

Hybrid Learningによる画像診断支援

Image Diagnosis Support using Hybrid Learning

影山昌広 Masahiro Kageyama / 野口喜実 Yoshimi Noguchi

吉田英恵 Hanae Yoshida / 金子幸生 Yukio Kaneko

荻野昌宏 Masahiro Ogino

株式会社 日立製作所 研究開発グループ

ABSTRACT

医療現場における作業効率化や診断の質向上、診療アウトカムの向上といった課題解決へ向け、AI (Artificial Intelligence) 活用が活性化している。画像診断は、その中でも最も実用化が早いと考えられている医療分野の一つである。現状ではまだ研究レベルの内容が多いが、米国ではすでに診断支援 (CADx) で FDA (Food and Drug Administration : アメリカ食品医薬品局) で承認される機器も出始めており、実用化へ向けた動きも進んでいる。日立は、Hybrid Learningというコンセプトの下、高精度かつ医学的妥当性の高い結果を導く独自の画像診断AI技術の研究開発を推進している。本稿では、具体例として、高精度な病巣検出機能を実現する肺がんCAD技術と撮像高速化を実現するMRI高画質化技術について述べる。

The use of AI(Artificial Intelligence) has been activated to solve problems such as improving work efficiency at medical sites, improving the quality of diagnosis, and improving medical outcome. Currently, most of the related study is still research level, but in the United States some medical devices that are approved by the FDA(Food and Drug Administration) are starting to appear, and movements toward practical use are also proceeding. Under the concept of “Hybrid Learning”, Hitachi is promoting R & D on original diagnostic imaging AI technology that leads to highly accurate and medical validity results. In this paper, as a specific example, we describe lung cancer CAD technology that realizes highly accurate lesion detection function and MRI high image quality technology to realize high speed imaging.

Key Word: AI, Deep Learning, Radiology, Diagnostic Support, Machine Learning

はじめに

世界では医療リソースの有効活用が喫緊の課題であり、例えば、医師・技師の負担軽減や人手不足の解消、画像診断装置の効率運用、画像診断の質の向上や標準化などが求められている。このような課題の解決に、AI (Artificial Intelligence、人工知能) を活用する研究開発が近年急激に活性化している。例えば、撮像パラメータや計測操作の自動化による技師の操作負担軽減や検査時間の短縮、病変候補領域検出の自動化や良悪性判断支援による医師の読影・診断負担軽減など、検査・診断ワークフローの効率化および画像診断の質の向上が期待されている。先行する米国では、こうした技術を活用した診断支援 (CADx) や自動診断ソリューションが医療機器としてFDAで承認され始めており¹⁾²⁾、今後医療現場へのAI活用が世界的に進んでいくものと考えられる。

本稿では、われわれが取り組んでいるAIを応用した画像診断支援技術に関して紹介する。

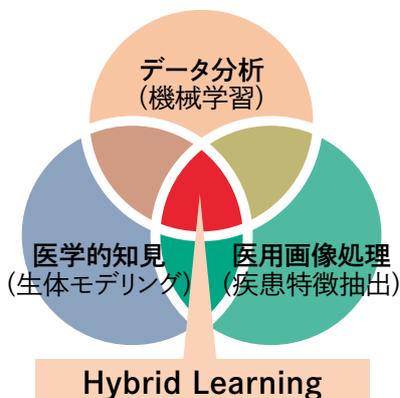
画像診断AI技術開発コンセプト

図1に、AIを活用した画像診断支援研究の方向性を示す。病変候補陰影の検出を目的としたCADe (Computer Aided Detection)、腫瘍の良悪性分類など鑑別まで踏み込んだCADx (Computer Aided Diagnosis)、そして例えば判断の難しい画像から将来の予測をスコアや確率で予測するCAP (Computer Aided Prediction) である。医療現場での受け入れやすさやコストを踏まえ、この進化過程で研究開発を進めることは顧客価値最大化を狙う意味で重要であると考えている。また、画像診断において画質の改善は不変のテーマであり、AIを活用した高画質化技術CAR (Computer Aided Reconstruction: 日立に

図1 画像診断支援の進化



図2 Hybrid Learning



よる造語)も重要な基盤技術と考えている。

図2は、日立独自の画像診断AI技術コンセプトである、Hybrid Learningの基本思想を示している。長年医用画像診断装置メーカーとして培った医学的知見、多くの産業分野で蓄積してきた画像処理技術と、Deep Learningに代表される機械学習とを融合させ、高精度かつ医学的妥当性の高い結果を導くAI技術の開発をめざしている。

以下、Hybrid Learningのコンセプトの下、開発中のCADeとCARの技術に関し紹介する。

開発技術

1 高精度な病巣検出機能を実現するCT肺がんCAD技術

1) 背景と目的

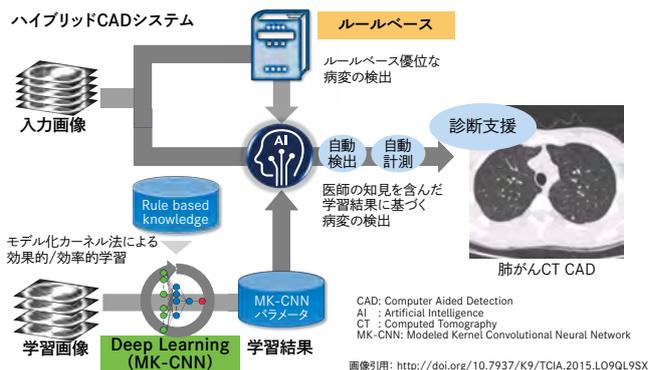
肺がんは世界的にみて死亡率第一位のがんであり、早期発見と早期診断が重要である。2011年、米国で行われたNLST (National Lung Screening Trial) が、胸部低線量CT検診(以下、肺がんCT検診)が重喫煙者の肺がん死亡率低減に有効と示した³⁾。日本では、対策型検診が胸部単純X線により実施され、任意型検診は胸部単純X線検査と肺がんCT検診が実施されている。

CT画像による検査では、医師が1受診者あたり100枚を超える画像を読影する必要があり、医師にとって心理的にも身体的にも負担が大きい。さらに、読影の質を担保するため、2人の医師による二重読影をすると、医師の負担に加え読影のコストも増加する。

日立では1990年代後半から、肺がん診断支援システム(CADe)の研究を進めてきた⁴⁾。今回、これまでの経験・知識とDeep Learningを融合して学習した「モデル化カーネル畳み込みニューラルネットワーク」(Modeled Kernel Convolutional

図3 肺がんCADの概要

ルールベースのアルゴリズムとDeep Learningを融合したハイブリッドCADシステムにより、医師の知見を含んだ学習結果に基づく病変検出を実現する。



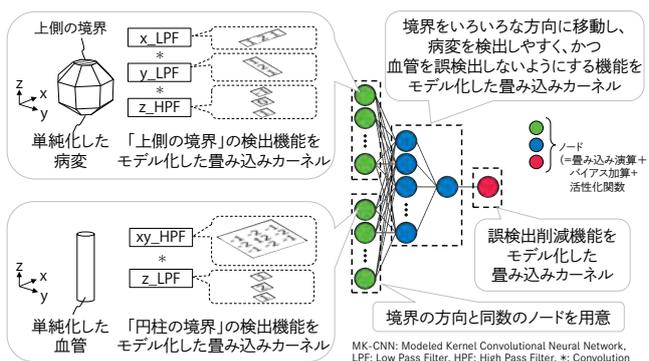
Neural Network: MK-CNN)と呼ぶ新技術を開発し、医師の知見に基づいたルールベース検出技術を融合した「ハイブリッドCADシステム」を構築して、病変検出の精度向上を図っている(図3)。

Deep Learningは、高性能を得やすい反面、学習結果がブラックボックスになってしまうため、性能調整の難しさや推論過程の説明が課題となっている。特に、学習開始前に設計者が決めておくハイパーパラメータ(ネットワークの層数、各層のノード数、ノード中の畳み込みカーネルの初期値、等)と性能との関係が体系化されておらず、高精度の病変検出を実現するためには、ハイパーパラメータ調整の多大な試行錯誤が必要であった。

そこで日立では、「モデル化カーネル法」と呼ぶ新しいハイパーパラメータ設計法を開発し、試行錯誤の回数を大幅に抑えながら、効果的かつ効率的なネットワーク学習を実現した⁵⁾。この設計法では、畳み込みニューラルネットワーク(CNN)を構成する各層に求める機能をあらかじめモデル化し、各モデルの周波数特性から畳み込みカーネルを設計して、学習開始時の初期値とする。このとき、一般的な画像フィルタ(Low Pass Filter: LPF、High Pass Filter: HPF)をルールベースで組み合わせて、CNNの全ノードの畳み込みカーネルの重み係

図4 モデル化カーネル法によってハイパーパラメータを設計した「MK-CNN」

畳み込みニューラルネットワークの各層に求める機能をあらかじめモデル化し、各モデルの周波数特性から畳み込みカーネルを設計して、学習開始時の初期値とする。



数を学習前に仮設定しておく。このCNNのことをモデル化カーネル畳み込みニューラルネットワーク (MK-CNN) と呼び、以下、その概要を説明する (図4)。

2) 方法

肺がんCT検診で取得した画像 (3次元ボリュームデータ) には、病変の陰影だけでなく、病変と類似した形状の血管断面等の陰影も映る。したがって、病変の検出精度を向上するには、両者の形状を高精度で区別可能な特徴の学習が不可欠である。

そこで、MK-CNN (図4) の第1層では、検出対象である病変を検出する機能と、誤検出の原因となりやすい血管を検出する機能を、それぞれモデル化する。

まず、検出対象である病変の形状を単純化し、立方体を45°単位で面取りした26面体とみなしておく。この26面体の上側の境界では、xy方向は平面であるため画像の輝度値の変化は小さく、z方向は輝度値が急峻に変化する。したがって、xy方向の各LPFとz方向のHPFを組み合わせて3次元フィルタを設計し、その畳み込みカーネル (重み係数) をノードに仮設定する。

同様に、誤検出の原因となりやすい血管の形状を単純化し、z方向の円柱とみなしておく。この円柱の境界では、xy方向は輝度値が急峻に変化し、z方向は輝度値の変化は小さい。したがって、xy方向の2次元HPFとz方向のLPFを組み合わせた3次元フィルタを設計し、その畳み込みカーネルをノードに仮設定する。

これらのノードだけでは「26面体の上側の境界」と「z方向の円柱の境界」しか検出できないが、それぞれの畳み込みカーネルを3次元空間で幾何学的に回転すれば、任意方向の境界を検出できるようになる。そこで、境界の方向と同数 (26個) のノードを用意しておき、「上側の境界」を検出する畳み込みカーネルを、45°刻みで26通りに3次元回転して各ノードに仮設定し、26面体の病変の検出機能を実現する。また、血管 (円柱) の境界についても同様に回転する。なお、図4に示した各フィルタ (LPF、HPF) の特性と境界の方向数 (ノード数) は、MK-CNN全体の性能を見ながら調整する必要があるが、物理的な意味が明確なため容易に調整可能である。

第2層と第3層では、「境界をいろいろな方向に移動し、病変を検出しやすく、かつ血管を誤検出しにくくする機能」を

3次元フィルタでモデル化して畳み込みカーネルを求め、各ノードに仮設定する。このとき、第1層と第2層の間のネットワークを増やすことによって、前述のような単純化した形状だけでなく、多様な形状を持った病変や血管等を検出できるようになる。

第4層では、誤検出削減機能を3次元フィルタでモデル化し、畳み込みカーネルを仮設定する。

以上の手順で仮設定した全ノードのパラメータ (畳み込みカーネルと、「0」で初期化したバイアス) を、学習によって最適化する。すなわち、入力画像 (3次元ボリュームデータ) と、それと同じ画像サイズで、病変領域を「白」、正常領域を「黒」とした教師画像 (3次元マスクデータ) の組を多数用意しておき、MK-CNNの出力画像が教師画像とできるだけ一致するように、順伝播と逆伝播を反復しながら全ノードの畳み込みカーネルを更新していく。この更新を所定回数行って、最終的なMK-CNNパラメータを得る。

このように設計・学習したMK-CNNを用いることにより、病変と血管断面を精度よく区別できるようになる (図5)。

3) 結果

米国国立がんセンター (National Cancer Institute : NCI) がインターネット上で無償提供している胸部CT画像データベース (LIDC-IDRI データ)⁶⁾の中から、816症例の画像 (3次元ボリュームデータ) を学習し、それとは別の202症例の画像を評価データとして、MK-CNN単体で肺がん病変を検出する実験を行った結果、充実性結節病変の検出率は93.4%であった。

日立では、このMK-CNNと、含気性結節病変にフォーカスしたルールベース検出を融合したハイブリッドCADシステム (図3) を構築し、現在、読影精度や読影効率に関する有効性を定量的に評価するための臨床評価を実施中である。

2 撮像高速化を実現するMRI高画質化技術

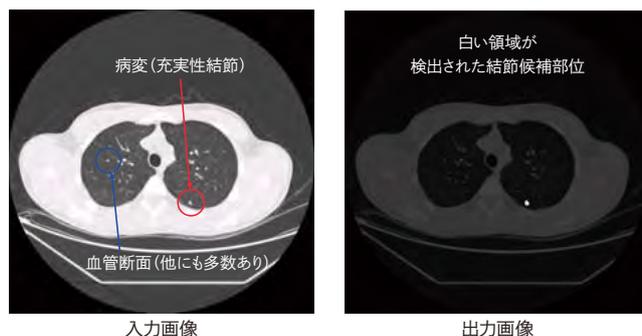
1) 背景と目的

MRI (Magnetic Resonance Imaging) 装置は放射線による被ばくがなくコントラストに優れることなどから、頭部をはじめさまざまな部位の診断に用いられているが、撮像に時間を要することが課題である。例えば、頭部のルーチン検査では15～25分程度を要し、腹部においては息止めの必要があるなど、被撮像者の負担も生じており、撮像時間の短縮が望まれている。MRIの撮像高速化に関しては、圧縮センシング⁷⁾が用いられつつあるが、繰り返し最適化処理による再構成時間や画質等の課題がある。近年、畳み込みニューラルネットワーク (CNN) をはじめとするDeep Learningを用いた画像処理技術が盛んに研究されており、画像認識分野だけでなく超解像技術⁸⁾やボケ除去、欠損復元⁹⁾¹⁰⁾など、画像処理への応用においても従来技術と比較して高い性能が報告されている。またCNNは多数の畳み込みフィルタで構成されており、繰り返し処理に比べ、並列計算による高速化が可能である。

本章では、撮像高速化をめざして、少数の計測データにより再構成された劣化MRI画像を、CNNを用いて高画質化した例¹¹⁾について紹介する。

図5 肺がんCADの入出力画像例

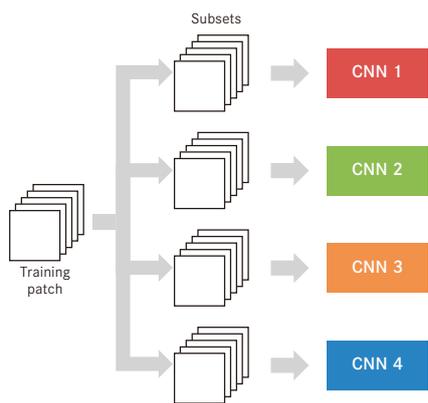
病変と血管断面は陰影の形状が類似しているため、病変の検出精度を向上するには、両者の形状を高精度で区別可能な特徴の学習が不可欠である。



画像引用: <http://doi.org/10.7937/K9/TCIA.2015.L09QL9SX>

図6 マルチアダプティブCNN再構成

(Multi-Adaptive Convolutional Neural Network Reconstruction : MA-CNNR)



2) 方法

CNNを用いた劣化画像の高画質化技術として、SRCNN (Super-Resolution Convolutional Neural Network) と呼ばれる超解像手法がある⁷⁾。SRCNNで利用されるネットワークはプーリング層を持たず、3つの畳み込み層のみで構成される。SRCNNの学習においては、元画像を教師データとし、元画像を縮小して生成した劣化画像を入力画像として学習を行う。パッチを切り出して学習することにより、データ拡張と学習時間の短縮を実現しており、従来手法であるスパースコーディングなどと比較しても高い精度が得られている。

MRI頭部画像には、脳、眼球、頭蓋骨、頸椎等、組成の異なるいくつかの部位が存在する。そのため、頭蓋骨周辺の高エッジ領域や、小脳をはじめとするテクスチャ様の構造物などの複合体として描出され、単一の高画質化ネットワークでは十分な高画質化を得ることは難しい。そこで今回、生体情報(組織の組成・構造等)とDeep Learningを融合して学習した、「マルチアダプティブCNN再構成」(Multi-Adaptive Convolutional Neural Network Reconstruction : MA-CNNR)を新たに開発した。MA-CNNRの概要を図6に示す。本手法では、

図7 使用したネットワーク構成

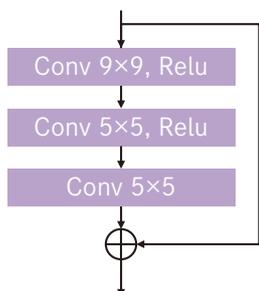
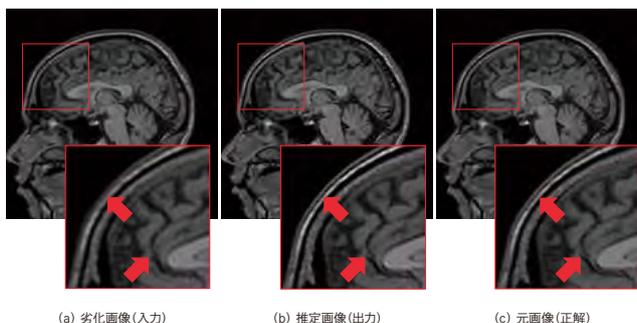


表1 各手法におけるPSNRの比較

Method	PSNR [dB]
3層CNN	32.8
3層CNN+Residual	33.8
MA-CNNR	35.1

図8 実験結果の例



生体情報を反映する輝度分布を利用して学習パッチをサブセットに分類し、サブセットごとにネットワークを学習することとした。入力画像の局所的な領域において最適なネットワークを利用することで、高画質化の精度を向上させることが可能である。なお、サブセットへの分類においては、教師無し学習であるクラスタリングを利用した。予測時には入力画像をタイル状に分割し、各タイルにおいて最適なネットワークを選択し推定する。

本検討で利用したネットワーク構造を図7に示す。3層CNNの最終層に、残差関数を学習するResidual構造を導入し精度向上を図っている。また、実験に際しては学習および評価用データセットとしてIXIdataset¹²⁾を利用した。入力となる劣化MRI画像として、撮像時間短縮を想定し、元画像をフーリエ変換した疑似的なk-spaceデータから25%のみをサンプリングした、4倍速相当の劣化画像を作成した。

3) 結果

表1に、評価用データ31枚における平均PSNR(Peak Signal-to-Noise Ratio : ピーク信号対雑音比)の比較結果を示す。MA-CNNRは、単一のネットワークを用いた場合に比べPSNRにおいて約1.3dBの改善が見られ、画質の向上が確認できた。これは画像をサブセットに分割したことで、各CNNに入力されるパッチの性質が類似し、推定問題が容易になったためであると考えられる。

図8に、MA-CNNRによる高画質化結果の例を示す。劣化画像と比べ、推定画像では微細な構造や微弱なエッジの復元が確認できる。本結果は、少数の計測データにより再構成された劣化MRI画像の画質を改善できる可能性を示しており、撮像の高速化につながることが期待される。

結語

Hybrid Learningのコンセプトに基づき開発した画像診断AI技術を2例紹介した。

長年培ってきた知識・知見とデータドリブンの手法を融合することにより、高精度化、高画質化に加え、学習の効率化を実現している。診療アウトカム向上へ向け、画像診断分野における本技術の適用範囲を拡大させるとともに、深化させていきたいと考える。

今後も日立では、医療現場の課題をデジタル技術で解決するソリューションの提供を進めていく。

参考文献

- 1) https://www.accessdata.fda.gov/cdrh_docs/pdf17/K170195.pdf
- 2) <https://www.fda.gov/newsevents/newsroom/pressannouncements/ucm604357.htm>
- 3) The National Lung Screening Trial Research Team : "Reduced lung-cancer mortality with low-dose computed tomographic screening", N. Eng. J. Med., 365, 395-409, 2011.
- 4) Kusano S, et al. : "Efficacy of computer-aided diagnosis in lung cancer screening with low-dose spiral computed tomography: receiver operating characteristic analysis of radiologists' performance", Jpn. J. Radiol, 28 (9), 649-655, 2010.
- 5) 影山昌広, ほか: "新しい畳み込みニューラルネットワーク設計法を用いた肺がんCT検診向け結節検出CADシステム", 第75回日本放射線技術学会総会学術大会, 2019
- 6) Armato III, Samuel G., McLennan, Geoffrey, Bidaut, Luc, McNitt-Gray, Michael F., Meyer, Charles R., Reeves, Anthony P., ... Clarke, Laurence P. (2015). Data From LIDC-IDRI. The Cancer Imaging Archive. <http://doi.org/10.7937/K9/TCIA.2015.LO9QL9SX>
- 7) D. L. Donoho : "Compressed sensing", IEEE Trans. Inf. Theory, vol.52, no.4, pp.1289-1306, April. 2006.
- 8) Chao Dong, et al. : "Learning a Deep Convolutional Network for Image Super-Resolution", ECCV, 2014.
- 9) Li Xu, et al. : "Deep Convolutional Neural Network for Image Deconvolution", NIPS, 2014
- 10) Jiwon Kim, et al. : "Accurate Image Super-Resolution Using Very Deep Convolutional Networks", arXiv: 1511.04587v1, 2015
- 11) 野口喜実, ほか : "クラスタリングを用いたCNN選択によるMRI高画質化の検討", JAMIT2018
- 12) IXI Dataset , brain-development.org, <http://brain-development.org/ixi-dataset/>