DNN を構築した。学習デー

Table 1: The maximum and the minimum value of displacement and stress in the training data.

		変位 [mm]	応力 [N/mm ²]
学習データ	最大値	7.2E+00	3.2E+05
	最小値	-1.2E+01	-3.9E+05
テストデータ	最大値	2.6E+00	1.5E+05
	最小値	-2.1E+00	-2.5E+05

Table 2: Average error of all internal nodes between FEM simulation values and estimated values by DNN.

		変位 [mm × 10 ⁻²]	応力 [N/mm ²]
学習	従来法 ¹⁾	4.4 ± 2.8	1.9 ± 1.9
	提案手法	3.2 ± 1.4	1.5 ± 1.2
汎化	従来法 ¹⁾	3.6 ± 2.5	1.5 ± 2.1
	提案手法	2.8 ± 1.2	1.1 ± 0.99

Table 3: Structure of DNN for a node with 5 neighbor nodes.

層数	局所結合層				全結合層														
19	12	60	60	60	180	144	115	92	73	58	46	36	30	24	18	14	11	8	4
	32	140	140	140															

タとして用いた変位と応力の最大値と最小値を、それぞれ Table 1 に示す。

本研究では、接続している節点数に応じて、局所結合層や全結合層のそれぞれの層数、各層内のニューロン数を変え、様々な構造の DNN を構築し、それによる被殻の変形精度を検証した。Table 3 に、隣接節点数が 5 の節点の DNN の構造を示す。

提案システムと、従来システム¹⁾それぞれの学習・汎化誤差を、Table 2 に示す。ここで、各誤差は、システムが推定した変位・応力ベクトルと、FEM によって得られた変位・応力ベクトルの L_2 ノルムとした。変位・応力を一つのベクトルとして扱う従来法と比べ、本手法は変位・応力に加え、相対速度・加速度を入力情報として用いるため、従来法より入力次元数が高い。一般に、入力次元数が高いと学習すべき問題が複雑になるが、Table 2 により、提案手法の各平均誤差は従来法以下であった。また、Table 1 に示す学習・テストデータの値域と比べると、学習・汎化の各誤差は小さく精度良く学習できているといえる。これは、提案手法が、変位・応力それぞれを高次元に写像しそれらを統合する構造によって、変位・応力のデータ分布を DNN が捉えやすくなり、それにより従来法より推定精度が向上したと考えられる。

4. 結言

本稿では、各節点の挙動を高精度に推定する DNN の構築を行った。そして、構築した DNN による推定値と、FEA によるシミュレーション値を比較し、精度を検証した。

現在、2次元モデルを用いた実験を行っている。この実験により求めた多面体要素の挙動を推定する DNN の構造を参考に、3次元である胸郭骨モデルを対象とした、多角形要素の挙動を推定する DNN を構築し、脊椎側彎症治療診断システムに導入可能となる精度を達成する高速な変形

推定を実現する。

謝辞

この研究の一部は、高橋産業経済研究財団、JSPS 科研費 16K00243、17H05299 の助成を受けた。

参考文献

- [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 Assia, pp.187-198(2017)
- [2] Kensuke Kubota, Toshio Doi, and Masaharu Murata, Disturbance of Rib Cage Development Causes Progressive Thoracic Scoliosis : The Creation of a Nonsurgical Structural Scoliosis Model in Mice, The Journal of Bone & Joint Surgery, vol.95, Issue 18, pp.1-7 (2013)
- [3] Francois Goulette, and Zhuo-Wei Chen, Fast computation of soft tissue deformations in real-time simulation with Hyper-Elastic Mass Links, Computer Methods in Applied Mechanics and Engineering, vol.295, pp.18-38 (2015)
- [4] Kazuhide Makiyama, Manabu Nagasaka, Toru Inuiya, Kentaro Takanami, Masato Ogata, and Yoshinobu Kubota. Development of a patient specific simulator for laparoscopic renal surgery. International Journal of Urology, Vol. 19, No. 9, pp. 829-835 (2012)
- [5] Matthias Müller, and Markus Gross. Interactive virtual materials. In Proceedings of Graphics Interface 2004, pp.239-246 (2004)
- [6] Yipeng Hu, Eli Gibson, Tom Vercauteren, Hashim U. Ahmed, Mark Emberton, Caroline M. Moore, J. Alison Noble, Dean C. Barratt, Intraoperative Organ Motion Models with an Ensemble of Conditional Generative Adversarial Networks, Medical Image Computing and Computer Assisted Interventions Conference, part2, pp.368-376 (2017)