

医用画像の xR

xR for Medical Images

京都大学 ○ 中尾 恵

Megumi Nakao

Kyoto University

Abstract The morphological information of human organs inherent in 3D medical images is used for diagnosis, pre-treatment planning and surgical guidance. However, the image quality and resolution in medical images available during treatment are insufficient or only 2D images are acquired due to physical or hardware limitations. To address this issue, extended reality (xR) images are generated based on machine learning and mathematical modeling, which utilize statistical knowledge of our body, and their clinical applications are being explored. In this presentation, we introduce recent trends and case studies of xR technology for reconstructing and enhancing medical images based on machine learning and mathematical modeling.

1 はじめに

医用イメージング機器の高度化やモダリティの多様化によって、診断時や治療前に患者個人の高解像度の3次元画像が撮像可能となったが、治療当日に生体臓器は同一の状態ではなく、治療時に利用可能な計測装置の制限から生体の一部しか観測できない。治療時における生体情報の不足は精密な治療を妨げる主要因であり、治療の低侵襲化と高精度化を目指す放射線治療、外科治療が直面する本質的な課題である。高度な治療の遂行に十分な情報が得られない現状において、医療従事者は追加の計測やデータの処理に多くの労力と時間を費やしている。

治療時における生体イメージングの困難さを補うことを目的に、患者個人の3次元画像から生成された生体臓器のバーチャル画像が臨床医学において広く活用されている [1]。バーチャル画像と実画像との融合や、元来の医用画像から拡張されたクロスリアリティ (Extended Reality, xR) 画像も生成され、手術計画や手術時のナビゲーション、若手医師の医学教育等に幅広く利用されるようになった [2][3]。さらに近年では機械学習の医用画像への応用が探索され、医用画像内の臓器や病変部位の検出精度が著しく向上した。以上のような背景の下、本稿では機械学習を利用した医用画像の xR に着目したい。

本研究では、機械学習による画像生成を活用した医用画像の xR の枠組みを広く探究しており、特に観測データに含まれない情報を生体の統計的性質に基づいて再構成、あるいは、拡張した画像を生成する試みを行ってきた。本問題は事前知識なしでは不良設定問題であるが、CT 画像に内在する生体組織と画素間の関係性、統計的知識を活用して追加の計測を必要とせずに xR 画像を生成する。

本概念により、例えば撮像領域が限られた画像や欠損を含む低画質画像から臓器全体の形状や変形を復元する、1枚の内視鏡カメラ画像や X 線画像のみから臓器変形を認識し、治療前に得られた CT を補正して腫瘍位置を可視化するなどへの応用が考えられる。これにより、手術支援や放射線治療における xR 画像のさらなる利用拡大、新たな診断、治療プロセスの創出に繋がることが期待できる。特に本稿では、医用画像を対象とした xR として医用画像の変換と拡張のテーマに焦点を当て、機械学習や数理モデリングに基づく画像生成技術の最近の動向と研究事例を紹介する。

2 医用画像の変換

医用画像の画質改善や超解像、モダリティ間の変換を目的とした深層学習の枠組みはこの 10 年間で多くの研究例が報告されてきた [4]。医療現場においては同一患者を対象に完全に構造が一致した画像群を得ることは容易ではないため、近年では 1 対 1 に対応が取られた画像群を前提としない教師なし学習が広く研究されており、特に敵対的生成ネットワーク (Generative Adversarial Network, GAN) やその拡張である CycleGAN の応用が試みられている [4][5]。これまでに複数の研究において CT 画像に含まれる歯科金属アーチファクトや頭頸部 CBCT 画像のアーチファクト低減に CycleGAN の枠組みが有効であることが確認されている [6][7][8]。

図 1 は歯科金属に複数の dark band や scattering noise を含む強いアーチファクトを有する 3 次元 CT 画像 (上段) に対して 20 年以上の経験を有する歯科技工士による手動補正 (中段) と cycleGAN を 3 次元に拡張した 3DGAN [6] を適用した結果 (下段) を示している。




図 1: 歯科技工士による手動修正と敵対的生成ネットワークによる画像変換




図 2: フィードバック機構を備えた敵対的学習による CBCT 画像の変換結果

3DGAN は 361 症例の実患者 3 次元 CT 画像を歯科金属の有無に基づいて分類した金属アーチファクトデータベースを構築し、アーチファクト低減向けに新たに設計した損失関数に基づいて敵対的トレーニング行ってきた金属アーチファクト低減モデルである。歯科技工士による手動修正では歯の表面に凹凸のある不規則なノイズが残存しているが、提案方法では臨床において利用可能なアーチファクト低減を達成し、かつ、滑らかな歯の構造を復元することが確認された。手動修正及び提案方法による処理時間はそれぞれ 52 分、13 秒であり臨床利用が可能な水準の修正結果が得られることが確認されている。

画質改善が期待されるモダリティに Cone-beam Computed Tomography (CBCT) 画像がある。CBCT は小

型かつ可動型のイメージング装置であり、外科手術や放射線治療において治療直前や治療中の姿勢で患者の 3 次元画像を取得することができる。一方、CBCT 画像におけるアーチファクトは、複数の発生要因から生じるために多様な画像特徴を示し、また画像内の広範囲に渡って存在する。このため、従来研究で提案された学習の枠組みや損失関数の正規化 [9][10] によっても十分な画質改善が達成されない場合が存在する。局所的に異なる画像特徴を捉えつつ、多様な画像生成を実現する敵対的学習、画像変換の達成は依然課題である。

本研究では、CBCT 画像の画質改善を目的とした新たな教師なし学習の枠組みとして、識別器からのフィードバック機構を備えた敵対的学習を提案した [11]。図 2 は敵対的学習による CBCT 画像の変換例である。上の CBCT 画像内の矢印部では腹部の一部の情報が欠損しており、CT 画像と比較して全体的に画像が暗くなっており、画素値も不正確であるが、生成画像では腹部の外形を復元しつつ CT 画像に近い画素値へ修正されている。下の例では、大腿骨の一部に強いアーチファクトが生じて形状情報が失われているが、生成画像では統計的に当該箇所の組織が示すべき画素に近い値で復元されており画質向上が達成されている。

3 医用画像の拡張

本節では、2 次元の医用画像に対してより高次元な生体情報を付与する xR 画像とその生成方法について紹介する。単一の 2 次元投影画像から臓器の 3 次元形状を再構成する問題は 2 次元空間における点から、より高次元の空間における点への変換を求めるものであり、事前知識なしでは不良設定問題である。この課題に対し、臨床では治療前に撮像される密な 3D-CT や MRI 画像から患者固有の臓器形状をサンプリングし、事前知識として活用する方法が考えられる。リアルタイムに撮像が可能な 2 次元投影画像に対して臓器形状モデルの配置や変形を求めるアプローチである。これは 2D/3D 位置合わせと呼ばれ、この医用画像解析の研究領域において精力的に研究がなされてきた [3][12][13]。

軟臓器を対象とした 2D/3D 可変形位置合わせは、2 次元画像と 3D ボリューム間で点对点の局所的な対応を求める問題である。剛体位置合わせと異なり、サンプリング点数に比例する大規模なパラメータの最適化が必要となる。これに近い問題として、ボリューム間の可変形位置合わせがあるが、大規模なパラメータセットに対する最適化に要する計算コストが問題とされてきた。この課題に対し、深層学習を用いて 3 次元変位場を学習する枠

組み [14] が報告されている。Graphic Processing Unit (GPU) による並列演算により訓練された学習モデルはより高速な位置合わせを実現可能である。

単一画像に対する 2D/3D 可変形位置合わせはボリューム間の位置合わせよりも利用可能な制約が少なく、安定な最適解の算出が難しい。入力画像のみに基づく予測は不確実性が高いため、事前知識として用いる臓器形状のモデルと入力となる 2 次元画像間のマッピング、及び、その学習方法が鍵となる。医用画像分野においてはこれまでに外科手術支援を目的とした 2 次元カメラ画像に対するモデルベース最適化が試みられている [2][15]。しかし、深層学習に基づく 2D/3D 可変形位置合わせの枠組みは少なく、特に腹部臓器を対象とした実証例は報告例がない。

筆者らは変位場の学習による単一投影像に対する可変形モデル位置合わせの開発を目指した。2 次元投影像に基づいて 3 次元臓器の形状再構築を可能とする image-to-graph convolutional neural network (IGCN) [16][17] を構築した。さらに IGCN における特徴抽出部を変位場生成モデルへ拡張することで位置合わせ精度を向上させた枠組みを構築した。図 3 は IGCN によって 1 枚の疑似 X 線画像 (左) に対して 3 次元メッシュを変形位置合わせして重畳可視化した結果 (右) である。特に胃、十二指腸、膵がんについては疑似 X 線画像において輪郭が全く視認されないが、周辺の画像特徴から各臓器の位置が推定されている。

深層学習に基づく 2D/3D 位置合わせは高速に位置合わせ結果を得ることができるため、手術支援においても利用が期待されている。事前に撮像された患者固有の 3 次元 CT 画像から得られる臓器モデルを手術時に得られる内視鏡カメラ映像に対して位置合わせすることで拡張内視鏡画像を生成可能である。図 4 は胸腔鏡下肺がん切除術を受けた患者から得られたバーチャル像を手術ビデオから事後的に得た手術シーンに対して位置合わせした結果を示している。臨床現場では研修医や若手医師は手術ビデオを繰り返し見て学習することがなされているが、内視鏡カメラ映像では初学者には解剖が分かりづらい場合がある。xR 画像によって実画像とバーチャル画像双方が持つ情報を生かした情報提示が可能となる。また、追加計測を必要としない画像誘導下手術の実現を目指し、手術中の内視鏡画像に対して実時間で位置合わせを行う枠組みについても開発を進めているが、学習データの少なさへの対応や定量評価の確立が必要であるなど実現へ向けた課題は多く残っている。




図 3: 1 枚の疑似 X 線画像から推定された腹部臓器形状, 赤: 肝臓, 青: 胃, 緑: 十二指腸, 黄: 腎臓, 灰: 膵がん




図 4: 手術映像にバーチャル像が重畳された拡張内視鏡像, 赤: 動脈, 青: 静脈, 紫: 気管支

4 おわりに

本稿では、医用画像の xR を実現する技術として医用画像の変換と拡張に焦点を当て、機械学習を用いた画像生成技術の最近の動向と研究事例を紹介した。臨床医学における xR 画像の利用機会は増加しており、画像生成技術のさらなる向上に伴って医師・患者双方の負担軽減や治療プロセスの高位平準化への貢献が期待される。

参考文献

- [1] J. Tokuno, T. F. Chen-Yoshikawa, M. Nakao, M. Ikeda, T. Matsuda, H. Date, Resection process map: A novel dynamic simulation system for pulmonary resection, The Journal of Thoracic and Cardiovascular Surgery, 159(3), pp.1139-1138, 2020.
- [2] B. Koo, E. özgür, B. Le Roy, E. Buc, and A. Bartoli, "Deformable registration of a preoperative 3D

- liver volume to a laparoscopy image using contour and shading cues,” *Medical Image Computing and Computer Assisted Intervention*, pp. 326-334, 2017.
- [3] C. J. F. Reyneke, M. Lüthi, V. Burdin, T. Douglas, T. Vetter, and T. Mutsvangwa, “Review of 2-D/3-D reconstruction using statistical shape and intensity models and X-Ray image synthesis: toward a unified framework,” *IEEE Reviews in Biomedical Engineering*, vol. 12, pp. 269-286, 2019.
- [4] X. Yi, E. Walia, P. Babyn, Generative adversarial network in medical imaging: A review, *Medical image analysis*, vol. 58, Art no. 101552, 2019.
- [5] J. Zhu, T. Park, P. Isola, A. A. Efros, ”Unpaired image-to-image translation using Cycle-consistent adversarial networks,” *IEEE Int. Conf. Computer Vision (ICCV)*, 2017.
- [6] M. Nakao, K. Imanishi, N. Ueda, Y. Imai, T. Kirita, T. Matsuda, Regularized three-dimensional generative adversarial nets for unsupervised metal artifact reduction in head and neck CT images, *IEEE Access*, Vol. 8, pp. 109453-109465, 2020.
- [7] M. Nakamura, M. Nakao, K. Imanishi, H. Hirashima, Y. Tsuruta, Geometric and dosimetric impact of 3D generative adversarial network-based metal artifact reduction algorithm on VMAT and IMPT for the head and neck region, *Radiation Oncology*, 16, 96, 2021.
- [8] X. Liang, L. Chen, D. Nguyen, Z. Zhou, X. Gu, M. Yang, J. Wang, S. Jiang, Generating synthesized computed tomography (CT) from cone-beam computed tomography (CBCT) using CycleGAN for adaptive radiation therapy, *Physics in Medicine and Biology*, Vol. 64, No. 12, p. 125002 (2019).
- [9] S. Kida, S. Kaji, K. Nawa, T. Imae, T. Nakamoto, S. Ozaki, T. Ohta, Y. Nozawa, K. Nakagawa, Visual enhancement of Cone-beam CT by use of Cycle- GAN, *Medical Physics*, Vol. 47, No. 3, pp. 998 – 1010, 2020.
- [10] T. Hase, M. Nakao, K. Imanishi, M. Nakamura, T. Matsuda, Improvement of image quality of cone-beam CT images by three-dimensional generative adversarial network, 43rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 2843-2846, 2021.
- [11] 羽瀬 拓視, 中尾 恵, 今西 勁峰, 中村 光宏, 松田 哲也, 識別器からのフィードバック機構を備えた敵対的学習による Cone-beam CT 画像の画質改善, 情報処理学会 コンピュータビジョンとイメージメディア研究会 (CVIM), 2022-CVIM-229(36), pp.1-8, 2022.
- [12] P. Markelj, D. Tomaževič, B. Likar, and F. Pernuš, “A review of 3D/2D registration methods for image-guided interventions,” *Medical image analysis*, vol. 16, no. 3, pp. 642-661, 2012.
- [13] G. Haskins, U. Kruger, P. Yan, ”Deep learning in medical image registration: a survey,” *Machine Vision and Applications*, vol. 31, no. 1, pp. 1-18, 2020.
- [14] G. Balakrishnan, A. Zhao, M. R. Sabuncu, J. Guttag, and A. V. Dalca, VoxelMorph: A learning framework for deformable medical image registration, *IEEE Trans Med Imaging* vol. 38, no. 8, pp. 1788-1800, 2019.
- [15] S. Wu, M. Nakao, J. Tokuno, T. Chen-Yoshikawa, and T. Matsuda, “Reconstructing 3D lung shape from a single 2D image during the deaeration deformation process using model-based data augmentation,” *IEEE Int. Conf. on Biomedical and Health Informatics (BHI)*, pp. 1-4, 2019.
- [16] F. Tong, M. Nakao, S. Wu, M. Nakamura and T. Matsuda, X-ray2Shape: Reconstruction of 3D liver shape from a single 2D projection Image, 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 1608-1611, 2020.
- [17] M. Nakao, M. Nakamura, T. Matsuda, Image-to-graph convolutional network for deformable shape reconstruction from a single projection image, International Conference on Medical Image Computing and Computer Assisted Intervention (MIC-CAI), pp. 259-268, 2021.