

MRIにおける脳ファントムを用いたDeep Learning Reconstructionの画像特性の検討

Evaluation of Image Characteristics of Deep Learning Reconstruction Using a Brain Phantom in MRI

宮尾 純奈^{1)*}, 伊原 陸¹⁾, 佐藤 晋平¹⁾, 大浦 大輔^{1),2)}

1) 小樽市立病院 医療技術部 放射線室

2) 北海道大学大学院保健科学研究院 医学生理工学分野

Key words: Magnetic Resonance Imaging, Deep Learning Reconstruction, Brain Phantom, variance of laplacian

【Abstract】

Deep Learning Reconstruction (DLR) has become available; however, its characteristics remain largely unclear. In this study, we used a phantom to compare the image characteristics of DLR with those of conventional methods. Quantitative evaluations were performed using the Variance of Laplacian (VL), Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index (SSIM), and Scale-Invariant Feature Transform (SIFT). The results demonstrated that DLR outperformed conventional methods in terms of VL and PSNR, and it maintained image quality even at high reduction factors. These findings suggest that DLR enables rapid imaging while preserving image quality.

【要 旨】

Deep Learning Reconstruction (DLR) が使用可能となったが特性は不明な点が多い。本研究ではファントムを用い、従来法と画像特性を比較した。Variance of Laplacian (VL), Peak Signal to Noise Ratio (PSNR), Structural Similarity Index (SSIM), Scale-Invariant Feature Transform (SIFT) で定量評価を行った。DLRはVL・PSNRが優れており、高reduction factor時も画質劣化が抑えられた。DLRは画質を保ちながら高速撮像が可能であることが示唆された。

1. 緒 言

Magnetic Resonance Imaging (MRI) は、その優れた軟部組織コントラストにより、画像診断に広く利用されている。一方で、MRIの撮像には比較的長時間を要するという課題があり、これが患者の快適性や装置の利用効率に影響を及ぼしてきた。撮像時間の短縮は、患者の負担を軽減し、MRI装置の稼働率を向上させるため、早期から研究開発の重要なテーマとされてきた。これにより、救急医療の場では迅速な診断が可能となり、治療のスピード向上に寄与する。

MRIの高速化に向けた取り組みは、主に撮像シーケンスの改良と新しい技術の導入によって進められてきた。初期には、従来のスピネコー (SE: Spin Echo) 法が主流であったが、その後、撮像時間を短縮するターボスピネコー (TSE: Turbo Spin Echo) が開発さ

れた。さらにマルチスライス法の導入により、複数のスライスを同時に取得することが可能となった。1980年代には、パラレルイメージング技術である Sensitivity Encoding (SENSE) が登場し、複数の受信コイルを利用することで撮像時間を大幅に短縮することが実現した¹⁾。続いて Compressed Sensing (CS) がスパース性を活用し、さらに効率的なデータ収集を可能にした¹⁾。そして近年、Deep Learning Reconstruction (DLR) が画期的な技術として注目されている。DLRは人工知能 (AI) を活用し、従来の手法と比較して効率的かつ正確な画像再構成を可能とする²⁾。この技術は、特に低磁場強度のスキャナーや高速撮像の分野でその効果が顕著であり、臨床現場での適用が拡大している³⁾。

近年の研究では、DLRを用いた高速化シーケンスの有用性が注目されている。肩関節のT₂強調画像では、標準的なシーケンスと比べ、同等の画質でスキャン時間を約67%短縮することができると報告されている²⁾。また下垂体腺腫の術後評価において、DLRを用いたthin slice MRIの方が診断性能が向上した⁴⁾。体幹部でもDLRの有用性は示唆されている⁵⁾。これらのことから、DLRは画質や診断性能に影響することなく高速撮像が可能であることが、複数の研究で示唆されている。

しかし、DLRについては未解明な部分も多い。例えばDLRのノイズ低減による鮮鋭度や類似性に与え

MIYAO Junna^{1)*}, IHARA Riku¹⁾, SATO Shimpei¹⁾,
OURA Daisuke^{1),2)}

1) Otaru General Hospital, Department of Medical Technology, Radiology Division

2) Department of Biomedical Science and Engineering, Faculty of Health Sciences, Hokkaido University

* E-mail: junna.miyao@gmail.com

Received March 18, 2025; accepted June 26, 2025

る影響や、Reduction factor (R factor) によるパフォーマンスの変動など、より詳細な検討が必要である。そこで本研究では、ファントムを用いてDLRとCS、SENSEの画像特性について調査した。

2. 方 法

2-1. ファントムの作成

ヒト脳のT₂強調画像を模擬するために、健康なボランティアのT₂強調画像を撮像し、3Dプリンター (CR-6 SE, Shenzhen Creality 3D Technology, Shenzhen, China) を用いてファントムを作成した (ファントム材質: PLA [ポリ乳酸] フィラメント, ファントムの大きさ186.8×186.8×14.8 mm)。これは, Saotomeらの先行研究⁶⁾にあるように、ヒト脳のシングルスライスT₂強調画像の信号強度をスライス方向の深さ方向に変換し、撮像した際のパーシャルボリューム効果を利用して、シングルスライスで頭部T₂強調画像を模擬できるファントムである。このファントム内に寒天を入れたものを32ch Headコイルで撮像した⁷⁾。

2-2. 使用装置・撮像条件

本研究では、MRI装置はIngenia 3.0T (Philips Medical Systems, Amsterdam, Nederland) を使用し、受信コイルとして32ch Headコイルを使用した。撮像条件はTable 1の通りである。本研究では、臨床に近い分解能でファントムを撮像したため、SNRを臨床画像に近づけるためにNEXを通常シーケンスよりも多く設定した。

DLR, CS, SENSEのR factorを2.0で固定し、その他撮像条件は変えずに、DLR, CS, SENSEの順に

一つずつ撮像した。これを5回撮像したもので差分法SNR (Signal to Noise Ratio) を、10回撮像したものでVariance of Laplacian (VL) を測定した。次に、DLRとCSのVoxelサイズが変わらない条件で、R factor=0をReferenceとし、R factorを1.0~6.0まで6段階変更したもの (R factor=1.0, 2.0, 3.0, 4.3, 5.0, 6.0) を、3回繰り返し撮像した。DLRは、CSと同様にランダムにアンダーサンプリングされたk-spaceを、Convolution Neural Network (CNN) を用いて再構成する。CNNは、事前にノイズのある画像と、ない画像のペアを学習しており、その学習された対応関係から、ノイズや微小アーチファクトを低減し、組織の輪郭や構造の保持を行う。また本研究では、全ての撮像条件でdenoiseの影響をできるだけ統一するため、denoising levelはlowで統一した。高速化方法が異なるとdenoising levelによる影響も変化する可能性がある。しかし、denoising levelをnoにして臨床で使用することは考えにくく、本研究は臨床に則した検討を行うためdenoising levelをlowとした。

2-3. 解析項目

撮像したファントムの画像を、Python (spyder 5.4.3) で、SNR, VL, PSNR (Peak Signal to Noise Ratio), SSIM (Structural Similarity Index), SIFT (Scale-Invariant Feature Transform) の5項目について解析を行った。SNRはDLR, CS, SENSEを5回ずつ撮像したデータ、VLは10回ずつ撮像したデータでそれぞれ箱ひげ図に示した。PSNR, SSIM, SIFTは、DLRとCSでR factorを変えたデータで散布図に示した。

2-3-1. SNR

SNRは差分法を用いて式 (1) より求めた。ファントムを5回撮像し、それらのうち重複のない二組、つまり計10通りの組み合わせで測定した⁸⁾。

$$SNR = \frac{(\sqrt{2} \times S)}{N} \dots (1)$$

S: 2枚の画像の平均値

N: 2枚の画像の差分の標準偏差

Fiji (ImageJ2, Version 2.14.0/1.54f, University of Wisconsin-Madison, Madison, WI, USA) を用いて以下のFig.1のように元画像と2枚の画像の差分画像でファントム全体にROIを設定した⁹⁾。1回目

Table 1 MRI scan parameters

	SNR・VL	PSNR・SSIM・SIFT
Sequence	2D TSE	2D TSE
TR/TE (ms)	4000/100	4000/100
FOV (mm)	180×180	180×180
Voxel (mm)	0.6×0.6	0.6×0.6
Slice number	1	1
Slice Thickness (mm)	6	6
Flip Angle	90	90
Refocus Angle	180	180
TSE factor	10	10
NEX	10	5
WFS (pix) / BW (Hz)	1.2	1.2




Fig.1 ROI setting for SNR calculation using the subtraction method.

(a) Original image (b) Subtraction Image

と2回目, 1回目と3回目, 1回目と4回目…のように全10通りの組み合わせで計算した。

2-3-2. VL (variance of laplacian)

cv2.laplacian関数を使用してDLR, CS, SENSEのラプラシアン分散の値を計算した。分散の値が高いほど、ぼやけが少なく鮮明な画像といえる¹⁰⁾。以下に、VLを計算で求める(2)式を示す¹¹⁾。

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (L(i, j) - \mu)^2 \dots (2)$$

σ^2 : ラプラシアン分散 (ぼやけ度を示す指標)

N: 画像全体のピクセル数

L(i, j): ラプラシアンフィルターを適用した画像のピクセル値

μ : ラプラシアンフィルターを適用した画像全体の平均値

2-3-3. PSNR

PSNRは、画像の品質を客観的に評価するための指標の一つである。ここでは、ReferenceとR factorを変化させたscanとの差異を示し、数値が高いほど劣化が少なく画像が似ていることを意味する。PSNRの計算は画像間のピクセル単位で行われ、以下の(3)式のように定義される¹²⁾。

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right) \dots (3)$$

MAX: 画像の最大ピクセル値

MSE: 平均二乗誤差 (Mean Squared Error)

2-3-4. SSIM

SSIMは、画像の構造的な情報や明るさ、コントラスト、構造的な相関の類似度を評価する指標であり、PSNRと比較して視覚的な評価ができる。SSIMが1.0に近いほど、Referenceのデータと視覚的に似ているということになる。SSIMは、以下の(4)式で求めることができる¹³⁾。

$$SSIM(x, y) = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \dots (4)$$

μ_x, μ_y : 画像x, yの平均値

σ_x^2, σ_y^2 : 分散

σ_{xy} : 共分散

C_1, C_2 : 安定化定数

2-3-5. SIFT

SIFTは、画像中の特徴点(キーポイント)を検出し、その周辺の特徴量を抽出して比較するアルゴリズムである¹⁴⁾。スケールや回転、ノイズ、アフィン変換に対して不変性・ロバスト性を持ち、画像マッチングに広く応用されている。本研究では、Reference画像と比較対象画像間のSIFTマッチング点数を評価指標とし、画像間の構造的な一致度を定量的に比較した。SIFTマッチング点数は、画像間でどれだけ類似した特徴が検出されているかを表す定量指標であり、Reference画像との構造的な一致度を定量的に比較するために用いた。マッチング点数が多いほど、元画像に対して構造的・視覚的に類似していると解釈できる。

SIFTアルゴリズムは、4つの主要な処理ステップから構成される¹⁵⁾。まず最初に、スケール空間極大値検出により、異なるスケールにおける画像のガウシアン関数を用いて差分画像(Difference of Gaussian: DoG)を生成し、これらの画像における局所的な極大値・極小値を検出することで、特徴点候補を抽出する。次に、特徴点の局所化処理を行い、位置とスケールをより安定かつ信頼性の高い特徴点に決定する。その後、各特徴点に対して画像勾配に基づく主方向(オリエンテーション)を割り当てることで、方向・スケール・位置に対して不変性が確保される。最後に、特徴点の周囲領域における画像勾配の方向と強度を基に128次元の特徴ベクトルを生成する。これらの勾配情報は、局所的な形状のゆがみや照明の変化に対しても頑健な表現へと変換される。これがSIFTにおける

特徴量 (Descriptor) であり, 画像マッチングや物体認識などにおける重要な指標として利用される。

2-4. statistical analysis

各Factorと、DLR、CS、SENSEとの関係をフリードマン検定を行った。フリードマン検定で有意差を認めた場合、さらに多重比較をウィルコクソンの順位和検定でボンフェローニの調整有意水準を用いて行った。統計学的有意水準は5%未満とした。統計解析ソフトはR studio version 2024.12.0+467 (The R Foundation for Statistical Computing, Vienna, Austria) を使用した。


2-5. 倫理的配慮

本研究は小樽市立病院臨床研究審査委員会の承認を得て実施した (承認番号: 06-028)


3. 結 果

DLR、CS、SENSEのR Factorを2.0で固定し、5回撮像した。そのうちの1枚の画像をそれぞれFig.2に示す。またこの画像の定量値のSNRをFig.3に示す。同じく、10回撮像した画像のVLの結果をFig.4に示す。


SNRは、DLRとCS、CSとSENSEで有意差があり、VLは、DLR_



(a)



(b)



(c)

Fig.2 (a) T₂-weighted MR image of a head phantom reconstructed using DLR (reduction factor=2).
(b) T₂-weighted MR image of a head phantom reconstructed using CS (reduction factor=2).
(c) T₂-weighted MR image of a head phantom reconstructed using SENSE (reduction factor=2).

CS、SENSE_CSの組み合わせで有意差が認められた。

次に、R factorを増加させて撮像した画像を、各R factorで1枚ずつFig.5, 6に示す。またPSNR, SSIM, SIFTの計測結果をFig.7~9に示す。それぞれR factorを増加させると減少する結果となり、SIFTのみDLRとCSで差が出た。




Fig.3 Box plots represent SNR measurements for Deep Learning Reconstruction (DLR), Compressed Sensing (CS), and SENSE. Each method was tested with a reduction factor of 2 and repeated five times. The central line in each box plot represents the median, and the whiskers indicate the interquartile range. Significant differences were observed between DLR and CS, and between CS and SENSE ($p < 0.05$). In this study, * indicates $p < 0.05$, ** indicates $p < 0.01$, and *** indicates $p < 0.001$.




Fig.4 Box plots of Variance of Laplacian for T₂-weighted MR images (DLR, CS, SENSE; reduction factor = 2, $n = 10$). Significant differences were observed between DLR and CS, and between CS and SENSE ($p < 0.01$, paired t-test).




Fig.5 Representative images reconstructed using DLR with varying reduction factors. The effect of acceleration on image quality can be visually assessed.

(a) R=1.0, (b) R=2.0, (c) R=3.0, (d) R=4.3, (e) R=5.0, (f) R=6.0.




Fig.6 Representative images reconstructed using CS with varying reduction factors. The effect of acceleration on image quality can be visually assessed.

(a) R=1.0, (b) R=2.0, (c) R=3.0, (d) R=4.3, (e) R=5.0, (f) R=6.0.




Fig.7 Comparison of PSNR among different reduction factors. PSNR values were calculated using a reference image.




Fig.8 Structural Similarity Index (SSIM) comparison among different reduction factors. SSIM values were calculated using a reference image.




Fig.9 Comparison of SIFT keypoints among different reduction factors. The number of SIFT keypoints was counted for each reduction factor.

4. 考 察

本研究では、DLR、CS、およびSENSEを用いて、ヒト脳を模擬したファントムのT₂強調画像を撮像し、SNRとLaplacian Varianceを比較した。またR factorを変化させ、DLRとCSにおけるPSNR、SSIM、SIFTの検討を行った。

差分法を用いたSNRの計測では、CSがDLRやSENSEよりも有意に高い結果となった。CSのSNRが高くなった理由としては、CS再構成におけるwavelet変換が、信号にスパース性を持たせ、効率良くノイズ成分を低減しているためであると考えられる^{16,17)}。今回の結果ではDLRはCSよりも低い結果となったが、DLRはCSのwavelet変換をAIに置換しているため、比較的数字の大きな変動はなく、安定したノイズ抑制効果を得ることができるといえる⁵⁾。本研究ではSNR計算に差分法を採用したが、この方法はノイズを直接測定できる点で有用である。しかし、差分画像でノイズ成分を推定するため、CSとDLRのランダムなサンプリング方法、再構成アルゴリズム内のdenoiseの撮像ごとの微小な再構成誤差や、長時間の撮像中における微小な変化などがSNRの結果に影響する可能性がある⁸⁾。

VLによる評価では、DLRとCS、SENSEとCSの組み合わせで有意な差を認めた。CSの鮮鋭度は、CSが高周波成分をランダムに間引いて再構成するために、若干の鮮鋭度の低下が起こるといわれている¹⁸⁾。以上より、DLRはCSと比較して、SNRを保ちつつ鮮鋭度を落とすことなく高速化できる再構成法であると考えられる。

PSNR・SSIM・SIFTの評価では、R factorが高くなるほど各値は小さくなった。PSNRは高いほど劣化が少なく、非可逆画像では30~50dBが一般的な値といわれている^{12,13)}。本研究の結果では、DLRとCSの結果に大きな違いは認められなかった。PSNRが低下した要因は、R factorが大きくなるにつれデータ収集量が減少し、画像のノイズが増加したため、reference画像との差が大きくなったことが考えられる。SSIMも両手法の差はごくわずかであった。SSIMは1に近い値ほど、reference画像との類似性が高く^{12,13)}、本研究では、R factor=3.0までの低R factorではSSIMが0.999以上と非常に高い値であったが、その後、低下を認めた。PSNRとSSIMで大きく差が出なかった理由としては、PSNRは輝度の平均二乗誤差(MSE)を示し¹²⁾、SSIMは輝度とコントラストや構造の全体

的な類似度を示す¹³⁾ことが挙げられる。DLRとCSは同じランダムサンプリングをしており、R factorを大きくした場合でもサンプリング法に違いはないため、PSNRとSSIMの結果で同じ挙動を示したのではないかと考えられる。

構造に関しては、SIFTとVLに着目して検討した。SIFT評価では、DLRがCSのSIFTマッチング点数を上回る結果が得られ、DLRがより多くの特徴点を正確に再構成できる可能性が示唆された。DLRがCSを上回った理由としては、CSのランダムサンプリングにより、高周波成分をカットしているが、その中に含まれる細部情報もカットしてしまい、テクスチャーを示すSIFTが変化してしまったのではないかと考える。一方、DLRはランダムサンプリングの後、CNNを用いて再構成するため、CSよりも構造の劣化が少ない結果となったと考えられる。本研究では2D TSEでの検討であり、SENSEはDLRやCSに比べ、高R factorでは折り返しによるアーチファクトが発生するため、SENSEでの評価は行わなかった。

さらにSENSE、CS、DLRにおけるk-spaceのデータ収集方法および補完手法についても検討した。MRIデータは、フーリエ変換によってk-spaceで収集される¹⁹⁾。k-spaceは画像再構成の基盤となる周波数空間であり、その埋め方が画像品質や再構成速度に大きな影響を与える²⁰⁾。SENSEでは、受信コイルアレイの空間感度を用いてアンダーサンプリングされたk-spaceからMR画像を再構成する¹⁹⁾。この補完は、空間情報と感度マップを基にして行われるため、CSのランダムに間引いたサンプリングよりも、高周波成分が保存されるため鮮鋭度が高くなったと考えられる。一方CSでは、k-spaceをランダムに間引きし、再構成時にwavelet変換でスパース性を活用して画像を再構築する²¹⁾。またCSでは、サンプリングデータを基にdenoising処理と逆wavelet変換を繰り返すことで、撮像時間の短縮とそれに伴うSNRの低下を最小限にする技術であるため、denoising処理の際、一部高周波成分をカットするため鮮鋭度が低くなってしまふと考えられる。これに対しDLRは、MR画像の再構成に深層学習技術を応用した手法であり、AIを活用することで従来の再構成アルゴリズムを高度化してい

る⁵⁾。教師付き学習に基づく訓練で、高品質な画像を参考画像とし、それに対応する低品質な画像を入力としてネットワークを訓練する⁵⁾。この訓練プロセスでは主にCNNが使用され、k-spaceデータや画像空間の情報を学習することで欠損データやノイズの補完が可能となる⁵⁾。このことから、DLRには高周波をカットする概念がなく、深層学習に基づいた再構成アルゴリズムであるため、DLRは辺縁情報を保ちつつ撮像時間の高速化を可能としている。本研究では、denoising levelを統一したが、CSとDLRでの詳細な設定はブラックボックスのため、今後さらなる検証が必要と思われる。

5. 限界

本研究では、T₂強調画像のみの検討であり、コントラストによって特性が異なる可能性がある。今回の結果からSIFTの違いが確認できたが、texture情報の変化まで検討できていない。また本研究はファントムを用いて画像特性を検討したものであり、診断性能は検討できていない。今後、臨床例を用いたマルチコントラストでの検討が必要である。

6. 結論

本研究により、DLRはCSと比較して辺縁情報を保持したままノイズリダクションが可能であり、辺縁情報は従来のSENSEと同等であることが示唆された。

利益相反

本研究の著者および共著者に開示すべき利益相反事項はない。

謝辞

本研究に際して、多くの皆さまにご指導およびご協力いただきましたことに心より感謝申し上げます。

表の説明

Table 1 撮像条件

図の説明

- Fig.1 差分法でSNRを求める際のROIの設定.
(a) 実画像
(b) 差分画像
- Fig.2 (a) DLRを用いた脳ファントムのT₂強調画像 (reduction factor=2)
(b) CSを用いた脳ファントムのT₂強調画像(reduction factor=2)
(c) SENSEを用いた脳ファントムのT₂強調画像 (reduction factor=2)
- Fig.3 箱ひげ図は、Deep Learning Reconstruction (DLR), Compressed Sensing (CS), SENSEのSNR測定結果を示している。各手法はリダクションファクター2で撮像し、5回繰り返した。箱ひげ図の中央の線は中央値を示し、ひげは四分位範囲を表す。DLRとCS, CSとSENSEの間に有意な差が認められた ($p < 0.05$)。この研究では、*はp値が0.05未満、**はp値が0.01未満、***はp値が0.001未満であることを示す。
- Fig.4 T₂ 強調MR画像のラプラシアン分散 (DLR, CS, SENSE; リダクションファクター=2, n=10) の箱ひげ図。DLRとCS, またCSとSENSEの間に有意な差が認められた ($p < 0.01$, 対応のあるt検定)。
- Fig.5 リダクションファクターを変化させたDLRで再構成された代表的な画像。撮像時間が短くなることによる画質への影響を視覚的に評価できる。
(a) R=1.0, (b) R=2.0, (c) R=3.0, (d) R=4.3, (e) R=5.0, (f) R=6.0。
- Fig.6 リダクションファクターを変化させたCSで再構成された代表的な画像。撮像時間が短くなることによる画質への影響を視覚的に評価できる。
(a) R=1.0, (b) R=2.0, (c) R=3.0, (d) R=4.3, (e) R=5.0, (f) R=6.0。
- Fig.7 異なるリダクションファクター間のPSNRの比較。PSNR値はレファレンス画像を用いて算出した。
- Fig.8 異なるリダクションファクター間の構造類似度指数 (SSIM) の比較。SSIM値はレファレンス画像を用いて算出した。
- Fig.9 異なるリダクションファクター間のSIFT特徴点の比較。各リダクションファクターに対してSIFT特徴点の数をカウントした。

参考文献

- 1) 町田好男, 他: MRI 高速撮像の進展 ~画像化の原理から圧縮センシングまで~, 医用画像情報学会雑誌, Vol. 30, No. 1, 2013.
- 2) Yuki Obama, 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. Magnetic Resonance Imaging, Vol. 94, 56-63, 2022.
- 3) Takahiro Ueda, et al.: Efficacy of compressed sensing and deep learning reconstruction for adult female

- pelvic MRI at 1.5 T. European Radiology Experimental, 8, 103, 2024.
- 4) Minjae Kim, et al.: Thin-Slice Pituitary MRI with Deep Learning-based Reconstruction: Diagnostic Performance in a Postoperative Setting. Radiology, Vol. 298, Issue 1, 114-122, 2021.
 - 5) Takeshi Nakaura, et al.: Update on the Use of Artificial Intelligence in Hepatobiliary MR Imaging. Magnetic Resonance in Medical Sciences, 22, 2,147-156, 2023.
 - 6) Kousaku Saotome, et al.: A brain phantom for motion-corrected PROPELLER showing image contrast and construction similar to those of in vivo MRI. Magnetic Resonance Imaging, 36, 32-39, 2017.
 - 7) 高橋悠馬, 他: 各ベンダーにおける最新PROPELLER法の動き補正技術の検証. 日放技学誌, Vol. 80, No. 11, 2024.
 - 8) 和田陽一: 撮像シーケンスとSNR測定法に関する検討. 日放技誌, Vol. 64, No. 772, 2017.
 - 9) 宮地利明, 他: Parallel MRIにおける画像SNR評価法の問題点. 日放技学誌, Vol. 62, No. 1, 2006.
 - 10) Chu Wing So, et al.: Solar image quality assessment: a proof of concept using Variance of Laplacian method and its application to optical atmospheric condition monitoring. Publications of the Astronomical Society of the Pacific, Vol. 136, No. 4, 2024.
 - 11) 鶴崎裕貴: Total Variation正則化を用いた単一画像の超解像における画質改善の検討. IMQ, Vol. 113, No. 164, 31-36, 2013.
 - 12) Anitha S, et al.: Quality Assessment of Resultant Images after Processing. Computer Engineering and Intelligent Systems, Vol. 3, No. 7, 105-112, 2012.
 - 13) 森 竜太郎, 他: 下垂体MRI検査におけるDeep Learning Reconstructionを用いた撮像時間短縮に関する検討. 日放技誌, Vol. 71, No. 862, 2024.
 - 14) David G. Lowe: Object Recognition from Local Scale-Invariant Features. Proceedings of the International Conference on Computer Vision (ICCV), 1150-1157, 1999.
 - 15) David G. Lowe: Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision, Vol. 60, No. 2, 91-110, 2004.
 - 16) Michael Lustig, et al.: Sparse MRI: The Application of Compressed Sensing for Rapid MR Imaging. Magnetic Resonance in Medicine, 58, 1182-1195, 2007.
 - 17) 郡 倫一: Compressed sensing併用Parallel Imaging法におけるDenoising強度の変化による定量値への影響. 日放誌, Vol. 70, No. 854, 2023.
 - 18) 朝比奈諒, 他: 圧縮センシングによるMRI画像シミュレータの高速化. MEDICAL IMAGING TECHNOLOGY, Vol. 32, No. 3, 2014.
 - 19) Thomas Sartorette, et al.: Common artefacts encountered on images acquired with combined compressed sensing and SENSE. Insights into Imaging, 9, 1107-1115, 2018.
 - 20) R. Marc Lebel: Performance characterization of a novel deep learning-based MR image reconstruction pipeline. Preprint at <https://doi.org/10.48550/arXiv.2008.06559>, accessed 2025-02-26.
 - 21) Suhung Park, et al.: Compressed sensing MRI exploiting complementary dual decomposition. Medical Image Analysis, Vol. 18, Issue 3, 472-486, 2014.