

博士論文

ディープラーニングを利用したMR画像の  
圧縮センシング再構成

2023年 3月

大内 翔平

宇都宮大学大学院 工学研究科  
システム創成工学専攻

## 内容梗概

医用画像診断装置である核磁気共鳴映像法 (MRI) は、生体に非侵襲かつ高品質な撮像が行える半面で撮像には時間を要する課題がある。撮像時間を短縮するために圧縮センシングの理論を応用し、少数の観測信号から画像を再構成する方法が検討されている。一方で、圧縮センシングを応用する場合には、画像再構成処理の長時間化や画像が人工的な様相になる課題があった。

これらの課題に対応すべく、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) からなるディープラーニングを利用した MR 画像の再構成法が検討されている。CNN によれば、学習によりパラメータを最適化できるため、数理的な反復処理が不要となり、高速かつ高品質な再構成が期待できる。少数の観測信号から画像を再構成する場合に、学習を通して CNN により再構成を実現する方法と、スパース性を仮定した数理的な反復的処理で再構成を行う方法では、得られる画像や再構成条件に本質的な差が生じる可能性がある。そこで、本研究では、これまで十分に明かされてこなかった二通りの再構成法の特徴について検討を行った。また、CNN を利用する再構成手法に関して、これまで多くの方法は理想的な条件である輝度値のみを持つ実関数画像を想定していた。しかしながら、一般に MRI で得られる画像は、位相情報を含んだ複素画像であるが、複素画像を考慮した CNN 再構成法は十分に検討されていない。

本論文では、はじめに実関数型の CNN を用いて画像空間上で再構成を行う Deep Residual Learning Convolutional Neural Network (DRL-CNN) について検討を行った。DRL-CNN と既存の反復的再構成法を、MR 信号の間引きを行う次元数や信号量、間引きのランダム性の観点から比較検討し、CNN による再構成法の特徴や適した間引きパターンを調査した。つぎに、DRL-CNN の検討で明らかになった CNN 再構成法の性質を利用して、実関数型の CNN で複素画像を再構成する方法を提案した。信号の間引き収集をする際に、信号空間の原点に対して対称となるように信号収集点を与えると、位相分布を求めることなく複素画像の実部と虚部をそれぞれ独立に再構成することが可能となる。本研究では、CNN 再構成法がランダム性の低い信号間引き法に対して頑健であることに着目して、上述の間引き法を CNN 再構成に導入し、実関数型の CNN を用いた再構成法の有効性を検討した。

本論文は序論から結論までの 7 章で構成される。

第 1 章の序論では、研究背景と目的を述べる。まず、MRI における撮像の長

時間化と、撮像時間の短縮化法である圧縮センシングが有する課題点を述べる。また、近年提案が進んでいる、再構成処理を CNN で行う手法の利点と課題点を述べ、本研究の位置づけと目的を明らかにする。

第2章では、本研究に関連する MRI の基礎的事項について述べる。まず、MRI での撮像を可能とする NMR 現象について述べたのち、任意の断面の撮像を可能とするフーリエ変換映像法や、被写体のコントラストを決定する方法について述べる。つぎに、本研究において重要となる、 $k$  空間および複素 MR 画像について概説する。最後に、圧縮センシングの原理と、画像再構成処理に必要となる反復的解法について述べる。

第3章では、ディープラーニングの基礎的事項であるパーセプトロンとニューラルネットワークの概要や、ネットワークを学習するための手法を概説する。

第4章では、CNN を用いた MR 画像の再構成法について、先行研究や関連手法を特徴ごとに分類して概説している。また、本研究で提案する、実関数画像を想定した CNN 再構成法である DRL-CNN と、複素画像を想定した CNN 再構成法について述べる。

第5章では、DRL-CNN を用いた実関数画像の再構成実験の結果を述べる。実際の MRI で撮像された実関数画像のデータセットを使用して、DRL-CNN の層数と受容野の関係、信号間引きを行う次元数や学習枚数および信号収集比の違いによる再構成像の品質の関係を検討し、再構成に要した時間を比較した。また、反復的再構成法において必要とされる信号の間引きパターンのランダム性と CNN 再構成法との関係を明らかにするため、ランダム収集領域と等間隔収集領域を混在したパターンを用いた再構成を行った。実験の結果、CNN 再構成法ではランダムな信号間引き法は必ずしも必要ではなく、等間隔のような規則的かつランダム性の低い信号間引き法に対して頑健であり、反復的再構成法を上回る品質の再構成像が得られることが明らかとなった。

第6章では、DRL-CNN の検討で明らかになった CNN 再構成法の性質を利用した、実関数型の CNN で複素画像の再構成を行う方法による再構成実験の結果を述べる。人工的に位相を付与した画像および臨床で得られたさまざまな位相変化を有する画像を用いた実験により、本手法では位相の複雑さに対して頑健であり、被写体構造や位相分布を良好に復元できることが明らかになった。

第7章の結論では、本論文全体の総括と今後の課題について述べる。

# Reconstruction of Compressed-sensing MR Imaging Using Deep Learning

Shohei Ouchi

## Abstract

MRI is a noninvasive diagnostic imaging device that can produce high-resolution images. However, it takes long time to acquire signals and images. One of the promising approach to accelerate the signal acquisition is the application of Compressed Sensing (CS). On the other hand, in the application of compressed sensing, there are still issues such as the time-consuming image reconstruction and the artificial appearance of the reconstructed image.

In order to solve these issues, MR image reconstruction methods using convolutional deep learning are being investigated. The CNN-based reconstruction can be expected to achieve higher quality images and faster image reconstruction. Although CNN methods have attracted attentions, there may be intrinsic differences in obtained images or reconstruction conditions between CNN-based reconstruction and iterative reconstruction. Therefore, we examined the characteristics of the two reconstruction methods, which have not been fully clarified so far. Many CNN-based methods have assumed real-valued images with only magnitude values. However, images obtained with MRI are generally complex-valued images that include phase information. A CNN-based reconstruction method that takes phase information into account is needed.

Firstly, we studied a real-valued image reconstruction using image-to-image learning (Deep Residual Learning CNN: DRL-CNN). The reconstruction performances of DRL-CNN were compared with an iterative reconstruction method in terms of imaging dimensions, quantity of signal and randomness of under-sampling pattern to clarify the characteristics of CNN-based reconstruction method. Next,

we proposed a method for reconstructing complex-valued images using a real-valued CNN. This method introduces to the symmetrical signal under-sampling with respect to the origin of signal space which enables to reconstruct the real and the imaginary part of complex-valued image independently. Reconstruction experiments were performed using the proposed method and other complex-valued CNNs as a comparison.

This thesis consists of seven chapters from the introduction to the conclusion.

Chapter 1 describes the research background. First, the reasons for the longer imaging time in MRI are described and therefore CS have been used to shorten the imaging time. Next, the advantage and challenges of CNN-based reconstruction methods that have been studied in recent years are described, and the purpose of this study are stated.

Chapter 2 describes the basis of MRI. First, the NMR phenomenon that makes MRI imaging possible is described, followed by the Fourier transform imaging method and a method for determining the image contrast of the subject. Next, k-space and complex-valued MR image is outlined. Finally, the theory of CS and the iterative image reconstruction methods are explained.

Chapter 3 describes the basis of deep learning and the method to train the CNN.

Chapter 4 outlines MR image reconstruction methods using CNNs, categorizing previous studies and related methods. Deep residual learning CNN reconstructing real-valued images, and CNN reconstructing complex-valued images is explained.

Chapter 5 describes the results of reconstruction experiments of real-valued images using DRL-CNN. The relationship between the number of layers and the receptive field of DRL-CNN, the number of dimensions for data acquisition, the number of training images, and the quality of reconstructed images for different signal acquisition ratios were investigated using a dataset of images acquired with MRI. To clarify the relationship between the randomness of the signal under-sampling pattern and the CNN-based reconstruction, reconstruction experiments using patterns with a mixture of random and equally spaced under-sampling were executed. The experimental results demonstrated that CNN-based reconstruction method can learn coherent artifacts and is effective especially for cases where the randomness of signal under-sampling is rather low. These results show that the

CNN reconstruction method produces better quality images than the iterative reconstruction method.

Chapter 6 describes the results of reconstruction experiments of complex-valued images using real-valued CNN. Experiments using a numerical image phantom with a regular phase distribution and real MR images with various phase changes showed that proposed method is robust to complex phase changes and can recover the object structure and phase distribution well.

In chapter 7, we summarize of this thesis and state the future works.

# 目次

内容梗概	i
Abstract	iii
目次	ix
<b>第1章 序論</b>	<b>1</b>
1.1 研究背景と研究目的	1
1.2 本論文の構成	3
<b>第2章 MRIの概要</b>	<b>4</b>
2.1 NMR信号の発生	4
2.2 フーリエ変換映像法	8
2.2.1 傾斜磁場	8
2.2.2 スライス選択傾斜磁場	8
2.2.3 周波数エンコード傾斜磁場	8
2.2.4 位相エンコード傾斜磁場	9
2.2.5 フーリエ変換による画像再生	9
2.2.6 撮像断面	10
2.3 パルスシーケンス	11
2.4 TR, TEと組織間コントラスト	13
2.4.1 TR	13
2.4.2 TE	13
2.4.3 組織間コントラスト	14
2.5 スピンエコー法と高速スピンエコー法	15
2.6 グラジエントエコー法	18
2.7 k空間	20
2.7.1 k空間の概要	20

2.7.2	k空間のエルミート対称性	20
2.7.3	位相の歪みと複素MR画像	21
2.8	圧縮センシングのMRI応用	23
2.8.1	圧縮センシング	23
2.8.2	MR画像のスパース性とL1, L2ノルム最小化	24
2.8.3	L1ノルムを含む最小化問題	24
2.8.4	MR信号の間引き処理	26
<b>第3章</b>	<b>深層学習</b>	<b>27</b>
3.1	パーセプトロン	27
3.2	活性化関数	27
3.2.1	SigmoidとReLU関数	28
3.3	ニューラルネットワーク	29
3.4	ニューラルネットワークの学習	30
3.4.1	データセットとミニバッチ学習	30
3.4.2	回帰	30
3.4.3	クラス分類	30
3.5	パラメータのオプティマイザー	32
3.5.1	確率的勾配降下法	32
3.5.2	Momentum	32
3.5.3	Adam	33
3.6	誤差逆伝播法	33
3.7	バッチ正規化	34
3.8	畳み込みニューラルネットワーク	35
3.8.1	畳み込み層	35
3.8.2	パディング	35
3.8.3	ストライド	35
3.8.4	プーリング	36
<b>第4章</b>	<b>CNNによるMR画像の再構成</b>	<b>37</b>
4.1	CNNによる再構成法の種類と概要	37
4.1.1	Image Domain Learning	37
4.1.2	Transform Learning	38
4.1.3	k-space Domain Learning	38



4.1.4	Unrolling-based モデルと End-to-end モデル	40
4.1.5	マルチコイルへの対応について	40
4.2	実関数画像の再構成と複素画像の再構成	41
4.2.1	実部と虚部を分離する手法	41
4.2.2	複素数型 CNN を用いる手法	42
4.2.3	本研究で想定する CNN-CS の方式について	42
4.3	DRL-CNN	42
4.3.1	DRL-CNN の概要	42
4.3.2	残差学習	43
4.3.3	受容野と CNN 層数	44
4.3.4	DRL-CNN による圧縮センシング再構成の概要	44
4.4	複素画像に対応した実関数型 CNN	47
4.4.1	本手法の概要	47
4.4.2	複素画像の実関数化処理	48
4.4.3	実関数化した複素画像によるデータ拡張について	49
4.4.4	提案法による複素画像の再構成処理の概要	50
4.4.5	再構成処理	53
<b>第 5 章</b>	<b>DRL-CNN による実関数画像の再構成実験</b>	<b>55</b>
5.1	実験の条件	55
5.1.1	使用する MR 画像	55
5.1.2	間引きパターン	56
5.1.3	反復的再構成法との比較	57
5.1.4	計算機環境と実行環境	59
5.1.5	再構成像の品質評価法	59
5.1.6	PSNR	59
5.1.7	SSIM	60
5.1.8	CNN の学習条件	60
5.2	DRL-CNN の CNN 構造の検討	61
5.3	学習枚数の検討	63
5.4	収集信号比の検討	68
5.5	再構成時間の比較	68
5.6	インコヒーレント性の低い間引き方法による再構成	77

5.7	考察	79
5.7.1	CNNの層数とパッチサイズの関係に関して	79
5.7.2	DRL-CNNによる画像再構成の特徴に関して	79
5.7.3	処理時間に関して	81
<b>第6章</b>	<b>実関数CNNによる複素画像の再構成実験</b>	<b>82</b>
6.1	実験の条件	82
6.1.1	使用するMR画像	82
6.1.2	間引きパターン	82
6.1.3	既存手法との比較	83
6.1.4	CS-MRI Complexの間引きパターンについて	84
6.1.5	計算機環境と実行環境	84
6.1.6	再構成像の品質評価法	84
6.1.7	CNNの学習条件	85
6.2	人工的位相を付与した画像による再構成と処理時間の検討	85
6.2.1	再構成実験結果	85
6.2.2	各手法の処理時間	90
6.3	臨床機で撮像された位相を含む画像による再構成	91
6.4	等間隔間引きパターンによる再構成	101
6.5	考察	104
6.5.1	位相変化の複雑さと再構成像の品質に関して	104
6.5.2	処理時間に関して	106
<b>第7章</b>	<b>結論</b>	<b>107</b>
	<b>参考文献</b>	<b>108</b>
	<b>謝辞</b>	<b>117</b>

# 第1章 序論

## 1.1 研究背景と研究目的

核磁気共鳴映像法 (Magnetic Resonance Imaging: MRI) は、磁気共鳴現象 (Nuclear Magnetic Resonance: NMR)<sup>[1][2]</sup> を利用して、生体内の水分に比例した分布を映像化する装置である。MRIにより、生体内で発生した脳卒中やがん、ヘルニアをはじめとする各部の疾患等を可視化できる。また、MRIでは、NMR信号の減衰や回復特性によって様々な体内組織を多様なコントラストで撮像できるほか、コンピュータ断層撮影 (Computed Tomography: CT) をはじめとする他の診断装置と比較して人体への危険性が少ないことが長所であり、広く普及している。その一方で、一般に、1回の診断では数十枚から数百枚の撮像を行うことから、撮像が長時間に及ぶことが短所である。撮像時には、装置内での安静や、必要に応じて息止めが必要なために、幼児や高齢者の撮像には使用できない場合があり、また、緊急時の使用には適さないことが課題である。

撮像時間を高速化するための改良は、ハードウェアとソフトウェアの両面から行われている。ハードウェア面での改良として代表的な方法であるパラレルイメージング<sup>[3][4]</sup> は、撮像に用いる信号受信コイルを増やして撮像を並列化する方法により、1つの信号受信コイル当たりの収集信号比を削減し、高速化を図る手法である。従来型のMRI装置への導入には、信号受信コイル系の追加や画像再構成ソフトウェアの追加が必要であり、導入コストが大きいが、最も普及している手法である。ソフトウェア面の改良のみで撮像を高速化する方法として、DonohoやCandesらが提案した信号回復理論である圧縮センシングを応用する方法<sup>[5][6][7]</sup> がある。圧縮センシングはソフトウェアの変更のみで実現されるため、シングルコイル、マルチコイルを問わずに既存のMRI装置に導入が可能であり、パラレルイメージングとの併用による更なる高速化も可能である。圧縮センシングの応用法は2000年代後半から普及が進み、実診断に活用されているが、以下の3点の課題がある。

- 撮像後の画像再構成処理には数理的な反復処理を伴うため、従来の逆フーリエ変換を基本とした再構成よりも多くの時間を要すること。
- 画像のスパース性やエイリアシングアーチファクトのインコヒーレント性を要する手法

であるため、撮像時の条件によっては画像に人工的な様相が発生すること。

- 一般的な撮像では、装置や被写体組織の特性が要因となり得られる画像は複素画像となるが、多くの手法が実関数画像を想定していること。

再構成の高速化と再構成像の高品質化および、実応用を想定した再構成法の提案は、MRI による診断の機会を拡げ、診断のプロセスを効率化するためにも必要不可欠といえる。

一方で、近年の画像処理分野の発展に注目すると、ディープラーニングをはじめとする人工知能 (Artificial Intelligence: AI) の性能向上が著しい。その応用分野は、ディープラーニングの代表的手法である CNN が注目されるきっかけとなった画像認識タスク向けの AlexNet<sup>[8]</sup>をはじめ、スタイル変換<sup>[9]</sup>、超解像<sup>[10]</sup>、雑音除去<sup>[11]</sup>のほか、音声認識<sup>[12][13]</sup>や自然言語処理<sup>[14]</sup>等、様々なタスクに応用されている。AI の応用は医用画像処理の分野にも進んでおり、臓器抽出<sup>[15]</sup>、超解像<sup>[16]</sup>、雑音除去<sup>[17]</sup>のほか、MRI や CT の画像再構成<sup>[18][19]</sup>にも応用されている。CNN による MR 画像の再構成法は 2010 年代後半に提案されて以来、従来の再構成法に必要な反復処理が不要なこと、学習が済んだ CNN を用いた処理は短時間で済むこと、再構成像の品質が高いことが報告されており、多くの注目を集めている。スパース性を仮定した数理的反復的处理を行う再構成法と、学習によって再構成法を習得する CNN 再構成法では、両手法間の再構成処理が大きく異なるため、再構成像の品質や特徴が異なると考えられるが、この点に関する検討は十分に行われていない。また、一般に MRI で得られる画像は位相情報を持つ複素画像となるため、再構成においては位相情報を考慮する必要があるが、反復的再構成法および CNN 再構成法ともに、実関数画像や緩やかな位相変化を想定した手法が多く、臨床で発生しうる様々な位相変化を想定した手法の検討は少ない。これは、不連続関数となる位相分布の推定が困難なこと、CNN 中で複素数値を直接的に扱う手法が確立されていないことが要因である。

本論文では、第一の検討課題として、反復的再構成法との比較により、実関数型の CNN を用いた画像空間上での MR 画像の再構成法の特徴と有効性を明らかにする。第二の検討課題として、実関数 CNN を使用して複素画像の再構成を行う新たな方法について検討を行う。具体的には、MR 信号の間引きを行う次元数や収集信号比、間引きのランダム性の観点から評価を行い、CNN による再構成法の特徴や適した間引きパターンを調査した。また、様々な位相情報を有する画像で再構成を行い、再構成像の品質および位相への頑健性を評価した。

なお、ディープラーニングという外来語は一般に広く認知されているが、同義の和訳表現に深層学習がある。本論文では、提案手法に使用する CNN が深層構造を持っており、また、その最適化処理を「学習」と称していることから、論文内では、表現を統一するためにディープラーニングを深層学習と称することにする。

## 1.2 本論文の構成

本論文は、本章である「序論」から「結論」までの7章で構成される。

第2章では、本研究を行う上で関連するMRIの基礎的事項について概説する。まず、MRIによる撮像を可能とするNMR現象について述べたのち、任意の断面の撮像を可能とするフーリエ変換映像法や、被写体のコントラストを決定する方法について述べる。つぎに、本研究において特に重要となる、MR信号空間および複素MR画像について概説する。最後に、圧縮センシングの原理と、画像再構成に必要となるノルム最小化問題について述べる。

第3章では、深層学習の基礎となるパーセプトロンとニューラルネットワークの概要や、ネットワークを学習するための手法について述べる。

第4章では、CNNを用いたMR画像の再構成法について、先行手法や関連手法を特徴ごとに分類してまとめている。また、本研究で提案する、実関数画像を想定したCNN再構成法であるDRL-CNNと、複素画像を想定したCNN再構成法の概要と具体的な処理内容について述べる。

第5章では、DRL-CNNを用いた実関数画像の再構成シミュレーションの結果を述べる。シミュレーションでは、実際のMRIで撮像された実関数画像のデータセットを使用して、DRL-CNNの層数と受容野の関係、学習枚数や収集信号比の違いによる再構成像の品質の関係を検討し、再構成に要した時間を比較した。学習枚数や収集信号比による比較では、信号間引きを行う次元数ごとに検討を行った。また、圧縮センシングにおいて必要とされる収集パターンのランダム性とCNN再構成法の間隔関係を明らかにするため、ランダム収集領域と等間隔収集領域を混合したパターンを用いた再構成を行った。シミュレーションの結果と考察を述べる。

第6章では、DRL-CNNの検討で明らかになったCNN再構成法の性質を利用した、実関数型のCNNで複素画像の再構成を行う方法による再構成シミュレーションの結果を述べる。人工的に位相を付与した画像および臨床で得られたさまざまな位相変化を有する画像を用いたシミュレーションを実施し、本方法の有効性と特徴を明らかにする。

第7章の結論では、論文全体の総括と今後の課題について述べる。

## 第2章 MRIの概要

本章では、MRIの基本となる核磁気共鳴現象やフーリエ変換映像法等の概要を述べる。

### 2.1 NMR信号の発生

核磁気共鳴(NMR)現象によれば、撮像対象に含まれる何らかの原子核の共鳴によってNMR信号の発生が可能となる。平常状態の原子核は、それぞれ角運動量  $I$  で固有の自転運動(スピン)をしており、原子核中の陽子と中性子の個数が一致しない場合に磁気双極子モーメントを持つ。NMR信号の発生には、磁気双極子モーメント  $\mu$  を持つ原子核のみが利用できる。原子核の磁気回転比を  $\gamma$ 、 $\hbar$  を  $h/2\pi$  ( $h$ : プランク定数) としたとき、磁気双極子モーメント  $\mu$  とスピン角運動量  $I$  の間には式(2.1)の関係が成立する。

$$\mu = \gamma \hbar I \quad (2.1)$$

磁気双極子モーメントを持つ原子核を磁束密度が  $B_0$  の静磁場中に置くと、原子核には静磁場方向に式(2.2)のエネルギーが加わる。式(2.2)では、静磁場方向の磁気双極子モーメントの大きさを  $\mu$  としている。

$$\begin{aligned} E &= -\mu B_0 \\ &= -\gamma \hbar I B_0 \end{aligned} \quad (2.2)$$

現在使用されているほぼ全てのMRIは、水素原子核(プロトン)を利用してNMR信号を観測する。プロトンは磁気回転比  $\gamma$  が 42.6 MHz/T、天然存在比が 99.985% であり、生体内での存在量が最も多いため、NMR信号の観測に適している。プロトンの核磁気共鳴を考えるにあたり、ここでは単体で正に荷電しているプロトンを考える。プロトンのスピン量子数  $I$  は 1/2 であるため、ゼーマン相互作用によるエネルギー準位の分裂により  $-1/2$  および  $1/2$  の2つのエネルギー状態を持つ。よってプロトンは2方向に対してスピンし、磁場を発生させて

いる。それぞれのプロトンが静磁場から受けるエネルギー  $E_1$ ,  $E_2$  を考えると式 (2.2) より、

$$\begin{cases} E_1 = -\frac{1}{2}\gamma\hbar B_0 \\ E_2 = \frac{1}{2}\gamma\hbar B_0 \end{cases} \quad (2.3)$$

となる。このとき、 $E_1$  と  $E_2$  の間には式 (2.4) のエネルギー差が生じる。

$$\Delta E = \gamma\hbar B_0 \quad (2.4)$$

この差に相当するエネルギーを持つ電磁波 (RF パルス) を外部から印加すると、 $E_1$  と  $E_2$  の間でプロトンの励起が起こる (図 2.1)。この現象を核磁気共鳴という。このとき、印加する RF パルスは角周波数を  $\omega_0$  としたとき

$$\hbar\omega_0 = \Delta E = \gamma\hbar B_0 \quad (2.5)$$

を満たさなければならない。よって、式 (2.6) が導かれる。

$$\omega_0 = \gamma B_0 \quad (2.6)$$

共鳴によってプロトンが励起したとき、電磁波の吸収と放出が発生する。このときに放出される電磁波が NMR 信号である。




図 2.1: エネルギーバンドの分裂と RF パルスによるプロトンの励起

静磁場に置かれたプロトンは  $B_0$  方向を軸とした歳差運動を行う。歳差運動の角周波数  $\omega_0$  はラーモア周波数とよばれ、式 (2.6) と一致する。先に示した角周波数  $\omega_0$  の RF パルスを、磁場の強さを  $B_1$  として  $B_0$  方向に対して垂直に印加すると、プロトンは  $B_0$  方向および  $B_1$  方向に対して以下の角周波数  $\omega_1$  で歳差運動をはじめると。

$$\omega_1 = \gamma B_1 \quad (2.7)$$

この様子を式 (2.8) に従い各々のプロトンの磁気双極子モーメント  $\mu$  を合成した磁化  $M$  で考える.

$$M = \sum_i \mu_i \quad (2.8)$$

静磁場中では各々のプロトンは同じラーモア周波数で歳差運動を行うが、位相はランダムに分布するため、 $M$  の  $B_0$  に垂直な方向の磁場成分  $M_{xy}$  は互いに打ち消され、 $B_0$  方向の磁場成分  $M_z$  のみが残る (図 2.2). 磁化が  $B_0$  方向のみの状態を  $M_0$  とする. ここで  $B_1$  を印加した場合は、 $B_1$  方向に対しても歳差運動を始めるため、磁化  $M$  は RF パルスを印加した方向 ( $B_1$  方向) に倒れる. このとき磁化  $M$  は、 $M_{xy}$  成分が増加し、 $M_z$  成分が減少している. したがって NMR 信号は、磁化が倒れた方向から観測される. 一般に、磁化が  $B_0$  方向から  $90^\circ$  倒れるまで RF パルスを印加する. このときの RF パルスを  $90^\circ$  パルスと呼ぶ. MRI では  $B_0$  方向から  $90^\circ$  倒れた方向に設置したコイルで電磁誘導の法則にしたがって NMR 信号を観測する. 磁化が倒れたのちに RF パルスの印加を終えると、共鳴によって励起したプロトンは励起前の状態に徐々に戻りはじめる. ゆえに磁化  $M_{xy}$  は減衰を、磁化  $M_z$  は回復を始める. これらの磁化の変化はそれぞれ独立して行われる.  $M_0$ ,  $M_z$ ,  $M_{xy}$  の磁化の強さをそれぞれ  $M_0$ ,  $M_z$ ,  $M_{xy}$  としたとき、 $M_z$  が  $M_0$  まで回復するのに要する時間を縦緩和時間  $T_1$  と呼び、組織ごとに固有の値をもつ. 時刻  $t$  における  $M_z$  は式 (2.9) で表される.




図 2.2:  $M_{xy}$  成分の打ち消しにより  $M_z$  成分のみが残った磁化  $M$

$$M_z(t) = M_0(1 - e^{-t/T_1}) \quad (2.9)$$



また,  $M_{xy}$  が 0 まで減衰するのに要する時間を横緩和時間  $T_2$  と呼び, 組織ごとに固有の値をもつ. 時刻  $t$  における  $M_{xy}$  は式 (2.10) で表される.

$$M_{xy}(t) = M_0 e^{-t/T_2} \quad (2.10)$$

RF パルスの印加によって揃ったスピンの位相は,  $M_{xy}$  の減衰の間に再び分散する. これは, 隣接するプロトンが互いの持つ小さな磁場によって干渉しあうことで発生するスピン-スピン相互作用と, MRI の磁場強度が位置によって僅かに異なるために発生する外部磁場の不均一性に由来する.  $T_2$  はこれら 2 つの要因のうち, スピン-スピン相互作用のみを考慮した緩和時間である. 両者を考慮した緩和時間は  $T_2^*$  で表され, 一般に  $T_2^*$  のほうが  $T_2$  よりも減衰が早い.  $M_z$  の回復と  $M_{xy}$  の減衰が同時に発生することにより, コイルが検出する NMR 信号は時間の経過につれて振幅が減少し, かつ振動している. この信号を自由誘導減衰 (Free Induction Decay: FID) 信号と呼ぶ.

## 2.2 フーリエ変換映像法

### 2.2.1 傾斜磁場

NMR 現象では、信号は励起されたすべてのプロトンから生じるため、得られた NMR 信号には位置情報が含まれていない。ボクセルごとのプロトン密度分布を特定するための空間エンコード法として、現在の MRI ではフーリエ変換映像法が広く用いられている。フーリエ変換映像法では、選択励起法や傾斜磁場によって NMR 信号に位置情報を持たせ、これをフーリエ変換することで MR 画像を再生している。FID 信号には周波数、位相、振幅の 3 つの情報が含まれているが、傾斜磁場の印加によって場所ごとに異なるラーモア周波数を与えることができ、周波数と位相に位置情報を持たせることが可能になる。なお、FID 信号の振幅はプロトン密度の情報を含む。また、傾斜磁場の印加の際には、RF パルスが設定した周波数成分のみを選択的に持つようにすると、特定の領域のスピンのみを励起させることができ、これを選択励起法と呼ぶ。傾斜磁場は第 2.1 節の図 2.2 における  $xyz$  の 3 方向に対して印加する。以下では各方向の傾斜磁場を概説する。

### 2.2.2 スライス選択傾斜磁場

スライス選択傾斜磁場は、図 2.2 の体軸方向となる  $z$  軸方向に重畳する傾斜磁場である。RF パルスと同時に印加すると、RF パルスに含まれるバンド幅の周波数で歳差運動をするプロトンのみを共鳴させる。これにより、 $z$  軸方向の任意の厚さで断層像を得ることができる。

### 2.2.3 周波数エンコード傾斜磁場

周波数エンコード傾斜磁場は、図 2.2 の  $x$  軸方向に与える傾斜磁場である。NMR 信号を観測する間に印加すると、被写体のプロトンは静磁場  $B_0$  と傾斜磁場  $G_x$  を合成した大きさの磁場

$$B_0 + G_x x \quad (2.11)$$

の中に置かれていることになり、プロトンは角周波数

$$\omega_0 + \gamma G_x x \quad (2.12)$$

で歳差運動をする。これにより、プロトンが共鳴する周波数は位置によって異なるので、観測される NMR 信号の周波数も座標  $x$  に依存して変化し、位置座標による信号の分離を可能とする。

### 2.2.4 位相エンコード傾斜磁場

RF パルスを印加した後、周波数エンコード傾斜磁場を印加する前に、図 2.2 の  $y$  方向に位相エンコード傾斜磁場を印加すると、被写体のプロトンは静磁場  $B_0$  と傾斜磁場  $G_y$  を合成した大きさの磁場

$$B_0 + G_y y \quad (2.13)$$

の中に置かれていることになり、プロトンは角周波数

$$\omega_0 + \gamma G_y y \quad (2.14)$$

で歳差運動をする。一度位相エンコード傾斜磁場を印加すれば、スピンは傾斜磁場の印加後も位相差を保存したまま歳差運動を行う。周波数エンコード傾斜磁場と位相エンコード傾斜磁場により、各々のプロトンによって得られる FID 信号は、プロトンの存在する場所によって異なる周波数と位相の情報を持つ。すなわち、傾斜磁場の印加によって空間エンコードが実現する。

### 2.2.5 フーリエ変換による画像再生

スライス選択傾斜磁場によって選択された 2 次元断面を考えると、プロトンは周波数エンコード傾斜磁場と位相エンコード傾斜磁場により、各方向に対して式 (2.12)、式 (2.14) の角周波数で歳差運動をしている。ここで、式中の角周波数  $\omega_0$  は静磁場  $B_0$  の影響で発生するため、その大きさは断面の位置によらず一定であるが、傾斜磁場  $G_x, G_y$  の影響で発生する角周波数  $\gamma G_x x, \gamma G_y y$  は、断面の座標  $(x, y)$  によって異なるため、空間エンコードが可能となる。座標  $(x, y)$  における NMR 信号  $s$  は、プロトンのスピン密度  $m(x, y)$ 、傾斜磁場の大きさに依存する角周波数  $\gamma G_x x, \gamma G_y y$  より、緩和項を無視すると式 (2.15) によりフーリエ変換の形で表される。

$$s(t_x, t_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} m(x, y) e^{-j\gamma(G_x t_x x + G_y t_y y)} dx dy \quad (2.15)$$

式 (2.15) において,  $t_x, t_y$  はそれぞれの傾斜磁場の印加時間であり,  $t_x, t_y$  を段階的に変化させて NMR 信号を取得する. ここで,

$$k_x = \gamma G_x t_x, \quad k_y = \gamma G_y t_y \quad (2.16)$$

と変数変換をすると, NMR 信号は式 (2.17) で表すことができる.

$$s(k_x, k_y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} m(x, y) e^{-j\gamma(k_x x + k_y y)} dx dy \quad (2.17)$$

式 (2.17) は電磁波の平面波と類似した式であり, 式の相似性から  $k_x, k_y$  は波数の意味がある. 信号空間  $(k_x, k_y)$  は,  $k$  空間と呼ばれる.

### 2.2.6 撮像断面

上述の傾斜磁場は, 図 2.2 に示す  $xyz$  の 3 軸それぞれに対して印加するが, 被写体に対する 3 軸のとり方は任意に決定できる. そのため, MRI では任意の方向の断面像を撮像可能である. 一般的には, 図 2.3 に示す矢状面 (sagittal), 横断面 (axial), 冠状面 (coronal) の 3 断面が用いられる.




図 2.3: MR 撮像で用いられる断面

## 2.3 パルスシーケンス

FID 信号は RF パルスの印加後に得られる最も基本的な NMR 信号である。傾斜磁場および RF パルスを適切に印加する時間的な手続きをパルスシーケンスといい、パルスシーケンスを図示したものをパルスシーケンス図という。パルスシーケンスによって得られる NMR 信号には複数の種類があり、MRI においてはグラディエントエコー (GRE)、スピネコー (SE)、スティミュレイテッドエコー (STE) が一般的である。ここでは最も基本的なシーケンスである、スピンワープ法のパルスシーケンスを図 2.4 に示す。MR 画像を再構成するためには、傾斜磁場によって位相エンコードと周波数エンコードを行った信号を収集する必要がある。周波数エンコード傾斜磁場では一度に全てのエンコードの信号を取得できるが、位相エンコード傾斜磁場では信号の緩和を待つ必要があるために、一度にすべてのエンコードの信号を得ることができない。そのため位相エンコードの信号は、印加する位相エンコード傾斜磁場の強さを少しずつ変化させながら、図 2.4 のシーケンスを繰り返すことで取得する。図 2.4 の  $G_y$  は、シーケンスを繰り返すごとに傾斜磁場の強さを段階的に変化することを表している。TR と TE は撮像された MR 画像のコントラストに影響を与える時間的要素であり、次節で概説する。

また、図 2.4 中ではスライス選択傾斜磁場  $G_z$  と周波数エンコード傾斜磁場  $G_y$  が負の値を持つ波形になっている。これは選択励起中に生じる各スピンの位相のずれを補正するためである。 $G_z$  に注目すると、RF パルスの印加と同時に正の傾斜磁場が印加され、直後に負の傾斜磁場が印加されている。これは、正の傾斜磁場によって発生したスピンの位相分散を抑え、位相を再収束するための処理である。 $G_x$  に注目すると、正の傾斜磁場を印加する前に負の傾斜磁場が印加されている。これは、一度位相分散させてから再収束することで、スピン間での位相のばらつきをなくし、エコー信号の振幅がピークとなる時刻で全てのスピンの位相を揃えるために行われている。スピンの再収束により、エコー信号はマイナスの時間軸を持つ信号となる。

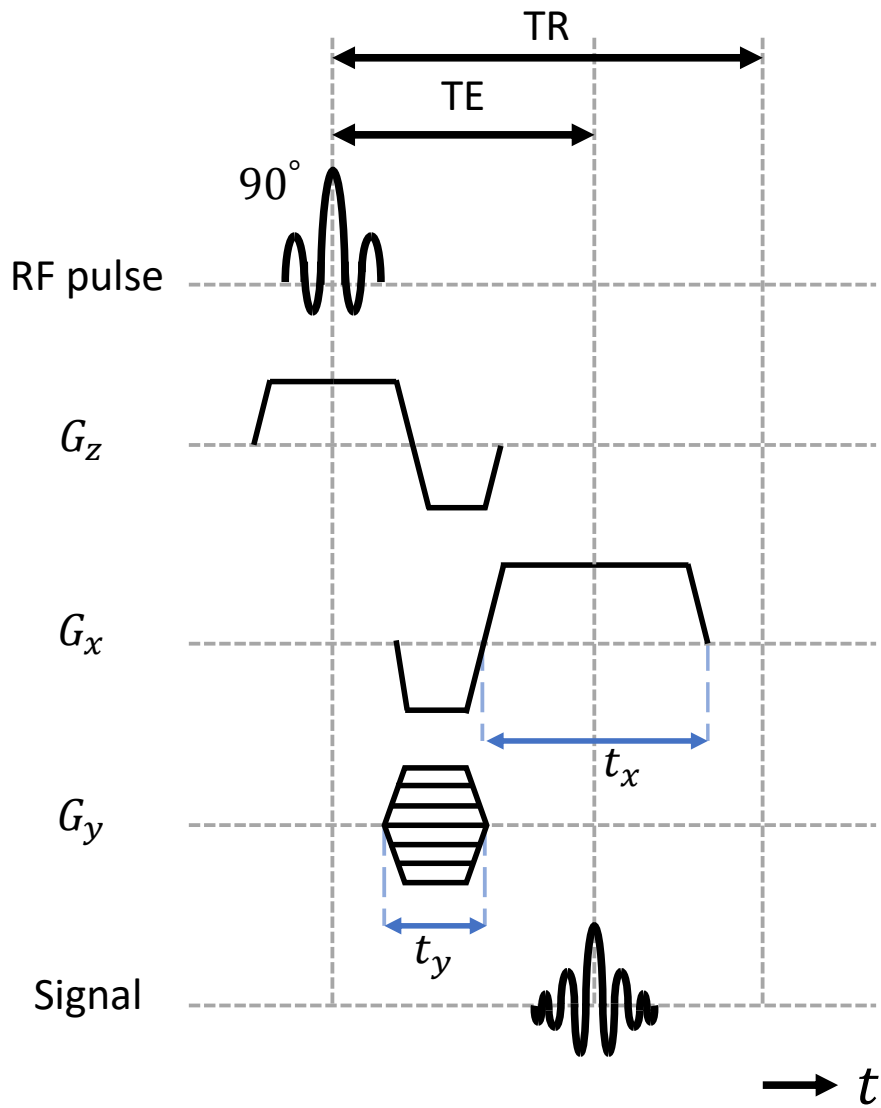


図 2.4: スピンワープ法のパルスシーケンス

## 2.4 TR, TE と組織間コントラスト

### 2.4.1 TR

TR(Repetition Time) は, RF パルスを印加する間隔を指す. 一度 RF パルスを印加した後は,  $M_z$  の回復と  $M_{xy}$  の減衰が始まるが,  $M_{xy}$  の減衰は  $M_z$  の回復よりも速い. そのため, 次の FID 信号を得るためには  $M_z$  の回復を待つ必要がある. しかし,  $M_z$  が  $M_0$  まで回復するのに要する時間は長いため, 実際には  $M_z$  が完全に回復するより前の時間を TR と定める. したがって, 2 回目以降の RF パルスで得られる FID 信号の振幅は 1 回目の FID 信号の振幅よりも小さい. FID 信号の振幅は組織のプロトンの数に応じて異なるため,  $M_z$  の回復の速さも組織によって異なる. 式 (2.8), 式 (2.9) より, ある組織のプロトンの数を  $N$  としたとき, 観測される FID 信号  $S$  の振幅は  $N$  に比例し, TR を用いて式 (2.18) で示される.

$$S \propto N(1 - e^{-\text{TR}/T_1}) \quad (2.18)$$

### 2.4.2 TE

TE(Echo Time) は, RF パルスを印加してから実際に信号が観測されるまでに要する時間を指す. TE の間,  $M_{xy}$  は  $T_2^*$  に従って減衰するため, 実際に得られる FID 信号の振幅  $S$  は式 (2.19) で示される.

$$S \propto N(e^{-\text{TE}/T_2^*})(1 - e^{-\text{TR}/T_1}) \quad (2.19)$$

### 2.4.3 組織間コントラスト

MRI では、被写体中の様々な組織を対象に撮像が行われるが、プロトンの数  $N$ 、 $T_1$ 、 $T_2$  は組織に固有の値である。ここで 2 つの組織（組織  $a$ 、組織  $b$ ）を考えると、組織間の FID 信号  $S_a$ 、 $S_b$  の比は式 (2.20) となる。式 (2.20) 中の  $S$ 、 $N$ 、 $TR$ 、 $TE$ 、 $T_1$ 、 $T_2$  の添え字  $a$ 、 $b$  は組織  $a$  および組織  $b$  を表している。

$$\frac{S_a}{S_b} = \frac{N_a(e^{-TE_a/T_{2a}^*})(1 - e^{-TR_a/T_{1a}})}{N_b(e^{-TE_b/T_{2b}^*})(1 - e^{-TR_b/T_{1b}})} \quad (2.20)$$

式 (2.21) より、 $TR$  が長くなるにつれて組織間の  $T_1$  の差による影響は少なくなり、組織間の FID 信号の振幅比は  $T_2$  の差に依存する。 $TE$  が十分に長いとき、FID 信号をフーリエ変換して得られる画像を  $T_2$  強調像という。

$$\lim_{TR \rightarrow \infty} (1 - e^{-TR/T_1}) = 1 \quad (2.21)$$

一方で、式 (2.22) より、 $TE$  が短くなるにつれて組織間の  $T_2$  の差による影響は少なくなり、組織間の FID 信号の振幅比は  $T_1$  の差に依存する。 $TR$  が短いとき、FID 信号をフーリエ変換して得られる画像を  $T_1$  強調像という。

$$\lim_{TE \rightarrow 0} (e^{-TE/T_2}) = 1 \quad (2.22)$$

$TR$  を極めて長く、かつ  $TE$  を極めて短く設定すれば、 $T_1$  と  $T_2$  の影響がともに少なくなり、組織間の FID 信号の振幅比はプロトンの数に依存する。このとき、FID 信号をフーリエ変換して得られる画像をプロトン密度強調像という。組織間の FID 信号の振幅比は、画像のコントラストとして現れる。したがって、撮像時に  $TR$  と  $TE$  を調整することでコントラストを決定できる。 $T_1$  強調像、 $T_2$  強調像、プロトン密度強調像の例を図 2.5 に示す。




図 2.5: 組織間コントラストの異なる画像例



## 2.5 スピンエコー法と高速スピンエコー法

90° パルスを印加した直後、 $B_0$  と直角な方向に倒れたプロトンのスピンは、そのほとんどが同一の位相を持つが、図 2.6(a) のように僅かな位相差を持つスピンは存在する。そのため実際に観測される FID 信号の振幅は、全てのスピンの位相が揃っている場合に観測される FID 信号の振幅よりも小さくなる。また、RF パルスの印加後のプロトンは励起前の状態に戻ろうとするため、横磁化  $M_{xy}$  の減衰が発生するが、このときスピン間の位相差は図 2.6(b) のように次第に大きくなっていく。そこで、図 2.6(c) のように 90° パルスの印加後に磁化を 180° 回転させる 180° パルスを印加する。これにより 180° パルスの印加前までに発生していた各プロトン間の位相の開きは、180° パルスの印加によって無くなる。プロトン間の位相差が完全に無くなったとき、ダイナミックレンジが最も大きい信号が得られる。この方法をスピンエコー法と呼び、位相差による FID 信号の減衰を回避できるが、180° パルスの印加が必要な分、撮像は時間を要する。スピンエコー法のパルスシーケンスを図 2.7 に示す。

またスピンエコー法の改良法として、1 回の TR の間に複数の 180° パルスを印加することで複数のエコー信号を収集する、高速スピンエコー法がある。収集するエコー信号は、それぞれ異なる強度の位相エンコード傾斜磁場によってエンコードされるため、通常のスピンエコー法よりも多くの FID 信号が取得できる。高速スピンエコー法のパルスシーケンスを図 2.8 に示す。

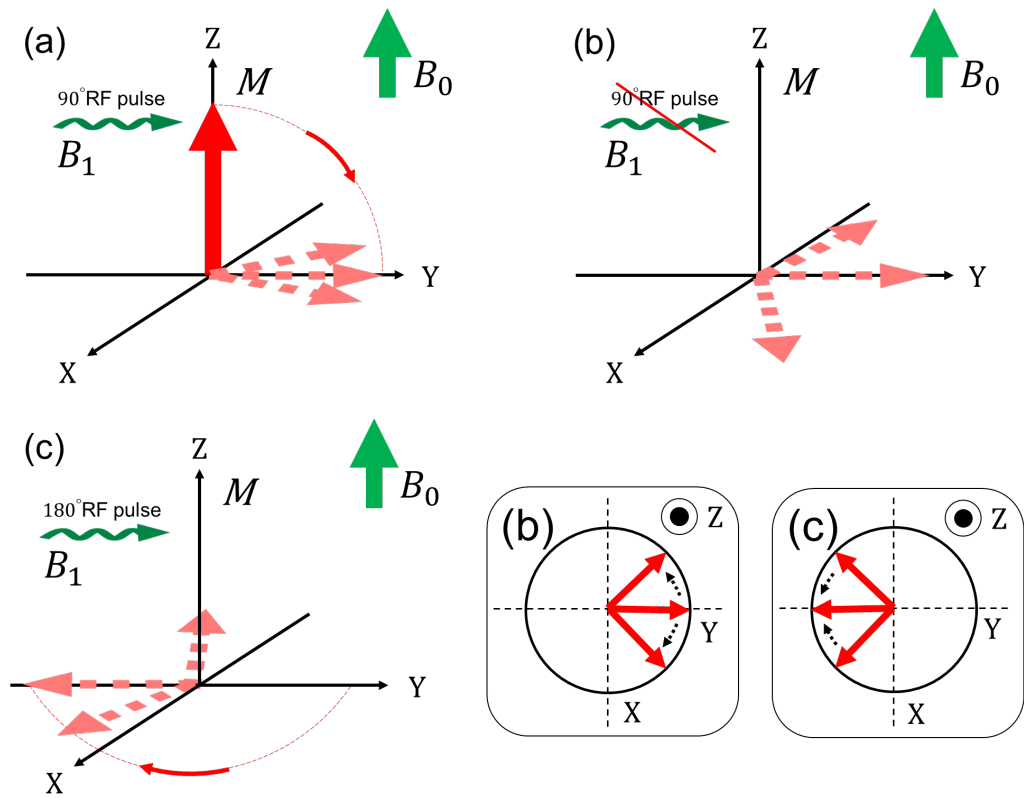


図 2.6: スピンエコー法の発生原理




図 2.7: スピンエコー法のパルスシーケンス




図 2.8: 高速スピンエコー法のパルスシーケンス

## 2.6 グラジエントエコー法

グラジエントエコー法では、磁化を  $M_0$  から倒すための RF パルスを  $\alpha^\circ$  ( $\alpha^\circ < 90^\circ$ ) とする。グラジエントエコー法の基本形である Fast Low Angle SHot 法 (FLASH) のパルスシーケンスを図 2.9 に示す。正負の周波数エンコード傾斜磁場の印加によって、エコー信号の最大点でスピンの位相が揃うため、 $90^\circ$  パルスを用いる場合よりはエコー信号の振幅は小さくなるが、十分な振幅を発生できる。また、磁化の倒れる角度が  $90^\circ$  以下であること、および  $180^\circ$  パルスを使用しないため、TR を短くすることが可能である。




図 2.9: グラジエントエコー法 (FLASH 法) のパルスシーケンス

## 2.7 k 空間

### 2.7.1 k 空間の概要

k 空間は、前章までに述べたパルスシーケンスによって得られるエコー信号の空間を指す。図 2.4, 図 2.7, 図 2.8, 図 2.9 より、パルスシーケンスでは位相エンコード傾斜磁場  $G_y$  を段階的に変化させて印加している。これにより、位相エンコードのステップ数に応じたエコー信号が得られるが、各エコー信号が k 空間の 1 行を埋めることで k 空間全体を構成している。この際、被写体から得られたエコー信号は連続的なアナログ信号のため、MRI 装置内でサンプリングされ、デジタル信号に変換されている。その他の重要な特徴としては、以下の項目が挙げられる。

- k 空間の一方向を位相エンコード方向としたとき、直交する方向は周波数エンコード方向となる。
- k 空間の原点は空間の中心部であり、位相エンコード傾斜磁場と周波数エンコード傾斜磁場の強さは、k 空間の座標  $(k_x, k_y)$  に対応する。
- k 空間信号の逆フーリエ変換により、実空間での画像が得られるため、k 空間信号と実空間は互いにフーリエ変換の関係にある。
- k 空間の中心部である低周波信号は画像のコントラストや概形を構成し、周辺部である高周波信号は画像の細部を構成する。
- 実空間の座標と k 空間の座標に対応関係は存在しない。そのため、k 空間の 1 点には実空間の全ての点の構成に必要な情報が含まれている。

### 2.7.2 k 空間のエルミート対称性

k 空間の 1 行は 1 つのエコー信号で埋められているが、k 空間の座標と傾斜磁場の強さには対応関係が存在するため、図 2.10 より  $k_x$  軸に対して対称な位置となる点  $A(k_{x_1}, k_{y_1})$  と点  $B(-k_{x_1}, -k_{y_1})$  に印加される傾斜磁場は、絶対値が等しく、極性が反転している。また、エコー信号は中央を振幅のピークとして左右対称な形状となるため、上記 2 点のエコー信号は実部と虚部の振幅の大きさが等しく、虚部の極性のみが異なっている。ここで、エコー信号の実部は偶関数、虚部は奇関数となることから、図 2.10 にあるように、点 A を  $a + ib$  ( $i$  を虚数単位とする) とすると、点 B は  $a - ib$  となり、原点对称な位置の信号は対称性がある。これをエルミート対称性 (Hermitian symmetry) という。この性質は理論的には成立するが、

次節で述べるように実際の撮像では装置誤差等があるため厳密なエルミート対称性を満たさない。

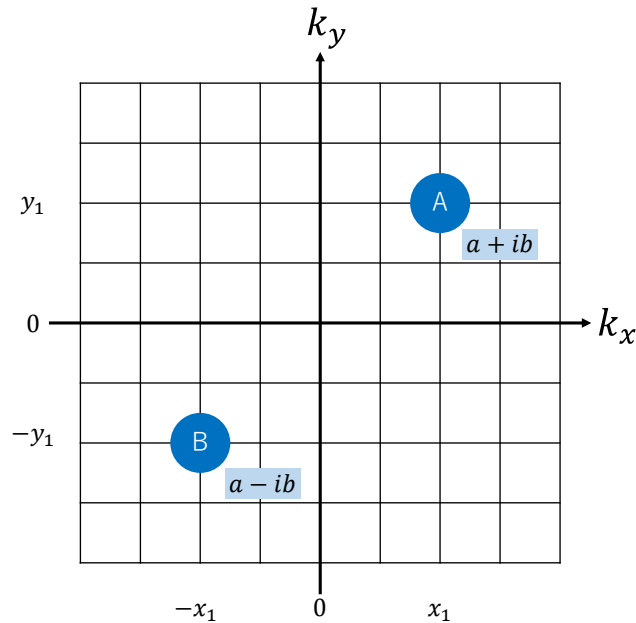


図 2.10: k 空間のエルミート対称性

### 2.7.3 位相の歪みと複素 MR 画像

k 空間の  $k_x$  軸に対して対称な行では、理論上は生じる位相の強さが等しくなるが、実際の撮像では、静磁場や RF パルスの不均一性や体動等による被写体の磁化率差が要因となり、位相の歪みが発生し、被写体は実関数とはならないため厳密にエルミート対称性を満たさない。このとき、k 空間信号の逆フーリエ変換像は、位相の歪みが原因で実関数とはならず、位相を伴った複素数となる。k 空間信号の逆フーリエ変換により得られた磁化の強さ  $m(\mathbf{x})$  は、実部を  $R(\mathbf{x})$ 、虚部を  $I(\mathbf{x})$  とすると式 (2.23) で表される。

$$m(\mathbf{x}) = R(\mathbf{x}) + iI(\mathbf{x}) \quad (2.23)$$

また、実際の磁化の強さの絶対値は式 (2.24)、磁化の位相歪みは式 (2.25) で表される。

$$|m|(\mathbf{x}) = \sqrt{R(\mathbf{x})^2 + I(\mathbf{x})^2} \quad (2.24)$$

$$\phi(\mathbf{x}) = \tan^{-1} \left[ \frac{I(\mathbf{x})}{R(\mathbf{x})} \right] \quad (2.25)$$

式 (2.24) を強度画像 (magnitude image), 式 (2.25) を位相画像 (phase image) という. 複素 MR 画像の強度画像, 実部像, 虚部像, 位相画像を図 2.11 に示す. 通常の撮像では強度画像のみが用いられるが, 近年では位相画像を用いて被写体組織の磁化率を算出することで, 脳内の出血を詳細に判別したり, 脳内での鉄沈着に伴う疾患の識別を可能とした Susceptibility-weighted imaging(SWI)<sup>[20]</sup> や Quantitative Susceptibility Mapping(QSM)<sup>[21][22]</sup> 等の手法も提案されている.

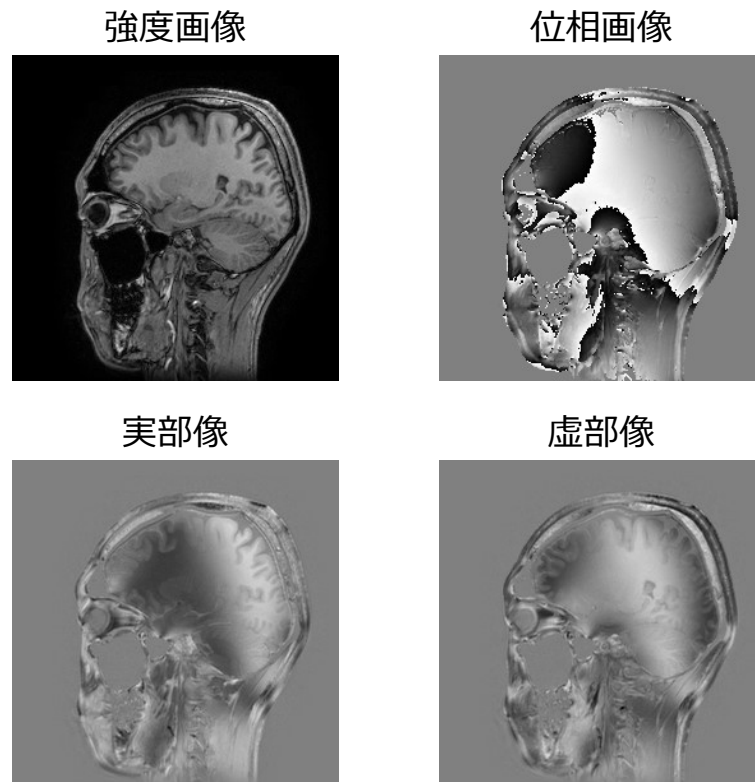


図 2.11: 複素 MR 画像の強度画像, 位相画像, 実部像, 虚部像の例



## 2.8 圧縮センシングの MRI 応用

MRI による撮像では、位相エンコード傾斜磁場の強さを段階的に変化しながら  $k$  空間を充填するが、傾斜磁場の印加ごとに TR 時間の間隔を置く必要がある。これは、撮像の長時間化の要因となり、MRI における大きな課題の一つである。本章では、撮像時間の高速化法の一つである、圧縮センシングの MRI への応用法について概説する。

### 2.8.1 圧縮センシング

圧縮センシング (Compressed Sensing: CS) は、Donoho らによって提案された信号回復理論<sup>[5]</sup>である。一般に観測データから原信号を推定する問題では、シャノンのサンプリング定理を満たしていない限り正しい復元は行えない。ここで原信号を  $\mathbf{x}$ 、観測データを  $\mathbf{y}$  とし、原信号のサンプリング点数を  $n$ 、観測データ数を  $m$  とする。このとき観測行列を  $A$  とすると原信号と観測データの関係は、式 (2.26) で表される。

$$\mathbf{y} = A\mathbf{x} \quad (2.26)$$

圧縮センシングは式 (2.26) が劣決定系 ( $m < n$ ) であり、観測データ数が原信号のサンプリング点数より少ない場合に、原信号がスパース性を持つ条件下で  $\mathbf{y}$  から  $\mathbf{x}$  の復元を行うための理論である。ここでスパース性とは、原信号の多くの成分がゼロ、あるいはゼロに近く無視できるほどの値を持つ性質をいう。スパース性が成立する場合は  $\mathbf{x}$  のうち未知の成分が減るために、 $\mathbf{x}$  の L1 ノルム  $\|\mathbf{x}\|_1$  を最小化することで、 $\mathbf{x}$  を高確率で復元できる。一般に、NMR 信号は雑音  $\epsilon$  を含むため、式 (2.26) は式 (2.27) で置き換えられる。

$$\mathbf{y} = A\mathbf{x} + \epsilon \quad (2.27)$$

### 2.8.2 MR 画像のスパース性と L1, L2 ノルム最小化

MR 画像において、血管像等の一部の画像はスパース性を満たしているが、脳等の複雑な構造を持つ被写体を撮像した画像はスパース性を満たしていない。この場合、画像にスパース化関数  $\Psi$  を施してスパース性を与えることで、スパース化された空間において圧縮センシングの適用が可能となる。

圧縮センシングによる原信号  $\mathbf{x}$  の推定は、スパース化した空間  $\Psi\mathbf{x}$  上で L1 ノルムの最小化を行うことで実現される。以降は、スパース化した  $\mathbf{x}$  を  $\mathbf{x} = \Psi\mathbf{x}$  で表す。このとき、L1 ノルムの最小化問題は式 (2.28) のように制約条件を付したものとなり、式 (2.28) を満足する解は式 (2.29) の最小化問題を解くことによって得られる。

$$\mathbf{x} = \arg \min_{\mathbf{x}} \|\mathbf{x}\|_1 \text{ subject to } \|\mathbf{y} - A\Psi^{-1}\mathbf{x}\|_2 < \epsilon \quad (2.28)$$

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\Psi^{-1}\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\} \quad (2.29)$$

ここで、 $\lambda$  は式 (2.29) の第 1 項と第 2 項の相対的な重みの調整を行う、ラグランジュ乗数である。また、式 (2.28)、式 (2.29) の観測行列  $A$  には、ランダム行列を用いる。圧縮センシングの MRI 応用では、 $F$  をフーリエ変換、 $P$  を信号間引きを行う関数としたとき、観測行列  $A$  は式 (2.30) で表され、式 (2.29) は式 (2.31) で表される。

$$A = PF \quad (2.30)$$

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - PF\Psi^{-1}\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\} \quad (2.31)$$

一般に L1 ノルム最小化問題は非線形かつ微分不可能な問題であるため、これを反復的に解くためのアルゴリズムが提案されている。式 (2.28) および式 (2.29) を LASSO (Least Absolute Shrinkage and Selection Operators)<sup>[23]</sup> と呼ぶ。

MR 画像の再構成問題では、スパース化関数  $\Psi$  として、Total Variation<sup>[24][25][26]</sup>、離散 Wavelet 変換<sup>[27][28]</sup>、離散 Curvelet 変換<sup>[29][30]</sup>、離散コサイン変換<sup>[31][32]</sup> のほか、eFREBAS 変換<sup>[33]</sup> を用いる手法が提案されている。

### 2.8.3 L1 ノルムを含む最小化問題

LASSO では L1 ノルムが絶対値関数であるために、単純な最小化が難しい。そこで絶対値関数を場合分けすることを考える。ここでは、凸関数の最小化である式 (2.32) を考える。式 (2.32) 中の  $b$  は任意の実数である。

$$\min_x \left\{ |x| + \frac{1}{2\lambda}(b-x)^2 \right\} \quad (2.32)$$

$x > 0$  のとき, 平方完成により式 (2.33) が得られる.

$$\min_{x>0} \left\{ \frac{1}{2\lambda} \{x - (b - \lambda)\}^2 + b - \frac{\lambda}{2} \right\} \quad (2.33)$$

式 (2.33) の最小値は  $x > 0$  の制約により  $b - \lambda$  のとる値に応じた場合分けが必要となる.  $b - \lambda > 0$  ならば単に  $b - \lambda$  が最小値となるが,  $b - \lambda \leq 0$  ならば 0 が最小値となる. 同様に  $x \leq 0$  の場合を考慮すると,

$$\min_{x \leq 0} \left\{ \frac{1}{2\lambda} \{x - (b + \lambda)\}^2 + b - \frac{\lambda}{2} \right\} \quad (2.34)$$

より,  $b + \lambda > 0$  ならば 0 が,  $b + \lambda \leq 0$  ならば  $b + \lambda$  が最小値となる. これら 4 通りを整理した式 (2.34) をソフト閾値関数 (soft thresholding function) と呼ぶ. ソフト閾値関数の外形図を図 2.12 に示す. L1 ノルムの最小化問題を解くためのアルゴリズムは複数提案されており, ISTA<sup>[34][6]</sup>, Split Bregman<sup>[35][36]</sup>, ADMM<sup>[37][38]</sup> 等が代表的手法として挙げられる.

$$S_\lambda(b) = \begin{cases} b - \lambda & (b > \lambda) \\ 0 & (-\lambda \leq b \leq \lambda) \\ b + \lambda & (b < -\lambda) \end{cases} \quad (2.35)$$




図 2.12: ソフト閾値関数

### 2.8.4 MR 信号の間引き処理

圧縮センシングによる信号回復法の応用により，MR 信号の収集を間引き，間引いた行にゼロデータを補うことで得られた  $k$  空間の信号から，元信号すなわち求める画像の近似的な復元が可能となる．2次元撮像において， $k$  空間には位相エンコード方向と周波数エンコード方向の2方向が存在するが，撮像の長時間化の要因は位相エンコード方向にある．そのため，位相エンコード方向の信号収集を間引くことで，撮像時間の短縮を図ることができる．信号間引きの際の留意点として，以下の項目が挙げられる．

- $k$  空間の信号振幅は，原点付近が最も大きく，周辺部に近づくにつれて小さくなる．画像の骨格となる信号成分の間引きを避けるため，原点付近は間引かずに連続的に収集する．
- サンプリング定理を満たさない信号から逆フーリエ変換により再構成を行った画像には，信号の間引きによるエイリアシングアーチファクトが発生する．圧縮センシングによる原信号の復元処理では，生じるアーチファクトが雑音状に（インコヒーレントに）分布する必要がある．観測行列をランダムな成分にする簡便な方法に，信号の間引きをランダムにする方法がある．

以降では，MR 信号を間引き収集する際の  $k$  空間の信号収集行の分布を間引きパターンと称し，紙面の上下方向を周波数エンコード方向，左右方向を位相エンコード方向と定義する．収集信号比を 30%とした間引きパターンの例を図 2.13 に示す．




図 2.13: 間引きパターンの例

## 第3章 深層学習

### 3.1 パーセプトロン

人間の脳の神経細胞(ニューロン)は、周囲のニューロンや神経からの電気信号を受けると興奮状態となる。このとき、ニューロンへの入力信号の総和が閾値を越えると、隣のニューロンへと信号が出力される性質があり、これを発火と呼ぶ。深層学習を構成するネットワークは、ニューロンを模したパーセプトロンを基本として構成される。パーセプトロンの出力信号を  $y$ 、 $i$  番目の入力信号を  $x_i$  としたとき、パーセプトロンへの入力の総和  $u$  は式 (3.1) で与えられる。

$$\begin{aligned} u &= \sum_{i=1}^n w_i x_i + b_i \\ y &= f(u) \end{aligned} \tag{3.1}$$

ここで、 $w$  は重みを、 $b$  はバイアスを表している。 $u$  は、重みを乗算した各入力とバイアスとの総和である。また、パーセプトロンの出力  $y$  は  $u$  を入力とした関数  $f$  の出力となっている。関数  $f$  を活性化関数という。

パーセプトロンを並べることで形成した層が複数連なったネットワークを多層パーセプトロンという。このネットワークは、信号が入力側から出力側へと一方向に流れていくため、順伝播型ネットワークとも呼ばれている。

### 3.2 活性化関数

活性化関数は、ニューロンの発火の際に出力する信号のエネルギーを決定する関数である。多層パーセプトロンを構成するパーセプトロンは、活性化関数として非線形関数を用いることで多様な関数の表現を可能とする。

### 3.2.1 Sigmoid と ReLU 関数

現在広く用いられている活性化関数として、Sigmoid と正規化線形関数<sup>[39]</sup>がある。正規化線形関数 (Rectified Linear Function) は、この関数を持つパーセプトロンを Rectified Linear Unit と呼んでいることから ReLU と呼ばれるのが一般的である。Sigmoid と ReLU を式 (3.2), 式 (3.3) に示す。ReLU では入力信号  $x$  が  $x \leq 0$  のとき常に 0 が出力されているが、これを様々に変更することで  $x \leq 0$  の情報も下層に伝達する、ReLU の派生にあたる関数が数多く提案されている。ここでは、 $x \leq 0$  の情報も下層に伝達できる ReLU の一種である、LeakyReLU<sup>[40]</sup> を式 (3.4) に示す。また、図 3.1 に、Sigmoid, ReLU および Leaky ReLU( $\alpha = 0.2$ ) の概形を示す。

$$f_{\text{Sigmoid}}(x) = \frac{1}{1 + e^{-x}} \quad (3.2)$$

$$f_{\text{ReLU}}(x) = \begin{cases} 0 & (x \leq 0) \\ x & (x > 0) \end{cases} \quad (3.3)$$

$$f_{\text{Leaky ReLU}}(x) = \begin{cases} \alpha x & (x \leq 0) \\ x & (x > 0) \end{cases} \quad (3.4)$$

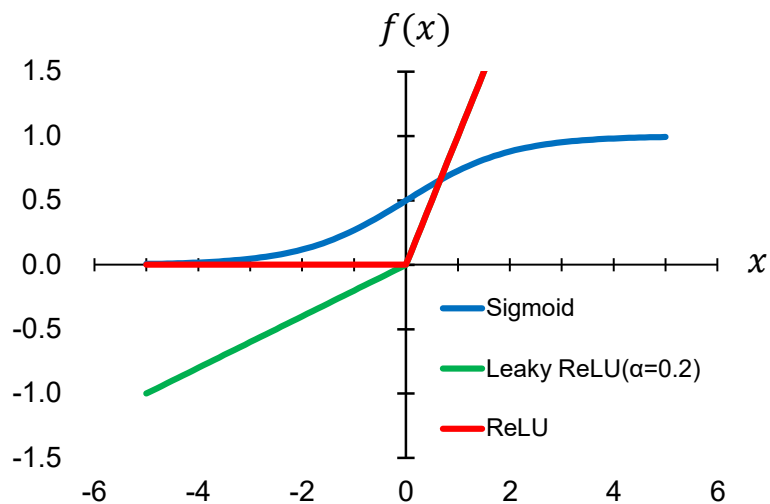


図 3.1: 活性化関数

### 3.3 ニューラルネットワーク

ニューラルネットワークは多層パーセプトロンを発展させた多層型のネットワークであり、与えられた入力情報に対して回帰や分類を行う。パーセプトロンの重みやバイアスといった各種のパラメータを適切に設定することによって様々な関数を表現することが可能であり、適切なパラメータを設定することが重要となる。ニューラルネットワークの大きな利点は、パラメータの値を自動で学習できる点にある。

ニューラルネットワークの構造を図 3.2 に示す。情報は左端の層から入力されて右端の層から出力される。情報が入力される層を入力層、出力される層を出力層といい、これらの中に位置する層を中間層または隠れ層と呼ぶ。各層の出力が次の層の入力となり、各層を構成するパーセプトロンは式 (3.1) に従って動作する。図中では簡単のため中間層を 1 層としているが、これ以上の層を持つことが可能である。

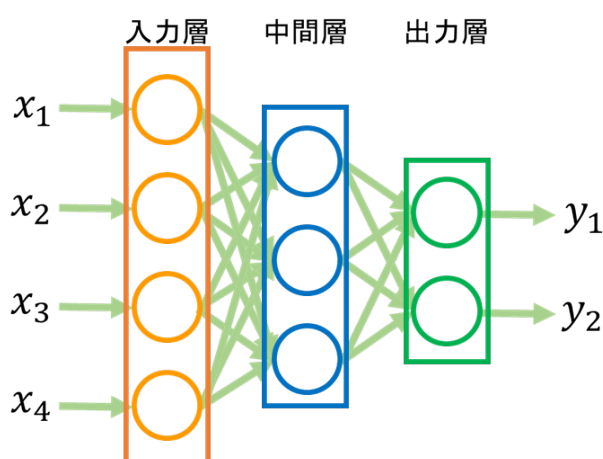


図 3.2: ニューラルネットワーク

## 3.4 ニューラルネットワークの学習

### 3.4.1 データセットとミニバッチ学習

ニューラルネットワークでは、パーセプトロンが各々に持つパラメータの設定次第で様々な関数を表現できる。したがって、ニューラルネットワークにおける学習とは、入力に対して所望の出力が得られる関数をネットワークが表現できるようにパラメータを更新することを指す。これを実現するために、関数への入力データと目標とする出力データのセットを用意してネットワークに与える必要がある。膨大な数のセットを集めたデータのことをデータセットと呼ぶ。データセットに含まれる入力データをネットワークに入力し、得られた出力データが目標とするデータに近似するように学習を進めていく。この際、計算コストの削減を図るため、データセットに含まれるデータを一定数ごとにグループ化して、グループ単位でネットワークに与え、パラメータの更新を行う並列計算方式が用いられることが多い。この方式をミニバッチ学習といい、分割されたグループをミニバッチという。また、学習においてはネットワークの出力と目標とする出力間の近似度を定量的に評価する関数を導入する必要がある。この関数を損失関数と呼ぶ。ネットワークで扱う回帰や分類といった問題によって、損失関数および出力層の活性化関数を適切に選択する必要がある。

### 3.4.2 回帰

回帰では出力が連続値となる場合に、目標とする出力データを良好に再現できるような関数を表現する。出力層の活性化関数には恒等関数を、損失関数には二乗和誤差を用いるのが一般的である。データセットのセット数を  $N$ 、目標とする出力を  $d_i$ 、ネットワークの出力を  $y_i$  としたとき、二乗和誤差  $E$  は式 (3.5) で与えられる。

$$E = \frac{1}{2} \sum_{i=1}^N (d_i - y_i)^2 \quad (3.5)$$

### 3.4.3 クラス分類

クラス分類では入力データを複数のクラスに分類する関数を表現する。出力層の活性化関数にはソフトマックス関数を、損失関数には交差エントロピー誤差を用いるのが一般的である。出力層のパーセプトロンの数はクラス数  $N$  と 1対1 に対応しているものとし、出力層へ



の入力を  $y'$  としたとき、出力層の  $i$  番目のパーセプトロンのソフトマックス関数は式 (3.6) で与えられる。

$$y_i = \frac{e^{y_i'}}{\sum_{j=1}^N e^{y_j'}} \quad (3.6)$$

ソフトマックス関数において、分母は 1 となるため、 $y_i$  は入力データが  $i$  番目のクラスに分類される確率を表しているのに等しい。また、交差エントロピー誤差  $E$  は式 (3.7) で与えられる。

$$E = - \sum_{i=1}^N d_i \log y_i \quad (3.7)$$

## 3.5 パラメータのオプティマイザー

パラメータの更新を行うオプティマイザーとして広く用いられている確率的勾配降下法および、Momentum, Adam の概要を示す。

### 3.5.1 確率的勾配降下法

ニューラルネットワークの学習では、損失関数を最小化できるようにパラメータを更新していく必要がある。データセットの全要素に対する損失関数の総和が最小となるように、各々の損失関数の勾配方向にパラメータを更新していく手法を勾配降下法という。しかし、一般に損失関数は凸関数にはならないため、局所解を探索してしまい適切な更新が不可能となる場合がある。これに対して、データセットの一部のデータのみから損失関数を求めて勾配降下法によるパラメータ更新を行う手法を確率的勾配降下法 (Stochastic Gradient Descent: SGD) という。この手法では、パラメータの更新ごとに損失関数を求めるデータをランダムに変更する。これにより、損失関数の値が毎回異なるため、局所解から抜け出せなくなるリスクを低減できる。更新するパラメータをベクトル  $\mathbf{w}$  として集約して表現し、更新の回数を  $t$  とすると、SGD は式 (3.8) のようにパラメータを更新する。

$$\mathbf{w}^{(t+1)} = \mathbf{w}^t - \eta \nabla E \quad (3.8)$$

ここで  $\eta$  を学習係数といい、パラメータの更新幅を決定する要素である。SGD はニューラルネットワークにおけるパラメータの更新手法として広く用いられているが、損失関数の形状が等方的でない場合に探索が非効率となる。

### 3.5.2 Momentum

Momentum (Momentum SGD) は SGD の改良法であり、SGD におけるパラメータの更新量  $(-\eta \nabla E)$  に、これより前の更新量を一定の割合で加算する。現在の更新回数が  $t$  のとき、 $t-1$  における重みの修正量を

$$\Delta \mathbf{w}^{(t-1)} = \mathbf{w}^t - \mathbf{w}^{(t-1)} \quad (3.9)$$

とする。  $\mu$  を加算の割合を調整する変数とすると、Momentum は式 (3.10) で更新を行う。

$$\mathbf{w}^{(t+1)} = \mathbf{w}^t - \eta \nabla E_t + \mu \Delta \mathbf{w}^{(t-1)} \quad (3.10)$$

これらの処理により、SGD における探索が非効率となる問題を回避できる。

### 3.5.3 Adam

Adam<sup>[41]</sup> は AdaGrad<sup>[42]</sup>, RMSprop<sup>[43]</sup> の改良法であり, 式 (3.11) で定義される.

$$\begin{aligned}
 \mathbf{m}^t &= \beta_1 \mathbf{m}^{t-1} + (1 - \beta_1) \nabla E^t \\
 \mathbf{v}^t &= \beta_2 \mathbf{v}^{t-1} + (1 - \beta_2) (\nabla E^t)^2 \\
 \hat{\mathbf{m}}^t &= \frac{\mathbf{m}^t}{1 - \beta_1^t} \\
 \hat{\mathbf{v}}^t &= \frac{\mathbf{v}^t}{1 - \beta_2^t} \\
 \mathbf{w}^{(t+1)} &= \mathbf{w}^t - \eta \frac{\hat{\mathbf{m}}^{(t+1)}}{\sqrt{\hat{\mathbf{v}}^{(t+1)} + \epsilon}}
 \end{aligned} \tag{3.11}$$

式 (3.11) における  $\epsilon$  は, 発散を防ぐための正の定数である.  $\mathbf{m}^t, \mathbf{v}^t$  において指数移動平均を適用すると, 各項に 1 以下の  $\beta$  および  $(1 - \beta)$  を乗じることになるため, 指数移動平均の適用前よりも  $\mathbf{m}^t, \mathbf{v}^t$  が小さくなる. これを回避するために  $\hat{\mathbf{m}}^t, \hat{\mathbf{v}}^t$  を導入した点が Adam の特徴である.

## 3.6 誤差逆伝播法

オプティマイザーによるパラメータの更新には, 損失関数のパラメータでの微分, すなわち勾配を使用する. 一般にニューラルネットワークは膨大な数のパーセプトロンを使用しており, 多層構造をとっているため, 微分の処理には極めて多くの時間を要する. そこで, 合成関数の連鎖率を利用して逆伝播方向から微分の計算を行う誤差逆伝播法が広く利用されている. 中間層と出力層のみに注目したときの誤差逆伝播法の計算の様子を図 3.3 に示す.

図 3.3 では, 本来出力層の持つ役割として一纏めに表現される計算過程を展開して示している. 各中間層の出力に重みを掛け合わせた値が出力層の処理 (1) に入力されると, この総和  $u$  が出力されて処理 (2) へと入力される. 処理 (2) では活性化関数  $f(u)$  の計算が行われ,  $y$  が出力されて処理 (3) へと入力される. 処理 (3) では損失関数  $E$  の計算が行われる. 逆伝播では, 各計算過程の前後の入出力のみに注目することで局所的な微分を求め, これらを出力側から順に伝播していく. これにより, 局所的な微分を逆伝播方向から順に掛け合わせることができるが, 掛け合わせた式は合成関数の微分となっており, 結果的に損失関数をパラメータで微分した結果が得られる.

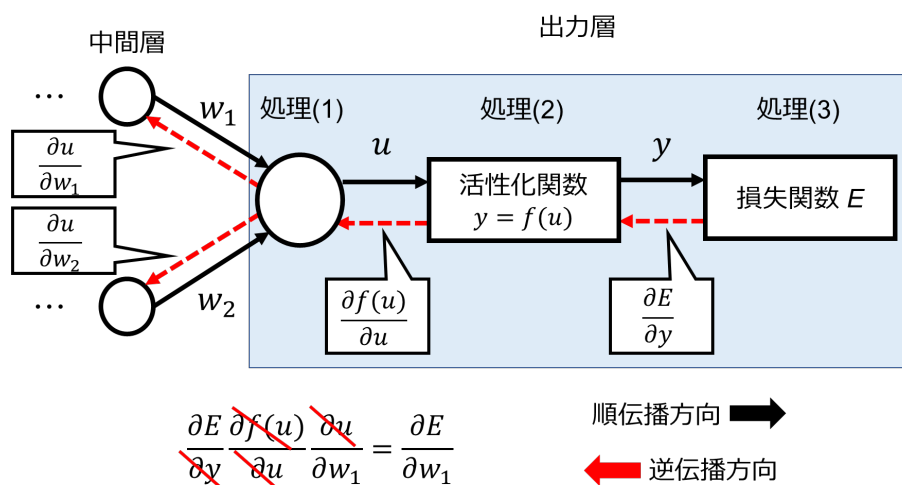


図 3.3: 誤差逆伝播法の概要図

### 3.7 バッチ正則化

ニューラルネットワークでは、複数の層を重ねてネットワークを構成することが一般的である。入力層にデータが入力され、各層での畳み込み等の処理を経て後方の層へと情報が伝播するが、入力するミニバッチの持つ特徴がミニバッチ間で異なる場合、異なるミニバッチを学習するたびに層内のパラメータの分布が変化する。よって、層の出力分布にも変化が生じ、この変化は後方の層に伝播する。これらの現象は、学習効率の低下を招くため、バッチ正則化<sup>[44]</sup>によって層ごとにデータの分布を正規化する手法が採られる。バッチ正則化による正規化は、式(3.12)に示すように各層におけるデータの平均 $\mu_B$ を0、分散 $\sigma_B^2$ を1とすることで行われ、 $\hat{x}_i$ が得られる。その後、式(3.13)のように $\gamma$ と $\beta$ を用いて $\hat{x}_i$ のスケールとシフトを行い、式(3.12)の画一的な処理によるネットワークの表現能力の低下を回避する。 $\gamma$ と $\beta$ は学習パラメータであり、学習過程で最適化される。バッチ正則化により、パラメータの初期値に対して頑健となり、学習が安定化する。

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (3.12)$$

$$y_i = \gamma \hat{x}_i + \beta \quad (3.13)$$

## 3.8 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) は、画像認識や音声認識に用いられるニューラルネットワークの一種である。前章までのニューラルネットワークは、隣接する層間のパーセプトロン同士が全て結合されている全結合層であるのに対し、CNNの層は特定のパーセプトロンのみが結合関係を持つ。ニューラルネットワークは、1次元のデータのみに対応するため、画像等の2次元データは全て1次元となるように変換処理を施す必要があり、画像中の位置関係は考慮できない。一方で、CNNは2次元のデータに対応しているため、画像処理に適している。CNNの各層では、2次元の畳み込み、活性化関数、バッチ正則化のほか、プーリング (pooling) による画像サイズの縮小処理等が行われる。また、CNNは中間層を2層以上設け、ネットワーク構造を深層化することが一般的であり、深層化したCNNを用いた処理全般を深層学習という。

### 3.8.1 畳み込み層

サイズが  $W \times W$  の入力画像と  $H \times H$  のフィルタ画像を考える。それぞれの画素を  $(i, j)$ ,  $(k, l)$  で表し、入力画像の  $(i, j)$  の画素値を  $x_{ij}$ , フィルタ画像の  $(k, l)$  の画素値を  $h_{kl}$  とする。このとき、畳み込みの計算は式 (3.14) で与えられる<sup>[45]</sup>。

$$u_{ij} = \sum_{k=0}^{H-1} \sum_{l=0}^{H-1} x_{i-k, j-l} h_{kl} \quad (3.14)$$

### 3.8.2 パディング

畳み込みの計算によって、出力画像のサイズは入力画像のサイズよりも小さくなる。これを防ぐために、予め入力画像の周囲を画素値0の画素で埋めておき、畳み込み後の出力画像が入力画像と同じサイズとなるように調整することをパディング (padding) という。

### 3.8.3 ストライド

畳み込み処理において、画像に対して畳み込みフィルタを適用する際の位置のストライド間隔をストライド (stride) という。

### 3.8.4 プーリング

画像の特徴を抽出しつつ画像サイズを小さくすることで、画像内での特徴の位置ずれに対してのロバスト性を高める処理をプーリングという。一般に用いられるプーリングには、式 (3.15) に示す最大値プーリングと式 (3.16) に示す平均値プーリングがある。畳み込みと活性化関数を経た画像  $z_{kl}$  のサイズを  $H \times H$  とし、この領域に含まれる画素の集合を  $P_{ij}$  とするとき、プーリングによれば  $H^2$  個の画素を用いて 1 つの画素値  $u_{ij}$  が求められる<sup>[45]</sup>。

$$u_{ij} = \max_{(k,l) \in P_{ij}} z_{kl} \quad (3.15)$$

$$u_{ij} = \frac{1}{H^2} \sum_{(k,l) \in P_{ij}} z_{kl} \quad (3.16)$$

## 第4章 CNNによるMR画像の再構成

MR画像の圧縮センシングによる画像再構成処理を深層学習に置き換える手法が提案されている。これらの手法によれば、サンプリング定理を満足しない少数の観測信号から、CNNによって元画像を近似的に復元可能であり、数理的な反復処理をCNNで代替することから再構成処理に要する時間が短縮される。本章では、CNNによる再構成法であるCNN-CSを概説する。

### 4.1 CNNによる再構成法の種類と概要

圧縮センシングの数理的な反復法では、L1-L2ノルム最小化の逐次処理によって画像を復元していたのに対し、CNN-CSではCNNによって同様の処理を行う。CNNは学習によって多様な特徴を柔軟に表現できるため、CNN-CSはCNNへの入出力データの空間に伴って、図4.1の3種に分類できる。

#### 4.1.1 Image Domain Learning

画像空間上で再構成を行う方式はImage Domain Learningに分類される。CNNへの入力画像は、間引き収集したMR信号の逆フーリエ変換像（ゼロフィル再構成像）であり、エイリアシングアーチファクトが重畳しているが、これを除去した画像をCNNによって推定することで、元画像の復元を図る手法である。DnCNN<sup>[11]</sup>やU-Net<sup>[46]</sup>等の、画像の雑音除去やセグメンテーションを目的としたCNNが応用される<sup>[47]</sup>。この手法では、CNN構造の複雑度を低くできるため、CNNによる学習とテストの処理が比較的高速に行えることが特徴である。また、既存の画像処理用のCNNを応用することが容易であり、その例として敵対的生成ネットワーク(GAN)<sup>[48]</sup>を再構成に応用する手法<sup>[49]</sup>がある。GANを用いた手法では、学習済みのクラス分類用CNNを損失関数として用いる手法<sup>[50]</sup>の併用により再構成像の高品質化を図るDAGAN<sup>[51]</sup>や、SSIM<sup>[52]</sup>を損失関数として併用し被写体構造の復元性能を高めた手法<sup>[53]</sup>等が提案されている。そのほか、回帰型ニューラルネットワーク(Recurrent Neural Network:

RNN) を応用し、動的な撮像を行えるダイナミック MRI の再構成に対応した手法<sup>[54]</sup> や、複数の RNN を併用して画像の高周波成分の復元性能を向上させた手法<sup>[55]</sup> 等が提案されている。また 2020 年以降は、自然言語処理用のネットワークとして提案された Transformer<sup>[56]</sup> を画像処理に応用する Vision Transformer<sup>[57]</sup> が注目を集めており、これを MRI の再構成に応用した手法<sup>[58][59]</sup> 等も提案されている。これらの手法は、いずれも学習用画像を必要とする教師あり学習方式であるのに対して、cycleGAN<sup>[60]</sup> の導入によって、CNN への入力画像と教師画像を必ずしも 1 対 1 のペアで用意するのではなく、アーチファクトの生じた画像群と目標となる画像群から再構成を学習する手法<sup>[61]</sup> や、Deep Image Prior(DIP)<sup>[62]</sup> の導入によって、教師画像を用いずに再構成を行う手法<sup>[63]</sup> 等も検討されている。

## 4.1.2 Transform Learning

k 空間と画像空間の関係を学習する方式は Transform Learning に分類される。CNN への入力は、間引き収集した k 空間であり、CNN 内部でフーリエ変換と画像の復元を行う方法により、アーチファクトを除去した画像を出力する。既存の代表的な手法として、Hammernik らの提案する、圧縮センシングによる反復的再構成と深層学習に基づく変分モデルで構成され、学習によって反復的再構成の定義式内のパラメータを最適化する手法<sup>[64]</sup> や、圧縮センシングに代表されるデータの整合性を維持できる変分フレームワークと CNN を併用する Model-Based Deep Learning(MoDL)<sup>[65]</sup> がある。また、圧縮センシングの反復的アルゴリズムである ISTA<sup>[34]</sup> や ADMM<sup>[37]</sup> と CNN を融合し、数式内のパラメータを CNN で最適化する ISTA-Net<sup>[66]</sup> や ADMM-CSNet<sup>[67]</sup>、反復的アルゴリズムである Split Bregman<sup>[35]</sup> を CNN に導入した手法<sup>[68]</sup> のほか、全結合をもつネットワークによって、信号空間と画像空間の関係を学習する AUTOMAP<sup>[69]</sup> 等も提案されている。

## 4.1.3 k-space Domain Learning

k 空間の間引き点を CNN で復元することで再構成を行う方式は k-space Domain Learning に分類される。この方式単体での再構成法も提案されているが<sup>[70]</sup>、間引いた k 空間から元信号を推定するのは難易度が高いため、Image Domain Learning との併用による手法が複数提案されている。併用法として、2 つの U-Net をカスケード接続して、前方の U-Net では画像空間を推定し、後方の U-Net では前方での再構成像をフーリエ変換した k 空間上で間引き点を推定するハイブリッド方式<sup>[71]</sup> や、k 空間用の CNN と画像空間用の CNN を交互に複数回適用して、両方の空間で再構成像の高品質化を図る KIKI-net<sup>[72]</sup> が提案されている。



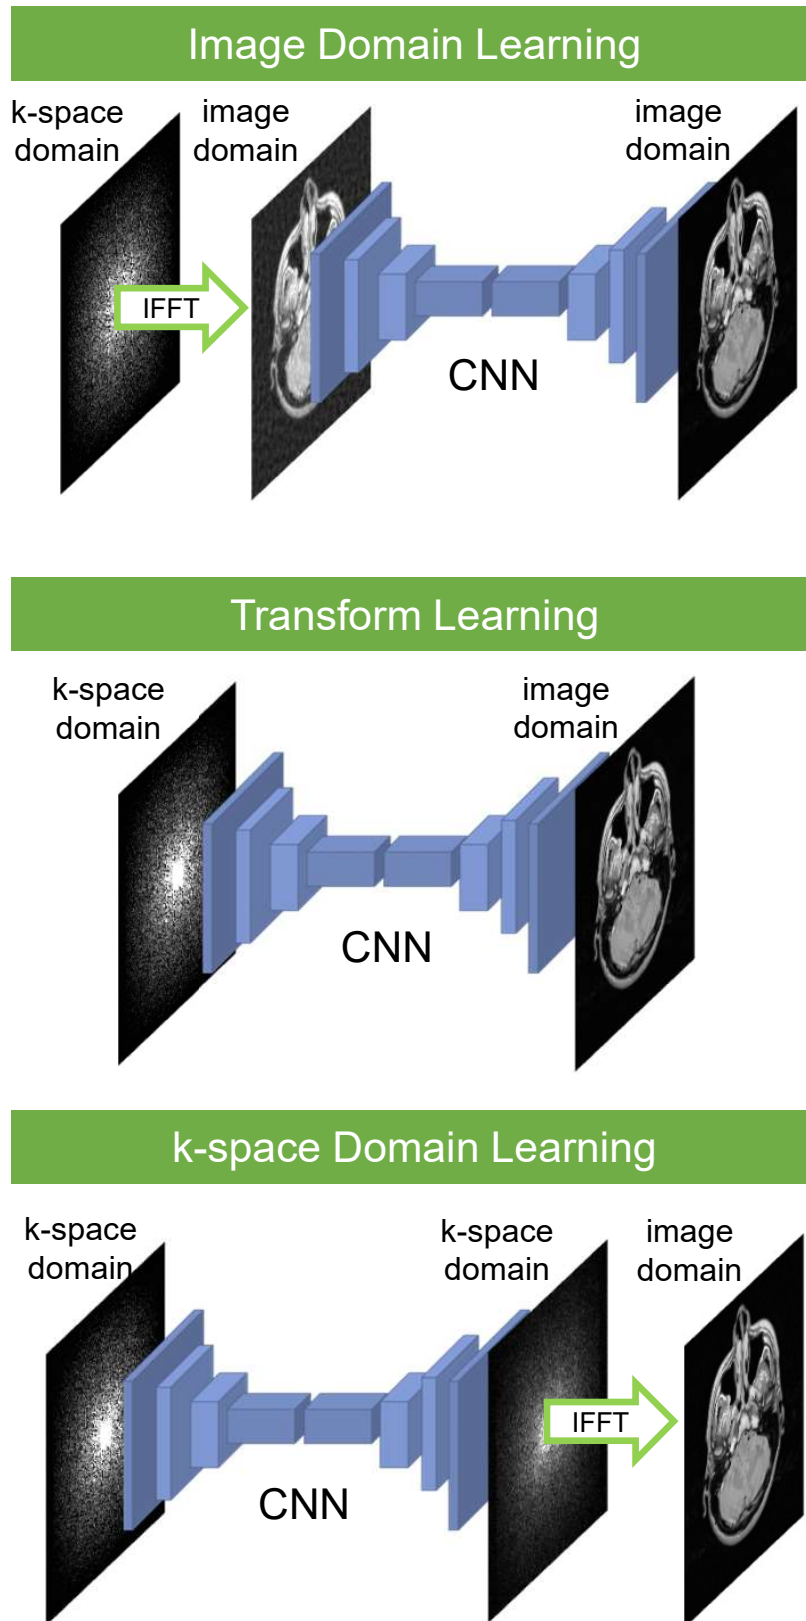


図 4.1: CNN-CS の分類

#### 4.1.4 Unrolling-based モデルと End-to-end モデル

CNN-CS は上記の 3 種類に大別できるが、これらの手法はいずれも、CNN 内部に圧縮センシングの反復的アルゴリズムを内包した手法および全ての処理を CNN のみで完結する手法に二分される。前者の手法を Unrolling-based モデルといい、Transform Learning の多くはこれに該当する。また後者の手法を End-to-end モデルといい、Image Domain Learning や k-space Domain Learning の多くはこれに該当する。

#### 4.1.5 マルチコイルへの対応について

MRI では、単一のコイルで信号取得を行う装置と、パラレルイメージングによって複数のコイルで同時に信号取得を行う装置の両方が存在する。また、パラレルイメージングと圧縮センシングは併用が可能なため、CNN-CS では Unrolling-based モデルと End-to-end モデルの違いに関わらず、単一のコイルで収集されたシングルチャンネルのデータに対応した手法<sup>[51][67]</sup>と、複数のコイルで収集されたマルチチャンネルのデータに対応する手法<sup>[73][74][75]</sup>が混在している。マルチチャンネルのデータを、シングルチャンネルのデータのみに対応した手法で再構成する場合には、あらかじめデータを変換してシングルチャンネル化する必要がある。

## 4.2 実関数画像の再構成と複素画像の再構成

MRI で得られる画像は、装置誤差や生体特性を要因として発生したプロトン間の位相差によって、位相情報を持つ複素画像となる。しかし、以下のような要因により、再構成処理においては実関数画像を想定した手法が多く提案されている。

- 一般的な診断では、絶対値化された実関数画像 (強度画像) が用いられるため、撮像直後のデータは生データであっても、保存の際には絶対値化されることが多い。
- 実関数画像は  $k$  空間のエルミート対称性を満足するため、原点に対して対称となる 2 点のうち 1 点のみを収集すれば、もう一方の点が補完され、見かけ上の間引き点数が削減されること。
- 複素画像の再構成では、強度画像と位相画像を共に推定するか、再構成処理自体を複素数に対応させるかのいずれかの対応が必要であるが、実関数画像は強度画像の推定のみで完結すること。

圧縮センシングのように少数信号から元画像を復元する問題において、精度の高い画像復元や、SWI や QSM 等の位相情報を活用した画像生成法に圧縮センシングを応用することを考慮すると、位相情報を含んだ複素画像で再構成を行えることが望ましい。CNN-CS においても、反復的再構成と同様に実関数画像を想定した手法が多く提案されているが、近年では複素画像に対応した手法も提案されている。ここでは、既存の複素数対応型の手法を、処理方法に応じて次の 2 つに分類する。

### 4.2.1 実部と虚部を分離する手法

複素画像を実部と虚部に分離する手法であり、多くの End-to-end モデルの CNN-CS で採用されている。CNN の入出力チャンネルを 2 ch とすることで実部像と虚部像の同時入力を可能とし、複素画像の再構成に対応する。本手法は最も容易に複素画像に対応できるが、間引き信号から生成したゼロフィル再構成像を実部と虚部に分離する場合、分離した画像は実関数画像となるためエルミート対称性を満たす必要がある。実部と虚部に分離する操作は、 $k$  空間上では 4.4.2 節の式 (4.6)、式 (4.7) で示す操作に相当するが、一般的なランダムな信号間引きパターンを適用した場合には、式 (4.6)、式 (4.7) による分離の処理が正しく行えない。よって、Cole らが指摘しているように<sup>[76]</sup>、これらの手法では複素数の構造を考慮しないため、ネットワーク内部では位相の情報を正しく維持できない可能性がある。エルミート対称性の考慮を不要とする手法として、強度画像と位相画像をそれぞれ CNN で再構成する手法

が Lee らによって提案されているが<sup>[77]</sup>, この手法では CNN を 2 つ用意して独立に学習するため計算コストが上昇するほか, 位相変化の大きな画像では位相分布の推定が困難となる.

#### 4.2.2 複素数型 CNN を用いる手法

2018 年以降は, 複素数に対応した CNN で複素画像を直接扱う手法が提案されている. Unrolling モデルでは, ADMM-CSNet の複素数対応版<sup>[67]</sup> や, ISTA-Net<sup>[66]</sup> を基本とした複素数対応型の CNN が提案されている<sup>[76]</sup>. また, End-to-end モデルでは Trabelsi らの提案する複素数型の手法<sup>[78]</sup> を基本とした CNN<sup>[76][79]</sup> や, カスケード方式の複素数対応型の CNN<sup>[80]</sup> 等が提案されている. これらの手法では, 複素数対応型の CNN の導入により, 実関数型の CNN よりも高品質な再構成を行えたことが報告されているものの, 位相変化への頑健性に関しては検討されていない点や, ほとんどの CNN がレイヤー間でのデータの伝達は複素数で行っているものの, レイヤー内部の畳み込み等では複素画像を実関数画像に分離しているため, 複素数の構造を厳密に維持できていない点が課題である. また, 通常の CNN では畳み込み, 活性化関数, バッチ正規化が利用されるが, これらの複素数対応については, 活性化関数を例にとると modReLU<sup>[81]</sup>, CReLU<sup>[78]</sup>, zReLU<sup>[78]</sup> 等様々な手法が使用されており, 確立的な手法は現状では提案されていない.

#### 4.2.3 本研究で想定する CNN-CS の方式について

本研究では, Image Domain Learning を行う End-to-End モデルの CNN を基本とし, シングルチャンネルのデータを想定した検討を行うこととする. また, 本研究では実関数画像と複素画像の両方を扱うが, 以降に示す通り全ての再構成処理は実関数型 CNN のみで行う.

### 4.3 DRL-CNN

#### 4.3.1 DRL-CNN の概要

Deep Residual Learning Convolutional Neural Network (DRL-CNN) は, 本研究で提案する, 実関数画像の再構成を想定した CNN である. Zhang らは自然画像の雑音除去を目的として, VGG ネットワーク<sup>[82]</sup> を基本とした Denoising Convolutional Neural Network (DnCNN) を提案したが<sup>[11]</sup>, MR 圧縮センシングでは信号の間引き方の工夫によってエイリアシングアーチファクトを雑音状にできる点に着目し, Zhang らの CNN を改良することで, 再構成

に応用した. DRL-CNN は図 4.2 に示すように, 畳み込み, Leaky ReLU, バッチ正規化で構成される平易な構造の CNN である. プーリング等の特徴マップの縮小・拡大のレイヤーを伴わない構造のため, データセットの画像をあらかじめ受容野のサイズに併せてパッチ化(切り出し)して使用することで, 入力画像の全要素を受容野の範囲内に収めている. 残差学習とバッチ正規化の併用による, 高精度な雑音推定を行えることが特徴であり, CNN によらない雑音除去法である Block-Matching and 3D filtering(BM3D)<sup>[83]</sup> や Trainable Nonlinear Reaction Diffusion(TNRD)<sup>[84]</sup>, Weighted Nuclear Norm Minimization(WNNM)<sup>[85]</sup> を上回る雑音除去性能を持つことが Zhang らによって報告されている<sup>[11]</sup>.

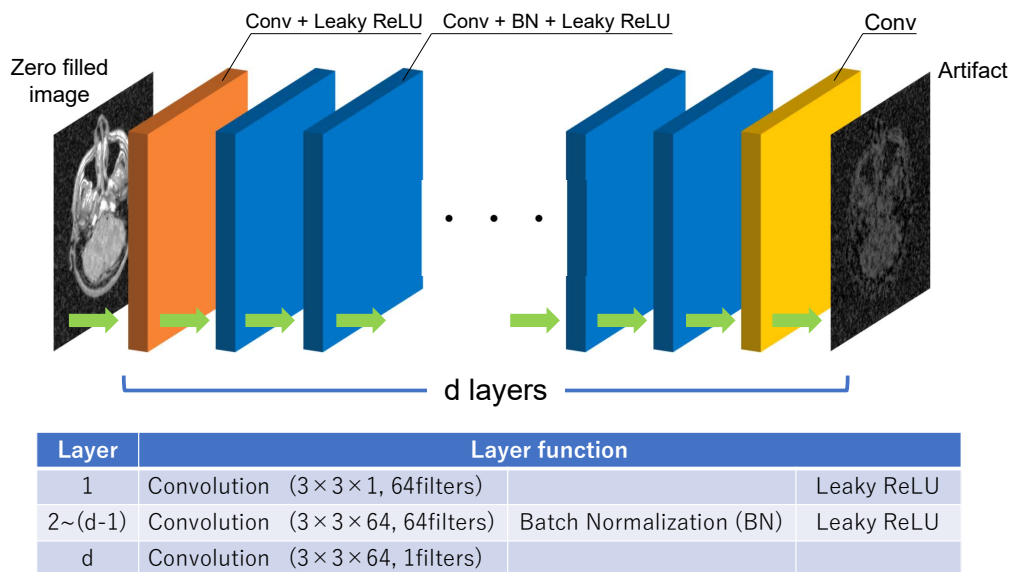


図 4.2: DRL-CNN の基本構造

### 4.3.2 残差学習

残差学習は He らによって提案された, 深層化によって生じる勾配消失問題の解決のために提案された手法である<sup>[86]</sup>. 残差学習を使用した際のネットワーク構造を図 4.3 に示す. 図 4.3(a) の通常の CNN では, ネットワークは入力  $x$  を受けて  $y$  を出力する. 一方で, 図 4.3(b) の残差学習を用いた CNN では, 入力  $x$  をスキップ構造によって畳み込みの出力と接続し, 最終的な出力  $y$  を  $R(x) + x$  としている. これにより畳み込みと ReLU による層は, 実質的に入力と出力の差の成分  $R(x)$  のみを学習する. スキップ構造では順伝播, 逆伝播ともに信号がそのまま伝播されるため, 勾配損失問題を軽減できる.

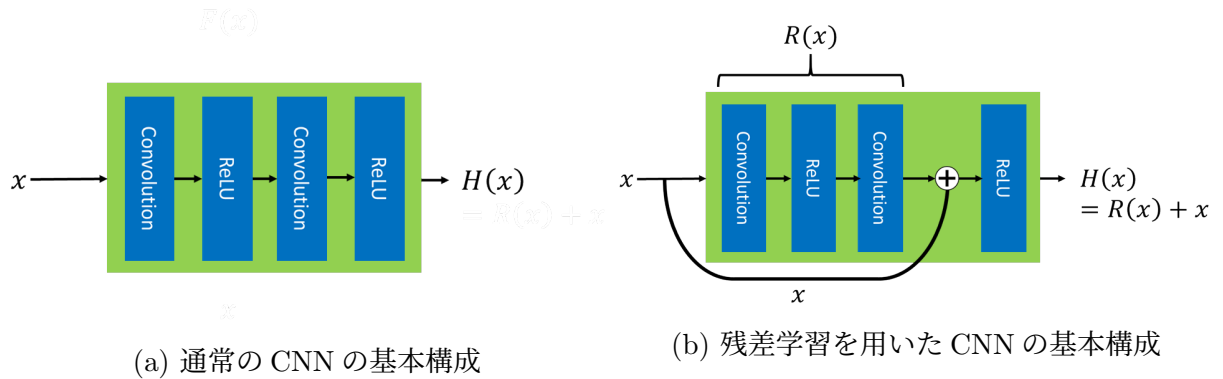


図 4.3: 通常の CNN 構成と残差学習を用いた CNN 構成の比較

ネットワークへの入力と所望の出力を結びつける関数が恒等関数に近いとき、入出力間の残差成分のみを推定する方がネットワークの最適化、すなわちパラメータの更新が容易であることが Zhang らによって報告されている [11]。雑音を含む画像と雑音を含まない画像はその近似度が高いため、画像の雑音除去問題においては残差学習が適している。このため DRL-CNN では残差学習を利用して、エイリアシングアーチファクトを含む入力画像  $x$  からアーチファクト成分  $R(x)$  のみを推定し、これを  $x$  から差し引くことで再構成像  $y$  を得る。

### 4.3.3 受容野と CNN 層数

図 4.2 より、DRL-CNN における畳み込みフィルタのサイズは  $3 \times 3$  である。畳み込みにより、ある層の  $3 \times 3$  の領域が次の層の 1 画素を構成することとなる。この関係を一般化すると、CNN の層数を  $d$  としたときの入力層の受容野の大きさは  $(2d + 1) \times (2d + 1)$  で与えられるため、この大きさを基準としてデータセットの画像をパッチ化する必要がある。パッチ化の際には畳み込みと同様にストライドを定めておく必要がある。

### 4.3.4 DRL-CNN による圧縮センシング再構成の概要

本研究では、ゼロフィル再構成像に重畳されたエイリアシングアーチファクトを DRL-CNN によって推定し、ゼロフィル再構成像から差し引くことで Image Domain Learning による再構成を実現する。また DRL-CNN による再構成処理に加えて、再構成像の信号に対して誤差軽減処理を行うことで再構成像の高品質化を図る、データ整合性処理 (Data Consistency) についても併せて検討する。これら 2 段階の処理を図 4.4 に示す。

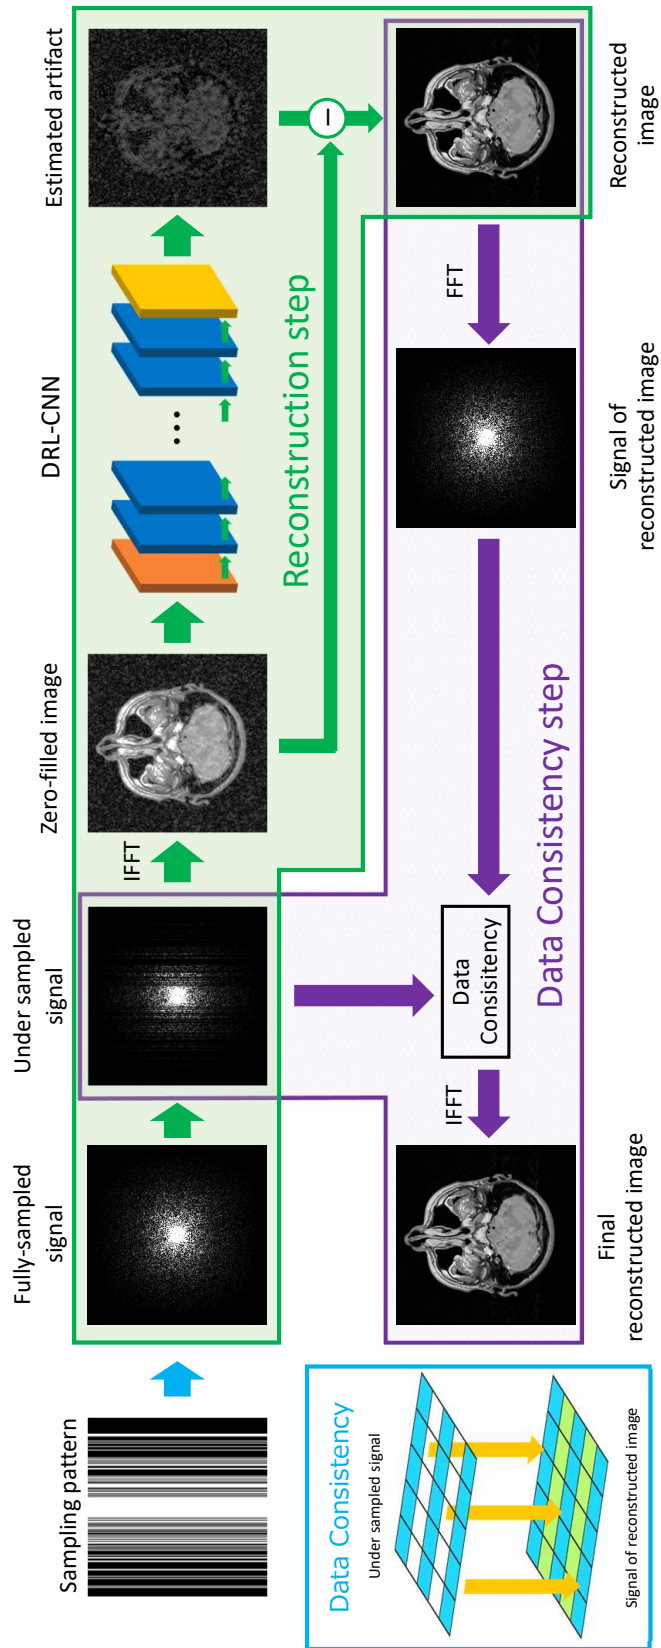


図 4.4: DRL-CNN による MR 圧縮センシング再構成の処理

## 4.3.4.1 再構成処理

最初に、全信号によって再生されたフルデータ像  $m$  にフーリエ変換  $F$  を行って MR 信号を得る。この MR 信号に対して、計算機上で間引きパターン  $P$  に従った信号間引き処理を行う。ここで、間引きパターン  $P$  は信号収集点を 1、非収集点を 0 で表す行列とする。次に、間引きを行った MR 信号を充填した  $k$  空間上の信号未収集点にゼロデータを補って、逆フーリエ変換  $F^H$  を行うことで、ゼロフィル再構成像  $\hat{m}$  を得る。

$$\hat{m} = F^H P F m \quad (4.1)$$

このとき、ゼロフィル再構成像  $\hat{m}$  にはエイリアシングアーチファクト  $v$  が発生する。本研究ではゼロフィル再構成像  $\hat{m}$  を、フルデータ像  $m$  (全信号を充填した  $k$  空間の逆フーリエ変換像) にエイリアシングアーチファクト  $v$  が重畳された状態、すなわち式 (4.2) であると仮定する。

$$\hat{m} = m + v \quad (4.2)$$

また、ゼロフィル再構成像  $\hat{m}$  がフルデータ像  $m$  に近似している (すなわち、 $\hat{m} \approx m$ ) と仮定する。これらの仮定の下で、DRL-CNN をエイリアシングアーチファクト  $v$  を推定する関数  $R$  として使用すれば、DRL-CNN にゼロフィル再構成像  $y$  を与えることで、エイリアシングアーチファクト  $v$  が推定 ( $R(\hat{m}) \approx v$ ) できる。これをゼロフィル再構成像  $\hat{m}$  から差し引くことで、フルデータ像に近似した再構成像  $m'$  を得る。

$$m' = \hat{m} - R(\hat{m}) \quad (4.3)$$



#### 4.3.4.2 データ整合性処理

収集された MR 信号は雑音を含んでいるが、確からしいので図 4.4 の Reconstruction Step で得られた再構成像の  $k$  空間 ( $Fm'$ ) の当該箇所を置換する。置換処理後の信号に逆フーリエ変換を行うことで、最終的な再構成像  $\hat{m}'$  を得る。式 (4.4) の  $I$  は単位行列である。

$$\hat{m}' = F^H \{PFm + (I - P)Fm'\} \quad (4.4)$$

データ整合性処理により、推定信号と収集信号との差分の二乗平均誤差が減少し、再生像の品質を改善することができる。

## 4.4 複素画像に対応した実関数型 CNN

### 4.4.1 本手法の概要

この手法は、本研究で提案する、複素画像の再構成を想定した実関数型 CNN である。この CNN は、Ronneberger らが提案した U-Net<sup>[46]</sup> を基本としており、次節に示す処理によって、複素画像を実部と虚部に分離した上で、分離後の画像から再構成を行う。CNN は図 4.5 に示した構造のとおり、畳み込み、ReLU、バッチ正規化、プーリング (pooling)、逆プーリング (unpooling) から構成されており、図中の左側は入力画像から特徴を抽出するエンコーダ、右側は抽出された特徴を基に教師データを再現するデコーダから構成されている。U-Net では、エンコーダにプーリング、デコーダに逆プーリングを用いることで、特徴マップのサイズが変化する。そのため、入力画像全体を CNN の受容野にできるため、DRL-CNN のような小領域ごとの切り出しが不要となる。エンコーダ・デコーダ間で特徴マップのサイズが等しくなるレイヤー間では、連結構造 (concatenate) によりエンコーダ側の出力信号がデコーダ側に連結される。この構造により、エンコーダ側のプーリングによって失われた画像の細かな情報がデコーダ側に伝播され、画像の特徴を保存できる。また、入力層と出力層の間にはショートカット接続があり、出力層では CNN によって推定した成分に対して入力成分であるゼロフィル再構成像が加算されるため、CNN は実質的にエイリアシングアーチファクトのみを推定する残差学習として機能する。

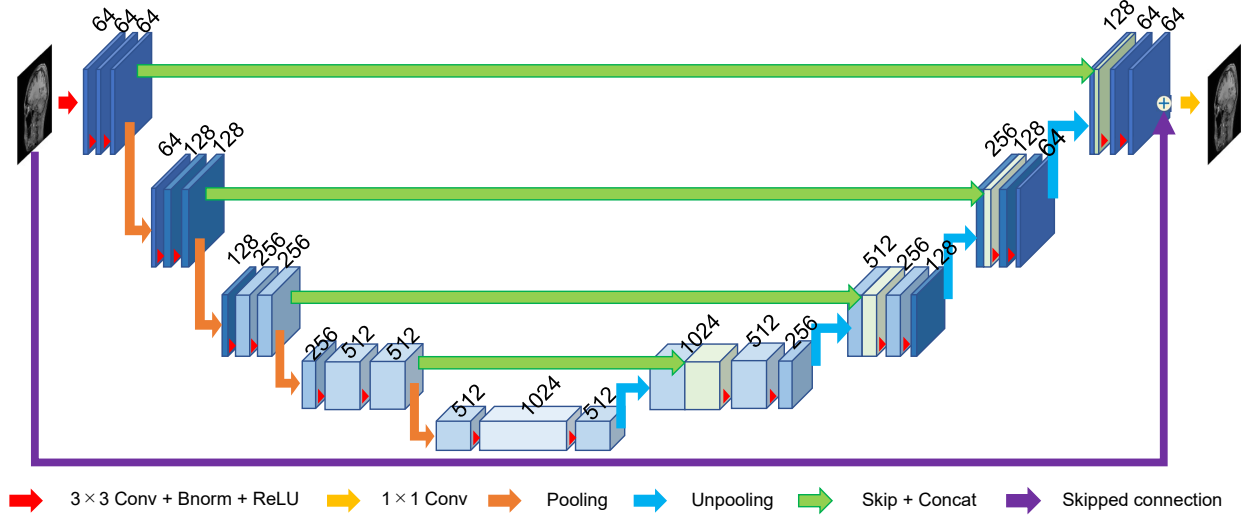


図 4.5: 提案する CNN の基本構造

#### 4.4.2 複素画像の実関数化処理

MR 信号を式 (4.5) とするとき,  $s(\mathbf{k})$  の実部と虚部は式 (4.6), 式 (4.7) によって独立に再生される [87].

$$s(\mathbf{k}) = \int m(\mathbf{r})e^{-j\phi(\mathbf{r})}e^{-j(\mathbf{k}\cdot\mathbf{x})}d\mathbf{r} = \mathbf{F}[m(\mathbf{r})e^{-j\phi(\mathbf{r})}] \quad (4.5)$$

$$F\{\text{Re}[m(\mathbf{r})e^{-j\phi(\mathbf{r})}]\} = \frac{1}{2}F\{m(\mathbf{r})e^{-j\phi(\mathbf{r})} + m(\mathbf{r})e^{j\phi(\mathbf{r})}\} = \frac{1}{2}\{s(\mathbf{k}) + s(-\mathbf{k})^*\} \quad (4.6)$$

$$F\{\text{Im}[m(\mathbf{r})e^{-j\phi(\mathbf{r})}]\} = -\frac{j}{2}F\{m(\mathbf{r})e^{-j\phi(\mathbf{r})} - m(\mathbf{r})e^{j\phi(\mathbf{r})}\} = -\frac{j}{2}\{s(\mathbf{k}) - s(-\mathbf{k})^*\} \quad (4.7)$$

$$s(-\mathbf{k})^* = \int m(\mathbf{r})e^{j\phi(\mathbf{r})}e^{-j(\mathbf{k}\cdot\mathbf{x})}d\mathbf{r} = \mathbf{F}[m(\mathbf{r})e^{j\phi(\mathbf{r})}] \quad (4.8)$$

ここで,  $\mathbf{r} \in \mathbb{C}^N$  を空間ベクトル,  $\mathbf{k} \in \mathbb{C}^N$  を  $k$  空間ベクトルとする. 式 (4.6), 式 (4.7) の計算には, 元の信号  $s(\mathbf{k})$  に加え,  $s(-\mathbf{k})^*$  が必要となる.  $s(-\mathbf{k})^*$  は  $s(\mathbf{k})$  の複素共役であるため,  $s(\mathbf{k})$  から生成可能である. 一方で, 式 (4.6), 式 (4.7) では  $s(\mathbf{k})$  と  $s(-\mathbf{k})^*$  の加減算を必要とするが, この処理を行うには  $s(\mathbf{k})$  において, 図 4.6 に示すようにエルミート対称となる 2 点が共に収集点であることが必要となる. 信号間引きのランダム性を維持しつつ  $k$  空間の原点

に対して対称形となる信号間引きパターンを採用することで、式(4.6)、式(4.7)の計算が可能となる。

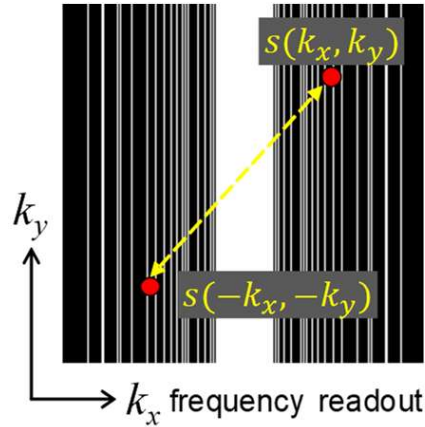


図 4.6: エルミート対称性を満たす信号間引き

#### 4.4.3 実関数化した複素画像によるデータ拡張について

4.4.2節の手法によって分離された複素画像の実部像と虚部像は、撮像によって生じる位相が $-\pi/2$ から $\pi/2$ の範囲となることから、その輝度は正と負の両方の値を持つ。一方で、実部と虚部は同一のスピンドensity分布 $m(\mathbf{r})$ から生成される画像であるため、これら2枚の画像は、同一の被写体を異なる輝度分布で表現した画像と捉えられる。1枚の複素画像から輝度分布のみが異なる2枚の画像が生成される過程は、CNNの学習において用いられる、1枚の画像に対して回転や変形等の処理を施すことで学習枚数を増加するデータ拡張の処理に類似する。また、実部像と虚部像が正負の輝度変化を持つことに着目すると、これらの輝度を反転した画像が生成でき、反転した画像は新たな輝度分布を持つ画像と捉えられる。この場合、図4.7のように輝度反転により実部像と虚部像が2枚ずつ生成されることから、前述のデータ拡張の概念を発展した新たなデータ拡張法と言える。複素画像のCNN再構成にあたっては、これらの性質を一種のデータ拡張法として導入する。以降では、輝度反転処理 (Pixel value Inversion : PI) を行わずに、1枚の複素画像から生成された実部と虚部の計2枚の画像を基本に学習を行う方式をRI-sepCNN、輝度反転処理を行い、1枚の複素画像から生成した計4枚の画像を基本に学習を行う方式をRI-sepCNN with PIと称する。

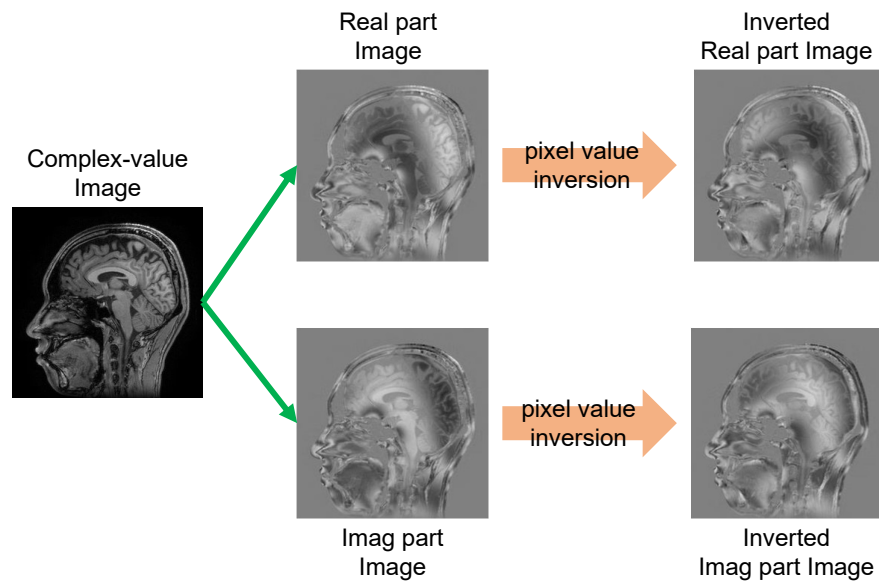


図 4.7: 輝度反転処理による新たな学習用画像の生成

#### 4.4.4 提案法による複素画像の再構成処理の概要

実関数化した複素ゼロフィル再構成像の実部と虚部に重畳されたエイリアシングアーチファクトを RI-sepCNN によって除去することで、Image Domain Learning による再構成を行う。また、RI-sepCNN による再構成処理に加えて、DRL-CNN と同様のデータ整合性処理を行う方法により、信号空間上での誤差軽減を図る。入力から出力を得るまでの処理の流れを図 4.8 に示す。RI-sepCNN では、RGB カラー画像を CNN で扱うときのように、CNN の入力層と出力層をマルチチャンネル (2 ch) とし、実部像と虚部像をそれぞれのチャンネルで処理する。実部像と虚部像は輝度分布が異なるが、同一の被写体を表現した画像であることから、入出力層を除いて中間層ではこれらを区別することなく扱う。これにより、双方の画像が持つ情報を有効に利用した画像推定を図る。RI-sepCNN with PI では、実部像と虚部像の輝度反転画像が存在するが、RI-sepCNN と同様の CNN で、2 ch のうち一方を実部像・輝度反転実部像用として、もう一方を虚部像・輝度反転虚部像用として扱う。したがって、2 ch の入力層に与える画像の組み合わせは常に (実部像・虚部像) もしくは (輝度反転実部像・輝度反転虚部像) のいずれかである。RI-sepCNN と RI-sepCNN with PI における画像と CNN の入出力層との対応関係を図 4.9 に示す。図より RI-sepCNN with PI では、1 枚の複素画像に対して 2 回の再構成処理を行う方式であり、輝度反転画像の併用はチャンネル数の増加ではなくデータセットの要素数を増加する目的で使用される。




図 4.8: 提案する実関数型 CNN による再構成処理

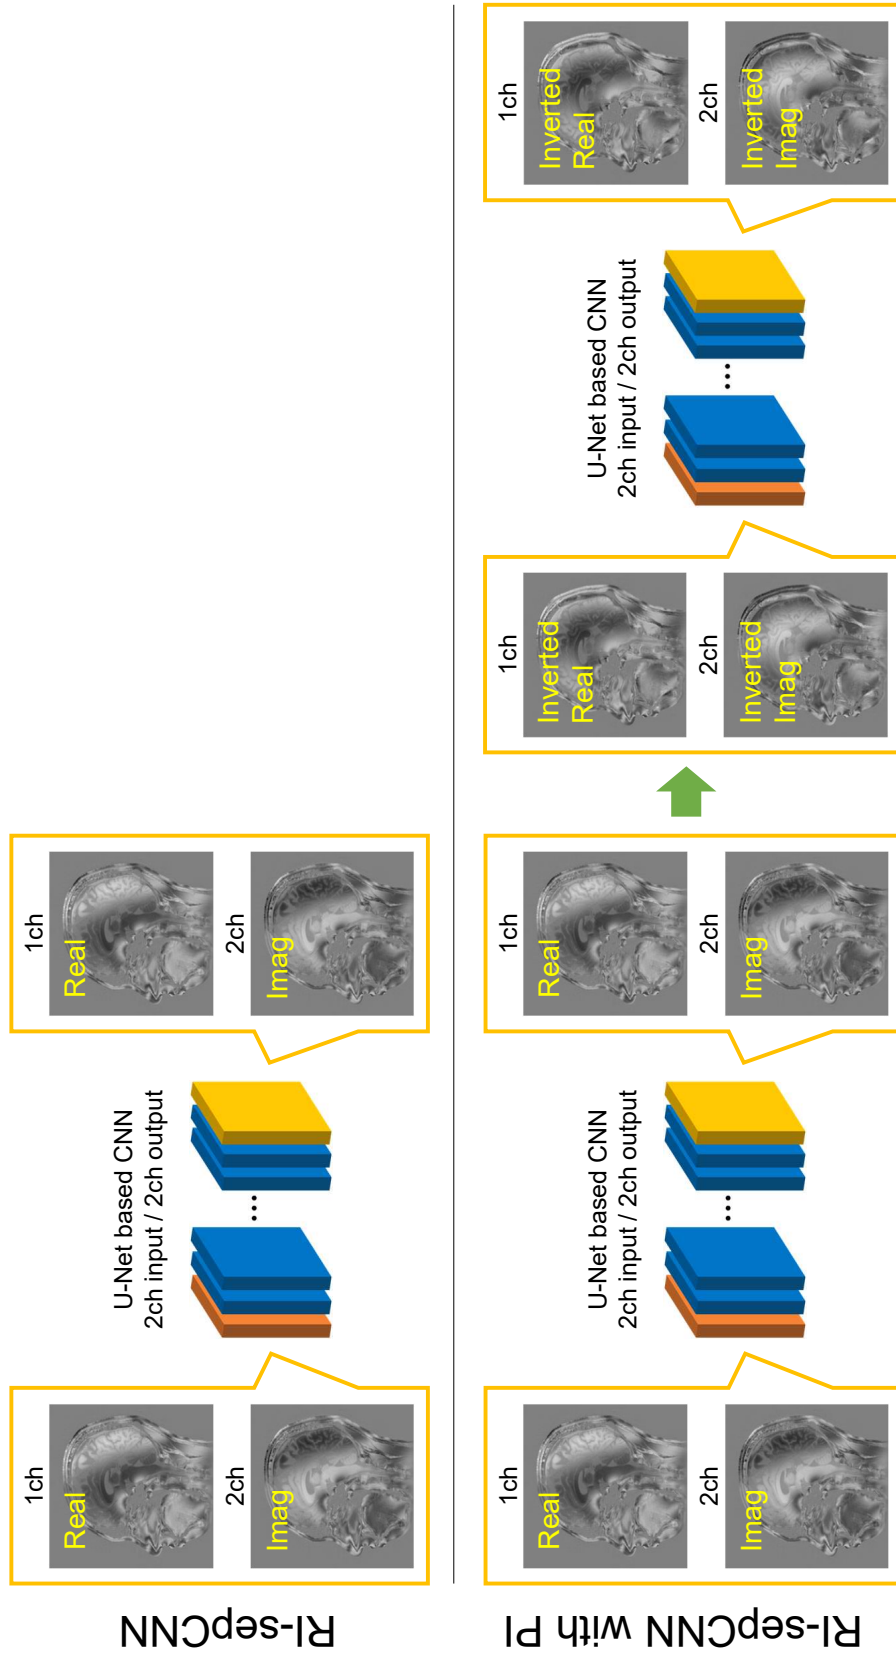


図 4.9: 提案する実関数型 CNN における入出力チャンネル数と輝度反転画像の関係

## 4.4.5 再構成処理

フルデータ像を式 (4.9) とするとき、フルデータ像の実部像と虚部像を式 (4.10)、式 (4.11) とする。また、ゼロフィル再構成像は式 (4.1) と同様に式 (4.12) で与えられ、ゼロフィル再構成像の実部像と虚部像は式 (4.13)、式 (4.14) とする。

$$\mathbf{m} = m(\mathbf{r})e^{-j\phi(\mathbf{r})} \quad (4.9)$$

$$\mathbf{m}_{\text{Re}} = \text{Re}[m(\mathbf{r})e^{-j\phi(\mathbf{r})}] \quad (4.10)$$

$$\mathbf{m}_{\text{Im}} = \text{Im}[m(\mathbf{r})e^{-j\phi(\mathbf{r})}] \quad (4.11)$$

$$\hat{\mathbf{m}}' = F^H P F \{m(\mathbf{r})e^{-j\phi(\mathbf{r})}\} \quad (4.12)$$

$$\hat{\mathbf{m}}'_{\text{Re}} = \text{Re}[\hat{\mathbf{m}}'] \quad (4.13)$$

$$\hat{\mathbf{m}}'_{\text{Im}} = \text{Im}[\hat{\mathbf{m}}'] \quad (4.14)$$

ゼロフィル再構成像の実部像  $\hat{\mathbf{m}}'_{\text{Re}}$  と虚部像  $\hat{\mathbf{m}}'_{\text{Im}}$  の輝度反転画像をそれぞれ  $\hat{\mathbf{m}}'_{\text{InvRe}}$ ,  $\hat{\mathbf{m}}'_{\text{InvIm}}$  として、RI-sepCNN, RI-sepCNN with PI をこれらに生じたエイリアシングアーチファクトを除去する関数  $R$  として使用すれば、これら 4 枚の再構成像は式 (4.15) から式 (4.18) で与えられる。

$$\hat{\mathbf{m}}'_{\text{Re}} = R(\hat{\mathbf{m}}'_{\text{Re}}) \quad (4.15)$$

$$\hat{\mathbf{m}}'_{\text{Im}} = R(\hat{\mathbf{m}}'_{\text{Im}}) \quad (4.16)$$

$$\hat{\mathbf{m}}'_{\text{InvRe}} = R(\hat{\mathbf{m}}_{\text{InvRe}}) \quad (4.17)$$

$$\hat{\mathbf{m}}'_{\text{InvIm}} = R(\hat{\mathbf{m}}_{\text{InvIm}}) \quad (4.18)$$

RI-sepCNN with PI では、式 (4.19)、式 (4.20) によりオリジナルの輝度を持つ画像と輝度反転画像を合成して再構成像を得る。

$$\hat{\mathbf{m}}''_{\text{Re}} = \frac{1}{2} \{ \mathbf{m}'_{\text{Re}} - \mathbf{m}'_{\text{InvRe}} \} \quad (4.19)$$

$$\hat{\mathbf{m}}''_{\text{Im}} = \frac{1}{2} \{ \mathbf{m}'_{\text{Im}} - \mathbf{m}'_{\text{InvIm}} \} \quad (4.20)$$

4.4.2 節では、複素画像から実部と虚部を分離したが、この処理により実部と虚部の  $k$  空間が独立に生成されている。したがって、 $k$  空間の誤差軽減を図るデータ整合性処理は、式 (4.21)、式 (4.22) のように  $\hat{\mathbf{m}}''_{\text{Re}}$  と  $\hat{\mathbf{m}}''_{\text{Im}}$  に対して独立に行うことができる。

$$\hat{\mathbf{m}}_{\text{DC(Re)}} = F^H \{ F \hat{\mathbf{m}}_{\text{Re}} + (I - P) F \hat{\mathbf{m}}''_{\text{Re}} \} \quad (4.21)$$

$$\hat{\mathbf{m}}_{\text{DC(Im)}} = F^H \{ F \hat{\mathbf{m}}_{\text{Im}} + (I - P) F \hat{\mathbf{m}}''_{\text{Im}} \} \quad (4.22)$$

最後に式 (4.23) により、 $\hat{\mathbf{m}}_{\text{DC(Re)}}$  と  $\hat{\mathbf{m}}_{\text{DC(Im)}}$  から再構成像  $\hat{\mathbf{m}}_{\text{DC}}$  を得る。

$$\hat{\mathbf{m}}_{\text{DC}} = \hat{\mathbf{m}}_{\text{DC(Re)}} + i \hat{\mathbf{m}}_{\text{DC(Im)}} \quad (4.23)$$

実部像と虚部像を分離して実関数画像として再構成する手法では、実部像と虚部像に対応する MR 信号が互いにエルミート対称性を満たさない限りデータ整合性処理を適用できないが、本手法で導入する原点对称形となる間引きパターンでは、この条件を満たすため、データ整合性処理による再構成像の高品質化を適用できる。



# 第5章 DRL-CNNによる実関数画像の再構成実験

## 5.1 実験の条件

### 5.1.1 使用する MR 画像

DRL-CNN の学習と、学習した CNN を用いたテストには IXI dataset<sup>[88]</sup> を使用した。IXI dataset は、インペリアル・カレッジ・ロンドンのバイオメディカル画像解析グループ (Biomedical Image Analysis Group) が公開する頭部 MR 画像のデータセットであり、含まれる画像は絶対値化処理を経た実関数画像である。Information eXtraction from Images プロジェクトの一環として、ロンドン市内の 3 つの医療機関から集められた、健常な被験者 600 名 (各人につき約 130 の頭部断面) の  $T_1$  強調像,  $T_2$  強調像, プロトン密度強調像, MRA, 拡散テンソル画像が含まれている。上記のうち本研究では, Guy's hospital にて Philips Intera(1.5 T) で撮像されたプロトン密度強調像 (PDW 像) を使用した。PDW 像の撮像条件を表 5.1 に示す。

表 5.1: 使用した画像の撮像条件

TR [ms]	8178.34
TE [ms]	8
位相エンコードステップ数	187
エコートレイン長	16
フリップ角 [°]	90

これらの画像は、画像空間で外周部にゼロデータを充填することで画像サイズを  $256 \times 256$  としている。

### 5.1.2 間引きパターン

2次元の撮像を仮定した場合、間引き処理は位相エンコード方向と周波数エンコード方法の2方向に対して行える。これら2方向のうち、信号収集に時間を要するのは位相エンコード方向のみであることから、一般に、位相エンコード方向の収集のみを間引くパターンが採用されている。一方で、エイリアシングアーチファクトは間引きを行った方向に対して発生するものであり、間引きをランダムに行った場合にはアーチファクトのインコヒーレント性も高くなる。そのため、位相、周波数の両方向をランダムに間引くパターンでは、アーチファクトのランダム性が最も高くなる。また、3次元の撮像では、位相、周波数方向に加えてスライス方向を考慮する必要があるが、この場合では2次元方向にランダムな間引きを行うことが可能であり、このとき発生するアーチファクトは2次元撮像において位相、周波数の両方向を間引いた場合のアーチファクトに近似する。これらの理由から、本検討では位相エンコード方向のみをランダムに間引く1次元ランダム間引きに加え、位相エンコード方向と周波数エンコード方向を共にランダムに間引く2次元ランダム間引きの2通りの間引き法を採用した。いずれの収集法においても、 $k$ 空間の中心部は信号エネルギーが集中するため、間引きを行わずに連続的に収集する。2次元ランダム収集では $k$ 空間中心部の半径14画素分の円形領域を、1次元ランダム収集では中心部50行を連続的に収集した。実際に使用した間引きパターンを図5.1、図5.2に示す。2つの間引き法ともに、収集信号比が30%、40%、50%となる間引きパターンをそれぞれ用意した。

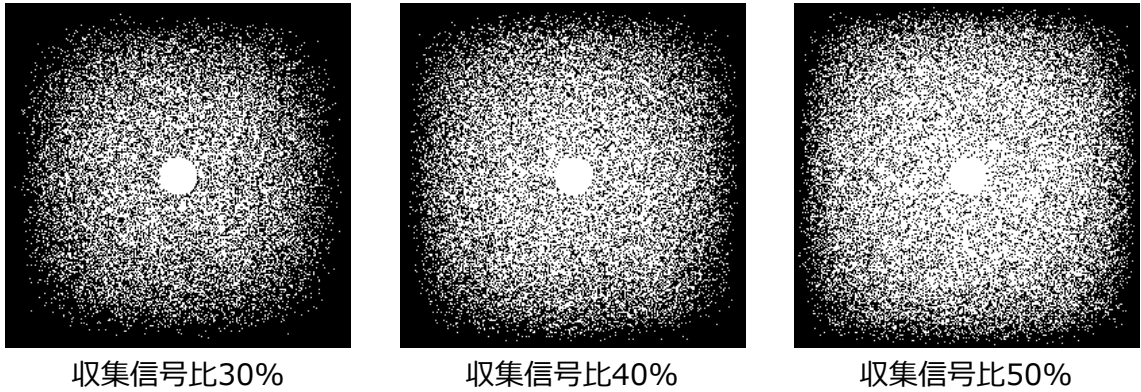


図 5.1: 実際に使用した 2 次元ランダム収集の間引きパターン



図 5.2: 実際に使用した 1 次元ランダム収集の間引きパターン

### 5.1.3 反復的再構成法との比較

DRL-CNN の再構成像の品質および再構成時間の比較検討を行うため、本検討では反復的再構成法である ISTA<sup>[6]</sup>, Split Bregman<sup>[35]</sup> および ADMM の一種である C-SALSA-B<sup>[38]</sup> による再構成を行った。Split Bregman および C-SALSA-B のアルゴリズムを以下に示す。以下のアルゴリズムにおいて、 $S_\tau$  は閾値  $\tau$  によるソフト閾値関数である。三手法ともに、スパース化変換  $\Psi$  には係数 6 の Daubechies 基底を用いたウェーブレット変換を採用し、ソフト閾値関数の閾値は、画像中の雑音の標準偏差の推測値  $\sigma_n$  を基に  $\tau = 2\sigma_n$  とした。また、C-SALSA-B における補助変数  $\alpha, z, h, d$  は  $n = 0$  における初期値をそれぞれ  $\alpha_0 = z_0 = h_0 = d_0 = 0$  とし、重み係数をそれぞれ  $\mu = 0.5, \rho = 1, \gamma = 0.5, \delta_h = \delta_d = 1$  に設定した。Split Bregman にお

ける補助変数  $x, \alpha, b$  は  $n = 0$  における初期値をそれぞれ  $x_0 = \alpha_0 = b_0 = 0$  とし, 重み係数は  $\mu = 1$  に設定した.

---

**Algorithm 1** Algorithm for C-SALSA-B

---

- 1:  $n = 1$
- 2: repeat
- 3:  $\alpha_{n+1} = \frac{\mu}{\mu + \rho} \Psi F^* P^*(y + h_n) + \gamma(z_n + d_n) + \Psi F^* \left[ (1 - \gamma)I - \frac{\mu}{\mu + \rho} U^* U \right] F \Psi^*(z_n + d_n)$
- 4:  $z_{n+1} = S_{\tau_s}(\alpha_{n+1} - d_n)$
- 5:  $h_{n+1} = h_n - \delta_h(PF\Psi^*\alpha_{n+1} - y)$
- 6:  $d_{n+1} = d_n - \delta_d(\alpha_{n+1} - z_{n+1})$
- 7:  $n = n + 1$
- 8: until converge

**Output:**  $\Psi^*\alpha_n$

---



---

**Algorithm 2** Algorithm for Split Bregman

---

- 1:  $n = 1$
- 2: repeat
- 3:  $x_{n+1} = \frac{1}{2\mu + 1} F^* y + (I - \frac{1}{2\mu + 1} F^* P^* P F) \Psi^*(\alpha_n - b_n)$
- 4:  $\alpha_{n+1} = S_{\tau_b}(\Psi x_{n+1} + b_n)$
- 5:  $b_{n+1} = b_n + \Psi x_{n+1} - \alpha_{n+1}$
- 6:  $n = n + 1$
- 7: until converge

**Output:**  $\Psi^*\alpha_n$

---

#### 5.1.4 計算機環境と実行環境

本研究における CNN の学習, テストならびに反復処理による反復的再構成プログラムの実行には, Intel Core i7-9700K CPU (3.60GHz), NVIDIA GeForce RTX 2080 Ti GPU(CUDA9.0, cuDNN7.0.5) を使用した. また, CNN の学習, テストおよび反復的再構成プログラムは Matlab R2017b で実行し, CNN の構築には MatConvNet(1.0-beta25) を使用した [89].

#### 5.1.5 再構成像の品質評価法

本研究では, 再構成像の品質評価に PSNR(Peak Signal-to-Noise Ratio) と SSIM<sup>[52]</sup>(Structural SIMilarity index) を採用した.

#### 5.1.6 PSNR

PSNR は, 2 枚の画像間の輝度値の差を元に算出される指標である. フルデータ像を  $\rho(x, y)$ , 再構成像を  $\rho'(x, y)$  とした場合の画像間の平均二乗誤差 (Root Mean Squared Error: RMSE) を式 (5.1),  $\rho(x, y)$  の最大輝度値  $\rho_{max}$  を式 (5.2) としたとき, PSNR は式 (5.3) で与えられる.

$$\text{RMSE} = \left[ \frac{1}{N} \sum \{ |\rho'(x, y)| - |\rho(x, y)| \}^2 \right]^{\frac{1}{2}} \quad (5.1)$$

$$\rho_{max} = \text{MAX} [|\rho(x, y)|] \quad (5.2)$$

$$\text{PSNR} = 20 \log \left( \frac{\rho_{max}}{\text{RMSE}} \right) \text{ [dB]} \quad (5.3)$$

なお, MR 画像において画像の被写体以外の箇所は無信号領域であり, 評価に含める必要はない. そこで最大輝度値  $\rho_{max}$  の 8% 以下の輝度値の画素に関しては評価対象から除外した. 式 (5.1) 中の  $N$  は除外対象の画素を差し引いた評価対象の画素数を示している.

### 5.1.7 SSIM

SSIM<sup>[52]</sup> は、2つの画像間での対応する局所領域内での輝度値、コントラスト、構造の相似性を元に算出される指標である。注目画素とその周辺の  $11 \times 11$  画素を1つの領域とし、フルデータ像を  $X$ 、再構成像を  $Y$  とした場合の、領域内の各画素値の平均  $\mu_X, \mu_Y$ 、標準偏差  $\sigma_X, \sigma_Y$ 、相互相関  $\sigma_{XY}$  から、注目領域の輝度値  $l(X, Y)$ 、コントラスト  $c(X, Y)$ 、構造  $s(X, Y)$  の相似性を導出する。この3要素の総合的な相似性  $S(X, Y)$  を式 (5.4) によって注目画素ごとに求め、各  $S(X, Y)$  を平均することで SSIM を得る。

$$\begin{aligned} S(X, Y) &= l(X, Y) \cdot c(X, Y) \cdot s(X, Y) \\ &= \left( \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1} \right) \cdot \left( \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2} \right) \cdot \left( \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3} \right) \end{aligned} \quad (5.4)$$

ここで、 $S(X, Y)$  における  $C_1, C_2, C_3$  は発散を防ぐための正の定数であり、画像の最大輝度値を  $L$  としたとき式 (5.5) で与えられる。

$$\begin{aligned} K_1 &= 0.01, K_2 = 0.03 \\ \begin{cases} C_1 = (K_1L)^2 \\ C_2 = (K_2L)^2 \\ C_3 = C_2/2 \end{cases} \end{aligned} \quad (5.5)$$

### 5.1.8 CNN の学習条件

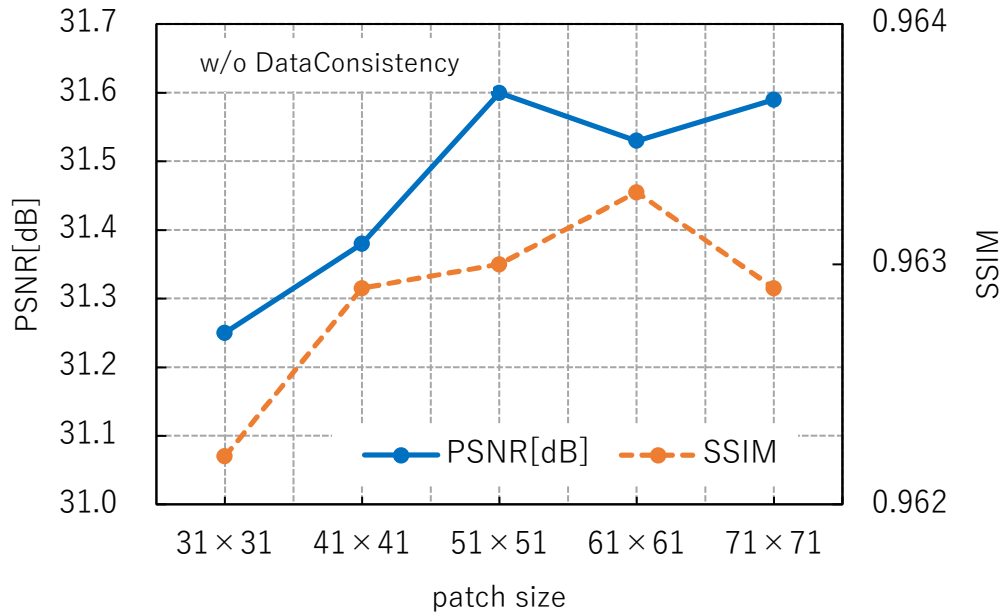
DRL-CNN の学習の際に用いた条件を表 5.2 に示す。エポック数に関しては、これまでの予備的な検討より 25 エポック以内に損失関数がおおむね収束することを確認している。

表 5.2: CNN の学習に適用した条件

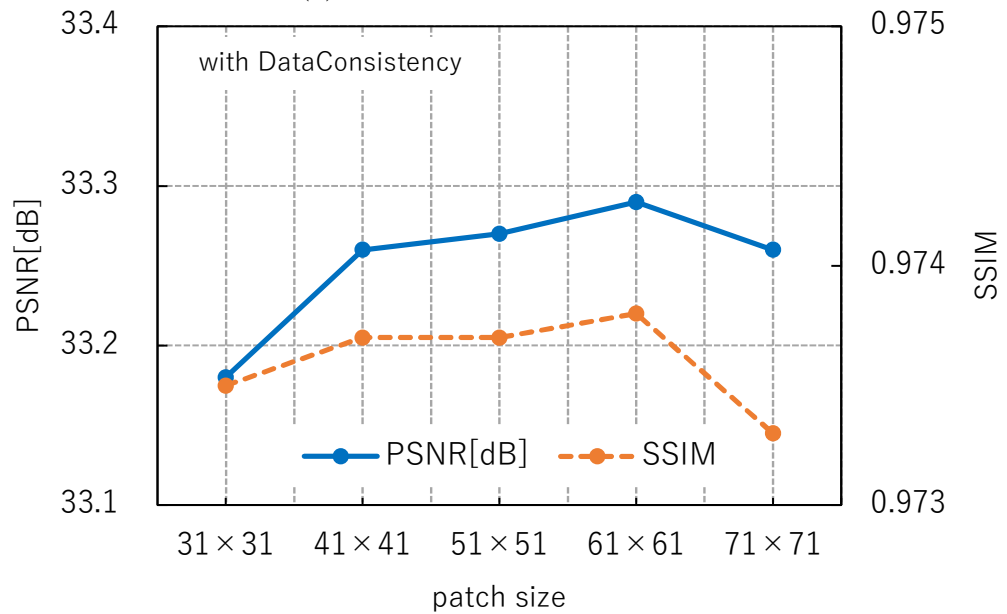
オプティマイザー	Adam
損失関数	画像空間での MSE
エポック	25

## 5.2 DRL-CNN の CNN 構造の検討

DRL-CNN では、CNN に与える画像をパッチとして切り出すことで、入力層の受容野のサイズと画像のサイズを一致させている。CNN の層数を  $d$ 、カーネルサイズを  $3 \times 3$  とするとき、入力層の受容野の大きさは  $(2d + 1) \times (2d + 1)$  で与えられる。DnCNN の考案者である Zhang らは自然画像の雑音除去において、重畳される雑音レベルが未知の場合には、既知の場合よりも受容野が大きくなるようにパッチサイズを設定している<sup>[11]</sup>。本研究における除去の対象はエイリアシングアーチファクトであり、ガウス雑音とは性質が異なる。本検討では、 $31 \times 31$  から  $71 \times 71$  の範囲でパッチサイズを変更して CNN を学習し、再構成処理の性能を比較した。本検討で使用したデータセットは、学習枚数 300 枚、テスト枚数 40 枚、収集信号比を 40% とした 1 次元ランダム収集の PDW 像である。なお、パッチ化の際のストライドは、パッチサイズの約 3 分の 1 で統一した。図 5.3 にそれぞれのパッチサイズで CNN を学習した際の、再構成像の PSNR と SSIM の平均値を示す。パッチサイズが  $61 \times 61$ 、層数  $d$  が 30 のときに良好な結果を示していることから、以降の DRL-CNN による圧縮センシング再構成の検討は、パッチサイズを  $61 \times 61$  (ストライド 20) に、層数を 30 に設定して行った。



(a) データ整合性処理なしの場合



(b) データ整合性処理ありの場合

図 5.3: 1次元ランダム収集におけるパッチサイズの検討結果



### 5.3 学習枚数の検討

DRL-CNN の学習に利用する画像枚数と再構成像の品質の関係性を比較するため、画像枚数を様々に変えたデータセットを作成し、DRL-CNN の学習と再構成を行った。DRL-CNN の学習に用いる画像の最大枚数は、学習時間を考慮して 2500 枚とした。この 2500 枚には、1 名あたり 100 断面分の画像（100 枚）が 25 名分含まれている。本検討では、25 名分から 1, 3, 5, 10, 15, 20, 25 名分をそれぞれ抽出してデータセットを作成した。40 枚の MR 画像で構成したテストデータセットに対して、それぞれの学習データセットを学習したネットワークを適用し、再構成を行った。また、本検討で使用する間引きパターンは、収集信号比 40% の 1 次元、2 次元ランダム収集とした。

図 5.4 と図 5.5 に学習枚数と PSNR と SSIM の関係を、図 5.6 と図 5.7 に再構成像を示す。1 次元および 2 次元ランダム収集のいずれにおいても、学習枚数の増加によって PSNR と SSIM が上昇し、学習枚数が 300 枚以上のとき 1 次元ランダム収集の PSNR が Split Bregman を上回る結果が得られた。再構成像では、学習枚数が増えるにつれて、データ整合性処理を適用しない場合でもアーチファクトが減少する傾向がみられた。データ整合性処理を適用した場合には、被写体構造の保存性能が改善する傾向がみられた。各種の学習枚数における CNN の学習に要した時間を表 5.3 に示す。

表 5.3: DRL-CNN の学習枚数と学習時間

学習枚数	学習時間 [分]
100	38
300	100
500	163
1000	338
1500	500
2000	675
2500	813

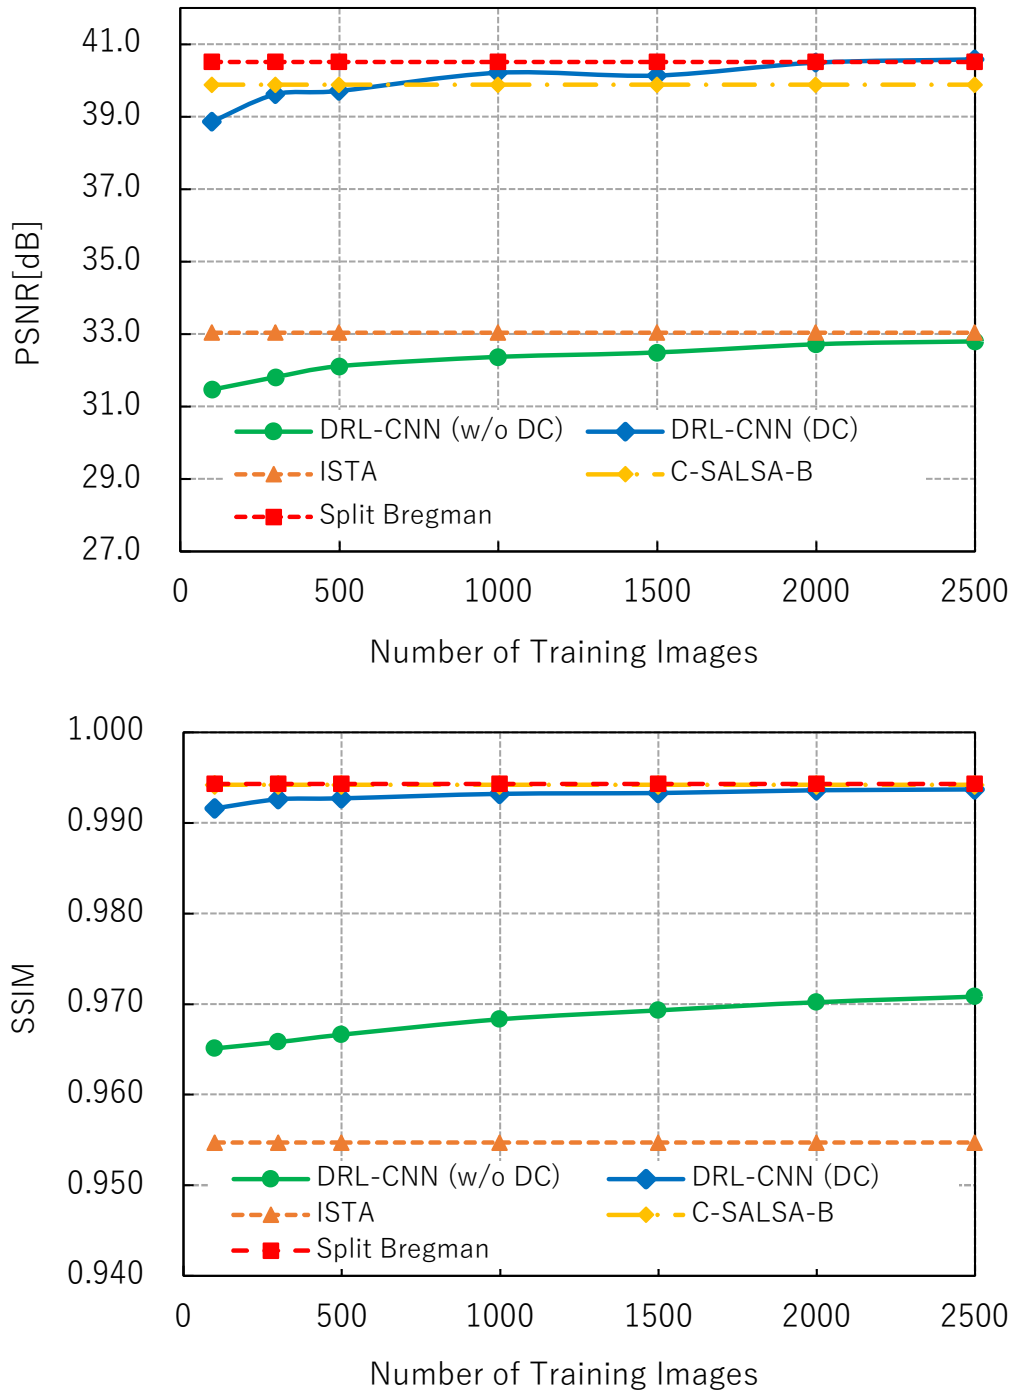


図 5.4: 各学習枚数における再構成像の PSNR と SSIM (2次元ランダム収集)

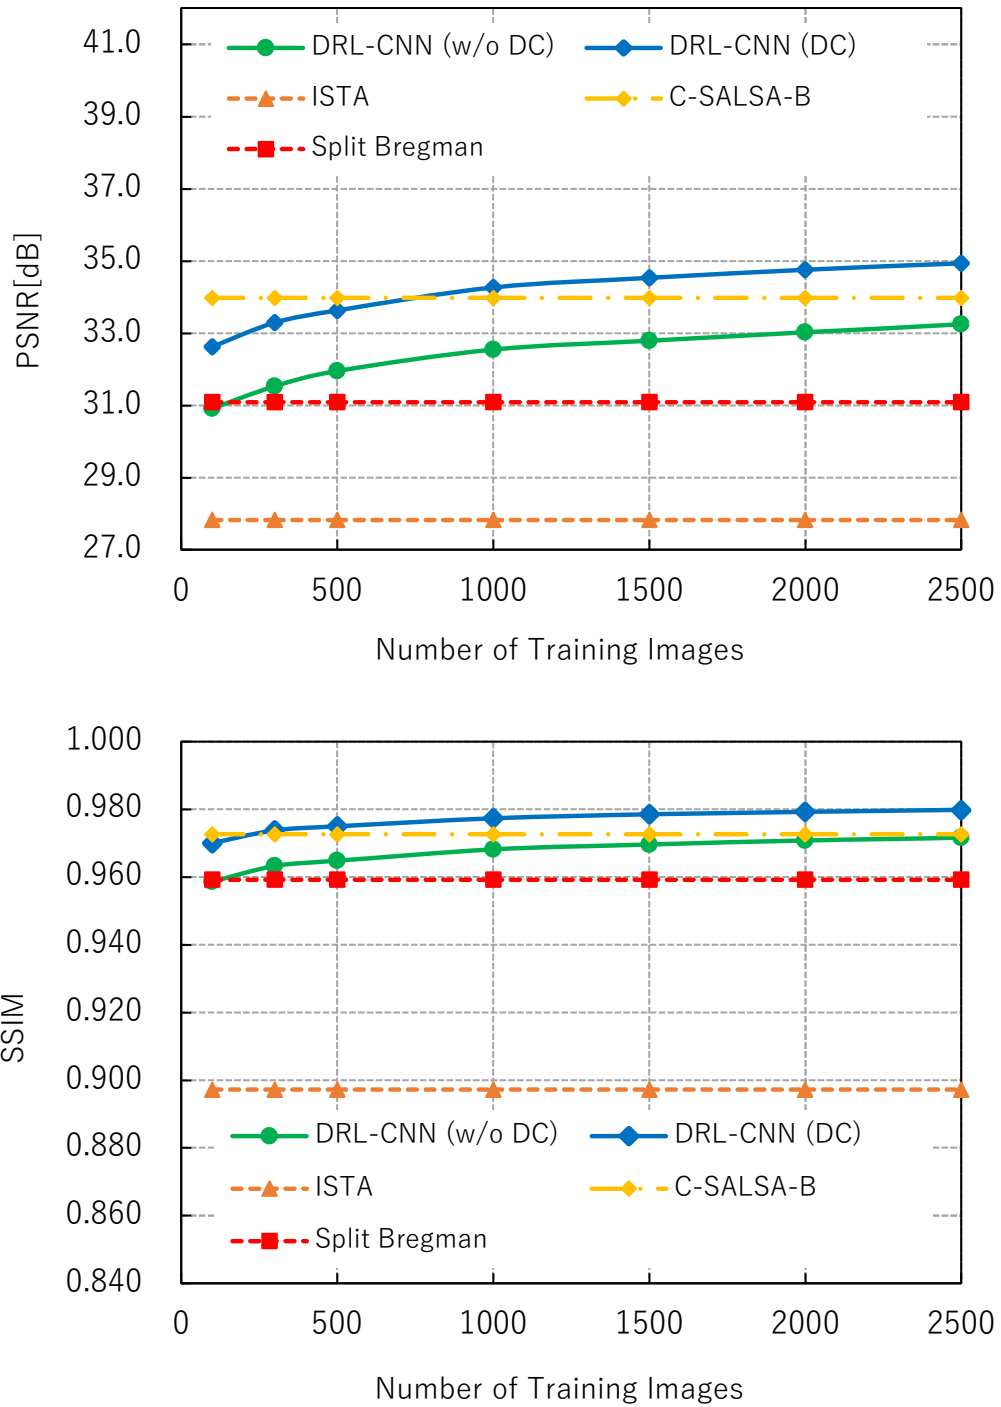


図 5.5: 各学習枚数における再構成像の PSNR と SSIM (1次元ランダム収集)

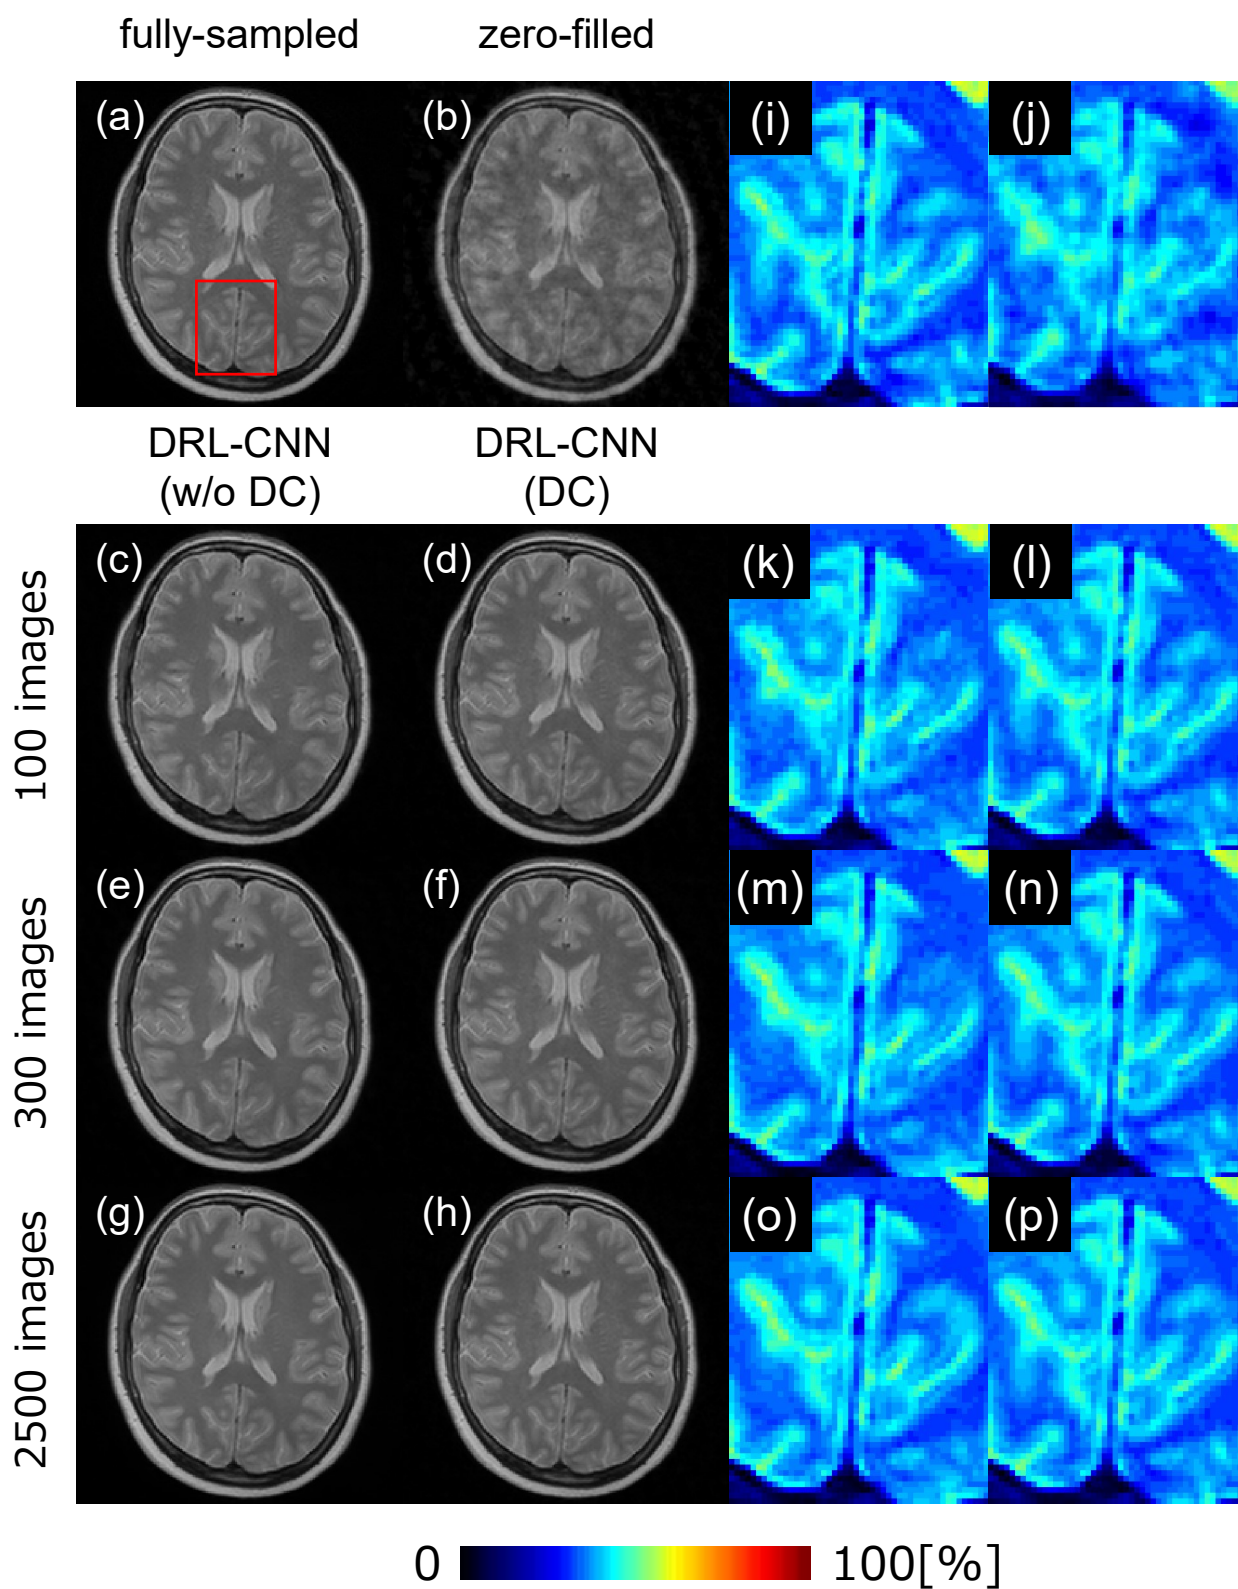


図 5.6: 各学習枚数における再構成像 (2次元ランダム収集)

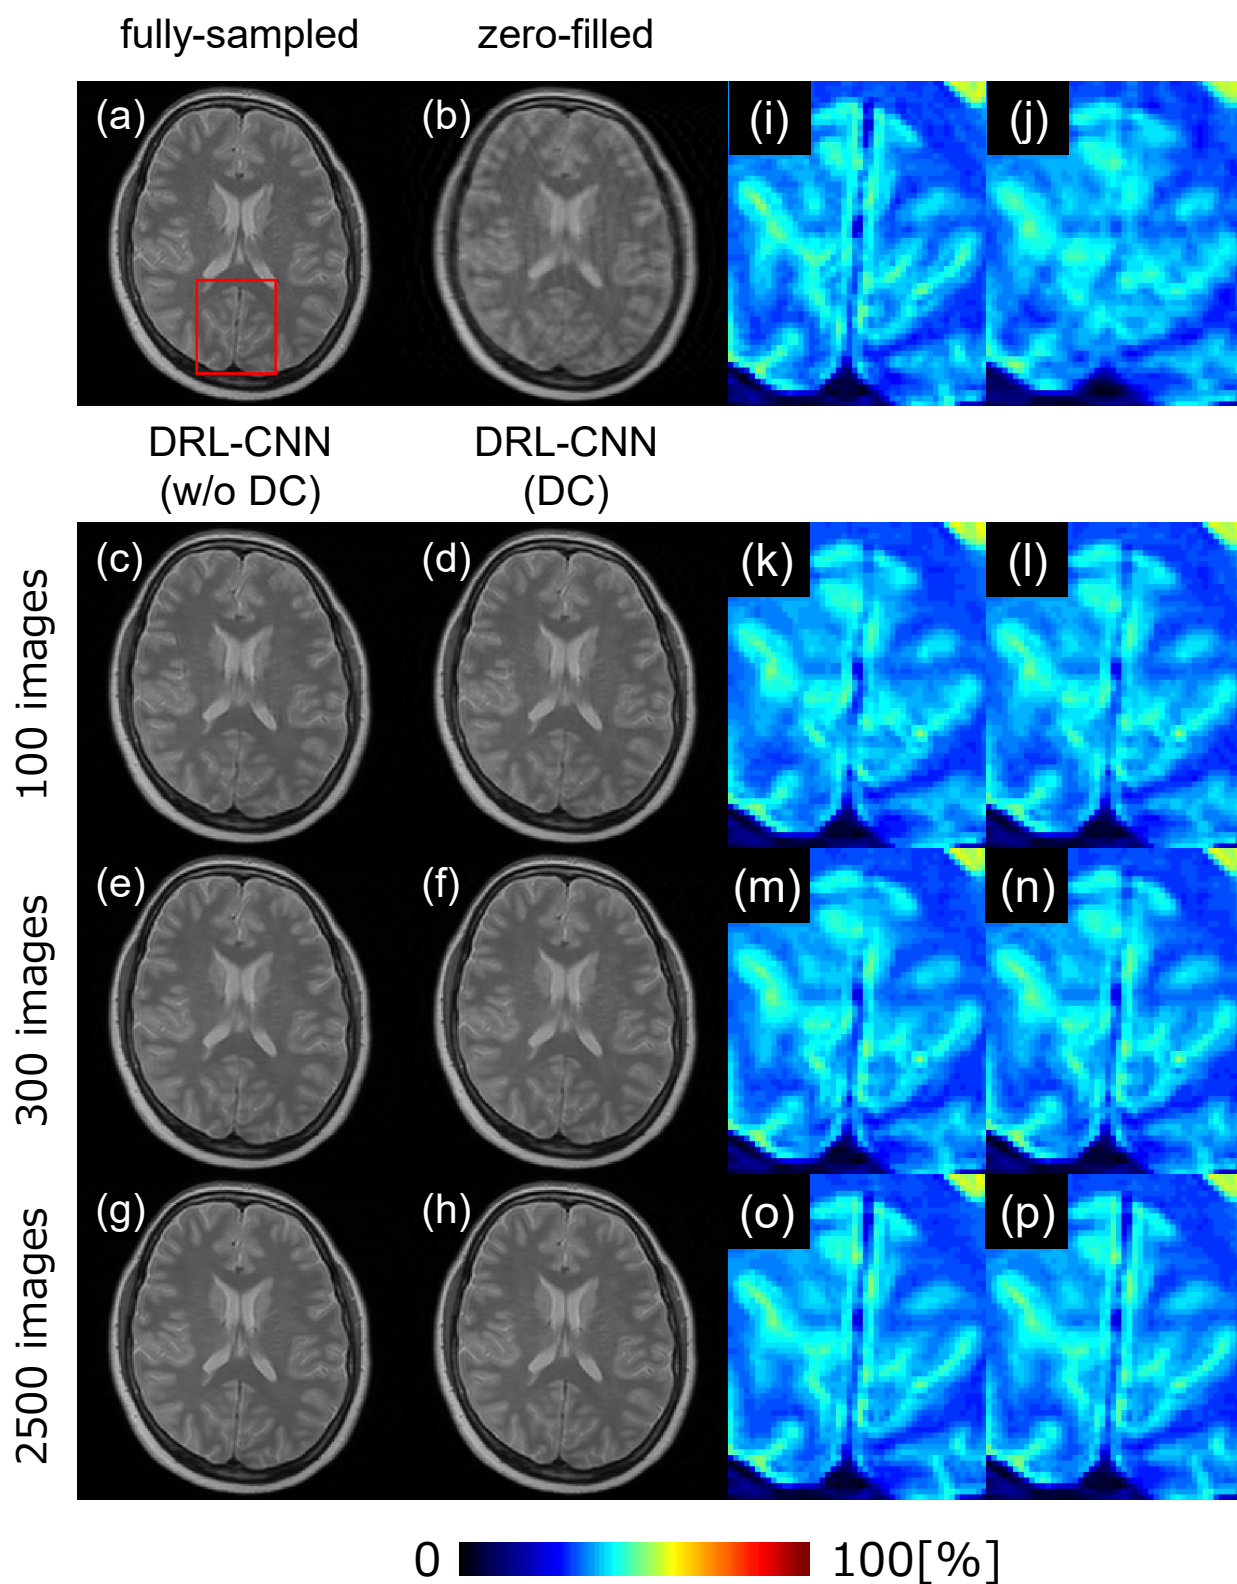


図 5.7: 各学習枚数における再構成像 (1次元ランダム収集)

## 5.4 収集信号比の検討

DRL-CNN と反復的再構成法の 2 つの方法において、収集信号比と再構成像の品質の関係性を比較した。本検討では、収集信号比を 30%、40%、50% と変化させて画像再構成実験を行った。学習には 2500 枚、テストには 40 枚を使用している。図 5.8 と図 5.9 にそれぞれの収集信号比での PSNR と SSIM の結果を示し、図 5.10 から図 5.15 に再構成像を示す。PSNR と SSIM は CNN による再構成法、反復的再構成法ともに、40 枚のテスト画像による再構成像の平均値である。

2次元ランダム収集の場合において、図 5.10 から図 5.12 より、ISTA では過度な平滑化によって被写体構造が消失していた。これとは対照的に、Split Bregman と C-SALSA-B ではいずれの信号比でも良好な再構成像が得られた。データ整合性処理を適用した DRL-CNN では、いずれの信号比でも Split Bregman や C-SALSA-B に比肩する品質の再構成像が得られた。この傾向は図 5.8 の PSNR や SSIM の数値からも確認できる。

1次元ランダム収集の場合において、信号比 40% 以下における DRL-CNN が Split Bregman や C-SALSA-B よりも高い PSNR と SSIM を示した。また、データ整合性処理の適用によってこれらの数値は適用前よりも向上した。図 5.13 から図 5.15 の再構成像をみると、反復的再構成法では信号比が 30~40% の場合にエイリアシングアーチファクトが除去しきれずに残存しており、被写体の細部構造の消失が確認できる。一方の DRL-CNN では、細部構造が概ね復元され、微細なコントラストも良好に保存されていた。また、データ整合性処理の適用によって細部構造の描出性能はさらに向上した。

## 5.5 再構成時間の比較

画像 1 枚あたりの再構成には、DRL-CNN が CPU を利用した場合で 1.78 秒、GPU を利用した場合で 0.022 秒、ISTA で 4.03 秒、Split Bregman で 13.95 秒、C-SALSA-B で 13.67 秒を要した。

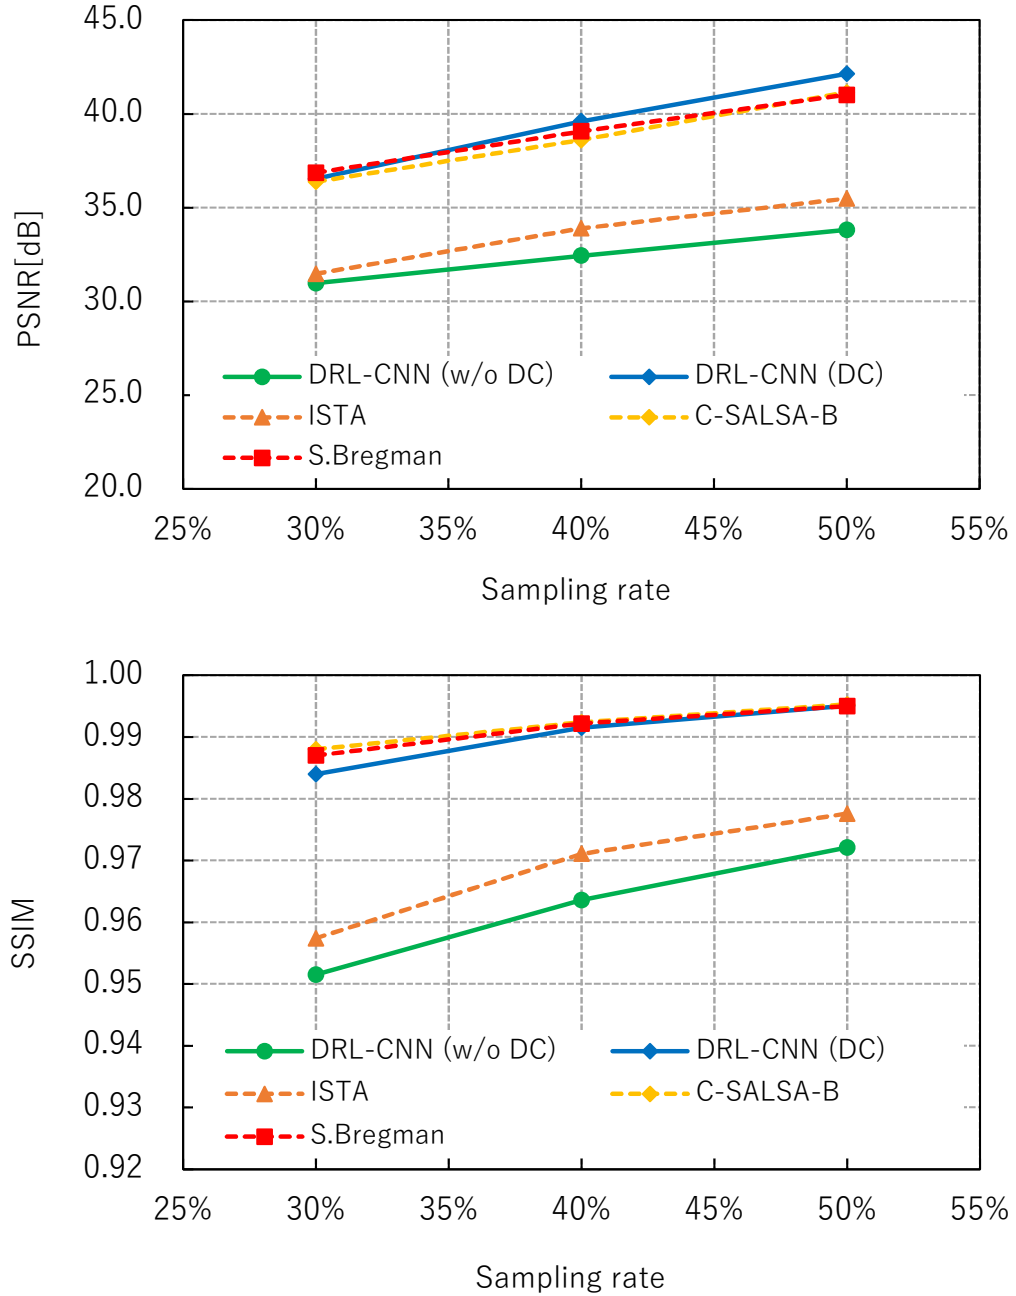


図 5.8: 各収集信号比における再構成像の PSNR と SSIM (2次元ランダム収集)

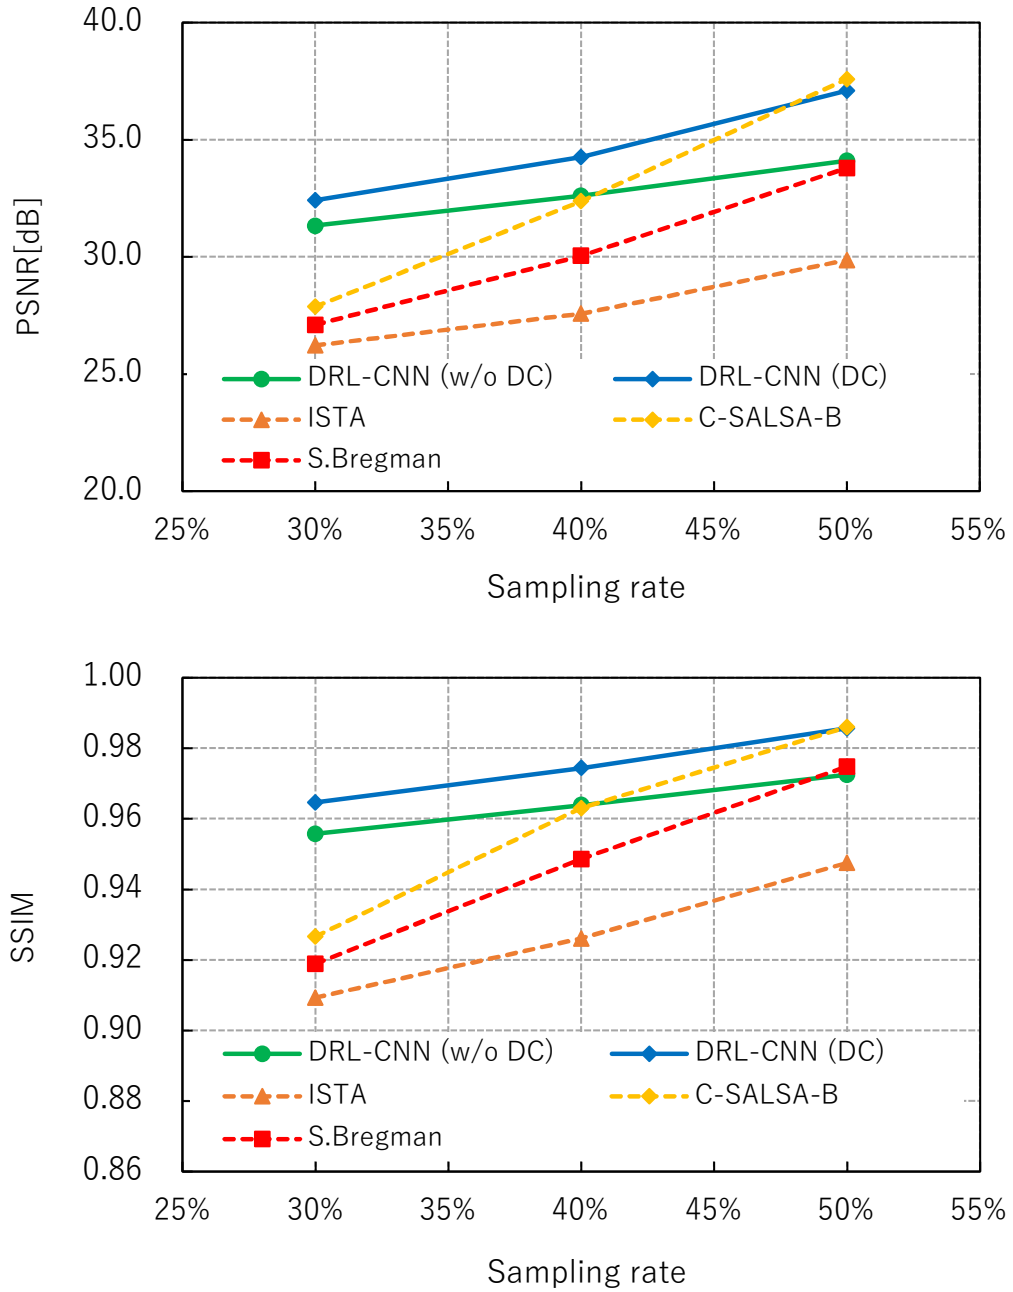


図 5.9: 各収集信号比における再構成像の PSNR と SSIM (1次元ランダム収集)



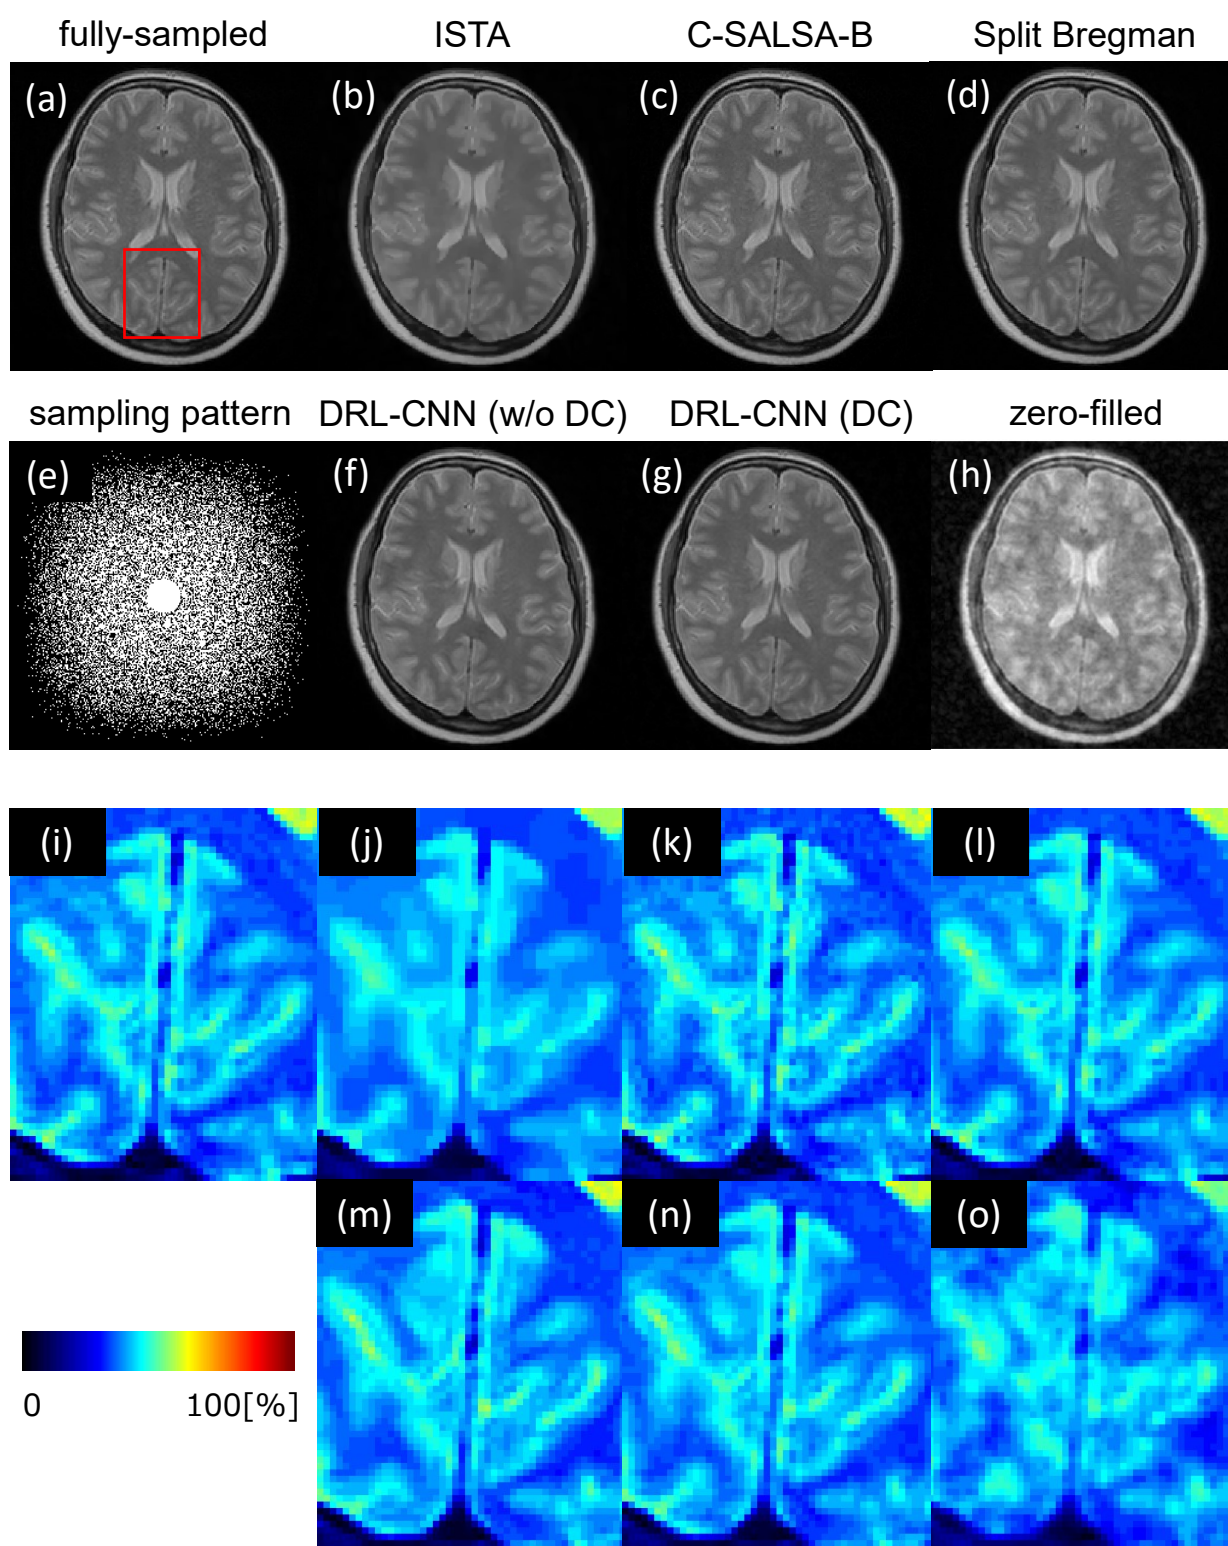


図 5.10: 収集信号比 30%における再構成像 (2次元ランダム収集)

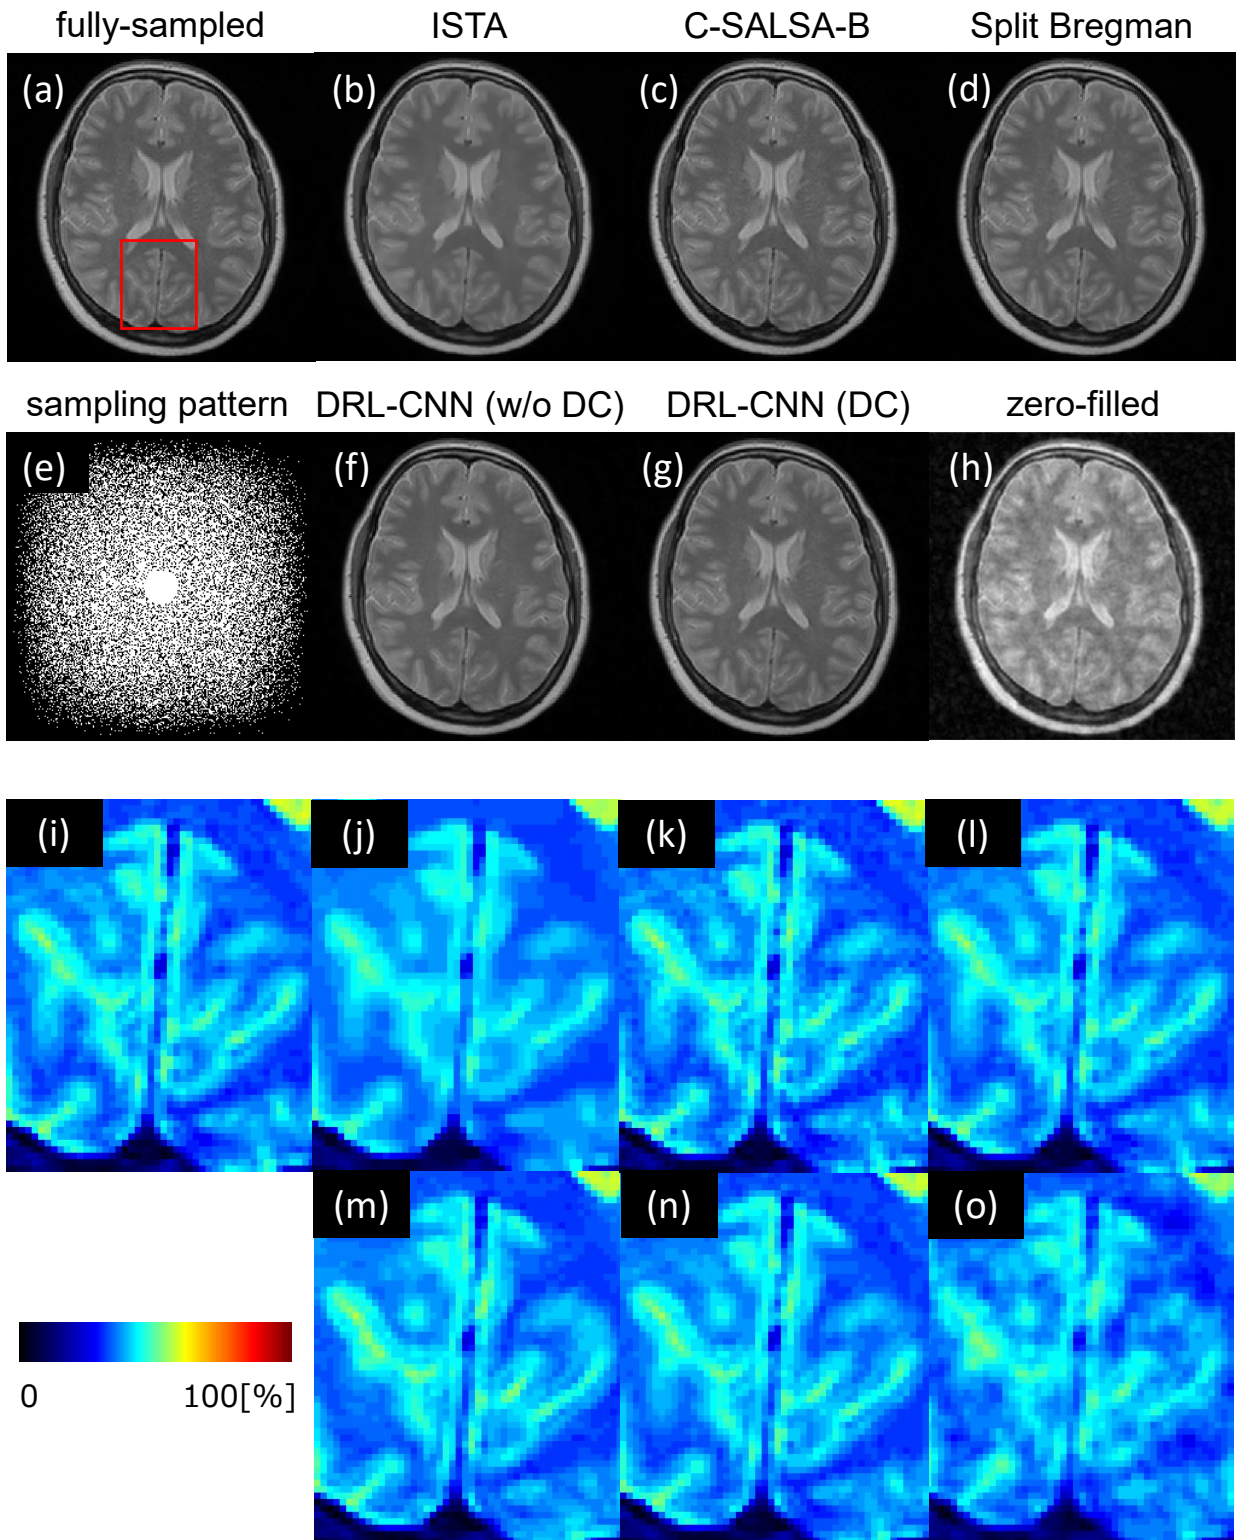


図 5.11: 収集信号比 40%における再構成像 (2次元ランダム収集)

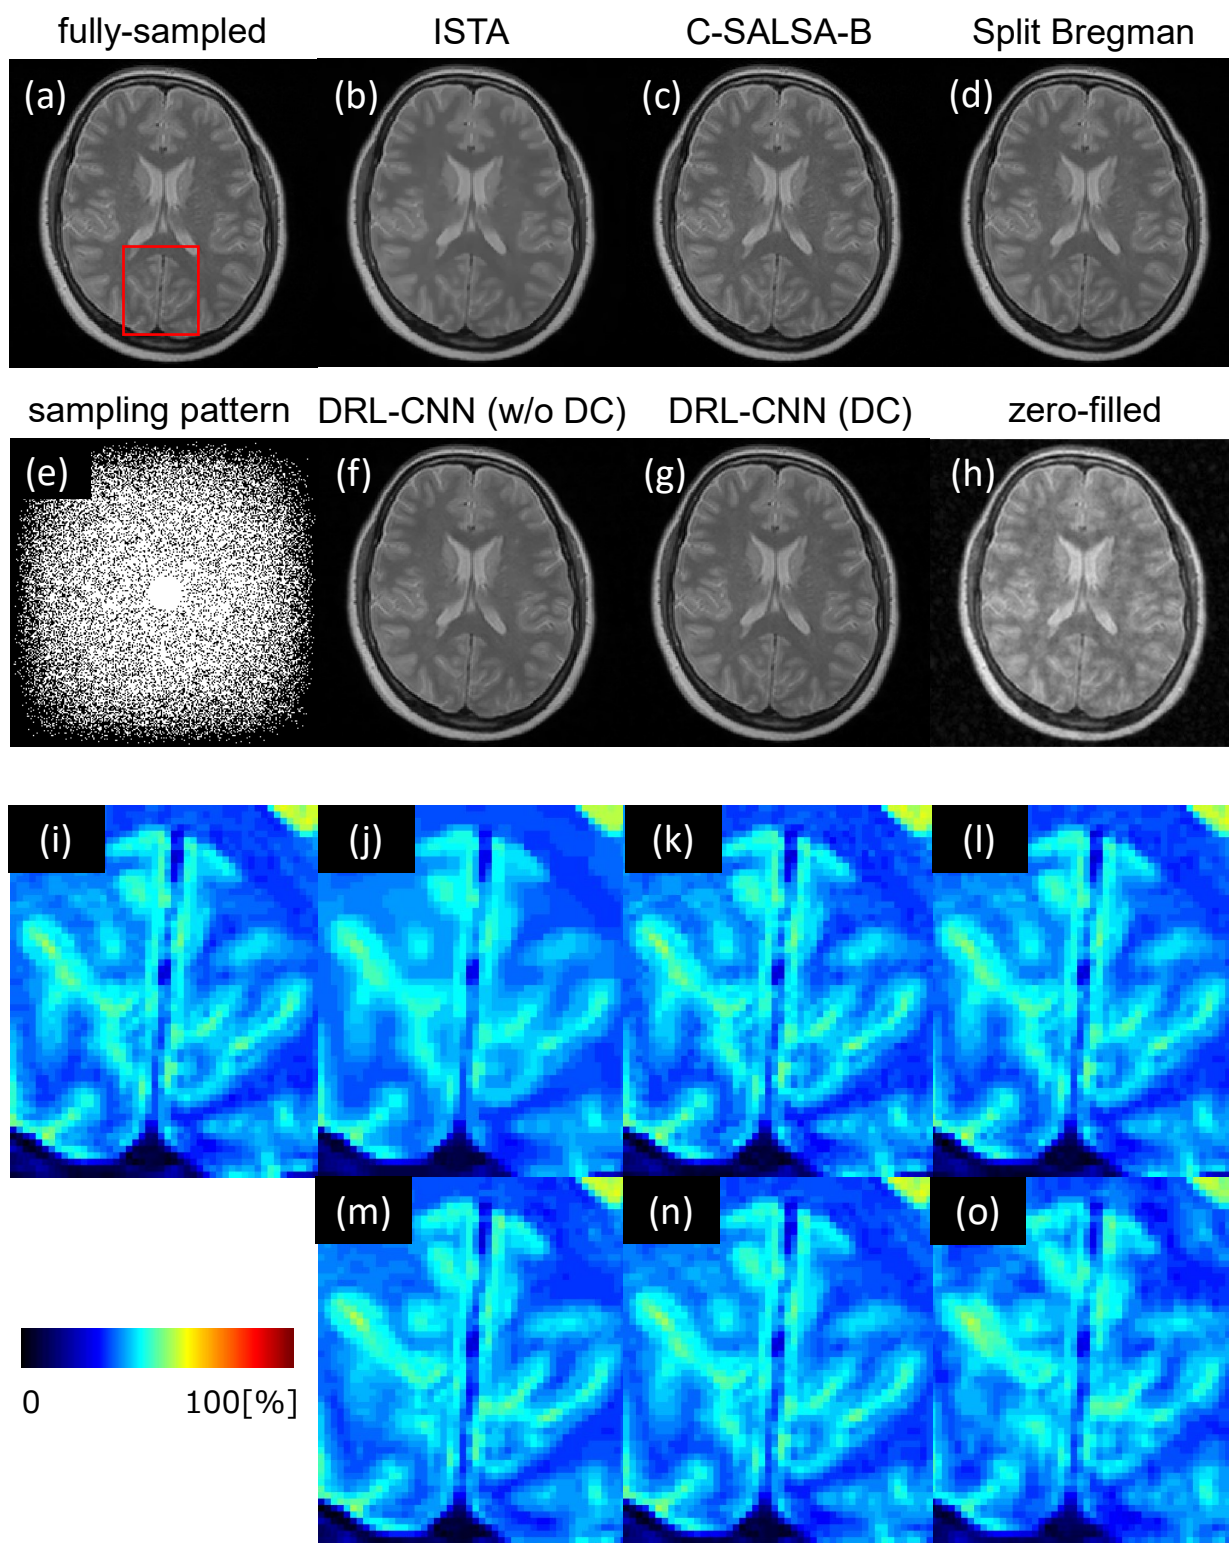


図 5.12: 収集信号比 50%における再構成像 (2次元ランダム収集)

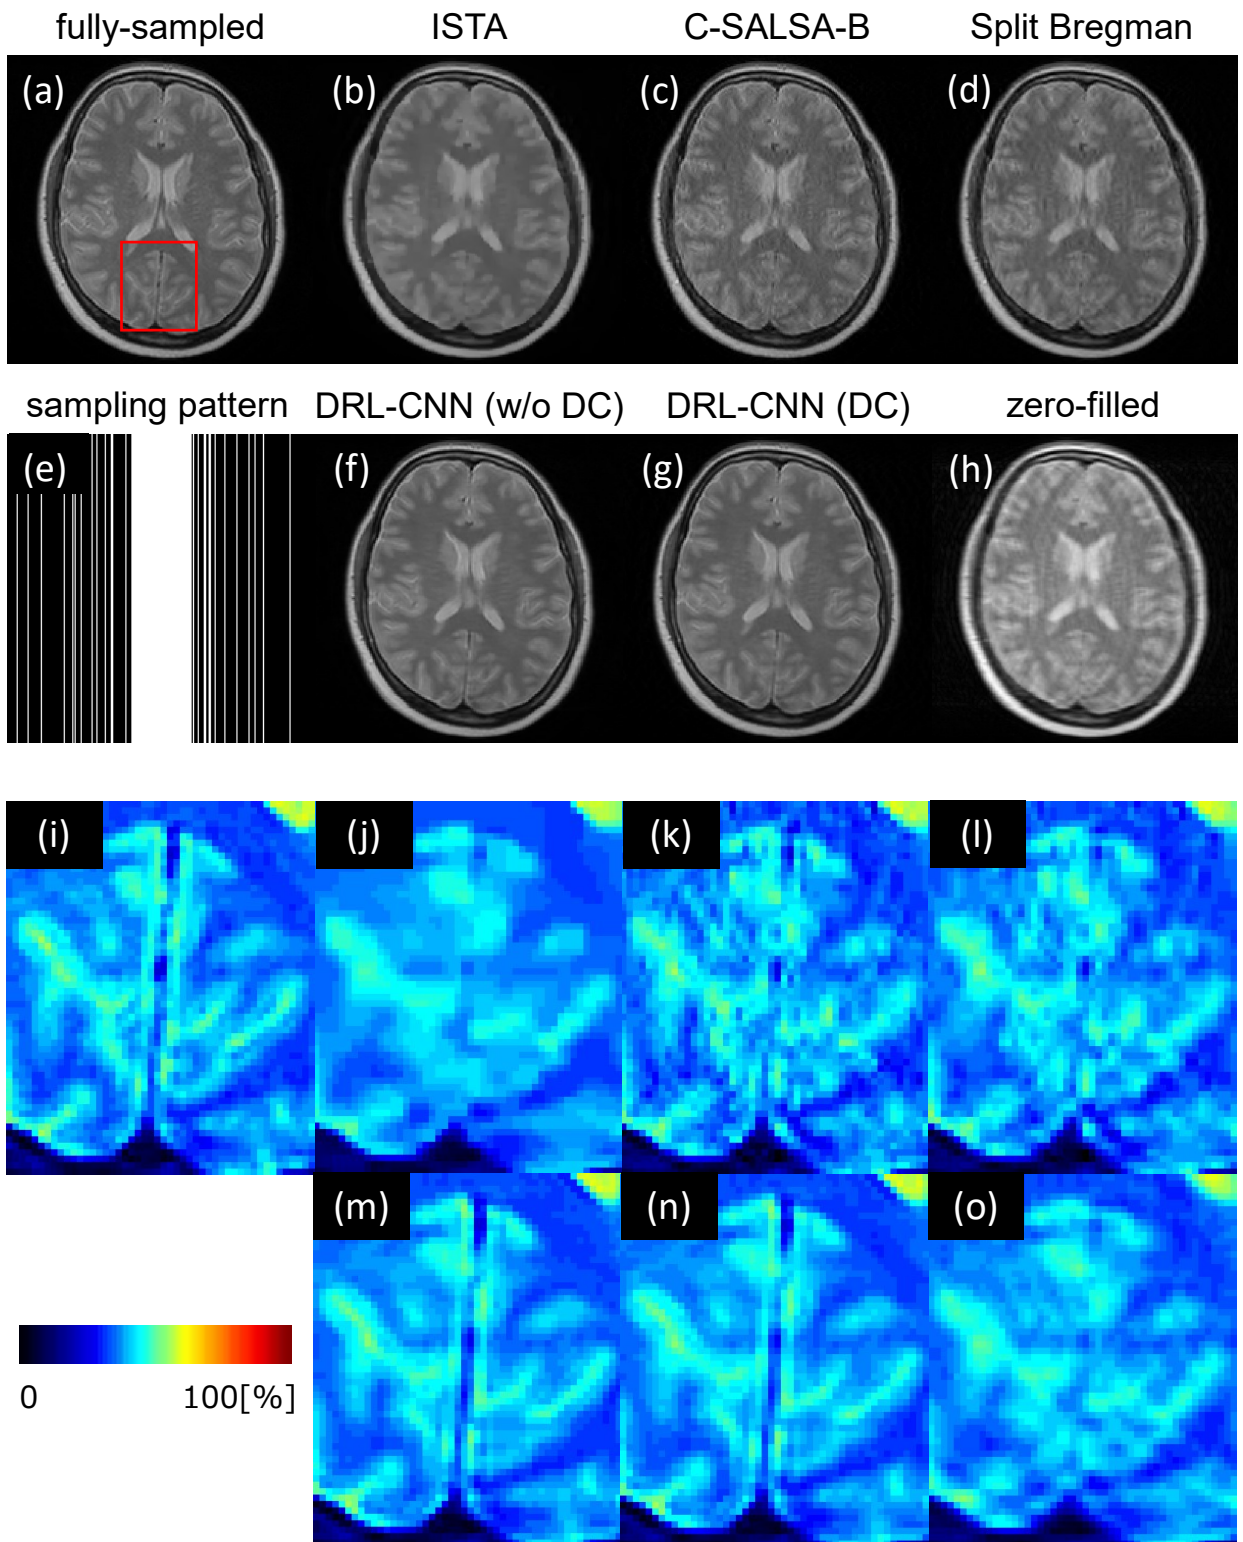


図 5.13: 収集信号比 30%における再構成像 (1次元ランダム収集)

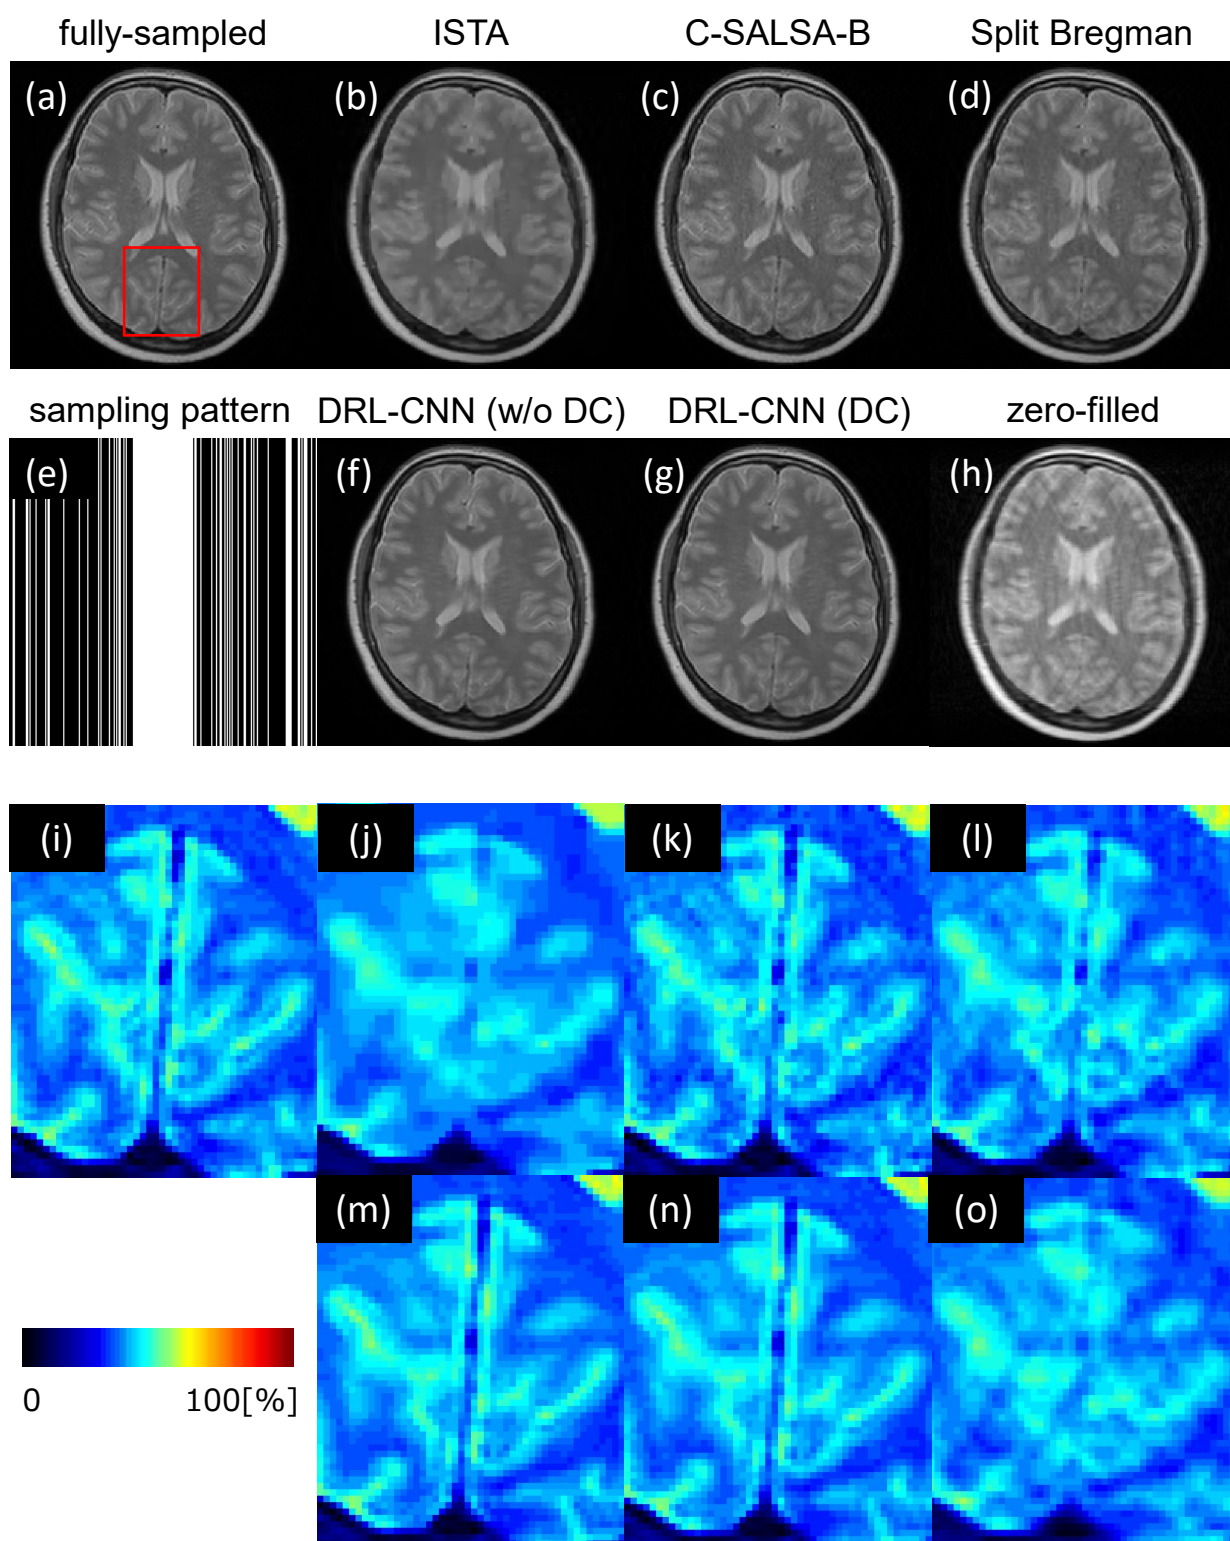


図 5.14: 収集信号比 40%における再構成像 (1次元ランダム収集)

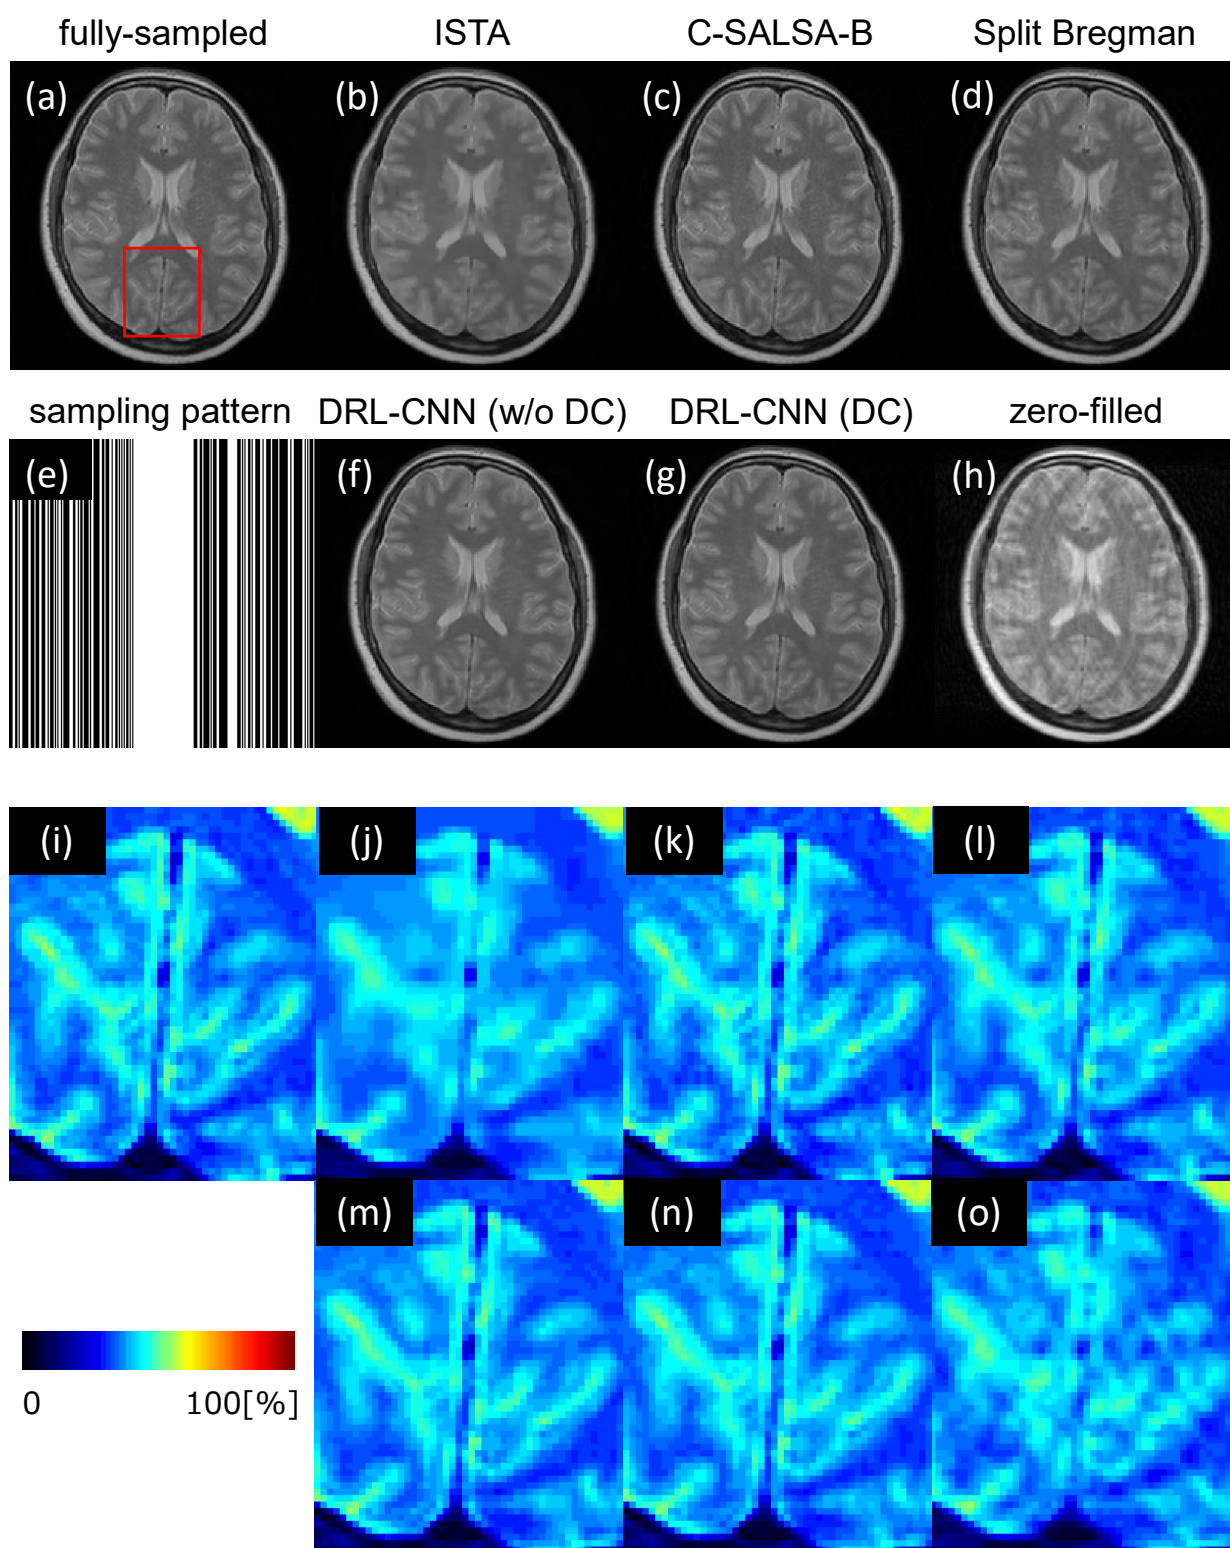


図 5.15: 収集信号比 50%における再構成像 (1次元ランダム収集)

## 5.6 インコヒーレント性の低い間引き方法による再構成

DRL-CNN(DC) における再構成像の品質とアーチファクトのインコヒーレント性の関係を調査するために、1次元ランダム収集において、等間隔に間引く領域とランダムに間引く領域を混在した間引きパターンを用いた再構成を行った。図 5.16 に示すように、 $k$  空間の中心部を 0 として、 $\pm L$  行以内の領域を等間隔に、その他の外周部の領域をランダムに間引くパターンを使用する。収集信号比は 30% および 40% となるように設定し、 $k$  空間の中心部 50 行は連続的に収集する。図 5.16 における  $\pm L$  は、以下の 3 通りを設定した。

- 中心部より外側の全領域をランダムに間引く場合 ( $L = 25$ , 図 5.2 のパターンを使用)
- 中心部より外側の領域のうち約半分を等間隔に間引く場合 ( $L = 80$ )
- 中心部より外側の全領域を等間隔に間引く場合 ( $L = 128$ )

また、DRL-CNN(DC) の学習には 5.2 節で用いた 300 枚のプロトン密度強調像を使用し、テスト用画像やその他の条件も 5.2 節と同一とする。反復的再構成法との比較のため、使用した反復的再構成法の中で最も優れた性能を示している C-SALSA-B でも同一のテスト画像を用いて再構成を行った。DRL-CNN(DC) と C-SALSA-B による再構成像の PSNR と SSIM の平均値を図 5.17 に、再構成像を図 5.18 に示す。いずれの手法でも等間隔間引きを行う範囲が増加するにつれて PSNR は低下したが、その傾向は C-SALSA-B で顕著であり、全領域が等間隔となる  $L = 128$  では、2 手法間の PSNR の差が大きく開いた。再構成像より、 $L = 128$  では C-SALSA-B でアーチファクトの残存が強く見られたが、DRL-CNN(DC) では間引き方法に依存せず高品質な再構成が行えた。




図 5.16: 使用する間引きパターンの概要図

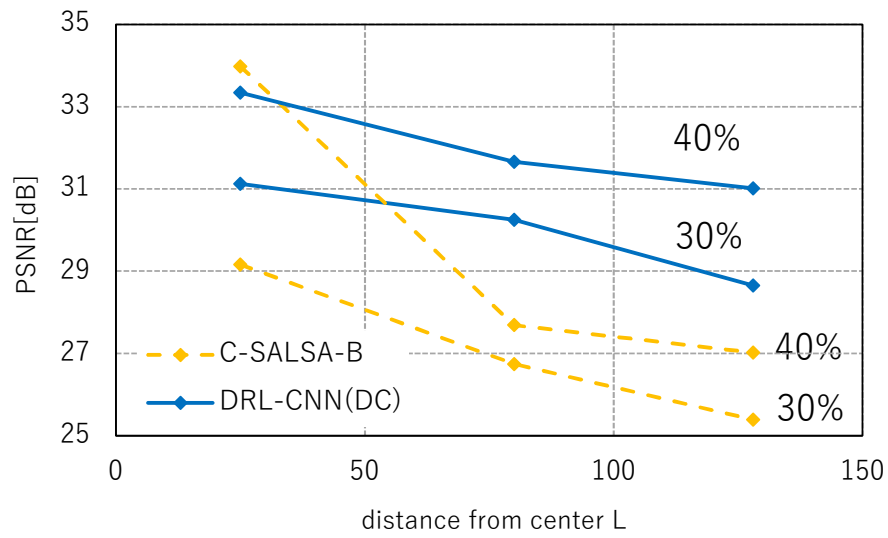


図 5.17: 再構成像の平均 PSNR

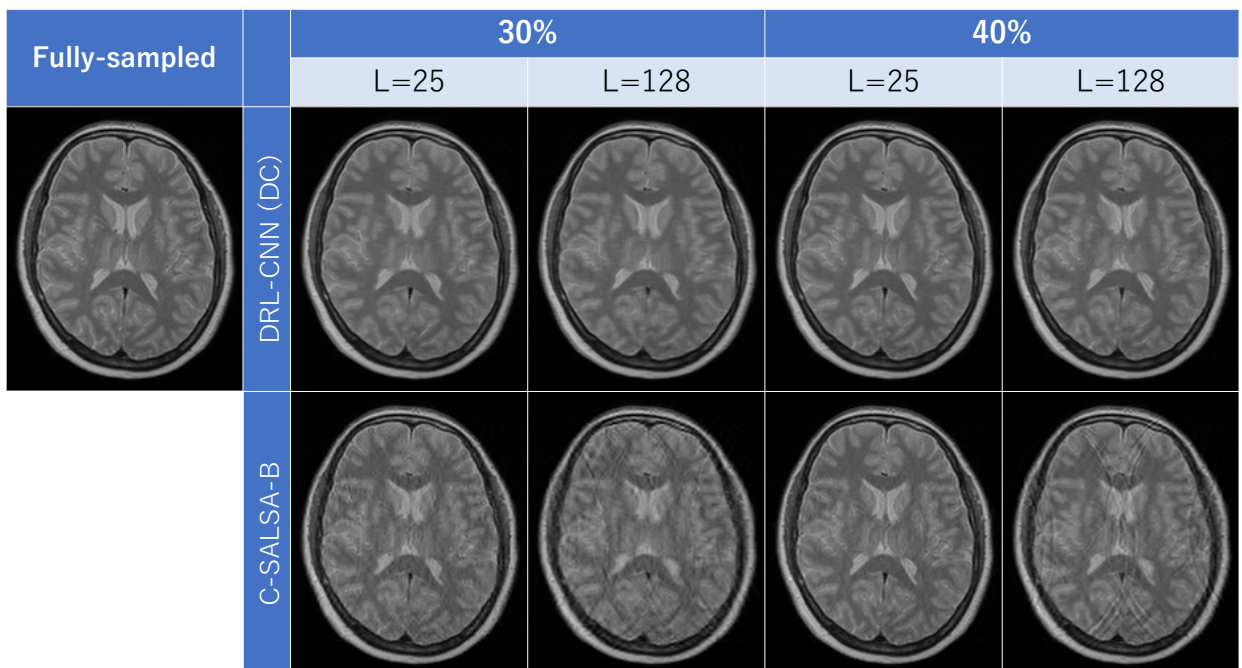


図 5.18: 信号間引きのコヒーレント性と再構成像の関連



## 5.7 考察

### 5.7.1 CNN の層数とパッチサイズの関係に関して

DRL-CNN に与える画像のパッチサイズと再構成像の PSNR と SSIM の関係を、パッチサイズが  $31 \times 31$  から  $71 \times 71$  の範囲で検討した。その結果、パッチサイズが大きいときほど PSNR と SSIM がともに高くなる傾向にあった。本研究では DRL-CNN による推定を対象をエイリアシングアーチファクトとしたが、アーチファクトは画像空間上に非一様に発生する。DRL-CNN は、Zhang らが提案した画像の雑音除去用の CNN である DnCNN を応用しているが、MR 信号の間引き収集によって逆フーリエ変換像に発生するエイリアシングアーチファクトは、Zhang らの主張における雑音レベルが未知の場合に近い状況であると言える。したがって、パッチサイズが大きく、CNN が一度に捉えられる情報量がより多いときに良好な再構成を行えたと考える。一方で、エイリアシングアーチファクトは間引きパターンや収集信号比等に影響される可能性があり、パッチサイズは状況に応じて適切に設定する必要があると言える。

### 5.7.2 DRL-CNN による画像再構成の特徴に関して

5.3 節では、DRL-CNN の学習枚数に伴う再構成像の品質を比較した。その結果、1次元ランダム収集、2次元ランダム収集のどちらも枚数の増加によって再構成像の品質が向上したが、その傾向は1次元ランダム収集に強く見られ、アーチファクトの除去性能と被写体構造の復元性能がともに向上した。1次元ランダム収集に関しては、図 5.5 の PSNR の推移より、学習枚数の増加でさらなる品質の向上が見込まれる。また、図 5.5 より十分な学習枚数さえ確保できればデータ整合性処理を用いなくても反復的再構成法に比肩する性能を得られる可能性が示された。一方、2次元ランダム収集に関しては、学習枚数が 100 枚の時点でアーチファクトを概ね除去できており、枚数の増加は構造の復元性能への寄与のほうが大きかった。そのため、枚数の増加による PSNR の向上が1次元ランダム収集よりも小さかったが、データ整合性処理による構造の復元性能の向上は1次元ランダム収集よりも目立っており、PSNR の大幅な向上につながった。

5.4 節では、収集信号比に伴う再構成像の品質を比較した。2次元ランダム収集では、DRL-CNN の PSNR と SSIM は ISTA よりも低い結果となったが、この傾向はデータ整合性処理の適用によって改善された。また、1次元ランダム収集では、DRL-CNN が2次元ランダム収集のときよりも高い PSNR を示しており、特に低信号比では反復的再構成法を上回る性能を示した。この結果に関して、CNN とエイリアシングアーチファクトの関係およびデータ整

合性処理の 2 点から考察する．まず，CNN とアーチファクトの関係では，一般に 2 次元ランダム収集のランダム性は 1 次元ランダム収集よりも高いため，通常の圧縮センシングの観点では 2 次元ランダム収集の方が優れた性能を示すと考えられる．一方で，収集信号比が低い場合を仮定すると，CNN 再構成においては 1 次元ランダム収集の方が優れた性能を示す場合がある．1 次元ランダム収集において，信号間引きを等間隔に行うと，逆フーリエ変換像に生じるエイリアシングアーチファクトも規則的な間隔で発生する．この場合，アーチファクトの発生ルールは単純であり，アーチファクトの生じていない領域では被写体構造も良好に保存されているため，CNN は 2 次元ランダム収集の場合よりもアーチファクトを認識しやすく，構造の保存性能も向上すると推測できる．実際に，図 5.13 から図 5.15 では低信号比において反復的再構成法よりも優れた性能を示している．この性質をさらに検討するために行った，インコヒーレント性の低い間引きパターンによる再構成では， $k$  空間中心付近から外周部に向かって次第に等間隔な間引きを行うことで，ランダム性を大きく低下させたパターンを採用した．その結果，C-SALSA-B ではランダム性が低下するにつれてアーチファクトの残存が目立ったのに対し，DRL-CNN では全領域を等間隔に間引いた場合でもアーチファクトが除去できており，アーチファクトの様相に対しての高い頑健性が示された．この結果より，CNN による再構成は，1 次元ランダム収集のようなランダム性の低い間引き方法の場合に特に有効であることが分かった．一方で， $k$  空間の信号分布は撮像対象の被写体の分布に依存するため，間引きパターンの選択は撮像条件や被写体の特性に合わせて適切に行う必要がある．

次に，データ整合性処理については，この処理の適用によって再構成像の品質を大きく改善できることが示唆される．DRL-CNN による再構成像は，フルデータ像と比較して誤差を含んでおり，そのフーリエ変換空間である  $k$  空間にも誤差が生じている．データ整合性処理では，再構成像の  $k$  空間のうち，実際に信号を収集した点については真の信号で置換する処理を行う．本検討で扱う実関数画像では信号のエルミート対称性を満足するため， $k$  空間上の 1 点  $(k_x, k_y)$  を考えたとき， $y(k_x, k_y) = y(-k_x, -k_y)^*$  が成立する．このため， $y(k_x, k_y)$  と  $y(-k_x, -k_y)$  はいずれか 1 点を収集していれば，もう一方の点は補完されるため，信号間引きにおいては，2 次元方向共にランダムな間引きを行う方が，1 次元のみランダムに間引く場合よりも  $y(k_x, k_y)$  と  $y(-k_x, -k_y)$  の両方を収集する確率が低くなる．以上より，データ整合性処理による品質の向上は，真の信号に置き換えられたサンプリング点の総数に比例することから，2 次元ランダム収集において高い効果が得られた．データ整合性処理は，CNN の学習を必要とせず，処理に要する時間も短いため，再構成像の品質を高める有効な手法と言える．

### 5.7.3 処理時間に関して

再構成に関わる処理時間については、画像 1 枚当たりの再構成時間は C-SALSA-B と Split Bregman で約 14 秒であるのに対し、DRL-CNN では CPU のみを利用した場合に 1.78 秒、GPU を使用した場合に 0.022 秒に短縮された。反復的再構成法では、L1-L2 最小化問題を解く際に反復処理を必要とするため画像の復元には多くの時間を要するが、CNN では反復処理が不要なため、ネットワークの深さやフィルターのカーネルサイズ等に依存するものの、反復法と比較して大幅な短縮が実現された。通常診断では、数十枚から数百枚の撮像を行うため、CNN による低信号比での高品質かつ高速な再構成は、撮像と診断のプロセスを高速化する有効な手法となる可能性がある。

# 第6章 実関数CNNによる複素画像の再構成実験

## 6.1 実験の条件

### 6.1.1 使用するMR画像

CNNの学習と、学習したCNNを用いたテストには、2014年7月に東芝メディカルシステムズ内で Vantage Titan 3.0T を用いて撮像された同意を得たボランティアの画像183枚を使用した。全ての画像が複素画像であり、大小さまざまな位相変化を持つ画像を含んでいる。これらの画像の内訳を表6.1に示す。表中のFSBBはFlow Sensitive Black Blood法の略称であり、これは $T_2^*$ 強調像を基本として、血管の描出性能を向上した撮像法である。各画像の撮像条件を表6.2に示す。

表 6.1: 使用した画像の種類と内訳

撮像シーケンス	撮像断面	画像枚数
T1W	Sagittal	75
T2W	Sagittal	75
T2W	Axial	27
FSBB	Axial	6

### 6.1.2 間引きパターン

5.6節での検討により、CNNによる再構成法では、ランダム性の低い間引きパターンに対しての頑健性が高いことが分かった。そこで、本検討では4.4.2節に示す複素画像の実部・虚部の実関数化処理を行うため、 $k$ 空間の原点に対して対称となる2点を共に収集する、エルミート対称性を満たす1次元ランダム収集パターンを採用した。実際に使用した収集信号比が20%、30%、40%となる間引きパターンを図6.1に示す。いずれのパターンにおいても、 $k$

表 6.2: 使用した画像の撮像条件

	T1W Sagittal	T2W Sagittal	T2W Axial	FSBB Axial
TR[ms]	7.2	3500	50	6000
TE[ms]	3.4	352	40	96
位相エンコードステップ数	240	64	128	120
スライス厚	1.2	1.2	1.5	4
フリップ角 [°]	9	90	20	90

空間の中心部 41 行を連続的に収集し、外周部の収集列は対称性を満たしつつランダムに選択している。




図 6.1: 実際に使用した 1 次元ランダム収集の間引きパターン

### 6.1.3 既存手法との比較

提案する CNN の位相情報に対する頑健性を比較検討するため、本検討では複素画像に対応した CNN-CS である、強度画像と位相画像を別々の CNN で推定する方法 (Magnitude & Phase estimation; Mag&Phase と称する) [77], ADMM-CSNet<sup>[67]</sup>, ComplexCNN<sup>[78][90][91]</sup>, 複素画像の強度画像と位相画像をそれぞれ反復的に再構成する手法 (CS-MRI Complex) <sup>[92]</sup> による再構成を行った。ADMM-CSNet は、反復的再構成法的一种である ADMM を CNN に導入した Unrolling-based モデルおよび Transform Learning に該当する手法であり、実関数画像用の手法を改良した複素画像対応型が提案されている。Mag&Phase は、複素数のゼロフィル再構成像から強度画像と位相画像を分離して、それぞれのフルデータ像を CNN で独立に

推定する手法である。End-to-End モデルおよび Image Domain Learning に該当する手法である。ComplexCNN は、複素数型の CNN を用いて再構成を行う手法であり、End-to-End モデルおよび Image Domain Learning に該当する。本検討は、Trabelsi らの提案手法<sup>[78]</sup>を基本とした複素数型 CNN を PyTorch で構築するためのライブラリである complexPyTorch<sup>[90][91]</sup>を用いて、複素数に対応した畳み込み、CReLU、バッチ正則化等により、図 4.5 と同様の構造の U-Net を構築して使用した。複素数型の畳み込みでは、 $n$  枚のフィルターのうち半分が入力画像の実部の畳み込み用に、残りの半分が入力画像の虚部の畳み込み用に割り当てられる。本検討では、提案する実関数型 CNN のフィルター数と、ComplexCNN の実部用と虚部用を合わせたフィルター数の合計が等しくなるように設定した。

#### 6.1.4 CS-MRI Complex の間引きパターンについて

CNN のように学習用画像から所望の処理を柔軟に学習できる CNN では、ランダム性の低い間引きパターンでも良好に再構成を行えるのに対し、圧縮センシングによる反復的再構成を行う CS-MRI Complex では、その性質上インコヒーレントなアーチファクトが発生するランダム性の高い間引きパターンが求められる。したがって本検討では、CS-MRI Complex での再構成に  $k$  空間の原点对称性を満たさない間引きパターンを使用した。原点对称性を満たさない間引きパターンは、図 6.1 に示すパターンの中心から左側をそのまま残し、左側と同一の収集密度で右側のパターンを新たに作成することで用意した。

#### 6.1.5 計算機環境と実行環境

提案法、ADMM-CSNet, Mag&Phase, CS-MRI Complex の実行には、MATLAB R2019b を使用した。また、提案法、ADMM-CSNet, Mag&Phase では MatConvNet(1.0-beta25) を、ComplexCNN では PyTorch と complexPyTorch<sup>[90][91]</sup> を使用して CNN を構築した。すべての手法は、Intel Core i7-9700K (3.60GHz), NVIDIA GeForce RTX 2080 Ti(CUDA9.0, cuDNN7.0.5) を搭載した計算機を用いて実行した。

#### 6.1.6 再構成像の品質評価法

本検討では、再構成像の品質評価法として、強度画像では PSNR と SSIM を、位相画像では RMSE(Root Mean Squared Error) を採用した。

### 6.1.7 CNN の学習条件

各 CNN 再構成法の学習の際に用いた条件を表 6.3 に示す.

表 6.3: CNN 再構成法の学習に適用した条件

	RI-sepCNN	ADMM-CSNet	Mag&Phase	ComplexCNN
オプティマイザー	Adam	L-BFGS <sup>[93]</sup>	Adam	Adam
損失関数	画像空間での MSE			
エポック	300			

## 6.2 人工的位相を付与した画像による再構成と処理時間の検討

### 6.2.1 再構成実験結果

提案法の位相変化への頑健性の検討を目的として、規則的な変化をする 2 次関数上の位相分布を付与した複素画像による再構成を行った. 本検討では式 (6.1) に示す原点からの距離に応じて変化が大きくなる位相分布を使用した.  $(p, q)$  は画像空間のインデックスであり, 画像左上を原点 ( $p = 0, q = 0$ ) とする. また, 式中の  $c$  は位相変化の定数であり,  $c$  は  $1.0 \times 10^{-3}$ ,  $5.0 \times 10^{-3}$ ,  $1.0 \times 10^{-2}$ ,  $2.0 \times 10^{-2}$  の 4 つを設定した. また, 本検討では図 6.1 に示す信号収集比が 30% となる間引きパターンで実験を行った.

$$\phi(p, q) = \exp\{-ic(p^2 + q^2)\} \quad (6.1)$$

実際に設定した  $c$  値と位相分布図を図 6.2 に,  $c$  値に応じた再構成像の PSNR, SSIM, RMSE の平均値を図 6.3, 図 6.4 に,  $c = 2.0 \times 10^{-2}$  での再構成像の強度画像と位相画像を図 6.5, 図 6.6 に示す.




図 6.2:  $c$  値と位相分布図




図 6.3:  $c$  値に応じた再構成像の平均 RMSE



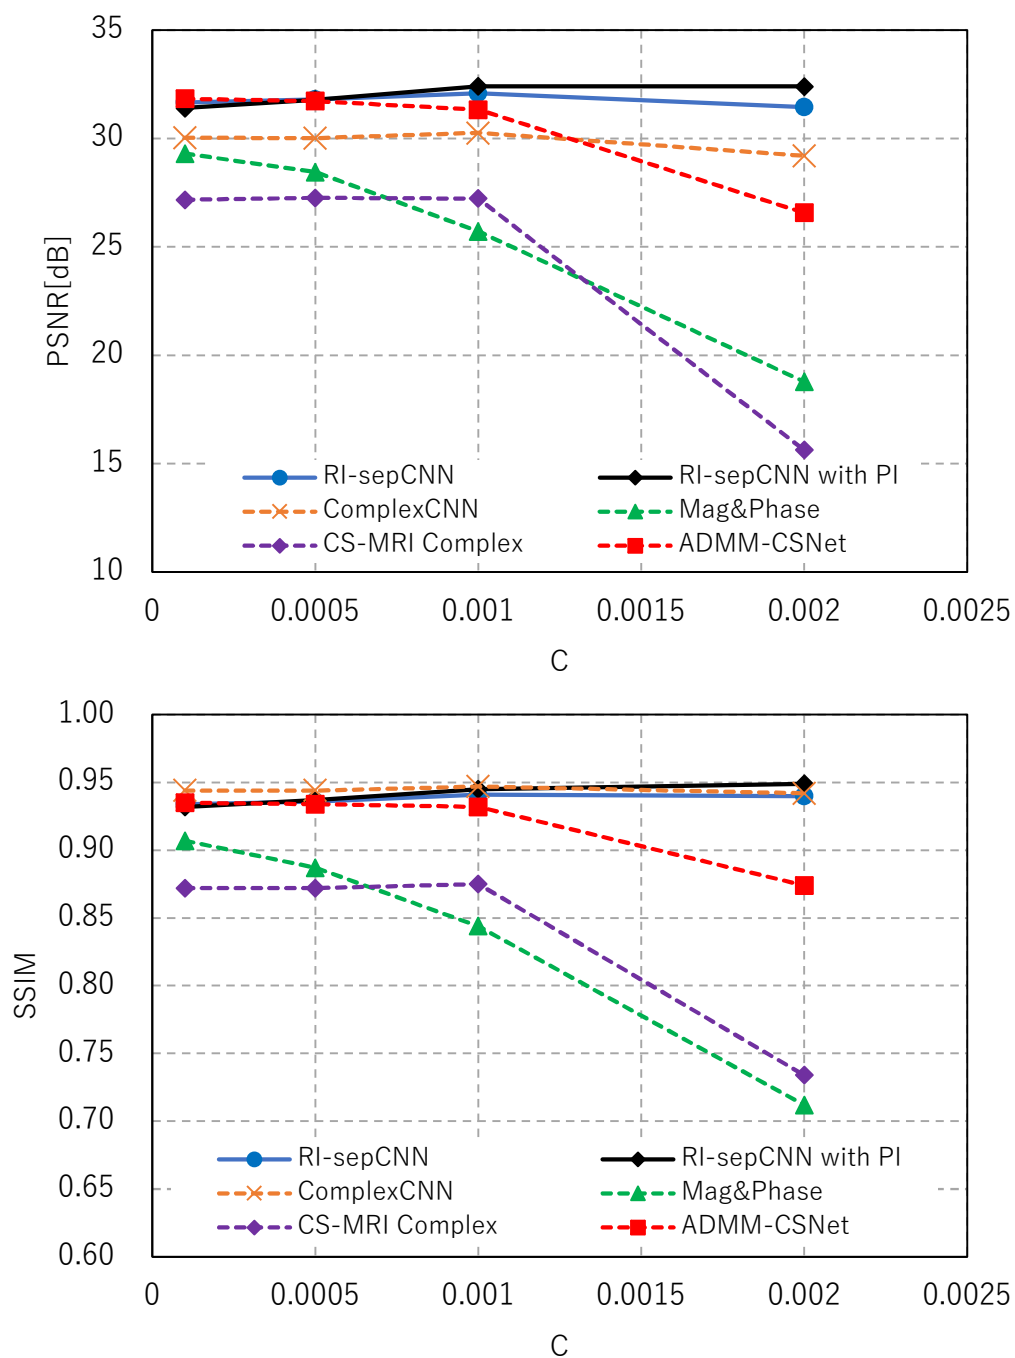


図 6.4:  $c$  値に応じた再構成像の平均 PSNR, SSIM

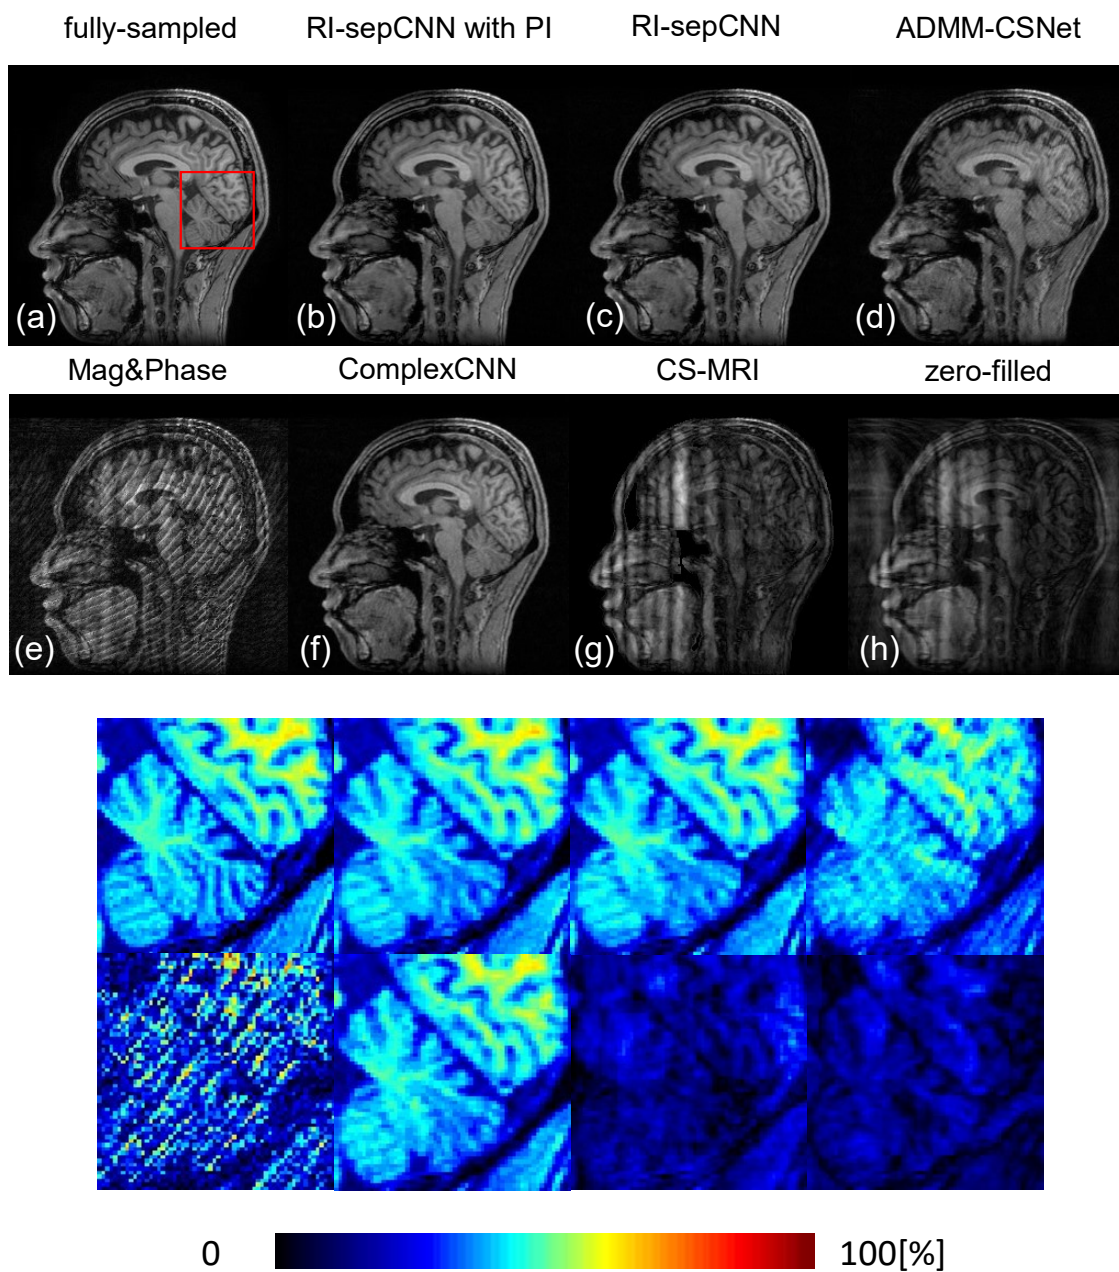


図 6.5:  $c = 2.0 \times 10^{-2}$  の再構成像 (強度画像)

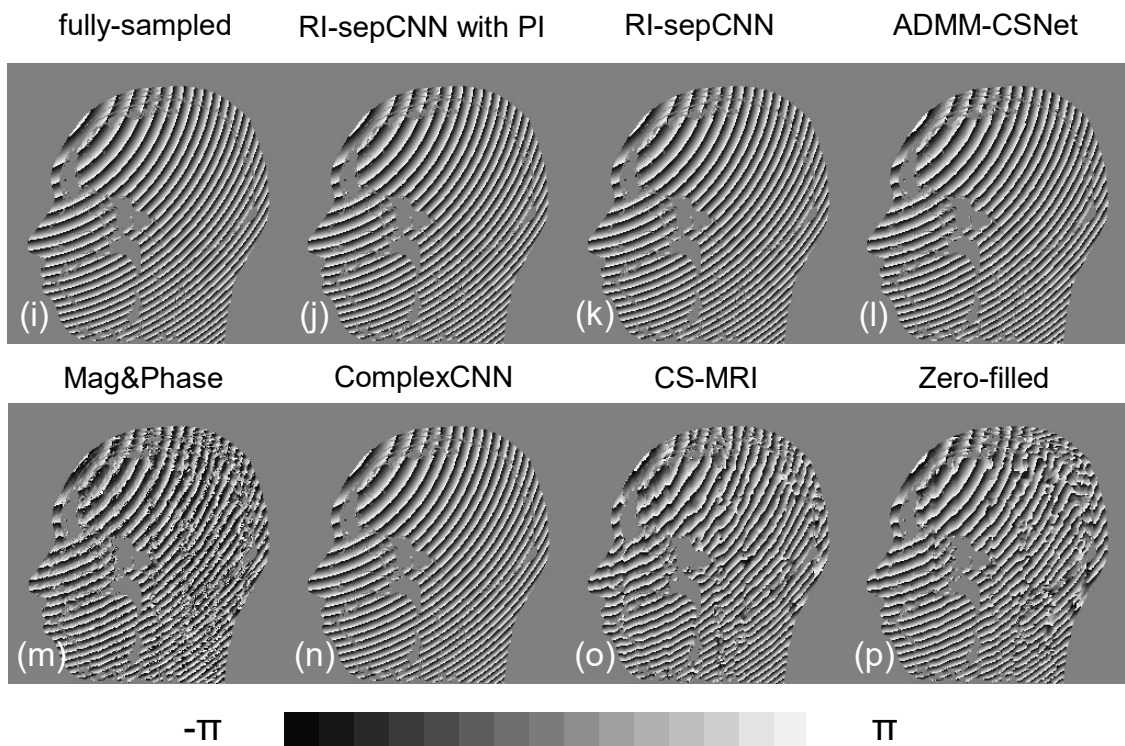


図 6.6:  $c = 2.0 \times 10^{-2}$  の再構成像 (位相画像)

図 6.3, 図 6.4 より, ADMM-CSNet, Mag&Phase, CS-MRI Complex の強度画像の PSNR と SSIM は  $c$  の増加につれて低下し, 位相画像の RMSE は  $c$  の増加につれて大きく増加した. 一方で, ComplexCNN と RI-sepCNN では, 上記の 3 手法とは対称的に  $c$  に関係なく高い PSNR と SSIM および低い RMSE を示していた. RI-sepCNN を ComplexCNN を比較すると, ComplexCNN では RI-sepCNN with PI に比肩する SSIM が得られている一方で, RI-sepCNN と RI-sepCNN with PI の方が高い PSNR と低い RMSE が得られた. 図 6.5, 図 6.6 の再構成像では, (h) のゼロフィル再構成像において, 強い位相変化の影響により被写体構造が大きく損失していた. このため, CS-MRI Complex ではアーチファクトの除去が困難であり, ADMM-CSNet と Mag&Phase では再構成像に位相分布状のアーチファクトの発生と細部構造の消失が見られた. 一方で, RI-sepCNN, RI-sepCNN with PI と ComplexCNN では, 僅かなアーチファクトの残存は見られたものの高品質な画像が得られた. 特に RI-sepCNN with PI の再構成像は鮮鋭度が高く, フルデータ像に最も近似する結果となった. 位相分布に注目すると, RI-sepCNN, RI-sepCNN with PI, ComplexCNN では位相変化が良好に復元された.

### 6.2.2 各手法の処理時間

各手法の学習および画像 1 枚あたりの再構成に要した時間を表 6.4 に示す. RI-sepCNN は学習および再構成に要した時間が最も短かった. また, RI-sepCNN with PI は輝度反転画像の併用により学習枚数が倍増したため, 処理時間は RI-sepCNN のほぼ 2 倍となった. 比較手法では, Mag&Phase は強度画像と位相画像で異なる 2 つの CNN を用いるため, 単一の CNN を用いる RI-sepCNN よりも処理時間が増加した. ADMM-CSNet は本検討で用いた CNN 再構成法の中で最も多くの処理時間を要した. また, ComplexCNN は RI-sepCNN with PI とほぼ同等の処理時間を要した.

表 6.4: 各手法の処理時間

	RI-sepCNN with PI	RI-sepCNN	ADMM- CSNet	Mag &Phase	Complex CNN	CS-MRI
学習時間 [h]	0.6	0.3	19	0.4	0.58	-
再構成時間 [s]	0.0565	0.0273	1.34	0.0422	0.0567	28.4

### 6.3 臨床機で撮像された位相を含む画像による再構成

提案法の実応用での有効性を検討するため、臨床機で撮像された大小さまざまな位相変化を持つ複素画像による再構成を行った。信号収集比が 20%、30%、40%における各 CNN 再構成法での再構成像の RMSE、PSNR、SSIM の平均値を図 6.7、図 6.8 に、各信号比での再構成像の強度画像と位相画像を図 6.9 から図 6.15 に示す。図 6.11 は各手法による再構成像とフルデータ像の誤差画像を示している。なお、これまでの検討では RI-sepCNN with PI は RI-sepCNN よりも優れた結果を得られる傾向にあったため、図 6.9 から図 6.15 ではこれら 2 手法のうち RI-sepCNN with PI の結果のみを示している。




図 6.7: 再構成像の平均 RMSE

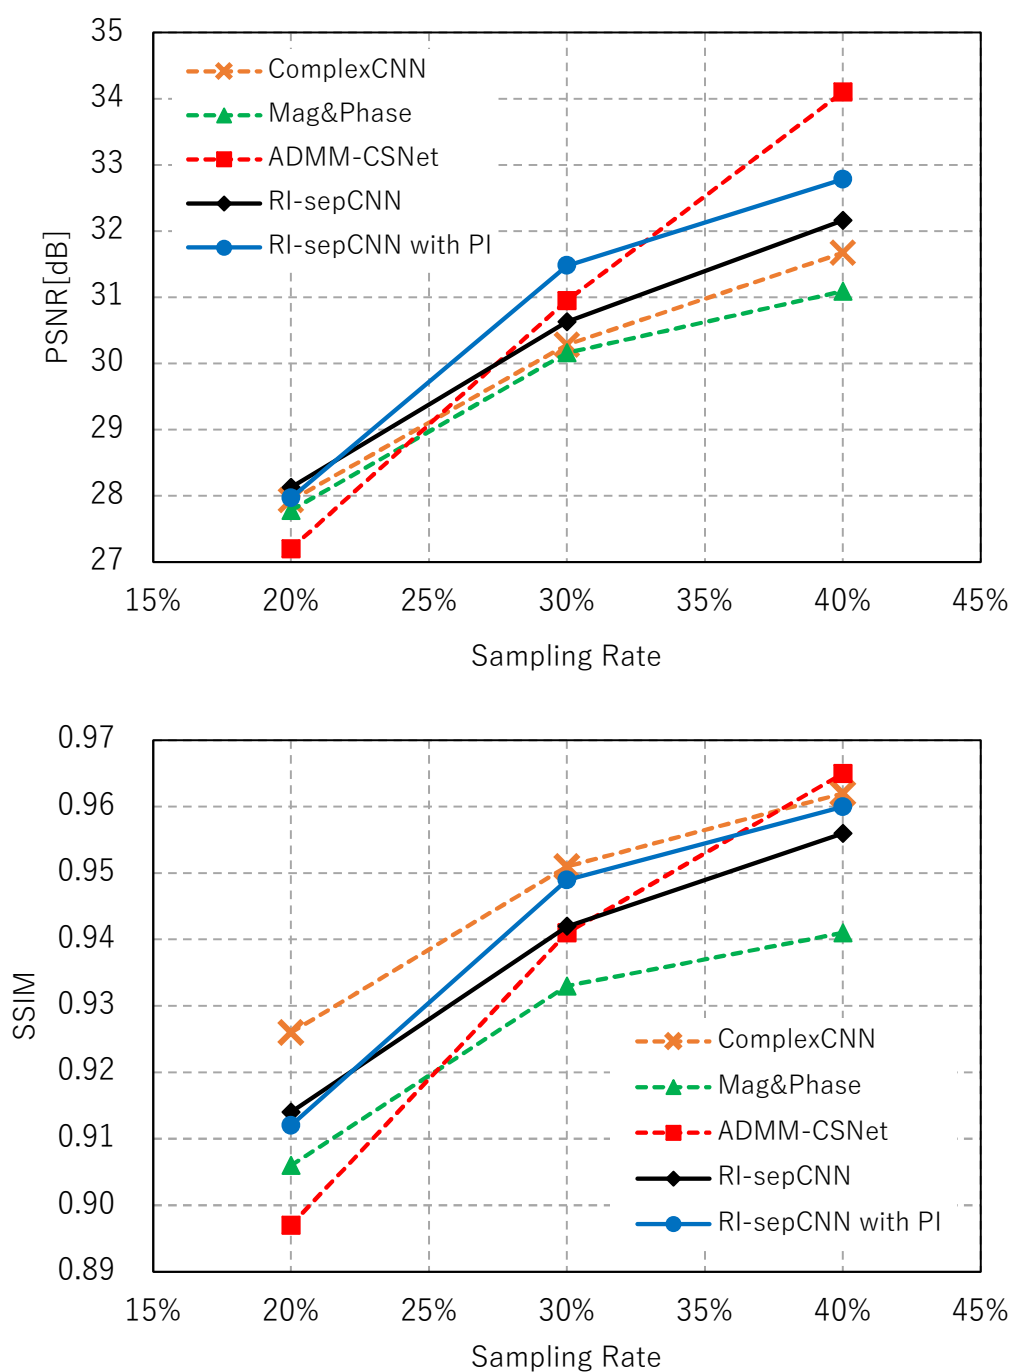




図 6.8: 再構成像の平均 PSNR, SSIM



0  100[%]

図 6.9: 信号比 20%の再構成像 (強度画像)

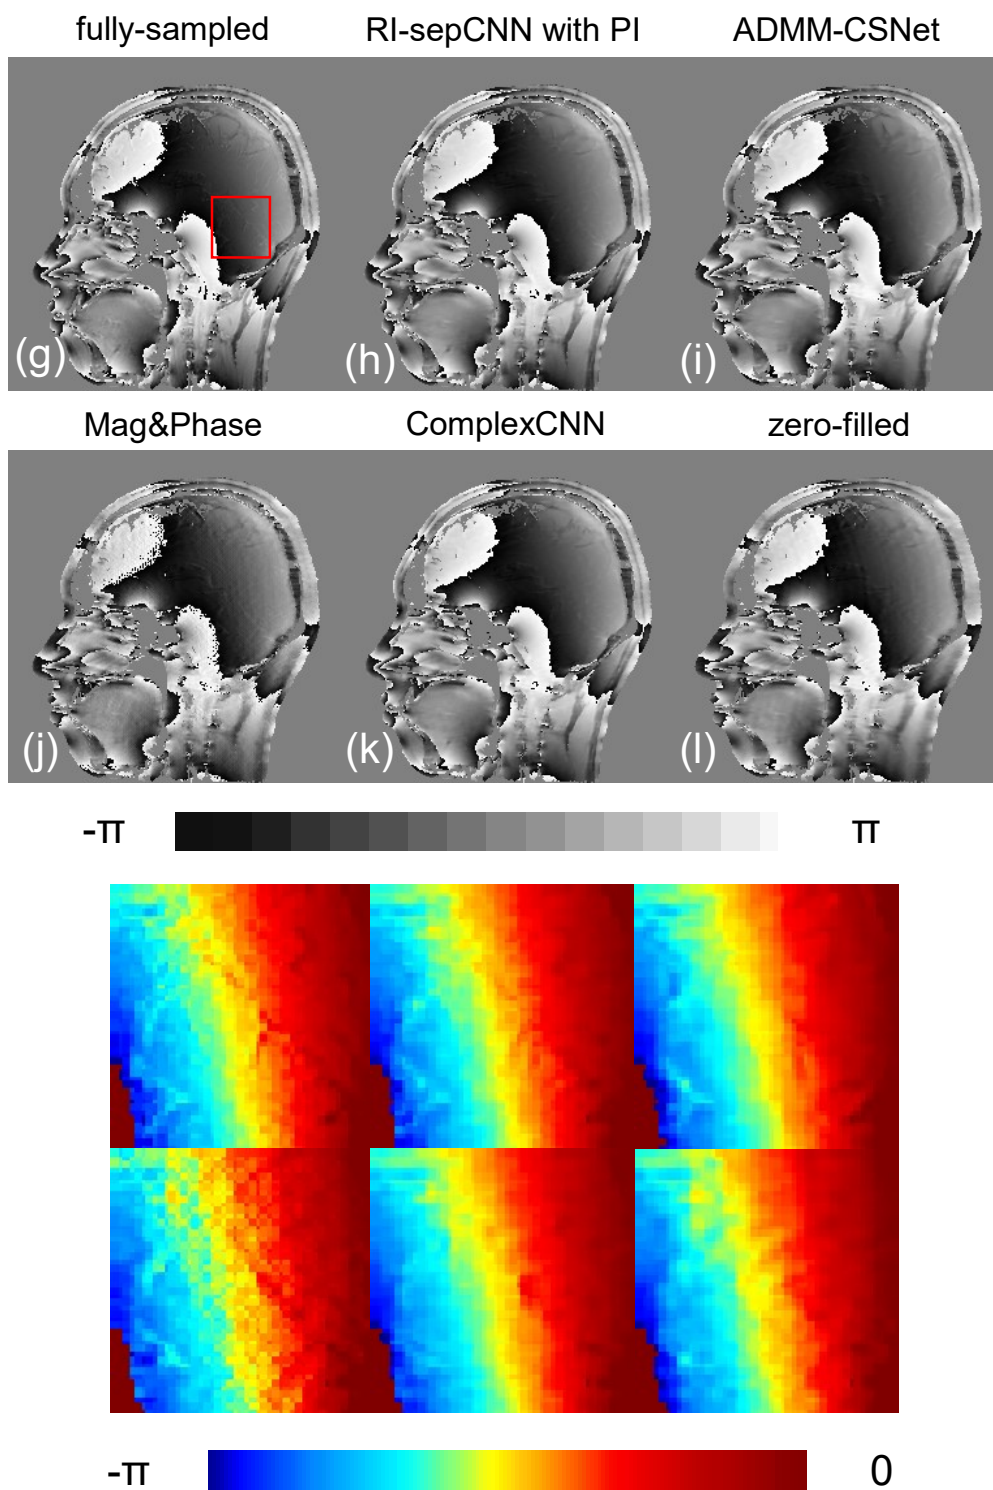


図 6.10: 信号比 20%の再構成像 (位相画像)






図 6.11: 信号比 20%の再構成像 (誤差画像)

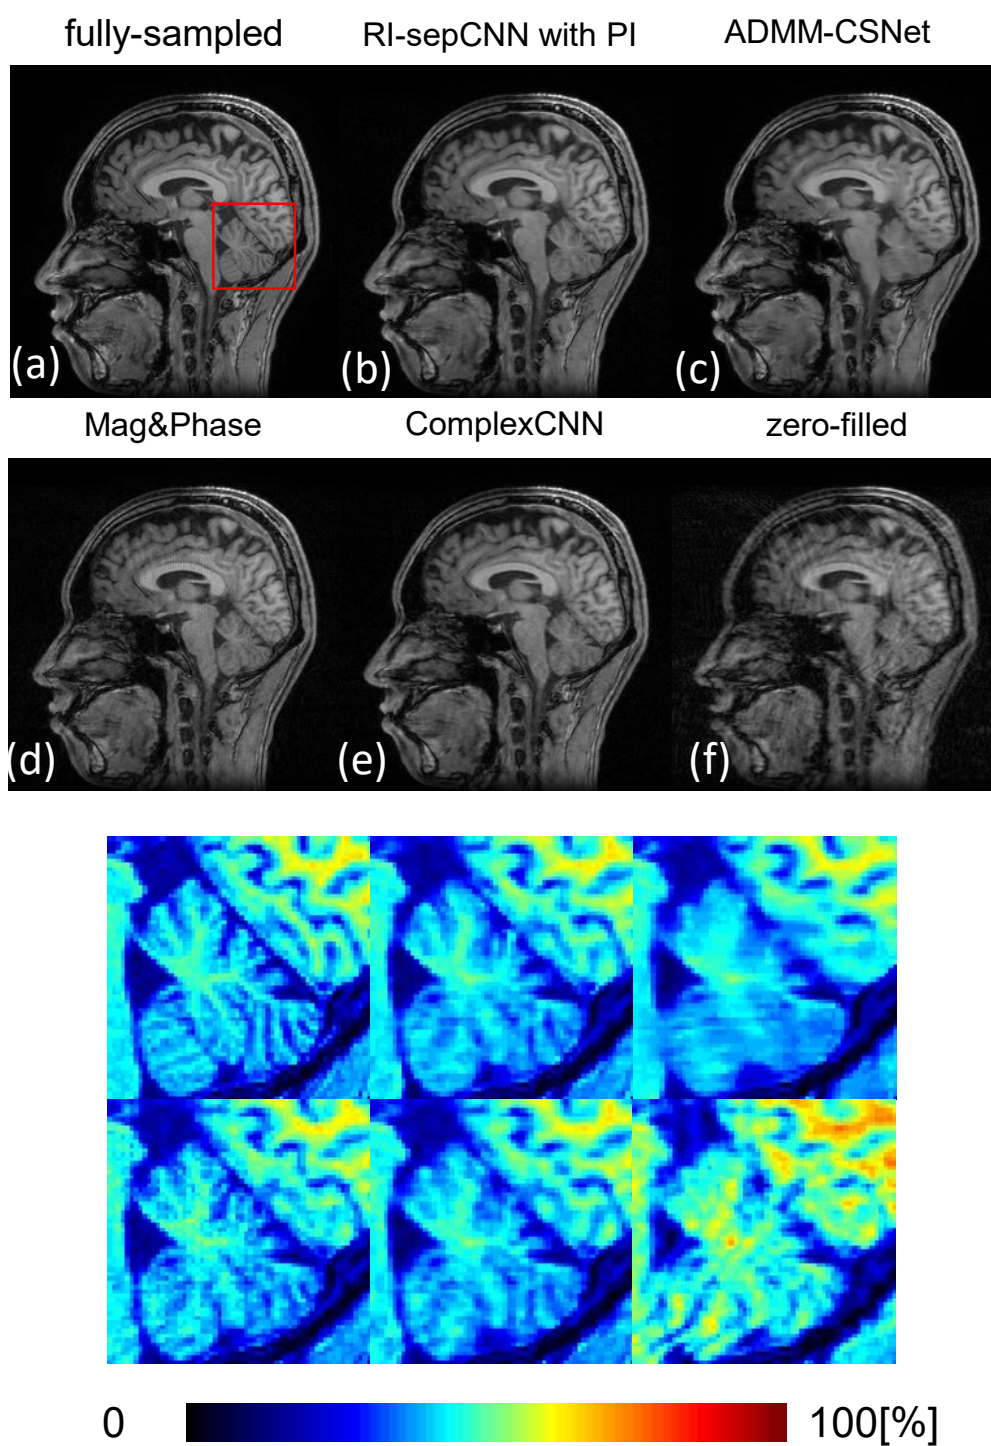


図 6.12: 信号比 30%の再構成像 (強度画像)

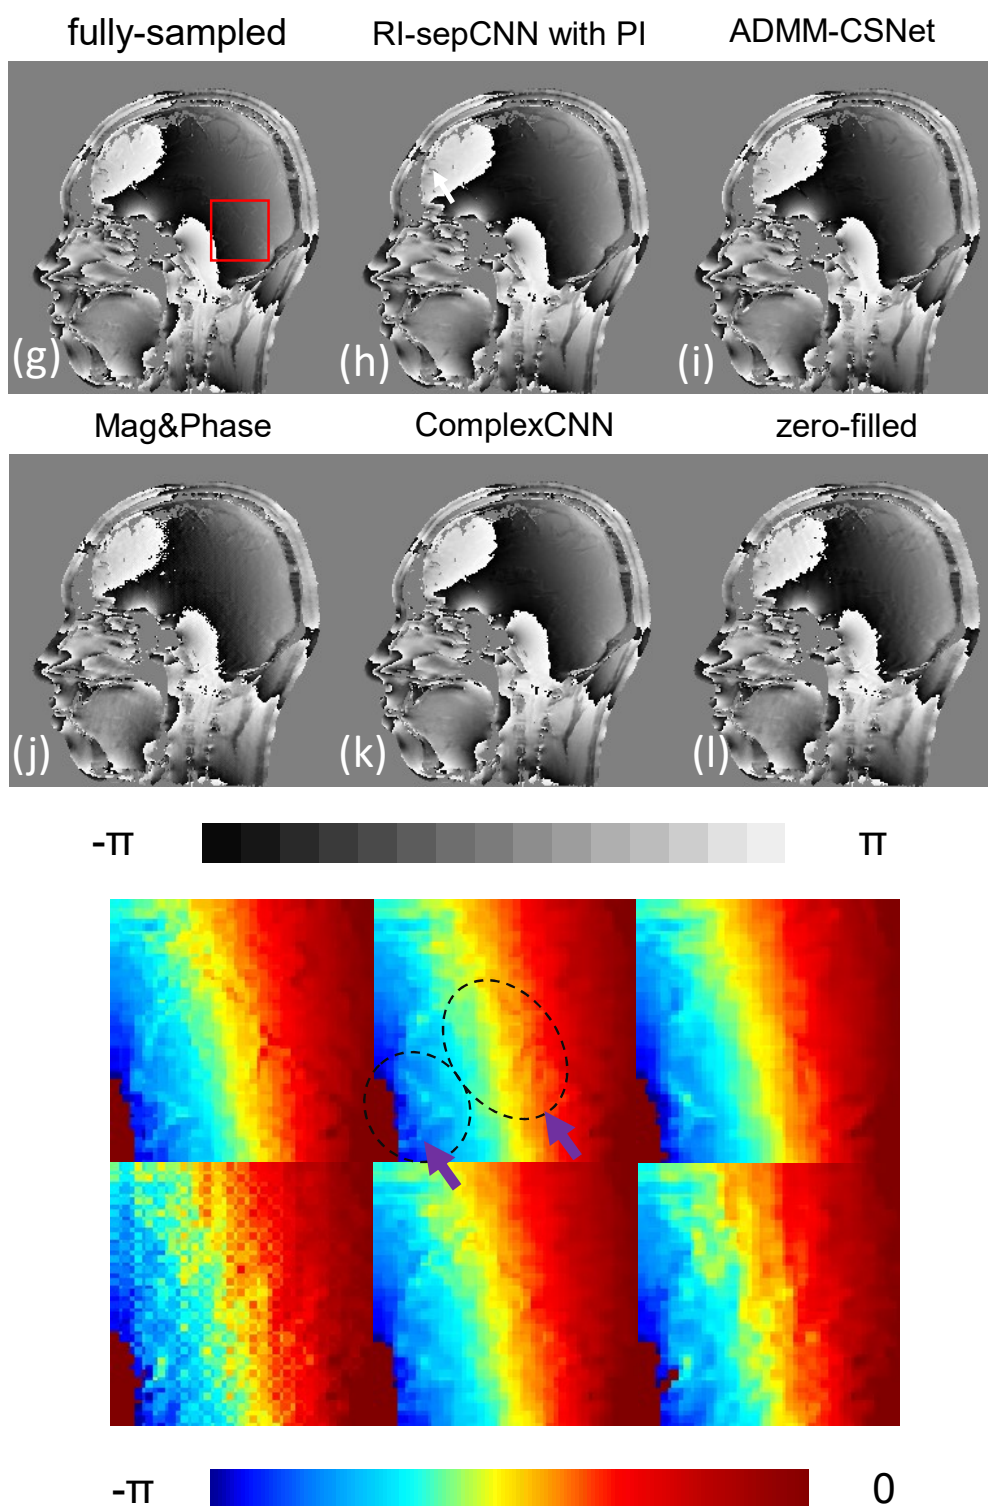




図 6.13: 信号比 30%の再構成像 (位相画像)



0  100[%]

図 6.14: 信号比 40%の再構成像 (強度画像)

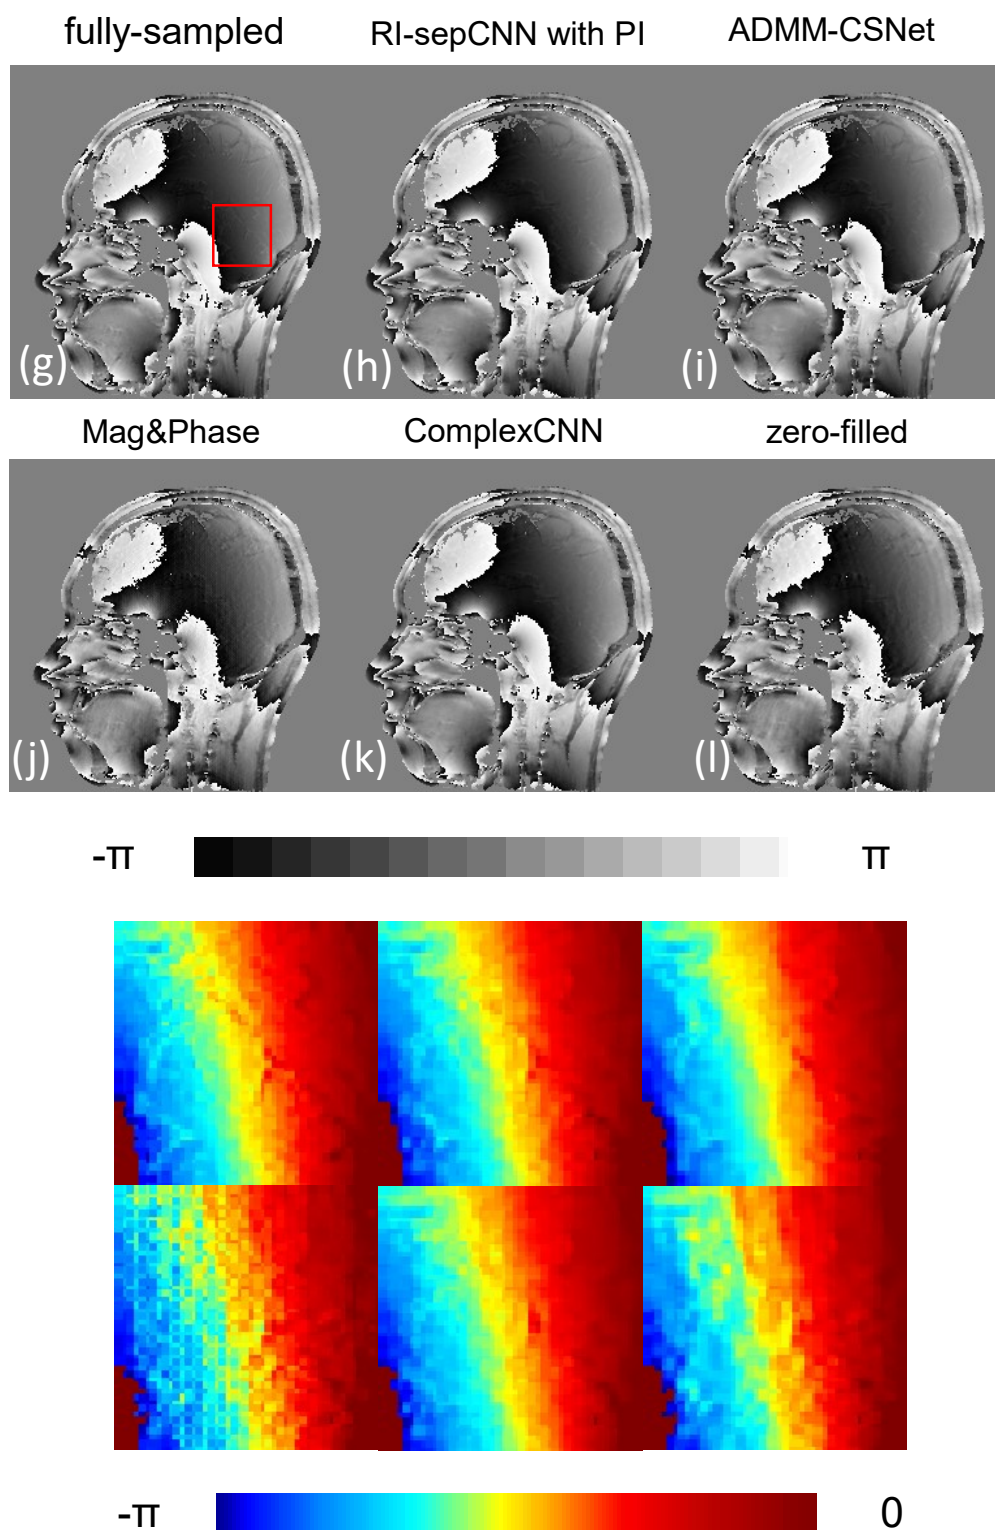


図 6.15: 信号比 40%の再構成像 (位相画像)

図 6.7, 図 6.8 より, 収集信号比 20%では各手法間の PSNR, SSIM, RMSE の差は小さかったものの, 提案法と ComplexCNN は他手法と比較して高い数値を示していた. 特に PSNR と RMSE では RI-sepCNN や RI-sepCNN with PI が, SSIM では ComplexCNN が最も優れた結果となった. 一方で, 収集信号比の増加に伴って, 各手法間の定量的評価の差は大きく開いたが, RI-sepCNN を基本とした手法と ComplexCNN は良好な結果を示していた. 収集信号比 40%では, 手法間の相対的な性能の優劣は, ADMM-CSNet を除いて収集信号比 30%のときと同様の結果を示した. 収集信号比が 20%と 30%の場合では RI-sepCNN with PI の PSNR と RMSE が, 収集信号比が 40%の場合では ADMM-CSNet の PSNR と SSIM が最良の結果となった.

再構成像を手法ごとに比較すると, いずれの信号比においても ADMM-CSNet では平滑化による被写体構造の消失が, Mag&Phase ではアーチファクト状の乱れが確認できた. また, RI-sepCNN with PI と ComplexCNN は, いずれも比較的良好な画像が得られた. ここでは, RI-sepCNN with PI と ComplexCNN について, 信号比ごとに詳細に比較する. 最初に, 図 6.9, 図 6.10 の信号比 20%では, 両手法ともアーチファクトの少ない良好な画像が得られたが, 図 6.11(q) の ComplexCNN の差分画像では鼻近辺で比較的大きな誤差が生じた. 図 6.12, 図 6.13 の信号比 30%では, 両手法は他手法と比較して画像の構造が良好に保存されていた. 位相画像を比較すると, (h) の RI-sepCNN with PI では破線と矢印で示した箇所において, ComplexCNN よりも位相の小さな変化を良好に保存できた. 図 6.14, 図 6.15 の信号比 40%では, (e) の ComplexCNN の拡大画像において, 小脳の輪郭にアーチファクトの残存に伴うぼけが発生していた.

## 6.4 等間隔間引きパターンによる再構成

5.6 節での検討より, CNN では等間隔な間引きパターンを用いても画像の復元が可能であることが示された. そこで本検討では, 6.3 節の検討で収集信号比 40% の際に良好な結果を示した RI-sepCNN with PI と ADMM-CSNet について, 原点对称性を満たす等間隔間引きパターンを使用した再構成を行った. 使用するパターンは,  $k$  空間の中心部から近い位置では高密度に, 遠い位置では低密度に間引くように 2 段階の間隔を設定しており, 収集信号比は 20%, 30%, 40% の 3 通りとした. 2 手法による再構成像の RMSE, PSNR, SSIM の平均値を図 6.16, 図 6.17 に, 使用した間引きパターンおよび再構成像を図 6.18 に示す. コヒーレント性の高いアーチファクトが発生する条件であることから, ADMM-CSNet では全体的に平滑化の傾向が強く見られたが, 提案法では細部構造を良好に復元できたため, 定量的評価では RI-sepCNN が優れた結果となった.




図 6.16: 再構成像の平均 RMSE




図 6.17: 再構成像の平均 PSNR, SSIM



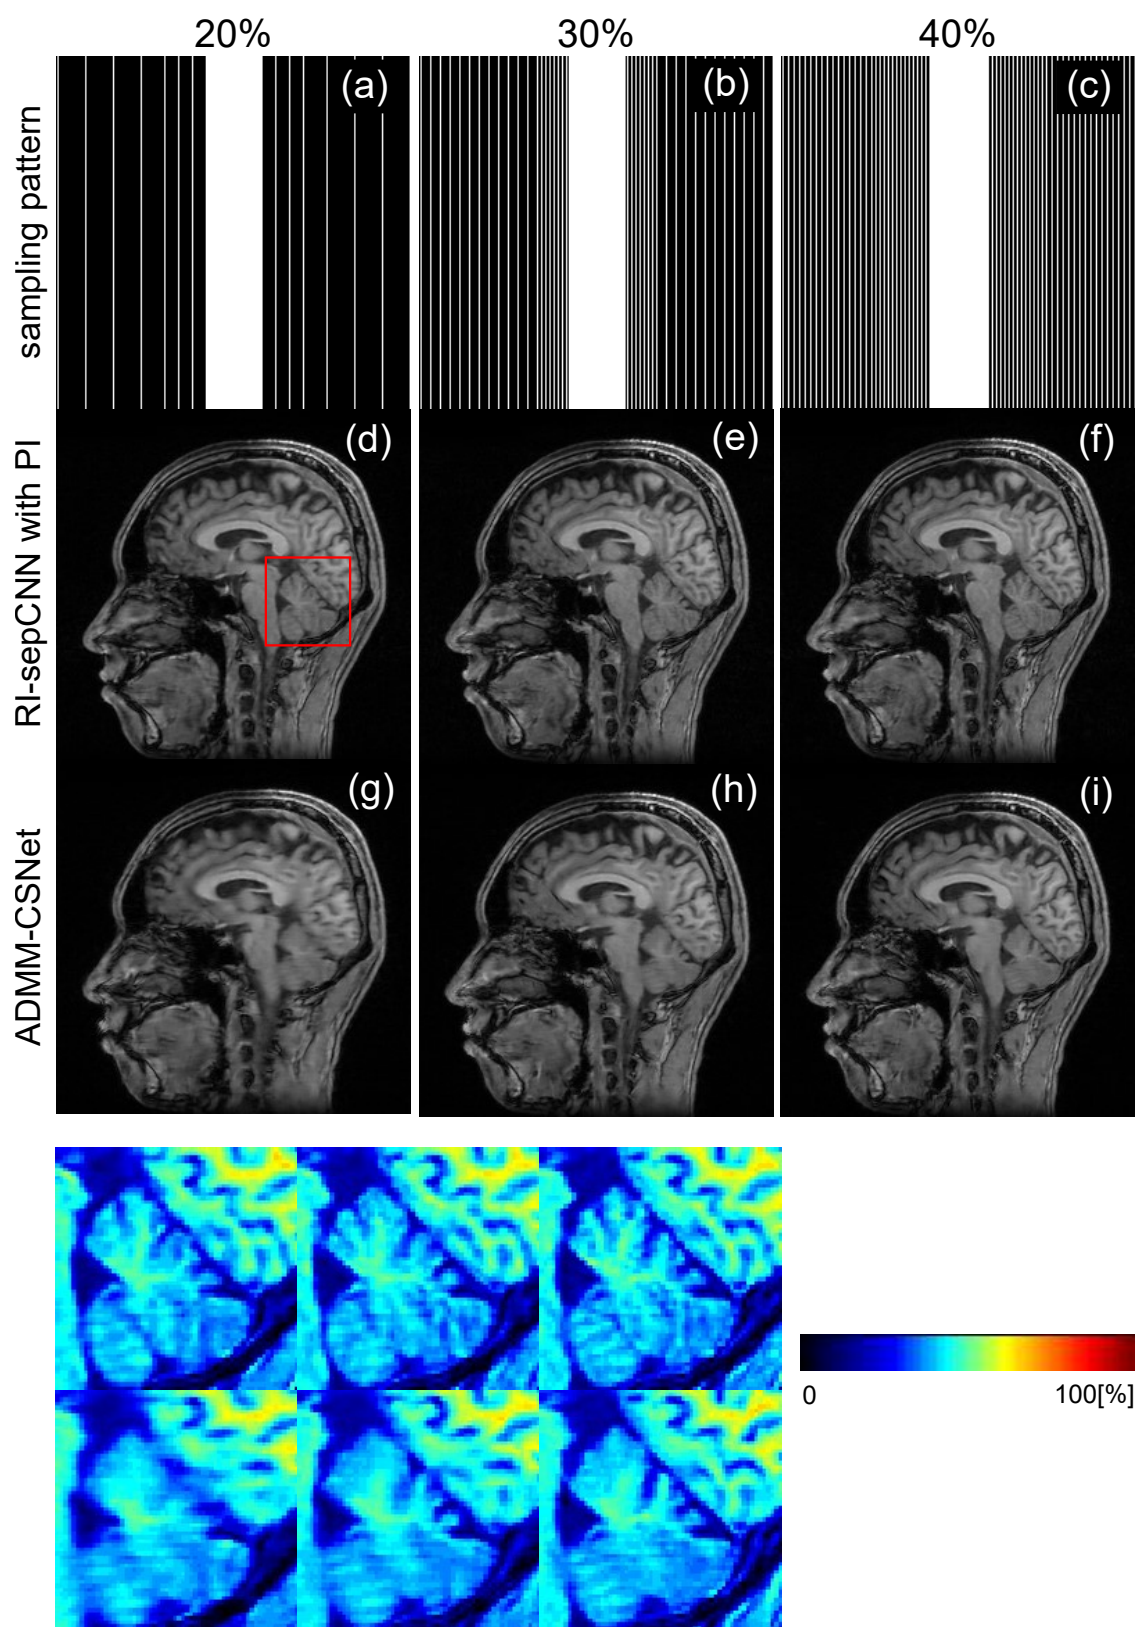


図 6.18: 等間隔間引きパターンを使用したときの再構成像

## 6.5 考察

### 6.5.1 位相変化の複雑さと再構成像の品質に関して

6.2 節では、人工的な位相分布を重畳した画像による再構成実験を行った。その結果、図 6.2 から図 6.6 より、ADMM-CSNet, Mag&Phase, CS-MRI Complex では位相が複雑さを増すにつれて再構成像の品質が低下したが、ComplexCNN と RI-sepCNN では位相変化に対して頑健な結果となった。一般に、位相分布は不連続であり、 $\pi$  と  $-\pi$  において微分不可能であるため、分布の推定は難しい。このため、位相分布を Image Domain Learning タイプの CNN で学習する Mag&Phase では、位相変化の複雑さが増すにつれて分布の推定が困難となり、再構成像には大きな誤差が生じた。また、ADMM-CSNet は複素数対応の手法であるが、CNN 中の畳み込み処理では、複素データの実部と虚部を分離してそれぞれに対して処理を行っており、畳み込み処理の後に適用される非線形の活性化関数は、実部と虚部が分離されたままの状態ですべてそれぞれ独立に適用される。したがって、CNN での計算過程で位相の情報を維持できず、位相変化の複雑度が増すにつれて RMSE が急速に増加した。ComplexCNN は複素数の構造を考慮できる手法であるが、実部用と虚部用でそれぞれに層が必要となる。そのため CNN 構造の深層化とパラメータ数の増大の影響で、逆伝播の計算が進むにつれて勾配の情報が消失し、被写体の細かなコントラストの変化を復元できなかったと考えられる。以上の要因により、RI-sepCNN with PI は他手法と比較して高い PSNR を示した。加えて、図 6.4 より RI-sepCNN と RI-sepCNN with PI では、RI-sepCNN with PI の方が高い PSNR と SSIM を示していることから、輝度反転画像の併用法は効果的であり、性能の向上に寄与すると推測できる。

6.3 節では各再構成法の収集信号比ごとの再構成像の品質を比較した。RI-sepCNN を基本とする手法では、図 6.8 より、収集信号比が 40% の場合を除いて、比較手法の中で最も高い PSNR を示した。また、RI-sepCNN と RI-sepCNN with PI の比較より、輝度反転画像の併用の効果は収集信号比が高いときほど有効な結果となった。RI-sepCNN with PI に導入した輝度反転画像の併用は、データ拡張および Test Time Augmentation<sup>[94]</sup> と同等の効果が期待できる手法である。RI-sepCNN with PI におけるデータ拡張は、学習用画像の輝度を反転した画像を生成することで、新たな特徴を持つ画像を生成し、学習枚数の増加や CNN の特徴認識能力の向上を図る手法である。一方で、Test Time Augmentation は、学習済み CNN によるテストの際に、オリジナルの輝度を持つ画像と輝度を反転した画像の 2 通りの画像を与え、式 (4.19)、式 (4.20) の加算平均処理で再構成像を生成することで、アーチファクトの減少と構造の復元性能の向上を図る手法である。したがって、データ拡張による学習枚数の増加の効果はいずれの収集信号比に対しても期待できるが、Test Time Augmentation につい

ては、加算する再構成像に平滑化等の様相が見られる場合、加算平均によって平滑化が強調される場合がある。図 6.9 から図 6.15 より、収集信号比が少ない場合の再構成像では被写体構造の消失や平滑化の傾向が見られたが、信号比の増加につれてその傾向は小さくなったため、図 6.8 のように信号比が増加するにつれて輝度反転画像の併用の効果が高くなった。

Mag&Phase では、大きく変化する位相を CNN が推定できず、その影響が再構成像の絶対値画像にも生じたため、他手法と比較して定量的評価の結果は優れなかった。しかし、強度画像に関しては、通常の実関数画像の再構成と同様の処理であり、位相を考慮する必要がないことから、細部構造の描出は比較的良好に行えた。

ADMM-CSNet では、信号比 40%において比較手法の中で最も高い PSNR や SSIM の値を示したものの、再構成像にはいずれの信号比でも平滑化の傾向が見られた。ADMM-CSNet は Transform Learning に分類される手法であり、反復的再構成法である ADMM を CNN で実装している。そのため、損失関数には画像空間での MSE を採用しているものの、この損失の逆伝播は Image Domain Learning を基本とした CNN よりも困難である。また、平滑化は被写体中のコントラスト差の小さな領域周辺で主に発生しているが、これらの領域の誤差は、MSE 等の数値的指標においては比較的小さな値として現れる。したがって、細かな損失の情報が逆伝播しにくく、パラメータの更新に反映されなかったと考えられる。

ComplexCNN は、複素数に対応した関数の導入により、本検討で用いた手法の中では最も複素数の構造を考慮できる手法である。複素数に対応した畳み込みやバッチ正規化等を提案した Trabelsi らは、複数の画像処理タスクで複素数型 CNN の検証を行った<sup>[79]</sup>が、実数型 CNN と複素数型 CNN の比較では、複素数型 CNN の性能が常に優れているとは限らず、2 つの CNN の性能は用いるデータセットやタスク、CNN 構造によって異なることが報告されている。複素数に対応した畳み込みでは、畳み込みフィルターを実部用と虚部用で独立に設けるため、CNN 構造の深層化を図りやすいが、その反面、パラメータ数の増加は過学習等の性能低下を招く可能性がある。複素数に対応し、なおかつ安定的に学習を行える手法は、実数型 CNN と比較すると十分に提案されていないといえる。一方で RI-sepCNN では、複素画像の実部と虚部を実関数画像として独立に再生し、2 ch の入出力を持つ実関数型 CNN で再構成を行うため、既存の関数を CNN に導入でき、ComplexCNN と比較してエイリアシングアーチファクトの学習処理は簡素化される。また、RI-sepCNN では、輝度反転画像の併用によるデータ拡張と Test Time Augmentation が適用可能である。以上の要因により、RI-sepCNN は ComplexCNN よりも優れた性能を示した。

6.4 節では RI-sepCNN with PI と ADMM-CSNet について、 $k$  空間の中心からの距離に応じて間引き間隔を変更する、可変密度等間隔間引きパターンを用いた再構成像の品質を比較した。その結果、RI-sepCNN with PI の PSNR はランダムな間引きパターンのときよりも高く、

ADMM-CSNet はランダムな間引きパターンのときよりも低い PSNR となった。RI-sepCNN は、Image Domain Learning 型の CNN であるため、5.6 節で DRL-CNN に対して行った検討と同様の理由により、本検討でも等間隔間引きに対して高い頑健性を示した。また、全領域を等間隔に間引くことでアーチファクトのコヒーレント性が増したため、ランダムな間引きの場合と比較して CNN によるアーチファクトの認識が容易になった。一方で、コヒーレント性の高いアーチファクトは、5.6 節の C-SALSA-B の結果のように圧縮センシングの反復的再構成法において元画像の復元が困難な条件であり、反復法である ADMM を CNN に導入した ADMM-CSNet では性能の低下が見られた。

### 6.5.2 処理時間に関して

ComplexCNN では複素数の畳み込み処理のために、実数での乗算処理が 4 回、実数での加算処理が 2 回生じるため、実数値を扱う CNN よりも計算時間が増加する。また、ADMM-CSNet は Unrolling-based モデルであり、L1-L2 ノルム最小化問題を解くための反復処理に相当する処理を、層を重ねることで実現しているため、学習と再構成ともに時間を要した。その一方で、RI-sepCNN は複素数であることを考慮せずに、実関数型の CNN を用いるため、比較した手法の中では処理時間が最短となった。また、RI-sepCNN with PI は輝度反転画像とオリジナルの輝度を持つ画像を併用することから、RI-sepCNN の 2 倍の学習時間を必要としたため、ComplexCNN に匹敵する学習時間となった。

## 第7章 結論

MRIの撮像を高速化するために導入する圧縮センシングにおいて、間引きをされた少数の観測信号から画像を再構成する問題を、深層学習によって行う方法について検討を行った。はじめに、実関数画像を想定したCNN再構成法であるDRL-CNNを、信号の間引き方法や収集信号比の観点から既存の反復的再構成法と比較した。その結果、DRL-CNNでは1次元ランダム収集において比較手法に比肩するPSNRとSSIMが得られ、再構成時間は大幅に短縮されること、信号空間での誤差軽減処理であるデータ整合性処理によって再構成像の品質が向上することが示された。また、反復的再構成法ではインコヒーレント性の高くなるランダムな間引き方法が再構成像の高品質化に寄与するのに対して、CNNによる再構成法ではインコヒーレント性の低くなるランダム性の低い間引き方法において高いPSNRとSSIMを得られることが明らかになった。これらの検討から、CNNを用いた画像空間での再構成法と反復的再構成法のそれぞれが持つ特徴を明らかにできた。

次に、MRIで得られる位相画像に対応するために、先に検討した実関数型CNNを利用する新たな再構成法について検討を行った。この方法では、実関数化した実部像と虚部像を利用した、学習時とテスト時の新たなデータ拡張法を導入した。規則的な位相変化を与えた複素画像と臨床で得られた複素画像を用いた再構成実験の結果、提案法では比較に用いた複素数対応型のCNN再構成法を上回る品質の再構成像が得られた。これらの検討から、複素画像を実関数型のCNNで再構成する方法の有効性が示された。

以上より、MRIの画像再構成をCNNによって行う手法は、再構成の高速化と再構成像の高品質化が実現できる有意な手法であることが示された。今後の課題として、MR画像は一般的な自然画像と比較して学習に利用できる画像枚数が少ないことから、提案法を少数の学習データもしくは学習データを用いずに再構成が行える手法へと発展していくこと、QSMやSWI等の位相情報を用いた画像再生法に応用すること、多重解像度解析手法等の画像解析法をCNN再構成に導入することで再構成像の高品質化を図ること等があげられる。

## 参考文献

- [1] F.Bloch, “Nuclear induction,” *Physical Review* 1946; 70:460-474.
- [2] EM.Purcell, HC.Torrey, RV.Pound, “Resonance Absorption by Nuclear Magnetic Moments in a Solid,” *Physical Review* 1946; 69:37-38.
- [3] KP.Pruessmann, M.Weiger, MB.Scheidegger, P.Boesiger, “SENSE: sensitivity encoding for fast MRI,” *Magnetic Resonance in Medicine* 1999; 42:952-962.
- [4] MA.Griswold, PM.Jakob, RM.Heidemann et al., “Generalized autocalibrating partially parallel acquisitions (GRAPPA),” *Magnetic Resonance in Medicine* 2002; 47:1202-1210.
- [5] DL.Donoho, “Compressed Sensing,” *IEEE Transactions on Information Theory* 2006; 52:1289-1306.
- [6] M.Lustig, DL.Donoho, J.Pauly, “Sparse MRI: The Application of Compressed Sensing for Rapid MR Imaging,” *Magnetic Resonance in Medicine* 2007; 58:1182-1195.
- [7] EJ.Candes, MB.Wakin, “An Introduction To Compressive Sampling,” *IEEE Signal Processing Magazine* 2008; 25:21-30.
- [8] A.Krizhevsky, I.Sutskever, GE.Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS)*, Lake Tahoe, Nevada, USA, 2012, 1097–1105.
- [9] P.Isora, JY.Zhu, T.Zhou, et al., “Image-to-Image Translation with Conditional Adversarial Networks,” *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, Hawaii, USA, 2017, 5967-5976.
- [10] C.Dong, CC.Loy, K.He, et al., “Learning a Deep Convolutional Network for Image Super-Resolution,” *Proceedings of the European Conference on Computer Vision* 2014, Zurich, Switzerland, 2014.
- [11] K.Zhang, W.Zuo, Y.Chen, et al., “Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising,” *IEEE Transactions on Image Processing* 2017; 26:3142-3155.

- [12] A.Oord, S.Dieleman, H.Zen, et al., “WaveNet: A Generative Model for Raw Audio,” arXiv:1609.03499.
- [13] G.Hinton, L.Deng, D.Yu, “Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups,” *IEEE Signal Processing Magazine* 2012; 29:82-97.
- [14] J.Devin, MW.Chang, K.Lee, et al., “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,” *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Minneapolis, Minnesota, USA, 2019*, 4171-4186.
- [15] HR.Roth, CT.Lee, HC.Shin, et al., “Anatomy-specific classification of medical images using deep convolutional nets,” *Proceedings of the IEEE 12th International Symposium on Biomedical Imaging, New York, USA, 2015*, 101-104.
- [16] X.Zhao, Y.Zhang, Y.Qin, et al., “Single MR image super-resolution via channel splitting and serial fusion network,” *Knowledge-Based Systems* 2022; 246:108669.
- [17] M.Kidoh, K.Shinoda, M.Kitajima, et al., “Deep Learning Based Noise Reduction for Brain MR Imaging: Tests on Phantoms and Healthy Volunteers,” *Magnetic Resonance in Medical Sciences* 2020; 19:195-206.
- [18] S.Wang, Z.Su, L.Ying, et al., “Accelerating magnetic resonance imaging via deep learning,” *Proceedings of the IEEE 13th International Symposium on Biomedical Imaging, Prague, Czech Republic, 2016*, 514–517.
- [19] E.Kang, J.Min, JC.Ye, “A deep convolutional neural network using directional wavelets for low-dose X-ray CT reconstruction,” *Medical Physics* 2017; 44:e360-e375.
- [20] EM.Haacke, Y.Xu, YCN.Cheng, et al., “Susceptibility weighted imaging (SWI),” *Magnetic Resonance in Medicine* 2004; 52:612-618.
- [21] L.Rochefort, R.Brown, MR.Prince, et al., “Quantitative MR susceptibility mapping using piece-wise constant regularized inversion of the magnetic field,” *Magnetic Resonance in Medicine* 2008; 60:1003-1009.
- [22] K.Shmueli, JA.Zwart, P.Gelderen, et al., “Magnetic susceptibility mapping of brain tissue in vivo using MRI phase data,” *Magnetic Resonance in Medicine* 2009; 62:1510-1522.
- [23] R.Tibshirani, “Regression Shrinkage and Selection via the Lasso,” *Journal of the Royal Statistical Society : Series B (Statistical Methodology)* 1996; 58:267-288.

- [24] LI.Rudin, S.Osher, E.Fatemi, “Nonlinear total variation based noise removal algorithms,” *Physica D: Nonlinear Phenomena* 1992; 60:259-268.
- [25] J.Yang, Y.Zhang, W.Yin, “A Fast Alternating Direction Method for TVL1-L2 Signal Reconstruction From Partial Fourier Data,” *IEEE Journal of Selected Topics in Signal Processing* 2010; 4:288-297.
- [26] F.Knoll, K.Bredies, T.Pock, et al., “Second order total generalized variation (TGV) for MRI,” *Magnetic Resonance in Medicine* 2011; 65:480-491.
- [27] X.Qu, D.Guo, B.Ning, et al., “Undersampled MRI reconstruction with patch-based directional wavelets,” *Magnetic Resonance Imaging* 2012; 30:964-977.
- [28] Z.Zhu, K.Wahid, P.Babyn, et al., “Compressed Sensing-Based MRI Reconstruction Using Complex Double-Density Dual-Tree DWT,” *International Journal of Biomedical Imaging* 2013; 2013:907501.
- [29] E.J.Candes, DL.Donoho, “New tight frames of curvelets and optimal representations of objects with piecewise  $C^2$  singularities,” *Communications on Pure and Applied Mathematics* 2003; 57:219-266.
- [30] R.Kazama, K.Sekine, S.Ito, “Compressed Sensing in Magnetic Resonance Imaging Using Non-Randomly Under-Sampled Signal in Cartesian Coordinates,” *IEICE Transactions on Information and Systems* 2019; E102-D:1851-1859.
- [31] M.Hong, Y.Yu, H.Wang, et al., “Compressed sensing MRI with singular value decomposition-based sparsity basis,” *Physics in Medicine and Biology* 2011; 56:6311-6325.
- [32] Y.Wang, L.Ying, “Undersampled dynamic magnetic resonance imaging using kernel principal component analysis,” *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* 2014, 2014:1533-1536.
- [33] 伊東賢治, 伊藤聡志, 山田芳文, “Multi-scale eFREBAS 変換を利用した MR 画像の圧縮センシング,” *映像情報メディア学会誌* 2016; 70:J118-J124.
- [34] A.Beck, M.Teboulle, “A fast Iterative Shrinkage-Thresholding Algorithm with application to wavelet-based image deblurring,” *Proceedings of the 2009 IEEE International Conference on Acoustics, Speech and Signal Processing, Taipei, Taiwan, 2009*, 693-696.
- [35] T.Goldstein, S.Osher, “The Split Bregman Method for L1-Regularized Problems,” *SIAM Journal on Imaging Sciences* 2009; 2:323-343.



- [36] VP.Gopi, P.Palanisamy, KA.Wahid, et al., “MR Image Reconstruction Based on Iterative Split Bregman Algorithm and Nonlocal Total Variation,” *Computational and Mathematical Methods in Medicine* 2013; 2013:985819.
- [37] S.Boyd, N.Parikh, E.Chu, et al., “Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers,” *Foundations and Trends in Machine Learning* 2011; 3:1-122.
- [38] Y.Liu, JF.Cai, Z.Zhan, et al., “Balanced Sparse Model for Tight Frames in Compressed Sensing Magnetic Resonance Imaging,” *PLoS ONE* 2015; 10:e0119584.
- [39] X.Glorot, A.Bordes, Y.Bengio, “Deep Sparse Rectifier Neural Networks,” *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*, Fort Lauderdale, Florida, USA, 2011, 15:315-323.
- [40] AL.Maas, AY.Hannun, Ay.Ng, “Rectifier Nonlinearities Improve Neural Network Acoustic Models,” *Proceedings of the 30th International Conference on Machine Learning (ICML)*, Atlanta, Georgia, USA, 2013.
- [41] DP.Kingma, J.Ba, “Adam: A Method for Stochastic Optimization,” *arXiv:1412.6980*.
- [42] J.Duchi, E.Hazan, Y.Singer, “Adaptive Subgradient Methods for Online Learning and Stochastic Optimization,” *Journal of Machine Learning Research* 2011; 12:2121-2159.
- [43] T.Tieleman, G.Hinton, “Lecture 6.5—RmsProp: Divide the gradient by a running average of its recent magnitude,” *COURSERA: Neural Networks for Machine Learning* 2012.
- [44] S.Ioffe, C.Szegedy, “Batch normalization: accelerating deep network training by reducing internal covariate shift,” *Proceedings of the 32nd International Conference on Machine Learning*, Lille, France, 2015, 37:448-456.
- [45] 岡谷貴之：機械学習プロフェッショナルシリーズ 深層学習．講談社，2015；83-90.
- [46] O.Ronneberger, P.Fischer, T.Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*, Munich, Germany, 2015, 234-241.
- [47] CM.Hyun, HP.Kim, SM.Lee, et al., “Deep learning for undersampled MRI reconstruction,” *Physics in Medicine and Biology* 2018; 63:135007.
- [48] IJ.Goodfellow, J.Pouget-Abadie, M.Mirza, et al., “Generative Adversarial Nets,” *Proceedings of the 27th International Conference on Neural Information Processing Systems*, Montreal, Canada, 2016, 2672-2680.

- [49] M.Mardani, E.Gong, JY.Cheng, et al., “Deep Generative Adversarial Neural Networks for Compressive Sensing MRI,” *IEEE Transactions on Medical Imaging* 2019; 38:167-179.
- [50] J.Johnson, A.Alahi, L.Fei-Fei, “Perceptual Losses for Real-Time Style Transfer and Super-Resolution,” *Proceedings of the European Conference on Computer Vision 2016*, Amsterdam, Netherlands, 2016.
- [51] G.Yang, S.Yu, H.Dong, “DAGAN: Deep De-Aliasing Generative Adversarial Networks for Fast Compressed Sensing MRI Reconstruction,” *IEEE Transactions on Medical Imaging* 2018; 37:1310-1321.
- [52] Z.Wang, AC.Bovik, HR.Sheikh, et al., “Image Quality Assessment: From Error Visibility to Structural Similarity,” *IEEE Transactions on Image Processing* 2004; 13:600-612.
- [53] P.Deora, B.Vasudeva, S.Bhattacharya, et al., “Structure Preserving Compressive Sensing MRI Reconstruction using Generative Adversarial Networks,” *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, Seattle, Washington, USA, 2020, 2211-2219.
- [54] C.Qin, J.Schlemper, J.Caballero, et al., “Convolutional Recurrent Neural Networks for Dynamic MR Image Reconstruction,” *IEEE Transactions on Medical Imaging* 2019; 38:280-290.
- [55] EZ.Chen, P.Wang, X.Chen, et al., “Pyramid Convolutional RNN for MRI Image Reconstruction,” *IEEE Transactions on Medical Imaging* 2022; 41:2033-2047.
- [56] A.Vaswani, N.Shazeer, N.Parmar, et al., “Attention is all you need,” *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, California, USA, 2017, 6000–6010.
- [57] A.Dosovitskiy, L.Beyer, A.Kolesnikov, et al., “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” *arXiv:2010.11929*.
- [58] J.Huang, Y.Fang, Y.Wu, et al., “Swin transformer for fast MRI,” *Neurocomputing* 2022; 493:281-304.
- [59] P.Guo, Y.Mei, J.Zhou, et al., “ReconFormer: Accelerated MRI Reconstruction Using Recurrent Transformer,” *arXiv:2201.09376*.
- [60] JY.Zhu, T.Park, P.Isola, et al., “Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks,” *Proceedings of the 2017 IEEE International Conference on Computer Vision*, Venice, Italy, 2017, 2242-2251.

- [61] TM.Quan, T.Nguyen-Duc, WK.Jeong, “Compressed Sensing MRI Reconstruction Using a Generative Adversarial Network With a Cyclic Loss,” *IEEE Transactions on Medical Imaging* 2018; 37:1488-1497.
- [62] V.Lempitsky, A.Vedaldi, D.Ulyanov, “Deep Image Prior,” *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, Utah, USA, 2018, 9446-9454.
- [63] D.Zhao, Y.Huang, F.Zhao, et al., “Reference-Driven Undersampled MR Image Reconstruction Using Wavelet Sparsity-Constrained Deep Image Prior,” *Computational and Mathematical Methods in Medicine* 2021; 2021:8865582.
- [64] K.Hammernik, F.Knoll, DK.Sodickson, et al., “On the influence of Sampling Pattern Design on Deep Learning-Based MRI Reconstruction,” *Proceedings of the International Society of Magnetic Resonance in Medicine 25th Scientific Meeting*, Hawaii, USA, 2017, 0644.
- [65] HK.Aggarwal, MP.Mani, M.Jacob, “MoDL: Model-Based Deep Learning Architecture for Inverse Problems,” *IEEE Transaction on Medical Imaging* 2019; 38:394-405.
- [66] J.Zhang, B.Ghanem, “ISTA-Net Interpretable Optimization-Inspired Deep Network for Image Compressive Sensing,” *Proceedings of the 2018 IEEE/CVF Computer Vision and Pattern Recognition*, Salt Lake City, Utah, USA, 2018, 1828-1837.
- [67] Y.Yang, J.Sun, H.Li, et al., “ADMM-CSNet: A Deep Learning Approach for Image Compressive Sensing,” *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2020; 42:521-538.
- [68] Y.Chen, T.Xiao, C.Li, et al., “Model-Based Convolutional De-Aliasing Network Learning for Parallel MR Imaging,” *Proceedings of the 22nd International Conference on Medical Image Computing and Computer Assisted Intervention*, Shenzhen, China, 2019, 11766:30-38.
- [69] B.Zhu, JZ.Liu, SF.Cauley, et al., “Image reconstruction by domain-transform manifold learning,” *Nature* 2018; 555:487-492.
- [70] Y.Han, L.Sunwoo, JC.Ye, “k-Space Deep Learning for Accelerated MRI,” *IEEE Transactions on Medical Imaging* 2020; 39:377-386.
- [71] R.Souza, R.Frayne, “A Hybrid Frequency-domain/Image-domain Deep Network for Magnetic Resonance Image Reconstruction,” *Proceedings of the 2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images*, Rio de Janeiro, Brazil, 2019, 257-264.

- [72] T.Eo, Y.Jun, T.Kim, et al., “KIKI-net: cross-domain convolutional neural networks for reconstructing undersampled magnetic resonance images,” *Magnetic Resonance in Medicine* 2018; 80:2188-2201.
- [73] K.Kwon, D.Kim, H.Park, “A parallel MR imaging method using multilayer perceptron,” *Medical Physics* 2017; 44:6209-6224.
- [74] A.Sriram, J.Zbontar, T.Murrell, et al., “GrappaNet: Combining Parallel Imaging With Deep Learning for Multi-Coil MRI Reconstruction,” *Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, Washington, USA, 2020, 14303-14310,
- [75] J.Duan, J.Schlemper, C.Qin, et al., “VS-Net: Variable Splitting Network for Accelerated Parallel MRI Reconstruction,” *Proceedings of the 22nd International Conference on Medical Image Computing and Computer Assisted Intervention*, Shenzhen, China, 2019, 11767:713-722.
- [76] E.Cole, J.Cheng, J.Pauly, et al., “Analysis of deep complex-valued convolutional neural networks for MRI reconstruction and phase-focused applications,” *Magnetic Resonance in Medicine* 2021; 86:1093-1109.
- [77] D.Lee, J.Yoo, S.Tak, et al., “Deep Residual Learning for Accelerated MRI Using Magnitude and Phase Networks,” *IEEE Transactions on Biomedical Imaging* 2018; 65:1985-1995.
- [78] C.Trabelsi, O.Bilaniuk, Y.Zhang, et al., “Deep complex networks,” *Proceedings of the 6th International Conference on Learning Representations*, Vancouver, British Columbia, Canada, 2018.
- [79] S.Wang, H.Cheng, L.Ying, et al., “DeepcomplexMRI: Exploiting deep residual network for fast parallel MR imaging with complex convolution,” *Magnetic Resonance Imaging* 2020; 68:136-147.
- [80] J.Schlemper, J.Caballero, J.V.Hajnal, et al., “A Deep Cascade of Convolutional Neural Networks for Dynamic MR Image Reconstruction,” *IEEE Transactions on Medical Imaging* 2018; 37:491-503.
- [81] M.Arjovsky, A.Shah, Y.Bengio, “Unitary evolution recurrent neural networks,” *Proceedings of the 33rd International Conference on Machine Learning*, New York, USA, 2016, 48:1120-1128.

- [82] K.Simonyan, A.Zisserman, “Very deep convolutional networks for large-scale image recognition,” Proceedings of the 3rd International Conference on Learning Representations, San Diego, California, USA, 2015.
- [83] K.Dabov, A.Foi, V.Katkovnik, et al., “Image denoising by sparse 3-D transform-domain collaborative filtering,” IEEE Transactions on Image Processing 2007; 16:2080-2095.
- [84] Y.Chen, T.Pock, “Trainable Nonlinear Reaction Diffusion: A Flexible Framework for Fast and Effective Image Restoration,” IEEE Transactions on Pattern Analysis and Machine Intelligence 2017; 39:1256-1272.
- [85] S.Gu, L.Zhang, W.Zuo, et al., “Weighted nuclear norm minimization with application to image denoising,” Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, Ohio, USA, 2014, 2862-2869.
- [86] K.He, X.Zhang, S.Ren, et al., “Deep Residual Learning for Image Recognition,” Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Nevada, USA, 2016, 770-778.
- [87] S.Ito, Y.Yamada, “Compressed sensing for magnetic resonance images with phase variations,” Proceedings of the 2014 IEEE International Conference on Acoustics, Speech and Signal Processing, Florence, Italy, 2014, 6598-6601.
- [88] IXI dataset. <https://brain-development.org/ixi-dataset/> (Accessed: November 25, 2022)
- [89] A.Vedaldi, K.Lenc, “MatConvNet: Convolutional Neural Networks for MATLAB,” Proceedings of the 23rd ACM international conference on Multimedia, Brisbane, Australia, 2015, 689-692.
- [90] complexPyTorch. <https://github.com/wavefrontshaping/complexPyTorch> (Accessed: November 25, 2022)
- [91] MW.Matthès, Y.Bromberg, J.Rosny, et al., “Learning and Avoiding Disorder in Multimode Fibers,” Physical Review X 2021; 11:021060.
- [92] F.Zhao, DC.Noll, JF.Nielsen, et al., “Separate magnitude and phase regularization via compressed sensing,” IEEE Transactions on Medical Imaging 2012; 31:1713-1723.
- [93] RH.Byrd, P.Lu, J.Nocedal, et al., “A Limited Memory Algorithm for Bound Constrained Optimization,” SIAM Journal on Scientific Computing 1995; 16:1190-1208.

- [94] D.Shanmugam, D.Blalock, G.Balakrishnan, et al., “Better Aggregation in Test-Time Augmentation,” Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision, Montreal, Quebec, Canada, 2021, 1194-1203.

# 謝辞

本研究を進めるにあたり、終始適切な助言を賜り、熱心にご指導いただきました指導教員の宇都宮大学大学院 工学研究科 伊藤 聡志教授に厚く御礼申し上げます。

また、本研究をまとめるにあたり、有益なご助言をいただきました副指導教員の宇都宮大学大学院 上村 佳嗣教授、長谷川 まどか教授に深く感謝申し上げます。同じく副指導教員である同大学院 外山 史准教授、森 博志准教授には、副専門研修においてもご指導をいただき、本研究をまとめるにあたって有益なご助言をいただきました。深く感謝申し上げます。

同大学院 山登 一輝助教には、本研究を進めるにあたり日頃から丁寧なご指導をいただきました。ここに感謝申し上げます。

本研究で使用したMR画像をご提供いただいたキヤノンメディカルシステムズ（旧東芝メディカルシステムズ）および、IXI dataset を提供する Information eXtraction from Images プロジェクトに感謝の意を表します。

博士前期課程を修了した風間 椋氏、加藤 慶大氏、齋藤 牧氏、佐々木 裕也氏、高野 航平氏、竹間 康浩氏、植松 駿氏、佐藤 佑紀氏、若槻 泰迪氏、島田 みなみ氏、須貝 太郎氏、宮本 裕大氏、平野 幸輝氏や、博士前期課程に在籍中の阿部 真弥氏、金澤 崇大氏、渋井 雅希氏、宮田 晶子氏、植田 貴之氏、佐藤 裕貴氏、深津 純奈氏をはじめとする伊藤・山登研究室 諸氏には、本研究を進めるにあたり、日頃からご助言をいただきました。心より感謝いたします。

また、日頃からお世話になりました宇都宮大学 情報工学技術職員の月川 淳氏、北本 拓磨氏、加治原 翔太氏、元技術職員の川上 典男氏に感謝の意を表します。

2023年3月 大内 翔平