

## 臨床トピックス

# コンピューター支援診断および人工知能の 画像診断への応用と今後の課題

大野 良治\*

## 内容紹介

コンピューター支援診断(Computer-Aided Diagnosis: 以下 CAD) や人工知能(Artificial Intelligence: 以下 AI)を画像解析へ応用する目的は、病変の存在診断や質的診断を定量的に行い、その情報を放射線科医等に“セカンドオピニオン”として伝えることである。また、近年の肺癌 CT 検診におけるエビデンスの確立や 2022 年の診療報酬改定に伴う画像診断管理加算の施設基準に盛り込まれたことに伴い、日本医学放射線学会が認証した AI などの臨床現場での活用も広まりつつある。

本稿においては画像診断における CAD および AI の現状に関して述べるとともに、AI を活用した放射線診断学の将来展望に関して述べる。

## はじめに

CAD を画像解析へ応用する目的は、病変の存在診断や質的診断を定量的に行い、その情報を放射線科医等に“セカンドオピニオン”として伝えることである。また、近年の肺癌や大腸がんに対するコンピューター断層撮影(Computer Assisted

Tomography: 以下 CT) を活用した CT 検診におけるエビデンスの確立に伴い、CAD の CT 検診における活用の有効性も示唆されつつある。あわせて、近年の AI の急速な発展と普及に伴い CAD においても AI が活用されつつある。また、2022 年の診療報酬改定に伴う画像診断管理加算の施設基準に盛り込まれたことに伴い、日本医学放射線学会が認証した AI などの臨床現場での活用も広まりつつあり、臨床現場においても放射線診断医は日常的に CAD や AI を活用している。このような現状を踏まえて、藤田医科大学 医学部 放射線診断学と先端画像診断・人工知能共同研究講座においては国内外企業と CAD や AI の臨床実装に向けた産学連携研究を行い、薬機法承認や認証取得に至ることができた。更に、昨今の CT や核磁気共鳴(Magnetic Resonance Imaging: 以下 MRI) の画像再構成への応用も試みられ、医用画像機器メーカーとの新規人工知能応用再構成法の開発、臨床研究や臨床応用促進を行っている。

本稿においては画像診断における CAD および AI の現状に関して述べるとともに、AI を活用した放射線診断学の将来展望に関して述べる。

## 1. CAD と AI の差および臨床現場で活用可能な 主な AI ソフト

胸部放射線領域における CAD の歴史は長く、1963 年の胸部単純写真における画像所見の Coding に始まる<sup>1)</sup>。その後様々な技術開発がなされ発展を遂げてきが、1990 年代後半に米国

### —Key words—

コンピューター支援診断、人工知能

\* Yoshiharu Ohno: 藤田医科大学 医学部 放射線診断学 主任教授  
藤田医科大学 医学部 先端画像診断・人工知能共同研究講座  
講座長

の U.S. Food and Drug Administration がマンモグラフィーにおける CAD, 中央演算処理装置 (Central Processing Unit : CPU) の高速化により, CAD 開発と研究が進み, 論文発表数も増加した。一方で AIにおいては第3次 AI ブームによる Deep Learning などの臨床応用は大量のデータを処理するために高い計算能力を必要とする。したがって, 1つのタスクを順番に処理する通常の CPU では, 大量データを処理するのに時間がかかるので, 3D グラフィックスなどの画像描写を行う際に必要となる計算処理を行う半導体チップ (プロセッサ) の一種である画像処理装置 (Graphics Processing Unit : GPU) を使用することで大量のデータを様々な並列処理し, 高速化を可能にするとともに精度向上を図っている。そのため, 2000 年代後半からは CAD の論文数に比して Machine Learning や Deep Learning などを用いた AI の論文数が画像診断領域を中心に指数関数的に増加し, その代表的領域は病理学と放射線診断学である<sup>2,3)</sup>。

一般に CAD は Computer-Aided Detection (CADe), Computer-Aided Diagnosis (CADx) および Computer-Aided Volumetry (CADv) に大別され, 近年では臨床医にとっての “セカンドオピニオン” であり, 臨床医にとって相補的であることが求められ, 臨床医の能力を凌駕する必要はないとしている<sup>4)</sup>。しかし, 機械学習 (Machine Learning) の一種である深層学習 (Deep Learning) の父とされ, 2024 年にノーベル物理学賞を受賞されたカナダ・トロント大学の Geoffrey Hinton 教授は 2016 年に, 「今後 5 年間で放射線科医の仕事はすべて Deep Learning に置き換わってしまうため, 放射線科医の育成はやめるべきだ」と発言されている。また, カナダ放射線科医協会の AI ワーキンググループ等は AI を「知的な人間の行動を模倣できる装置」と規定しており, CADe, CADx および Computer-Aided Triage (CAT) あるいは Computer-Aided Simple Triage (CAST) とは異なるとしている<sup>5)</sup>。しかし, 放射線診断領域における AI と CAD において, その臨床目的および効能に明確な差はなく, 放射線科医の適切な評価と

管理下に置いて “セカンドオピニオン” として適切に使用されることを目的に臨床応用されていることから, CAD と AI は一般臨床において明確に分けられるべきものではなく, CAD の精度向上に AI 手法が活用されている。したがって, 画像工学的観点から CAD と AI を分けた場合には図 1 のように定義するとよいと考える。そして, CAD と AI はほぼ同義語として用いられていると考える。

現在, 臨床現場で活用可能な AI に関しては 2024 年度診療報酬改定で画像診断管理加算 3, 4 の施設基準に「関係学会の定める指針に基づいて, 人工知能関連技術が活用された画像診断補助ソフトウェアの適切な安全管理を行っていること。」ほかが要件とされたことにより, 日本医学放射線学会画像診断管理認証制度による認証がされた AI ソフトウェアが臨床現場で活用し, 画像診断管理加算 3 および 4 を取得した施設において診療報酬の算定に寄与することができる。しかし, これらの AI ソフトは市販されていることから, 診療報酬の算定に寄与しなくとも臨床現場でその他の施設でも臨床導入することは可能である。

表 1 に 2025 年 9 月末時点で認証されている AI ソフトの一覧を示す。

## 2. 臨床現場および低線量 CT 肺癌検診で活用される CAD と AI の活用と課題

表 1 で示されるように CAD や AI が最も盛んに応用・研究されている診断部位は胸部放射線医学領域である。また, 低線量 CT の肺癌検診における有用性に関しては欧米の Randomized Control Trial (RCT) により明らかになりつつあるが, 過去の様々な研究ではその有用性が示唆されたものと示唆されなかったものもある<sup>6,8)</sup>。の中でも CADv を肺結節のマネジメントに使用して成果を上げたものもあり<sup>7,8)</sup>, 本邦でも低線量 CT 肺癌検診の導入が議論される中で, CAD や AI は低線量 CT 肺癌検診での適切な活用は推奨されると考えられる。

通常線量および低線量 CT における CADe の性能を, 医師と CAD の肺結節検出能などの対比

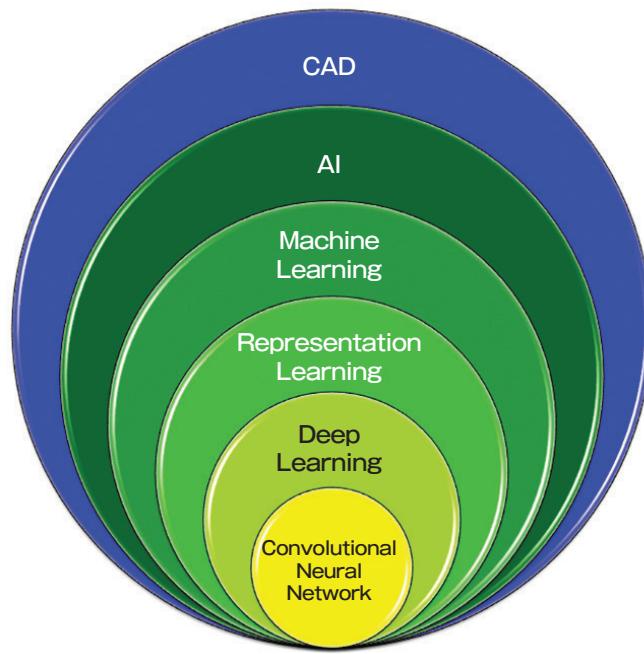


図1 CADとAIにおける各手法の関係に関する模式図

AIはCADの一種と考えられ、AIにおける一手法である機械学習(Machine Learning)には表現学習(Representation Learning)や深層学習(Deep Learning)などの手法があり、昨今流行りの畳み込みニューラルネットワーク(Convolutional Neural Network)はDeep Learningの一手法である。

などを行い、その有用性を示した研究は多く報告されている。その結節検出能評価結果は様々であり、多くの臨床研究では既存のデータベースを用いた評価であり、被曝線量や再構成法による影響などを評価した論文は少ない<sup>9-15)</sup>。我々は逐次近似応用再構成法(Hybrid-Type Iterative Reconstruction: 以下 Hybrid-Type IR)と従来使用されてきたフィルター補正逆投影法(Filtered Back Projection: 以下 FBP)を用いて、通常線量、低線量および超低線量CTにおける肺結節検出能をCADeにて比較し、Hybrid-Type IRを用いることでFBPのように線量低減にともなう肺結節検出能の低下を回避できることを明らかにした<sup>13)</sup>。

CTにおけるX線被曝低減技術は管電流や管電圧およびビームピッチなどを変化させて低線量化を図るのが一般的であるが、現在では逐次近似再構成法(Model-Based Iterative Reconstruction: 以

下MBIR)や深層学習応用再構成法(Deep Learning Reconstruction: 以下 DLR)などの最新画像再構成法や通常の銅製X線スペクトラム変調フィルター(Copper X-Ray Spectrum Modulation Filter: Cu Filter)に加えて錫製や銀製X線スペクトラム変調フィルター(Tin or Silver X-Ray Spectrum Modulation Filter: Tin Filter or Ag Filter)などが現在臨床応用されている<sup>16-24)</sup>。したがって、今後はこれらのX線被曝低減技術を応用した通常線量および低線量CT肺癌検診においてより良い性能を示すことができるようCADeの性能向上を図ることも肝要である。

一方、CADvに関しては北米放射線学会(Radiological Society of North America: 以下 RSNA)のQuantitative Imaging Biomarker Alliance(以下 QIBA)が各企業や大学および研究機関より提案されているアルゴリズムを評価するためにQIBA 3A Public Challengingを行ったこ

表1 日本医学放射線学会画像診断管理認証制度による認証 AI ソフトウェア

No.	AI 製造販売会社	AI ソフト名	承認・認証番号
1	エルピクセル株式会社	医用画像解析ソフトウェア EIRL aneurysm	承認番号：30100BZX00142000
2	エルピクセル株式会社	医用画像解析ソフトウェア EIRL X-Ray Lungodule	承認番号：30200BZX00269000
3	キヤノンメディカルシステムズ株式会社	COVID-19 肺炎解析ソフトウェア SCO-PA01	承認番号：30400BZX00123000
4	コニカミノルタ株式会社	画像診断支援ソフトウェア KDSS-CXR-AI-101	承認番号：30300BZX00271000
5	シーメンスヘルスケア株式会社	AI-Rad コンパニオン	承認番号：30200BZX00202000
6	富士フィルム株式会社	類似画像症例検索ソフトウェア FS-CM687 型	承認番号：30100BZX00263000
7	富士フィルム株式会社	肺結節検出プログラム FS-AI688 型	承認番号：30200BZX00150000
8	富士フィルム株式会社	COVID-19 肺炎画像解析プログラム FS-AI693 型	承認番号：30300BZX00145000
9	富士フィルム株式会社	胸部 X 線画像病変検出(CAD)プログラム LU-AI689 型	承認番号：30300BZX00188000
10	富士フィルム株式会社	肋骨骨折検出プログラム FS-AI691 型	承認番号：30300BZX00244000
11	シーメンスヘルスケア株式会社	AI-Rad コンパニオン CT	認証番号：302AABZX00047000
12	シーメンスヘルスケア株式会社	AI-Rad コンパニオン MR	認証番号：302AABZX00092000
13	日本メジフィジックス株式会社	核医学画像解析ソフトウェア VSBONE BSI	認証番号：301ADBZX00029000
14	プラスマン合同会社	Plus.lung.Nodule プラスラングノジユール	認証番号：301AGBZX00004000
15	エルピクセル株式会社	医用画像解析ソフトウェア EIRL Chest XR	承認番号：30400BZX00285000
16	シーメンスヘルスケア株式会社	肺結節検出プログラム syngo.CT Lung CAD	承認番号：30500BZX00032000
17	株式会社東陽テクニカ	胸部 CT 読影支援システム ClearRead CT+DC	認証番号：303ADBZX00098000
18	キヤノンメディカルシステムズ株式会社	汎用画像診断ワークステーション用プログラム Abierto SCAI - 1AP (AI 機能オプション付)	認証番号：302ABBZX00004000
19	株式会社東陽テクニカ	胸部 X 線骨組織透過処理システム ClearRead XR	認証番号：303ADBZX00013000
20	Qure 株式会社	VUNO Med®-LungCT ビューノメドラングシーティー	認証番号：301AGBZI00003000
21	エルピクセル株式会社	医用画像解析ソフトウェア EIRL Brain Segmentation	認証番号：303AGBZX00043Z00
22	エルピクセル株式会社	医用画像解析ソフトウェア EIRL Brain Metry	認証番号：230AGBZX00107Z00
23	エルピクセル株式会社	医用画像解析ソフトウェア EIRL Chest CT	認証番号：304AGBZX00037Z00
24	株式会社メディカルブリッジ	汎用画像診断装置ワークステーション用プログラム A ビュー	認証番号：302AGBZI00005000
25	株式会社ダブリューエスエム	MR 装置ワークステーション用プログラム Neurophet AQUA アクア	認証番号：304AHBZI00007000
26	P D R ファーマ株式会社	汎用画像診断装置ワークステーション用プログラム ボンナビ® BSI	認証番号：227ADBZX00091000
27	P D R ファーマ株式会社	汎用画像診断装置ワークステーション用プログラム カーディオレボ®	認証番号：227ADBZX00090000
28	株式会社ドクターネット	胸部 X 線肺炎検出エンジン DoctorNet JLK-CRP	承認番号：30300BZX00339000
29	株式会社ダブリューエスエム	汎用画像診断装置ワークステーション用プログラム Neurophet SCALE PET スケール ベット	認証番号：304AHBZI00035000
30	富士通 Japan 株式会社	HOPE LifeMark-CAD 肺炎画像解析支援プログラム for COVID-19	承認番号：30300BZX00350000
31	キヤノンメディカルシステムズ株式会社	汎用画像診断ワークステーション用プログラム Abierto Vision AVP-001A	認証番号：22000BZX00379000
32	株式会社ダブリューエスエム	汎用画像診断装置ワークステーション用プログラム Neurophet AQUA AD アクア エイディー	認証番号：307AHBZI00001000
33	株式会社ドクターネット	汎用画像診断装置ワークステーション用プログラム 胸部 CT 画像解析 AI エンジン DoctorNET MONCAD CTLN	認証番号：307AGBZX00003000
34	エルピクセル株式会社	X 線画像診断装置ワークステーション用プログラム 医用画像解析ソフトウェア EIRL Chest CT2	承認番号：30700BZX00064000
35	GE ヘルスケア・ジャパン株式会社	汎用画像診断装置ワークステーション AW サーバー	認証番号：22200BZX00295000
36	Qure 株式会社	X 線画像診断装置ワークステーション用プログラム VUNO Med-CXR アシスト	認証番号：307AGBZI00005000
37	ザイオソフト株式会社	汎用画像診断装置ワークステーションザイオステーション レヴォラス R L	認証番号：304ABBZX00001000
38	富士通 Japan 株式会社	X 線画像診断装置ワークステーション用プログラム HOPE LIFE MARK -類似画像症例検索支援システム for びまん性肺疾患	承認番号：30700BZX00127000
39	アドバンスジャパン株式会社	汎用画像診断装置ワークステーション用プログラム 脳 NCCT 画像診断プログラム JLK-NCCT	認証番号：307AGBZI00001000

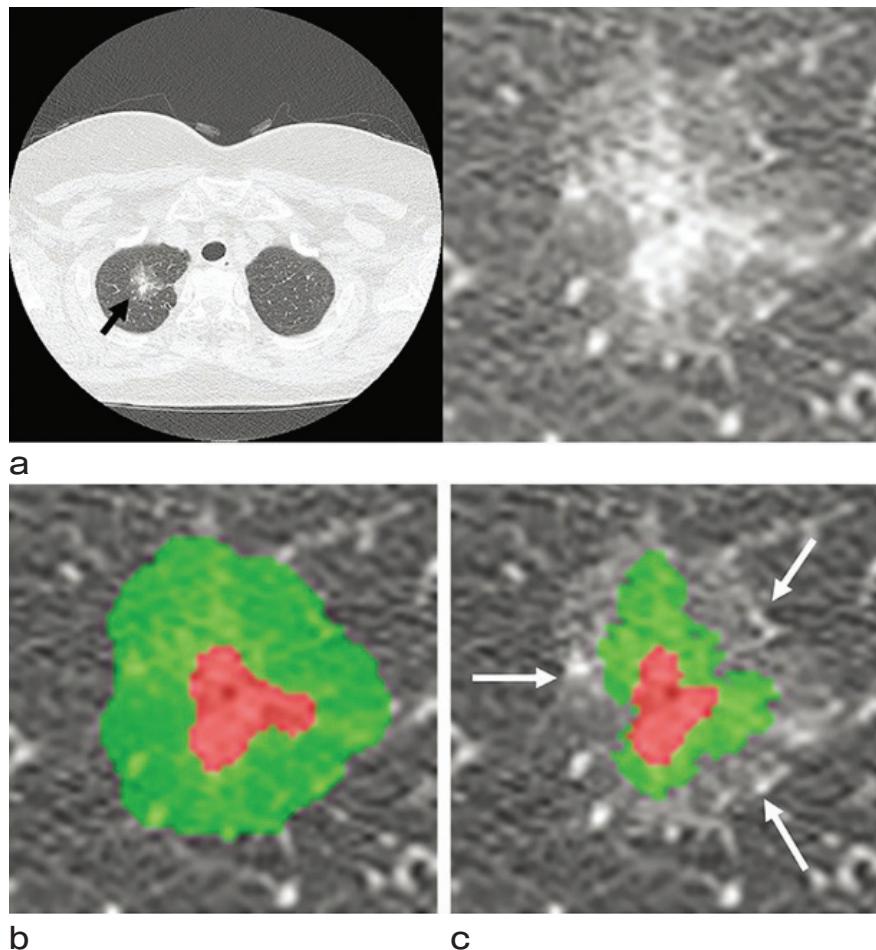


図2 70歳 Invasive adenocarcinoma患者 CT 画像(a) および convolutional neural network (CNN)併用(b) および非併用(c) CADv 解析結果(参考文献 28 より許可を得て転載)

(a)右上葉に art-solid nodule (arrow) が認められる。(b) CNN 併用 CADv では GGO 部分をピンク、充実部分を緑で区分している。1日当たりの全肺結節容積変化は  $4.65 \text{ mm}^3 \text{ per day}$  であり、倍加時間は 75 日と求められた。(c) CNN 非併用 CADv でも GGO 部分をピンク、充実部分を緑で区分したが、1日当たりの全肺結節容積変化は  $2.87 \text{ mm}^3 \text{ per day}$  であり、倍加時間は 167 日と求められた。両手法とも本結節を悪性結節と診断した。

とで、共通の肺結節ファントムで性能評価を行わされた<sup>25)</sup>。そのため、継続的なアルゴリズムの改良および改善が可能になった。また、同ファントムを使用することで被曝線量のみならず再構成法による CADv における各種肺結節の体積測定における影響などを評価することも可能になった<sup>26)</sup>。また、最近では肺結節における成分分析や評価を可能にする CADv、CADx や AI なども報告されており、肺腺癌浸潤度評価や予後予測などにおける有用性も明らかになりつつある(図2)<sup>26,30)</sup>。今

後は CADe と同様に各種被曝低減技術や再構成法による低線量 CT への対応を行うことが必要である。

### 3. 呼吸器疾患を対象にした CAD および AI の開発と臨床応用

現在、CT における CAD や AI の開発及び臨床応用研究は、主に肺結節を中心とした悪性腫瘍の検出、診断や経過観察を目的に行われている。しかし、現在の呼吸器診断において肺癌は依然

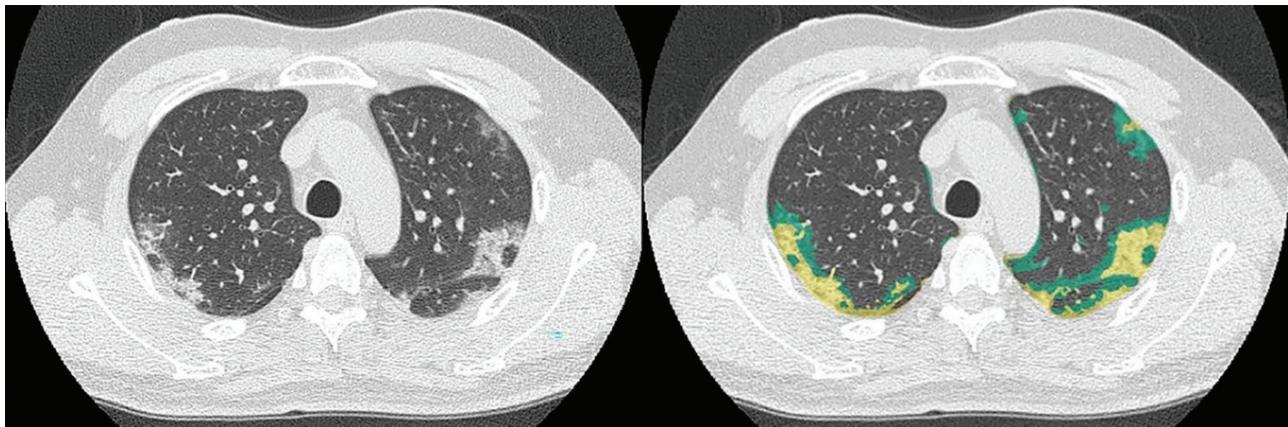


図3 46歳男性PCRにて診断されたCOVID-19肺炎(L to R: 薄層CTおよびCAST解析結果) (参考文献35より許可を得て転載) (表1No.3のソフトは本ソフトの機能制限された簡易版)

薄層CTにおいてすりガラス影やcrazy-paving patternに分類される網状影が両側肺末梢を中心に認められる。CASTソフトではすりガラス影は緑色、網状影は黄色に分類されている。本症例はPCR検査にてCOVID-19肺炎陽性と診断されているが、CASTソフトおよび全胸部放射線診断専門医によってもCOVID-19肺炎陽性と診断され、真陽性症例である。

として重要な位置を占めているものの、肺気腫などの慢性閉塞性肺疾患(Chronic Obstructive Pulmonary Disease: 以下 COPD)、欧米では特に関心の高い肺血栓塞栓症および読影者間一致率が低く、重症度評価が難しいびまん性肺疾患などの間質性肺炎(Interstitial Lung Disease: 以下 ILD)の評価を行うためのCT Texture解析などを行い、定量的病変検出、診断、重症度評価や治療効果判定を行うためのCADやAIの開発が急務となりつつあり、その臨床応用研究成果報告が増加しつつある<sup>31-40)</sup>。そこで、我々はキヤノンメディカルシステムズ株式会社との産学連携共同研究として、CT Texture解析アルゴリズムを応用した肺疾患用AIを開発し、びまん性肺疾患などのILDの読影一致率向上、定量的治療効果判定や新規薬剤の臨床治験成績評価の精度向上などへの応用に関して臨床研究を行い、臨床実装を目指している<sup>33-35)</sup>。そして、2020年以降世界的に蔓延したCOVID-19肺炎を対象にCOVID-19肺炎疑いとして要精査と精査不要を判断するCASTアルゴリズムを開発し、薬機法承認を得て臨床実装も行った(図3)<sup>36)</sup>。今後も様々な臨床ニーズを的確にとらえて、新たなCADおよびAI開発を行う予定である。

#### 4. AIを活用した放射線医学への新たな挑戦

従来、CADやAIは主に画像診断を行う医師を補助する“セカンドオピニオン”を提示する装置として開発、臨床応用研究および臨床実装が図られてきた。しかし、2019年以降、AIはCTやMRIにおける新たな画像再構成法として臨床応用されている。表2および表3に主な医用画像機器メーカーより臨床実装されているCTおよびMRI用の人工知能応用画像再構成法を示す。これらの人工知能応用再構成法は主にDLRの手法を使用しており、様々な領域におけるCTおよびMRI画像の画像ノイズ低減することにより画質改善を図っており、その臨床的有用性は種々の画像取得技術と合わせて評価され、明らかにされてきた(図4)<sup>41-57)</sup>。そして、2023年以降は従来のDLRとは異なり、従来のマルチスライスCTやMRI撮像法で取得したCTおよびMRI画像の空間分解能を通常の $512 \times 512$ マトリックスから高精細あるいは超高精細画像である $1024-2048 \times 1024-2048$ マトリックスに変換するDLRの臨床応用も進められている。本DLRを使用することにより、現在臨床現場で使用されている通常CTやMRI装置にて得た画像をより高価な最新の量子計測型検出器CT(Photon-Counting CT)や高精細

表2 市販あるいは臨床実装されているCTにおける人工知能応用再構成法

アルゴリズム名	提供企業	アルゴリズムの種類	教育に採用した画像種
AiCE	Canon Medical Systems	DLR	MBIRにて再構成されたCT画像
TrueFidelity	GE Healthcare	DLR	FBPにて再構成されたCT画像
Precise Image	Philips Healthcare	DLR	FBPにて再構成されたCT画像
PixelShine	AlgoMedica	DLD	FBP, Hybrid-type IR, MBIRにて再構成されたCT画像
ClariCT.AI	ClariPi	DLD	FBPにて再構成されたCT画像

AiCE: Advanced Intelligent Clear-IQ Engine, DLR: deep learning reconstruction, MBIR: model-based iterative reconstruction, FBP: filtered back projection, DLD: deep learning-based denoiser, IR: iterative reconstruction

表3 市販あるいは臨床実装されているMRIにおける人工知能応用再構成法

アルゴリズム名	提供企業	アルゴリズムの種類	アルゴリズムの適応目的	
AiCE	Canon Medical Systems	DLR	ノイズ低減	
AIR Recon DL	GE Healthcare	DLR	ノイズ低減および画像先鋭化	
SmartSpeed AI	Philips Healthcare	DLR & IR (Hybrid DL-IR)	画像再構成及びノイズ低減	
Deep Resolve	Deep Resolve Gain	Siemens Healthineers	DLR	ノイズ低減
	Deep Resolve Sharp		CNN	空間分解能改善
	Deep Resolve Boost		DNN	撮像時間短縮
Synergy DLR	Fuji Film	DNN	ノイズ低減	
uAI FI DeepRecon	United Imaging Healthcare	CNN	ノイズ低減および画像先鋭化	

DLR: deep learning reconstruction, IR: iterative reconstruction, DL-IR: deep learning and iterative reconstruction, CNN: convolutional neural network, DNN: deep neural network

CT (High-Definition CT) および最新の3テスラ (Tesla: 以下 T) MRI 装置にて得られる高精細画像に再構成技術のみで変換し、診断能の向上などに寄与することも可能になりつつある(図5)<sup>58-60</sup>。したがって、本研究領域は放射線診断学領域および医用画像工学領域におけるAIの新たな可能性を示すものといつても過言はないと考える。

## おわりに

画像診断におけるCADおよびAIの現状に関して述べた。あわせて、AIを活用した放射線診

断学の将来展望に関して我々のこれまでの研究成果と文献的考察を加えて述べた。CADやAIはコンピューターを用いた病変の存在診断や質的診断を定量的に行い、その情報を放射線科医等の画像診断を行う医師に診断能向上を目的に“セカンドオピニオン”として伝えることを主目的に開発および臨床応用が進められている。したがって、これらのCADやAIが更に進歩して高い信頼性を勝ち得た“セカンドオピニオン”になりえた時に、日常臨床読影のワークフローの改善と精度向上に大きく寄与すると考える。また、現在進行形の問

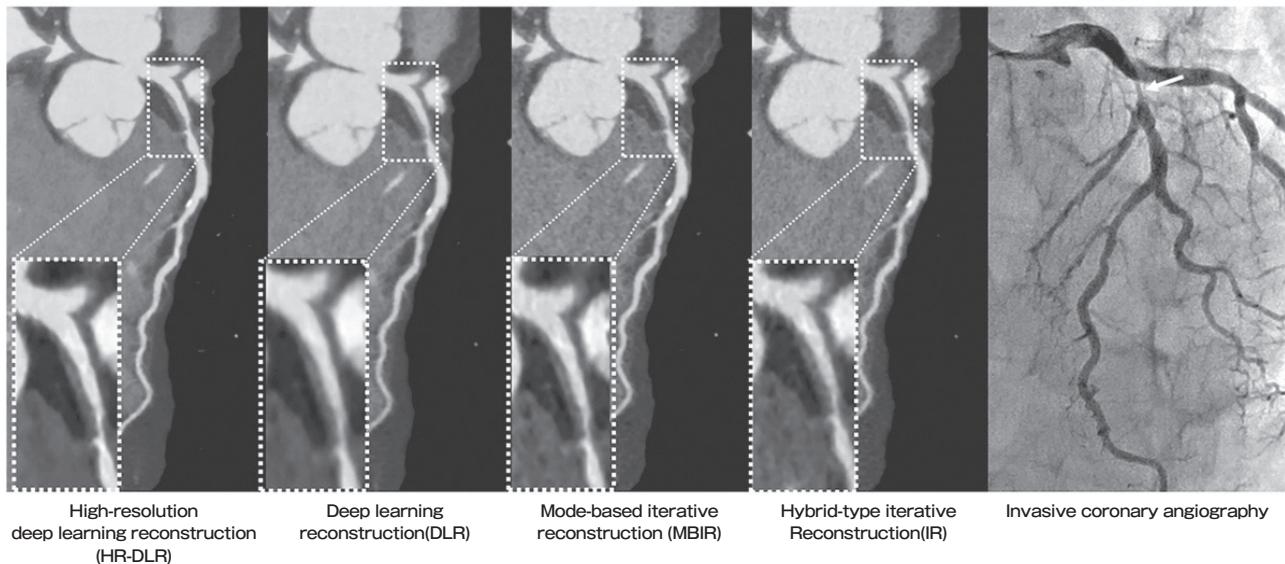


図4 虚血性心疾患者の各種再構成法にて再構成された冠動脈 CT 血管造影(CT Angiography: 以下 CTA)と侵襲的冠動脈造影の比較(左から右: 高精細深層学習応用再構成法 [High-Resolution Deep Learning Reconstruction: 以下 HR-DLR], DLR, MBIR, および Hybrid-Type IR にて再構成された CTA 画像および侵襲的冠動脈造影) (参考文献 59 より許可を得て転載)

HR-DLR で再構成された CTA の画質は他再構成よりも優れているが、冠動脈の狭窄度評価における CAD-RADS 分類は明らかな差は認めず、狭窄度は侵襲的冠動脈造影の評価と一致した。

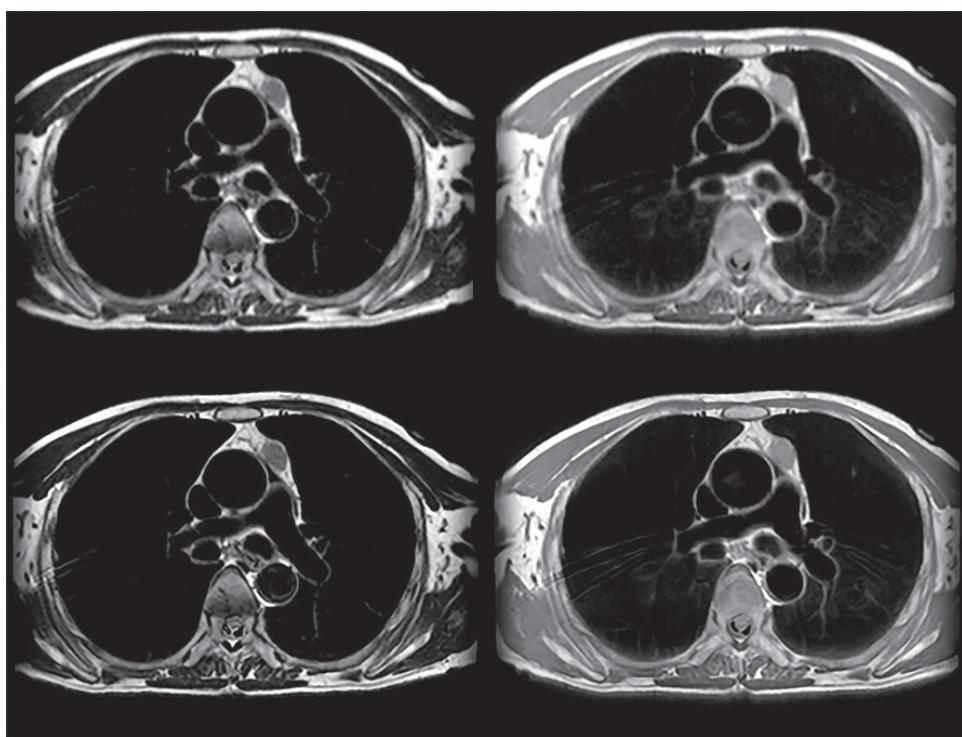


図5 48歳 男性 胸腺上皮性腫瘍(WHO type A) (参考文献 57 より許可を得て転載)

(上段、左から右: Fast Spin-Echo [FSE] 法にて撮像し、通常の再構成法を用いて 192 × 256 マトリックスで再構成を行った T2 強調像および T1 強調像。下段、左から右: FSE 法にて撮像し、高精細深層学習応用再構成法である PIQE を用いて、撮像時間の延長なく 768 × 768 マトリックスで再構成を行った T2 強調像および T1 強調像)

撮像データは同じであるが、キヤノンメディカルシステムズ社製高精細深層学習応用再構成法である Precise IQ Engine (PIQE) を用いて再構成を行うことにより、撮像時間延長などを著明な画質改善を行い、胸腺腫や正常解剖の描出能を向上することが可能である。

質性肺炎や慢性閉塞性肺疾患などの肺癌以外の肺疾患を対象としたCT Texture 解析を応用したAIアルゴリズムは、従来の“セカンドオピニオン”としてのみならず、医師による治療効果評価や治験の中央判定に比してより正確な治療効果予測や予後予測を可能にすることができると考えられ、より良い患者マネージメントに寄与するものと考えられる。

あわせて、最新のAIを活用した様々な人工知能応用再構成法による日常臨床CTおよびMRIの画質改善は適切な医療資源により良い医療を患者や国民に提供することを可能にするものと考えられ、我々放射線診断専門医および産学共同研究に携わる研究者の責務はより一層大きくなるものと考える。本稿が放射線診断医のみならず、画像診断に携わる様々な診療科医師などの医療従事者のより良いCADおよびAIに関する現状とその将来展望に関する理解に役立ち、より良い医療の提供と医師のワークライフバランスの改善などを目的としたCADやAIを積極的な臨床現場での活用につながれば幸いと考える。

### 利益相反

筆者はキヤノンメディカルシステムズ株式会社、LPIXEL株式会社およびCoreline Soft株式会社より共同研究費を得ています。また、筆者は喫煙科学研究財団より研究助成を得ています。

### 文献

- 1) Lodwick GS, et al : The coding of roentgen images for computer analysis as applied to lung cancer. *Radiology*. 1963 ; 81 : 185-200.
- 2) Giger ML : Machine learning in medical imaging. *J Am Coll Radiol*. 2018 ; 15(3 Pt B) : 512-520.
- 3) Meskó B, et al : A short guide for medical professionals in the era of artificial intelligence. *NPJ Digit Med*. 2020 ; 3 : 126.
- 4) Katsuragawa S, et al : Computer-aided diagnosis in chest radiography. *Comput Med Imaging Graph*. 2007 ; 31 : 212-223.
- 5) Tang A, et al : Canadian association of radiologists white paper on artificial intelligence in radiology. *Can Assoc Radiol J*. 2018 ; 69 : 120-135.
- 6) National Lung Screening Trial Research Team : Reduced lung-cancer mortality with low-dose computed tomographic screening. *N Engl J Med*. 2011 ; 365 : 395-409.
- 7) de Koning HJ, et al : Reduced lung-cancer mortality with volume CT screening in a randomized trial. *N Engl J Med*. 2020 ; 382 : 503-513.
- 8) Adams SJ, et al : Lung cancer screening. *Lancet*. 2023 ; 401 : 390-408.
- 9) Al Mohammad B, et al : A review of lung cancer screening and the role of computer-aided detection. *Clin Radiol*. 2017 ; 72 : 433-442.
- 10) Ohno Y, et al : Pulmonary functional imaging : Part 1-state-of-the-art technical and physiologic underpinnings. *Radiology*. 2021 ; 299 : 508-523.
- 11) Prosper AE, et al : Expanding role of advanced image analysis in CT-detected indeterminate pulmonary nodules and early lung cancer characterization. *Radiology*. 2023 ; 309(1) : e222904.
- 12) Yuan R, et al : Computer-aided detection in screening CT for pulmonary nodules. *AJR Am J Roentgenol*. 2006 ; 186 : 1280-1287.
- 13) Ohno Y, et al : Comparison of computer-aided detection (CADe) capability for pulmonary nodules among standard-, reduced- and ultra-low-dose CTs with and without hybrid type iterative reconstruction technique. *Eur J Radiol*. 2018 ; 100 : 49-57.
- 14) Revel MP, et al : Lung CAncer SCreening in French women using low-dose CT and Artificial intelligence for DEtection : the CASCADE study protocol. *BMJ Open*. 2022 ; 12 : e067263.
- 15) Adams SJ, et al : Artificial intelligence and machine learning in lung cancer screening. *Thorac Surg Clin*. 2023 ; 33 : 401-409.
- 16) Kubo T, et al : Radiation dose reduction in chest CT : a review. *AJR Am J Roentgenol*. 2008 ; 190 : 335-343.
- 17) Kubo T, Et al : Use of 3D adaptive raw-data filter in CT of the lung : effect on radiation dose reduction. *AJR Am J Roentgenol*. 2008 ; 191 : 1071.
- 18) Matsumoto K, et al : 3D automatic exposure control for 64-detector row CT : radiation dose reduction in chest phantom study. *Eur J Radiol*. 201 ; 77 : 522-527.
- 19) Ohno Y, et al : Adaptive iterative dose reduction using 3D processing for reduced- and low-dose pulmonary CT : comparison with standard-dose CT for image noise reduction and radiological findings. *AJR Am J Roentgenol*. 2012 ; 199 : W477-485.
- 20) Weis M, et al : Radiation dose comparison between 70 kVp and 100 kVp with spectral beam shaping for non-contrast-enhanced pediatric chest computed tomography : A prospective randomized controlled study. *Invest Radiol*. 2017 ; 52 : 155-162.

21) Ohno Y, et al : Radiation dose reduction techniques for chest CT : Principles and clinical results. *Eur J Radiol.* 2019 ; 111 : 93-103.

22) Ohno Y, et al : Effects of acquisition method and reconstruction algorithm for CT number measurement on standard-dose CT and reduced-dose CT : a QIBA phantom study. *Jpn J Radiol.* 2019 ; 37 : 399-411.

23) Oshima Y, et al : Capability for dose reduction while maintaining nodule detection : Comparison of silver and copper X-ray spectrum modulation filters for chest CT using a phantom study with different reconstruction methods. *Eur J Radiol.* 2023 ; 166 : 110969.

24) Hamabuchi N, et al : Effectiveness of deep learning reconstruction on standard to ultra-low-dose high-definition chest CT images. *Jpn J Radiol.* 2023 ; 41 : 1373-1388.

25) Athelogou M, et al : Algorithm variability in the estimation of lung nodule volume from phantom CT scans : Results of the QIBA 3A public challenge. *Acad Radiol.* 2016 ; 23 : 940-952.

26) Ohno Y, et al : Comparative evaluation of newly developed model-based and commercially available hybrid-type iterative reconstruction methods and filter back projection method in terms of accuracy of computer-aided volumetry (CADv) for low-dose CT protocols in phantom study. *Eur J Radiol.* 2016 ; 85 : 1375-1382.

27) Kamiya S, et al : Computer-aided volumetry of part-solid lung cancers by using CT : Solid component size predicts prognosis. *Radiology.* 2018 ; 287 : 1030-1040.

28) Ohno Y, et al : Differentiation of benign from malignant pulmonary nodules by using a convolutional neural network to determine volume change at chest CT. *Radiology.* 2020 ; 296 : 432-443.

29) Saied M, et al : Efficient pulmonary nodules classification using radiomics and different artificial intelligence strategies. *Insights Imaging.* 2023 ; 14 : 91.

30) Sun J, et al : Deep learning-based solid component measuring enabled interpretable prediction of tumor invasiveness for lung adenocarcinoma. *Lung Cancer.* 2023 ; 186 : 107392

31) Iwasawa T, et al : Computer-aided quantification of pulmonary fibrosis in patients with lung cancer : Relationship to disease-free survival. *Radiology.* 2019 ; 292 : 489-498.

32) Ma G, et al : Influence of monoenergetic images at different energy levels in dual-energy spectral CT on the accuracy of computer-aided detection for pulmonary embolism. *Acad Radiol.* 2019 ; 26 : 967-973.

33) Ohno Y, et al : Machine learning for lung CT texture analysis : Improvement of inter-observer agreement for radiological finding classification in patients with pulmonary diseases. *Eur J Radiol.* 2021 ; 134 : 109410.

34) Ohno Y, et al : Machine learning for lung texture analysis on thin-section CT : Capability for assessments of disease severity and therapeutic effect for connective tissue disease patients in comparison with expert panel evaluations. *Acta Radiol.* 2022 ; 63 : 1363-1373.

35) Ohno Y, et al : Newly developed artificial intelligence algorithm for COVID-19 pneumonia : utility of quantitative CT texture analysis for prediction of favipiravir treatment effect. *Jpn J Radiol.* 2022 ; 40 : 800-813.

36) Ohno Y, et al : Machine learning-based computer-aided simple triage (CAST) for COVID-19 pneumonia as compared with triage by board-certified chest radiologists. *Jpn J Radiol.* 2024 ; 42 : 276-290.

37) Langius-Wiffen E, et al : Added value of an artificial intelligence algorithm in reducing the number of missed incidental acute pulmonary embolism in routine portal venous phase chest CT. *Eur Radiol.* 2024 ; 34 : 367-373.

38) Shiraishi Y, et al : Longitudinal assessment of interstitial lung abnormalities on CT in patients with COPD using artificial intelligence-based segmentation : a prospective observational study. *BMC Pulm Med.* 2024 ; 24 : 200.

39) Savage CH, et al : Prospective evaluation of artificial intelligence triage of incidental pulmonary emboli on contrast-enhanced CT examinations of the chest or abdomen. *AJR Am J Roentgenol.* 2024 ; 223 : e2431067.

40) Oosawa A, et al : Deep-learning-based 3D content-based image retrieval system on chest HRCT : Performance assessment for interstitial lung diseases and usual interstitial pneumonia. *Eur J Radiol Open.* 2025 ; 15 : 100670

41) Nakamura Y, et al : Deep learning-based CT image reconstruction : Initial evaluation targeting hypovascular hepatic metastases. *Radiol Artif Intell.* 2019 ; 1 : e180011.

42) Tian SF, et al : Potential value of the PixelShine deep learning algorithm for increasing quality of 70 kVp+ASiR-V reconstruction pelvic arterial phase CT images. *Jpn J Radiol.* 2019 ; 37 : 186-190.

43) Choe J, et al : Deep learning-based image conversion of CT reconstruction kernels improves radiomics reproducibility for pulmonary nodules or masses. *Radiology.* 2019 ; 292 : 365-373.

44) Hata A, et al : Combination of deep learning-based

denoising and iterative reconstruction for ultra-low-dose CT of the chest : Image quality and lung-RADS evaluation. *AJR Am J Roentgenol.* 2020 ; 215 : 1321-1328.

45) Bak SH, et al : Emphysema quantification using low-dose computed tomography with deep learning-based kernel conversion comparison. *Eur Radiol.* 2020 ; 30 : 6779-6787.

46) Matsukiyo R, et al : Deep learning-based and hybrid-type iterative reconstructions for CT : comparison of capability for quantitative and qualitative image quality improvements and small vessel evaluation at dynamic CE-abdominal CT with ultra-high and standard resolutions. *Jpn J Radiol.* 2021 ; 39 : 186-197.

47) Nam JG, et al : Image quality of ultralow-dose chest CT using deep learning techniques : potential superiority of vendor-agnostic post-processing over vendor-specific techniques. *Eur Radiol.* 2021 ; 31 : 5139-5147.

48) Tanabe N, et al : Kernel conversion for robust quantitative measurements of archived chest computed tomography using deep learning-based image-to-image translation. *Front Artif Intell.* 2022 ; 4 : 769557.

49) Ohno Y, et al : Comparison of lung CT number and airway dimension evaluation capabilities of ultra-high-resolution CT, using different scan modes and reconstruction methods including deep learning reconstruction, with those of multi-detector CT in a QIBA phantom study. *Eur Radiol.* 2023 ; 33 : 368-379.

50) Oshima Y, et al : Capability for dose reduction while maintaining nodule detection : Comparison of silver and copper X-ray spectrum modulation filters for chest CT using a phantom study with different reconstruction methods. *Eur J Radiol.* 2023 ; 166 : 110969.

51) Hamabuchi N, et al : Effectiveness of deep learning reconstruction on standard to ultra-low-dose high-definition chest CT images. *Jpn J Radiol.* 2023 ; 41 : 1373-1388.

52) Ueda T, et al : Compressed sensing and deep learning reconstruction for women's pelvic MRI denoising : Utility for improving image quality and examination time in routine clinical practice. *Eur J Radiol.* 2021 ; 134 : 109430.

53) Ikeda H, et al : Compressed sensing and parallel imaging accelerated T2 FSE sequence for head and neck MR imaging : Comparison of its utility in routine clinical practice. *Eur J Radiol.* 2021 ; 135 : 109501.

54) Obama Y, et al : MR imaging for shoulder diseases : Effect of compressed sensing and deep learning reconstruction on examination time and imaging quality compared with that of parallel imaging. *Magn Reson Imaging.* 2022 ; 94 : 56-63.

55) Nagata H, et al : Compressed sensing with deep learning reconstruction : Improving capability of gadolinium-EOB-enhanced 3D T1WI. *Magn Reson Imaging.* 2024 ; 108 : 67-76.

56) Takenaka D, et al : Deep learning reconstruction to improve the quality of MR imaging : Evaluating the best sequence for t-category assessment in non-small cell lung cancer patients. *Magn Reson Med Sci.* 2023. doi : 10.2463/mrms.mp.2023-0068. Online ahead of print.

57) Ozawa Y, et al : Artificial intelligence-based reconstruction for chest computed tomography and magnetic resonance imaging. *J Radiol Sci.* 2025 ; 50 : 30-41.

58) Kawai H, et al : Coronary computed tomography angiographic detection of in-stent restenosis via deep learning reconstruction : a feasibility study. *Eur Radiol.* 2024 ; 34 : 2647-2657.

59) Matsuyama T, et al : High-resolution deep learning reconstruction for coronary CTA : compared efficacy of stenosis evaluation with other methods at in vitro and in vivo studies. *Eur Radiol.* 2025 ; 35 : 4763-4774.

60) Takada S, et al : Impact of super-resolution deep learning-based reconstruction for hippocampal MRI : A volunteer and phantom study. *Eur J Radiol.* 2025 ; 191 : 112289.