

Universidade de Brasília – UnB  
Campus Gama – FGA  
Engenharia Eletrônica

**ANÁLISE DE PRÉ-FILTRAGEM PARA A RECONSTRUÇÃO DE  
IMAGENS DE RESSONÂNCIA MAGNÉTICA EM  
*Compressive Sensing* COM INFORMAÇÃO A PRIORI**

**ARIVANE NORONHA MACHADO**

Orientador: Dr. CRISTIANO JACQUES MIOSSO



**UNB – UNIVERSIDADE DE BRASÍLIA**

**FGA – FACULDADE GAMA**

**ENGENHARIA ELETRÔNICA**

**ANÁLISE DE PRÉ-FILTRAGEM PARA A RECONSTRUÇÃO DE IMAGENS  
DE RESSONÂNCIA MAGNÉTICA EM *Compressive Sensing* COM  
INFORMAÇÃO A PRIORI**

**ARIVANE NORONHA MACHADO**

**ORIENTADOR: CRISTIANO JACQUES MIOSSO**

**TRABALHO DE CONCLUSÃO DE CURSO  
ENGENHARIA ELETRÔNICA**

**BRASÍLIA/DF, FEVEREIRO DE 2023**

UNB – UNIVERSIDADE DE BRASÍLIA  
FGA – FACULDADE GAMA  
ENGENHARIA ELETRÔNICA

ANÁLISE DE PRÉ-FILTRAGEM PARA A RECONSTRUÇÃO DE IMAGENS  
DE RESSONÂNCIA MAGNÉTICA EM *Compressive Sensing* COM  
INFORMAÇÃO A PRIORI

ARIVANE NORONHA MACHADO

TRABALHO DE CONCLUSÃO DE CURSO SUBMETIDO À FACULDADE UNB GAMA DA  
UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A  
OBTENÇÃO DO GRAU DE BACHAREL EM ENGENHARIA ELETRÔNICA

APROVADA POR:

---

Cristiano Jacques Miosso

(Orientador)

---

Prof. Dr. Marcos Vinícius Chaffim Costa

---

MSc. Filipe Emídio Torres

**FICHA CATALOGRÁFICA**

MACHADO, ARIVANE NORONHA

Análise de Pré-Filtragem para a Reconstrução de Imagens de Ressonância Magnética em *Compressive Sensing* com Informação A Priori

Distrito Federal, 2022.

48p., 210 × 297 mm (FGA/UnB Gama, Bacharelado em Engenharia Eletrônica, 2020).

Trabalho de Conclusão de Curso, Faculdade UnB Gama, Engenharia Eletrônica

- |   |                               |
|---|-------------------------------|
| 1. Imageamento de Ressonância Magnética | 2. <i>Compressive Sensing</i> |
| 3. Pré-filtragem                        | 4. Informação a Priori        |
| I. FGA UnB/UnB.                         | II. Título (série)            |

**REFERÊNCIA**

MACHADO, ARIVANE NORONHA (2023). Análise de Pré-Filtragem para a Reconstrução de Imagens de Ressonância Magnética em *Compressive Sensing* com Informação A Priori. Trabalho de Conclusão de Curso, Engenharia Eletrônica, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 48p.

**CESSÃO DE DIREITOS**

AUTOR: Arivane Noronha Machado

TÍTULO: Análise de Pré-Filtragem para a Reconstrução de Imagens de Ressonância Magnética em *Compressive Sensing* com Informação A Priori

GRAU: Bacharel em Engenharia Eletrônica

ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta monografia de conclusão de curso e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta monografia pode ser reproduzida sem a autorização por escrito do autor.

---

arivane.machado@gmail.com

Brasília, DF – Brasil

## RESUMO

A ressonância magnética é uma técnica de imageamento médico pautada na utilização de gradientes magnéticos, frequentemente utilizada por ser segura e eficaz. Por proporcionar imagens de alta qualidade em que é possível aferir variadas informações sobre a condição do paciente, é comum utilizá-las para treinamento de algoritmos de *Machine Learning* e *Deep Learning* para classificação, bem como no estudo de processamento de imagens.

Todavia, a principal limitação da ressonância magnética é o tempo de aquisição das medidas, em que o paciente fica imóvel durante todo o exame, sendo mais difícil para pessoas claustrofóbicas e crianças. Tendo em vista essas limitações, desde 1970 existem pesquisas para diminuir o tempo de aquisição e, atualmente, há vários estudos técnicas que utilizam poucas medidas para reconstruir imagens de ressonância magnética, como *Compressive Sensing*. O *Compressive Sensing* é uma metodologia de amostragem de sinais fundamentado na representação esparsa dos sinais e um domínio conhecido, sendo possível utilizar em conjunto com a pré-filtragem, uma vez que auxilia na esparsificação dos sinais. Além disso, também há estudos sobre *Compressive Sensing* e informação a priori, em que a informação a priori utiliza medidas anteriores para reconstruir o sinal futuro. Contudo, não foram encontrados estudos sobre o impacto de usar em conjunto pré-filtragem e informação a priori.

Dessa forma, o objetivo desse trabalho é analisar como a pré-filtragem e informação a priori impactam na reconstrução em *Compressive Sensing* de imagens de ressonância magnética, bem como avaliar o comportamento de diferentes filtros para a pré-filtragem, usando a *SNR* das imagens como métrica de comparação. Para tanto, os algoritmos de *Compressive Sensing* e pré-filtragem foram validados por meio da reconstrução do fantoma de Shepp-Logan e uma imagem de ressonância magnética de cabeça. Posteriormente, foi realizado um breve experimento com informação a priori reconstruindo sinais aleatórios no domínio 1d.

Com todas as técnicas validadas, foram realizadas 55 reconstruções da mesma imagem de cabeça utilizando apenas *Compressive Sensing* e pré-filtragem, com o objetivo de identificar os filtros que fornecem maior *SNR*, tendo como resultado os filtros de *Daubachies* de ordem 2 e *Fejér-Korovkin* de ordem 4. Para testar o comportamento dos filtros selecionados com outras imagens, foram usadas ressonâncias de abdômen, pélvis, coxas e pés, provenientes da base *Visible Human Project*. Em todas as reconstruções, a *SNR* foi maior utilizando informação a priori e o menor resultado de pré-filtragem foi de *Daubachies*. Por conseguinte, no teste posterior, usou-se apenas os filtros de *Haar* e *Fejér-Korovkin*, que consiste na reconstrução de 40 imagens de cabeça diferentes, sem e com informação a priori. A reconstrução utilizando *Haar* e informação a priori obteve a maior média, 23, 2dB em contrapartida a de *Fejér-Korovkin*, 22, 8. Por fim, para analisar as médias obtidas dos resultados anteriores, aplicou-se testes estatísticos para os

seguintes casos: *Haar* e *Fejér-Korovkin* sem informação a priori, *Haar* e *Fejér-Korovkin* com informação a priori e ganho utilizando *Haar* e *Fejér-Korovkin*. Para a ressonância magnética funcional, foi utilizado o conteúdo disponível no banco FBIRN, em que 10 *frames* foram reconstruídos utilizando os mesmos parâmetros da imagem anatômica.

Conforme os resultados obtidos, foi possível concluir que utilizar informação a priori com pré-filtragem fornece maior *SNR* para a imagem final, contudo, o ganho não é muito acentuado para filtros que esparsificam mais a imagem, como foi notado para *Haar*. Assim, o ganho é maior para os filtros menos esparsificadores, como *Daubachies* e *Fejér-Korovkin*.

**Palavras-chave:** Imagem de Ressonância Magnética, *Compressive Sensing*, Pré-Filtragem, Informação a Priori.

## ABSTRACT

Magnetic resonance imaging is a medical imaging technique based on the use of magnetic gradients, often used because it is safe and effective. By providing high quality images in which it is possible to assess various information about the patient's condition, it is common to use them for training Machine Learning and Deep Learning algorithms for classification, as well as in the study of image processing.

However, the main limitation of magnetic resonance imaging is the time taken to acquire the measurements, in which the patient remains motionless throughout the examination, which is more difficult for claustrophobic people and children. In view of these limitations, since 1970 there have been studies to reduce the acquisition time and, currently, there are several technical studies that use few measurements to reconstruct magnetic resonance images, such as Compressive Sensing. The Compressive Sensing is a signal sampling methodology based on the sparse representation of the signals and a known domain, being possible to use together with the pre-filtering, since it helps in the sparsification of the signals. In addition, there are also studies on Compressive Sensing and prior information, in which the prior information uses previous measurements to reconstruct the future signal. However, no studies were found on the impact of using pre-filtering and prior information together.

Thus, the objective of this work is to analyze how pre-filtering and prior information impact the Compressive Sensing reconstruction of magnetic resonance images, as well as to evaluate the behavior of different filters for pre-filtering, using the SNR of the images as a comparison metric. For this purpose, the Compressive Sensing and pre-filtering algorithms were validated through the reconstruction of the Shepp-Logan phantom and a magnetic resonance image of the head. Subsequently, a brief experiment with prior information was carried out by reconstructing random signals in the 1d domain.

With all techniques validated, 55 reconstructions of the same head image were performed using only Compressive Sensing and pre-filtering, with the aim of identifying the filters that provide the highest SNR, resulting in Daubachies filters of order 2 and Fejér-Korovkin of order 4. To test the behavior of the selected filters with other images, resonances of the abdomen, pelvis, thighs and feet, coming from the base Visible Human Project, were used. In all reconstructions, the SNR was highest using prior information and the lowest pre-filtering result was Daubachies. Therefore, in the subsequent test, only the Haar and Fejér-Korovkin filters were used, which consists of the reconstruction of 40 different head images, with and without prior information. The reconstruction using Haar and prior information obtained the highest average,  $23.2dB$  in contrast to

Fejér-Korovkin, 22.8. Finally, to analyze the averages obtained from the previous results, statistical tests were applied for the following cases: Haar and Fejér-Korovkin without prior information, Haar and Fejér-Korovkin with prior information and gain using Haar and Fejér-Korovkin. For functional magnetic resonance imaging, the content available in the FBIRN bank was used, in which 10 frames were reconstructed using the same parameters of the anatomical image.

According to the results obtained, it was possible to conclude that using prior information with pre-filtering provides higher SNR for the final image, however, the gain is not very pronounced for filters that sparsify the image more, as noted for Haar. Thus, the gain is greater for less sparsifying filters, such as Daubachies and Fejér-Korovkin.

**Keywords:** Magnetic Resonance Imaging, Compressive Sensing, Pre filtering, Prior Information.



## SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	O Contexto do Imageamento Médico: Vantagens e Desafios da Ressonância Magnética . . . . .	1
1.2	Definição do Problema Científico e Proposta de Pesquisa . . . . .	3
1.3	Objetivos . . . . .	5
1.3.1	Objetivo Geral . . . . .	5
1.3.2	Objetivos Específicos . . . . .	5
1.4	Estrutura da Dissertação . . . . .	5
<b>2</b>	<b>Fundamentação teórica e Estado da Arte</b>	<b>7</b>
2.1	Princípios da Ressonância Magnética . . . . .	7
2.1.1	A física da Ressonância Magnética . . . . .	10
2.2	<i>Compressive Sensing</i> . . . . .	12
2.2.1	<i>Compressive Sensing</i> e Pré-Filtragem . . . . .	12
2.2.2	<i>Compressive Sensing</i> e Informação a Priori . . . . .	13
<b>3</b>	<b>Materiais e Métodos</b>	<b>15</b>
3.1	<b>Banco de Imagens</b> . . . . .	15
3.1.1	NLM Visible Human Project . . . . .	15
3.1.2	Functional Imaging BIRN . . . . .	16

3.2	Reconstrução por <i>Compressive Sensing</i> de imagens artificiais já esparsas no domínio de pixels . . . . .	17
3.3	<i>Compressive Sensing</i> com Pré-filtragem de imagens de ressonância magnética . . . . .	18
3.3.1	Composição espectral . . . . .	19
3.4	Reconstrução por <i>Compressive Sensing</i> de sinais aleatórios no domínio 1D com Informação a Priori . . . . .	20
3.5	Reconstrução de imagens em <i>Compressive Sensing</i> com Informação a Priori e Pré-filtragem . . . . .	20
3.6	Escolha de filtros a partir da reconstrução de imagem de ressonância magnética de cabeça em <i>Compressive Sensing</i> com Pré-filtragem . . . . .	21
3.7	Reconstrução de múltiplas imagens de ressonância magnética em <i>Compressive Sensing</i> com informação a priori utilizando diferentes filtros para a pré-filtragem . . . . .	22
3.7.1	Experimento com quatro imagens . . . . .	22
3.7.2	Experimento com quarenta imagens . . . . .	22
3.8	Reconstrução de múltiplos <i>frames</i> de ressonância magnética funcional em <i>Compressive Sensing</i> com informação a priori utilizando diferentes filtros para a pré-filtragem . . . . .	23
3.9	Teste estatístico . . . . .	23
4	Resultados e Discussão . . . . .	25
4.1	Escolha de filtros a partir da reconstrução de imagem de ressonância magnética de cabeça em <i>Compressive Sensing</i> com Pré-filtragem . . . . .	25
4.2	Reconstrução de múltiplas imagens de ressonância magnética em <i>Compressive Sensing</i> com informação a priori utilizando diferentes filtros para a pré-filtragem . . . . .	26
4.2.1	Experimento com quatro imagens . . . . .	26

4.2.2	Experimento com quarenta imagens . . . . .	27
4.3	Reconstrução de múltiplos <i>frames</i> de ressonância magnética funcional em <i>Compressive Sensing</i> com informação a priori utilizando diferentes filtros para a pré-filtragem . . . . .	32
5	Conclusão	36
6	Apêndice	41
6.1	Reconstrução por <i>Compressive Sensing</i> de imagens artificiais já esparsas no domínio de pixels . . . . .	41
6.2	<i>Compressive Sensing</i> com Pré-filtragem de imagens de ressonância magnética . . . . .	42
6.3	Reconstrução por <i>Compressive Sensing</i> de sinais aleatórios no domínio 1D com Informação a Priori . . . . .	44
6.4	Reconstrução de imagens em <i>Compressive Sensing</i> com Informação a Priori e Pré-filtragem . . . . .	46
6.4.1	Fantoma de Shepp-Logan . . . . .	46
6.4.2	Imagem de ressonância magnética . . . . .	47

## LISTA DE TABELAS

4.1	Resultado dos melhores filtros nos 55 testes. . . . .	25
4.2	Relação entre os filtros selecionados e $SNR(dB)$ da reconstrução sem e com informação a priori, das imagens de ressonância magnética de 3.1. . . . .	26
4.3	$SNR(dB)$ da reconstrução sem e com informação a priori com pré-filtragem dos filtros <i>Haare Fejér-Korovkin</i> . . . . .	29
4.4	Médias com os resultados apresentados em 4.3, em $dB$ . . . . .	30
4.5	Resultado do teste estatístico para o primeiro caso: <i>Haar</i> e <i>Fejér-Korovkin</i> sem informação a priori. . . . .	31
4.6	Resultado do teste estatístico para o segundo caso: <i>Haar</i> e <i>Fejér-Korovkin</i> com informação a priori. . . . .	31
4.7	Resultado do teste estatístico para o terceiro caso: ganho utilizando informação a priori para <i>Haar</i> e <i>Fejér-Korovkin</i> . . . . .	31
4.8	$SNR(db)$ utilizando informação a priori para reconstrução de <i>frames</i> de ressonância magnética funcional. . . . .	34
4.9	Médias com os resultados apresentados em 4.3, em $dB$ . . . . .	34
4.10	Resultado do teste estatístico para o primeiro caso: <i>Haar</i> e <i>Fejér-Korovkin</i> sem informação a priori. . . . .	34
4.11	Resultado do teste estatístico para o primeiro caso: <i>Haar</i> e <i>Fejér-Korovkin</i> com informação a priori. . . . .	35
4.12	Resultado do teste estatístico para o terceiro caso: ganho utilizando informação a priori para <i>Haar</i> e <i>Fejér-Korovkin</i> . . . . .	35
6.1	$SNR(dB)$ dos sinais reconstruídos sem e com informação a priori. Os parâmetros definidos em 3.4 foram mantidos. . . . .	46

6.2	$SNR(dB)$ do fantoma reconstruído sem e com informação a priori. . . . .	47
6.3	$SNR(dB)$ da imagem 3.5 reconstruída sem e com informação a priori. . .	47

## LISTA DE FIGURAS

2.1	Representação da orientação dos cortes. Imagem adaptada de [1]. O corte transversal é perpendicular ao eixo Z, sagital perpendicular ao eixo X e coronal ao eixo Y. Por convenção, o eixo Z é apontado para a “entrada” da máquina. . . . .	8
2.2	Imagens de ressonância magnética de corte coronal de uma pélvis humana. Com os diferentes contrastes a imagem total modifica e assim é possível visualizar outros aspectos desejados. Fonte: [2]. . . . .	8
2.3	Exemplificação de gradientes. Figura modificada de [1]. No processo de seleção de fatia, o pulso RF e o gradiente $G_{ss}$ são restritos ao plano bidimensional. A codificação de fase é efetuada pelo gradiente $G_{PE}$ e a codificação de frequência por $G_{FE}$ . A amplitude é representada verticalmente e o tempo de aquisição horizontalmente. . . . .	9
2.4	Imagem dos métodos não cartesianos para adquirir um número suficiente de amostras para o $k$ -space. De acordo com o teorema de Nyquist-Shannon, o número de amostras é determinada pelo <i>Field of View</i> ( $FOV$ ) e a largura de banda da frequência espacial. O $FOV$ é determinado pela taxa de amostragem $\Delta k = 1/FOV$ . Fonte: [1]. . . . .	10
2.5	Ilustração da precessão do próton que está oposta a $B_0$ , ao interagir com o próprio $B_0$ . Como a magnitude do componente de <i>spin</i> no eixo z não muda durante a revolução, ele é o elemento de interesse para a ressonância magnética. Fonte: [3]. . . . .	11
2.6	Diagrama que esquematiza o processo de pré-filtragem utilizando $n$ filtros. Esquemático modificado de [4]. . . . .	13
3.1	Imagens de ressonância magnética de contraste $T_1$ de <i>The Visible Human Male</i> . . . . .	16

3.2	Exemplo de <i>frame</i> formado por várias imagens de ressonância magnética funcional disponível em FBIRN. . . . .	17
3.3	Fantoma de Shepp-Logan. . . . .	18
3.4	Fantoma esparsificado. . . . .	18
3.5	Ressonância magnética de cabeça de corte sagital, tamanho 1024x1024. As medidas da imagem foram usadas para a reconstrução. . . . .	19
3.6	Imagens de ressonância magnética utilizadas para: <b>(a)</b> teste número 1 e <b>(b)</b> teste número 40. As 40 imagens são de contraste $T_1$ e são do projeto <i>The Visible Human Male</i> , de [2]. . . . .	23
4.1	Reconstrução da imagem 36 em <i>Compressive Sensing</i> com informação a priori e pré-filtragem de <i>Haar</i> . . . . .	27
4.2	Reconstrução da imagem 36 em <i>Compressive Sensing</i> com informação a priori e pré-filtragem de <i>Fejér-Korovkin</i> . . . . .	28
4.3	Gráfico representando a <i>SNR</i> máxima obtida em cada reconstrução de imagem sem e com informação a priori, com os filtros de <i>Haar</i> e <i>Fejér-Korovkin</i> . FK4 é uma sigla para o filtro <i>Fejér-Korovkin</i> de ordem 4. . . .	29
4.4	Reconstrução da imagem 36 em <i>Compressive Sensing</i> com informação a priori e pré-filtragem de <i>Haar</i> . . . . .	32
4.5	Reconstrução da imagem 36 em <i>Compressive Sensing</i> com informação a priori e pré-filtragem de <i>Fejér-Korovkin</i> . . . . .	32
4.6	Gráfico representando a <i>SNR</i> máxima obtida em cada reconstrução de <i>frame</i> sem e com informação a priori, com os filtros de <i>Haar</i> e <i>Fejér-Korovkin</i> . FK4 é uma sigla para o filtro <i>Fejér-Korovkin</i> de ordem 4. . . .	33
6.1	Resultado após a aplicação da diferença finita no fantoma de Shepp-Logan. . . . .	41
6.2	Comparação entre a imagem original e reconstruída. . . . .	42
6.3	Resultados da pré-filtragem da imagem 3.5. . . . .	43
6.4	Comparação entre a imagem original e reconstruída. . . . .	44

6.5	Gráfico da representação do sinal original (vermelho) e sinal reconstruído (azul), sem informação a priori. . . . .	45
6.6	O processo de reconstrução foi repetido para o mesmo sinal, com adição de informação a priori para minimização de $l_p$ . . . . .	45



## LISTA DE SÍMBOLOS, NOMENCLATURAS E ABREVIACÕES

TC	–	Tomografia Computadorizada
RM	–	Ressonância Magnética
<i>CS</i>	–	<i>Compressive Sensing</i>
<i>PPA</i>	–	<i>Partially Parallel Acquisitions</i>
<i>SNR</i>	–	<i>Signal-to-Noise Ratio</i>
<i>SER</i>	–	<i>Signal-to-Error Ratio</i>
<i>PD</i>	–	<i>Proton Density</i>
RF	–	Rádio Frequência
<i>TR</i>	–	<i>Repetition Time</i>
<i>TE</i>	–	<i>Echo Time</i>
<i>FFT</i>	–	<i>Fast Fourier Transform</i>
<i>FOV</i>	–	<i>Field of View</i>

# 1 INTRODUÇÃO

Este trabalho aborda técnicas avançadas de Imageamento por Ressonância Magnética com o objetivo de avaliar técnicas voltadas à redução do número de medidas exigidas para uma dada qualidade de imagem. Para tanto, é proposto a investigação do uso de *Compressive Sensing* com pré-filtragem usando diferentes filtros em combinação com informação a priori, já que durante a pesquisa bibliográfica realizada, não foi encontrada uma quantidade expressiva de estudos acerca da relação entre esses dois recursos que, isoladamente, têm permitido a melhora da qualidade de imagem em ressonância a partir de um mesmo número de medidas no  $k$ -space. Assim, essa relação é o principal objeto de investigação deste trabalho, por meio da construção de experimentos numéricos.

Dessa forma, este capítulo apresenta um panorama geral sobre metodologias de imageamento, principalmente os obstáculos da ressonância magnética. Posteriormente, é apresentada a proposta diante dessas dificuldade e os objetivos a serem cumpridos, no propósito de averiguar os efeitos do uso combinado de informação a priori e dos diferentes filtros utilizados para a pré-filtragem.

## 1.1 O Contexto do Imageamento Médico: Vantagens e Desafios da Ressonância Magnética

As técnicas de imageamento médico proporcionaram evolução na biologia e medicina por viabilizarem a análise de estruturas anatômicas e o estudo do corpo e comportamento humanos de forma não invasiva. O princípio do imageamento é a interação de diferentes processos físicos correspondentes a diferentes formas de energia e os tecidos vivos que compõem os organismos. Os resultados dessa interação são medidos por um equipamento, geralmente um escâner de imageamento, em que também é utilizada alguma técnica de imageamento para reconstruir as imagens a partir daquelas medidas, que refletem uma ou mais propriedades dos tecidos analisados [5]. Os métodos mais comuns de imageamento médico são raio-X, Tomografia Computadorizada (TC) e Ressonância Magnética (RM).

O raio-X foi a primeira tecnologia utilizada para imageamento médico após o uso de fotografia comum para registros médicos, sendo que o seu emissor de energia é eletromagnético. Devido ao seu comprimento de onda da ordem de 0,01 a 10 nanômetros [5], penetra em objetos que absorvem luz, e praticamente não sofre difração neste processo e assim consegue iluminá-los [6]. Contudo, a imagem de raio-X apresenta superposição de estruturas internas e baixo contraste de imagem [3].

Neste sentido, em 1970, foi criada a TC com o intuito de contornar as limitações do raio-X. Assim, combina o princípio do raio-X com outros equipamentos: computador e tubo de cátodos. A base do exame é a possibilidade de criar uma imagem por meio de várias projeções de feixes de raio x que atravessam um organismo. A partir da intensidade dos raios que atingem o objeto, técnicas matemáticas são usadas para deduzir as densidades internas, já que quanto maior a densidade, maior a radiação absorvida. Portanto, é possível obter informações de várias direções e fabricar uma imagem que reflete a densidade, ou seja, construir um imagem de densidade de massa [3]. A imagem é resultado desta atenuação e da secção analisada, sendo esta bidimensional ou tridimensional [5].

Embora o raio-X e a TC sejam técnicas conhecidas e efetivas, o maior ponto negativo é o uso de radiação ionizante, que a longo prazo aumenta a chance de desenvolvimento de câncer e outras complicações de saúde. Além disso, a TC apresenta normalmente menor contraste de imagem comparado à RM, contraste esse relacionado à densidade dos tecidos (tecidos moles possuem densidade baixa e tecidos duros densidade alta) [5]. Assim, a RM torna-se uma alternativa atrativa para a visualização de tecidos por meio de campos magnéticos.

A descoberta de imageamento por gradientes magnéticos foi feita por Paul Lauterbur e Peter Mansfield, ganhadores do Prêmio Nobel de Medicina em 2003, sendo que a máquina de ressonância magnética começou a ser utilizada em 1980 [7]. Apesar de apresentar restrição para pacientes que utilizam marca-passo ou próteses metálicas, é benéfica por não utilizar radiação ionizante, uma vez que o seu princípio é “a interação entre um campo magnético aplicado e um núcleo que possui rotação (*spin*)” [3].

Uma máquina de RM é composta por ímã, sistema de gradiente e sistema de rádio frequência [8]. O princípio do exame é a resposta dos tecidos aos campos magnéticos dinâmicos e estáticos. Esta reação é a soma dos momentos magnéticos dos prótons, que podem ser medidos por meio da bobina de recebimento [1]. Devido a variada quantidade de frequências que muitas vezes se sobrepõem, a análise dos sinais no domínio do tempo torna-se difícil, então é mais adequada uma análise no domínio da frequência e para tanto, utiliza-se a transformada de Fourier. Portanto, a resposta depende dos tipos de tecidos presentes e suas distâncias, mas fazendo o gradiente espacial de campo, é possível alterar

esses pesos e conseguir diferentes somas ponderadas, que correspondem à imagem a ser reconstruída no domínio de Fourier [3].

Após a excitação dos prótons, a energia é liberada por meio da relaxação dos tecidos, que é fundamental para o contraste da imagem, sendo eles  $T_1$  (relaxação longitudinal) e  $T_2$  (relaxação transversal). O nível de contraste está ligado ao tempo de repetição  $T_R$  entre dois pulsos de excitação consecutivos e as propriedades do próprio tecido [3].

Ainda que a RM seja uma das técnicas mais seguras e eficazes atualmente [9], o tempo e a necessidade do paciente estar imóvel durante todo o processo são quase impossíveis, principalmente bebês e crianças, que geralmente precisam de anestesia geral [10]. Além disso, episódios de ansiedade e claustrofobia são comuns [11], o que aumenta a duração do exame e o desconforto do paciente, e por vezes é preciso de sedação [12]. Neste contexto, há pesquisas e estudos desde o final de 1970 para acelerar a aquisição de medidas [9] e, dessa forma, seria possível ultrapassar estas adversidades.

## 1.2 Definição do Problema Científico e Proposta de Pesquisa

Neste sentido, a redução de medidas é promissora por também reduzir o tempo de exame, que geralmente dura várias dezenas de minutos ou até horas e por esse motivo, torna alguns exames praticamente inviáveis. Assim, diminuir o tempo não seria benéfico apenas para o conforto do paciente, mas também tornaria mais acessível financeiramente o exame, uma vez que diminuiria os custos envolvidos: máquina, médicos, enfermeiros, técnicos e outros [12].

Atualmente, existem várias técnicas e estudos para aperfeiçoarem o *MRI* [13, 14, 15, 16, 17, 18, 19, 20, 21], principalmente abordando a redução do tempo de exame, contudo, não é do escopo deste trabalho abordar todas detalhadamente. Dessa forma, será discutido brevemente sobre aquisição paralela parcial (*Partially Parallel Acquisitions-PPA*) e *Compressive Sensing (CS)*, que são metodologias mais conhecidas e já utilizadas comercialmente.

O *CS* é uma metodologia que o princípio já é trabalhado e abordado há mais de 100 anos, mas não com a teoria e nomenclatura atual [22]. Para exemplificação, o *CS* é uma teoria de amostragem de sinais esparsos para um certo domínio [23]. A sua importância não se aplica somente à engenharia, mas também à física e à matemática, pois “sistemas, códigos e dados de dimensões superiores” [24] são cada vez mais comuns. A *PPA* é pautada na utilização de bobinas para adquirir informações espaciais que seriam obtidas por meio de gradientes, diminuindo assim o tempo de aquisição [16], já que

menos medidas são necessárias para a reconstrução da imagem devido à esparsidade (característica de ter em um domínio conhecido mais elementos nulos do que não-nulos) do  $k$ -space (representação no domínio da frequência da imagem da ressonância). Mesmo já sendo utilizada clinicamente, o maior impedimento é a necessidade de conhecimento exato da sensibilidade das bobinas, já que na prática é associada com o ruído [16]. Dessa forma, o seu uso está limitado a imagens com alto *Signal-to-Noise Ratio* (*SNR*), como imagens volumétricas [19]. Neste sentido, não é incomum a combinação entre *PPA* ou outras técnicas de aquisição paralela com *CS* [17, 25, 26, 27], sendo que o *CS* já demonstrou ser efetivo para diminuir o tempo de aquisição de medidas na RM [9, 17, 28].

Uma vez que a base do *CS* é a esparsidade e incoerência de amostragem [29], outros métodos também são utilizados em conjunto para melhorar essas características, como a pré-filtragem [29, 30]. Neste sentido, a implementação de filtros mostrou resultados melhores do que somente a utilização de uma transformada esparsificadora [4], sendo que os filtros são aplicados nas medidas fornecidas pela máquina e posteriormente utilizadas para a reconstrução da imagem por meio do *CS*. Além disso, é possível utilizar a informação a priori para agilizar a reconstrução da imagem, já que muitas vezes a informação de um *frame* para outro muda pouco.

Neste sentido, já há trabalhos na literatura que utilizam a pré-filtragem com filtros específicos e que mostram a melhora efetiva da imagem final, como observado em [30] e [4]. Em [30], os autores utilizaram três diferentes filtros *Haar* para a pré-filtragem e usaram a relação *SNR* como métrica de avaliação da imagem, sendo que ocorreu acréscimo de em média  $5,8dB$  nas imagens utilizadas. Paralelo a isto, usar informação a priori também aprimora as imagens [31], em que o autor obteve para a abordagem estocástica um valor médio de *Signal-to-Error Ratio* (*SER*) de  $21dB$ , inclusive em casos críticos que outras técnicas falharam. Contudo, o que não foi encontrado foi uma investigação sobre o resultado da combinação de pré-filtragem e informação a priori e por conta disso, não há base na literatura sobre a clareza destas duas técnicas juntas, o que ocasiona a seguinte questão: de quanto seria o ganho, em termos de métricas de qualidades objetivas de imagem, se as duas técnicas fossem utilizadas em conjunto? Dessa forma, a proposta do trabalho é responder a esta pergunta, bem como implementar numericamente a pré-filtragem de diferentes conjuntos de filtros e a reconstrução de imagens de RM com base em *CS* usando informação a priori.

## 1.3 Objetivos

### 1.3.1 Objetivo Geral

O trabalho propõe implementar métodos de imageamento por ressonância magnética que utilizam em conjunto pré-filtragem e informação a priori de cortes anteriores, com o intuito de medir o impacto do uso combinado destas técnicas e avaliar como cada uma influencia na outra, como por exemplo se existe alguma família de filtro que contribua para resultados melhores com a informação a priori ou se o ganho final medido por *SNR* é igual a soma da contribuição de ambos os métodos. Além disso, o critério usado para selecionar os filtros é o quão esparsa tornam as medidas, que substituirão a transformada esparsificante. Inicialmente, será feito uma comparação sistemática de um conjunto de filtros e nessa comparação, será testado um conjunto com e sem uso de informação a priori.

### 1.3.2 Objetivos Específicos

Com o objetivo de ter esta informação acerca do uso conjugado de pré filtragem e informação a priori e entender o impacto de uma com a outra, os seguintes objetivos são definidos:

- Implementação de algoritmo de pré-filtragem para diferentes conjuntos de filtros;
- Desenhar experimentos em que são usados algoritmos para comparar os resultados de pré-filtragem com informação a priori para diferentes famílias de filtros. O mesmo deve ser feito sem informação a priori;
- Escolher os filtros a partir dos melhores resultados esparsificantes;
- Comparar os resultados com e sem informação a priori a partir da métrica *SNR*.

## 1.4 Estrutura da Dissertação

Os aspectos gerais sobre a ressonância magnética, tempo de relaxação do tecido e a sua importância para o o exame são abordadas no capítulo 2. Além disso, também é exposta a metodologia de aquisição das medidas por meio de pulsos de radio frequência e gradientes de campos magnéticos, bem como a utilidade da equação de Larmor para o processo. Também é citado as formas de preenchimento do *k-space* ressaltando os

desafios da utilização da trajetória cartesiana e não cartesianas e as características físicas que proporcionam a viabilidade do exame, como a rotação dos prótons presentes nos tecidos e a equação de Bloch. Por fim, uma breve teoria sobre *Compressive Sensing* é apresentada e posteriormente a combinação com pré-filtragem e informação a priori.

A implementação dos conceitos citados anteriormente está no capítulo 3, ou seja, algoritmos de *Compressive Sensing* com pré-filtragem e informação a priori. Inicialmente, são feitas reconstruções por *CS* de uma imagem artificial e posteriormente extrapoladas para imagens reais com utilização de pré-filtragem, sendo três filtros de *Haar*. Com base nos testes iniciais, a proposta do trabalho é apresentada: reconstruir imagens a partir de várias famílias de filtros com e sem informação a priori, sendo este processo dividido em pré-filtragem, informação a priori, composição espectral da imagem e reconstrução.

No capítulo 4 são mostradas as imagens das reconstruções assim como a relação *SNR* de cada uma. A partir dos resultados, os objetivos são identificar quais filtros tornam as medidas mais esparsa e se a combinação com informação a priori diminui ou aumenta a *SNR* da imagem e se sim, quais filtros combinados com informação a priori são mais eficazes.

## 2 FUNDAMENTAÇÃO TEÓRICA E ESTADO DA ARTE

### 2.1 Princípios da Ressonância Magnética


A base da ressonância magnética pode ser definida como troca de energia e a utilização de gradientes de campos magnéticos, que permite a identificação de mudanças sutis nos tecidos, uma vez que o método é pautado na sensibilidade e propriedades da água, que constitui em média 70-90% dos tecidos [1]. Apesar disso, a máquina de RM contempla conceitos físicos e matemáticos complexos, que serão abordados de forma geral.

À princípio, é importante definir o que a máquina de ressonância pode identificar e como. Primeiramente, é possível dividir os tecidos em três categorias [1]:


- Fluidos: líquido cefalorraquidiano, líquido sinovial, edema
- Tecidos à base de água: músculo, cérebro, cartilagem, rins
- Tecido à base de gordura: gordura, medula óssea

Esta separação é importante pois cada tecido possui uma propriedade de relaxamento  $T_1$  e  $T_2$ , sendo que  $T_1$  é mais longa e ambas estão relacionadas às propriedades biológicas do tecido. Isto influencia diretamente nas descrições de contraste das imagens,  $T_1$ -weighted images ( $T_1w$ ) e  $T_2$ -weighted images ( $T_2w$ ).  $T_1w$  é um contraste que favorece o relaxamento  $T_1$  e são mais rápidos de obter, enquanto  $T_2w$  favorece  $T_2$  e é mais sensível aos fluídos, o que por exemplo seria benéfico para a identificação precoce de uma anomalia [1]. Há também o contraste de densidade de próton, *proton density (PD)*, que é o sinal máximo do tecido e obtido minimizando  $T_1$  e  $T_2$  [32].





**Figura 2.1.** Representação da orientação dos cortes. Imagem adaptada de [1]. O corte transversal é perpendicular ao eixo Z, sagital perpendicular ao eixo X e coronal ao eixo Y. Por convenção, o eixo Z é apontado para a “entrada” da máquina.



(a) Imagem  $T_1$

(b) Imagem  $T_2$

(c) Imagem PD


**Figura 2.2.** Imagens de ressonância magnética de corte coronal de uma pélvis humana. Com os diferentes contrastes a imagem total modifica e assim é possível visualizar outros aspectos desejados. Fonte: [2].

A aquisição de medidas é realizada por meio da aplicação de uma série de pulsos de rádio frequência (RF) e gradientes de campos magnéticos, descritos em conjunto por um pulso de frequência [8]. O tempo de repetição entre um pulso de frequência e o próximo é chamado de TR, *repetition time*, e o tempo entre um pulso e o eco de resposta do objeto é TE, *echo time*. Durante o exame, o corpo do indivíduo responde ao campo magnético da máquina com um campo magnético da ordem de microtesla. Para medir este campo, é preciso deslocá-lo do eixo z de origem a partir de um pulso RF na frequência de Larmor, dada por,

$$f_0 = \gamma \cdot B_0, \quad (2.1)$$

sendo  $B_0$  o campo magnético da máquina e  $\gamma$  a razão giromagnética, sendo que o sinal medido é proporcional às contribuições presente nos eixos  $xy$ ,  $M_{xy}$ , e o sinal máximo obtido quando  $M$  vira  $90^\circ$ , *spin echo*. O *spin echo* é formado quando há excitação do pulso RF inicial,  $90^\circ$ , e depois com um pulso de  $180^\circ$ , isso porque as partes que têm maior atraso de fase passam a ter maior avanço de fase [8, 1].

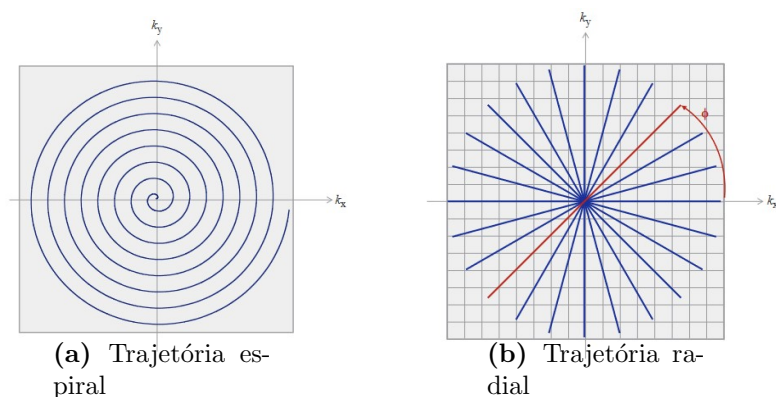
Dessa forma, para obter-se uma imagem, são necessários pulsos RF em conjunto com um gradiente  $G_{ss}$  (*slice selective gradient*), que estimula os prótons apenas da parte selecionada e gera o eco. O que possibilita a formação de imagens de vários cortes é a mudança de posição do gradiente,  $G_x, G_y, G_z$ . Paralelo a isso, é aplicado a codificação de fase, *phase encoding*, que armazena a resposta no codificador de fase, *phase encoder*, e da mesma forma é feito para a frequência, com o codificador de frequência, *frequency encoding*, que ao fim são adquiridas as medidas. Este processo é repetido até que todo o  $k$ -space esteja completo [1]. O  $k$ -space pode ser compreendido como um *array* de números da frequência espacial dos sinais, que a partir da transformada inversa de Fourier 2D, pode ser produzida uma imagem [33].



**Figura 2.3.** Exemplificação de gradientes. Figura modificada de [1]. No processo de seleção de fatia, o pulso RF e o gradiente  $G_{ss}$  são restritos ao plano bidimensional. A codificação de fase é efetuada pelo gradiente  $G_{pe}$  e a codificação de frequência por  $G_{fe}$ . A amplitude é representada verticalmente e o tempo de aquisição horizontalmente.

Um dos métodos comuns de se preencher o  $k$ -space é pela trajetória cartesiana, sendo obtida uma linha de cada vez, posicionando os pontos coletados no plano cartesiano. Apesar de entregar uma trajetória completa e direcionada, sendo possível aplicar diretamente a *Fast Fourier Transform (FFT)* para a reconstrução da imagem, é um processo demorado e que depende de um cenário ideal, como a imobilização completa do paci-

ente [8]. Assim, há também outros métodos de trajetória mais eficazes, como espiral e radial, que são trajetórias não uniformes e não são diretamente posicionadas no plano cartesiano, o que reduz o tempo de aquisição. A trajetória espiral é capaz de cobrir boa parte do  $k$ -space com cada excitação RF [1], sendo promissora para obtenção de imagens em tempo real e em movimentação, como o coração [32]. Enquanto isso, a trajetória radial é obtida por meio de ângulos diferentes  $\phi$  para contemplar todo o objeto e por não ser uniforme, é preciso uma interpolação das trajetórias com o plano cartesiano para aplicar a  $FFT$ , sendo este um dos maiores problemas para os métodos não cartesianos, uma vez que a interpolação e o modelo de codificação de Fourier tornam os resultados menos precisos [8]. Além disso, uma amostragem errada do  $k$ -space e movimentação do paciente podem gerar *artefatos* na imagem, que são distorções e “sombras”. Em relação ao  $k$ -space, os motivos dos artefatos podem ser: amostragem inadequada em uma direção, troca abrupta de amostragem em altas frequências e sinal espúrio em pontos isolados de tempo durante a aquisição [34].




**Figura 2.4.** Imagem dos métodos não cartesianos para adquirir um número suficiente de amostras para o  $k$ -space. De acordo com o teorema de Nyquist-Shannon, o número de amostras é determinada pelo *Field of View (FOV)* e a largura de banda da frequência espacial. O *FOV* é determinado pela taxa de amostragem  $\Delta k = 1/FOV$ . Fonte: [1].

### 2.1.1 A física da Ressonância Magnética

A possibilidade de imageamento é pautada na utilização de gradientes de campos magnéticos, devido a rotação (*spin*) do núcleo. Para um elemento ser utilizado na RM, precisa possuir um número atômico ímpar para interagir com um campo magnético. Assim, o elemento mais utilizado é o hidrogênio por apresentar a maior resposta aos campos e ser encontrado em abundância em tecidos, já que são constituídos principalmente de água e gordura.

Devido ao movimento dos elétrons, o núcleo do átomo cria um campo magnético,

sendo paralelo ao eixo de rotação, e cada próton tem um vetor de *spin* de magnitude igual e suas direções são diversas e aleatórias. Quando o tecido tem contato com o campo magnético  $B_0$ , os prótons rotacionam perpendicularmente em torno do campo, pela frequência descrita em (2.1). Assim, os prótons são posicionadas de forma oposta ao eixo do campo, contudo, o eixo de rotação é paralelo a  $B_0$ , o que cria uma “polarização induzida da orientação do *spin*” [3].



**Figura 2.5.** Ilustração da precessão do próton que está oposta a  $B_0$ , ao interagir com o próprio  $B_0$ . Como a magnitude do componente de *spin* no eixo  $z$  não muda durante a revolução, ele é o elemento de interesse para a ressonância magnética. Fonte: [3].

Por sua vez, a polarização induzida cria um momento magnético  $M$ , e assim é aplicada outro campo magnético de RF,  $B_1$ , que é perpendicular a  $B_0$ , fazendo com que  $M$  seja desviado a um plano transversal a  $B_0$ . O vetor do momento magnético pode ser descrito pela equação de Bloch

$$\frac{dM}{dt} = \gamma M \times B - \frac{M_{xy}}{T_2} - \frac{M_z - M_0}{T_1}, \quad (2.2)$$

sendo  $\gamma$  a razão giromagnética,  $B$  o campo magnético efetivo e  $M_0$  a magnetização de equilíbrio. Para  $M$  atingir  $M_0$ , precisa liberar energia para o ambiente, processo também conhecido como relaxação.  $T_1$  e  $T_2$  são as constantes de relaxação, cada uma relacionada às componentes de magnetização de cada eixo: o crescimento de  $M_z$  e o decaimento de  $M_{xy}$ , respectivamente [35].

## 2.2 Compressive Sensing

O *CS* é uma técnica de amostragem de sinais que permite adquirir  $N$  amostras a uma subamostragem de Nyquist, dependendo de duas características do sinal: esparsidade e incoerência na amostragem [29]. Em relação à esparsidade, é considerado um domínio conhecido  $\mathbb{B}$  em que o sinal  $x$  seja representado de forma mais esparsa, em que exista poucos elementos não nulos, tal que  $N < p$ , em que  $p$  é a amostra total do sinal [24]. Assim, considerando  $\hat{x}$  o domínio esparsa e  $T$  a matriz de transformada, a representação de  $x$  esparsa é:

$$\hat{x} = Tx. \quad (2.3)$$

Além disso,  $x$  pode ser reconstruído por  $l < N$  medidas lineares, utilizando um vetor  $b$  de dimensão  $l$ , sendo que  $l$  representa o número de medidas adquiridas em um domínio não esparsa e depende de quantos valores não nulos há em  $\hat{x}$ .

$$b = Mx. \quad (2.4)$$

Dessa forma, o objetivo é encontrar um  $\hat{x}$  mais esparsa possível, com transformada inversa  $T^{-1}$  e que  $0 < p \leq 1$ . Assim, a reconstrução pode ser feita resolvendo o seguinte problema de otimização [30]

$$\operatorname{argmin} \|\hat{x}\|_p^p \quad \text{s.a.} \quad A\hat{x} = b, \quad (2.5)$$

sendo  $A = MT^{-1}$ .

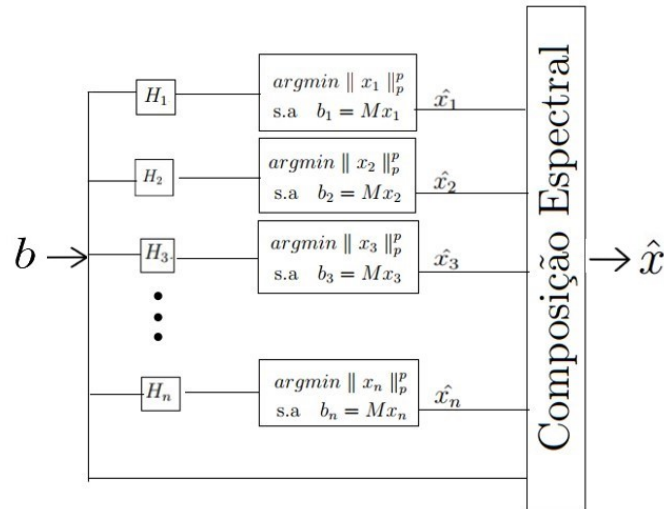
### 2.2.1 Compressive Sensing e Pré-Filtragem

Uma vez que qualidade da reconstrução por *CS* é a esparsidade das amostras [1], alguns estudos propõem a utilização da pré-filtragem ao invés de uma transformada esparsificadora, uma vez que apresentam resultados promissores [30, 4]. Considere o filtro bidimensional  $h$ , também nomeado de *kernel* e  $H$  a transformada de Fourier desse filtro com o mesmo valor de pixels da imagem a ser reconstruída. Além disso, considere que  $H_{k\mathcal{T}}$  representa os valores empilhados de  $H$  pertencentes a uma trajetória  $\mathcal{T}$  do *k-space* e  $b$  representa o vetor de medidas da imagem no *k-space*, a sua versão filtrada corresponderia a

$$b_f = H_{kCT} \circ b. \quad (2.6)$$

Assim, são feitas várias filtragens das medidas antes da reconstrução da imagem, e essas versões filtradas serão “somadas” por um processo chamado de composição espectral. Em [30], os filtros utilizados realçam partes específicas e a na ressonância magnética, a maior parte da informação está em baixa frequência, então não é possível fazer uma divisão direta de imagem pré-filtrada e filtro para se obter a transformada de Fourier da versão não filtrada da imagem. Assim, como em algumas regiões da  $H$  é próximo de zero, é preciso avaliar o maior ganho entre os filtros utilizados pixel a pixel, contudo, se naquela posição a medida original foi amostrada, ela tem preferência, pois as medidas filtradas são usadas para completar espaços faltantes. Após a composição espectral, é obtido como resultado uma imagem não filtrada  $\hat{x}$ .

Assim, os filtros escolhidos são aqueles que tornam a imagem mais esparsa no domínio do pixel e que se complementem, pois é importante abranger todo o espectro de banda para perder menos informação possível.



**Figura 2.6.** Diagrama que esquematiza o processo de pré-filtragem utilizando  $n$  filtros. Esquemático modificado de [4].

## 2.2.2 Compressive Sensing e Informação a Priori

Como citado anteriormente, um dos aspectos fundamentais para garantir uma reconstrução satisfatória com  $CS$  é a esparsidade das informações. Assim, novas técnicas são estudadas para garantir tal propriedade, sendo uma delas a utilização de informação a

priori [36, 37, 38, 39, 31]. A informação a priori é a aplicação da informação esparsa de  $\hat{x}$  com o objetivo de diminuir o número de medidas lineares  $l$  para a reconstrução [37, 31], ou seja, se temos um sinal similar ao que deve ser reconstruído, é possível utilizar este sinal anterior para reduzir a quantidade de informação a ser obtida para um sinal futuro [39]. No contexto da RM, constitui em utilizar os cortes anteriores, uma vez que normalmente a frequência de uma região não muda instantaneamente.

A proposta presente em [37] é um algoritmo para redução de  $p$  em (2.5), em que é obtido o melhor resultado de minimização  $l_p$  de  $\hat{x}$ . Para tanto, os autores consideraram como suporte de  $\Phi$  os pontos não nulos  $\hat{x}_k$  nas posições  $\{1, 2, \dots, N\}$

$$\hat{x}_k \neq 0 \quad \forall \quad k \in \Phi. \quad (2.7)$$

Este método altera o problema de minimização de (2.5), tal forma que

$$\min_{\hat{x}} \sum_{\substack{k=1 \\ k \notin \Phi}}^N |\hat{x}_k|, \quad s.a \quad A\hat{x} = b, \quad (2.8)$$

e assim, a informação a priori é utilizada durante a reconstrução com  $CS$  como parte da solução de minimização para  $l_p$  com a utilização do suporte  $\Phi$ , que corresponde a posição dos elementos não-nulos.

## 3 MATERIAIS E MÉTODOS

Esse capítulo apresenta a aplicação dos conceitos abordados a partir de 2.2. Primeiramente, é demonstrado em 3.1 os bancos de imagens que foram retiradas as imagens de ressonância magnética utilizadas para os testes. Os capítulos 3.2 a 3.5 são estudos das técnicas que foram utilizadas para atingir os objetivos da pesquisa e mantidos para melhor compreensão da evolução do trabalho. Em 3.2, é exposto um caso simplificado de reconstrução por *CS* do fantoma de Shepp-Logan, imagem frequentemente utilizada para avaliar a qualidade de algoritmos para reconstrução de imagens. Já em 3.3, o *CS* é extrapolado para imagens reais e com substituição da transformada esparsificadora por filtros de *Haar*, em que o processo de reconstrução também abrange a composição espectral, detalhado em 3.3.1. Em relação à teoria de informação a priori, é aplicada em um caso simples de sinal 1D e posteriormente para imagens, em 6.4.


Após a validação das técnicas, foi possível testar filtros de *Wavelets* em 3.6 e reconstruir variadas imagens com os filtros de melhor resultado em 3.7.1. Posteriormente, foi realizado um experimento mais abrangente com 40 imagens em 3.7.2 e o mesmo foi feito para ressonância magnética funcional 3.8, mas com 10 *frames*. Tanto os resultados das reconstruções anatômica e funcional foram validados pelos testes estatísticos descritos em 3.9.

### 3.1 Banco de Imagens


#### 3.1.1 NLM Visible Human Project

Projeto de domínio público composto por imagens de TC, RM e anatômicas, de um cadáver masculino e feminino. Para cabeça e pescoço o corte é axial e para as outras, longitudinal. Todas as imagens foram tiradas em intervalos de 4mm, de resolução 256x256 e cada pixel formado por 12 bits de tons de cinza. As características do banco de imagens do corpo feminino são iguais, com exceção do intervalo de 0,33m [2].







(a) Abdômen



(b) Pélvis



(c) Pernas



(d) Pés


**Figura 3.1.** Imagens de ressonância magnética de contraste  $T_1$  de *The Visible Human Male*.

### 3.1.2 Functional Imaging BIRN

Conjunto de dados da comunidade virtual *Biomedical Informatics Research Network* (BIRN) formado por ressonâncias magnéticas funcionais cerebral com o objetivo de estudar disfunção dos lobos frontal e temporal na esquizofrenia. É constituído por três fases: Fase 1 é o estudo de 5 indivíduos sem patologia psicológica e saudáveis, submetidos a

exames em 10 *scanners* diferentes de 1,5 a 4 Tesla. Fase 2 consiste em 87 indivíduos diagnosticados com esquizofrenia ou transtorno esquizoafetivo juntamente com 85 sem essas condições mentais. As condições do exame também variaram de 1,5 a 4 Tesla. Por fim, a Fase 3 repete os procedimentos da Fase 2, mas em uma escala maior em vários centros clínicos [40].

As informações disponibilizadas não identificam os pacientes e cada arquivo é formado por vários *frames* daquele instante.



**Figura 3.2.** Exemplo de *frame* formado por várias imagens de ressonância magnética funcional disponível em FBIRN.


### 3.2 Reconstrução por *Compressive Sensing* de imagens artificiais já esparsas no domínio de pixels

Para testar a implementação da reconstrução por *Compressive Sensing* foi utilizado o fantoma de Shepp-Logan que é uma imagem simples comparada a imagens reais de ressonância magnética, já que o objetivo é gerar resultados a partir de casos simples para posteriormente usar imagens reais. A figura 3.3 é a imagem original e não é esparsa, ou seja, há poucos valores nulos ou próximos de zero, então o primeiro passo foi esparsificá-la para uma reconstrução mais direta e sem utilização da transformada esparsificadora.

Para tanto, foi feita uma transformada linear, extraindo as bordas por meio da diferença entre a matriz deslocada e a original, sendo realizada tanto para colunas quanto para linhas, resultado ao final em 3.4. Para reconstrução, como a imagem já é esparsa, ela é igual no domínio original e no domínio da transformada.




**Figura 3.3.** Fantoma de Shepp-Logan.



**Figura 3.4.** Fantoma esparsificado.

### 3.3 *Compressive Sensing* com Pré-filtragem de imagens de ressonância magnética

Para reconstruir uma imagem real por *CS* é utilizado um vetor que representa as posições das medidas obtidas pela máquina que estão no domínio da frequência, representado por  $b$  em (2.4). Dessa forma, precisamos calcular  $x$  por meio de (2.5), o que é feito pelo método indireto pois apesar da esparsidade das amostras, as matrizes para reconstrução não são, o que demanda alto custo de memória. Além disso, as medidas dos casos reais não são esparsas, o que demanda a esparsificação por meio de transformada ou outro método, sendo aqui utilizada a pré-filtragem.



**Figura 3.5.** Ressonância magnética de cabeça de corte sagital, tamanho 1024x1024. As medidas da imagem foram usadas para a reconstrução.

Dessa forma, a transformada esparsificante é substituída pelos seguintes filtros bidimensionais de *Haar*, sendo eles passa-altas horizontal, vertical e diagonal, respectivamente

$$h_1 = \begin{bmatrix} 1 & -1 \\ 1 & -1 \end{bmatrix} \quad h_2 = \begin{bmatrix} 1 & 1 \\ -1 & -1 \end{bmatrix} \quad h_3 = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix}. \quad (3.1)$$

A pré-filtragem acontece pela multiplicação dos filtros com cada medida. Para se obter a representação da imagem final no domínio esparso, a imagem é reconstruída pelo processo de otimização de minimização de  $l_p$  e por fim, passa pela composição espectral, como demonstrado em 2.6.

### 3.3.1 Composição espectral

Esta metodologia é aplicada após a filtragem de várias representações da imagem também reconstruídas,  $\hat{x}_n$ . Para tanto, é necessário calcular a transformada de Fourier de todas as imagens filtradas e também da original e criar uma matriz de zeros do tamanho da imagem original. Essa matriz é preenchida com as medidas originais e os espaços faltantes são completados com as medidas filtradas. O método de avaliação para selecionar o filtro é aquele de maior ganho entre os  $n = 3$  filtros usados em 3.3. Por fim, a medida final  $X_{final}$  naquela posição é representada por [41]

$$X_{final}(position) = \frac{\hat{x}_n(position)}{H_n(position)}, \quad (3.2)$$

em que  $x_n$  é a medida de maior ganho e  $H_n$  o filtro respectivo. Todo este processo é feito do domínio de Fourier e para se obter a imagem de fato, é preciso realizar a transformada inversa de Fourier.

### 3.4 Reconstrução por *Compressive Sensing* de sinais aleatórios no domínio 1D com Informação a Priori

Para compreender a técnica de informação a priori, foi realizado um teste no domínio 1D a partir da construção de sinais aleatórios de  $N = 1024$  medidas com  $\eta = 30$  elementos não-nulos em locais aleatórios, sendo esta a representação esparsa  $\hat{x}$  no domínio da transformada aleatória.

O procedimento de reconstrução foi adaptado de 3.2 para o caso 1D, sendo que para este caso foi possível calcular o problema de otimização pelo método direto. Além disso, a informação a priori é usada ao calcular o menor valor de  $l_p$ , em que  $\Phi$  fornece a posição dos valores não-nulos. Além disso, para a reconstrução não foram usados os 1024 elementos, mas sim  $n = 3 * \eta$ , ou seja, para reconstruir um sinal de 1024 elementos foram usados apenas 90. Ao final, foram gerados gráficos para os cenários de reconstrução sem e com informação a priori.

### 3.5 Reconstrução de imagens em *Compressive Sensing* com Informação a Priori e Pré-filtragem

Estendendo o conceito de informação a priori para o domínio 2d, foram realizados três testes para as imagens 3.3 e 3.5, contabilizando seis resultados ao total. Cada teste é composto pela reconstrução de uma imagem utilizando as técnicas 2.2.1 e 3.3 em conjunto. O objetivo desta etapa é entender como a informação a priori e o suporte  $\Phi$  mencionado em 3.5, aqui chamado de índice de proporção, alteram a *SNR* das imagens. Dessa forma, o índice de proporção é obtido por meio da própria imagem para a reconstrução da mesma. Além disso, foi alterado para cada teste o número de ângulos da trajetória radial para a reconstrução, afim de visualizar se o índice de proporção e número de ângulos são diretamente proporcionais.

Para os testes com o fantoma, foi utilizado um índice de proporção que varia de 0 a

10%, distribuídos em 60 pontos. Essa faixa foi escolhida por ser uma imagem com pouca informação e um valor elevado do índice diminuir a  $SNR$  por fornecer elementos nulos para a reconstrução. O número de ângulos variou a cada etapa: 10, 20 e 30 e os filtros de Haar foram mantidos em todos os processos.

Já para a imagem de ressonância magnética de cabeça o índice de proporção foi de 0 a 50%, também distribuídos em 60 pontos. Esse valor foi mantido pela imagem conter mais pontos não-nulos e demandar mais tempo para reconstrução. Por conta da maior quantidade de informação, foi preciso aumentar a faixa de  $\Phi$  para se obter a  $SNR$  máxima. O número de ângulos foi variado para 40, 60 e 80 também pela complexidade da imagem e os filtros de *Haar* foram preservados.

### 3.6 Escolha de filtros a partir da reconstrução de imagem de ressonância magnética de cabeça em *Compressive Sensing* com Pré-filtragem

Após a validação dos algoritmos em *CS* com pré-filtragem e informação a priori, foi possível realizar o teste para verificar quais filtros fornecem a maior  $SNR$  comparado a  $SNR$  obtida utilizando o filtro de *Haar*.

Esta etapa consiste em fazer a reconstrução da imagem 3.5 a partir do *CS* com pré-filtragem apenas, pois o objetivo é selecionar os melhores filtros de acordo com a  $SNR$  obtida para depois reconstruir a imagem com informação a priori. Diferente dos testes anteriores, o número de ângulos foi fixado em 40, uma vez que o intuito é a análise dos filtros e não como  $\Phi$  altera a reconstrução.

Foram feitos 55 testes, sendo 37 utilizando a função *firwin* disponível na biblioteca *Scipy* no *Python*. Para tanto, foram alterados o tipo de janela, variando entre *Hamming*, *Blackman*, *Hann* e Triangular assim como a ordem do filtro, frequência de corte e tipo de filtro: passa-baixa na horizontal e passa-alta na vertical, passa-alta na horizontal e passa-baixa na vertical e passa-alta na horizontal e passa-alta na vertical .

Contudo, nenhuma dessas combinações resultaram em  $SNR$  superior ao resultado obtido utilizando o filtro de *Haar*. Assim, utilizou-se um arquivo *.mat* contendo alguns filtros de *Wavelet*, como *Daubechies*, *Symlets* e *Fejér-Korovkin*, com ordens distintas. A imagem foi reconstruída 17 vezes com diferentes filtros e ordens, até se obter pelo menos dois filtros com valor próximo ou superior a de *Haar*.

### 3.7 Reconstrução de múltiplas imagens de ressonância magnética em *Compressive Sensing* com informação a priori utilizando diferentes filtros para a pré-filtragem

Afim de verificar se os filtros selecionados a partir dos resultados de 6.4 são efetivos para outras imagens de ressonância, foram utilizadas algumas imagens de 3.1.1 nesta etapa, uma vez que os testes anteriores usaram apenas a imagem 3.5.

Dois procedimentos foram executados: o primeiro utiliza as quatro imagens de 3.1, submetidas a pré-filtragem pelos filtros de *Haar* e *Fejér-Korovkin* de ordem 4. A segunda utiliza os mesmos dois filtros e quarenta imagens de cabeça do mesmo banco de imagem.

#### 3.7.1 Experimento com quatro imagens

Para o início do processo de validação dos filtros selecionados, imagens distintas do corpo humano foram reconstruídas. Foram utilizadas as ressonâncias do abdômen, tórax, coxas e pés, indicadas em 3.1. Todas foram reconstruídas com e sem informação a priori e utilizando três filtros distintos: *Haar*, *Fejér-Korovkin* e *Daubachies*. Aqui, a informação a priori foi obtida da própria imagem, o número de ângulo foi fixado em 40 e índice de proporção 0 a 50%, distribuída por 50 pontos.


Estas imagens foram escolhidas como uma forma de verificar os efeitos da mudança de filtro para ressonâncias de partes diferentes do corpo, mesmo que de forma mais simples e com poucas imagens. Assim, para um experimento mais detalhado e com banco de imagens maior, o algoritmo foi adaptado para reconstruir quarenta imagens de cabeça.

#### 3.7.2 Experimento com quarenta imagens

Foram reconstruídas as imagens 2 a 41 disponíveis em 3.1.1 porque a informação a priori é do corte anterior e não da própria imagem como feito anteriormente. O motivo dessa escolha foi para simular um cenário mais prático, onde se tem apenas informação do corte anterior e as frequências obtidas durante o exame, aqui retiradas das medidas da própria imagem, para reconstruir a imagem desejada.

Além disso, o índice de proporção foi estabelecido de 0 a 40%, distribuído por 50 pontos. O objetivo é medir a *SNR* de reconstrução de cada imagem para avaliar os impactos de utilizar filtros diferente, sendo a *SNR* obtida por *Haar* o padrão de comparação. As-

sim, cada imagem representa uma etapa do experimento, totalizando 40 resultados para *Haar* e 40 para *Fejér-Korovkin*.



**Figura 3.6.** Imagens de ressonância magnética utilizadas para: (a) teste número 1 e (b) teste número 40. As 40 imagens são de contraste  $T_1$  e são do projeto *The Visible Human Male*, de [2].

### 3.8 Reconstrução de múltiplos *frames* de ressonância magnética funcional em *Compressive Sensing* com informação a priori utilizando diferentes filtros para a pré-filtragem

Para estudar a reconstrução de imageamento na ressonância magnética funcional, a mesma metodologia de 3.7.2 foi aplicada. Esse é um experimento reduzido e para tanto, foram selecionados os primeiros 10 arquivos de 3.1.2, composto por vários *frames*. Assim, foi utilizado apenas o décimo terceiro *frame* para se obter as medidas para reconstruir a imagem, e o décimo segundo *frame* para obter-se informação a priori - informação no domínio do tempo.

### 3.9 Teste estatístico

Os resultados adquiridos em 3.7 e 3.8 passaram pelo teste estatístico para compreender a precisão da média amostral da *SNR* nos seguintes casos:

- Pré-filtragem utilizando *Haar* e *Fejér-Korovkin* sem informação a priori;
- Pré-filtragem utilizando *Haar* e *Fejér-Korovkin* com informação a priori;
- Ganho utilizando informação a priori com *Haar* e *Fejér-Korovkin*.



Cada teste é composto por dois vetores, um de *Haar* e outro de *Fejér-Korovkin*, formados pela maior *SNR* de cada um dos quarenta testes. Primeiramente, ambos passaram pelo teste de normalidade de Shapiro-Wilk por conterem quarenta amostras. A hipótese nula, que ambas as amostras advém de distribuição normal, é rejeitada se pelo menos um  $p$  é menor que 5%. Se a normalidade for rejeitada, é utilizada o Teste de Wilcoxon e caso contrário, usa-se o Teste t de Student.

## 4 RESULTADOS E DISCUSSÃO

Aqui são apresentados os resultados das metodologias citadas anteriormente. Os resultados obtidos dos testes de validação para as técnicas estudadas, que contemplam os capítulos de 3.2 a 3.5 foram inseridos no capítulo 6. Assim, os resultados demonstrados são os principais objetos de estudo do trabalho, a começar pelos filtros selecionados em 4.1 e que foram utilizados para a reconstrução de imagens anatômicas em 4.2 e para *frames* em 4.3. Os resultados são apresentados em forma de tabelas e gráficos, junto ao teste estatístico aplicado.

### 4.1 Escolha de filtros a partir da reconstrução de imagem de ressonância magnética de cabeça em *Compressive Sensing* com Pré-filtragem

Para identificar os melhores filtros associados à técnica de pré-filtragem, foram feitos ao total 55 testes com a imagem 3.5, sendo 38 utilizando a função *firwin* e 17 os filtros de *Wavelets*. Nenhum dos filtros criados a partir de *firwin* fornecerem resultados melhores do que *Haar*, utilizado como parâmetro de comparação, então foi utilizado o arquivo contendo os filtros de *Wavelets*. Nesse, apenas dois filtros foram selecionados: *Fejér-Korovkin* de ordem 4, com *SNR* maior que *Haar* e *Daubachies* de ordem 2, com segundo melhor resultado.

**Tabela 4.1.** Resultado dos melhores filtros nos 55 testes.

Filtro utilizado	Correspondente no <i>Matlab</i>	<i>SNR</i> (dB) da reconstrução
Haar	<i>haar</i>	12,8
Fejér-Korovkin (4)	<i>fk4</i>	13,1
Daubechies (2)	<i>db2</i>	11,3

Ordens superiores para os filtros de *Fejér-Korovkin* e *Daubachies* foram testados,

contudo, a  $SNR$  foi menor do que a mostrada em 4.1. Esses filtros foram selecionados a partir da reconstrução da imagem 3.5 apenas, sendo que o ideal seria testar com diferentes imagens, uma vez que partes distintas do corpo podem apresentar mais ruído e artefatos do que outras, afetando a eficácia do filtro utilizado.

Tendo em vista essas múltiplas variáveis: região da ressonância magnética e tipo de contraste, filtro para a pré-filtragem, número de ângulos para a reconstrução e índice de proporção de elementos não-nulos para a informação a priori, os próximos experimentos restringiram-se à mudanças de imagem e filtro. Primeiramente, um teste preliminar utilizando RM de abdômen, pélvis, coxa e pés com os filtros previamente selecionados e posteriormente um mais detalhado com 40 imagens de cabeça, sendo todas as imagens de 3.1.1.

## 4.2 Reconstrução de múltiplas imagens de ressonância magnética em *Compressive Sensing* com informação a priori utilizando diferentes filtros para a pré-filtragem

A partir dos filtros selecionados em 4.1, imagens selecionadas de 3.1.1 foram reconstruídas utilizando os mesmos para a pré-filtragem.

### 4.2.1 Experimento com quatro imagens

Para se ter um panorama geral de como os filtros comportam-se em diferentes RM do corpo humano, as imagens 3.1 foram reconstruídas utilizando informação a priori.

**Tabela 4.2.** Relação entre os filtros selecionados e  $SNR(dB)$  da reconstrução sem e com informação a priori, das imagens de ressonância magnética de 3.1.

Imagem	<i>Haar</i>		<i>Fejér-Korovkin(4)</i>		<i>Daubachies(2)</i>	
	$SNR$ sem informação a priori	$SNR$ com informação a priori	$SNR$ sem informação a prior	$SNR$ com informação a priori	$SNR$ sem informação a priori	$SNR$ com informação a priori
Abdômen	12,0	16,1	12,1	16,2	11,7	15,6
Pélvis	17,4	22,3	17,1	22,5	15,5	21,7
Coxa	17,0	23,0	16,7	22,9	14,3	22,0
Pés	17,0	27,9	16,5	27,6	14,6	27,5

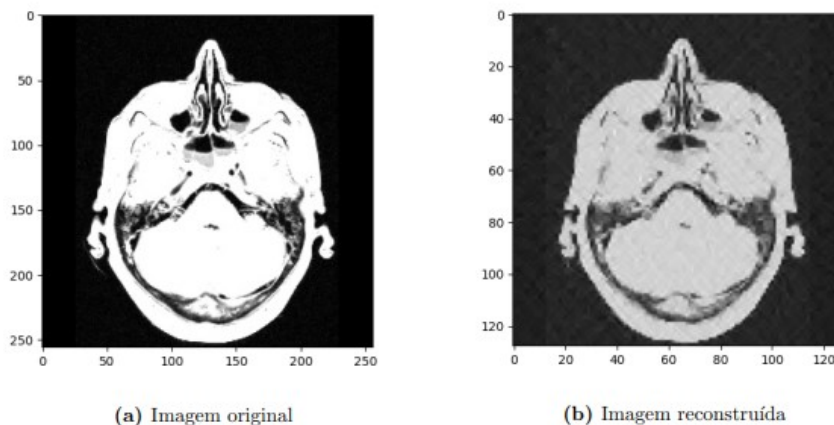
Podemos verificar a partir de 4.2 que os filtros de *Haar* e *Fejér-Korovkin* forneceram

as maiores  $SNR$ . Apenas com as técnicas de *Compressive Sensing* e pré-filtragem, as maiores  $SNR$  são do filtro de Haar, contudo, com adição de informação a priori, o filtro de *Fejér-Korovkin* atingiu maiores resultados para as imagens de abdômen e pélvis. Para a imagem de coxa a diferença foi de apenas  $0,1dB$  e a maior foi a imagem de pés, com  $0,3dB$ .


Em suma, todos apresentaram maiores  $SNR$  com utilização de informação a priori, sendo o ganho ao utilizar a técnica para *Haar*, *Fejér-Korovkin* e *Daubachies*, de  $6,5dB$ ,  $6,7dB$ ,  $7,7dB$ , respectivamente. Mesmo que *Daubachies* tenha o maior ganho médio, ao compararmos com a  $SNR$  dos outros filtros, os resultados são menores. Além disso, por serem imagens distintas, era esperado que os filtros não tivessem o mesmo comportamento para todas as regiões, o que exigira estudos mais detalhados. Contudo, a informação a priori prova-se um incremento para a pré-filtragem.

#### 4.2.2 Experimento com quarenta imagens

Aqui, quarenta imagens foram reconstruídas, a primeira e a última mostradas em 3.6. Diferente dos ensaios precedentes, a informação a priori foi obtida da imagem anterior e para a pré-filtragem, usou-se os filtros de *Haar* e *Fejér-Korovkin*, que apresentou resultados superiores ao de *Daubachies* e por isso foi o escolhido para essa etapa. Para demonstrar a imagem reconstruída, foi escolhida a imagem 36 que fornece melhor visualização da região.

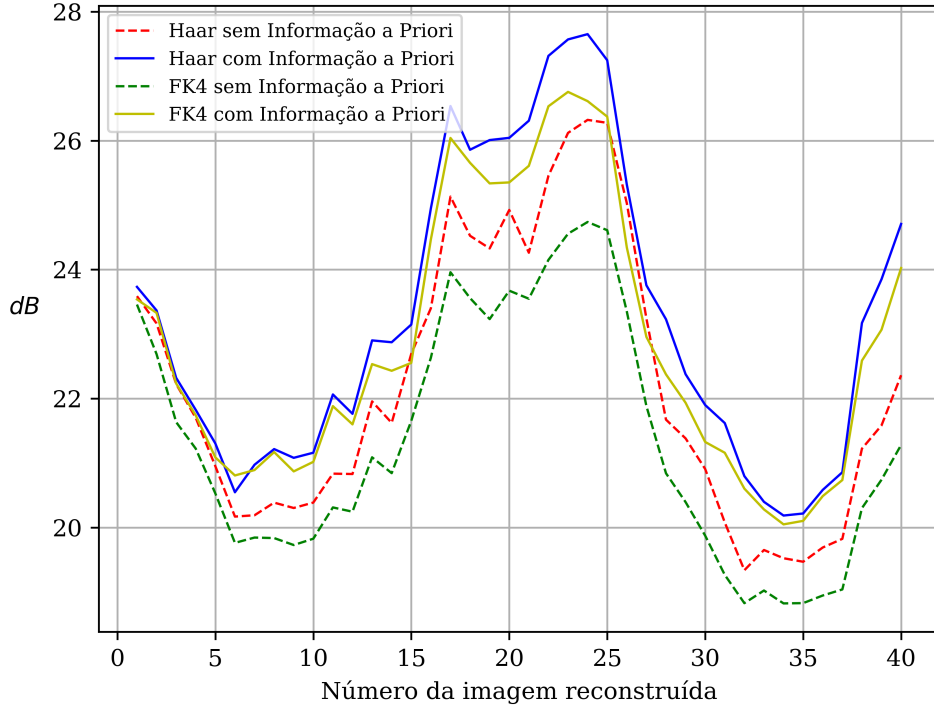


**Figura 4.1.** Reconstrução da imagem 36 em *Compressive Sensing* com informação a priori e pré-filtragem de *Haar*.



**Figura 4.2.** Reconstrução da imagem 36 em *Compressive Sensing* com informação a priori e pré-filtragem de *Fejér-Korovkin*.

Considerando os resultados acima, pode-se notar que apesar da reconstrução não ter preservado todos os detalhes da imagem, o aspecto geral dela foi reconstruído. Vale ressaltar que a reconstrução usou um número pequeno de ângulos, sendo este igual a 40, e utilizou informação a priori da imagem anterior para representar um cenário mais realista, em que está disponível apenas informação do corte anterior. Além disso, tentar achar diferenças entre as imagens com pré-filtragem de *Haar* e *Fejér-Korovkin* é quase impossível, por isso é indispensável utilizar a *SNR* como métrica de comparação.



**Figura 4.3.** Gráfico representando a  $SNR$  máxima obtida em cada reconstrução de imagem sem e com informação a priori, com os filtros de *Haar* e *Fejér-Korovkin*. FK4 é uma sigla para o filtro *Fejér-Korovkin* de ordem 4.

**Tabela 4.3.**  $SNR(dB)$  da reconstrução sem e com informação a priori com pré-filtragem dos filtros *Haar* e *Fejér-Korovkin*.

Imagem	<i>Haar</i>		<i>Fejér-Korovkin</i>	
	$SNR$ sem informação a priori	$SNR$ com informação a priori	$SNR$ sem informação a priori	$SNR$ com informação a priori
2	23,6	23,7	23,5	23,5
3	23,2	23,4	22,7	23,3
4	22,2	22,3	21,6	22,2
5	21,7	21,8	21,2	21,7
6	21,0	21,3	20,5	21,1
7	20,2	20,5	19,8	20,8
8	20,2	21,0	19,8	20,9
9	20,4	21,2	19,8	21,2
10	20,3	21,1	19,7	20,9
11	20,4	21,2	19,8	21,0
12	20,8	22,1	20,3	21,9
13	20,8	21,8	20,2	21,6
14	22,0	22,9	21,1	22,5

15	21,6	22,9	20,8	22,4
16	22,7	23,1	21,7	22,6
17	23,4	25,0	22,6	24,5
18	25,1	26,5	24,0	26,0
19	24,5	25,9	23,6	25,7
20	24,3	26,0	23,2	25,3
21	24,9	26,0	23,7	25,4
22	24,3	26,3	23,5	25,6
23	25,5	27,3	24,2	26,5
24	26,1	27,6	24,6	26,8
25	26,3	27,7	24,7	26,6
26	26,3	27,2	24,6	26,4
27	25,0	25,3	23,4	24,3
28	23,2	23,8	21,9	23,0
29	21,7	23,2	20,8	22,4
30	21,4	22,4	20,4	21,9
31	20,9	21,9	19,9	21,3
32	20,1	21,6	19,3	21,2
33	19,3	20,8	18,8	20,6
34	19,7	20,4	19,0	20,3
35	19,5	20,2	18,8	20,0
36	19,5	20,2	18,8	20,1
37	19,7	20,6	18,9	20,5
38	19,8	20,9	19,0	20,7
39	21,2	23,2	20,3	22,6
40	21,6	23,9	20,7	23,1
41	22,4	24,7	21,3	24,0

Com os resultados mostrados em 4.3, as seguintes médias amostrais foram calculadas:

**Tabela 4.4.** Médias com os resultados apresentados em 4.3, em *dB*.

	<i>Haar</i>	<i>Fejér-Korovkin</i>
Média da <i>SNR</i> sem informação a priori	22,2	21,3
Média da <i>SNR</i> com informação a priori	23,2	22,8
Ganho com informação a priori	1,05	1,5

Para verificar a precisão das médias mostradas em 4.9, o processo relatado em 3.9 foi realizado. Para o primeiro caso, o teste de normalidade foi rejeitado por ambos  $p$ -value serem menores que 0,05. Assim, utilizou-se o teste não-paramétrico de Wilcoxon.

**Tabela 4.5.** Resultado do teste estatístico para o primeiro caso: *Haar* e *Fejér-Korovkin* sem informação a priori.

Teste de normalidade		Teste de Wilcoxon Pareado
$p$ -value de <i>Haar</i>	$p$ -value de <i>Fejér-Korovkin</i>	
0,00962	0,00693	$1.819 \times 10^{-12}$

No segundo caso, o teste de normalidade também foi rejeitado e usou-se Wilcoxon.

**Tabela 4.6.** Resultado do teste estatístico para o segundo caso: *Haar* e *Fejér-Korovkin* com informação a priori.

Teste de normalidade		Teste de Wilcoxon Pareado
$p$ -value de <i>Haar</i>	$p$ -value de <i>Fejér-Korovkin</i>	
0,00643	0,0037	$5.8943 \times 10^{-10}$

Finalmente, para o terceiro, a normalidade foi provada e utilizou-se o Teste t de Student.

**Tabela 4.7.** Resultado do teste estatístico para o terceiro caso: ganho utilizando informação a priori para *Haar* e *Fejér-Korovkin*.


Teste de normalidade		Teste t de Student
$p$ -value de <i>Haar</i>	$p$ -value de <i>Fejér-Korovkin</i>	
0,4192	0,9826	$2.3822 \times 10^{-16}$

A partir dos dados das tabelas acima, pode-se afirmar que o melhor filtro para utilizar sem ou com informação a priori para este conjunto de imagens é o de *Haar*. Os resultados dos testes estatísticos nos três cenários rejeitam que as médias de *Haar* e *Fejér-Korovkin* são iguais, ou seja, que as médias calculadas em 4.9 apresentam uma precisão aceitável. Além disso, é perceptível que o ganho ao utilizar informação a priori de *Fejér-Korovkin* é superior ao de *Haar*, porque a informação a priori proporciona menor ganho para os filtros que esparsificam mais as imagens, como foi observado também em 4.2 para *Daubachies*.

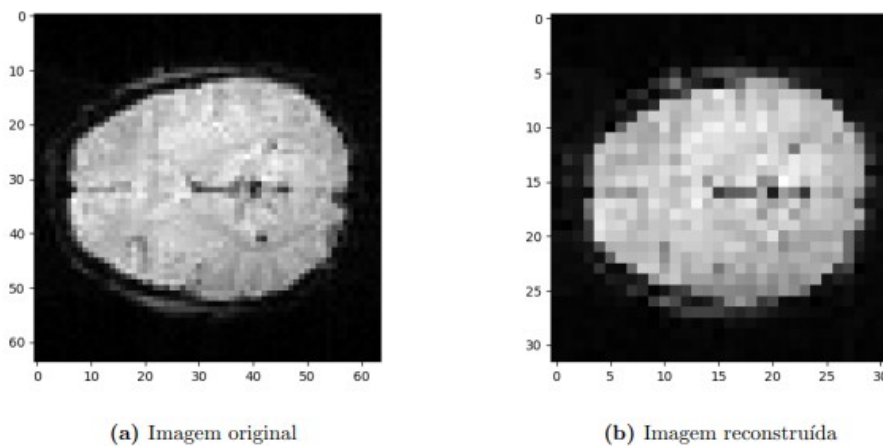


### 4.3 Reconstrução de múltiplos *frames* de ressonância magnética funcional em *Compressive Sensing* com informação a priori utilizando diferentes filtros para a pré-filtragem

Para um breve estudo sobre ressonância magnética funcional, foram reconstruídos 10 *frames* utilizando informação a priori do instante anterior com os filtros *Haar* e *Fejér-Korovkin*. Abaixo, segue uma exposição da reconstrução de um *frame* retirado do arquivo 1.



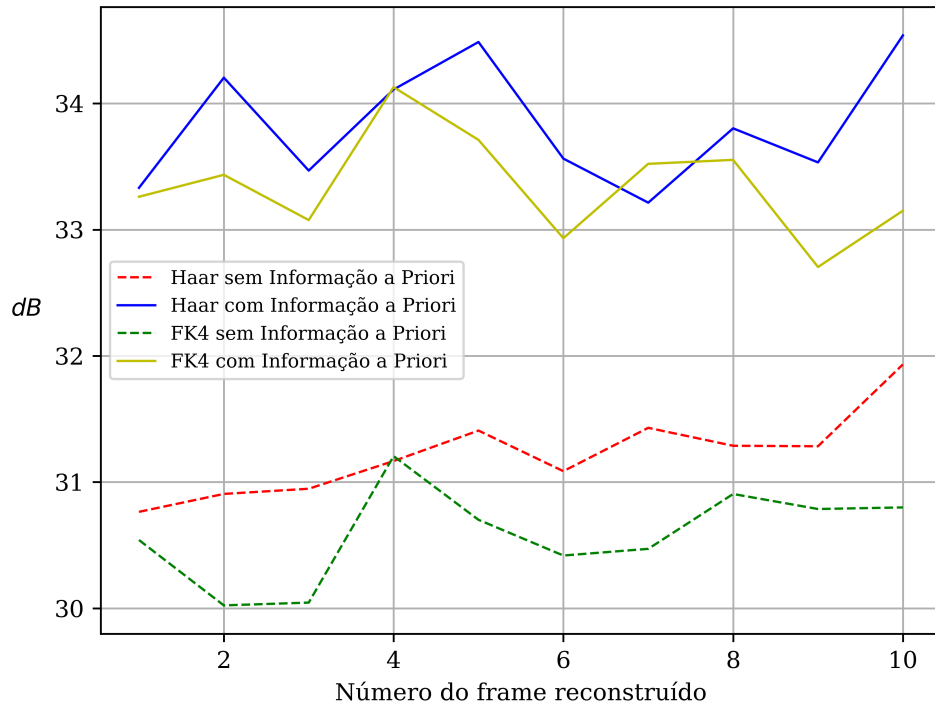
**Figura 4.4.** Reconstrução da imagem 36 em *Compressive Sensing* com informação a priori e pré-filtragem de *Haar*.



**Figura 4.5.** Reconstrução da imagem 36 em *Compressive Sensing* com informação a priori e pré-filtragem de *Fejér-Korovkin*.

É possível observar que a resolução da imagem funcional é menor quando comparada a uma imagem anatômica, pois é uma característica do próprio exame. Quando compara-

se a qualidade da imagem reconstruída é perceptível que a reconstrução não preservou todos os detalhes internos e preservou a forma geral da imagem. A reconstrução também foi realizada com 40 ângulos, assim como em 3.7.2.



**Figura 4.6.** Gráfico representando a  $SNR$  máxima obtida em cada reconstrução de *frame* sem e com informação a priori, com os filtros de *Haar* e *Fejér-Korovkin*. FK4 é uma sigla para o filtro *Fejér-Korovkin* de ordem 4.

**Tabela 4.8.**  $SNR(db)$  utilizando informação a priori para reconstrução de *frames* de ressonância magnética funcional.

Número do arquivo	<i>Haar</i>		<i>Fejér-Korovkin</i>	
	$SNR$ sem informação a priori	$SNR$ com informação a priori	$SNR$ sem informação a priori	$SNR$ com informação a priori
1	30,8	33,3	30,5	33,3
2	30,9	34,2	30,0	33,4
3	30,9	33,5	30,0	33,1
4	31,2	34,1	31,2	34,1
5	31,4	34,5	30,7	33,7
6	31,1	33,6	30,4	32,9
7	31,4	33,2	30,5	33,5
8	31,3	33,8	30,9	33,6
9	31,3	33,5	30,8	32,7
10	31,9	34,5	30,8	33,2

Seguindo a mesma estrutura de 3.7.2, abaixo é apresentado as médias amostrais dos resultados de 4.8.

**Tabela 4.9.** Médias com os resultados apresentados em 4.3, em  $dB$ .

	<i>Haar</i>	<i>Fejér-Korovkin</i>
Média da $SNR$ sem informação a priori	31,2	30,6
Média da $SNR$ com informação a priori	33,8	33,3
Ganho com informação a priori	2,6	2,7

Por fim, a partir dos resultados anteriores, foram feitos os testes estatísticos.

**Tabela 4.10.** Resultado do teste estatístico para o primeiro caso: *Haar* e *Fejér-Korovkin* sem informação a priori.

Teste de normalidade		Teste t de Student
$p$ -value de <i>Haar</i>	$p$ -value de <i>Fejér-Korovkin</i>	
0,61232	0,751001	0,0003937

**Tabela 4.11.** Resultado do teste estatístico para o primeiro caso: *Haar* e *Fejér-Korovkin* com informação a priori.

Teste de normalidade		Teste t de Student
<i>p-value</i> de <i>Haar</i>	<i>p-value</i> de <i>Fejér-Korovkin</i>	
0,33539	0,99081	0,01424

**Tabela 4.12.** Resultado do teste estatístico para o terceiro caso: ganho utilizando informação a priori para *Haar* e *Fejér-Korovkin*.

Teste de normalidade		Teste t de Student
<i>p-value</i> de <i>Haar</i>	<i>p-value</i> de <i>Fejér-Korovkin</i>	
0,69691	0,82663	0,31386

Com fundamento nas tabelas acima, foi provado a normalidade para todos os casos, uma vez que todos *p-values* foram maiores que 0,05, por consequência, foi utilizado o Teste t de Student nos três cenários. O objetivo é rejeitar ou não a hipótese nula, que as duas médias são iguais e o quão confiável é essa rejeição segundo o *p-value* do teste. Para o primeiro e segundo caso foi rejeitada a hipótese nula, enquanto para o terceiro não foi encontrado diferença estatística.

## 5 CONCLUSÃO

Nesse trabalho, as técnicas de *Compressive Sensing* e pré-filtragem e *Compressive Sensing* e informação a priori foram estudadas separadas para validação e posteriormente em conjunto, utilizando informações de ressonância magnética anatômica e funcional. Para início da pesquisa, testou-se vários filtros de *Wavelets* em uma imagem de cabeça e apenas dois foram identificados como os melhores, mas que não fornecerem *SNR* superior a de *Haar*. Por serem testes empíricos, é difícil afirmar quais propriedades de um filtro esparsificam as amostras, tendo em vista que *Haar* é um filtro simples, mas apresentou os melhores resultados em todos os experimentos, com exceção da imagem da pélvis reconstruída com informação a priori. Assim, também é possível aferir que a região da imagem influencia o desempenho do filtro, e que seria preciso fazer a reconstrução de imagens de partes variadas do corpo humano.

Em relação à informação a priori, a partir dos próprios resultados preliminares, já é concebível afirmar que usar a técnica proporciona resultados melhores do que sem. Para as reconstruções posteriores, obteve-se informação a priori da imagem e *frame* anterior, que constitui um cenário mais realista. Para os filtros que já apresentam elevada *SNR* apenas com a pré-filtragem, utilizar informação a priori não aumenta a *SNR* significativamente, como foi observado no teste anatômico e funcional comparando os valores de *Haar* e *Fejér-Korovkin*. Por conseguinte, utilizar informação a priori pode ser melhor para filtros pouco esparsificantes, que aqui foram *Fejér-Korovkin* e *Daubachies*.

Em síntese, pode-se inferir que a combinação de pré-filtragem e informação a priori proporciona resultados melhores que a reconstrução sem, e o valor do ganho depende do tipo de imagem. Além disso, trabalhos futuros podem investigar as múltiplas variáveis que influenciam a reconstrução de uma imagem: número de ângulos para reconstrução, proporção de informação a priori, região e tipo de imagem ( $T_1, T_2, PD$ ) e filtro utilizado para pré-filtragem.

# Referências Bibliográficas

- [1] Donald W. McRobbie, Elizabeth A. Moore, Martin J. Graves, e Martin R. Prince. *MRI from Picture to Proton*. Cambridge University Press, 3 edition, 2017.
- [2] M. J. Ackerman. The visible human project. *Proceedings of the IEEE*, 86(3):504–511, March 1998.
- [3] Joseph K.T. Lee et al. *Tomografia Computadorizada do Corpo em Correlação com Ressonância Magnética, 4<sup>o</sup> edição*. LIPPINCOTT WILLIAMS & WILKINS, 2008.
- [4] Jonathan A. Lima, Cristiano J. Miosso, Mylène C. Q. Farias, e Ricardo von Borries. Evaluation of different types of filters in magnetic resonance imaging using compressive sensing with pre-filtering. In *40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2018, Honolulu, HI, USA, July 18-21, 2018*, pages 5575–5578, 2018.
- [5] Hany Kasban, MAM El-Bendary, e DH Salama. A comparative study of medical imaging techniques. *International Journal of Information Science and Intelligent System*, 4(2):37–58, 2015.
- [6] Francisco Antonio de A Filho. *Geração e aplicação de raio x 1<sup>a</sup> edição*. Editora Saraiva, 2019.
- [7] Peter Lauterbur, Paul e Mansfield. Nossa capa. *Jornal Brasileiro de Patologia e Medicina Laboratorial [online]*, 2004.
- [8] Mariya Doneva. Mathematical models for magnetic resonance imaging reconstruction: An overview of the approaches, problems, and future research areas. *IEEE Signal Processing Magazine*, 37(1):24–32, January 2020.
- [9] O. N. Jaspan, R. Fleysher, e M. L Lipton. Compressed sensing mri: a review of the clinical literature. *British Institute of Radiology*, 88(1056), 2015.
- [10] R. Ahmad, H. H. Hu, R. Krishnamurthy, e R. Krishnamurthy. Reducing sedation for pediatric body mri using accelerated and abbreviated imaging protocols. *Pediatric Radiology*, 48(1):37–49, 2018.

- [11] M. E. Quirk, A. J. Letendre, R. A. Ciottone, e J. F Lingley. Anxiety in patients undergoing mr imaging. *Radiology*, 170(2):463–466, 1989.
- [12] X. V et al. Nguyen. Prevalence and financial impact of claustrophobia, anxiety, patient motion, and other patient events in magnetic resonance imaging. *Topics in Magnetic Resonance Imaging*, 29(3):125–130, June 2020.
- [13] Jeffrey Tsao e Sebastian Kozerke. Mri temporal acceleration techniques. *Journal of Magnetic Resonance Imaging*, 36:543–560, 2012.
- [14] Patricia M Johnson, Michael P Recht, e Florian Knoll. Improving the speed of mri with artificial intelligence. 24(01):012–020, 2020.
- [15] Li Feng et al. Compressed sensing for body mri. *Journal of Magnetic Resonance Imaging*, 00, 2016.
- [16] Mark A. Griswold et al. Generalized autocalibrating partially parallel acquisitions (grappa). In *Magnetic Resonance in Medicine*, volume 47, pages 1202–1210, 2002.
- [17] Michael Dieckmeyer et al. Effect of mri acquisition acceleration via compressed sensing and parallel imaging on brain volumetry. *Magnetic Resonance Materials in Physics, Biology and Medicine*, 34:487–497, 2021.
- [18] Michael Hutchinson e Ulrich Raff. Fast mri data acquisition using multiple detectors. *MAGNETIC RESONANCE IN MEDICINE*, 6:87–91, 1988.
- [19] F. Breuer, M. Blaimer, M. Griswold, e P. Jakob. Caipirinha – revisited. *MAGNETOM Flash*, 63, 2015.
- [20] Mohammad Zalbagi Darestani, Akshay S Chaudhari, e Reinhard Heckel. Measuring robustness in deep learning based compressive sensing. In *International Conference on Machine Learning*, pages 2433–2444. PMLR, 2021.
- [21] Takahiro Ueda, Yoshiharu Ohno, Kaori Yamamoto, Akiyoshi Iwase, Takashi Fukuba, Satomu Hanamatsu, Yuki Obama, Hirotaka Ikeda, Masato Ikedo, Masao Yui, et al. Compressed sensing and deep learning reconstruction for women’s pelvic mri denoising: utility for improving image quality and examination time in routine clinical practice. *European journal of radiology*, 134:109430, 2021.
- [22] Donoho David. Scanning the technology. *Proceedings of the IEEE*, 98(6):910–912, 2010.
- [23] Y. Bao, Z. Tang, e H Li. Compressive-sensing data reconstruction for structural health monitoring: a machine-learning approach. *Structural Health Monitoring*, 19(1):293–304, 2020.

- [24] Richard G. Baraniuk. Compressive sensing [lecture notes]. *IEEE Signal Processing Magazine*, 24(4):118–121, 2007.
- [25] Ricardo Otazo et al. Combination of compressed sensing and parallel imaging for highly accelerated first-pass cardiac perfusion mri. *Magnetic Resonance in Medicine*, 64(3):767–776, September 2010.
- [26] Peng Li, Xiangdong Yu, Jay Griffin, Jonathan M Levine, e Jim Ji. High-resolution mri of spinal cords by compressive sensing parallel imaging. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 4266–4269, 2015.
- [27] Samira Vafay Eslahi, Pranav Vaidik Dhulipala, Caiyun Shi, Guoxi Xie, e Jim X. Ji. Parallel compressive sensing in a hybrid space: Application in interventional mri. In *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 3260–3263, 2017.
- [28] Badnjar Jelena. Comparison of algorithms for compressed sensing of magnetic resonance images. In *2015 4th Mediterranean Conference on Embedded Computing (MECO)*, pages 303–306, 2015.
- [29] Nai-Shan Huang, Yu-Min Lin, Yi Chen, e An-Yeu Andy Wu. Adaptive filter-based reconstruction engine design for compressive sensing. In *2014 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS)*, pages 499–502, 2014.
- [30] C. J. Miosso, R. von Borries, e J. H. Pierluissi. Compressive sensing method for improved reconstruction of gradient-sparse magnetic resonance images. In *2009 Conference Record of the Forty-Third Asilomar Conference on Signals, Systems and Computers*, pages 799–806, 2009.
- [31] Daniel Lucas Ferreira e Almeida. Reconstrução de imagens de ressonância magnética com base em compressive sensing usando informação a priori estrutural em abordagem estocástica. page 83, 2017. Dissertação de Mestrado.
- [32] Borut Marinček Dominik Weishaupt, Victor D. Koechli. *How does MRI work An Introduction to the Physics and Function of Magnetic Resonance Imaging*. Springer, 2nd edition, 2006.
- [33] D. Moratal, A. Vallés-Luch, L. Martí-Bonmatí, e M. Brummer. k-space tutorial: an mri educational tool for a better understanding of k-space. In *Biomedical imaging and intervention journal*, volume 4, 2008.
- [34] G.A. Wright. Magnetic resonance imaging. *IEEE Signal Processing Magazine*, 14(1):56–66, 1997.

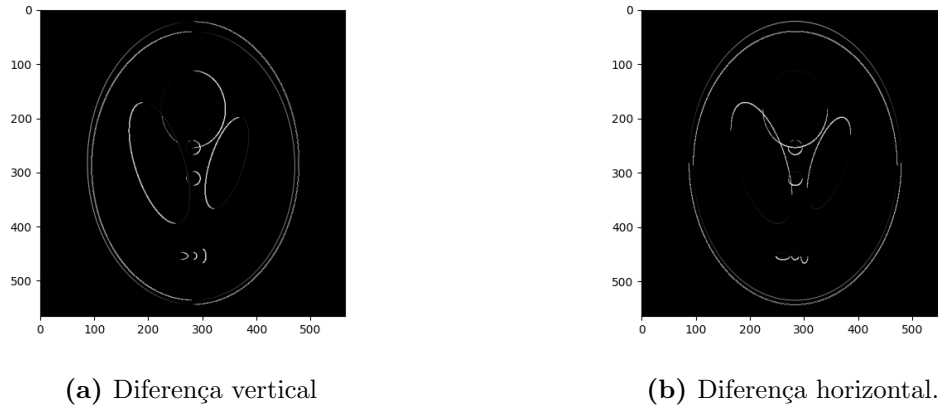


- [35] R. Nick Bryan. *Introduction to the Science of Medical Imaging*. Cambridge University Press, 2009.
- [36] R. von Borries, C. Jacques Miosso, e C. Potes. Compressed sensing using prior information. In *2007 2nd IEEE International Workshop on Computational Advances in Multi-Sensor Adaptive Processing*, pages 121–124, 2007.
- [37] C. J. Miosso, R. von Borries, M. Argaez, L. Velazquez, C. Quintero, e C. M. Potes. Compressive sensing reconstruction with prior information by iteratively reweighted least-squares. *IEEE Transactions on Signal Processing*, 57(6):2424–2431, June 2009.
- [38] Jiao Wu, Fang Liu, Lc Jiao, e Xiaodong Wang. Multivariate pursuit image reconstruction using prior information beyond sparsity. *Signal Process.*, 93(6):1662–1672, jun 2013.
- [39] João F. C. Mota, Nikos Deligiannis, e Miguel R. D. Rodrigues. Compressed sensing with prior information: Strategies, geometry, and bounds. *IEEE Transactions on Information Theory*, 63(7):4472–4496, 2017.
- [40] David B et al. Keator. The function biomedical informatics research network data repository. *NeuroImage*, 124:1074–1079, 2016.
- [41] Camila Franco. Implementação e avaliação de métodos de compressive sensing com pré-filtragem para imageamento por tomografia computadorizada. page 45, 2019. Trabalho de Conclusão de Curso.

## 6 APÊNDICE


### 6.1 Reconstrução por *Compressive Sensing* de imagens artificiais já esparsas no domínio de pixels

O fantoma de Shepp-Logan é frequentemente utilizado em trabalhos de imageamento por ser semelhante a um crânio e apresentar diferentes propriedades de absorção das elipses, simulando assim os tecidos que apresentam tempos de relaxação distintos. Os resultados após o processo de esparsificação de colunas e linhas do fantoma de Shepp-Logan de tamanho 566x566 seguem abaixo.



**Figura 6.1.** Resultado após a aplicação da diferença finita no fantoma de Shepp-Logan.

É perceptível que a diferença horizontal enfatiza bordas verticais e a diferença vertical enfatiza bordas horizontais, então é preciso unir ambos os resultados para obter a imagem reconstruída.




**Figura 6.2.** Comparação entre a imagem original e reconstruída.

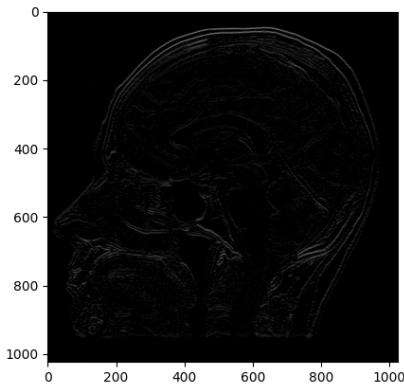
Como observado, o fantoma esparsa comparada ao reconstruído são semelhantes, pois a imagem já é esparsa no domínio de pixels e ao durante a reconstrução,  $A$  e  $A_h$  são identidades.

## 6.2 *Compressive Sensing* com Pré-filtragem de imagens de ressonância magnética


Foram feitos experimentos com medidas reais obtidas de uma imagem de cabeça de corte sagital, em formato *.mat* de tamanho 1024x1024. Utilizando os filtros de *Haar* e  $\theta = 200$ , que representa o número de ângulos das trajetórias, os resultados obtidos seguem abaixo.



(a) Pré-filtragem com filtro  $h_1$




(b) Pré-filtragem com filtro  $h_2$



(c) Pré-filtragem com filtro  $h_3$

**Figura 6.3.** Resultados da pré-filtragem da imagem 3.5.

Apesar dos métodos diferentes, os resultados aqui apresentados e em 6.1 são semelhantes por ressaltarem partes específicas da imagem. Assim, o filtro  $h_1$  destaca partes verticais,  $h_2$  horizontais e  $h_3$  diagonais. A figura 6.3c comparada às outras não apresenta diferença nítida pela imagem original não armazenar a maior parte da sua informação nas diagonais. Contudo, mesmo que não haja diferença visual, é importante utilizar filtros complementares para não haver perda de informação, além de apenas um filtro não abranger toda a imagem. Por fim, as 3 imagens foram “unidas” pela composição espectral.



(a) Imagem original

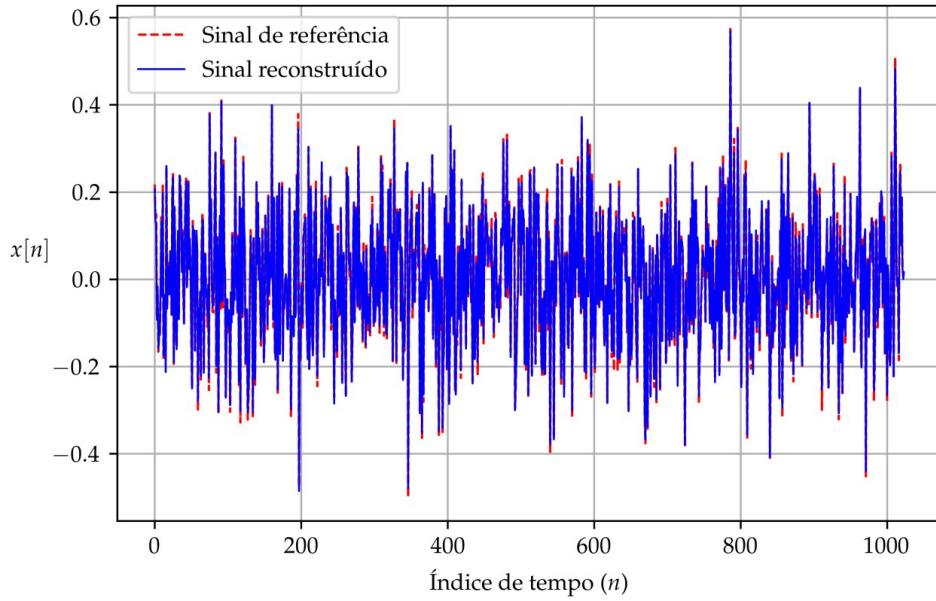
(b) Imagem reconstruída

**Figura 6.4.** Comparação entre a imagem original e reconstruída.


Comparando as imagens de 6.4, ambas são semelhantes, com poucas perdas visuais, contudo, a métrica visual não é um parâmetro confiável, sendo preciso outras formas de comparação, como o *SNR*. Todavia, os testes aqui feitos são iniciais, com o objetivo de avaliar o desempenho do algoritmo de reconstrução.

### 6.3 Reconstrução por *Compressive Sensing* de sinais aleatórios no domínio 1D com Informação a Priori

A partir do sinal aleatório de 1024 medidas e 30 elementos não nulos, os seguintes gráficos foram feitos com a reconstrução em *CS* sem e com informação a priori.



**Figura 6.5.** Gráfico da representação do sinal original (vermelho) e sinal reconstruído (azul), sem informação a priori.



**Figura 6.6.** O processo de reconstrução foi repetido para o mesmo sinal, com adição de informação a priori para minimização de  $l_p$ .

Comparando visualmente ambas as figuras, é possível notar que apesar do *CS* reconstruir boa parte do sinal, ele não consegue recuperar totalmente o sinal original. Para a figura 6.6, a técnica *CS* com informação a priori conseguiu reconstruir boa parte do sinal original, sendo que a diferença visual entre os sinais original e reconstruído não é nítida. Em seguida, é mostrado os resultados dos 10 testes realizados com sinais aleatórios.

**Tabela 6.1.**  $SNR(dB)$  dos sinais reconstruídos sem e com informação a priori. Os parâmetros definidos em 3.4 foram mantidos.

Número do teste	$SNR(dB)$	
	sem informação a priori	com informação a priori
1	43,6	50,5
2	31,6	37,1
3	42,2	51,3
4	34,4	125,2
5	31,1	37,5
6	21,9	26,7
7	15,3	29,4
8	25,7	36,2
9	29,1	61,3
10	17,3	32,1

No geral, é perceptível que a informação a priori propicia maior ganho, e como são sinais aleatórios, a  $SNR$  oscilou em cada caso, chegando à diferença de 90,8dB para o caso 4. Dessa forma, o algoritmo de informação a priori foi certificado e pode ser utilizado para o domínio 2d.

## 6.4 Reconstrução de imagens em *Compressive Sensing* com Informação a Priori e Pré-filtragem

Estendendo o conceito de informação a priori para o domínio 2d, foram realizados três testes para as imagens 3.3 e 3.5, contabilizando seis resultados ao total. Cada teste é composto pela reconstrução de uma imagem em *CS* com informação a priori e pré-filtragem. O objetivo desta etapa é comparar como a informação a priori, o índice de proporção e o número de ângulos influenciam a  $SNR$ .

### 6.4.1 Fantoma de Shepp-Logan

Para início dos testes, o fantoma foi a primeira imagem reconstruída, ao total de três vezes e mudando o número de ângulos a cada uma. Em todas as etapas o índice de proporção variou de 0 a 10%. Abaixo são mostrados os resultados e em todos os casos a  $SNR$  com informação a priori é o valor máximo obtido no respectivo teste.

**Tabela 6.2.**  $SNR(dB)$  do fantoma reconstruído sem e com informação a priori.

Número do teste	Número de ângulos	$SNR(dB)$ sem informação	$SNR(dB)$ com informação a priori
1	10	4,3	15,5
2	20	19,2	47,9
3	30	22,4	86,9

É possível notar a partir de 6.2 que a utilização de informação a priori aumenta significativamente a  $SNR$  para o pior caso, em que o número de ângulos é 10. Como o fantoma é uma imagem com pouca informação, em apenas aumentar o número de ângulos há ganho de  $16,5dB$  em média, comparando o valor de 1 com 2 e 3. Isso porque um número maior de ângulos proporciona mais informação para a reconstrução da imagem e aumenta o valor de  $l$  visto em 2.2, contudo, não é uma solução prática, tendo em vista que depende da aquisição em um domínio não nulo.

Em relação aos resultados com informação a priori, a média de incremento em cada teste foi de  $34,8dB$ , sendo assim, utilizar a técnica promove maior ganho comparado apenas à mudança de número de ângulos.

#### 6.4.2 Imagem de ressonância magnética

Após o teste preliminar com o fantoma, as reconstruções foram feitas com imagens reais de ressonância magnética, iniciando pela imagem 3.5. Por conter mais informação, o número de ângulos foi de 40, 60 e 80, para contemplar mais informação da imagem.

**Tabela 6.3.**  $SNR(dB)$  da imagem 3.5 reconstruída sem e com informação a priori.

Número do teste	Número de Ângulos	$SNR(dB)$ sem informação	$SNR(dB)$ com informação a priori
4	40	12,7	16,8
5	60	15,7	19,6
6	80	17,9	21,7

Os ganhos foram menores quando comparados aos de 6.2, porque é uma imagem real e mais complexa, sendo mais difícil alterar a  $SNR$ . Mas mesmo com esses fatores, utilizar informação a priori ainda é vantajoso, pois houve em média ganho de  $3,9dB$ .



Dessa forma, é possível aferir que informação a priori e utilizar mais ângulos aumentam a  $SNR$ , contudo, o objetivo não é estudar sistematicamente ambas em conjunto, e sim como a combinação de diferentes filtros com informação a priori impacta a reconstrução da imagem. Assim, nos próximos testes, o número de ângulos foi fixado para investigar a reconstrução com outros filtros.