日本コンピュータ外科学会 年次報告

コンピュータ外科と人工知能・機械学習

Computer Aided Surgery and Artificial Intelligence/Machine Learning

森 健策 (正会員)^{a*,b}^a 名古屋大学大学院情報学研究科知能システム学専攻^b 名古屋大学情報基盤センターKensaku Mori^a^a Department of Intelligent System, Graduate School of Informatics, Nagoya University^b Information Technology Center, Nagoya University

Key words

機械学習, 人工知能, 医用画像処理, 解剖学的構造, 術前診断, シミュレーション

1. 基本説明

2016 年は人工知能がブームとなったと記憶される年であった。パターン認識技術が人工知能技術であるかのようなブームであったともいえよう。「ディープラーニング」と呼ばれるニューラルネットワークにより、コンピュータによる画像認識精度が格段に向上することが示されると、画像だけにとどまらず、音声、言語などの種々のメディア処理分野で深層ニューラルネットワークが活用されるようになった。1960 年代の第 1 次ニューラルネットワークブーム、1980 年代後半から 1990 年代前半にかけての第 2 次ニューラルネットワークブームに次ぐ、第 3 次ニューラルネットワークブームとなっている。第 1 次ニューラルネットワークブームでは、パーセプトロン¹⁾と呼ばれる線形識別が可能なニューラルネットワークが、第 2 次ニューラルネットワークブームでは、3 層ニューラルネットワークとそれを学習させるための誤差逆伝播学習法 (バックプロパゲーション) がブームを支えた技術基盤であったと考える^{2),3)}。そして、第 3 次ニューラルネットワークブームでは、ニューラルネットワークの層を十分に深くしたディープ

ラーニングがそのブームを支えているといえよう。

本年次報告では、人工知能技術 (機械学習技術) がコンピュータ外科の分野において、どのような影響を与えているかについて述べたい。

2. 国内外の研究動向

2.1 進歩が著しい点

先述のように、人工知能=ニューラルネットワークとマスコミなどではとらえられているが、ニューラルネットワークは機械学習と呼ばれる学問分野の一つの技術にすぎない。このような誤解は現在のマスメディアの過度な期待での取り上げ方にも依存しているといえよう。機械学習においては、統計的パターン認識、パラメトリックパターン認識、非パラメトリックパターン認識など種々の手法があり²⁾⁻⁴⁾、ニューラルネットワークはその一部にすぎない。CNN (Convolutional Neural Network) と呼ばれるニューラルネットワークは、現在画像認識で活用されているが、もとをたどれば 1980 年代における Fukushima らの Neocognitron⁵⁾ と名付けられた手法である。当時と大きく異なるのは、コンピュータの処理性能向上、とりわけ、GPU (General Processing Unit) と呼ばれるグラフィックス処理ユニットを源流するプロセッサの飛躍的な計算能力向上がある。この処理能力向上

*名古屋大学大学院情報学研究科知能システム学専攻
〒464-8601 愛知県名古屋市中種区不老町
kensaku@is.nagoya-u.ac.jp

によって、もともと大きな処理能力が必要とされる深層ニューラルネットワークが誰でも利用可能になったことは疑う余地がない。もちろん Caffer, Tensorflow, cuDNN などのソフトウェアパッケージの充実も多大なる貢献をしているといえよう。

機械学習を画像認識などの分野において利用する場合、主として2つの手法がある。一つは、特徴量抽出ではあらかじめ人が作成した特徴量抽出処理によって行い、得られた特徴量を機械学習の方法によって分類するものである。この場合の特徴量は、Hand-Crafted Features などとも呼ばれる。この場合には、ニューラルネットワーク、AdaBoost, Support Vector Machine (SVM), Random Forest などの分類器によって識別処理が行われる^{2),3),6)}。一方、特徴抽出自体も機械学習によって行うのが CNN と呼ばれる手法である。これは、入力画像と教師データ（正解データ）のペアを与えれば、特徴抽出も含めてニューラルネットワークが分類などを行うものである。

2.2 進歩が停滞している点

機械学習の医用応用は、まさに現在絶頂期にあるとはいえ、活発に研究がなされている。進歩が停滞している点はないともいえよう。

2.3 新しい研究の動きが出ている点

文部科学省科学新学術領域「多元計算解剖学」など医用画像をもとに様々な意思決定を機械学習を用いて行う試みがある。また、AMED などにおいても人工知能（機械学習）技術を用いた診断治療支援に関する研究開発公募がなされており、今後新たな研究の動きが出てくるといえよう。先述のように、オープンソースソフトウェアの整備により、誰でも気軽に Deep Learning, とりわけ, CNN を試すことが可能となった。これらを用いた新しい研究の動きが今後出てくるものと期待される。

3. 臨床応用・製品化の動向

コンピュータ外科領域は、術前・術中に計測されるデータをコンピュータによって処理し、その結果を外科医に提示する、あるいはロボット駆動にフィードバックする研究が行われている。このような判断部分において、人工知能・機械学習が大きな力を発揮することになる。特に、臓器セグメンテーションなどについては、市販の画像処理ワークステーション上

で気軽に実行できるようになっている。術前診断、術中ナビゲーションに必要な CT 画像の画像解析における機械学習の利用方法について例示し、今後の製品化動向を予測する。

3.1 リンパ節検出

内視鏡下胃切除術など腹部のがんを対象とした手術において、腫大リンパ節の存在位置をあらかじめ診断することは、必要な術前診断の一つとなる。機械学習を用いて腫大リンパ節領域を検出するには、大きく分けて3つの方法がある。一つ目は、腫大リンパ節が疑われる領域（腫大リンパ節候補領域とする巢ことにする）を塊状構造強調フィルタにより抽出し、その後、過検出と疑われる領域を SVM³⁾などの機械学習によって削減するものである。FP 削減に使用される特徴量は、腫大リンパ節候補領域から計算される、濃度値平均、分散、体積、球形度などの特徴量が用いられる。Fig. 1 に塊状構造強調フィルタによるリンパ節検出例を示す。

2つ目の方法は、小さな画像パッチ（例えば 32×32×32 画素）に画像を分割し、この画像パッチ内にリンパ節が含まれるか否かを機械学習によって判断するものである。AdaBoost などの判別機を多段につなげ、リンパ節が存在すると疑われるパッチのみを過力する。3つ目の方法は、CNN によってリンパ節候補領域直接的に検出するものである。3D U-Net などの Fully Connected Neural Network などがセグメンテーションに利用される。

3.2 臓器領域セグメンテーション

CT 画像、MRI 画像などの医用画像から臓器領域をセグメンテーションする技術の開発は、コンピュータ外科分野全般において重要な問題である。医用画像からの臓器領域セグメンテーションにおいても、機械学習が重要な役割を果たすようになっている。

例えば、Regression Forest と呼ばれる手法を利用することによって、ある特定の臓器のバウンディングボックスを検出することが可能となっている^{7),8)} (Fig. 2)。これは、ちょうどデジタルカメラにおいて人の顔の部分に枠が表示されるのと同様である。また、3D U-net などの Fully Convolutional Neural Network^{9)~11)}を利用した手法も開発されており、腹部 CT 像における臓器領域セグメンテーションでも良好な結果が得られている (Fig. 3)。また、セグメンテーション結果

Fig.1 Example of lymph node detection based on machine learning-based FP reduction process.

Fig.2 Example of pancreas bounding box detection based on random regression.

Fig.3 Example of abdominal multiorgan segmentation from 3D CT volume by 3D U-net.

Fig.4 Anatomical structure display synchronized to laparoscope motion as surgical navigation.

を内視鏡手術ナビゲーションで利用している例を **Fig. 4** に示す.

3.3 血管名自動命名

腹腔鏡を対象とした手術ナビゲーションシステムにおいて、現在観察している血管名などを重畳表示する、あるいは、CT像から抽出された血管の3次元画像表示において血管名を表示することは、診断・治療を支援する一つの技術としてとらえることができる。CT画像などからセグメンテーションされた血管領域に対して、その各血管枝に解剖学的名称を割りあてる処理においても機械学習が利用されている。

文献 12 に示す手法では、血管領域セグメンテーション結果から、血管分岐構造の木構造を取り出す。その後、木構造の各枝（血管の各枝）において、特徴量を求め、血管名を分類クラスとして出力する AdaBoost 分類器を構築する（学習させる）。未知のデータが入力された場合には、血管木構造を取り出したのち特徴量を計算し、その後 Adaboost 分類器で血管名ラベルを得るものである。

一方、文献 13 に示される手法では、CRF (Conditional Random Field; 条件付き確率場) と呼ばれるグラフカルモデルに基づく機械学習の手法を利用して血管名を出力する分類器を実現するものである。この手法では、各血管枝において計算される特徴量のみでなく、親子関係をも考慮することができる特徴がある。機械学習による血管名自動命名例を **Fig. 5** に示す。

Fig.5 Example of automated anatomical labeling of abdominal arteries based on conditional random field.

3.4 ユーザインタフェース

手術ナビゲーションシステム、手術ロボットにおける音声認識の利用もコンピュータ外科領域における機械学習利用の応用であるといえよう。手術ロボット Aesop における音声コマンドは、その一つの例である。先述のように機械学習を利用して患者個々の解剖学的構造を認識できるようになり、それを手術ナビゲーションに利用している。術中に目的とする解剖学的構造を手術ナビゲーションシステムに表示する場合でも、例えば「SMA」と話しかければ、SMAを表示するユーザインタフェースが実現されている¹⁴⁾。重要なのは、機械学習によって個々人の解剖学的構造が認識されており、音声認識などのユーザインタフェースと組み合わせることで、個々の患者の解剖学的構造に対応した高度なユーザインタフェースが実現できることである。

4. 求められるブレークスルー

本報告では、人工知能技術（機械学習技術）がコンピュータ外科の分野において、どのような手法が実現できているのかについて、筆者が専門とする画像認識を中心にして述べた。また、機械学習のトレンドについて簡単に述べた。機械学習を用いた医用画像処理は一番ホットな話題となっており、これを用いた製品が今後数多く商品化されると期待される。機械学習の場合、質の良い学習用データベースが勝負のポイントとなる。データベースの構築が一つのブレークスルーポイントとなるであろう。

謝辞

本研究の一部は、JSPS 科研費 17H00867, 15K21716, 26560255, 26108006, JSPS 二国間交流, AMED 研究費によった。日頃討論いただく名古屋大学森健策研究室諸氏に感謝する。

文献

- 1) Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol Rev* 1958;65: 386-408.
- 2) Duda RO, Hart PE, Stork DG. *Pattern Classification*. John Wiley 2001.
- 3) Bishop CM. *Pattern Recognition And Machine Learning*. Springer 2006.
- 4) Fukunaga K. *Introduction to Statistical Pattern Recognition*.

Academic Press 1990.

- 5) Fukushima K, Miyake S, Ito T. Neocognitron: A neural network model for a mechanism of visual pattern recognition. *IEEE Trans Syst. Man Cybern* vol. SMC-13. 1983;826-834.
- 6) Breiman L. Random forests. *Mach Learn* 2001;45:5-32.
- 7) Criminisi A, Robertson D, Konukoglu E, et al. Regression forests for efficient anatomy detection and localization in computed tomography scans. *Med Image Anal* 2013;17:1293-1303.
- 8) Oda M, Shimizu N, Karasawa K, et al. Regression Forest-Based Atlas Localization and Direction Specific Atlas Generation for Pancreas Segmentation. *MICCAI* 2016. LNCS 9901. Greece. 2016;556-563.
- 9) Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *LNCS* 2015 (Proc. MICCAI 2015);9351.
- 10) Roth HR, Oda M, Hayashi Y, et al. Multi-organ segmentation in abdominal CT using 3D fully convolutional networks. *Int J Comput Assis Radiol Surg* 2017;12(Suppl 1):S55-57.
- 11) Chen LC, Papandreou G, Kokkinos I, et al. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *arXiv Prepr* 2016;1-14.
- 12) Matsuzaki T, Oda M, Kitasaka T, et al. Automated anatomical labeling of abdominal arteries and hepatic portal system extracted from abdominal CT volumes. *Med Image Anal* 2015; 20:152-161.
- 13) Kitasaka T, Kagajo M, Nimura Y, et al. Automatic anatomical labeling of arteries and veins using conditional random fields. *Int J Comput Assist Radiol Surg* 2017;12:1041-1048.
- 14) Mori K, Hirata M, Matsuzaki T, et al. Development of laparoscope surgery navigation system activated by utterance of anatomical name based on automated anatomical name recognition of abdominal blood vessels. *International Journal of Computer Assisted Radiology and Surgery* 2014;9:S353-S354.