



MÉTODOS PARA RECONSTRUÇÃO DE
IMAGENS HIPERESPECTRAIS PARA A
COSTA BRASILEIRA BASEADOS EM
COMPRESSIVE SENSING

DANIELE DIAS

DISSERTAÇÃO DE MESTRADO
EM ENGENHARIA ELÉTRICA

DEPARTAMENTO DE ENGENHARIA ELÉTRICA

FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA

Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Elétrica

Métodos para Reconstrução de Imagens Hiperespectrais para a Costa
Brasileira Baseados em *Compressive Sensing*

Daniele Dias

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO PROGRAMA DE
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE DE
BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OB-
TENÇÃO DO GRAU DE MESTRE.

APROVADA POR:

Ugo Silva Dias, Dr. (UnB)
(Orientador)

Robson de Oliveira Albuquerque, Dr. (CEPESC)
(Examinador Externo)

Leonardo Aguayo, Dr. (ENE/UnB)
(Examinador Interno)

Brasília/DF, janeiro de 2023.

FICHA CATALOGRÁFICA

DIAS, DANIELE

Métodos para Reconstrução de Imagens Hiperespectrais para a Costa Brasileira Baseados em *Compressive Sensing*. [Brasília/DF] 2023.

xxx, nnp., 210 x 297 mm (ENE/FT/UnB, Mestre, Dissertação de Mestrado, 2023).

Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Elétrica.

Departamento de Engenharia Elétrica

- | | |
|----------------------------|------------------------|
| 1. Imagens Hiperespectrais | 2. Compressive Sensing |
| 3. Índice de Qualidade | 4. Costa Brasileira |
| I. ENE/FT/UnB | II. Título de Mestre |

REFERÊNCIA BIBLIOGRÁFICA

DIAS, DANIELE (2023). Métodos para Reconstrução de Imagens Hiperespectrais para a Costa Brasileira Baseados em *Compressive Sensing*. Dissertação de Mestrado, Publicação (PPGEE.DM 194/2023, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 78p.

CESSÃO DE DIREITOS

AUTOR: Daniele Dias

TÍTULO: Métodos para Reconstrução de Imagens Hiperespectrais para a Costa Brasileira Baseados em *Compressive Sensing*.

GRAU: Mestre ANO: 2023

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

Daniele Dias

Universidade de Brasília (UnB)

Campus Darcy Ribeiro

Faculdade de Tecnologia - FT

Departamento de Engenharia Elétrica(ENE)

Brasília - DF CEP 70919-970

Este trabalho é dedicado a cada pessoa que me falou: Não desista. E acreditem, foram tantas que não consigo nomeá-las.

AGRADECIMENTOS

Este foi o trabalho mais árduo da minha vida. Iniciar um mestrado no meio de uma pandemia global, com todos os problemas pessoais que isso me acarretaram, trocar 3 vezes de tema devido a problemas externos que eu não poderia lidar, mais momentos difíceis do que prazerosos, e mesmo assim chegar a finalizar este trabalho já é uma vitória pessoal. Tenho muitos a agradecer, em especial aos professores Giancarlo Santilli e Cristiano Miosso, sem eles não teria conseguido fazer nada, ou publicados os artigos que publiquei neste período. Aos amigos que estiveram ao meu lado nos piores momentos como Arthur Wernke, Elpidio Cândido, Daniel Caio, Suzane e Daniel Sales, ou somente aqueles que me olhavam e falavam: "você consegue, termina, você já fez o mais difícil". Sinceramente eu só posso agradecer a cada pessoa que durante este período acreditou na minha capacidade.

RESUMO

A imagem hiperespectral surgiu como uma nova geração de tecnologia para observação da Terra e exploração espacial desde o início deste milênio e amplamente utilizada em várias disciplinas e aplicações. A informação espectral detalhada é adquirida por imageadores hiperespectrais, nos quais, geralmente produzem resultados impossíveis de serem obtidos com imagens multiespectrais ou outros tipos de satélites. Muitas técnicas para análise de qualidade dos dados foram desenvolvidas ao longo dos anos, e adaptadas para imagens hiperespectrais de acordo com o objetivo, como o NDVI (*Normalized Difference Vegetation Index*) e o NDWI (*Normalized Difference Water Index*). A grande limitação deste tipo de tecnologia é o armazenamento dos dados devido a limitação de peso que satélites possuem. Desta forma, técnicas de compressão passaram-se a ser utilizadas, como o *Compressive Sensing* (CS) criado para imageamento médico, gerando imagens com alta qualidade a partir de linhas radiais no espaço- k mesmo quando a relação de Shannon-Nyquist não é obtida. Assim, este trabalho combinou a técnica de CS com a de análise de qualidade para reconstruir imagens hiperespectrais da costa brasileira, a partir de estimação de dados no domínio de Fourier e quantificar a qualidade do dado a partir dos dados reais, obtidos pelo satélite PRISMA. Os resultados obtidos apresentam tanto a relação sinal-ruído da reconstrução, onde há uma variação entre 45 dB e 330 dB comparados a imagem original e que mesmo em imagens o valor de números de radias abaixo do ideal, é visível a ênfase de informação de acordo com o NDWI. A partir dessa variação é possível determinar um número ótimo de radias que é 750. Estes resultados sugerem que *Compressive Sensing* com pré-filtragem permite uma melhora em relação à técnica de pré-filtragem para imageamento hiperespectral, analogamente à melhora observada nos últimos anos em problemas de imageamento médico.

Palavras-chave: Imagens hiperespectrais, Compressive Sensing, Análise de qualidade, Costa Brasileira.

ABSTRACT

Hyperspectral imaging has emerged as a new generation of technology for Earth observation and space exploration since the beginning of this millennium and widely used in various disciplines and applications. Detailed spectral information is acquired by hyperspectral imagers, which generally produce results that are impossible to obtain with multispectral images or other types of satellites. Many techniques for data quality analysis have been developed over the years, and adapted for hyperspectral imaging according to the objective, such as NDVI and NDWI. The great limitation of this type of technology is the storage of data due to the weight limitation that satellites have. In this way, compression techniques started to be used, such as Compressive Sensing (CS) created for medical imaging, generating high quality images from radial lines in k -space even when the ratio of Shannon-Nyquist is not obtainable. Thus, this work combined the CS technique with quality analysis to reconstruct hyperspectral images of the Brazilian coast, based on data estimation in the Fourier domain and to quantify data quality based on real data obtained by the PRISMA satellite. The results obtained show both the signal-to-noise ratio of the reconstruction, where there is a variation between 45 dB and 330 dB compared to the original image and that even in images the value of radiant numbers below the ideal, the emphasis of information is visible according to the NDWI. From this variation it is possible to determine an optimal number of radiates which is 750. These results suggest that Compressive Sensing with prefiltering allows an improvement over the prefiltering technique for hyperspectral imaging, similarly to the improvement observed in recent years in medical imaging problems.

Keywords: Hyperspectral imaging, Compressive Sensing, Quality analysis, Brazilian Coast.

SUMÁRIO

Sumário	i
Lista de figuras	iii
Lista de tabelas	v
Lista de símbolos	vi
Capítulo 1 – Introdução	1
1.1 Contextualização	3
1.2 Trabalhos Desenvolvidos	5
1.3 Definição do Problema Científico e Proposta de Pesquisa	5
1.4 Objetivos	6
1.4.1 Objetivo Geral	6
1.4.2 Objetivos Específicos	6
Capítulo 2 – Fundamentação teórica e Estado da Arte	7
2.1 Transformada de <i>Fourier</i>	7
2.1.1 Transformada de <i>wavelets</i>	8
2.2 <i>Compressive Sensing</i>	11
2.2.1 Amostragem de sinais	12
2.2.2 Teorema de minimização	12
2.2.3 Esparsidade	14
2.2.4 Solução de otimização combinatorial	14
2.2.5 Propriedades das p-normas	15
2.2.6 Proposta de solução	17
2.3 Missões de Satélites Hiperespectrais	18
2.3.1 Missão PRISMA	23
2.3.2 Veículo espacial	24
2.3.3 Sensores complementares	26
2.3.4 Calibragem do instrumento	33

2.3.5	Segmento de solo	35
2.4	Índice de qualidade	35
2.4.1	NDWI	36
Capítulo 3	– Materiais e Métodos	38
3.1	Visão Geral	38
3.2	Procedimento de otimização para reconstrução	39
3.3	Pré-filtragem	40
3.4	Algoritmo	41
3.5	Imagem-teste	44
Capítulo 4	– Resultados e Discussões	46
4.1	Resultados no domínio de Fourier	46
4.2	Comparação	54
Capítulo 5	– Conclusão	57
5.1	Trabalhos Futuros	57
Referências		59

LISTA DE FIGURAS

2.1	Transformada de Haar.	10
2.2	Comportamento da bola de influência na norma euclidiana.	15
2.3	Comportamento da bola de influência na norma L_1	16
2.4	A bola L_p para diferentes valores de p	17
2.5	<i>HyperSpectral Imager</i>	19
2.6	Satélite MightySat II.	20
2.7	Visão artística da missão NEMO.	20
2.8	the Hyperion – um espectrorradiômetro de imagem.	21
2.9	Imageador hiperespectral EO-1/Hyperion.	22
2.10	Satélite EOS-AM1.	23
2.11	Ilustração do layout da nave espacial PRISMA.	25
2.12	Ilustração da cabeça óptica Hyp / Pan do instrumento PRISMA	26
2.13	Diagrama de blocos esquemático do instrumento PRISMA.	27
2.14	Diagrama de blocos da unidade óptica.	28
2.15	Vista esquemática da configuração do telescópio.	29
2.16	Layout óptico dos espectrômetros VNIR e SWIR.	30
2.17	Layout óptico da câmera Pan.	31
2.18	Visão interna da arquitetura PRISMA.	32
2.19	Acomodação opto-mecânica e caminhos ópticos da UTI.	33
2.20	Vista esquemática dos caminhos ópticos da UTI.	34

2.21	Os principais elementos do segmento de solo.	35
2.22	Resultado do índice MSAVI na região de Milão, Itália.	36
3.1	Visão geral da metodologia utilizada para a realização do trabalho proposto. . .	39
3.2	Linhas radiais de trajetória de amostras (os pontos vermelhos representam as medidas tomadas).	40
3.3	Pré-filtragem das medidas de entrada b e reconstrução separada de cada versão filtrada com as medidas b_{f1} , b_{f2} e b_{f3}	41
3.4	Região de São Sebastião em SP, situada na bacia de Santos, com as coordenadas (-23.82, -45.40).	45
4.1	Reconstrução com linhas radiais da imagem-teste para diferentes valores de k . .	47
4.2	Índice de Similaridade Estrutural da reconstrução com a imagem original. . . .	54
4.3	NDWI feito com os resultados da imagem real da área de interesse.	55
4.4	Relação Sinal-Ruído da reconstrução com a imagem original.	56

LISTA DE TABELAS

2.1	Principais características do PDHT	25
2.2	Visão geral dos parâmetros do instrumento PRISMA	27
3.1	Algoritmo utilizado para a reconstrução das imagens a partir das medidas no domínio da frequência, com base nos métodos iterativo dos mínimos quadrados reponderados.	44

LISTA DE ABREVIATURAS E SÍMBOLOS

<i>AGILE</i>	– <i>Agile MicroSatellite</i>
<i>ALI</i>	– <i>Advanced Land Imager</i>
<i>ASI</i>	– <i>Agência Espacial Italiana</i>
<i>AVIRIS</i>	– <i>Airborne Visible / InfraRed Imaging Spectrometer</i>
<i>BRDF</i>	– <i>Bidirectional Reflectance Distribution Function</i>
<i>CCD</i>	– <i>Charge Coupled Devices</i>
<i>CGS</i>	– <i>Carlo Gavazzi Soace SpA</i>
<i>CHRIS</i>	– <i>Compact High Resolution Imaging Spectrometer</i>
<i>COIS</i>	– <i>Coastal Ocean Imaging Spectroradiometer</i>
<i>CS</i>	– <i>Compressive Sensing</i>
<i>DBS</i>	– <i>Dichroic Beam Splitter</i>
<i>EnMap</i>	– <i>Environmental Mapping and Analysis Program</i>
<i>ESA</i>	– <i>European Space Agency</i>
<i>EOL</i>	– <i>End of Life</i>
<i>FITS</i>	– <i>Flexible Image Transport System</i>
<i>FOR</i>	– <i>Field of Regard</i>
<i>FOV</i>	– <i>Campo de Visão</i>
<i>FPA</i>	– <i>Conjunto de plano focal</i>
<i>FTHSI</i>	– <i>Fourier Transform Hyperspectral Imager</i>
<i>FWHM</i>	– <i>Resolução espectral</i>
<i>GSD</i>	– <i>Amostragem de Distância do Solo</i>
<i>HIRIS</i>	– <i>High Resolution Imaging Spectrometer</i>
<i>HRC</i>	– <i>âmera pancromática alta resolução</i>
<i>HRS</i>	– <i>Hyperspectral Remote Sensing</i>
<i>HSI</i>	– <i>HyperSpectral Imager</i>
<i>Hyp</i>	– <i>Hiperespectral</i>
<i>HypSEO</i>	– <i>Hyperspectral Satellite for Earth Observation</i>
<i>ICU</i>	– <i>Unidade de Calibração Interna</i>
<i>IDHS</i>	– <i>Instrument Data Handling System</i>
<i>IRIS</i>	– <i>Interface Region Imaging Spectrograph</i>
<i>IRLS</i>	– <i>Iteratively reweighted least-squares</i>
<i>IS</i>	– <i>Imaging Spectrometry</i>
<i>JPL</i>	– <i>Laboratório de Propulsão a Jato</i>
<i>LAC</i>	– <i>Atmospheric Corrector</i>
<i>LEISA</i>	– <i>Linear Etalon Imaging Spectrometer Array</i>
<i>LTDN</i>	– <i>Hora local da travessia do equador no nó descendente</i>
<i>MIR</i>	– <i>Estação Espacial Russa</i>
<i>MODIS-N</i>	– <i>Moderate Resolution Imaging Spectrometer-Nadir</i>
<i>MPC</i>	– <i>Planejamento e Controle de Missão</i>

<i>MSAVI</i>	– Índice de Vegetação Ajustado ao Solo Modificado
<i>MSS</i>	– <i>Multispectral Sensor System</i>
<i>MTF</i>	– Função de transferência de modulação
<i>NASA</i>	– <i>National Aeronautics and Space Administration</i>
<i>NDSSI</i>	– <i>Normalized Difference Suspended Sediment Index</i>
<i>NDVI</i>	– <i>Normalized Difference Vegetation Index</i>
<i>NDWI</i>	– <i>Normalized Difference Water Index</i>
<i>NEMO</i>	– <i>Naval Earth Map Observer</i>
<i>NMP</i>	– <i>New Millennium Program</i>
<i>OSDI</i>	– <i>Oil Slick Detection Index</i>
<i>Pan</i>	– Pancromáticas
<i>PDHT</i>	– <i>Payload Data Handling Transmission</i>
<i>POV</i>	– <i>Point-of-view</i>
<i>PRISMA</i>	– <i>PRecursore IperSpettrale della Missione Applicativa</i>
<i>PROBA</i>	– <i>PRoject for OnBoard Authonomy</i>
<i>PROCAD – DEFESA</i>	– Programa de Cooperação Acadêmica em Defesa Nacional
<i>SG</i>	– <i>Selex Galileo</i>
<i>SNR</i>	– Relação Sinal-Ruído
<i>SPAM</i>	– <i>Spectral Analysis Manager</i>
<i>SRTI-BAS</i>	– <i>Space Research and Technology Institute</i> na Academia de Ciências da Bulgária
<i>SSIM</i>	– <i>Structural Similarity Index Measure</i>
<i>STFT</i>	– Transformada de Fourier de Tempo curto (Transformada de Gabor)
<i>SWIR</i>	– <i>Short-Wavelength Infrared</i>
<i>SZA</i>	– <i>Sun Zenith Angle</i>
<i>TMA</i>	– <i>Three Mirror Anastigmat</i>
<i>TOA</i>	– Conjunto de plano focal
<i>TT&C</i>	– <i>Telemetry, Tracking and Command</i>
<i>VAFB</i>	– <i>Vandenberg Space Force Base</i>
<i>VNIR</i>	– <i>Visible and Near-infrared</i>
<i>WCS</i>	– <i>World Coordinate System</i>
<i>A</i>	– Matriz de medidas
<i>b</i>	– Vetor de medidas
\mathcal{F}	– Operador da transformada de <i>Fourier</i>
L_0	– Espaço métrico para solução combinatorial
L_1	– Espaço métrico de <i>Manhattan</i>
L_2	– Espaço métrico euclidiano
p	– Comprimento de perpendicular a linha de trajetória
k	– Número de projeções
\hat{T}	– Matriz de Transformação Esparsificante
\mathcal{W}	– Operador da transformada de <i>Wavelets</i>
x	– Imagem na Forma Empilhada
\hat{x}	– Sinal no Domínio Transformado
λ	– Multiplicador de <i>Lagrange</i>
ω_m	– Maior Frequência do sinal de estudo
ω_s	– Frequência de Amostragem

INTRODUÇÃO

Na astronomia, a definição da qualidade de uma imagem está associada a quantidade de fótons que o equipamento consegue detectar [1]. Além disso, para a maioria dos problemas astronômicos de compressão de dados, três propriedades principais devem estar sob controle: resolução (função de propagação de ponto), sensibilidade (capacidade de detectar sinais de baixo nível) e fotometria [2], permitindo assim o tipo de ênfase em informações que se deseja retirar neste tipo de aplicação.

Em muitas aplicações de interesse prático, como em imagens astronômicas e imagens médicas, é desejável reconstruir um objeto (um sinal, uma imagem etc.) a partir de amostras incompletas de *Fourier*, e para tal, foi desenvolvida a teoria do *Compressive Sensing* (CS). Depois do conhecido Teorema de Amostragem de *Shannon-Nyquist*, a introdução do CS é um grande avanço à comunidade de processamento de sinais [3, 4], tendo como principal característica, a avaliação da esparsidade da imagem [5].

A tecnologia HRS (*Hyperspectral Remote Sensing*) pode fornecer informações espectrais detalhadas de cada pixel de uma imagem. Enquanto HRS se refere principalmente ao sensoriamento remoto (à distância), a técnica IS (*Imaging Spectrometry*) cobre todos os domínios espaciais-espectrais, do microscópico ao macroscópico [6]. O objetivo do HRS é obter o espectro de cada pixel na imagem de uma cena, com o objetivo de localizar objetos, identificar materiais ou detectar processos. Além de adquirir o espectro eletromagnético usando a técnica IS, o HRS, como a tecnologia de sensoriamento remoto tradicional geral, também considera os processos de dados de imagem hiperespectral (incluindo processamento de imagem e extração e apresentação de informações úteis) e aplicações [7].

No HRS, a capacidade real de identificar materiais depende de vários fatores. Esses fatores incluem a abundância do material de interesse; a força das características de absorção para aquele material na região do comprimento de onda medida; e a cobertura espectral, re-

solução espectral e a relação sinal-ruído do sensor hiperespectral ou espectrômetro. Apesar desses fatores, e uma vez que o HRS foi desenvolvido para uma identificação aprimorada de materiais e determinação quantitativa de propriedades físicas e químicas em áreas de interesse, como minerais, água, vegetação, solos e materiais artificiais, a tecnologia HRS é bem aceita em sensoriamento remoto como ferramenta para muitas aplicações [8]. Algumas dessas aplicações incluem geologia, ecologia, geomorfologia, limnologia, pedologia e ciências atmosféricas – especialmente nos casos em que outros meios de sensoriamento remoto falharam ou são incapazes de obter informações adicionais [6].

Embora a tecnologia HRS tenha muitas vantagens sobre o sensoriamento remoto tradicional, ela apresenta desafios, como adquirir dados espectrais de alta qualidade em casos de HRS aerotransportados e espaciais não é como adquirir dados em um laboratório, onde as condições são constantes, ideais e bem controladas. É encontrada interferência significativa, como o curto tempo de permanência de aquisição de dados em um determinado pixel e, portanto, levando a uma relação sinal-ruído (SNR) mais baixa; atenuação atmosférica de gases (dispersões e absorções); e as condições de iluminação descontroladas da fonte e dos objetos [7]. Tais interferências podem resultar em dados HRS indesejáveis para fins de aplicação e apresentar desafios para muitas disciplinas, incluindo ciência atmosférica, engenharia eletro-óptica, aviação, ciência da computação, estatística, matemática aplicada e muito mais [9].

Ao contrário das imagens pancromáticas convencionais ou mesmo imagens multiespectrais, o conteúdo da informação em imagens hiperespectrais não se presta a ser facilmente visualizado e extraído por técnicas e algoritmos de processamento de imagem. Assim, no campo da pesquisa e aplicação de HRS deve ser dada atenção significativa ao desenvolvimento de técnicas para detectar, classificar, identificar, quantificar e caracterizar objetos e recursos de interesse [10].

O objetivo geral do desenvolvimento de HRS é extrair informações físicas de dados brutos de HRS em um espectro (radiância), semelhante ao que é coletado por um espectrômetro em um laboratório. Dadas as medições espectrais tomadas em condições de laboratório, as informações espectrais em todas as regiões espectrais podem ser analisadas quantitativamente para todos os materiais naturais e artificiais da Terra, como vegetação, água, gases, material artificial, solos, minerais e rochas, com muitos já disponíveis em bibliotecas espectrais [9]. Espera-se que se um sensor HRS ideal que pode resultar em dados espectrais de SNR altos for usado, uma técnica

análítica espectral possa ser incorporada para produzir novos produtos espectrais nunca antes detectados por meios de sensoriamento remoto tradicionais [6].

Neste seção serão contextualizados a evolução histórica das missões hiperespectrais, as missões nas quais, visando especificamente satélites de sensoriamento remoto à Terra, dando ênfase a missão PRISMA (*PRecursore IperSpettrale della Missione Applicativa*), missão que utilizada para o desenvolvimento das atividades, utilizando-se de técnicas de *Compressive Sensing* e índices de qualidade para observação da Costa Brasileira.

1.1 CONTEXTUALIZAÇÃO

Com o avanço da tecnologia, os registros dos eventos astronômicos foram se tornando recorrentes e crescentes a cada ano, e em parte, isso se deve a pesquisas no infravermelho óptico e próximo, no qual, foi possível graças ao desenvolvimento de matrizes de imagens digitais, como dispositivos de carga acoplada (CCDs). Essa tecnologia pode ter sido vista em seu ápice com o telescópio James Webb da NASA, que apesar de ser para observação de espaço profundo, é um observatório infravermelho orbitando o Sol a cerca de 1,6 milhões de quilômetros da Terra para encontrar as primeiras galáxias que se formaram no início do universo e para ver estrelas formando sistemas planetários [11].

Outro fenômeno que ocorreu foi o contínuo e crescente tamanho dos *arrays* digitais, impulsionado pelas demandas da pesquisa astronômica por quantidades cada vez maiores de dados em períodos de tempo cada vez mais curtos. Como resultado, a comunidade astronômica também é confrontada, com uma necessidade de técnicas de compressão de dados [5, 1].

Dentro desse contexto, muitas técnicas de compressão de dados astronômicos foram usadas ou desenvolvidas [12]. Dentre elas, técnicas que não necessariamente seguiam o Teorema da amostragem de *Shannon-Nyquist*, como em casos do satélite *Herschel*, que não conseguiu utilizar métodos convencionais de compressão, por limitação do seu equipamento [2, 5].

Uma técnica desenvolvida no ano de 2004 por Donoho, Candès, Romberg e Tao [3, 13, 14] para aquisição de sinais que são escassos ou compressíveis, de modo a esparsidade ser uma propriedade inerente desses sinais para os quais, toda a informação contida no sinal pode ser representada apenas com a ajuda de poucos componentes significativos, em comparação com o

comprimento total do sinal. Um sinal pode ter representação esparsa / compressível no domínio original ou em alguns domínios de transformação como transformada de *Fourier*, transformada de cosseno, transformada *wavelet*, etc [4]. Desta forma mesmo ainda sendo majoritariamente utilizada na área da engenharia biomédica, iniciou-se mesmo que de maneira tímida, a introdução do CS na área de compressão de dados astronômicos.

Imagens multiespectrais são intimamente ligadas às imagens astronômicas. O primeiro Sistema de Sensores Multiespectrais *Landsat* (MSS), lançado em 1972, com suas 4 bandas espectrais, cada uma com cerca de 100 nm de largura e 80 nm de tamanho de pixel, iniciou a era moderna do sensoriamento remoto terrestre a partir do espaço. Existem sistemas de satélites operacionais que amostram quase todas as partes do espectro eletromagnético disponíveis com dezenas de bandas espectrais, e com tamanhos de pixel variando de menos de 1 m a 1000 m, complementados por vários sistemas hiperespectrais aéreos com centenas de bandas espectrais, cada um no ordem de 10 nm de largura [15].

A primeira missão que embarcou um sensor hiperespectral à bordo de um satélite foi no programa *New Millenium* da NASA, no satélite *Earth Observation – 1* em 2000. O sensor era o *Hyperion*, que foi projetado como uma demonstração de tecnologia e forneceu dados hiperespectrais espaciais calibrados para avaliação de aplicações hiperespectrais, como em estudos de biogeoquímica [16].

Após anos de evolução, chegamos na atual tecnologia do PRISMA, visando qualificá-la, contribuindo para o desenvolvimento de aplicações e para fornecer produtos a usuários institucionais e científicos para observação ambiental, e gerenciamento de riscos [16], onde devido a sua cobertura espectral, foram desenvolvidos índices de qualidade para diferentes análises [17]. Desta forma, o desenvolvimento de técnicas de compressão e de análise de qualidade determinam atualmente o futuro da tecnologia hiperespectral. Devido a esta característica, o Governo Brasileiro com o Programa de Cooperação Acadêmica em Defesa Nacional – PROCAD – DEFESA, que constitui na ação que fomenta a cooperação entre instituições civis e militares para implementação de projetos voltados à formação de recursos humanos e à produção de pesquisas científicas e tecnológicas qualificados na área de Defesa [18] visa o uso das aplicações do PRISMA voltados para aplicações nacionais.

1.2 TRABALHOS DESENVOLVIDOS

Utilizando-se da técnica descrita, o CS, porém para o propósito de imagens de tomografia solar, o trabalho [19] apresenta o desenvolvimento de um algoritmo similar ao utilizado nesta dissertação, com o acréscimo de uma adaptação da mudança do domínio de Radon (imagens de tomografia são obtidas diretamente neste domínio) para o domínio de Fourier, através do Teorema de cortes de Fourier e o compara com o método mais clássico de reconstrução de tomografia, a Retroprojeção Filtrada e com um algoritmo ideal, considerando que o dado já é obtido no domínio de Fourier. Com esta pesquisa, foi possível definir a eficiência do algoritmo e suas limitações.

Com o trabalho [20], foi feita uma análise estatística com um banco de 31 imagens de tomografia solar, onde foi explorado as correlações, testes de normalidade e confiabilidade, para saber como o algoritmo se comportava com diferentes tipos de configurações de tomografia, onde houve a constatação que mesmo com um banco de imagens relativamente pequeno, a tendência era de distribuição normal e o comportamento da solução é estatisticamente uniforme, além de definir um número ótimo de projeções que se adequava as imagens.

Por último, o trabalho [21] realizou a análise estatística de performance do algoritmo, pois esta é sua principal desvantagem, onde com esta análise reforçou os resultados obtidos pelo artigo [20].

1.3 DEFINIÇÃO DO PROBLEMA CIENTÍFICO E PROPOSTA DE PESQUISA

A cor do oceano e a temperatura da superfície do mar são duas “variáveis essenciais do clima”, uma vez que, através da observação por satélites, se conseguem obter dados globais em escalas espaciais e temporais de alta resolução, permitindo deste modo o seu monitoramento ao longo de séries temporais. A cor do oceano permite medir a concentração de clorofila a, que representa o entendimento de ecossistemas marinhos e como estes respondem à variabilidade climática [22]. Além das questões ambientais, existe a necessidade da proteção e defesa, já que o Brasil possui umas das maiores faixas costeiras do mundo.

Por este motivo, a importância da observação e monitoramento via satélite deste vasto

território, tendo em vista que o objetivo do HRS é obter o espectro de cada pixel na imagem de uma cena, com o objetivo de localizar objetos, identificar materiais ou detectar processos, aprimorando a detecção de propriedades físicas e químicas.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

O objetivo deste trabalho é desenvolver um algoritmo que reconstrua imagens da costa brasileira oriundas de satélite hiperespectral, em alta qualidade, utilizando da técnica de *Compressive Sensing* e análise de índice de qualidade NDWI (*Normalized difference water index*).

1.4.2 Objetivos Específicos

Este trabalho visa modelagem da técnica de CS, considerando a imagem esparsa no domínio de Fourier:

- Reconstruir cada comprimento de onda necessário para se determinar índices de qualidade em corpos d'água;
- Desenvolver um algoritmo que implemente a modelagem das técnicas descritas;
- Implementar o algoritmo e reconstruir exemplos de casos reais; e
- Identificar o ponto ótimo de número de projeções para este tipo de imagem.

FUNDAMENTAÇÃO TEÓRICA E ESTADO DA ARTE

Nesta seção será detalhado todo o conteúdo matemático necessário para o desenvolvimento deste trabalho, a partir da transformada de Fourier e Haar, como o desenvolvimento da tecnologia de satélites hiperspectrais e a definição dos índices de qualidade desenvolvidos para este tipo de aplicação.

2.1 TRANSFORMADA DE *FOURIER*

O desenvolvimento da análise de Fourier tem uma longa história, envolvendo diferentes pessoas e a investigação de diversos fenômenos físicos. A utilização de “somadas trigonométricas” – ou seja, somas de senos e cossenos relacionados harmonicamente ou exponenciais complexas periódicas – para descrever fenômenos periódicos é datado pelo menos da época dos babilônios, que usavam ideias desse tipo para prever eventos astronômicos. A história moderna sobre o assunto começa em 1748, com L. Euler, que examinou o movimento de uma corda vibrante [23].

A transformada de Fourier é chamada de representação do domínio da frequência do sinal original. O termo transformada de Fourier, refere-se à ambas representações do domínio frequência e a operação matemática que associa a representação domínio frequência a uma função temporal. A transformada não é somente limitada a funções temporais, contudo para fins de convenção, o domínio original é comumente referido como domínio do tempo. Para muitas funções de interesse prático, pode-se definir uma operação de reversão: a transformada inversa de Fourier, também chamada de síntese de Fourier, de um domínio de frequência combina as contribuições de todas as frequências diferentes para a reconstituição de uma função temporal original [23, 24].

A transformada de tempo contínuo de Fourier e sua transformada inversa são apresentadas nas Eqs. 2.1 e 2.2 [25, 23]

$$\mathcal{F}\{f(t)\} = F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-\omega jt} dt, \quad (2.1)$$

$$\mathcal{F}^{-1}\{F(\omega)\} = f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega)e^{\omega jt} d\omega, \quad (2.2)$$

em que \mathcal{F} é chamado operador de transformação de Fourier. Uma condição suficiente para que $f(t)$ tenha uma transformação de Fourier é que $f(t)$ seja absolutamente integrável em $(-\infty, \infty)$, garantindo sua convergência. De fato, a integral converge uniformemente em relação a ω .

A transformada de tempo discreto de Fourier e sua transformada inversa são apresentadas nas Eqs. 2.3 e 2.4 [25, 23]

$$\mathcal{F}\{x[n]\} = X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x[n]e^{-j\omega n}, \quad (2.3)$$

$$\mathcal{F}^{-1}\{X(e^{j\omega})\} = x[n] = \frac{1}{2\pi} \int_{2\pi} X(e^{j\omega})e^{j\omega n} d\omega. \quad (2.4)$$

A transformada de Fourier de tempo discreto compartilha muitas semelhanças com o caso de tempo contínuo. As principais diferenças entre os dois casos são a periodicidade da transformação de tempo discreto $X(e^{j\omega})$ e o intervalo de integração finito na equação de síntese. Essas diferenças vêm de um fato que, exponenciais complexas de tempo discreto que se diferem em frequência por um múltiplo de 2π , são idênticas.

A Transformada clássica de Fourier inclui implicitamente uma hipótese sobre a estacionaridade dos sinais. Uma análise espectral adequada aos sinais não estacionários requer mais do que a transformada $Tf(u)$, e demanda a introdução de uma dependência no tempo e espaço na análise, visto que a mesma enfatiza somente uma ou a outra, se possível, preservando a linearidade, assim tornando necessário o desenvolvimento de outras transformadas [26].

2.1.1 Transformada de *wavelets*

Como descrito anteriormente, a transformada de Fourier considera que o sinal é estacionário, uma alternativa para abordar o problema no plano conjunto tempo-frequência consiste em permitir uma resolução variável no tempo. A partir dessa necessidade, a ideia da Transformada

de Fourier de Tempo curto STFT (ou Transformada de Gabor) é introduzir um parâmetro de frequência local (local no tempo) como se a Transformada de Fourier Local observasse o sinal através de uma curta “janela” dentro da qual o sinal permanece aproximadamente estacionário, assim a transformada local observa $f(t)$ “através” de uma janela $J(t)$ centrada no instante de tempo e de extensão “limitada”, antes do cálculo do espectro, como mostra a Eq. 2.5 [26]

$$STFT(\tau, \omega) = \int_{-\infty}^{\infty} f(t) J^*(\tau - t) e^{-j\omega t} dt. \quad (2.5)$$

Apesar das diversas escolhas para a janela, uma vez fixada a janela para a STFT, a resolução no tempo e na frequência f e t permanece constante em todo o plano $t - f$. Intuitivamente, quando a análise é visualizada como um banco de filtros, a resolução no tempo deveria aumentar com o aumento da frequência central dos filtros, ou seja, realizar a análise em banco de filtros compostos por passa-faixas com banda passante relativamente constante, assim a transformada contínua de *wavelets* origina uma análise com janelas flexíveis cuja largura e altura se adaptam às frequências. A ideia da transformada é também, como no caso da transformada de Fourier em tempo curto, calcular o produto interno de f com uma família de funções $\psi_{a,\tau}$ dependentes de dois parâmetros. Neste caso, no entanto, essas funções $\psi_{a,\tau}$ são obtidas de uma função básica ψ (chamada *wavelet*-mãe) por dilatações ou contrações – isto é, mudanças de escala – controladas pelo parâmetro a e translações, controladas pelo parâmetro τ como mostra a Eq. 2.6 [25, 27, 26]

$$\psi_{a,\tau} = |a|^{-\frac{1}{2}} \psi\left(\frac{t - \tau}{a}\right), \quad a, \tau \in \mathbb{R}, a \neq 0. \quad (2.6)$$

Definindo a transformada contínua de *wavelets* e a sua transformada inversa como a Eq. 2.7 e 2.8 [27]

$$\{\mathcal{W}_\psi f\}(a, \tau) = \langle f, \psi_{a,\tau} \rangle = |a|^{-\frac{1}{2}} \int_{-\infty}^{\infty} f(t) \overline{\psi\left(\frac{t - \tau}{a}\right)} dt, \quad (2.7)$$

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_0^{\infty} \{\mathcal{W}_\psi f\}(a, \tau) \psi_{a,\tau} \frac{da}{a^2} d\tau, \quad (2.8)$$

em que o $|a|^{-\frac{1}{2}}$ é introduzido para as diversas funções de mesma energia.

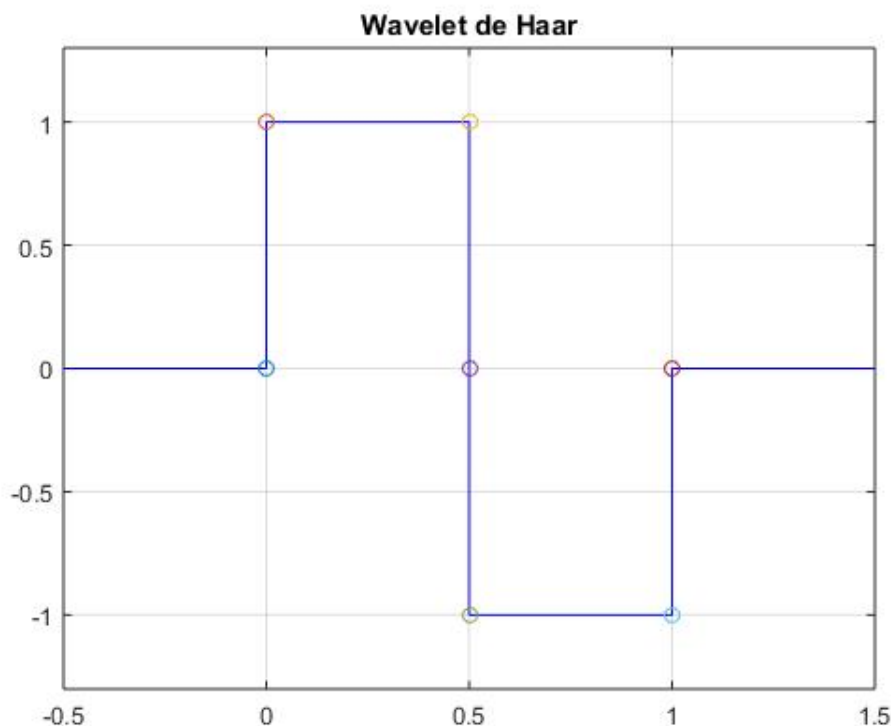
As propriedades da transformada contínua de *wavelets* dependem das propriedades da sua função original ψ , onde esta exige ser bem localizada no tempo e na frequência, devendo satisfazer a condição de admissibilidade C_ψ , como mostra a Eq. 2.9

$$C_\psi = \int_0^\infty \frac{|\hat{\psi}(\xi)|^2}{\xi} d\xi < \infty, \quad (2.9)$$

para tal, a função ψ deve ter uma condição de decaimento e portanto de certa forma, oscilar. Por esta característica, a transformada contínua é naturalmente redundante, exigindo que algoritmos eficientes tenham que restringir o parâmetro de escala a e a translação τ a valores discretos, ou seja, calcular $\sum_{j,k \in \mathbb{Z}} \{\mathcal{W}_\psi f\}(a, \tau)$ apenas em uma rede discreta do plano tempo-escala [25, 27].

Historicamente, a primeira base ortonormalizada construída é a bem conhecida base de Haar, introduzida muito antes do aparecimento do conceito de *wavelets*. Esta *wavelets* tem ótimas propriedades de localização no tempo, mas a sua localização na frequência é muito fraca, a Figura 2.1 apresenta um caso da transformada de Haar [27, 25, 28].

Figura 2.1. Transformada de Haar.



Fonte: Autoria própria.

Onde este sinal é definido pela Eq. 2.10

$$\psi(t) = \begin{cases} 1, & 0 \leq t < 0.5 \\ -1, & 0.5 \leq t < 1 \\ 0, & \text{para outros valores de } t \end{cases}. \quad (2.10)$$

A chamada base de Shannon é outro exemplo de uma *wavelets* ortogonal, sendo as suas propriedades de localização ao tempo-frequência como que complementares da base de Haar, como mostra a Eq. 2.11 [27, 25]

$$\psi(t) = \frac{1}{\pi t}(\sin(2\pi t) - \sin(\pi t)) = \frac{\sin\left(\frac{\pi t}{2}\right)}{\left(\frac{\pi t}{2}\right)}\cos\left(\frac{3\pi t}{2}\right). \quad (2.11)$$

2.2 COMPRESSIVE SENSING

A medida que a civilização moderna, ano após ano, aumenta cada vez mais a quantidade de dados adquiridos e explorados, têm-se a necessidade de uma melhor análise do que são os dados adquiríveis e os que “podem ser descartados” com quase nenhuma perda perceptual. O fenômeno da compressibilidade presente levanta questões muito naturais, como por que tanto esforço para adquirir todos os dados quando a maior parte do que obtemos será descartada e se não podemos apenas selecioná-las previamente [29]. Desta maneira, o CS foi desenvolvido para projetar protocolos de aquisição de dados compactados, que executam como se fosse possível adquirir diretamente apenas as informações importantes sobre os sinais / imagens – com efeito, não adquirindo a parte dos dados que acabaria sendo “descartada” por compressão com perda e reconstruir a partir de muito menos dados ou medidas do que normalmente é necessário [30, 29].

De um ponto de vista geral, a esparsidade e de forma mais genérica, a compressibilidade desempenha papel fundamental em muitos campos da ciência, e não seria diferente com o CS. Inicialmente, assumindo que o sinal de interesse seja vetor $x \in R^m$, onde x pode ser um sinal ou imagem com m amostras ou pixels, e que existe uma base ortonormal A . Assumindo também que o sinal é compressível [2, 29, 30], logo esta formulação possui o objetivo de reconstruir sinais com frequência de amostragem incompletas.

2.2.1 Amostragem de sinais

Ao se falar de processamento de sinais, de forma geral sob certas condições, um sinal de tempo contínuo pode ser completamente recuperado a partir de uma sequência de suas amostras que fornecem um meio (forma) para representar um sinal de tempo contínuo por um sinal de tempo discreto. Este procedimento é realizado, devido ao fato do processamento de sinais de tempo discreto ser mais flexível (como a resposta ao ruído) e normalmente preferível ao processamento de sinais de tempo contínuo [31].

A teoria de amostragem clássica, ou teorema de *Shannon-Nyquist*, considera que a frequência de amostragem ω_s , seja superior a maior que o dobro da frequência ω_m , do sinal x [31], como mostrado na Eq. 2.12

$$\omega_s > 2\omega_m. \quad (2.12)$$

Este critério mínimo muitas vezes não pode ser atendido, como quando se fala de satélites, devido à limitação de peso e equipamentos que ele pode comportar, e para que haja a garantia de reconstrução do sinal, tem-se a necessidade que mesmo com um número insuficiente de amostras, de acordo com o teorema de *Shannon-Nyquist*, também possa ser completamente recuperado [32].

Nas seções subsequentes, será apresentado a teoria na qual se embasa esse trabalho, para garantir a reconstrução das imagens astronômicas, mesmo não satisfazendo as condições de *Shannon-Nyquist*.

2.2.2 Teorema de minimização

Por ser um método para reconstrução de imagens, onde o número de amostras não é suficiente para se aplicar o critério necessário de *Shannon-Nyquist*, este é naturalmente um problema de sistema linear subdeterminado [33], onde é representado pela Eq. 2.13

$$b = Ax, \quad (2.13)$$

em que o sinal x é a imagem na sua forma empilhada de dimensões $n \times 1$, A é a matriz de medidas de dimensões $l \times n$, sendo $n \gg l$ e b é o vetor de medidas obtidas de dimensão $l \times 1$. Para que x , a incógnita do problema, seja obtida dado o vetor b . Em geral, este tipo de problema possui infinitas soluções. Das infinitas possibilidades, pode-se encontrar a solução de energia mínima [34], assim como na Eq. 2.14

$$x^* = \underset{x}{\operatorname{argmin}} \|x\|_2^2 \text{ sujeito a } Ax = b. \quad (2.14)$$

Para minimizar a função, pode-se utilizar a função de Lagrange, que é uma técnica de otimização convexa para encontrar pontos críticos em uma função de uma ou mais variáveis suscetíveis a uma ou mais restrições [35]. Desta maneira, o multiplicador de Lagrange da Eq. 2.14 é mostrado na Eq. 2.15

$$L(x, \lambda) = \frac{1}{2} \|x\|_2^2 + \lambda^H (Ax - b), \quad (2.15)$$

em que o λ é o vetor multiplicador de *Lagrange*, com as mesmas dimensões de b e λ^H sua hermitiana. Calculando o gradiente em relação a cada variável da função, temos que

$$\begin{cases} \nabla_x L(x, \lambda) = \frac{1}{2} x^H x + \lambda^H (Ax - b) \\ \nabla_\lambda L(x, \lambda) = Ax - b. \end{cases}$$

Igualando o sistema ao vetor nulo e isolando x , resolve-se o problema de reconstrução, como mostra na Eq. 2.16

$$x = A^H (AA^H)^{-1} b. \quad (2.16)$$

Porém, não necessariamente a solução de mínimos quadrados é a resposta que se procura para este problema, pois o sinal procurado geralmente é uma estrutura organizada e pela teoria da informação, o grau de desordem do sistema é ligado ao seu nível de energia [36]. Também se sabe da complexidade computacional que A apresenta, assim o que se busca é uma solução esparsa [34, 33, 30, 37].

2.2.3 Esparsidade

Diz-se que o sinal x é esparso em A se a maioria das entradas do vetor b é zero ou próximo de zero e, portanto, apenas algumas têm amplitudes significativas. Em outras palavras, o sinal pode ser eficientemente aproximado (com baixa erro de aproximação ou distorção), a partir de apenas alguns coeficientes significativos [2]. Considerando a transformação linear esparsificante da matriz \hat{T} , define-se uma nova variável \hat{x} , sendo esta esparsa, na Eq. 2.17

$$\hat{T}x = \hat{x}. \quad (2.17)$$

Por possuir esta característica, como provado em [34], a maior parte do conjunto de soluções da reconstrução de imagens utilizando a norma euclidiana não pertence ao conjunto da norma euclidiana. Desta maneira, para a solução exata do problema, é proposto a solução de otimização combinatorial, ou norma L_0 .

2.2.4 Solução de otimização combinatorial

A norma L_0 é uma solução de otimização convexa, no qual se proporciona a solução de maneira exata sistema subdeterminados, para os quais, exista uma solução suficientemente esparsa [37].

Assim como feito na seção 2.2.2, na equação 2.14, se propõe a calcular o argumento que minimiza a função, porém se utilizando da norma L_0 e a definição da Eq. 2.17. Assim, a reconstrução a ser feita inicialmente é descrita na Eq. 2.18

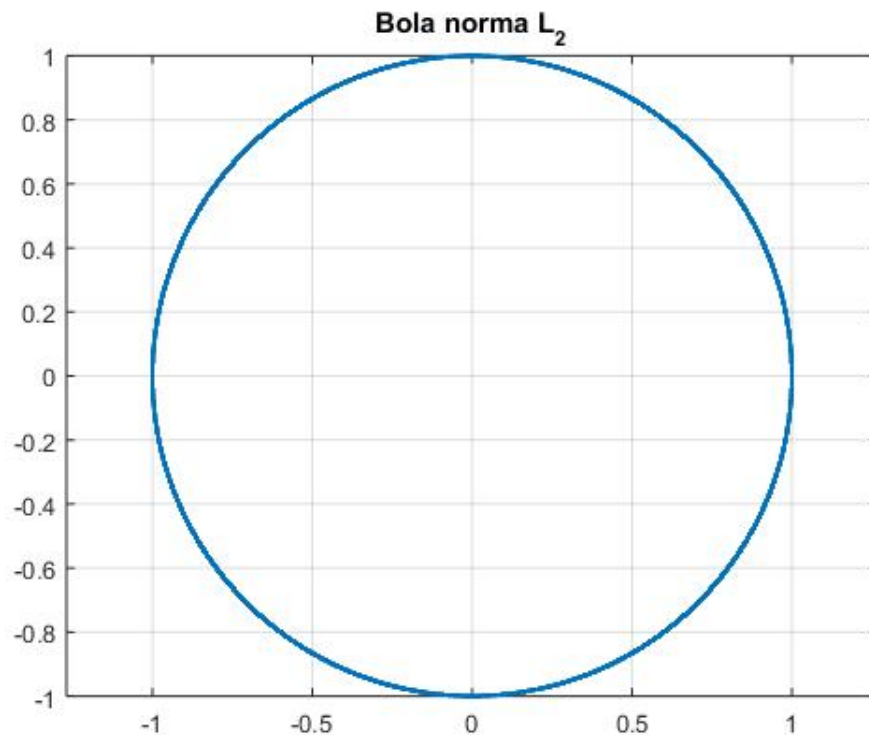
$$\hat{x}^* = \underset{\hat{x}}{\operatorname{argmin}} \|\hat{\mathbf{x}}\|_0 \quad \text{sujeito a } A\hat{T}^{-1}\hat{x} = b. \quad (2.18)$$

Em geral, utilizar a norma L_0 é impraticável, pois possui complexidade combinatorial. Sendo as normas L_p , entre $0 < p < 1$ e a norma L_1 , um “relaxamento” convexo da norma L_0 , são estas as utilizadas de maneira efetiva [37].

2.2.5 Propriedades das p-normas

Como dito na seção 2.2.2 e 2.2.3, a teoria de minimização é baseada na norma euclidiana, em que apresenta o conjunto de soluções desta norma, sua área de influência, ou bola, no qual cresce igualmente em todas as direções [38], como apresentado na Figura 2.2.

Figura 2.2. Comportamento da bola de influência na norma euclidiana.



Fonte: Autoria própria.

Por esta solução e a otimização combinatorial não serem soluções viáveis, foi-se necessário o estudo das p-normas, como descrito na seção 2.2.4.

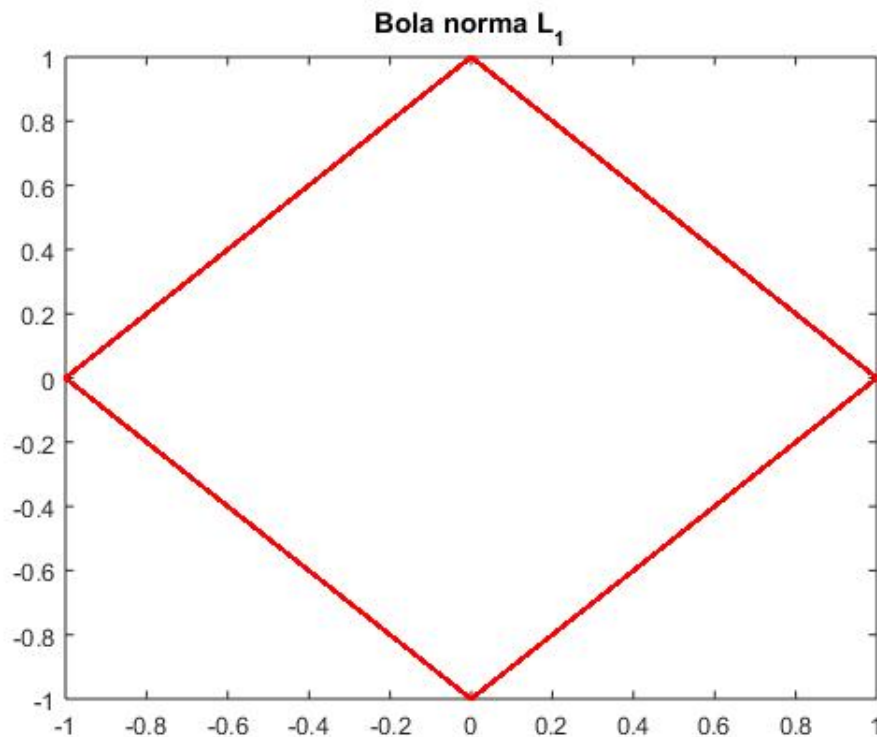
Os espaços funções da forma L_p têm um papel central em várias questões de análise. Esta importância se deve ao fato de eles serem uma generalização dos espaços L_2 [39, 40]. A definição da norma L_p é apresentado na Eq. 2.19, em que para as p-normas, p é definido entre $0 < p < 1$

$$\|x\|_p = \left(\sum_{k=1}^n |x_k|^p \right)^{\frac{1}{p}}. \quad (2.19)$$

Para valores de $p = 1$, obtêm-se a norma L_1 , ou norma de Manhattan e para $p = 2$ norma L_2 , ou norma euclidiana [38].

A área de influência ou bola da norma L_1 , o raio de crescimento r da bola é determinado por $|x - a| < r$, em que a é o centro da bola [38], assim como mostrado na Figura 2.3.

Figura 2.3. Comportamento da bola de influência na norma L_1 .

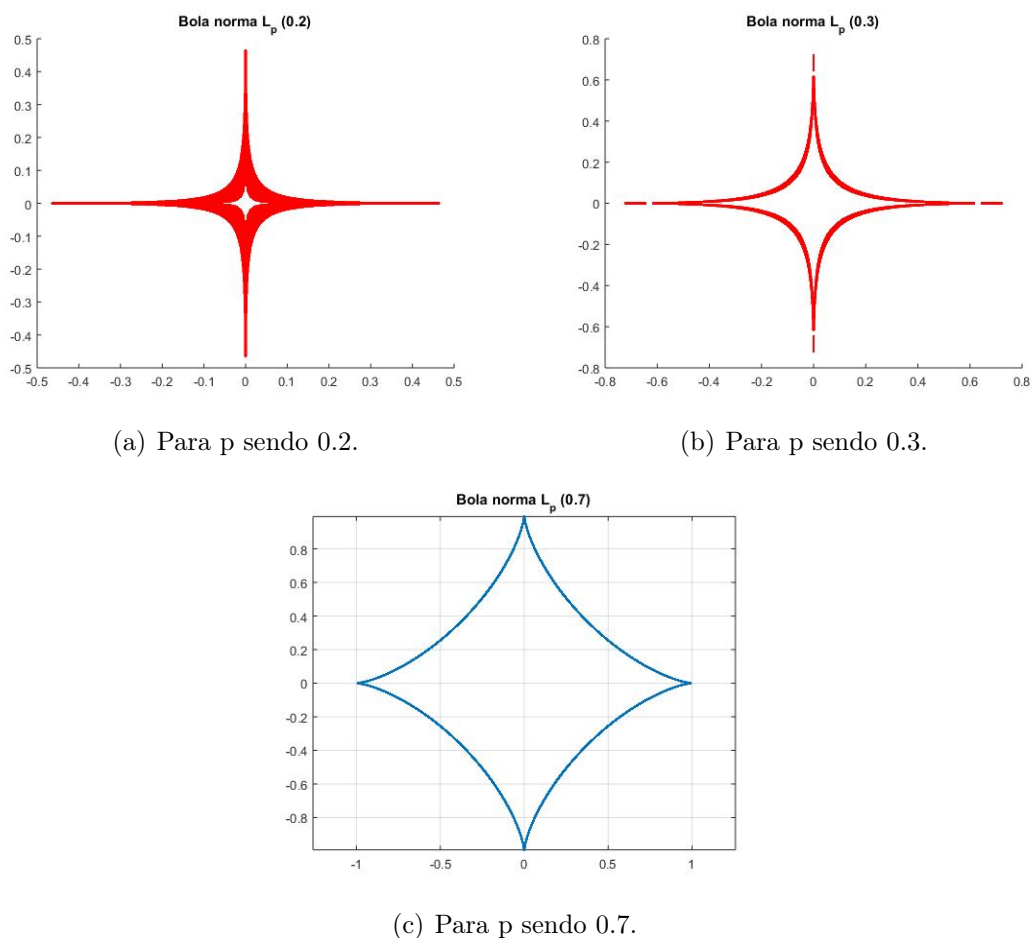


Fonte: Autoria própria.

Por ser a norma L_p do tipo côncava, apesar de aumentar a complexidade de solução ela garante a unicidade de solução do sistema [40], porém a norma L_1 é menos suscetível a influência de ruído, também sendo bastante utilizada para a reconstrução neste tipo de problema.

Sendo as normas L_p , um “relaxamento” convexo da norma L_0 [37], a sua área de influência ou bola da norma é apresentação na Figura 2.4.

Figura 2.4. A bola L_p para diferentes valores de p .



Fonte: Autoria própria.

Assim como visto na Figura 2.4, quanto menor o valor de p , mais ele se aproxima da norma L_0 , aumentando sua complexidade de resolução, porém melhorando-a.

2.2.6 Proposta de solução

Utilizar as p -normas e a norma de *Manhattan* aplicadas a Eq. 2.18, a reconstrução é apresentada na Eq. 2.20 e Eq. 2.21

$$\hat{x}^* = \underset{\hat{x}}{\operatorname{argmin}} \|\hat{\mathbf{x}}\|_1 \quad \text{sujeito a } A\hat{T}^{-1}\hat{x} = b, \quad (2.20)$$

$$\hat{x}^* = \underset{\hat{x}}{\operatorname{argmin}} \|\hat{\mathbf{x}}\|_p^p \quad \text{sujeito a } A\hat{T}^{-1}\hat{x} = b. \quad (2.21)$$

Podendo esta condição de sujeição ser alterada (no caso da Eq. 2.20) para uma condição de inequação em relação à um erro [41].

2.3 MISSÕES DE SATÉLITES HIPERESPECTRAIS

Devido ao grande volume de dados que devem ser armazenados em uma missão hiperespectral, o seu desenvolvimento foi lento em relação ao multiespectral. Assim, o começo das primeiras missões de sensoriamento remoto por satélite hiperespectral foram restritos a testes de sistemas hiperespectrais sem imagens, seguido pelo desenvolvimento de protótipos de sistemas hiperespectrais aerotransportados. Estes sistemas eram etapas necessárias devido ao fator limitante de armazenamento de dados e a capacidade de telemetria. Sobre a época dos primeiros sistemas aerotransportados, os primeiros sistemas de software, como *Spectral Analysis Manager* (SPAM) do Laboratório de Propulsão a Jato (JPL), foram desenvolvidos para lidar com as grandes quantidades de dados utilizando algoritmos pioneiros de extração de informações [42].

Um dos primeiros sistemas de sensoriamento remoto hiperespectral sem imagem é o sistema búlgaro SMP-32 [43]. O sistema foi lançado a bordo do satélite *Meteor-Priroda* “Bulgária-1300-II” em 7 de agosto de 1981. O instrumento tem 32 bandas espectrais ($\lambda = 457 \sim 888 \text{ nm}$ e resolução espectral de 14 nm) e 280 m de Amostragem de Distância do Solo (GSD). Os dados coletados são armazenados em dois gravadores, cada um com capacidade de 60 megabit. O transmissor principal com 10 W na banda de 130 MHz. O sistema espectrométrico foi desenvolvido no *Space Research and Technology Institute* na Academia de Ciências da Bulgária (SRTI-BAS) e como seus antecessores (*Spektar - 15*, possui 15 bandas espectrais na estação espacial Salut-6, é um espectrômetro sem imagem [43, 42]. O princípio de aquisição é de um detector *whiskbroom nadir-looking* mas sem um mecanismo de varredura para reconstruir uma imagem.

Durante os anos 1980, com base na experiência adquirida a partir do desenvolvimento do SMP-32, o espectrômetro *Spektar-256* foi desenvolvido por SRTI-BAS e o *Institute of Technical Cybernetics and Robotics* no BAS. O espectrômetro estava coletando os espectros em dois modos: 1) 128 bandas e 2) 256 bandas, na faixa espectral ($\lambda = 480 \sim 810 \text{ nm}$). Foi usado ativamente a bordo da estação espacial MIR por mais de 12 anos [42]. Os experimentos a bordo

do MIR foram realizados usando em conjunto uma câmera fotográfica topográfica *KATE-140* com o *Spektar-256*. A câmera foi usada para identificar o tipo de cobertura vegetal. Alguns dos experimentos científicos realizados foram: oceano, contraste, poluição, cor e Percepção de Cor.

Já na era satelital, com os dados e a experiência nos sistemas aerotransportados, a NASA e o JPL desenvolveram o *Airborne Visible / InfraRed Imaging Spectrometer* (AVIRIS) (224 bandas espectrais, $\lambda = 0,4 \sim 2,45 \mu m$, resolução espectral de $10 nm$, SR $11 m$ para uma cena de $11 km \times 11 km$). O instrumento foi testado em 1987 e começou as operações em 1989 [44].

No início da década de 90, a NASA e TRW corporation co-desenvolveram o sistema *HyperSpectral Imager* (HSI) para a missão LEWIS, que foi projetada para filmar em 128 bandas em uma faixa espectral $\lambda = 0,4 \sim 1 \mu m$ e outras 256 bandas em $\lambda = 0,9 \sim 2,5 \mu m$, no total 384 bandas, como mostra na Figura 2.5. A resolução espectral em ambas as faixas espectrais foram, respectivamente, $5 nm$ e $6,5 nm$. Três dias após o lançamento, em 23 de agosto de 1997, o controle do satélite foi perdido e posteriormente entrou na atmosfera terrestre em Setembro de 1997 [45].

Figura 2.5. *HyperSpectral Imager*.




Fonte: 7, 42.

Outro espectrômetro de imagem desenvolvido pelo Laboratório de Pesquisa da Força Aérea dos EUA, o *Fourier Transform Hyperspectral Imager* (FTHSI) do satélite MightySat II (Sindri P99-1), como mostra a Figura 2.6. O instrumento foi projetado com 256 bandas operando na faixa $\lambda = 0,35 \sim 1,05 \mu m$. O satélite foi lançado em 19 de julho de 2000 da VAFB e reentrou na atmosfera terrestre em 12 de novembro de 2002 com 100% sucesso da missão [46].

Figura 2.6. Satélite MightySat II.

Fonte: 46.

Outra missão de observação da Terra hiperespectral, que também foi malsucedido e desenvolvida pela Força Aérea dos EUA, foi o *Naval Earth Map Observer* (NEMO), como mostra a Figura 2.7. Ao contrário de outros sensores satelitais hiperespectral existentes, como EO-1/Hyperion e CHRIS/PROBA, o NEMO tinha uma dupla finalidade militar e civil. Ele foi projetado para transportar a bordo *Coastal Ocean Imaging Spectroradiometer* (COIS) instrumento que foi projetado para adquirir imagens na faixa espectral $\lambda = 400 \sim 2500 \text{ nm}$ com uma resolução espectral de 10 nm . A largura projetada da cena era de 30 km , com um tamanho de pixel de $60 \text{ m} \times 30 \text{ m}$. Apresentava também um alto SNR em comparação com os sistemas semelhantes anteriores, como o *High Resolution Imaging Spectrometer* (HIRIS). O NEMO era planejado para lançamento em 2000, mas o programa foi colocado em espera e posteriormente cancelado [47].

Figura 2.7. Visão artística da missão NEMO.

Fonte: 47.

Somente após o surgimento das novas plataformas de satélite desenvolvidas no âmbito do *New Millennium Program* (NMP) da NASA, como *Earth Observer-1* (NMP / EO-1), com o

espectrômetro *Hyperion* a bordo, e *Project for OnBoard Authonomy* (PROBA), com o instrumento hiperespectral *Compact High Resolution Imaging Spectrometer* (CHRIS), desenvolvido pela Agência Espacial Europeia (ESA), lançado em 1999 e 2001, respectivamente, o satélite de espectrometria de imagem para aplicações civis e científicas tornou-se possível [7].


A missão NMP/EO-1 carrega três radiômetros a bordo: 1) O *Advanced Land Imager* (ALI) - um radiômetro multiespectral pushbroom com 1 banda pancromática e 9 multiespectrais; 2) o Hyperion, como mostra a Figura 2.8; e 3) o *Linear Etalon Imaging Spectrometer Array* (LEISA) - *Atmospheric Corrector* (LAC) . O EO-1/Hyperion é um espectrômetro de imagem com grade com 30 m de amostragem de distância do solo (GSD) e largura de faixa de 7,7 km . Ele fornece 10 nm (intervalo de amostragem) bandas contíguas do espectro solar refletido $\lambda = 400 \sim 2500 \text{ nm}$. O LAC é um espectrômetro de imagem operando na faixa espectral $\lambda = 900 \sim 1600 \text{ nm}$, que foi adequado para a equipe de validação de ciência EO-1 monitorar as linhas de absorção de água atmosférica para correção dos efeitos atmosféricos em imageadores multiespectrais durante o primeiro ano da missão [42].

Figura 2.8. the Hyperion – um espectrorradiômetro de imagem.



Fonte: 42.

O objetivo principal do espectrômetro de imagem CHRIS/PROB é a coleta de dados da *Bidirectional Reflectance Distribution Function* (BRDF) para uma melhor compreensão da refletância espectral, como mostra a Figura 2.9 [17].

Figura 2.9. Imagem hiperespectral EO-1/Hyperion.

Fonte: 17.


A missão PROBA levou a bordo também uma câmera pancromática alta resolução (HRC), um telescópio miniaturizado do tipo *Cassegrain* com um tamanho de abertura de 115 mm e um focal de 2296 mm , que adquire imagens com uma área de 25 km^2 com $5/8\text{ m}$ de GSD. O CHRIS voou a bordo do satélite PROBA-1, em 2001, com 18 bandas espectrais nos modos de aquisição 2, 3 e 4 e 37 bandas espectrais no Modo 5 na faixa VNIR ($\lambda = 415 \sim 1050\text{ nm}$) com um GSD de 17 m . O instrumento pode ser programado para 63 bandas espectrais (CHRIS é totalmente programável para até 150 bandas) em um GSD de cerca de 34 m no Modo 1 [17]. A missão está agora em extensão modo e ofertas apenas para usuários registrados.

No final de 1980 dentro do Programa *Earth Observing System* (EOS) da NASA foram planejados dois instrumentos hiperespectrais, o *High Resolution Imaging Spectrometer* (HIRIS) e o *Moderate Resolution Imaging Spectrometer-Nadir* (MODIS-N). O HIRIS foi projetado para capturar 192 bandas com uma resolução espectral de $\lambda = 9,4 \sim 11,7\text{ nm}$ (nominal 10 nm) em diferentes áreas do espectro eletromagnético na faixa $\lambda = 0,4 \sim 2,5\ \mu\text{m}$ [48]. A largura da faixa foi de 30 km e uma área de visão de 25 off track e $+60/-30\text{ de track}$ [49]. Ao comparar o HIRIS com a missão bem - sucedida EO-1/Hyperion, pode ser facilmente visto que EO-1/Hyperion possui algumas das características deste instrumento.

Dentro do programa EOS, que desenvolveu de diversos satélites e após 15 anos de trabalho, o instrumento MODIS foi lançado a bordo do satélite EOS-AM1, como mostra a Figura 2.10. Começou a operar em Fevereiro de 2000. A largura da faixa MODIS é igual a 2300 km , com

aquisição quase diariamente, operando em 36 bandas na faixa espectral $\lambda = 0,4 \sim 14,4 \mu m$ [50].

Figura 2.10. Satélite EOS-AM1.



Fonte: 42.

Outras missões também foram realizadas como a missão alemã *Environmental Mapping and Analysis Program* (EnMap), projetada para registrar dados biofísicos, bioquímicos e geoquímicos em uma base global de variáveis e, para aumentar a compreensão de processos da biosfera/geosfera garantindo a sustentabilidade de nossos recursos e uma das mais recentes a missão italiana PRISMA, mais detalhada a seguir, desenvolvida pela Agência Espacial Italiana (ASI), lançado em 2019 na Guiana Francesa [42, 51].

2.3.1 Missão PRISMA

Como descrito em [52, 51], o PRISMA é uma missão de imagens hiperespectrais de média resolução da Agência Espacial Italiana (ASI) em desenvolvimento desde 2008. É um projeto de continuação do HypSEO (*Hyperspectral Satellite for Earth Observation*) cuja fase B foi concluída em 2002 e depois descontinuada. - O projeto PRISMA é concebido como uma missão pré-operacional e demonstradora de tecnologia, focada no desenvolvimento, entrega de produtos hiperespectrais e na qualificação da carga hiperespectral no espaço.

O PRISMA se concentrará nas necessidades das entidades institucionais e de pesquisa italianas. Os objetivos da missão são:

- desenvolver uma pequena missão satelital inteiramente na Itália para monitorar os recursos naturais e as características atmosféricas (informações sobre a cobertura do solo e

estado das culturas, qualidade da poluição das águas interiores, estado das zonas costeiras e do Mar Mediterrâneo, mistura de solos e ciclo do carbono), tomando vantagem dos desenvolvimentos anteriores realizados pela ASI;

- fornecer os produtos de dados padrão com curtos períodos de atraso após o recebimento à comunidade científica para abordar as várias aplicações selecionadas, como aquelas relacionadas à qualidade e proteção do meio ambiente, desenvolvimento sustentável, mudança climática, etc;
- para demonstrar novas tecnologias em órbita.

O objetivo geral é fornecer uma capacidade de observação global - as áreas de interesse específicas a serem abrangidas são a Europa e a região do Mediterrâneo.

2.3.2 Veículo espacial

O sistema é baseado em um ônibus minissatélite e está sendo desenvolvido na Carlo Gavazzi Space SpA (CGS) de Milão, Itália, como mostra a Figura 2.11. A plataforma PRISMA representa uma evolução significativa da plataforma MITA/AGILE desenvolvida como plataforma italiana padrão de pequenos satélites (lançamento do AGILE em 23 de abril de 2007). As principais melhorias do PRISMA são:

- Sistema de controle de atitude aprimorado com agilidade de apontamento. Uma capacidade de apontar o corpo da nave espacial de $\pm 14,7^\circ$ (fora do nadir) é fornecida em trajetória cruzada;
- Subsistema de propulsão para controle de órbita e disposição final.


Os principais recursos de desempenho são:

- Determinação de atitude: $0,015^\circ$ com estabilização de 3 eixos;
- Precisão de apontamento: $0,07^\circ$ em todos os 3 eixos;
- Determinação da órbita: 20 m (onboard), com geolocalização da imagem: 168 m.

Tabela 2.1. Principais características do PDHT

Taxa de entrada de dados do instrumento imageador	até 600 Mbit/s
Memória disponível EOL (End of Life)	256 Gbit de capacidade de armazenamento após 3 anos
Criptografia de dados	Sim
Taxa de dados de Downlink	155 Mbit/s
Massa do PDHT	42 kg
Confiabilidade do PDHT	>0,96

Fonte: 52.

Figura 2.11. Ilustração do layout da nave espacial PRISMA.

Fonte: 52.

Com uma órbita circular sincronizada com o Sol, altitude de 614 *km*, inclinação de 98,19°, período de ~ 99 *min*, ciclo de repetição da órbita de 29 dias e capacidade de relook de 7 dias com manobra de rotação e LTDN (hora local da travessia do equador no nó descendente) igual a 10:30 horas.


Comunicações RF: A banda S é usada para comunicações TT&C. A banda X é usada para o downlink dos dados da carga útil. O subsistema PDHT (*Payload Data Handling & Transmission*), de herança do COSMO-SkyMed, é dedicado ao processamento dos dados de carga para o downlink da banda X.

A Tabela 2.1 mostra as principais características do PDHT.

2.3.3 Sensores complementares

O PRISMA (o nome da missão e do sensor são idênticos), como mostra a Figura 2.12, é um instrumento hiperspectral avançado que inclui uma câmera pancromática de resolução média. SG (Selex Galileo) de Campi Bisenzio, Itália, é o contratante principal para o projeto e desenvolvimento do instrumento PRISMA. O projeto é baseado em um conceito de observação do tipo vassoura, fornecendo imagens hiperspectrais (~ 250 bandas) com uma resolução espacial de 30 m em uma faixa de 30 km . A resolução espectral é melhor do que 12 nm em uma faixa espectral de $\lambda = 400 \sim 2500\text{ nm}$ (regiões VNIR e SWIR). Em paralelo, imagens Pan (pancromáticas) são fornecidas com uma resolução espacial de 5 m ; os dados Pan são co-registrados com os dados Hyp (hiperspectral) para permitir o teste de técnicas de fusão de imagem.

Figura 2.12. Ilustração da cabeça óptica Hyp / Pan do instrumento PRISMA

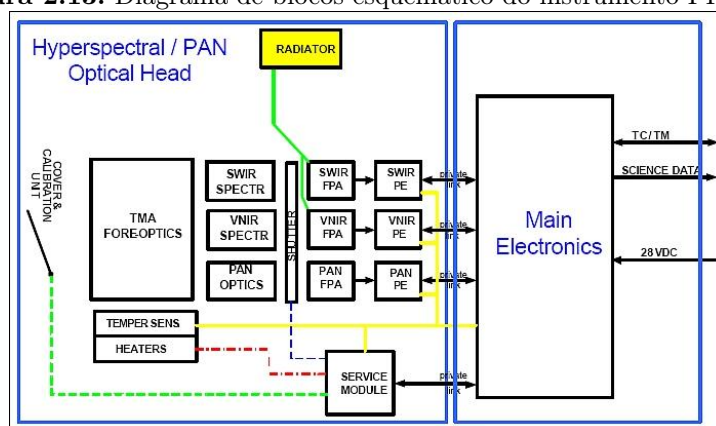


Fonte: 52.

O instrumento PRISMA é baseado no conceito de espectrômetro de prisma e é composto pelas unidades: Hyp/Pan, cabeça óptica e caixa eletrônica principal. A separação física das unidades fornece uma melhor distribuição de massa na espaçonave. O telescópio comum do Hyp/Pan e das unidades ópticas principais coletam a radiação de entrada de ambos os canais, que é dispersa por dois espectrômetros; os fótons são convertidos em elétrons por detectores adequados, então os sinais elétricos são amplificados e convertidos em um fluxo de dados digital.

Na Tabela 2.2, mostra os parâmetros dos instrumentos do PRISMA.

Figura 2.13. Diagrama de blocos esquemático do instrumento PRISMA.



Fonte: 52.

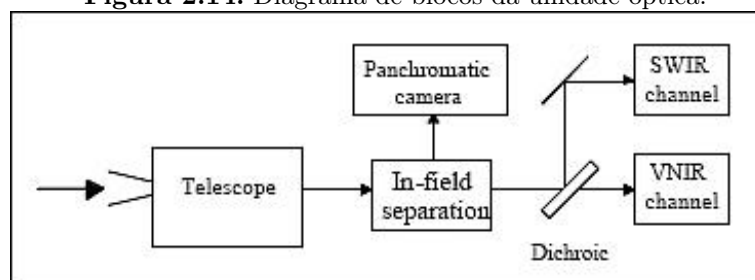
Tabela 2.2. Visão geral dos parâmetros do instrumento PRISMA

Parâmetros	canal VNIR	canal SWIR	canal Pan
Faixa espectral	400-1010 nm	920-2505 nm	400-700 nm
Resolução espectral (FWHM)	$\leq 12 \text{ nm}$	$\leq 12 \text{ nm}$	-
Bandas espectrais	66	171	1
SNR	>200 na faixa de $0,4 - 1,0 \mu\text{m}$ $600 @ 0,65 \mu\text{m}$	>200 na faixa de $1,0 - 1,75 \mu\text{m}$ $>400 @ 1,55 \mu\text{m}$ >100 na faixa de $1,95 - 2,35 \mu\text{m}$ $>200 @ 2,1 \mu\text{m}$	240
MTF (função de transferência de modulação)	$>0,8 @ \text{Nyquist}$	$>0,7 @ \text{Nyquist}$	$>0,2 @ \text{Nyquist}$
Largura da faixa		30 km ($FOV = 2,77^\circ$)	
Resolução espacial		30 m	5 m
Pixels detectores espaciais		1000 x 256 com $30 \mu\text{m}$ pitch	6000
Ifov		$48,34 \mu\text{rad}$	
Tipo de Telescópio		TMA (Three Mirror Anastigmat)	
Abertura do telescópio		210 mm de diâmetro	
Comprimento focal efetivo do telescópio		620 mm	
Quantização de dados		12 bit	
Frame rate		230 Hz	
Massa e dimensões da caixa eletrônica		$\sim 400\text{mm} \times 300\text{mm} \times 250\text{mm}, < 8\text{kg}$	
Dimensões do instrumento		$770 \text{ mm (L)} \times 590 \text{ mm (W)} \times 780 \text{ mm (H)}$	
Massa do instrumento		$< 90 \text{ kg}$	
Potência do instrumento		$< 110 \text{ W (média)}, < 50 \text{ W (standby)}$	
Sistema de resfriamento		Radiador passivo	
FOR (<i>Field of Regard</i>)		$\pm 15^\circ$ (body pointing capability of the S/C to direct observations in cross-track)	

Fonte: 52.

A caixa eletrônica tem a função de controlar o instrumento e lidar com o fluxo de bits da imagem de acordo com os protocolos acordados. O resfriamento do conjunto de detectores SWIR é fornecido por meio de um radiador passivo voltado para o espaço frio, o seu esquemático é mostrado na Figura 2.13.

O sistema óptico consiste em um telescópio comum, um espectrômetro de banda dupla, operando nas bandas VNIR e SWIR, e uma câmera pancromática. A configuração do telescópio

Figura 2.14. Diagrama de blocos da unidade óptica.**Fonte:** 52.

consiste em uma implementação TMA (Three Mirror Anastigmat) para garantir excelente qualidade óptica com um número mínimo de elementos ópticos. O telescópio possui três espelhos esféricos com uma abertura de entrada de 210 mm e uma distância focal efetiva de 695 mm . A escolha do diâmetro da pupila de entrada permite que o sistema atenda ao alto SNR exigido com uma seleção de $f/\text{número}$ para obter um alto desempenho geométrico em termos de *smile effect*, efeito *keystone* e co-registro. O telescópio tem um MTF limitado por difração e uma energia dentro de $30 \times 30\ \mu\text{m}$ de um pixel de referência de 80%. A Figura 2.14 mostra o diagrama deste sistema.


Os efeitos de luz difusa e imagem fantasma no telescópio estão sendo controlados por:

- defletor interno que impede a luz de atingir a fenda fora do caminho nominal;
- escurecimento convencional da maioria das superfícies da estrutura interna.

Um defletor externo é implementado para contribuir para a redução das entradas radiantes térmicas para a óptica do telescópio. Uma fenda comum aos espectrômetros VNIR e SWIR (FOVs idênticos) é colocada no plano focal do telescópio. A separação entre o caminho óptico VNIR e SWIR é realizada com um DBS (*Dichroic Beam Splitter*) para melhorar o requisito de co-registro, como mostra a Figura 2.15.

O design mecânico do instrumento faz uso das seguintes diretrizes/drivers de design:

- os três canais ópticos (VNIR, SWIR, Pan) devem ser espaçados o máximo possível e localizados no lado do instrumento voltado para o espaço frio;
- a eletrônica de proximidade deve ser mantida perto dos FPAs (Conjunto de plano focal) para minimizar os comprimentos dos cabos flexíveis;

Figura 2.15. Vista esquemática da configuração do telescópio.

Fonte: 52.

- as massas mais relevantes devem estar localizadas o mais próximo possível da interface mecânica entre o instrumento e o barramento;
- a porta de entrada do instrumento deve ser fechada para evitar contaminação da óptica interna.

A bancada ótica que suporta a ótica e os FPAs é realizada em liga de alumínio para reduzir a massa do instrumento.


O resfriamento do detector SWIR é realizado usando um radiador voltado para o espaço frio. O design térmico do instrumento é baseado em uma arquitetura com as seguintes características:

- o detector SWIR é resfriado a uma faixa de temperatura de $160 - 180\text{ K}$;
- a temperatura do detector VNIR é mantida na faixa de $240 - 250\text{ K}$;
- os fluxos de calor das partes eletrônicas quentes para as zonas frias do instrumento são reduzidos ao mínimo;
- os componentes ópticos, contidos em uma bancada ótica isolada, são confinados a uma faixa de temperatura relativamente estreita de $2 - 4^\circ\text{ C}$ por controles térmicos dedicados para fornecer uma boa estabilidade termo-mecânica;

- parte específica do espectrômetro, como o FPA e seu escudo frio, são posicionados próximos ao radiador para permitir uma boa eficiência do sistema passivo;
- os subsistemas ópticos devem ser mantidos isolados termicamente da estrutura de suporte, em particular das partes da faixa de temperatura mais fria.

O design do espectrômetro implementa uma solução de prisma e um conceito patenteado de Selex Galileo, como mostra a Figura 2.16. O uso de prismas refrativos, otimizados para cada banda, permite uma eficiência muito maior e menor sensibilidade de polarização do que as implementações de grade. Desta forma, é possível obter o SNR necessário com um diâmetro de entrada do telescópio relativamente pequeno, oferecendo uma vantagem no tamanho e na massa do instrumento.

Figura 2.16. Layout óptico dos espectrômetros VNIR e SWIR.



Fonte: 52.


A radiação espectral geral do instrumento (400-2505 nm) é dividida em dois canais (VNIR e SWIR), adotando duas matrizes de plano focal diferentes. O VNIR cobre a faixa ($\lambda = 400 \sim 1010 \text{ nm}$) com 66 bandas espectrais, enquanto a faixa do canal SWIR é ($\lambda = 920 \sim 2505 \text{ nm}$) com 171 bandas. Devido ao design óptico adotado, a dispersão espectral não é constante com

o comprimento de onda.

A dispersão espectral é obtida por prismas colocados em feixes paralelos, projetados para alcançar a alta qualidade ótica exigida em termos de PSF (*Point Spread Function*), *smile effect* e *keystone*. Estes efeitos do espectrômetro são bem corrigidos. Os erros estão contidos em 10% do pixel, para os arranjos de plano do detector VNIR e SWIR. O design óptico fornece uma transparência para alcançar o SNR necessário para um cenário típico de 30% de refletância a 30° SZA (*Sun Zenith Angle*) para o verão de latitude média.

O canal Pan é obtido pela separação do feixe principal proveniente do telescópio TMA por uma técnica de separação em campo complementada por uma segunda fenda paralela à dos espectrômetros. A imagem Pan é obtida usando um relé óptico de três espelhos que é limitado por difração para $\lambda > 400 \text{ nm}$, como mostra a Figura 2.17.

Figura 2.17. Layout óptico da câmera Pan.



Fonte: 52.

O efeito de separação de campos é um deslocamento constante (em termos de geolocalização) entre as imagens hiperespectrais e pancromáticas, que é levado em consideração pelos algoritmos de processamento de imagens, ao co-registrar as imagens hiperespectrais e pancromáticas. A distância entre os dois campos será mantida mínima, levando em consideração:

- acomodação mecânica, que deve limitar a distância física mínima viável no plano focal;

- co-registro temporal das imagens Hyp/Pan, ou seja, ter dois campos significa adquirir imagens Hyp e Pan da mesma zona em momentos diferentes.


O layout selecionado da unidade pancromática é uma configuração *Offner* (1,3x) modificada com uma objetiva corretora. Um espelho dobrável é colocado antes do plano de imagem do TMA para dobrar a trajetória ótica dos raios em direção a um espaço disponível e não utilizado da bancada ótica.

O layout óptico do canal Pan é composto por três espelhos esféricos, dois deles descentrados, dois espelhos dobráveis e três lentes em sílica fundida. Os espelhos do telescópio TMA e do relé Pan são em vidro *Schott Zerodur*, esvaziando as superfícies traseiras para reduzir a massa em até 50%.

O detector Pan é uma matriz linear com 6000 pixels e um pitch de $6,5 \mu m$.

O eixo óptico do dispositivo Pan é ligeiramente inclinado em relação ao do espectrômetro; a separação fora do eixo entre o espectrômetro e o dispositivo Pan é de cerca de $2,84 mm$, o que produz uma separação de campo no solo de $< 3 km$. Esta é a distância ideal compatível com as restrições mecânicas e de fabricação para reduzir ao mínimo a separação de campo no solo, a Figura 2.18, mostra esta arquitetura.

Figura 2.18. Visão interna da arquitetura PRISMA.



Fonte: 52.

O dispositivo Pan é otimizado em toda a faixa espectral visível ($0,4 - 0,7 \mu m$). A frequência


de Nyquist é 77 cy/mm ($6,5 \mu\text{m}$ é o tamanho do pixel); a qualidade óptica do dispositivo Pan é excelente em toda a faixa espectral.

2.3.4 Calibragem do instrumento

A ICU (Unidade de Calibração Interna) é projetada para permitir o suporte de calibrações radiométricas absolutas, relativas e espectrais. A ICU utiliza um caminho óptico muito compacto, capaz de captar a imagem da luz solar por meio de uma porta de entrada solar dedicada por meio de um difusor interno, visto durante a atividade de calibração pelo espelho primário do telescópio TMA. A unidade de calibração consiste em um mecanismo de cobertura da porta solar, filtros e lâmpadas espectrais. A calibração do escuro é implementada por meio de um obturador leve colocado na frente da fenda óptica.

A radiância espectral de entrada ICU para calibração é gerada pelo Sol (modo ICU-S) ou por Fontes Internas (modo ICU-IS), através de um caminho óptico dedicado, como mostra a Figura 2.19. O objetivo da UTI é a iluminação de toda a pupila do instrumento e FOV pela radiação de referência que passa pelo mesmo caminho óptico do sinal observado na Terra: na verdade, um caminho óptico dedicado de calibração (tanto para o sol quanto para as fontes internas) é realizado para colidir com a superfície posterior da tampa da porta principal. Este é dotado de um difusor metálico, que permite uma iluminação estacionária diretamente no espelho primário do telescópio, preenchendo toda a pupila de entrada do telescópio.

Figura 2.19. Acomodação opto-mecânica e caminhos ópticos da UTI.



Fonte: 52.


Os quadros escuros são adquiridos periodicamente fechando-se o obturador localizado na fenda de entrada do espectrômetro, permitindo a subtração do fundo de compensação das fontes internas da UTI.

A Figura 2.20, esquematiza cada modo do sistema, onde,

Modo ICU-S: Durante a calibração solar, a tampa da porta solar deve ser aberta pelo tempo estritamente necessário para realizar a aquisição. A radiação solar entra no instrumento pela porta solar, passa por um difusor de transmissão e então, por meio de um espelho plano dobrável, um relé óptico dedicado e o Divisor de Feixe de Sol (otimizado para maximizar o brilho das fontes das lâmpadas), é redirecionado para a superfície interna (traseira) da tampa da porta principal.

Modo ICU-Is: a unidade ICU é fornecida por lâmpadas de tungstênio calibradas com radiação posicionadas em caixas de lâmpadas refletoras dedicadas. A abertura do compartimento da lâmpada suporta um filtro de transmitância com assinaturas espectrais calibradas. As fontes de calibração internas são compostas por dois grupos iguais (principal e redundante) de um par de lâmpadas: uma lâmpada para VNIR e outra para o canal SWIR. As lâmpadas VNIR e SWIR diferem nas características espectrais do filtro e no revestimento do compartimento da lâmpada.

Figura 2.20. Vista esquemática dos caminhos ópticos da UTI.



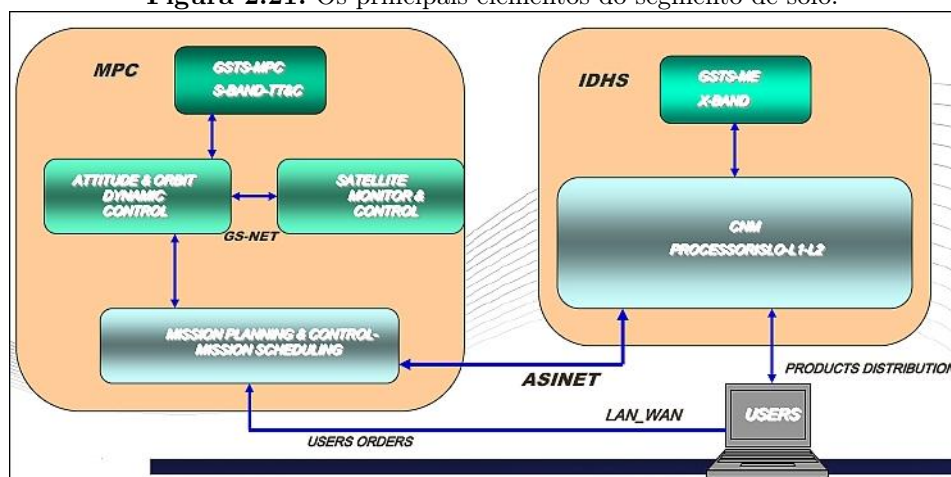
Fonte: 52.

2.3.5 Segmento de solo

O segmento terrestre da missão PRISMA inclui dois elementos, como mostra a Figura 2.21, principais:

- **MPC** (Planejamento e Controle de Missão) em Fucino, Itália;
- **IDHS** (*Instrument Data Handling System*) em Matera, Itália. Dedicado à aquisição, processamento, arquivamento e distribuição de dados de imagem (interface de usuário PRISMA). A função de processamento de dados IHDS é dedicada a gerar produtos de Nível 0, Nível 1 e Nível 2.

Figura 2.21. Os principais elementos do segmento de solo.



Fonte: 52.

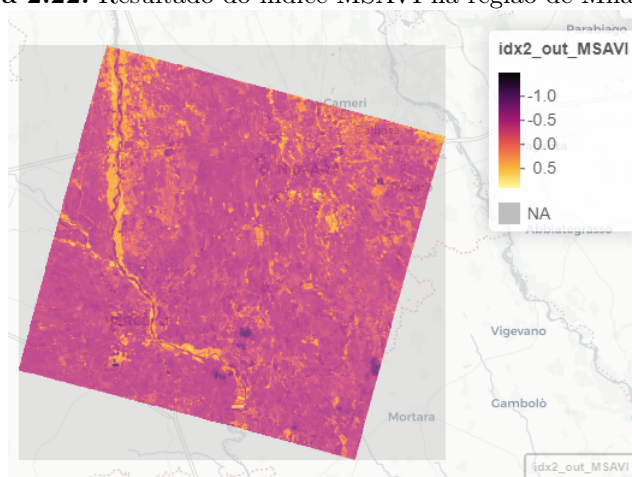
2.4 ÍNDICE DE QUALIDADE

Para que se tornasse possível a análise de diferentes características a partir de dados oriundos de satélites, durante a corrida espacial, houve uma busca não somente da ida à Lua, ou lançamento de satélites, mas também de como tratar da melhor forma possível as informações e dados obtidos por ambas as potências envolvidas. Desta maneira, foram desenvolvidos diferentes índices de qualidade de imageamento, onde se utiliza zonas específicas do espectro para expressar numericamente o seu estado ecológico [53]. Alguns índices utilizados para este fim são NDWI (*Normalized Difference Water Index*) [54], OSDI (*Oil Slick Detection Index*) [55],

NDSSI (*Normalized Difference Suspended Sediment Index*) [56], entre muitos outros [53], sendo o mais conhecido e bem sucedidos deles o NDVI (*Normalized Difference Vegetation Index*).

Devido ao fato destes índices utilizarem zonas específicas do espectro para classificação da região, a necessidade de haver mais zonas do espectro disponível fez com que o uso de satélites hiperespectrais aumentasse ainda mais a precisão dos resultados destes índices. A Figura 2.22 mostra o resultado do Índice de Vegetação Ajustado ao Solo Modificado (MSAVI), que é um índice de vegetação que é usado para aumentar os limites da aplicação do NDVI nas áreas com alta composição de solo descoberto. O MSAVI é usado nas áreas onde o NDVI apresenta dados inválidos, principalmente devido a uma pequena quantidade de vegetação ou devido à falta de clorofila na mesma. Assim, o índice é usado para minimizar a influência do fundo do solo e para aumentar a gama dinâmica do sinal da vegetação [57], combinado ao detalhamento de informações que uma imagem hiperespectral tem em relação a satélites multiespectrais.

Figura 2.22. Resultado do índice MSAVI na região de Milão, Itália.



Fonte: 58, 59.

Pela gama de opções disponíveis, como limitação de escopo, por ser o índice mais clássico e por se tratar de uma pesquisa com corpos d'água, neste trabalho foi utilizado o NDWI, que é definido a seguir:

2.4.1 NDWI

O NDWI faz uso da radiação infravermelha refletida e da luz verde visível para realçar a presença de características da águas, ao mesmo tempo em que elimina a presença de solo e

recursos de vegetação terrestre. Implica-se que o NDWI também possa fornecer aos pesquisadores estimativas de turbidez de corpos d'água usando dados digitais de sensoriamento remoto [60]. O NDWI, para este caso, é definido como

$$NDWI = \frac{X_{green} - X_{NIR}}{X_{green} + X_{NIR}}, \quad (2.22)$$

em que X_{green} é a luz verde e X_{NIR} é o infravermelho próximo.

Para a interpretação dos dados, é dado um intervalo de resposta entre -1 e 1, no qual se a resposta for < 0.3 não é água. Para esta análise, é realizado a reconstrução do CS, descrita em 2.2, para cada banda espectral utilizada no NDWI.

No caso de se utilizar mais índices de interesse, seria necessário a análise para cada um dos comprimentos utilizados em cada índice, porém quando a análise é feita ao decorrer do espectro para se obter novos índices ou detectar padrões mesclados, o estado da arte atualmente é a utilização de inteligência artificial e aprendizado de máquina [61, 62].

MATERIAIS E MÉTODOS

Nesta seção será detalhado o algoritmo de reconstrução desenvolvido, em que leva-se em consideração cada banda utilizada para o cálculo de índice de qualidade antes do procedimento de otimização para reconstrução, a otimização necessária para aplicar a teoria do CS e as medições correspondentes a uma ou mais versões filtradas da imagem esparsa com gradiente desejada. A reconstrução é decorrente do domínio espectral representado na transformada de Fourier, como apresentada na Seção 2.1, sendo esta, a transformada esparsificante escolhida para este trabalho.

3.1 VISÃO GERAL


A Figura 3.1 apresenta, de maneira geral, um diagrama com metodologia utilizada para a realização deste trabalho. O caso de estudo se inicia com um vetor de medidas b , que é estimado diretamente no domínio de Fourier.

No próximo passo, é aplicado um conjunto de filtros lineares a fim de esparsificar a imagem, em seguida, inicializando a reconstrução utilizando a teoria do CS para cada filtro e banda espectral utilizada na análise do índice de qualidade, como descrito na Seção 2.2, que descreve como o CS é aplicado a este tipo de imagem e 2.4.1, que discorre sobre o índice de qualidade para corpos d'água.

Após finalizado a solução numérica, a imagem passa por um processo de composição espectral, considerando tanto a resposta de cada filtro linear utilizado, quanto os valores captados de b e as bandas espectrais, assim finalizando o processo de reconstrução da imagem. Logo após finalizada a reconstrução, é feita a normalização da imagem por meio do índice NDWI.

Cada um destes processos serão discutidos e detalhados neste capítulo, ao final apresentando o algoritmo proposto por este trabalho.

Figura 3.1. Visão geral da metodologia utilizada para a realização do trabalho proposto.



Fonte: Autoria própria.

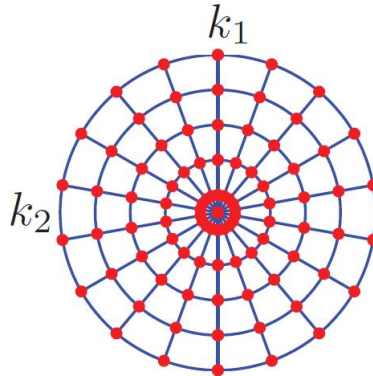
3.2 PROCEDIMENTO DE OTIMIZAÇÃO PARA RECONSTRUÇÃO

Devido ao fato de estar trabalhando com diferentes bandas espectrais (todas no domínio da frequência) para a determinação do seu comportamento em relação ao NDWI, a estimação de dados para o CS já é feita no domínio de Fourier [63]. As funções de base da discretização da matriz de medidas do sistema, impacta na reconstrução da imagem. Esta matriz possui dependência do equipamento utilizado para a maneira de obtenção de b , como descrito na Seção 2.2.2.

A aplicação é possível considerando que medições geralmente envolvem amostras tomadas em trajetórias específicas nos domínios de frequência das imagens, ou espaços, para que a reconstrução corresponda às imagens computacionais com base em suas transformadas de Fourier subamostradas [41, 64]. A aplicação dos métodos de reconstrução da transformada de Fourier é limitada pela dificuldade percebida de interpolação da grade polar ou outra medida para a grade cartesiana necessária para o cálculo eficiente da transformada de Fourier [65]. A Figura 3.2 mostra a trajetória utilizada para esta reconstrução, sabendo que em técnicas de CS a trajetória também deve corresponder a um conjunto de coeficientes de frequência incoerentes em

relação à transformação esparsificante [41].

Figura 3.2. Linhas radiais de trajetória de amostras (os pontos vermelhos representam as medidas tomadas).



Fonte: Adaptado de 41.

3.3 PRÉ-FILTRAGEM

Após o processo de calcular o procedimento de otimização para reconstrução (Seção 3.2), as medições são correspondentes a projeções da imagem esparsa. Essas versões, ou combinações lineares delas, são reconstruídas e um estágio final compõe a imagem, analisando as imagens filtradas e as amostras originais obtidas pelas suas projeções. Em outras palavras, um conjunto de filtros lineares é indiretamente aplicado à imagem desejada, mas de maneira que as imagens filtradas reconstruídas forneçam as informações espectrais necessárias para obter a imagem não filtrada. A ideia fundamental é que os filtros usados sejam escolhidos de forma a aumentar a dispersão das imagens no domínio do pixel. Além disso, observe que, como essas amostras correspondem aos coeficientes de Fourier da imagem a serem reconstruídos, o cálculo das medições pré-processadas associadas às versões linearmente filtradas dessa imagem é simples. De fato, como mostra a Eq. 3.1, seja h o núcleo bidimensional de um dos filtros lineares invariáveis por deslocamento e seja a transformação de Fourier de h calculada com o mesmo número de *pixels* da imagem a ser reconstruída. Se b é o vetor de amostras da imagem original e b_f é o conjunto de medidas para uma versão filtrada [41], logo

$$b_f = H_{k \in L} \circ b, \quad (3.1)$$

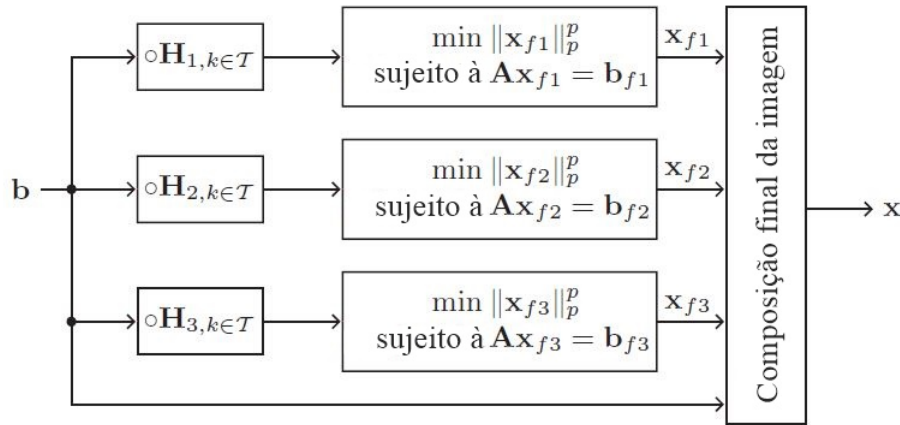
em que \circ representa o produto elemento a elemento e onde $H_{k \in L}$ é o vetor obtido empilhando todos os valores de H que pertencem as amostras estimadas.

O filtros utilizados para a realização da pré-filtragem serão do conjunto de filtros na decomposição bidimensional de wavelets de Haar 2D (Seção 2.1.1), como mostra na Eq. 3.2, pois dependendo das configurações do sistema (valor de p e filtros usados), o tempo total de computação e a relação sinal-ruído - SNR são influenciadas [41],

$$h_1 = h_2^T = \begin{bmatrix} 1 & 1 \\ -1 & -1 \end{bmatrix} \text{ e } h_3 = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix}. \quad (3.2)$$

A Figura 3.3, esquematiza o processo de pré-filtragem descrito nesta seção.

Figura 3.3. Pré-filtragem das medidas de entrada b e reconstrução separada de cada versão filtrada com as medidas b_{f1} , b_{f2} e b_{f3} .



Fonte: Adaptado de 41.

Neste ponto, após a composição espectral, a reconstrução de cada banda espectral está completa, assim é calculado e representado graficamente o índice de qualidade NDWI, percorrido na Seção 2.4.1.

Para este trabalho, o valor de norma utilizado para a solução do CS (Seção 2.2.4) é $p = 1$, por apresentar uma complexidade computacional menor em relação as p -normas, assim minimizando o tempo de processamento.

3.4 ALGORITMO

Até esta seção foi apresentado toda a teoria e metodologia necessária para a solução do problema proposto. A partir de agora, será mostrado a otimização feita para o desenvolvimento do algoritmo de reconstrução. Para solucionar a Eq. 2.20 foi usado o método dos mínimos

quadrados com ponderação iterativa - IRLS, onde com a função objetivo modificada, cada função de iteração se aproxima a $\sum_{n=1}^N |x_n|^p$. A Eq. 3.3 apresenta o problema de otimização [66]

$$\hat{x}^* = \min_{\hat{x}} \frac{1}{2} \sum_{n=1}^N \mathbf{w}_n^{p-2} \hat{\mathbf{x}}_n^2 \quad \text{sujeito a } A\hat{T}^{-1}\hat{x} = b, \quad (3.3)$$

em que \mathbf{w}_n é um parâmetro de peso [67]. O fator \hat{x}_n^2 determina a complexidade de solução. Observe que a Eq. 3.3 pode ser resolvido em apenas uma iteração, mas se o problema for resolvido repetidamente alterando os valores de \mathbf{w}_n a cada momento, para que \mathbf{w}_n se aproxime de $\hat{\mathbf{x}}_n$ a Eq. 3.3 se aproximará da Eq. 2.20, em que soluciona o problema de minimização do CS, e assim determinando a complexidade $O(2)$ para cada iteração, como mostra a Eq. 3.4 [66]

$$|\mathbf{w}^{(m)}| = |\hat{\mathbf{x}}^{(m-1)}|. \quad (3.4)$$

Como falado em [67, 66, 68], a fim de adicionar informações anteriores sobre a região de suporte da representação esparsa, se essa informação estiver disponível, é possível reduzir a quantidade de medições realizadas e ainda reconstruir sem ambiguidade o sinal subjacente. Como mostra a Eq. 3.5, seja ϕ o subconjunto de posições em $1, 2, \dots, N$ e pertencem à região de suporte de \hat{x} [66, 68]

$$\hat{x}_n \neq 0 \quad \forall \quad n \in \phi. \quad (3.5)$$

Assim as informações representadas pela Eq. 3.5 podem ser adicionadas ao procedimento de reconstrução (Eq. 2.20), como mostra a Eq. 3.6 [68]

$$\hat{x}^* = \min_{\hat{x}} \frac{1}{2} \sum_{\substack{n=1 \\ n \notin \phi}}^N |\hat{\mathbf{x}}_n| \quad \text{sujeito a } A\hat{T}^{-1}\hat{x} = b, \quad (3.6)$$

na qual \mathbf{w}_n seja suficientemente próximo de \hat{x}_n , a Eq. 3.5 também é verdade para o mesmo. Sendo isto verdade, como mostra a Eq. 3.7, \mathbf{w}_n é definido para $n \notin \phi$

$$\mathbf{w}_n = \begin{cases} |\hat{\mathbf{x}}_n^{(m-1)}|, & \text{se } n \notin \phi \\ \tau |\hat{\mathbf{x}}_n^{(m-1)}|, & \text{caso contrário.} \end{cases} \quad (3.7)$$

Sendo necessário que τ seja muito pequeno para que a aproximação seja verdade. Desta formas as Eqs. 3.6 e 2.16 são reescritas como as Eq. 3.8 e 3.9, e considerando que $M = A\hat{T}^{-1}$

$$\hat{x}^* = \min_{\hat{x}} \frac{1}{2} \sum_{n=1}^N \mathbf{w}_n^{(m)} |^{(p-2)} \hat{\mathbf{x}}_n^2 \quad \text{sujeito a } A\hat{T}^{-1}\hat{x} = b, \quad (3.8)$$

$$\hat{x}^{(m)} = Q^{(m)} M^H (M Q^{(m)} M^H)^{-1} b. \quad (3.9)$$

Onde

$$Q = \text{diag}[q_1, q_2, \dots, q_N] \quad (3.10)$$

e

$$q_n = \begin{cases} \hat{\mathbf{x}}_n^{(m-1)} |^{(2-p)}, & \text{se } n \notin \phi \\ \tau^{(2-p)} \hat{\mathbf{x}}_n^{(m-1)} |^{(2-p)}, & \text{caso contrário.} \end{cases} \quad (3.11)$$

Devido a inversão presente na Eq. 3.9, a fim de garantir que sempre haja a inversão de matriz, é acrescido a $|\hat{\mathbf{x}}_n|$ uma constante μ . Assim a Eq. 3.11 é reescrita na Eq. 3.12

$$q_n = \begin{cases} \hat{\mathbf{x}}_n^{(m-1)} |^{(2-p)} + \mu, & \text{se } n \notin \phi \\ \tau^{(2-p)} \hat{\mathbf{x}}_n^{(m-1)} |^{(2-p)} + \mu, & \text{caso contrário.} \end{cases} \quad (3.12)$$

Ao definir o critério de convergência para cada estágio de iteração, o procedimento iterativo com informações anteriores fornecidas pela Eq. 3.9 pode seguir a mesma estratégia proposta em [67]. Nesse esquema, a Eq. 3.9 é repetida, primeiro com $\mu = 1$ até

$$\frac{|\hat{\mathbf{x}}_n^{(m)} - \hat{\mathbf{x}}_n^{(m-1)}|}{1 + \|\hat{\mathbf{x}}_n^{(m-1)}\|} < \frac{\sqrt{\mu}}{100}. \quad (3.13)$$

Os valores de inicialização utilizados foram os mesmo apresentados em [66], com $\mu = 10^{-3}$ e tolerância de 10^{-8} , e $\tau^{2-p} = 10^{-3}$. Esta otimização é feita para cada estágio da pré-filtragem (Seção 3.3), onde também há a restrição para cada estágio um máximo de 100 iterações, e o algoritmo a um máximo de 10 estágios [41].

O estágio de composição da imagem mostrada na Figura 3.3, visa obter a imagem desejada a partir do conjunto de imagens filtradas reconstruídas e as medidas originais em b . As imagens filtradas, correspondentes aos operadores de diferenças finitas aplicadas às linhas, colunas e diagonais de x , fornecem as informações de passa alta que complementam as informações espectrais originais em b . O nível *DC* de x , por exemplo, é perdido nas imagens filtradas, mas

está disponível nas medições originais b . Nesta implementação, x é reconstruído primeiro no domínio da frequência, adotando as seguintes etapas: (1) Dividi-se os componentes de frequência de X_{f_1}, X_{f_2} e X_{f_3} pelos filtros correspondentes H_1, H_2 e H_3 (filtragem inversa). (2) Em seguida, combina-se os coeficientes de frequência resultantes de x dados pela filtragem inversa acima, com os das linhas de trajetória original. (3) Finalmente, a transformada de Fourier inversa dos coeficientes estimados de x é calculada, fornecendo a representação de x no domínio de pixel [41].

O Algoritmo 3.1 introduz o algoritmo de reconstrução desenvolvido.

Tabela 3.1. Algoritmo utilizado para a reconstrução das imagens a partir das medidas no domínio da frequência, com base nos métodos iterativo dos mínimos quadrados reponderados.

Algoritmo 1 Método IRLS para reconstrução de sinal no CS com informações a priori e metodologia de pré-filtragem

Entradas: $p > 0$, M , b , k , de cada banda espectral.

Passo 1. Estimaco das linhas de trajetria no domnio de Fourier.

Passo 2. Com os filtros apresentados em (3.2), inicie o processo de pr-filtragem.

Passo 3. Para cada filtro, inicialize $\hat{x}^{(m)}$ e $Q^{(m)}$, utilizando a Eq. 3.9.

Passo 4. Faa o lao interno:.

4.1 Inicialize $m := 1$.

4.2 Atualize $Q^{(m)}$ com (3.10) e (3.12).

4.3 Compute $\hat{x}^{(m)}$ usando (3.9) .

4.4 Se (3.13) for satisfeita, v para o Passo 5, seno $m := m + 1$ e volte ao Passo 4.2.

Passo 5. Para cada filtro, atualizar o parmetro de regularizao $\mu := \mu / 10$.

Passo 6. Para cada filtro, se $\mu < \text{tol}$ termine, seno retorne para o Passo 4.

Passo 7. Realize o processo de composio da imagem.

Passo 8. Clculo e construo do NDWI.

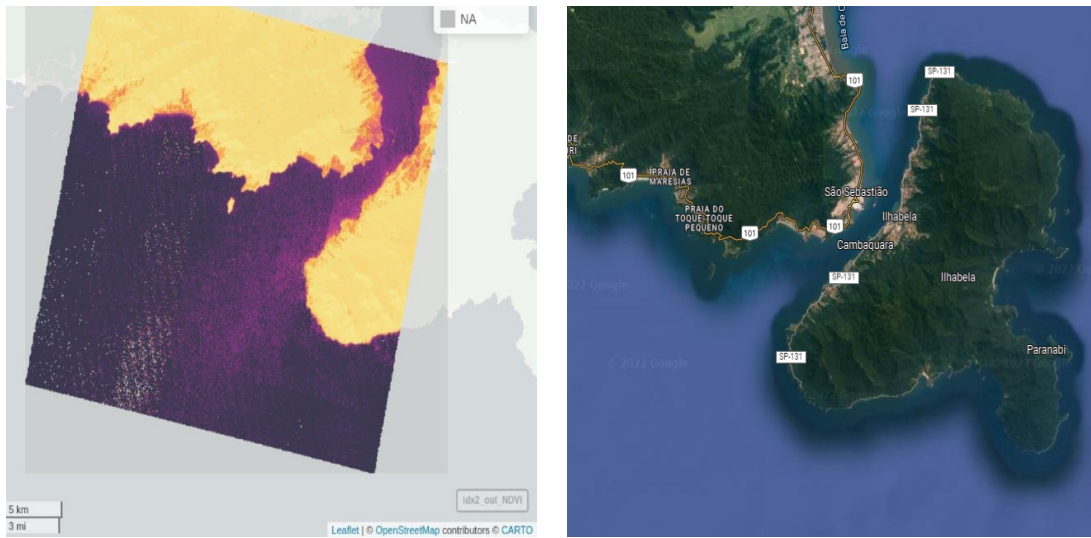
Retorna: Imagem reconstruda x .

Fonte: Autoria prpria.

3.5 IMAGEM-TESTE

Para testar o Algoritmo 3.1, a Figura 3.4, situada na bacia de Santos, regio de interesse petrolfero brasileiro (juntamente a bacia de campos), localizada entre o sul do Rio de Janeiro e Florianpolis. A escolha desta regio se deve ao fato que esta bacia  a mais importante e lucrativa no ramo petrolfero brasileiro [69] e por ser uma regio com bastante vegetao, onde o ndice poderia identificar gua das plantas tambm.

Figura 3.4. Região de São Sebastião em SP, situada na bacia de Santos, com as coordenadas (-23.82, -45.40).



(a) Imagem GeoTiff.

(b) Imagem no Google Maps.

Fonte: Autoria própria.

RESULTADOS E DISCUSSÕES

Assim como descrito na Seção 3.2, serão apresentados dois formatos de resultados. Primeiramente foi realizado os testes com diferentes linhas radiais no domínio de Fourier no espaço- k , utilizando o Algoritmo 3.1. Após realizado este procedimento, foram escolhidos o melhor e o pior caso e comparados com o resultado com uma imagem PRISMA real.


4.1 RESULTADOS NO DOMÍNIO DE FOURIER

Como apresentado na Seção 3.2, podem ser utilizados diferentes valores de linhas radiais para a determinação de um espaço- k que discretize as amostras no domínio de Fourier, otimizando o tempo de processamento.

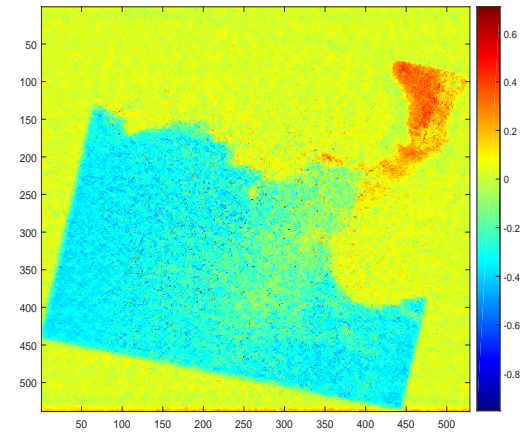
Desta forma foram realizadas simulações com diferentes linhas radiais k (40, 50, 60, 70, 80, 90, 100, 150, 200, 250, 300, 350, 400, 450, 500, 750, 1000, 1250), tanto para a banda espectral verde quanto o infravermelho próximo, afim de determinar um número ótimo de linhas necessárias para este tipo de imagem. Estes valores foram escolhidos devido a tendência da curva de crescimento da relação do sinal-ruído ser exponencial nas primeiras 100 projeções, ser mais linear entre as 100 e 800 projeções e estabilizar logo após isso [21]. Caso essa distribuição de linhas radiais for insuficiente, é necessário aumentar a resolução de projeções, para a imagem de estudo esta distribuição já foi suficiente, porém no trabalho [20] foi observado o problema da falta de resolução com pequenos vales na curva de crescimento da relação sinal-ruído, onde foi aumentado a resolução localmente.

A Figura 4.1 apresenta as reconstruções, referentes a Figura 3.4.


Figura 4.1. Reconstrução com linhas radiais da imagem-teste para diferentes valores de k .




(1) Reconstrução para k sendo 40.




(2) NDWI para k sendo 40.



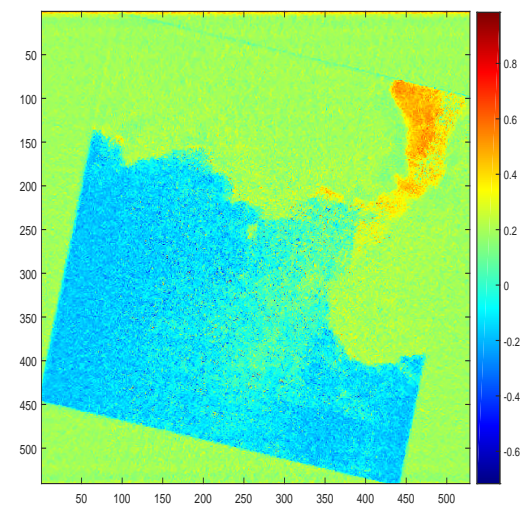
(3) Reconstrução para k sendo 50.




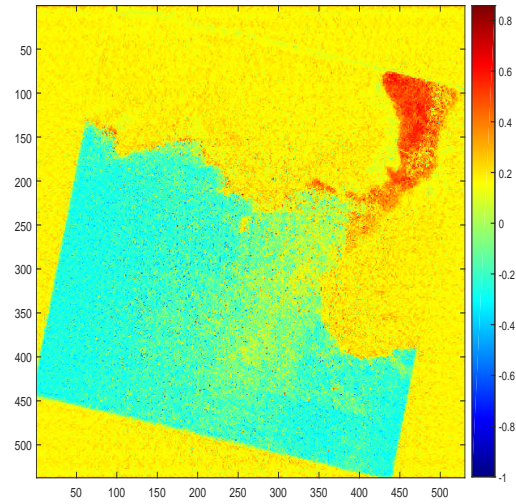

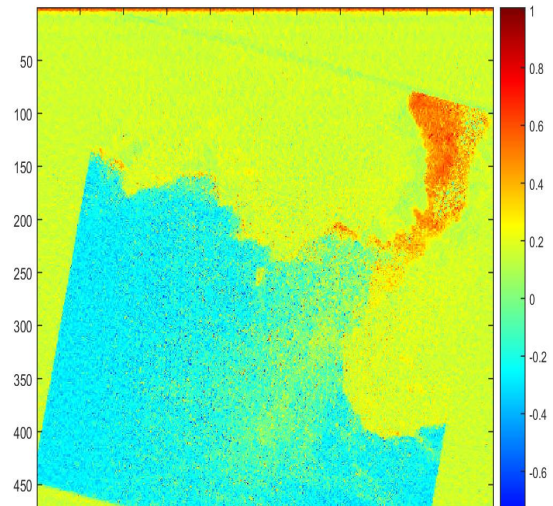


(4) NDWI para k sendo 50.




(5) Reconstrução para k sendo 60.




(6) NDWI para k sendo 60.


(7) Reconstrução para k sendo 70.(8) NDWI para k sendo 70.(9) Reconstrução para k sendo 80.(10) NDWI para k sendo 80.(11) Reconstrução para k sendo 90.(12) NDWI para k sendo 90.




(13) Reconstrução para k sendo 100.




(14) NDWI para k sendo 100.




(15) Reconstrução para k sendo 150.




(16) NDWI para k sendo 150.




(17) Reconstrução para k sendo 200.




(18) NDWI para k sendo 200.




(19) Reconstrução para k sendo 250.




(20) NDWI para k sendo 250.




(21) Reconstrução para k sendo 300.




(22) NDWI para k sendo 300.




(23) Reconstrução para k sendo 350.




(24) NDWI para k sendo 350.




(25) Reconstrução para k sendo 400.




(26) NDWI para k sendo 400.




(27) Reconstrução para k sendo 450.




(28) NDWI para k sendo 450.




(29) Reconstrução para k sendo 500.




(30) NDWI para k sendo 500.




(31) Reconstrução para k sendo 750.




(32) NDWI para k sendo 750.




(33) Reconstrução para k sendo 1000.



(34) NDWI para k sendo 1000.



(35) Reconstrução para k sendo 1250.




(36) NDWI para k sendo 1250.

Fonte: Autoria própria.

As imagens foram processadas em preto e branco para diminuir o tempo de processamento, já que o CS o tem como principal desvantagem [20]. A análise foi feita pensando no intervalo necessário para garantir qualidade de reconstrução, considerando o valor de linhas radiais, quanto maior o número de linhas melhor a discretização, qual o tipo de norma utilizada para solucionar o CS, que como apresentado na Seção 2.2.5, pode ser definido entre $0 < p \leq 1$, e pensando no tempo de processamento é $p = 1$ e finalmente o tipo de sinal para a análise de qualidade, onde diferentes faixas de frequências são processadas no domínio de Fourier. Desta forma, é possível controlar as três principais características no problema de compressão de dados astronômicos descrito na Seção 1, que são a resolução, ou seja a qualidade de detalhes que podem ser observados após a ênfase de informações que o NDWI pode gerar, a sensibilidade, que é trabalhada na composição final da imagem, como discorrido na Seção 3.3, onde o sinal DC é composto novamente a imagem e a fotometria que compõe a imagem reconstruída, garantindo a qualidade de resolução e a análise de resultados.

Como dito na Seção 2.4.1, sobre o índice de qualidade para corpos d'água, em que quando os valores do índice estão abaixo de 0.3 não podem ser considerado água, pode-se aferir que em todos os resultados apresentados na Figura 4.1, a distribuição de comportamento do que é água e do que não é, se manteve, mesmo em imagens com número de radial baixo (ou seja, alta compressão). O comportamento da distribuição do que é corpo d'água se mantém de forma quase linear, e isso pode ser visto na Figura 4.2, que apresenta o Índice de Similaridade Estrutural (SSIM) [70], que nos mostra a percepção de degradação da imagem como percebida na sua informação estrutural, ao mesmo tempo em que mostra importantes fenômenos perceptivos, incluindo luminância e contraste.

Figura 4.2. Índice de Similaridade Estrutural da reconstrução com a imagem original.



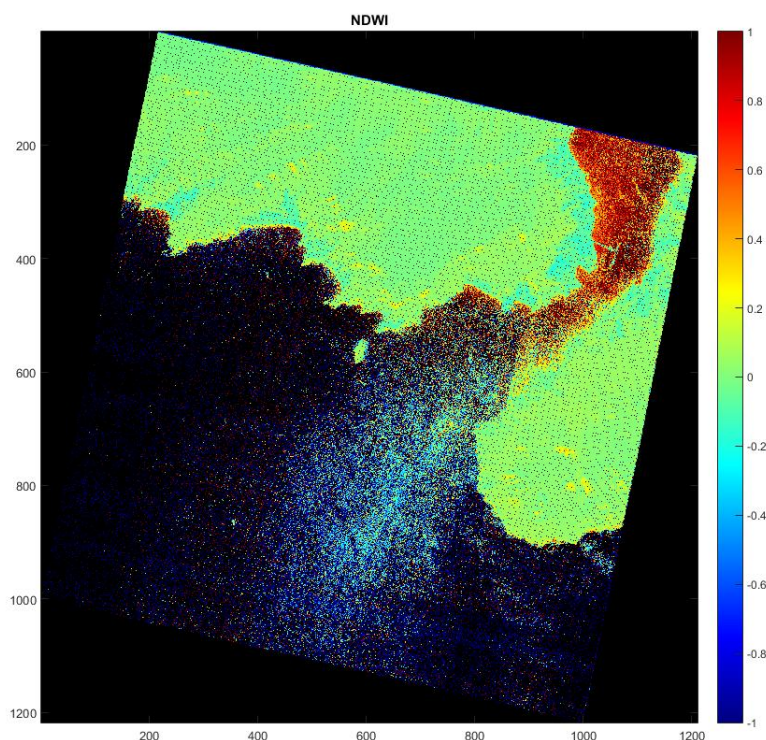
Fonte: Autoria própria.

Quanto mais próximo de 1, melhor e a percepção de luminância e contraste que a reconstrução em relação a imagem real pode nos proporcionar. A Figura 4.2 mostra que já com um número de radiais de 500, o SSIM é cerca de 60% em relação a imagem original e praticamente não há distinção a partir de 750, ou seja, para uma análise qualitativa do que é um corpo d'água com o valor de linhas radiais entre 500 e 750 já seria mais do que suficiente para esta imagem.

4.2 COMPARAÇÃO

O resultado do NDWI com os dados reais podem ser vistos na Figura 4.3. A imagem apresentava pixels com valores corrompidos, que foram considerados como zero (preto) para a análise da imagem. Essa consideração fez com que na reconstrução, devido a utilização da discretização no espaço- k , gerassem erros de reconstrução, dessa forma tornando a visualização destes pontos em tonalidade mais azul no índice de qualidade NDWI (ainda mantendo a relação de ser < 0.3).

Figura 4.3. NDWI feito com os resultados da imagem real da área de interesse.




Fonte: Autoria própria.

Para analisar o comportamento da reconstrução e a estabilidade da otimização realizada para a solução do problema do CS, apresentado na Seção 3.4, com o método de mínimos quadrados com ponderação iterativa (IRLS), o gráfico da Figura 4.4 apresenta a relação sinal-ruído *versus* o número de radiais utilizados.

Assim como na Figura 4.2, a qualidade de reconstrução só começa a estabilizar a partir da radial 750, que para o próximo passo apresenta uma melhora de aproximadamente 10% porém não visualmente em sua estrutura. Tendo em vista que o tempo de processamento médio é de 1,65h, com um desvio de cerca de 1h para cada valor de linha radial, o valor ótimo para esta análise é o de 750 linhas radiais. A estabilização da solução mostra que a otimização da solução para este problema se consolidou, garantindo que os erros introduzidos após a discretização do espaço- k sejam minimizados, garantindo a qualidade quantitativa da compressão dos dados obtidos.

Figura 4.4. Relação Sinal-Ruído da reconstrução com a imagem original.



Fonte: Autoria própria.

CONCLUSÃO

De acordo com os resultados obtidos, visando o controle das três características para análise de dados astronômicos, considerar a transformada esparficante de Haar, além de optar pela norma de Manhattan ou $p = 1$ e a utilização do método de mínimos quadrados com ponderação iterativa (IRLS) são suficientes para a estabilização e convergência da solução de *Compressive Sensing*. Devido a este resultado, foi possível determinar o que é um corpo d'água ou não com os pixels válidos, e que a abordagem de se utilizar valores nulos para os pixels corrompidos auxilia, porém pode gerar resultados visualmente poluídos. Entretanto mesmo assim, estruturalmente a imagem apresenta alto grau de similaridade quando comparado a imagem original.

Tanto com a relação sinal-ruído quanto com o Índice de Similaridade Estrutural, é possível notar que para esta imagem, a partir do número de radial 750 a solução inicia sua estabilização, tornando-se visualmente e estruturalmente difícil de notar mudanças na reconstrução. Desta forma, pode-se concluir que o presente trabalho mesmo com uma menor quantidade de número de radiais disponíveis, é possível identificar na reconstrução corpos d'água.

De forma geral, é possível garantir a qualidade de reconstrução deste tipo de imagem, mesmo com baixos valores de linhas radiais apresentadas no espaço- k , ou seja alto grau de compressão, assim sendo possível a extração de informações necessárias e apresentando uma alternativa ao problema da necessidade de técnicas de compressão de dados na área de Astronomia e Espaço.

5.1 TRABALHOS FUTUROS

Como possíveis trabalhos futuros, pode-se apontar:

- Tendo um banco de dados de imagens maior disponível, uma análise estatística no comportamento da estabilização da solução e do número de linhas radiais necessário em relação ao tempo de processamento.

- Utilizar outras transformadas de base para a realização da pré-filtragem e comparar os resultados com a base de Haar, verificando e analisando o custo computacional e o comportamento das suas propriedades de localização de tempo-frequência.
- Analisar estatisticamente o método de avaliação de qualidade de imagem (SSIM) para o caso proposto neste trabalho, caso seja possível a obtenção de novas imagens.
- Analisar o comportamento do ruído e custo computacional necessário, para diferentes p-normas, para a imagem utilizada. Assim fazendo uma comparação de custo-benefício verificando a viabilidade de cada solução proposta.
- Testar e adaptar, caso necessário, o algoritmo proposto para diferentes aplicações, algo já feito para imagens solares e agora hiperespectrais;
- Utilização de inteligência artificial para desenvolvimento de novos índices.

REFERÊNCIAS BIBLIOGRÁFICAS

- 1 BERRY, R.; BURNELL, J. *Handbook of astronomical Image Processing*. 2nd. ed. [S.l.]: Willmann-Bell, 2005. ISBN 9780943396828. Citado 2 vezes nas páginas 1 and 3.
- 2 BOBIN, J.-L. S. J.; OTTENSAMER, R. *Compressed Sensing in Astronomy. IEEE Journal of Selected Topics in Signal Processing*, Vol. 2, n. 5, p. 718–726, 2008. Disponível em: <<https://doi.org/10.1109/JSTSP.2008.2005337>>. Citado 4 vezes nas páginas 1, 3, 11, and 14.
- 3 CANDÈS, J. R. E. J.; TAO, T. *Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information. IEEE transactions on information theory*, Vol. 52, p. 489–509, 2006. Disponível em: <<https://doi.org/10.1109/TIT.2005.862083>>. Citado 2 vezes nas páginas 1 and 3.
- 4 RANI, S. B. D. M.; DESHMUKH, R. B. *A Systematic Review of Compressive Sensing: Concepts, Implementations and Applications. IEEE Access*, Vol. 6, p. 4875–4894, 2018. Disponível em: <<https://doi.org/10.1109/ACCESS.2018.2793851>>. Citado 2 vezes nas páginas 1 and 4.
- 5 BOBIN, J.; STARCK, J. *Astronomical Data Analysis and Sparsity: From Wavelets to Compressed Sensing. Proceedings of the IEEE*, Vol. 98, n. 6, p. 1021–1030, 2010. Disponível em: <<https://doi.org/10.1109/JPROC.2009.2025663>>. Citado 2 vezes nas páginas 1 and 3.
- 6 PU, R. *Hyperspectral Remote Sensing: Fundamentals and Practices*. 1. ed. [S.l.]: CRC Press, 2017. (Remote Sensing Applications Series). ISBN 1498731597,978-1-4987-3159-1,9781315120607,1315120607,978-1-1387-4717-3. Citado 3 vezes nas páginas 1, 2, and 3.
- 7 MEER, F.; JONG, S. D. *Imaging Spectrometry: Basic Principles and Prospective Applications. Dordrecht : Kluwer Academic Publishers, 2001. ISBN: 1-4020-0194-0. - (Bookseries Remote Sensing and digital image processing ; 4)*, 01 2001. Citado 4 vezes nas páginas 1, 2, 19, and 21.
- 8 CLARK ANDREA J GALLAGHER, G. A. S. R. N. *Material absorption band depth mapping of imaging spectrometer data using a complete band shape least-squares fit with library reference spectra. Proceedings of the Second Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop*, p. 176–186, 06 1990. Citado na página 2.
- 9 BEN-DOR, E. *Imaging Spectrometry For Urban Applications*. p. 2193 – 2218, 01 2002. Disponível em: <https://doi.org/10.1007/978-0-306-47578-8_9>. Citado na página 2.
- 10 EISMANN, M. *Hyperspectral remote sensing*. [s.n.], 2012. 1 - 726 p. Disponível em: <<https://doi.org/10.1117/3.899758>>. Citado na página 2.
- 11 NASA. James Webb Space Telescope. 2022. <<https://solarsystem.nasa.gov/missions/james-webb-space-telescope/in-depth/>>. Accessed: 27/11/2022. Citado na página 3.

- 12 White, R. L.; Postman, M.; Lattanzi, M. G. *Compression of the Guide Star Digitised Schmidt Plates*. In: MacGillivray, H. T.; Thomson, E. B. (Ed.). *Digitised Optical Sky Surveys*. [s.n.], 1992. (Astrophysics and Space Science Library, v. 174), p. 167. Disponível em: <https://doi.org/10.1007/978-94-011-2472-0_22>. Citado na página 3.
- 13 DONOHO, D. L. *Compressed Sensing*. *IEEE Transactions on Information Theory*, v. 52, p. 1289 – 1305, 2006. Disponível em: <<https://doi.org/10.1109/TIT.2006.871582>>. Citado na página 3.
- 14 CANDÈS, E. J.; TAO, T. *Near-Optimal Signal Recovery From Random Projections: Universal Encoding Strategies?*. *IEEE Transactions on Information Theory*, v. 52, n. 12, p. 5406 – 5425, 2006. Disponível em: <<https://doi.org/10.1109/TIT.2006.885507>>. Citado na página 3.
- 15 SCHOWENGERDT, R. A. *Remote Sensing: Models and Methods for Image Processing*. 3rd. ed. [S.l.]: Elsevier, 2007. ISBN 9780080480589. Citado na página 4.
- 16 QIAN, S.-E. *Hyperspectral Satellites, Evolution, and Development History*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 14, p. 7032–7056, 2021. Disponível em: <<https://doi.org/10.1109/JSTARS.2021.3090256>>. Citado na página 4.
- 17 AGÊNCIA ESPACIAL EUROPEIA. Proba-1 CHRIS Level 1A. 2014. <<https://earth.esa.int/eogateway/catalog/proba-chris-level-1a>>. Accessed: 10/12/2020. Citado 3 vezes nas páginas 4, 21, and 22.
- 18 FUNDAÇÃO CAPES. Programa de Cooperação Acadêmica em Defesa Nacional (Procad). 2019. <<http://www1.capes.gov.br/bolsas/programas-estrategicos/formacao-de-recursos-humanos-em-areas-estrategicas/programa-procad-defesa>>. Accessed: 13/12/2020. Citado na página 4.
- 19 DIAS, D.; MIOSSO, C.; SANTILLI, G. *Methods for Reconstruction of Solar Corona Based on Compressive Sensing of Tomography Images*. In: *IAF SPACE EXPLORATION SYMPOSIUM*. [s.n.], 2020. p. 1–5. Disponível em: <<https://iafastro.directory/iac/paper/id/60839/summary/>>. Citado na página 5.
- 20 DIAS, D.; MIOSSO, C. J.; SANTILLI, G. *Statistical Analysis for Reconstruction of Tomographic Solar Images Using Compressive Sensing*. In: *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*. [s.n.], 2022. p. 3460–3463. Disponível em: <<https://doi.org/10.1109/IGARSS46834.2022.9883913>>. Citado 3 vezes nas páginas 5, 46, and 53.
- 21 DIAS, D.; MIOSSO, C.; SANTILLI, G.; DIAS, U. *Statistical and Performance Analysis of Compressive Sensing in Solar Corona Tomography*. In: *2022 Workshop on Communication Networks and Power Systems (WCNPS)*. [s.n.], 2022. p. 1–5. Disponível em: <<https://doi.org/10.1109/WCNPS56355.2022.9969707>>. Citado 2 vezes nas páginas 5 and 46.
- 22 SUTCLIFFE, A.; BRITO, A.; SÁ, C.; SOUSA, F.; BOUTOV, D.; BROTAS, V. *OBSERVAÇÃO DA TERRA: uso de imagens de temperatura da superfície do mar e cor do oceano para a monitorização de águas costeiras e oceânicas*. [S.l.: s.n.], 2016. ISBN 978-989-99601-4-5. Citado na página 5.

- 23 OPPENHEIM, A.; WILLSKY, A.; NAWAB, S. *Sinais e sistemas*. Prentice-Hall, 2010. ISBN 9788576055044. Disponível em: <<https://books.google.com.br/books?id=ZOg9bwAACAAJ>>. Citado 2 vezes nas páginas 7 and 8.
- 24 BAILEY, D. H.; SWARZTRAUBER, P. N. *A Fast Method for the Numerical Evaluation of Continuous Fourier and Laplace Transforms*. *SIAM Review*, v. 15, p. 1105–1110, 1994. Disponível em: <<https://doi.org/10.1137/0915067>>. Citado na página 7.
- 25 DEBNATH, L.; BHATTA, D. *Integral Transforms and Their Applications, Third Edition*. Taylor & Francis, 2014. ISBN 9781482223576. Disponível em: <<https://books.google.com.br/books?id=tGpYBQAAQBAJ>>. Citado 5 vezes nas páginas 7, 8, 9, 10, and 11.
- 26 OLIVEIRA, H. de. *Análise de Fourier e Wavelets (Sinais Estacionários e não Estacionários)*. [s.n.], 2007. 343 p. ISBN 978-85-7315-417-7. Disponível em: <<https://doi.org/10.13140/RG.2.1.3519.9127>>. Citado 2 vezes nas páginas 8 and 9.
- 27 SOARES, M. J. *Onduletas e Processamento de Sinal*. Fundação João Jacinto Magalhães, p. 395–400, 1997. Disponível em: <<http://hdl.handle.net/1822/1554>>. Citado 3 vezes nas páginas 9, 10, and 11.
- 28 CANDÈS, E.; ROMBERG, J. *Sparsity and Incoherence in Compressive Sampling*. *Inverse Problems*, IOP Publishing, v. 23, p. 969–985, Apr 2007. Disponível em: <<https://doi.org/10.1088/0266-5611/23/3/008>>. Citado na página 10.
- 29 DONOHO, D. L. *Compressed Sensing*. *IEEE Trans. on Inf. Theory*, v. 52, n. 4, p. 1289–1306, 2006. Disponível em: <<https://doi.org/10.1109/TIT.2006.871582>>. Citado na página 11.
- 30 CANDÈS, E. J. *Compressive sampling*. *Proceedings of the International Congress of Mathematicians*, 2006. Disponível em: <<https://doi.org/10.4171/022-3/69>>. Citado 2 vezes nas páginas 11 and 13.
- 31 OPPENHEIM, A. V.; WILLSKY, A. S. *Sinais e Sistemas*. 2°. ed. [S.l.]: Pearson, 1997. ISBN 9789332550230. Citado na página 12.
- 32 ELДАР, Y. C. *Compressed sensing*. Cambridge University Press, p. 390–471, 2012. Disponível em: <<https://doi.org/10.1017/CBO9780511794308>>. Citado na página 12.
- 33 DONOHO, D. For Most Large Underdetermined Systems of Linear Equations the Minimal L1-norm Solution is also the Sparsest Solution. 2004. <<http://wwwstat.stanford.edu/Edonoho/Reports/2004>>. Data de acesso: 06/09/2019. Citado 2 vezes nas páginas 12 and 13.
- 34 CANDES, E.; ROMBERG, J.; TAO, T. *Robust Uncertainty Principles: Exact Signal Reconstruction from Highly Incomplete Frequency Information*. *IEEE Information Theory Society*, Vol. 52, p. p. 489–509, 2008. Disponível em: <<https://doi.org/10.1109/TIT.2005.862083>>. Citado 2 vezes nas páginas 13 and 14.
- 35 WEIR, M. D.; HASS, J.; THOMAS, G. B. *Cálculo*. 12th. ed. [S.l.]: Pearson, 2012. v. 2. ISBN 9780134439280. Citado na página 13.
- 36 SHANNON, C. E. *A Mathematical Theory of Communication*. *The Bell System Technical Journal*, Nokia Bell Labs, v. 27, n. 3, p. 379–423, Aug 1948. Disponível em: <<https://ieeexplore.ieee.org/document/6773024/>>. Citado na página 13.

- 37 DONOHO, D. *For most large underdetermined systems of equations, the minimal l_1 -norm near-solution approximates the sparsest near-solution*. *Communications on Pure and Applied Mathematics*, v. 59, p. 907 – 934, Sep 2006. Disponível em: <<https://doi.org/10.1002/cpa.20131>>. Citado 3 vezes nas páginas 13, 14, and 16.
- 38 LIMA, E. L. *Espaços Métricos*. 2nd. ed. [S.l.]: Instituto de Matemática Pura e Aplicada - IMPA, 1977. ISBN 9786599052873. Citado 2 vezes nas páginas 15 and 16.
- 39 QUEIROZ, O. S. de. Notas de Aula de Análise Funcional. 2013. <<https://www.ime.unicamp.br/~olivaine/Funcional.pdf>>. Data de acesso: 06/09/2019. Citado na página 15.
- 40 BRUCKSTEIN, D. L. D. A. M.; ELAD, M. *From Sparse Solutions of Systems of Equations to Sparse Modeling of Signals and Images*. *Society for Industrial and Applied Mathematics*, Vol. 51, p. 34 – 81, 2009. Disponível em: <<https://doi.org/10.1137/060657704>>. Citado 2 vezes nas páginas 15 and 16.
- 41 MIOSSO, C.; BORRIES, R. von; PIERLUISSI, J. *Compressive sensing method for improved reconstruction of gradient-sparse magnetic resonance images*. In: . [s.n.], 2009. p. 799 – 806. Disponível em: <<https://doi.org/10.1109/ACSSC.2009.5469970>>. Citado 6 vezes nas páginas 18, 39, 40, 41, 43, and 44.
- 42 FILCHEV, L. *Satellite Hyperspectral Earth Observation Missions – A Review*. *Aerospace Research in Bulgaria*, v. 26, p. 191–207, 01 2014. Disponível em: <<http://journal.space.bas.bg/arhiv/n2026/Articles/10.pdf>>. Citado 4 vezes nas páginas 18, 19, 21, and 23.
- 43 SERAFIMOV, K. Bulgarian space activity. *Advances in Space Research*, v. 3, n. 10, p. 1 – 6, 1984. ISSN 0273-1177. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0273117784900528>>. Citado na página 18.
- 44 PHD, R. H. W. J. B. C. *Introduction to Remote Sensing, Fifth Edition*. Fifth edition, fifth edition. [S.l.]: The Guilford Press, 2011. ISBN 160918176X,9781609181765. Citado na página 19.
- 45 LEWIS (SSTI 1). LEWIS mission - NASA. 1997. <https://space.skyrocket.de/doc_sdat/lewis.htm>. Accessed: 10/12/2020. Citado na página 19.
- 46 EOPORTAL DIRECTORY. MightySat Program. 1994. <<https://directory.eoportal.org/web/eoportal/satellite-missions/m/mightysat>>. Accessed: 10/12/2020. Citado 2 vezes nas páginas 19 and 20.
- 47 FORÇA AÉREA AMERICANA. NEMO (Naval Earth Map Observer). 2000. <https://space.skyrocket.de/doc_sdat/nemo.htm>. Accessed: 10/12/2020. Citado na página 20.
- 48 DOZIER, J. HIRIS - The High Resolution Imaging Spectrometer. In: SLATER, P. N. (Ed.). *Recent Advances in Sensors, Radiometry, and Data Processing for Remote Sensing*. SPIE, 1988. v. 0924, p. 23 – 30. Disponível em: <<https://doi.org/10.1117/12.945667>>. Citado na página 22.
- 49 HOGG, J. Introduction to environmental remote sensing, e. c. barrett and l. f. curtis. chapman and hall ltd (science paperbacks), 1976. no. of pages: 336. about 50 black and white and 9 colour plates, numerous diagrams. price: £5.95 paperback. *Earth Surface Processes*,

- v. 3, n. 2, p. 209–210, 1978. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/esp.3290030208>>. Citado na página 22.
- 50 KRAMER, H. J. *Observation of the Earth and Its Environment: Survey of Missions and Sensors*. 4th ed.. ed. [S.l.]: Springer Berlin Heidelberg;Springer, 2002. ISBN 978-3-540-42388-1,978-3-642-56294-5. Citado na página 23.
- 51 AGÊNCIA ESPACIAL ITALIANA. PRISMA (Hyperspectral Precursor and Application Mission). 2019. <<https://directory.eoportal.org/web/eoportal/satellite-missions/p/prisma-hyperspectral>>. Accessed: 10/12/2020. Citado na página 23.
- 52 AGÊNCIA ESPACIAL ITALIANA. PRISMA (Hyperspectral Precursor and Application Mission). 2013. <<https://earth.esa.int/web/eoportal/satellite-missions/p/prisma-hyperspectral>>. Accessed: 10/12/2020. Citado 12 vezes nas páginas 23, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, and 35.
- 53 CALMUC, V.-A.; CALMUC, M.; ȚOPA, C.; MIHAELA, T.; ITICESCU, C.; GEORGESCU, L. *Various methods for calculating the water quality index*. v. 41, p. 171–178, 06 2018. Disponível em: <<https://doi.org/10.35219/ann-ugal-math-phys-mec.2018.2.09>>. Citado 2 vezes nas páginas 35 and 36.
- 54 GAO, B. cai. *NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space*. *Remote Sensing of Environment*, v. 58, n. 3, p. 257–266, 1996. ISSN 0034-4257. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0034425796000673>>. Citado na página 35.
- 55 ZHAO, D.; CHENG, X.; ZHANG, H.; ZHANG, H. *An Oil Slick Detection Index Based on Landsat 8 Remote Sensing Images*. In: . [s.n.], 2018. p. 1–4. Disponível em: <<https://doi.org/10.1109/BGDDS.2018.8626850>>. Citado na página 35.
- 56 PETERSON, K. T.; SAGAN, V.; SIDIKE, P.; COX, A. L.; MARTINEZ, M. *Suspended Sediment Concentration Estimation from Landsat Imagery along the Lower Missouri and Middle Mississippi Rivers Using an Extreme Learning Machine*. In: . [s.n.], 2018. v. 10, n. 10. ISSN 2072-4292. Disponível em: <<https://doi.org/10.3390/rs10101503>>. Citado na página 36.
- 57 EARTH OBSERVATION SYSTEM. *Índice de Vegetação Ajustado ao Solo Modificado*. 2019. <<https://eos.com/pt/industries/agriculture/msavi/>>. Accessed: 31/07/2021. Citado na página 36.
- 58 VANGI, E.; D'AMICO, G.; FRANCINI, S.; GIANNETTI, F.; LASSERRE, B.; MARCHETTI, M.; CHIRICI, G. *The New Hyperspectral Satellite PRISMA: Imagery for Forest Types Discrimination*. *Sensors*, v. 21, n. 4, 2021. ISSN 1424-8220. Disponível em: <<https://doi.org/10.3390/s21041182>>. Citado na página 36.
- 59 BUSETTO, L.; RANGHETTI, L. *Prismaread: A tool for facilitating access and analysis of PRISMA L1/L2 hyperspectral imagery v1.0.0*. 2020. <<https://lbusett.github.io/prismaread/>>. Accessed: 31/07/2021. Citado na página 36.
- 60 MCFEETERS, S. K. *The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features*. *International Journal of Remote Sensing*, Taylor Francis, v. 17, n. 7, p. 1425–1432, 1996. Disponível em: <<https://doi.org/10.1080/01431169608948714>>. Citado na página 37.

- 61 CHEN, Y.; JIANG, H.; LI, C.; JIA, X.; GHAMISI, P. *Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks*. *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 10, p. 6232–6251, 2016. Disponível em: <<https://doi.org/10.1109/TGRS.2016.2584107>>. Citado na página 37.
- 62 LI, X.; DING, J.; ILYAS, N. *Machine learning method for quick identification of water quality index (WQI) based on Sentinel-2 MSI data: Ebinur Lake case study*. *Water Supply*, v. 21, n. 3, p. 1291–1312, 12 2020. ISSN 1606-9749. Disponível em: <<https://doi.org/10.2166/ws.2020.381>>. Citado na página 37.
- 63 MARTÍN, G.; BIOUCAS-DIAS, J. M. *Hyperspectral compressive sensing from spectral projections*. In: *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. [s.n.], 2015. p. 1000–1003. Disponível em: <<https://doi.org/10.1109/IGARSS.2015.732593>>. Citado na página 39.
- 64 WRIGHT, G. A. *Magnetic resonance imaging*. *IEEE Signal Processing Magazine*, v. 14, n. 1, p. 56–66, Jan 1997. Disponível em: <<https://doi.org/10.1109/79.560324>>. Citado na página 39.
- 65 O’SULLIVAN, J. D. *A Fast Sinc Function Gridding Algorithm for Fourier Inversion in Computer Tomography*. *IEEE Transactions on Medical Imaging*, v. 4, n. 4, p. 200–207, 1985. Disponível em: <<https://doi.org/10.1109/TMI.1985.4307723>>. Citado na página 39.
- 66 MIOSSO, C. J.; BORRIES, R. von; ARGAEZ, M.; VELAZQUEZ, L.; QUINTERO, C.; POTES, C. M. *Compressive Sensing Reconstruction With Prior Information by Iteratively Reweighted Least-Squares*. *IEEE Transactions on Signal Processing*, v. 57, n. 6, p. 2424–2431, Jun 2009. ISSN 1941-0476. Disponível em: <<https://doi.org/10.1109/TSP.2009.2016889>>. Citado 2 vezes nas páginas 42 and 43.
- 67 CHARTRAND, R.; YIN, W. *Iteratively reweighted algorithms for compressive sensing*. In: *2008 IEEE International Conference on Acoustics, Speech and Signal Processing*. [s.n.], 2008. p. 3869–3872. ISSN 2379-190X. Disponível em: <<https://doi.org/10.1109/ICASSP.2008.4518498>>. Citado 2 vezes nas páginas 42 and 43.
- 68 BORRIES, R. von; MIOSSO, C. J.; POTES, C. *Compressed Sensing Using Prior Information*. In: *2007 2nd IEEE International Workshop on Computational Advances in Multi-Sensor Adaptive Processing*. [s.n.], 2007. p. 121–124. ISSN null. Disponível em: <<https://doi.org/10.1109/CAMSAP.2007.4497980>>. Citado na página 42.
- 69 PETROBRÁS. *Comunicação Bacia de Santos*. 2019. <<https://comunicabaciadesantos.petrobras.com.br/programa-ambiental/plano-de-emergencia-para-vazamento-de-oleo-pevo.html>>. Accessed: 02/08/2022. Citado na página 44.
- 70 WANG, Z.; BOVIK, A. C.; SHEIKH, H. R.; SIMONCELLI, E. P. *Image quality assessment: from error visibility to structural similarity*. *IEEE Transactions on Image Processing*, v. 13, n. 4, p. 600–612, Apr 2004. ISSN 1941-0042. Disponível em: <<https://doi.org/10.1109/TIP.2003.819861>>. Citado na página 53.