



Programa de Pós-Graduação em

**Computação Aplicada**

Mestrado/Doutorado Acadêmico

Marianne Müller

Formulação de um Novo Índice Espectral Para Identificação de  
Rochas Carbonáticas

São Leopoldo, 2021



UNIVERSIDADE DO VALE DO RIO DOS SINOS — UNISINOS  
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA  
NÍVEL MESTRADO

MARIANNE MULLER

**FORMULAÇÃO DE UM NOVO ÍNDICE ESPECTRAL PARA IDENTIFICAÇÃO DE  
ROCHAS CARBONÁTICAS**

São Leopoldo  
2021



Marianne Muller

**FORMULAÇÃO DE UM NOVO ÍNDICE ESPECTRAL PARA IDENTIFICAÇÃO DE  
ROCHAS CARBONÁTICAS**

Dissertação apresentada como requisito para a  
obtenção do título de Mestre pelo Programa de  
Pós-Graduação em Computação Aplicada da  
Universidade do Vale do Rio dos Sinos —  
UNISINOS

Orientador:  
Prof. Dr. Luiz Gonzaga Silveira Jr

Coorientador:  
Prof. Dr. Mauricio Roberto Veronez

São Leopoldo  
2021



M958f Muller, Marianne.  
Formulação de um novo índice espectral para  
identificação de rochas carbonáticas / Marianne Muller. –  
2021.  
61 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos  
Sinos, Programa de Pós-Graduação em Computação Aplicada,  
2021.

“Orientador: Prof. Dr. Luiz Gonzaga Silveira Jr  
Coorientador: Prof. Dr. Mauricio Roberto Veronez.”

1. Índices espectrais. 2. Afloramentos carbonáticos. I. Título.

CDU 004

Dados Internacionais de Catalogação na Publicação (CIP)  
(Bibliotecária: Amanda Schuster – CRB 10/2517)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) - Código de Financiamento 001 /"This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001.



## **AGRADECIMENTOS**

À minha família, meus pais Alfredo e Ercy, minha irmã Anna Cecília e minha tia Marly, pelo apoio incondicional em todas as fases da minha vida.

Ao Prof. Dr. Daniel Capella Zanotta pelos ensinamentos, pela contribuição com o meu trabalho, com minha formação e pelo exemplo.

Aos Profs. Drs. Luiz Gonzaga Jr e Mauricio Veronez por aceitarem me orientar no desenvolvimento da dissertação, na produção de artigos, e por ampliar os meus horizontes na minha vida profissional.

Minha eterna gratidão ao meu amigo Vinicius, por todo incentivo e apoio prestado a mim ao longo dos últimos anos, À Graciela, Diego, Ademir, Douglas, Thais e Rodrigo, por todos os momentos valiosos que me proporcionaram e pelo apoio oferecido durante essa jornada.

Ao Vizlab e à toda equipe do laboratório, por toda infraestrutura que me foi oferecida e pela oportunidade de conhecer e trabalhar com grandes pesquisadores.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES pelo financiamento.

À Universidade do Vale Rio dos Sinos - UNISINOS e o ao Programa de Pós-Graduação em Computação Aplicada (PPGCA) por me fornecerem uma formação acadêmica de qualidade.



## RESUMO

Afloramentos carbonáticos são um dos focos de pesquisa da indústria do petróleo e a investigação *in situ* é a maneira mais eficiente de caracterizar um afloramento, entretanto ela demanda tempo e investimentos altos. Análises através de dados de sensoriamento remoto convertidos em indicadores que atestem a presença de determinados materiais no local de estudo, como índices espectrais ou imagens de fração, representam uma alternativa viável. Embora já existam índices espectrais de rochas carbonáticas, eles apresentam limitações ligadas principalmente a resolução do dado de entrada e a extensão do indicador para outros ambientes diferentes dos quais ele foi treinado. A presente dissertação de mestrado se propôs a abordar este problema de forma estruturada para formulação de um novo índice que supere o desempenho dos existentes na literatura. O procedimento de mineração dos dados disponíveis foi utilizado para entender como as decisões são tomadas a fim de separar alvos carbonáticos de outros materiais quaisquer. Posteriormente, gráficos de espalhamento de dados foram produzidos para localizar a região que concentra alvos de interesse no espaço multiespectrais, bem como para visualizar como se diferenciam dos demais alvos. Por fim, um versátil índice espectral para rochas carbonáticas foi formulado, com parâmetros ajustados de acordo com o sensor em uso (no caso o sensor OLI-Landsat 8), oferecendo ao usuário uma possibilidade de adaptação do índice para o seu cenário. O índice foi calculado para uma imagem e comparado com um Ground Truth (GT) produzido a partir de interpretação visual seguida de degradação do dado para atingir a escala adequada em cada situação. O índice proposto seguiu todas as premissas indicadas pela literatura e alcançou um desempenho de 83.2% de acerto, valor relativamente maior do que os outros índices referenciados na literatura atual. Os resultados sugerem o potencial para pesquisas futuras a fim de testar a aplicação do índice a outras áreas de estudo e a dados de outros sensores (com os ajustes necessários).

**Palavras-chave:** Índices espectrais. Afloramentos carbonáticos.



## ABSTRACT

Carbonate outcrops are one of the focuses of research in the oil industry. *In situ* research is the most efficient way to characterize an outcrop, though it requires time and high investments. Analysis using remote sensing data converted into indicators that attest to the presence of certain materials on the study site, such as spectral indexes or fraction images, represents a viable alternative. Although spectral indices for carbonate rocks already exist, they present limitations mostly related to the input data's resolution and the indicator's extension to other environments. The present master's thesis proposed approaching this problem in a structured way to formulate a new index that surpasses those existing in the literature's performance. The present master's thesis proposed approaching this problem in a structured way to formulate a new index that surpasses those existing in the literature's performance. The mining procedure was used on the available data to understand how decisions are made in order to separate carbonate targets from any other material. Afterward, data scatter plots were produced to locate the region that concentrates targets of interest in the multispectral space, as well as to visualize how they differ from other targets. Finally, a versatile spectral index for carbonate rocks was formulated, with parameters adjusted according to the sensor in use (in this case, the OLI-Landsat 8 sensor), offering the user the possibility to adapt the index to his scenario. The index was calculated for an image and compared with a Ground Truth (GT) produced from visual interpretation followed by data degradation to reach the appropriate scale in each situation. The proposed index followed all the premises indicated by the literature and achieved a performance of 83.2 % of global accuracy, a value relatively higher than the other indexes referenced in the current literature. These results suggest the potential for further research to test the index application to other study areas and other sensors' data (with the necessary adjustments).

**Keywords:** Spectral indexes. carbonate outcrops.



## LISTA DE FIGURAS

Figura 1 – Representação do espectro eletromagnético. . . . .	19
Figura 2 – Reflectância aparente dos diferentes minerais frente aos dados hiperespectrais do AVIRIS – NG. . . . .	23
Figura 3 – Curvas de reflectância de componentes de rocha carbonática. . . . .	24
Figura 4 – Reflectância aparente dos diferentes minerais frente aos dados hiperespectrais do HySpex. . . . .	26
Figura 5 – Mapa de localização da Área de Estudo . . . . .	29
Figura 6 – Fluxograma da metodologia aplicada para análise dos indicadores de carbonato . . . . .	31
Figura 7 – (a) Área do afloramento (região cinza clara) composta principalmente por calcita com algumas áreas de dolomita. (b) O GT gerado a partir da interpretação visual auxiliada por um especialista na área. (c), (d), (e) GT correspondente de (b) redimensionado para combinar com tamanhos de imagens diferentes usadas como entrada, 44x27 (Sentinel-2B), 29x17 (Landsat-8) e 10x6 (ASTER-TERRA) , respectivamente . . . . .	32
Figura 8 – Resoluções espectrais abordadas na metodologia . . . . .	35
Figura 9 – Gráficos de dispersão entre os indicadores e o GT e as imagens computadas para cada indicador. (a) ASTER - TIR Eq. ( ref eq: 1), (b) Landsat - KBRI (Eq. ref eq: KBRI), (c) Landsat - NIR visível (Eq. ref eq: CRI1), (d) Sentinel - NIR visível (Eq. ref eq: CRI1), (e) Sentinel - LSMM, (f) Landsat - LSMM . . . . .	40
Figura 10 – Reflectância dos alvos . . . . .	41
Figura 11 – Interpolação do SFR para a banda azul . . . . .	42
Figura 12 – Árvores de decisão geradas para os 3 cenários supostos para as assinaturas espectrais, onde a classe CR representa a classe de rochas carbonática e N_CR representa a classe de não-carbonáticas . . . . .	42
Figura 13 – Árvores de decisão para imagem Landsat 8 . . . . .	43
Figura 14 – Espalhamento das classes utilizando as assinaturas espectrais, onde a classe CR representa a classe de rochas carbonática e N_ CR representa a classe de não-carbonáticas . . . . .	44
Figura 15 – Espalhamento das classes utilizando a imagem Landsat 8 . . . . .	45
Figura 16 – Isolinhas geradas a partir da distribuição das classes no espaço espectral . . . . .	46
Figura 17 – Distribuição das classes no espaço espectral das assinaturas simuladas . . . . .	46
Figura 18 – Modelo inicial para construção do índice . . . . .	47
Figura 19 – Modelo inicial e pixels da imagem . . . . .	47
Figura 20 – Modelo final . . . . .	49
Figura 21 – Imagem computada para o índice proposto e gráfico de dispersão entre a imagem e o GT . . . . .	49



## **LISTA DE TABELAS**

Tabela 1 – Pico de absorção das rochas carbonáticas conforme sua composição mineral	22
Tabela 2 – Comparação entre os resultados alcançados por cada abordagem. . . . .	39



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>17</b>
<b>2</b>	<b>REVISÃO TEÓRICA</b>	<b>19</b>
2.1	Características Espectrais de Rochas Carbonáticas	19
2.2	Sensoriamento Remoto aplicado a Rochas Carbonáticas	20
2.3	Índices espectrais de carbonatos	24
2.4	Simulação de bandas	27
2.5	Mineração de dados por CART - <i>Classification and Regression Tree</i>	27
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>29</b>
3.1	Área de Estudo	29
3.2	Análise quantitativa dos indicadores de carbonato	30
3.3	Elaboração de um novo índice espectral de Rochas Carbonáticas	33
3.3.1	Estudo e emprego analítico das bandas espectrais para identificação de rochas carbonáticas	34
3.3.2	Modelagem do índice espectral para rochas carbonáticas	37
<b>4</b>	<b>ANÁLISE DOS RESULTADOS E DISCUSSÕES</b>	<b>39</b>
4.1	Análise quantitativa dos indicadores	39
4.2	Elaboração de um novo índice espectral de Rochas Carbonáticas	41
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>51</b>
	<b>REFERÊNCIAS</b>	<b>53</b>
	<b>APÊNDICE A – ARTIGO PUBLICADO</b>	<b>57</b>



## 1 INTRODUÇÃO

Na Geologia do Petróleo existem dois tipos de reservatórios de interesse: os reservatórios turbidíticos e os reservatórios carbonáticos (EHRENBERG; NADEAU, 2005). Um dos principais componentes de reservatórios turbidíticos são arenitos compostos por quartzo (Dióxido de Silício – $SiO_2$ ), sendo o turbidito um depósito sedimentar originado por turbidez marinha. Já os reservatórios carbonáticos são compostos por carbonato de cálcio ( $CaCO_3$ ) (TEIXEIRA et al., 2017). Estes reservatórios podem ser divididos de acordo com o processo de formação da rocha, sendo ou por precipitação química de sais em solução - como no caso dos calcários - ou a partir do acúmulo de fragmentos de animais invertebrados (ex. como conchas de moluscos) cimentados por carbonatos de cálcio.

No Brasil, após o descobrimento da camada do pré-sal, ficou em evidenciada a importância que o estudo das rochas carbonáticas possuem no processo de extração de petróleo, isso porque a reserva do pré-sal “se encontra em rochas carbonáticas situadas a grande profundidade e em lâminas d’água superiores a 2 km de espessura” (CORRÊA, 2013).

Uma alternativa para caracterizar reservatórios carbonáticos em grandes profundidades, é analisar afloramentos rochosos análogos (BASSO; KURODA; VIDAL, 2017), pois estes podem fornecer informações a respeito de fatores como caracterização do meio geológico (ARAÚJO, 2019). Afloramentos carbonáticos são, portanto, foco de estudo da indústria petrolífera. O estudo de afloramentos análogos aos reservatórios de petróleo também constitui uma alternativa economicamente mais viável, uma vez que existem como mapeamento por LIDAR (*Light Detection And Ranging*) e Fotogrametria Digital que permitam reconstruir em meio digital os afloramentos, permitindo que sejam feitas visualizações e interpretações dos mesmos (GONZAGA et al., 2018).

A maneira mais eficiente para a caracterização de materiais carbonáticos na superfície é a investigação *in situ* por especialistas (YUE et al., 2010). No entanto, existem desvantagens no serviço de campo tradicional, entre elas, o tempo demandado, a susceptibilidade à tendência do intérprete (XIE et al., 2015), e ainda, a inacessibilidade de algumas áreas de estudo. Uma alternativa para contornar as desvantagens da saída de campo é a aplicação do Sensoriamento Remoto, visto que rochas carbonáticas apresentam um padrão distinto principalmente na faixa espectral do Infravermelho de Ondas Curtas - *Short Wave Infrared* (SWIR) (PEDROSA; MENESSES; CARMELO, 2010).

Para a indicação de materiais em imagens de satélite, podem ser utilizados modelos de mistura espectral, que tem como função indicar a proporção dos alvos selecionados dentro do pixel (GALO et al., 2002) e os índices espectrais que são relações matemáticas usadas para indicar a presença de feições de interesse (ALEXANDER, 2020). Comparando-os, os índices espectrais têm vantagens aparentes sobre os modelos de mistura devido a sua precisão e praticidade (XIE et al., 2015).

Os índices espectrais são variáveis adimensionais derivadas de equações matemáticas que

incluem a reflectância de duas ou mais bandas espectrais (ALEXANDER, 2020). Além disso, possuem aplicações em diversos campos, como a indicação de vegetação, água, edificações e feições geológicas.

Embora já existam índices espectrais de rochas carbonáticas estabelecidos na literatura, eles apresentam limitações, pois operam em faixas espectrais específicas de sensores obsoletos, ou que não são cobertas pelos principais sensores multiespectrais. Nesta investigação, por meio da metodologia proposta, foi elaborado um novo índice espectral para rochas carbonáticas com parâmetros flexíveis e estabelecidos para imagens do sensor OLI-Landsat 8, oferecendo ao usuário uma possibilidade de adaptação do índice para o seu cenário. Uma vez produzido, o índice pode ser calculado e utilizado como camada extra em representação de afloramentos tanto bidimensionais como tridimensionais, indicando assim a presença de rochas carbonáticas em um local.

O presente trabalho também propõe-se a aplicar um refinamento na seleção e emprego analítico das bandas disponíveis, aplicando análises visuais sobre o comportamento espectral e aprendizado de máquina para mineração de dados, a fim de otimizar a precisão das medidas obtidas sobre afloramentos de rochas carbonáticas, usando como fonte de dados assinaturas espectrais de alta resolução espectral e imagem de satélite.

São investigadas as limitações que os índices espectrais existentes possuem e como poderíamos contorná-las. A hipótese é que o novo índice criado apresente resultados mais robustos e seja adaptável para outros tipos de dados/sensores, quando comparado aos índices já existentes.

Diante disso, esta pesquisa tem como objetivo geral elaborar um novo índice espectral para identificação de materiais compostos por rochas carbonáticas em imagens multiespectrais. E como objetivos específicos:

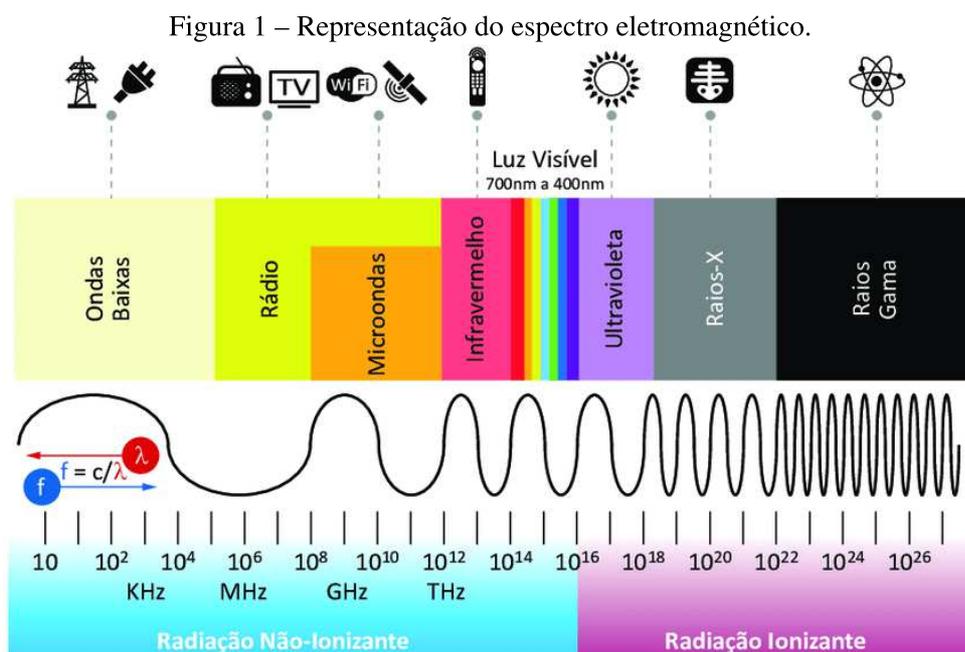
1. Compreender índices espectrais para detecção de materiais carbonáticos já consagrados na bibliografia;
2. Realizar uma análise quantitativa destes índices, avaliando as diferenças entre os resultados alcançados por cada abordagem;
3. Estudar o comportamento de dados imagem que incluam alvos carbonáticos e outros alvos diversos de comparação, através de mineração de dados e gráficos de espalhamento;
4. Elaborar um novo índice espectral que ofereça a possibilidade de ajuste dos parâmetros para diferentes sensores multiespectrais;
5. Aplicar o novo índice em imagem de satélite advinda do sensor OLI-Landsat 8 e validar os resultados encontrados neste estudo, aplicando a análise quantitativa para o mesmo.

## 2 REVISÃO TEÓRICA

O desenvolvimento de métricas, como os índices físicos aos quais este projeto de pesquisa se dedica requer uma ampla carga de inferências e simulações computacionais a fim de testar exaustivamente o desempenho de uma determinada relação matemática robusta e pouco sensível a mudanças sutis de ambientes. Antes de abordar as técnicas de modelagem normalmente utilizadas para esse fim, é fundamental compreender a base teórica e os conceitos envolvidos na aplicação específica, no caso os afloramentos de rochas carbonáticas. Nas subseções que seguem, alguns desses conceitos base serão apresentados.

### 2.1 Características Espectrais de Rochas Carbonáticas

A caracterização de rochas a partir de imagens multiespectrais sempre foi encarada como um desafio para a comunidade do Sensoriamento Remoto. Muito disso reside no fato de que as diferenças entre materiais só costumam ser detectadas em faixas muito estreitas do espectro e em regiões muito específicas (como SWIR e TIR). Uma abordagem que vem ganhando destaque na caracterização de minerais aos quais hidrocarbonetos podem estar associados é a espectroscopia (SCAFUTTO; SOUZA FILHO; OLIVEIRA, 2017; ASADZADEH; SOUZA FILHO, 2016; FERREIRA et al., 2016; LINAJE; KHAN; BHATTACHARYA, 2018). Para que essas análises possam ser realizadas, a espectroscopia tem sido utilizada (LINAJE; KHAN; BHATTACHARYA, 2018) como meio de caracterizar os objetos a partir das taxas de absorção e reflexão da energia eletromagnética (Figura 1) em seus diferentes comprimentos de onda.



Fonte: Costa (2019)

A reflectância dos minerais é estudada em função de uma determinada resolução espectral, geralmente dos 200nm aos 3.000nm (ASADZADEH; SOUZA FILHO, 2016). No caso das rochas carbonáticas, a importância dos estudos espectrais se dá pela possibilidade de se caracterizar os minerais pelo seu nível de reflexão e emissão, por exemplo, separar frações de calcita e dolomita com base nas diferenças de respostas espectrais.

Para as rochas carbonáticas, estudos mostram que a faixa espectral do infra vermelho de ondas curtas (*Short Wave Infrared* – SWIR) é a faixa ideal para a sua caracterização (PEDROSA; MENESES; CARMELO, 2010). A partir da análise espectral de um conjunto de amostras de rochas carbonáticas, Pedrosa, Meneses e Carmelo (2010), concluíram que nos calcilitos, calcarenitos e calcários argilosos, a semelhança espectral é muito próxima, porém, quando aumenta a granulometria ou a presença de argilominerais essa semelhança reduz.

Gaffey (1986) também fez uma caracterização da calcita, dolomita e aragonita a partir das faixas espectrais do visível e infravermelho próximo (*Near Infra Red* – ou NIR). Em seus resultados, o autor coloca que a calcita, a dolomita e o aragonita possuem pelo menos 7 feições de absorção entre os intervalos de 1.600nm e 2.550nm, atribuindo isto a processos vibracionais dos ions de carbonato. Zaini (2019) utilizou de imageamento hiperespectral para caracterizar as propriedades químicas de rochas carbonáticas. A utilização desse tipo de metodologia permite estabelecer uma curva relacionando o nível de reflectância dos alvos ao longo dos comprimentos de onda do espectro.

Crowley (1986) estudou a variação do comportamento espectral de rochas carbonáticas relacionada a impurezas como matéria orgânica, texturas petrográficas, como o tamanho do grão, a partir de informações do espectro visível ao infravermelho próximo (400nm – 2.500nm). Os resultados desse estudo mostram que a matéria orgânica contida nas rochas carbonáticas é um fator preponderante para explicar as variações espectrais. A temperatura espectral por matéria orgânica, provavelmente complicará a detecção remota e as determinações espectrais de laboratório da composição de carbonatos. Por outro lado, variações na temperatura podem revelar-se úteis para distinguir rochas que sofreram condições diagenéticas, térmicas ou outras condições incomuns que afetam o conteúdo da matéria orgânica.

Para a caracterização de rochas carbonáticas, diversas tecnologias de aquisição de dados vêm sendo utilizadas, como sensores orbitais acoplados em satélites e nano-satélites, aeronaves de médio e grande porte com sensores acoplados, drones, tecnologia *Light Detection and Ranging* (LIDAR), além de tecnologia de scanners que utilizam difração de raios-X, espectrorradiômetros, entre outras tecnologias (ZAINI, 2019; BEDINI, 2017; RAMAKRISHNAN; BHARTI, 2015; KURZ et al., 2012).

## **2.2 Sensoriamento Remoto aplicado a Rochas Carbonáticas**

O Sensoriamento Remoto é a área da ciência responsável por estudar a aquisição de informações espectrais de forma remota para posterior análise e interpretação. O termo foi cunhado

por Evelyn Pruitt, uma cientista que trabalhava para o Escritório de Pesquisa Naval da Marinha dos EUA, ao reconhecer que o termo fotografia aérea não descrevia mais com precisão as diversas formas de imagens coletadas usando radiação fora da região visível do espectro. (CAMPBELL; WYNNE, 2011). Quando se fala em Sensoriamento Remoto na área da Geologia, existem duas subdivisões que são estudadas: O Sensoriamento Remoto multiespectral e o Sensoriamento Remoto hiperespectral (RAJENDRAN; NASIR, 2014).

O que diferencia um sensor entre multiespectral e hiperespectral é a capacidade que o sensor possui de captar a energia eletromagnética em diferentes faixas espectrais. Enquanto os sensores multiespectrais mais utilizados atualmente captam dezenas de faixas espectrais, os sensores hiperespectrais captam na ordem de centenas de faixas espectrais.

Os sensores multiespectrais foram os primeiros a ganhar relevância em estudos relacionados a rochas. A série de satélites Landsat, iniciada na década de 1970 pelo governo dos Estados Unidos, se encontra atualmente em seu oitavo satélite (Landsat 8), possuindo 11 bandas espectrais, cobrindo desde os 435nm até os 12.510nm (de maneira não uniforme).

Dados do sensor ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*), sensor este desenvolvido principalmente para aplicações geológicas, foram utilizados para analisar a resposta espectral das rochas carbonáticas em um estudo realizado no Sultanato de Omã, na península arábica (POUR; HASHIM, 2014). No estudo, as bandas ASTER 8 (2,295-2,365 $\mu\text{m}$ ), 4 (1,6-1,7 $\mu\text{m}$ ) e 5 (2,145-2,185 $\mu\text{m}$ ) apresentaram amplo destaque na distinção das rochas carbonáticas em relação aos outros materiais, como rochas hidrotermicamente alteradas e rochas alcalinas intrusivas ultramáficas. Os valores de absorção e reflexão dessas rochas também foram avaliados, de modo a observar as possíveis diferenças entre os minerais.

Outro estudo de Rajendran e Nasir (2014), demonstra e confirma a sensibilidade espectral das rochas carbonáticas. Os carbonatitos têm baixa refletividade nas bandas espectrais ASTER VNIR-SWIR e alta emissividade nas bandas espectrais ASTER TIR devido à ausência de minerais contendo hidroxila e à presença de minerais e carbonáticos. Essa diferença foi notada a partir da interpretação espectral das 14 bandas do sensor ASTER. A técnica elaborada pelo autor, demonstrou ser economicamente viável no mapeamento de áreas com topografia extremamente acidentada ocorrida em regiões áridas, onde é difícil realizar uma amostragem exaustiva e inacessível para o mapeamento geológico convencional.

Outro exemplo de satélite recentemente utilizado para estudos de caracterização espectral de rochas carbonáticas é o Sentinel-2). Ge et al. (2018) utilizou dados do Sentinel-2, sensor MSI (*Multi Spectral Imager*) lançado pela Agência Espacial Europeia (ESA) para classificação litológica em uma região da China. Além deste, também foram utilizados dados do ASTER e do Landsat 8, sensor OLI, especialmente informações contidas no VNIR (*Visible Near*) e no SWIR.

Os sensores hiperespectrais vêm ganhando bastante destaque devido a sua maior resolução espectral (TRANSON et al., 2018), podendo ser utilizados para analisar diferentes ambientes litológicos compostos por carbonatos (POUR; HASHIM, 2014), como o calcário, o karst e as

Tabela 1 – Pico de absorção das rochas carbonáticas conforme sua composição mineral

TIPO	MINERAL	PICO DE ABSORÇÃO (u.m.)				
		1	2	3	4	5
Calcita	Magnesita	2.496	2.305		1.925	1.975
	Dolomita	2.528	2.315	2.145	1.985	1.865
	Calcita	2.528	2.335	2.165	1.195	1.875
	Dialogite		2.365	2.175	2.005	1.895
	Siderite	2.528	2.345		1.925	
Aragonita	Estrôncio		2.345	2.175	2.015	1.885
	Alstonita		2.386	2.205	2.045	1.915
Malaquita	Azurita	2.418	2.365	2.265	2.205	
	Malaquita		2.355	2.285	2.215	2.205

Fonte: Pan (2019)

dolomitas hidrotermais (KURZ et al., 2012). Sensores hiperespectrais são capazes de fornecer uma leitura detalhada das características espectrais dos materiais na superfície, semelhante a um espectroradiômetro. Pan et al. (2019) estuda alterações nas propriedades mineralógicas de rochas carbonáticas a partir do pico de absorção espectral, em dados hiperespectrais, de acordo com a Tabela 1.

Satélites com sensores hiperespectrais também vêm sendo amplamente utilizados, como o EO-1 Hyperion (DUCART et al., 2016), desenvolvido pela NASA (*National Aeronautics and Space Administration*), que permite mapear continuamente no intervalo entre 400nm até 2.500nm, gerando 242 bandas espectrais. Além do instrumento Hyperion, o satélite EO-1 possui mais dois sensores, o ALI (*Advanced Land Imager*) e o AC (*Atmospheric Corrector*) (EARTH OBSERVING-1: TEN YEARS OF INNOVATION, 2010).

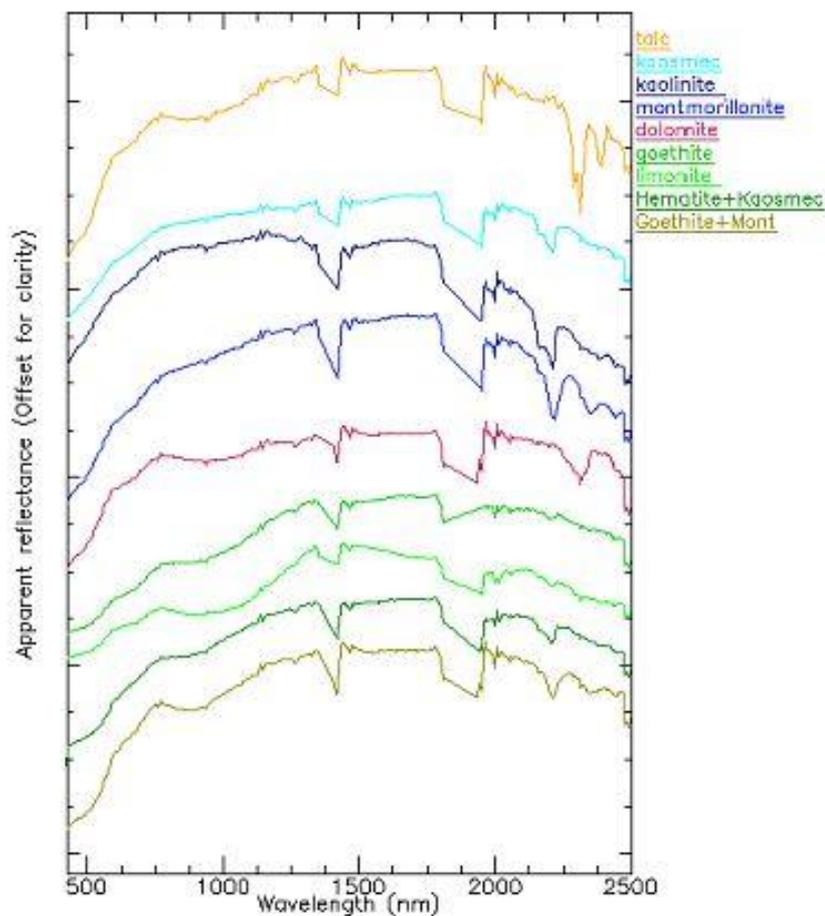
Kumar e Yarrakula (2019) utilizou imagens do Hyperion, juntamente com dispositivos de varredura eletrônica baseados em espectroscopia por raios-X, para determinar a composição química dos calcários analisados e o espectrorradiômetro de campo para determinar o comportamento espectral dos mesmos. Percebeu-se que, devido a concentração de calcita ( $\text{CaCO}_3$ ), o calcário teve uma absorção profunda da energia eletromagnética, entre 2.320nm e 2.34nm, na faixa do SWIR. Essa metodologia foi então adotada para poder melhorar a capacidade de classificação das rochas utilizando imagens do Hyperion.

Sensores hiperespectrais também podem ser acoplados em aeronaves. Um exemplo disso é o AVIRIS (*Airborne Visible/Infrared Imaging Spectrometer*), um projeto lançado pela NASA, consistindo de um instrumento capaz de gerar 224 bandas espectrais, cobrindo continuamente dos 0,4 $\mu\text{m}$  aos 2,5 $\mu\text{m}$ .

Os dados oriundos do AVIRIS possuem diversas aplicações para a Geologia, inclusive na caracterização de depósitos carbonáticos, sendo possível analisar as diferentes faixas de absorção com uma resolução considerável (KINGSTON, 1989). Atualmente, dados do sensor aeroportado AVIRIS-NG (*AVIRIS New - Generation*) vem sendo utilizados para caracterização mineral de rochas carbonáticas. Este sensor opera, no momento atual, fazendo levantamentos apenas no

Estados Unidos. Dados do AVIRIS-NG foram utilizados por Mishra et al. (2019) para aplicações geológicas na parte sudeste dos contrafortes de Aravalli, no Rajastão – Índia. Utilizando imagens espectrais, foi possível identificar diferentes minerais hidrotermalmente alterados que consistem em hidroxila, carbonato e espécies portadoras de ferro. Assinaturas espectrais de minerais (Figura 2) como caulinita-esmectita, talco, caulinita, dolomita e montmorillonita foram discretizados na região SWIR, enquanto minerais contendo ferro, como goethita e limonita, foram identificados no VNIR.

Figura 2 – Reflectância aparente dos diferentes minerais frente aos dados hiperespectrais do AVIRIS – NG.

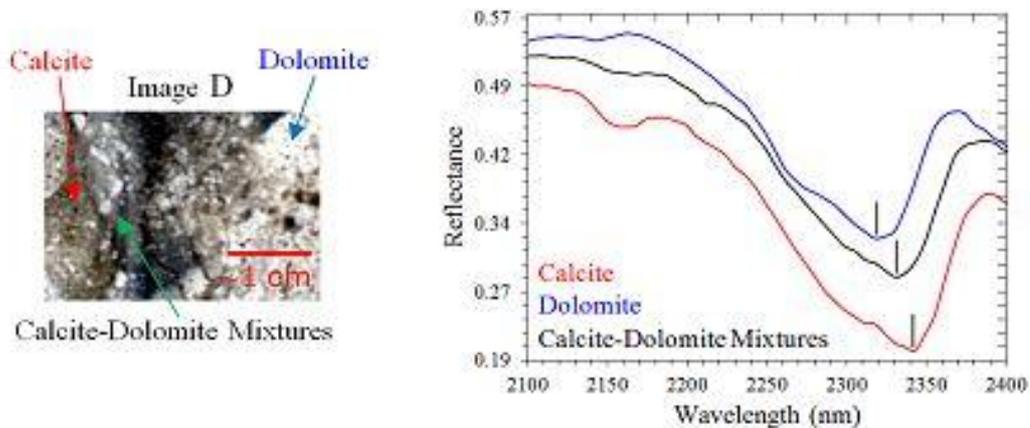


Fonte: Mishra et al.(2019)

Imagens hiperespectrais obtidas em laboratório também vêm sendo amplamente utilizadas para caracterizar a mineralogia e a físico-química das rochas carbonáticas. Sensores como o HyLogger, HySpex-Mjolnir, SisuROCK e o SisuCHEMA são bastante utilizados para geração de imagens hiperespectrais para caracterização de rochas carbonáticas (ZAINI, 2019). Zaini (2019) utilizou imagens hiperespectrais obtidas através do sensor SisuCHEMA, para determinar as proporções dos minerais e a composição química de rochas carbonáticas. A grande vantagem de sensores hiperespectrais de laboratório é que eles têm a capacidade de gerar imagens com resolução espacial milimétrica, tornando-se ideal para mapeamento de pequenas amostras de

rochas carbonáticas.

Figura 3 – Curvas de reflectância de componentes de rocha carbonática.



Fonte: Zaini (2014)

### 2.3 Índices espectrais de carbonatos

Em geral, índices espectrais são indicadores da presença de um determinado material na área coberta por um pixel. Podem ser índices de vegetação, como Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI), água, como Normalized difference Water Index (NDWI), ou índices de neve como Normalized Difference Snow Index (NDSI). Não correspondem à quantidade de um determinado material ou percentual de ocupação deste em um pixel, mas são importantes indicadores da presença desse material em um ambiente.

Por contarem com uma grande quantidade de bandas, as imagens de sensores hiperespectrais precisam receber um tratamento prévio que selecione ou extraia as informações mais importantes contidas no dado. Esse procedimento geralmente se refere a seleção ou extração de feições. A formulação de índices que indiquem a presença de um material específico a partir de um conjunto restrito de bandas espectrais é uma alternativa bastante conveniente e útil para concentrar a informação útil do dado em saídas mais objetivas. A maioria dos índices, normalmente chamados de índices físicos, são derivados de operações matemáticas simples como adição, subtração, multiplicação e divisão entre bandas da imagem. Cada índice terá uma configuração específica dependendo do tipo de material alvo da aplicação. Alguns exemplos de índices para rochas carbonáticas frequentemente encontrados na literatura serão apresentados a seguir.

O primeiro índice a ser apresentado foi proposto por Ninomiya (2002). As propriedades que embasaram este índice foram a característica das rochas carbonáticas (calcita e dolomita) em comparação com a propriedade espectral do quartzo e dos silicatos na faixa termal (Eq. 2.1):

$$CI_1 = \frac{T_{13}}{T_{14}}. \quad (2.1)$$

Embora o índice proposto na Eq. 2.1 tenha provado ser um estimador de carbonato eficaz, as faixas espectrais de interesse são muito estreitas, apenas os canais termais do sensor ASTER são capazes de captar as faixas específicas, e ainda que fosse possível ajustar o índice para outro sensor, há poucos sensores que operam nessa faixa. Como exemplo, os canais TIR do Landsat 8, 10 (10.6 - 11.19  $\mu\text{m}$ ) e 11 (11.50 - 12.51  $\mu\text{m}$ ) estão fora do intervalo em que o índice opera (cerca de 11.3  $\mu\text{m}$ ). Outra limitação desse índice é o tamanho dos pixels nas imagens TIR (90m), o que torna o estudo de pequenas áreas inviável.

Proposto por Xie et al. (2015), o índice descrito na Eq.2.2, foi elaborado com a finalidade de propor a melhor segmentação de regiões incluindo carste - a carstificação é o processo de dissolução química das rochas carbonáticas - por meio da razão entre as bandas azul (Banda 2) e NIR (Banda 5) do sensor Landsat-8. Para os autores o índice se mostrou eficiente na estimativa em ambiente cárstico com uma grande área de exposição.

$$CI_2 = \rho_{blue} / \rho_{NIR}. \quad (2.2)$$

Para a criação do índice proposto na Eq. 2.2, o autor selecionou três componentes em uma imagem, rocha exposta, solo e vegetação. Após coletar visualmente as assinaturas na imagem, ele fez a razão entre as bandas das 3 composições, onde a maior razão resultou no índice, a razão entre azul e NIR. Nessa metodologia o autor está adotando que um pixel com resolução de 30m é uma representação pura das composições selecionadas, no entanto nessa escala é primordial considerar a mistura espectral dos materiais presentes no pixel.

Pei et al. (2018), utilizou dados de imageamento do Landsat 8, sensor OLI (*Operational Land Imager*) para estimar a fração de solo exposto em regiões que apresentam rochas carbonáticas carstificadas no sudoeste da China a partir de um índice chamado *Karst Bare-Rock Index* (KBRI), utilizando informações do NIR e do SWIR:

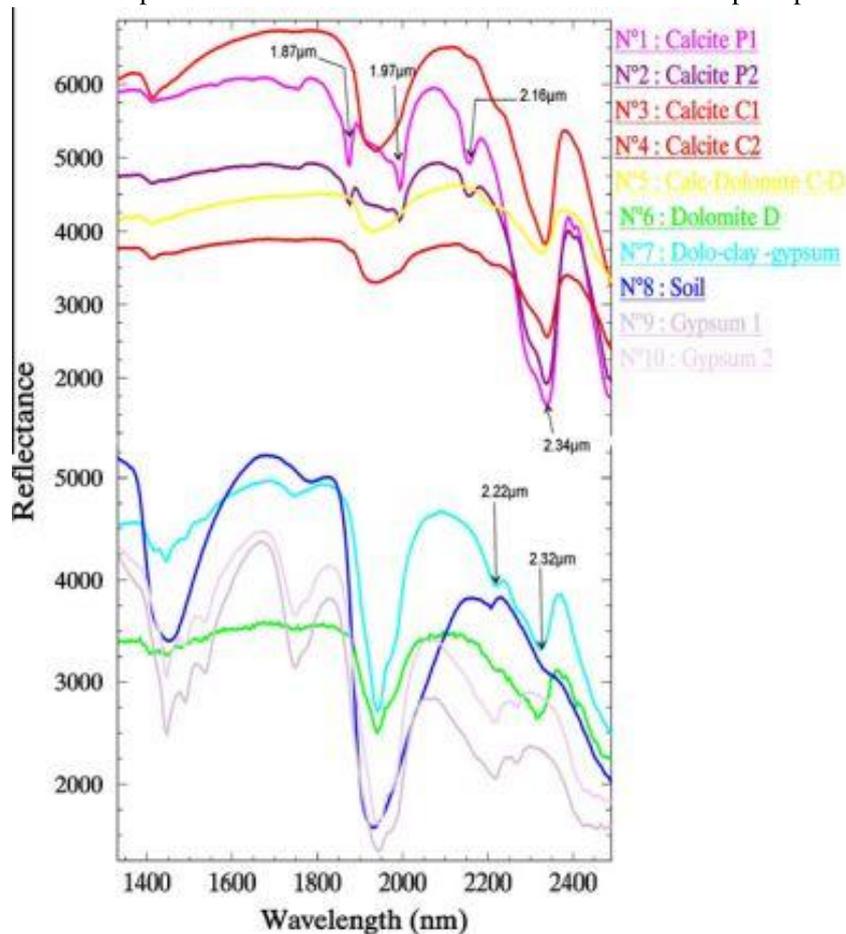
$$CI_3 = \frac{\rho_{SWIR} - \rho_{NIR}}{20 \times \sqrt{\rho_{SWIR} + \rho_{NIR}}}, \quad (2.3)$$

Onde  $\rho_{SWIR}$  é a reflectância no canal do SWIR e  $\rho_{NIR}$  é a reflectância no canal NIR.

Embora o índice proposto na Eq. 2.3 apresente uma maior complexidade na formulação, assim como os índices propostos por Ninomiya (2002) e Xie et al. (2015), a seleção das bandas que compõe o índice foi realizada sobre a análise de reflectância de poucos alvos, e usando dados de baixa resolução espectral e espacial.

Dados do sensor HySpex também vêm sendo utilizados para identificação e mapeamento de minerais em rochas carbonáticas. Baissa et al. (2011) propôs um estudo utilizando pequenas amostras de rochas das fácies carbonáticas (Figura 4) da idade jurássica na Bacia de Agadir, utilizando imagens hiperespectrais fornecidas pela câmera HySpex SWIR-320m, em comprimentos de onda que variam de 1300 a 2500 nm. Foi calculado o Índice de Carbonato de Diferença Normalizada (NDCI) com o objetivo de estudar o aprofundamento da banda de absorção principal de carbonatos.

Figura 4 – Reflectância aparente dos diferentes minerais frente aos dados hiperespectrais do HySpex.



Fonte: Baissa et al., (2011)

Importante salientar que, ainda que sensores hiperespectrais sejam capazes de produzir informações muito detalhadas sobre qualquer material, sua disponibilidade é bastante limitada, resumindo-se apenas a poucos levantamentos que abrangem áreas pequenas. Logo, por mais que a utilização de imagens multiespectrais não seja a alternativa mais precisa, trata-se do dado mais rápido e simples de obter, podendo ser adquirido de forma regular e frequente.

Além dos índices, é possível utilizar uma análise da mistura espectral, para indicação de carbonatos. A mistura espectral tem como função descrever e separar a contribuição de cada material dentro do pixel. Na primeira etapa, a resposta espectral de cada material puro é recolhida em cada banda de interesse (GALO et al., 2002). Posteriormente, a partir de cada valor é possível modelar o espectro de cada pixel de uma imagem multiespectral como uma combinação linear de cada um dos materiais selecionados (SHIMABUKURO; SMITH, 1991). Essa abordagem pode ser utilizada para fins de comparação, porém, demanda maior envolvimento do usuário e conhecimento dos materiais disponíveis na cena, os quais precisam ser apontados de forma exaustiva.

## 2.4 Simulação de bandas

A simulação de bandas é uma forma de obter dados espectrais relevantes, pois ela permite gerar com precisão as características dos dados advindos do sensor (METZ et al., 2020).

A simulação de bandas de sensores pode ser feita a partir de dados hiperespectrais, sendo também considerada a função resposta do sensor (SFR) (BERNARDO, 2015), e ainda, que haja sobreposição espectral dos dados e as bandas a serem simuladas.

A função de resposta espectral de um sensor (SRF) define a sensibilidade de um sensor em detectar um fóton em uma determinada frequência (OTAZU et al., 2005).

Um exemplo de sensor que disponibiliza a função resposta de cada uma das suas bandas é o OLI (Operational Land Imager), a bordo do satélite Landsat 8. O resultado do processo é normalmente correlacionado aos dados de imagem do sensor. Entretanto este processo não considera as condições climáticas da aquisição da imagem e nem integra correções atmosféricas. Essa característica leva à necessidade de normalização quando comparamos os dados simulados com aqueles originalmente adquiridos pelo sensor.

## 2.5 Mineração de dados por CART - *Classification and Regression Tree*

Árvores de decisão são comumente aplicadas para classificar conjuntos de dados ou realizar regressão. É possível encontrar classificadores baseados em árvore de decisão nos principais softwares de geoprocessamento. O processo de fabricação da árvore inclui mineração de dados com algoritmos intuitivos que apontam de forma hierárquica quais são as feições que apresentam maior separabilidade entre as classes de interesse (ARVOR et al., 2013).

A mineração de dados é o processo de descoberta de padrões de grandes volumes de dados, envolvendo normalmente a limpeza, integração, seleção e transformação destes dados. Apresentado uma crescente demanda, a mineração de dados é parte da evolução da tecnologia da informação (HAN; KAMBER; PEI, 2011). Um grande número de algoritmos de mineração de dados vêm sendo desenvolvidos para executar diferentes tarefas de análise de dados, sendo o CART um dos principais e mais influentes destes algoritmos (WU et al., 2008).

Na década de 80, a monografia de Breiman et al. (1984) - “*CART: Classification and Regression Trees*”, se tornou uma significativa referência para a evolução da inteligência artificial, aprendizado de máquina, estatísticas não-paramétricas e mineração de dados (WU et al., 2008). CART foi a primeira árvore de decisão a ser descrita com rigor analítico e fundamentada pela teoria de probabilidade e estatísticas sofisticadas (STEINBERG, 2009).

A árvore de decisão CART é um procedimento de particionamento recursivo binário que processa atributos nominais e contínuos como preditores e alvos. Os dados são tratados na sua forma bruta e começam a ser divididos a partir do nó raiz em dois filhos e cada um destes então, é dividido em netos, e assim por diante. O crescimento da árvore até seu tamanho máximo ocorre sem uma regra de parada, ela somente para de crescer caso nenhuma divisão nova seja

possível devido à falta de dados (WU et al., 2008; STEINBERG, 2009).

Árvores de decisão podem se apresentar de forma bastante ramificada dependendo do número de classes e da complexidade da separação. Devido a isso, existe a possibilidade de generalização do resultado para que a regra torne-se mais simples e o fenômeno do sobreajuste seja evitado. Essa generalização é popularmente conhecida como poda. Na poda, as ramificações secundárias são removidas a fim de otimizar o processo de decisão. A escala com a qual esse processo ocorre pode ser definida pelo usuário. Na presente, o algoritmo CART de mineração será utilizado para estudar a separabilidade das rochas carbonáticas quando comparada a materiais normalmente presentes no problema.

A poda da árvore de tamanho máximo, a mesma ocorre através do método de complexidade de custo em que as divisões que são menos eficientes para o desempenho geral da árvore são removidas. Desta forma, o mecanismo CART produz uma sequência de árvores podadas aninhadas. A partir dos dados de testes independentes (ou por validação cruzada) do desempenho de cada árvore na sequência, a árvore “honestas”, ou do ‘tamanho certo’, é selecionada. Sem o teste ou a validação cruzada o CART se torna incapaz de selecionar a melhor árvore na sequência (STEINBERG, 2009).

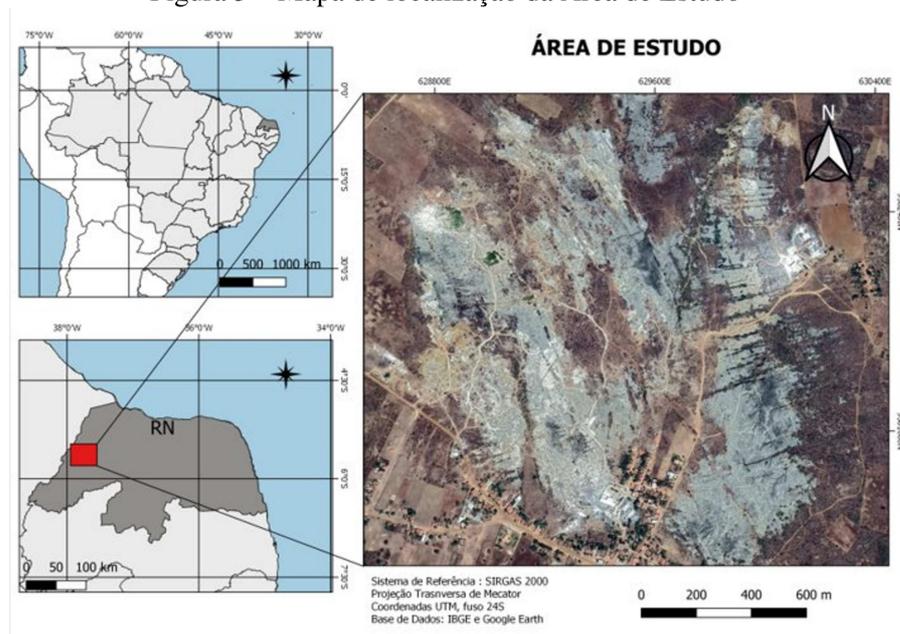
### 3 MATERIAIS E MÉTODOS

A pesquisa proposta nesse trabalho foi criada dentro do contexto do Vizlab | X-Reality and GeoInformatics Lab, que é um laboratório de pesquisa em X-Reality (realidades mistas) e geoinformática. O laboratório trabalha com uma equipe interdisciplinar no desenvolvimento de soluções tecnocientíficas.

#### 3.1 Área de Estudo

A área de estudo (Figura 5) situa-se no sítio arqueológico chamado Lajedo Soledade, pertencente ao município de Apodi, a 80 quilômetros de Mossoró, no Rio Grande do Norte - Brasil. Geologicamente se tratando, o Lajedo Soledade pertence a seção inferior da Formação Jandaíra, inserido a porção superior da Bacia Potiguar (BAGNOLI, 1994) e pertencente ao Cretáceo Superior, sendo depositadas no final deste período.

Figura 5 – Mapa de localização da Área de Estudo



Fonte: Elaborada pela autora.

A bacia Potiguar situa-se na costa do nordeste do Brasil, e ocupa em sua porção emersa e submersa parte setentrional dos estados do Rio Grande do Norte e do Ceará. Tem como área aproximadamente  $48.000 \text{ km}^2$ , com cerca de  $21.000 \text{ km}^2$  referente à porção emersa e  $27.000 \text{ km}^2$  representando a porção submersa de plataforma e talude continental (PESSOA NETO et al., 2007). Esta bacia tem sua evolução tectono-sedimentar relacionada ao embasamento Pré-Cambriano do Gondwana e as tensões ocorridas durante a sua separação (PESSOA NETO et al., 2007). Desta forma, é diferenciada em três super-sequências. A primeira Super-sequência é denominada de Rifte, que teve sua deposição no Cretáceo inferior, dando origem a sedimentos

de origem fluvio-deltaicos e lacustres das formações Pendência e Pescada (SOARES; ROSSETI; CASSAB, 2003), conforme deu-se a evolução do rifte, a segunda super-sequências é chamada de Pós-Rifte, que contem os registros sedimentares que indicam a passagem gradual entre os sistemas continentais e marinhos, e são compreendidos como Formação Alagamar (PESSOA NETO et al., 2007); e por fim a Super-sequência Drifte, sendo esta é marcada por mecanismos termais e isostáticos, caracterizados por uma sequência flúvio-marinha transgressiva onde estão inseridas as formações Açú, Ponta do Mel, Quebradas, Ubarana e Jandaíra alvo de estudo deste trabalho (PESSOA NETO et al., 2007).

A formação Jandaíra é composta por rochas sedimentares carbonáticas marinhas, caracterizadas por ambientes de águas rasas e agitadas (TIBANA; TERRA, 1981). Possui espessuras distintas em diferentes pontos da bacia, podendo apresentar espessuras de 30 m na região de Upanema e superiores a 600m na região de Apodi, sendo a menor espessura em direção às águas profundas em razão do processo erosivo e a maior porção da plataforma interna atual (PESSOA NETO et al., 2007)). Ainda é composta por calcirruditos, calcarenitos e cacilutitos bioclásticos, depositados no contexto de plataforma carbonática dominada por maré, refletindo ambiente marinho com predominância de águas rasas, com desenvolvimento de planícies de marés e lagunares e que desta forma contribuiu para uma rica e diversificada associação fóssilífera. Há também registros de fácies sedimentares de ambientes de alta energia, como *shoals* oolíticos e de água profunda (PESSOA NETO et al., 2007; OLIVEIRA et al., 2013). Estas rochas foram densamente fraturas pelos esforços distensivos, o que possibilitou a dissolução das rochas produzido zonas extensamente expostas e profundas, com cavernas e fendas que chegam até 8 metros de profundidade. Estas zonas acabam gerando drenagens direcionais que possibilitaram a deposição de fósseis e a exposição de grande diversidade de feições geológicas que mostram os diversos momentos de evolução da bacia tornando o Lajedo Soledade um dos mais importantes sítios arqueológicos brasileiros e de grande prestígio geocientífico.

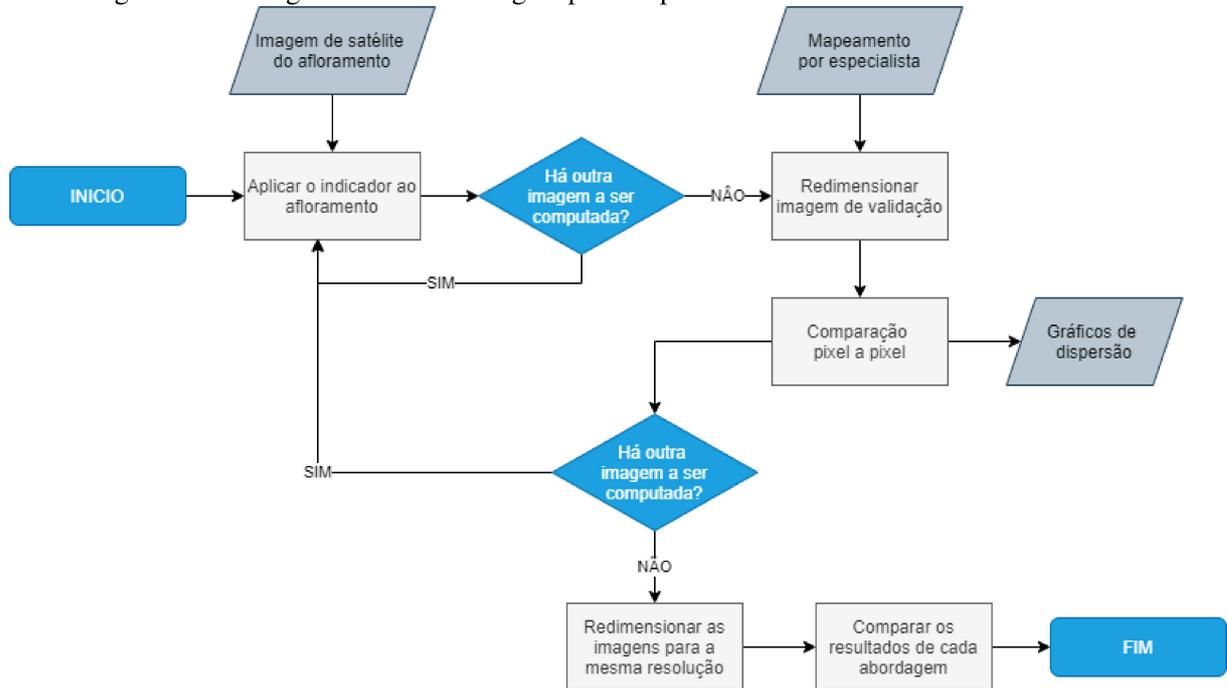
### **3.2 Análise quantitativa dos indicadores de carbonato**

Com o objetivo de entender o potencial dos índices carbonáticos, avaliar a adequação da proposta e apropriação do tema específico, um estudo com índices que aparecem com maior frequência na literatura recente foi conduzido. A avaliação foi realizada em termos de comparação dos índices selecionados aplicados para a área de estudo.

A análise resultante do trabalho preliminar foi publicada em formato de artigo e pode ser consultada em Muller et al. (2020). A Figura 6 mostra as principais etapas da metodologia aplicada neste tópico.

Primeiramente, foram selecionados os indicadores, sendo eles, um Modelo Linear de Mistura Espectral (MLME) e os três índices espectrais (SI) de rochas carbonáticas propostos por Ninomiya (2002), Pei et al. (2018) e Xie et al. (2015), que contemplam o espectro eletromagnético do visível ao TIR.

Figura 6 – Fluxograma da metodologia aplicada para análise dos indicadores de carbonato



Fonte: Elaborada pela autora.

A mistura espectral tem como função descrever e separar a contribuição radiométrica de cada material dentro do pixel. Na primeira etapa, identifica-se cada material presente na cena e define-se a resposta espectral pura desse material, chamada de componente pura ou *endmember* (GALO et al., 2002). Posteriormente, é possível modelar o espectro de cada pixel de uma imagem multiespectral como uma combinação linear de um conjunto finito de componentes (SHIMABUKURO; SMITH, 1991).

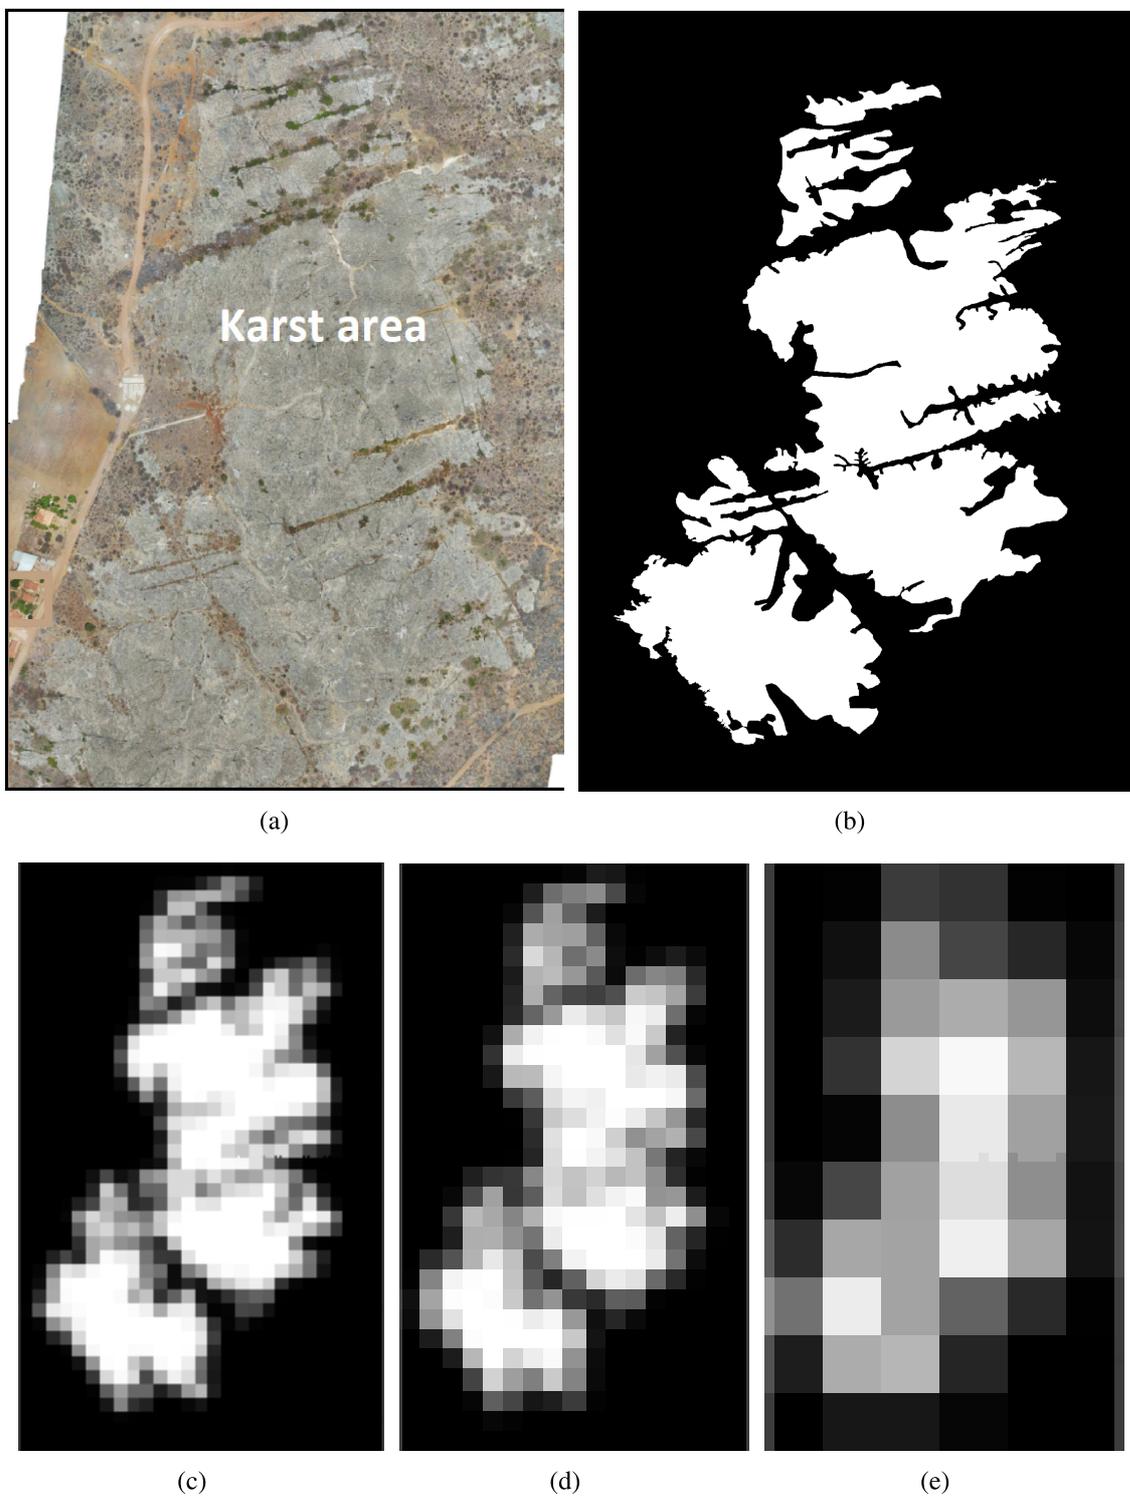
Os indicadores selecionados foram aplicados em imagens multiespectrais distribuídas gratuitamente. Os dados de imagem utilizados foram um MSI-Sentinel-2B, um ASTER-TERRA e um OLI-Landsat-8 adquiridos em 02 de novembro de 2018, 27 de novembro de 2018 e 21 de novembro de 2018, respectivamente.

Uma equipe de pesquisadores do Vizlab visitou a área de estudo no dia 17 de outubro de 2019 com o objetivo de mapear o afloramento por meio de um levantamento aerofotogramétrico. A partir da Ortofoto gerada, foi feita uma vetorização em alta resolução do material carbonático exposto, estabelecendo assim o Ground Truth (GT).

Para comparar o resultado da aplicação dos indicadores com o GT, foi necessário re-amostrar os pixels do GT para o tamanho de cada uma das imagens, como mostra a Figura 7. Desta forma, os índices computados foram comparados diretamente com cada versão correspondente do GT criado. Dessa forma, em cada escala, a quantidade de material carbonático presente no pixel foi determinada pelo percentual de área ocupada segundo o GT original. Na prática, uma degradação da resolução pela interpolação bilinear foi suficiente para executar a tarefa.

Para comparação e validação dos resultados foram feitas análises pixel a pixel, de modo

Figura 7 – (a) Área do afloramento (região cinza clara) composta principalmente por calcita com algumas áreas de dolomita. (b) O GT gerado a partir da interpretação visual auxiliada por um especialista na área. (c), (d), (e) GT correspondente de (b) redimensionado para combinar com tamanhos de imagens diferentes usadas como entrada, 44x27 (Sentinel-2B), 29x17 (Landsat-8) e 10x6 (ASTER-TERRA) , respectivamente



Fonte: Elaborada pela autora.

que a verdade de campo (ortofoto) e os valores gerados pelos índices, pudessem ser avaliados. Essa avaliação foi realizada a partir das métricas de Coeficiente de Determinação (R<sup>2</sup>) e Matriz de Confusão. A primeira métrica analisou qual seria o nível de proximidade entre o GT e os indicadores computados, enquanto a segunda promoveu uma análise de similaridade entre os indicadores propostos.

Os valores foram gerados redimensionando cada estimativa dos indicadores para a menor resolução espacial disponível (ASTER, 60m) e, em seguida, comparadas duas a duas. Desta forma, os resultados foram organizados em gráficos de dispersão, confrontando os índices e a porcentagem ocupada pelo material carbonático, de acordo com a imagem de referência, pixel por pixel.

### **3.3 Elaboração de um novo índice espectral de Rochas Carbonáticas**

Os índices analisados apresentaram resultados bastante variados de acordo com o estudo preliminar realizado. O índice que mais se aproximou do dado utilizado como referência foi aquele que utilizou em sua formulação bandas do visível, infravermelho próximo e infravermelho de ondas curtas. Esses resultados indicam um maior potencial em índices que empregam bandas nessas faixas espectrais para a formulação de um indicador específico para carbonatos presentes em afloramentos.

A abordagem escolhida nesse trabalho utiliza métodos de simulação computacional para produzir faixas espectrais (bandas) sintéticas a partir de dados hiperespectrais, incluindo na análise tanto variações de largura das faixas, como combinações de faixas diferentes com operações matemáticas diversas, procurando alcançar um resultado satisfatório e ao mesmo tempo robusto. Ou seja, que não sofra com sobre-ajuste e seja aplicável em outros ambientes similares apresentando resultados convincentes.

Esta subseção é dividida em duas etapas, sendo a primeira de estudo e emprego analítico que foi dado de acordo com a análise de reflectância dos objetos, aplicação de mineração de dados e análise do espalhamento dos elementos no espaço espectral, e a segunda dedicada à modelagem matemática do índice.

Uma equipe de pesquisadores do Vizlab, durante uma visita à Universidade Federal do Rio Grande do Norte (UFRN), realizada em 29 de maio de 2019, teve acesso a um conjunto de 19 amostras de rochas carbonáticas coletadas na área de estudo. Nesse conjunto de amostras foram coletadas as leituras espectrais por meio do espectroradiômetro Spectral Evolution SR-3500. O equipamento opera nos comprimentos de onda entre 350 e 2.500nm do espectro eletromagnético, ou seja, atinge as regiões do visível ao SWIR, discretizando o espectro em faixas com o intervalo de 1,6nm.

Uma das vantagens de se usar o espectrorradiômetro, além da resolução espectral, é que por se tratar de uma medida realizada diretamente na amostra, a leitura não recebe interferência atmosférica ou de iluminação, sendo assim, obtém-se diretamente a reflectância da superfície

do alvo.

### 3.3.1 Estudo e emprego analítico das bandas espectrais para identificação de rochas carbonáticas

Nessa seção, é importante destacar a essencialidade de conhecer o dado para propor um índice espectral, então optou-se por identificar as zonas de corte entre a classe carbonática e todas as demais classes eventualmente presentes no problema, definir as bandas com maior potencial de separação, e também, estudar como os dados se comportam em maior detalhe.

#### 3.3.1.1 Análise de reflectância dos objetos

As leituras realizadas pelo espectroradiômetro são analisadas quanto às distinções apresentadas pelas assinaturas espectrais, as distinções podem ser utilizadas para classificação dessas rochas a partir de imagens hiperespectrais. Entretanto, muitas feições que diferenciam entre algumas espécies de rocha quando se conta com um grande número de bandas são bastante sutis e dificilmente são percebidas por sensores multiespectrais com poucas bandas. Apesar disso, a diferenciação entre rochas e outros materiais como solo, vegetação, água, entre outros, pode ser realizada analisando-se caso a caso. Dito isso, um dos especialistas que visitou a área de estudo, relatou a presença de quartzo e feldspato alcalino nas ravinas do afloramento, e ainda, como se trata de uma região que sofre com períodos de seca, não apresenta grandes áreas cobertas por vegetação.

Sendo assim, além das leituras espectrais das rochas carbonáticas, foram selecionadas em bibliotecas espectrais públicas as assinaturas espectrais dos outros alvos presentes no afloramento, como de solo, outros minerais, vegetação verde e seca, água e alvos antrópicos, como asfalto e telhado. Assim, a assinatura espectral de outros alvos, além de rochas carbonáticas, alimentou o modelo matemático por meio da análise do comportamento da resposta de alvos que ele deve desconsiderar na indicação de carbonatos. A escolha dos outros minerais que integram o modelo foi feita a partir da identificação de minerais no afloramento, minerais que ocorrem próximos à afloramento carbonáticos e minerais abundantes e comuns de serem encontrados na superfície terrestre, foram eles: quartzo, albita, caulinita, muscovita, barita e alunita.

#### 3.3.1.2 Análise da mineração de dados por CART

Por meio das assinaturas espectrais coletadas nas bibliotecas, foi possível realizar a primeira análise dos canais que melhor discretizam o material carbonático dos outros alvos, tal análise foi feita visualmente com as assinaturas plotadas em um mesmo gráfico.

Para realizar a simulação das bandas do sensor OLI, foi necessário considerar a Função de Resposta do Sensor (SFR), os dados de SFR do sensor OLI estão disponíveis no site da NASA

Figura 8 – Resoluções espectrais abordadas na metodologia



Fonte: Elaborada pela autora.

(SPECTRAL RESPONSE OF THE OPERATIONAL LAND IMAGER IN-BAND, BAND-AVERAGE RELATIVE SPECTRAL RESPONSE, 2014).

No entanto, antes de aplicá-los na simulação das bandas, foi necessário re-amostrar os dados de SFR, visto que o intervalo espectral das informações do SFR é de 1nm, diferente dos dados coletados pelo espectrorradiômetro, que tem intervalos de 1,6nm. Para re-amostrar os dados, foi utilizado a interpolação linear, que utiliza a média ponderada dos valores originais que se encontram ao redor do valor a ser calculado, como mostra a Eq. 3.1:

$$y = y_0 + (x - x_0) \frac{y_1 - y_0}{x_1 - x_0} \quad (3.1)$$

A partir dos dados coletados com o espectrorradiômetro (hiperespectral) e os dados do SFR do sensor OLI reamostrados, é possível realizar a simulação das faixas realizando a ponderação dos dados. A simulação também foi aplicada aos dados selecionados em bibliotecas espectrais (assinaturas de outros minerais, solos, alvos antrópicos, vegetação e água), entretanto como o intervalo espectral entre as bandas das assinaturas é igual ao do SFR original, não foi necessário aplicar nenhuma interpolação. Para realizar a simulação das bandas do sensor OLI-landsat 8 foi aplicada a Eq. 3.2 proposta por Barsi et al. (2014).

$$R_s = \frac{\int_{x_{min}}^{x_{max}} R \cdot SFR \cdot dx}{\int_{x_{min}}^{x_{max}} SFR \cdot dx} \quad (3.2)$$

Onde  $x$  é o comprimento de onda da banda,  $R$  é a reflectância do dado a ser simulado (assinaturas colhidas) e  $SFR$  é o valor da função de resposta do sensor.

Como o presente estudo se propõe a avaliar o emprego de índices para afloramentos de rochas carbonáticas, é preciso considerar todas as condições de cada ambiente como quantidade

de alvos, escala e resoluções, para a determinação do índice. Nesse processo, foram empregados conceitos de modelagem computacional e aprendizado de máquina.

Nesse sentido, foi aplicado ao conjunto de dados uma classificação por CART com a finalidade de selecionar pelos primeiros níveis das árvores, os nós (bandas espectrais) que melhor destacam a refletividade das rochas carbonáticas. As árvores de decisão foram implementadas dentro da plataforma O Colaboratory ou "Colab" que permite escrever códigos em Python de modo a ter uma GPU de acesso gratuito. As classificações foram compiladas a partir da biblioteca *sklearn* na versão 0.24 desenvolvida pelos pesquisadores Pedrosa, Meneses e Carmelo (2010), utilizando o comando "Decision.Tree".

A construção do modelo para o conjunto de assinaturas simuladas foi feita utilizando 3 cenários supostos e dividindo os dados entre classe rochas carbonáticas e classe não-rochas carbonáticas. Para o primeiro cenário, foi visto no GT estabelecido na análise quantitativa, que a área de estudo que o afloramento carbonático representa aproximadamente 65% da área de cobertura, então os indivíduos foram divididos em 19 para rochas carbonáticas e 10 para a classe de outros elemento. A fim de testar a estrutura da árvore, mais dois cenários foram propostos, um cenário mantendo a distribuição, mas variando os elementos da segunda classe e outro de 65% para a classe de outros elementos e 35% para rochas carbonáticas.

A classificação por CART também foi empregada à uma imagem Landsat-8. Os dados de imagem utilizados foram de reflectância de superfície do sensor OLI-Landsat 8 adquirida em 23 de novembro de 2018. Antes de aplicar a classificação a imagem passou por um tratamento visto que as imagens Landsat vem codificadas em valor numérico (número digital - DN) e separa em camadas para cada banda, foi necessário convertê-los para reflectância, para realizar o processo de mesclagem e conversão, foi utilizado o software QGIS e para obter os parâmetros e fórmulas de conversão dos dados foi utilizado o guia de produtos Landsat 8 disponível no site da NASA (LANDSAT 8 DATA USERS HANDBOOK NOW AVAILABLE, 2015). A Classificação deu-se respeitando as classes definidas para o conjunto de assinaturas.

O algoritmo foi utilizado com a finalidade de minerar os dados e individualmente a cada conjunto, para aplicá-lo as informações foram divididas em 70% para treinamento e 30% para teste. Depois de treinar o modelo para cada conjunto, foram geradas as árvores de decisão e a partir da análise da estrutura da árvore foi possível extrair as bandas que melhor discretizaram as rochas carbonáticas entre os dados das assinaturas coletadas para compor o índice.

### 3.3.1.3 Análise do espalhamento das classes no espaço espectral

Uma outra análise exploratória abordada foi a análise do espalhamento das classes no espaço espectral entre duas bandas. Para isso, foram feitos gráficos de dispersões comparando duas a duas as bandas espectrais tanto para os pixels das imagens, quanto para as assinaturas simuladas. Essa análise mostra qual combinação discretiza melhor os pontos de rochas carbonáticas no espaço espectral, em outros termos, a análise expõe a combinação de bandas que melhor agrupa

os pontos de rocha carbonática no espaço espectral e que conjuntamente os separa de outros alvos diversos.

É essencial que a metodologia considere ambos espaços espectrais (imagem e assinaturas) nesta análise, vez que a imagem apresenta um cenário de mais mistura espectral dos elementos, engloba uma menor quantidade de alvos e alvos restritos ao ambiente específico. Já nas assinaturas há uma minimização das misturas espectrais e a permissão de analisar o comportamento das rochas carbonáticas frente a assinaturas que não estão presentes na área de estudo mas que podem estar em outros ambientes.

O processo de seleção das bandas espectrais que melhor discretizam as rochas carbonáticas, portanto, foi dado em três diferentes análises, sendo elas: A análise da reflectância dos alvos de interesse e de não interesse, a interpretação da estrutura da árvore de classificação gerada para a imagem OLI-Landsat 8 e para as bandas simuladas, e por último, o espalhamento dos pontos de acordo com a reflectância no espaço espectral combinando as bandas duas a duas.

### 3.3.2 Modelagem do índice espectral para rochas carbonáticas

Mediante a interpretação do gráfico de espalhamento das bandas espectrais selecionadas, é possível definir a região espectral onde há uma concentração das rochas carbonáticas e ao mesmo tempo uma separação dos outros elementos, sendo assim, foram desenhadas sobre o gráfico isolinhas. As isolinhas funcionam como curvas de níveis que orientam a modelagem do índice, graficamente isso corresponde a destacar as regiões de interesse em níveis a partir de um centro de incidência do objeto.

Após determinada as isolinhas, um modelo matemático foi ajustado usando uma calculadora gráfica 3D, o Math3d, onde pontos da classe de rochas carbonáticas foram plotados em um sistema cartesiano tridimensional. A definição do índice deu-se partir de diversas operações matemáticas ajustando uma superfície aos pontos do gráfico sobre o espaço espectral das bandas selecionadas. O processo se deu de acordo com o que foi previsto em Verstraete e Pinty (1996). Vale ressaltar que é interessante modelar índices espectrais partindo de funções de menor complexidade, vez que a formulação e o ajuste dos parâmetros do índice tornam-se de mais fácil entendimento para o usuário.

Para promover a validação, o índice elaborado foi submetido a mesma análise pixel a pixel descrita anteriormente para os experimentos de avaliação dos índices selecionados para estudo prévio, sendo computado para a imagem Landsat 8 utilizada na análise e não para imagem que alimentou a modelagem do índice.



## 4 ANÁLISE DOS RESULTADOS E DISCUSSÕES

Os resultados expostos nesse capítulo foram divididos em duas seções, a primeira referente a seção 3.2 Análise quantitativa de indicadores de carbonatos do capítulo de Materiais e Métodos e a segunda refere-se a seção 3.3 Elaboração de um novo índice espectral de Rochas Carbonáticas.

### 4.1 Análise quantitativa dos indicadores

Como era esperado, houveram discordâncias entre os indicadores e os dados de imagem, os indicadores selecionados eram incompatíveis à resolução espectral de algumas imagens. Desta forma, o índice baseado nas faixas termais pode ser aplicado apenas para dados ASTER, o índice baseado no NIR e visível foi aplicado para dados do Landsat e Sentinel, o KBRI para dados do Landsat e o LSMM foi aplicado a dados do Landsat e Sentinel.

Embora as formulações selecionadas sejam muito diferentes umas das outras, era esperado inicialmente que elas apresentassem resultados semelhantes, indicando a presença de rochas carbonáticas. Entretanto, os resultados mostram uma discordância considerável entre as medições selecionadas e o GT. A Figura 9 expõe essa discordância e também apresenta as imagens computadas de cada abordagem.

O índice termal calculado para o ASTER, proposto por Ninomiya (2002), mostrou correlação moderada (R) quando comparada à verdade de campo. O índice sugerido por Pei et al. (2018), baseado nas regiões NIR e SWIR, apresentou uma correlação muito fraca com o GT. Por outro lado, o índice NIR visível sugerido por Xie et al. (2015) apresentou uma alta correlação com os dados de referência para ambos, Landsat e Sentinel. Em relação ao LSMM computadas para Landsat e Sentinel, os resultados foram positivos, porém não tão precisos quanto o índice NIR visível.

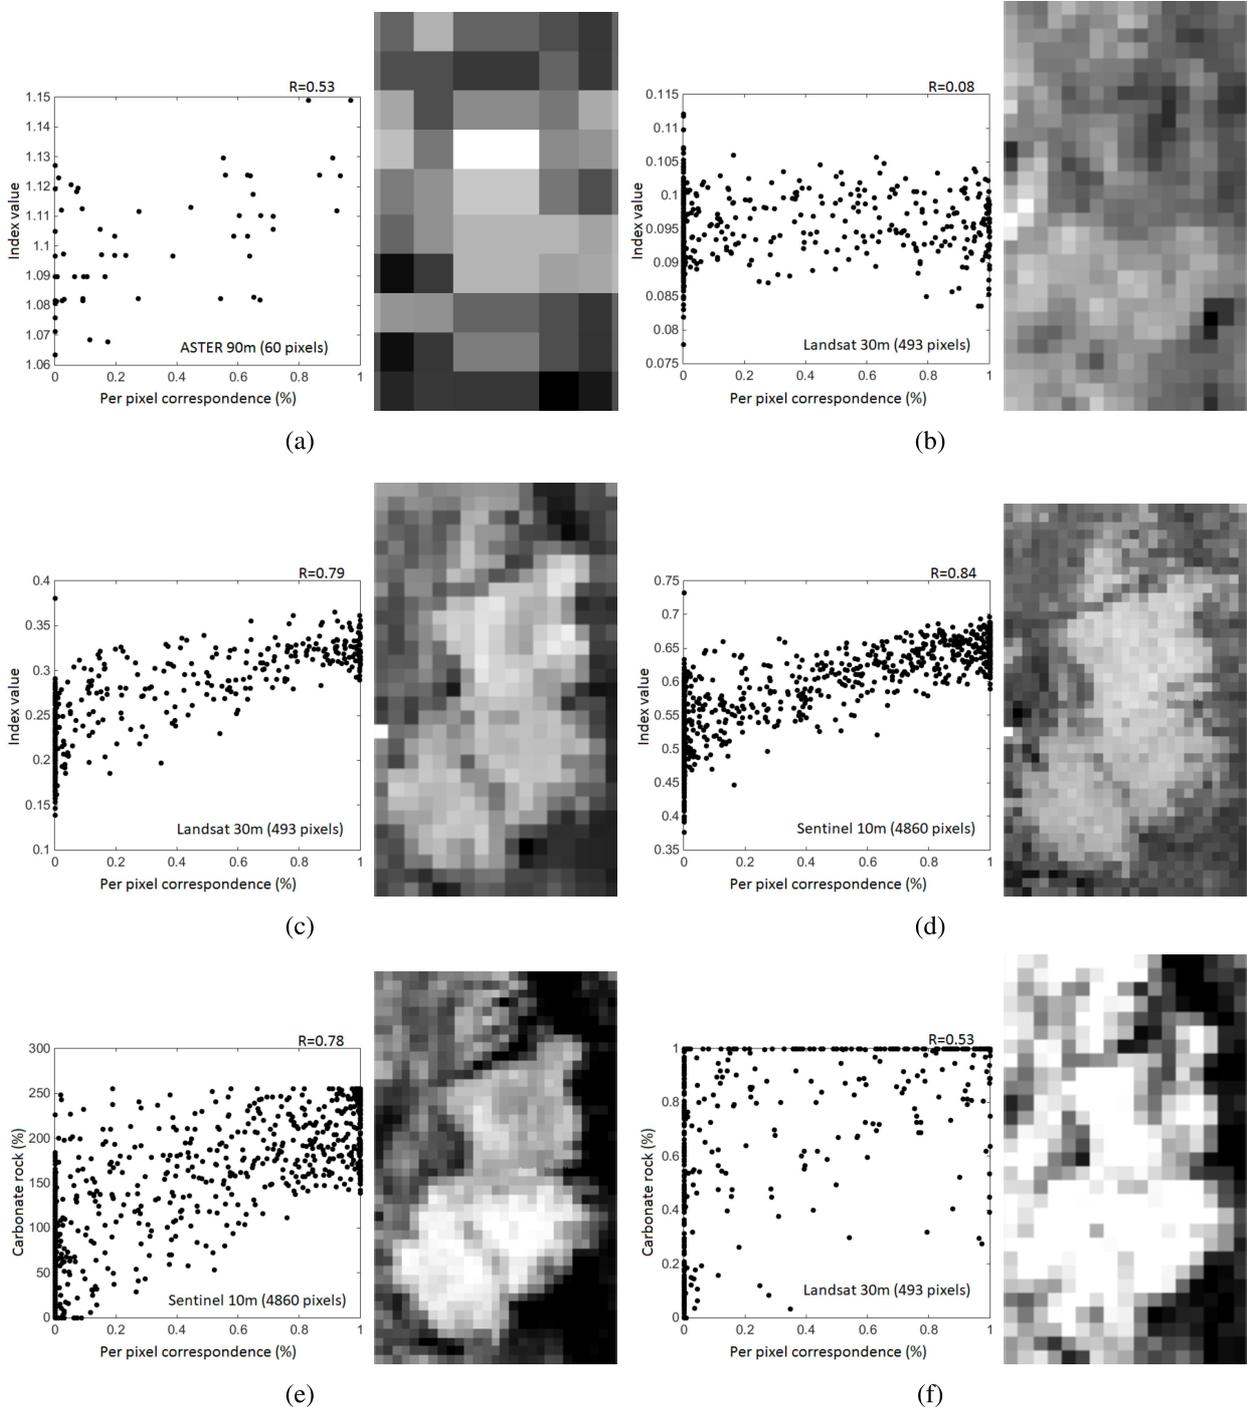
A Tabela 2 mostra a relação entre os resultados alcançados por cada abordagem.

Os resultados mostraram o melhor desempenho de acordo com o GT, alcançados pelo índice com base nos canais visível e NIR. A forte dissimilaridade encontrada entre as formulações selecionadas alerta para o uso cuidadoso dos índices e sugere mais estudos, incluindo variações da área de estudo. O desempenho do índice usando os canais visível e NIR e a consistência

Tabela 2 – Comparação entre os resultados alcançados por cada abordagem.

	$C_1$ -ASTER	$C_3$ -OLI	$C_2$ -OLI	$C_2$ -SEN	LSMM-SEN	LSMM-OLI
$C_1$ -ASTER	1	-0.02	0.53	0.6	0.44	0.37
$C_3$ -OLI	-0.02	1	0.26	-0.008	0.55	0.73
$C_2$ -OLI	0.53	0.261	0.92	0.91	0.81	
$C_2$ -SEN	0.6	-0.008	0.92	1	0.8	0.59
LSMM-SEN	0.44	0.55	0.91	0.8	1	0.89
LSMA-OLI	0.37	0.73	0.81		0.89	1

Figura 9 – Gráficos de dispersão entre os indicadores e o GT e as imagens computadas para cada indicador. (a) ASTER - TIR Eq. (ref eq: 1), (b) Landsat - KBRI (Eq. ref eq: KBRI), (c) Landsat - NIR visível (Eq. ref eq: CRI1), (d) Sentinel - NIR visível (Eq. ref eq: CRI1), (e) Sentinel - LSMM, (f) Landsat - LSMM



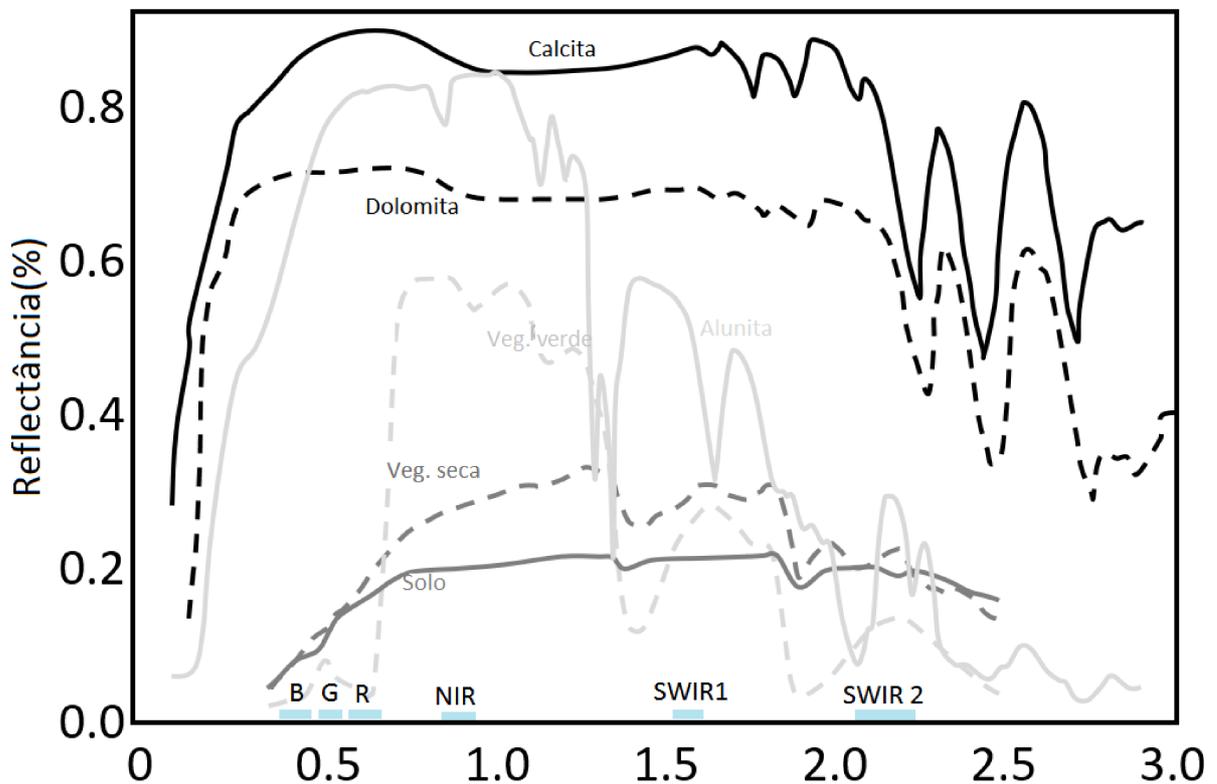
entre a aplicação nas imagens Landsat e Sentinel indicam a adequação desse índice espectral.

## 4.2 Elaboração de um novo índice espectral de Rochas Carbonáticas

### 4.2.0.1 Análise de reflectância dos objetos

A análise de reflectância dos objetos de interesse ocorreu em gráfico de linha, conforme mostra a Figura 10:

Figura 10 – Reflectância dos alvos



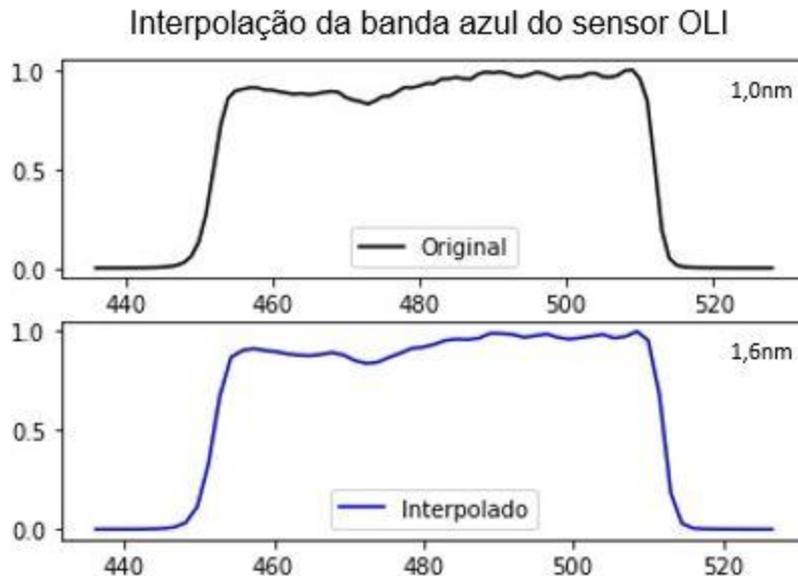
Fonte: Elaborada pela autora.

Na análise do gráfico, não é possível identificar visualmente um potencial dos canais do visível e NIR em discretizar as rochas carbonáticas dos outros alvos, os canais que mostram maior potencial, sobretudo considerando o mineral alunita, são os canais na região do SWIR, principalmente o SWIR 2.

### 4.2.0.2 Análise da mineração de dados por CART

Conforme indicado na metodologia proposta, o primeiro processo para realizar essa análise foi o de simular as bandas espectrais do sensor OLI de acordo com as assinaturas coletadas nas bibliotecas espectrais e pelo espectrorradiômetro. Para ajustar as diferenças de resolução espectral entre o espectrorradiômetro e a SFR do sensor OLI, foi necessário interpolar os valores da função de resposta. A Figura 11 mostra o resultado da interpolação para o canal azul do SFR.

Figura 11 – Interpolação do SFR para a banda azul

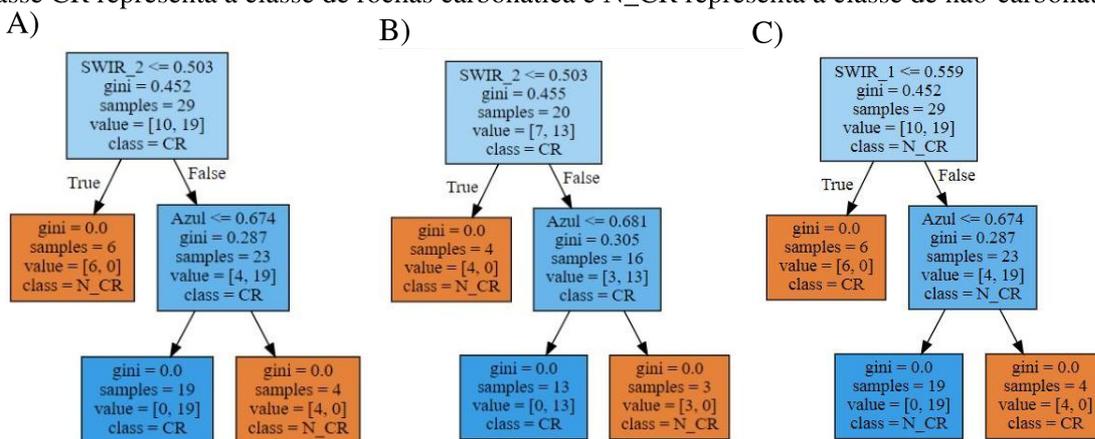


Fonte: Elaborada pela autora.

As árvores de decisão geradas para as assinaturas espectrais mostraram um resultado concordante com a análise de reflectância dos objetos para a região do SWIR e uma contraposição em relação ao canal azul, como mostra a Figura 12.

subcaption

Figura 12 – Árvores de decisão geradas para os 3 cenários supostos para as assinaturas espectrais, onde a classe CR representa a classe de rochas carbonáticas e N\_CR representa a classe de não-carbonáticas



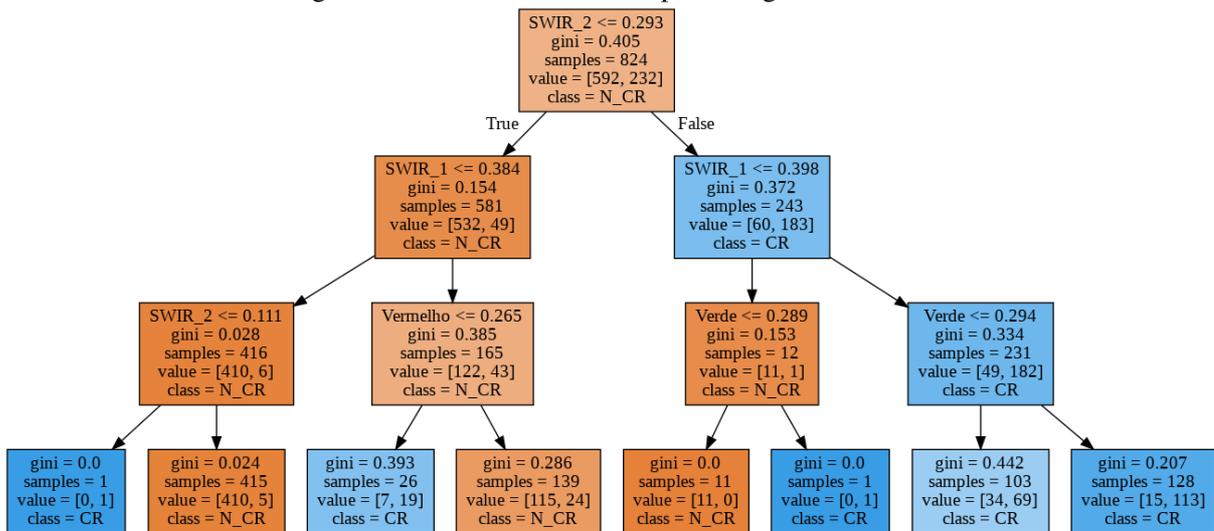
- A) 1º cenário, 65% dos indivíduos CR e 35%N\_CR (Vegetação verde e seca, telhado, asfalto, água, quartzo, albita, 2 tipos de solos quartzosos, Muscovita).
- B) 2º cenário, 65% dos indivíduos CR e 35%N\_CR (quartzo, albita, 2 tipos de solo quartzosos, muscovita, caulinita, barita).
- C) 3º cenário, 35% dos indivíduos CR e 65%N\_CR (Vegetação verde e seca, 3 tipos de telhado, asfalto, água, 2 tipos de solo quartzosos, quartzo, albita, muscovita, caulinita, barita, alunita e conglomerados),

Fonte: Elaborada pela autora.

Analisando a diferença na seleção do SWIR 1 e SWIR 2 nos cenários propostos, pode-se inferir que em cenário mais heterogêneo, o SWIR 2 seja mais adequado para distinguir as assinaturas de rochas carbonáticas.

A Figura 13 que expõe a estrutura da árvore de decisão para a imagem Landsat 8, similarmente aos outros resultados, indica a adequação da região do SWIR para identificação do alvo. Diferente do que era esperado, a classificação apresentou os canais verde e vermelho.

Figura 13 – Árvores de decisão para imagem Landsat 8



Fonte: Elaborada pela autora.

#### 4.2.0.3 Análise do espalhamento das classes no espaço espectral

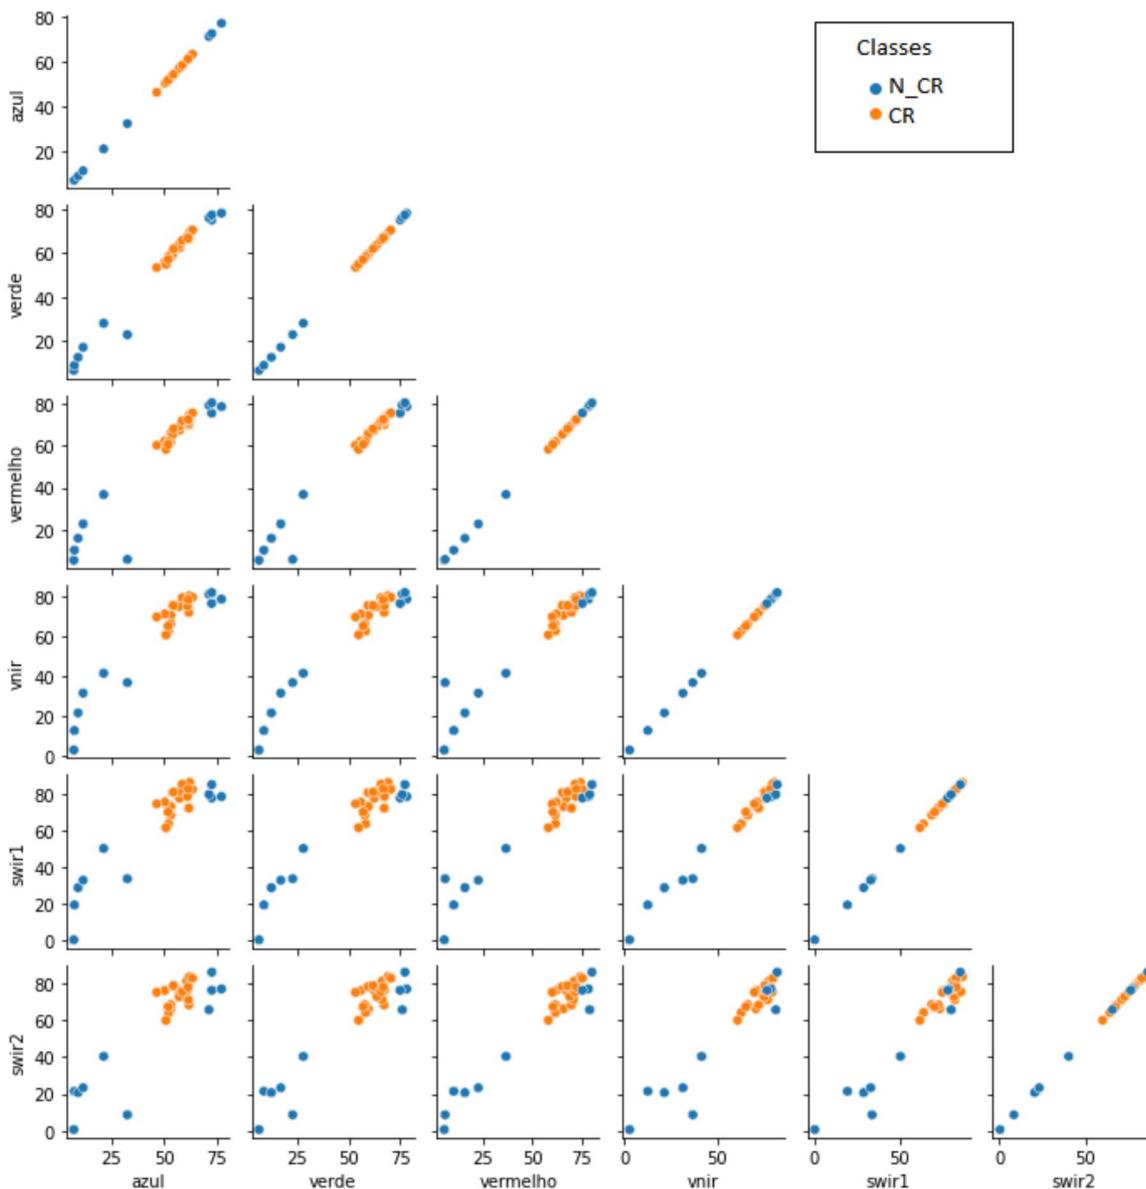
A Figura 14 mostra o espalhamento das classes no espaço espectral comparando os canais dois a dois. A banda que apresentou um resultado mais consistente na discretização das assinaturas espectrais de rochas carbonáticas foi a banda azul.

Já para os pixels classificados na imagem Landsat 8, é possível perceber a adequação da região do SWIR na identificação, sobretudo no espaço espectral entre o azul e o SWIR 2. A partir da modelagem proposta de seleção das bandas espectrais que indicou os canais azul e SWIR 2 como os maiores potenciais de identificação de rochas carbonáticas em imagens Landsat 8, é possível modelar uma equação matemática utilizando o espaço espectral entre os canais.

#### 4.2.0.4 Modelagem do índice espectral para rochas carbonáticas

Como destaca as isolinhas apresentadas na Figura 16 é possível identificar no espaço espectral uma concentração da classe de rochas carbonáticas (pontos laranjas) próximo aos pontos de 0,25 no azul e 0,3 no SWIR 2 e que a medida que a reflectância aumenta, menos pontos da outra classe são identificados. Nota-se também a ausência de pontos de alta reflectância, as

Figura 14 – Espalhamento das classes utilizando as assinaturas espectrais, onde a classe CR representa a classe de rochas carbonáticas e N\_ CR representa a classe de não-carbonáticas



Fonte: Elaborada pela autora.

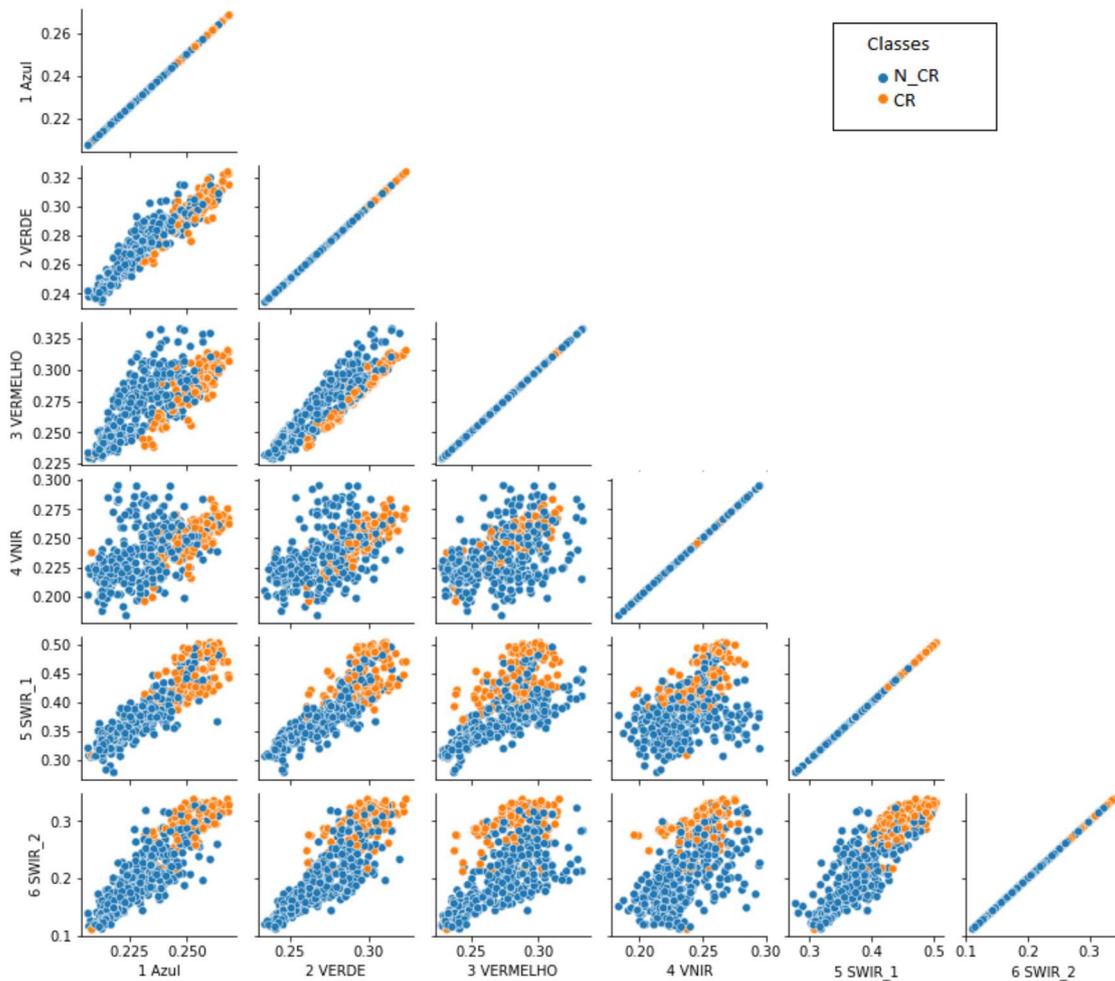
reflectância do eixo do SWIR 2 variando até 0.4 e no azul estando abaixo de 0.3.

No entanto, analisando o gráfico plotado para as assinaturas espectrais simuladas exposto na Figura 17, há pontos da classe dos outros elementos em regiões de maior reflectância que a de rochas carbonáticas.

Como supramencionado, existe diferença na aquisição dos dados por sensores a bordo de satélite e por espectrorradiômetros, seja ela pela nível pureza do dado aferido ou pela interferência do ambiente no sinal coletado, tal diferença fica evidente na disparidade das reflectâncias entre as assinaturas simuladas e os pixels da imagem, conseqüentemente isso implica em formulações diferentes para o índice.

A análise das Figuras 16 e 17 permite dizer que uma equação linear não se ajusta aos dados,

Figura 15 – Espalhamento das classes utilizando a imagem Landsat 8



Fonte: Elaborada pela autora.

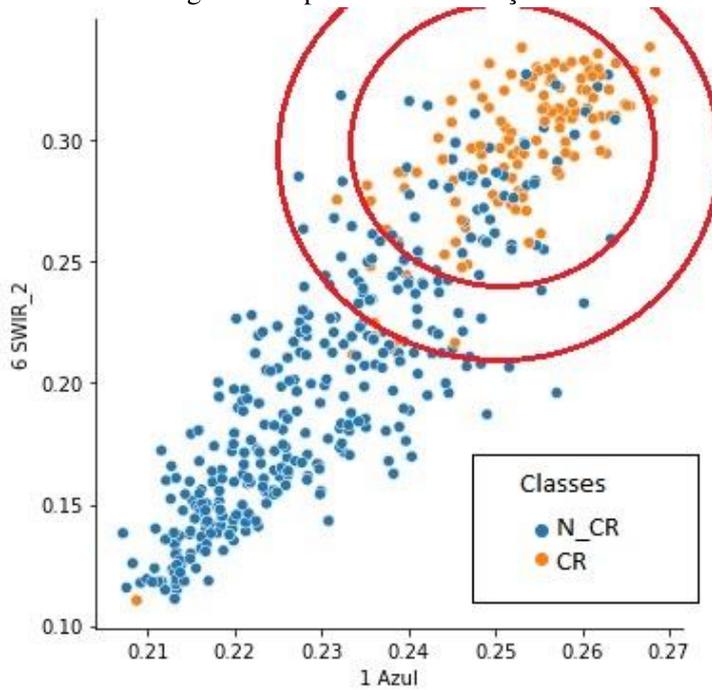
visto que em suma o modelo deve crescer na região espectral onde se concentra a classe do alvo afim de destacá-las e decrescer na região onde há presença da outra classe. Tal comportamento lembra um parábola pois como visto nas figuras, há elementos distribuídos em regiões de mais baixa e mais alta reflectância que a região de concentração de rochas carbonáticas. A equação plotada para esse modelo foi:

$$ACRI = 25 - 1 \left( \left( \frac{(azul - T_x)^2}{C1} \right) + \left( \frac{(SWIR2 - T_y)^2}{C2} \right) \right) \quad (4.1)$$

Onde  $C1$  abertura do ângulo de abrangência do modelo no eixo x e  $C2$  abertura do ângulo de abrangência do modelo no eixo y,  $t_x$  ponto de máxima no eixo x e  $t_y$  ponto de máxima no eixo y, *ACRI* Índice Adaptativo para Rochas Carbonáticas (*Adaptive Carbonate Rocks Index*).

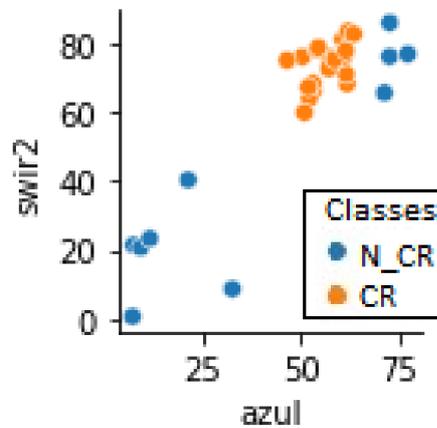
Considerando as características dos dados, como supracitado, foi plotada uma fórmula de parabolóide com concavidade para baixo, onde o ponto de máxima (ponto mais alto ou crista - o ponto mais destacado pela equação) foi ajustado para a região de concentração das rochas carbonáticas como indicado nas isolinhas, a região de reflectância de aproximadamente 25% no

Figura 16 – Isolinhas geradas a partir da distribuição das classes no espaço espectral



Fonte: Elaborada pela autora.

Figura 17 – Distribuição das classes no espaço espectral das assinaturas simuladas



Fonte: Elaborada pela autora.

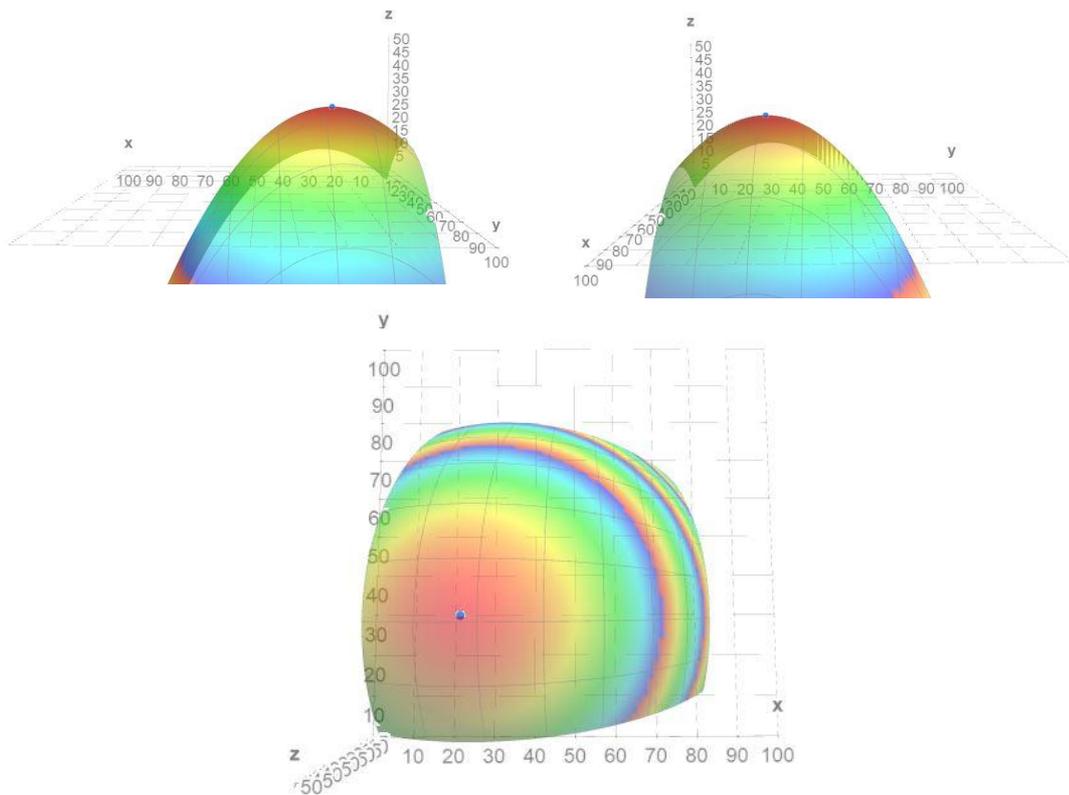
azul e 30% no SWIR 2:

$$ACRI = 25 - 1 \left( \left( \frac{(azul - 25)^2}{50} \right) + \left( \frac{(SWIR2 - 30)^2}{50} \right) \right) \quad (4.2)$$

A Figura 18 representa a equação no espaço 3D, onde o eixo x representa a banda azul e eixo y a banda SWIR 2.

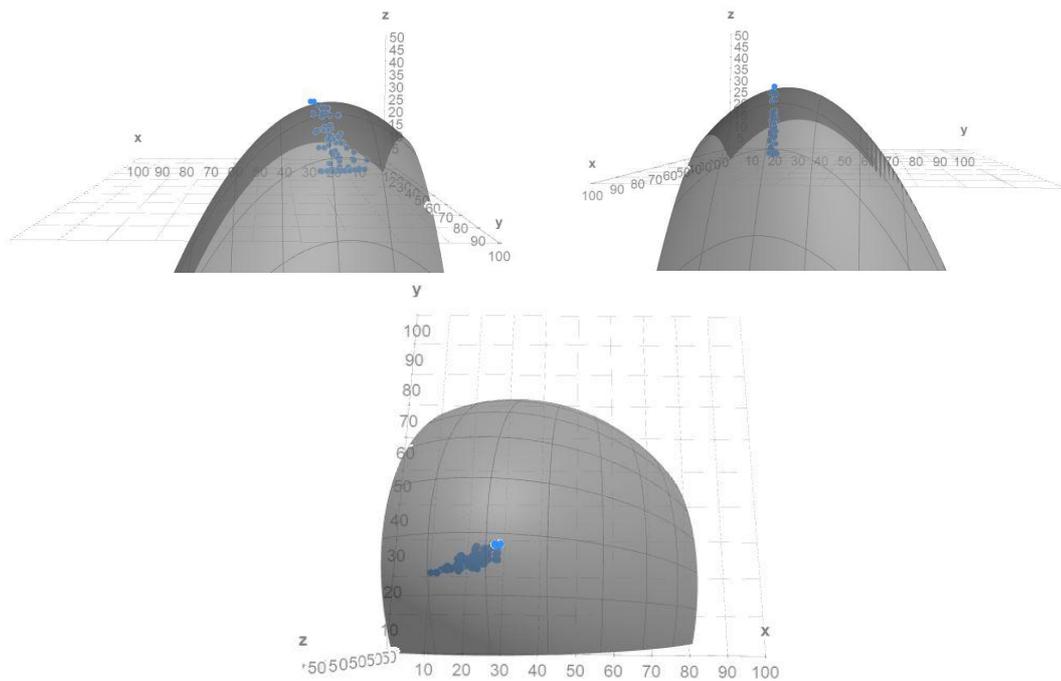
Para melhor ajustar os parâmetros da equação, as informações do azul e SWIR 2 de alguns pixels da imagem foram inseridos no gráfico 3d, como pode ser visto na Figura 19.

Figura 18 – Modelo inicial para construção do índice



Fonte: Elaborada pela autora.

Figura 19 – Modelo inicial e pixels da imagem



Fonte: Elaborada pela autora.

Analisando os pontos plotados, é possível perceber que a crista do modelo (região de maior destaque do índice) está abrangendo uma região maior que a área de concentração dos pixels, e que também, os pixels seguem uma orientação, apresentando mais variação no eixo x (azul) que no eixo y (SWIR 2). Dito isso, foram necessários dois ajustes principais, como mostrou a Figura 18 a crista do modelo está em um formato circular, este formato extrapola a área de interesse do índice, sendo assim, os parâmetros da equação foram ajustados para um formato elipsoidal, já o segundo ajuste foi na rotação do plano, visto que há uma variação na distribuição dos pixels em ambos os eixos entretanto uma variação desuniforme. Dessa forma, o plano foi rotacionado de forma que o eixo maior da elipse estivesse conforme a orientação dos pixels e que o eixo menor afinilasse a área de abrangência do índice, para isso foi incorporada ao índice a equação de rotação:

$$x' = x \cdot \cos(\theta) - y \cdot \sin(\theta) \quad (4.3)$$

Sendo assim, o modelo foi ajustado para a segunda equação:

$$ACRI = 25 - 1 \left( \left( \frac{((azul \cdot R1 - SWIR2 \cdot R2) - T_x)^2}{C1} \right) + \left( \frac{(SWIR2 - T_y)^2}{C2} \right) \right) \quad (4.4)$$

Onde  $R1$  é o parâmetro de rotação cossenoidal e  $R2$  o parâmetro de rotação senoidal,  $C1$  concavidade do modelo no eixo x e  $C2$  concavidade do modelo no eixo y,  $t_x$  translação do ponto de máxima no eixo x e  $t_y$  translação do ponto de máxima no eixo y.

Os parâmetros de rotação e abertura do modelo são relacionados ao comportamento da rochas carbonáticas no espaço espectral, já o ponto de máxima refere-se a reflectância das rochas adquirida por um sensor espectral. Para definir os valores das variáveis foram realizados diversos testes, analisando visualmente como o modelo se comportava em frente aos pontos plotados dos pixels da imagem Landsat 8, até que chegou-se no modelo exposto na Figura 20 alcançado pelos seguintes parâmetros:

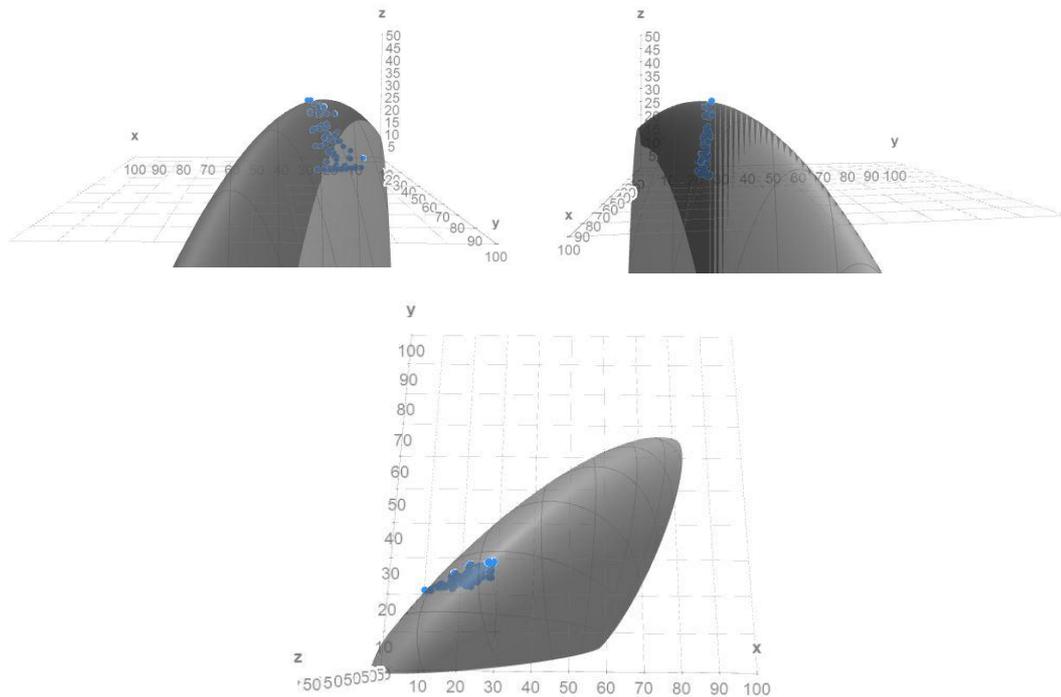
$$ACRI = 25 - 1 \left( \left( \frac{((azul \cdot 2.45 - SWIR2 \cdot 2.10) - 74)^2}{600} \right) + \left( \frac{(SWIR2 - 28)^2}{23} \right) \right) \quad (4.5)$$

Como aludido anteriormente sobre a adimensionalidade do índice, foi aplicado um parâmetro de normalização da equação para padronizar os resultados, a normalização foi aplicada através da divisão da equação. Finalmente o índice resultante da metodologia proposta com os parâmetros ajustados para o Landsat 8 foi:

$$ACRI = \left( 25 - 1 \left( \left( \frac{((azul \cdot 2.45 - SWIR2 \cdot 2.10) - 74)^2}{600} \right) + \left( \frac{(SWIR2 - 28)^2}{23} \right) \right) \right) / 65 \quad (4.6)$$

O índice proposto mostrou uma forte correlação com GT conforme mostra a Figura 21, os

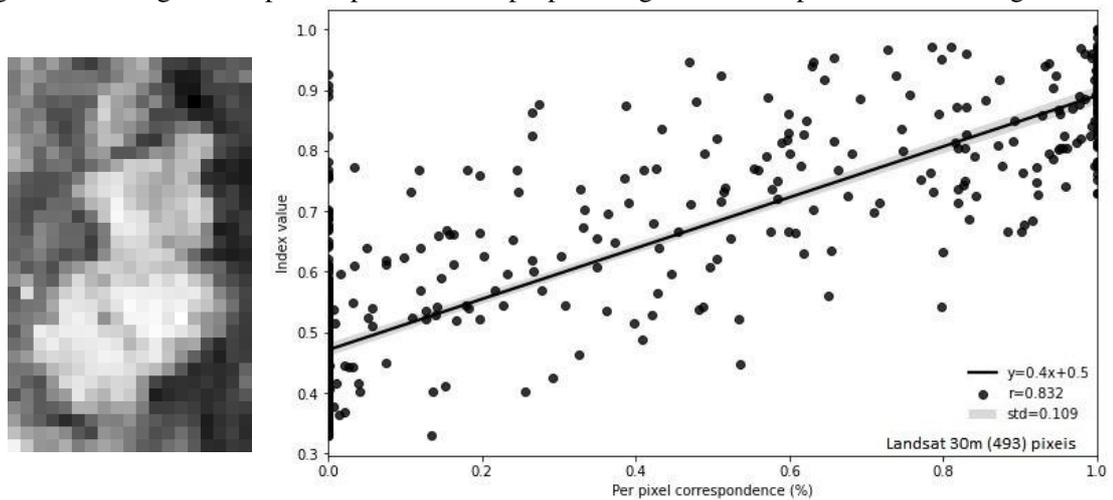
Figura 20 – Modelo final



Fonte: Elaborada pela autora.

resultados alcançados, forte correlação e baixo desvio padrão demonstram uma adequação do índice espectral desenvolvido. O coeficiente de correlação foi inclusive maior que o resultado alcançado pelo índice proposto por Xie et al. (2015) aplicado a imagem Landsat (79%).

Figura 21 – Imagem computada para o índice proposto e gráfico de dispersão entre a imagem e o GT



Fonte: Elaborada pela autora.



## 5 CONSIDERAÇÕES FINAIS

Por meio da metodologia proposta, foram levantadas algumas limitações existentes nos índices desenvolvidos por Xie et al. (2015); Ninomiya (2002); Pei et al. (2018), como a baixa resolução espectral e espacial dos dados utilizados nos estudos para seleção dos canais espectrais, poucos alvos sendo considerados no estudo e a divergência da resolução espectral dos índices, das principais imagens de satélite. A partir das análises e mineração de dados das curvas espectrais em conjunto com os pixels da imagem multiespectral, o presente trabalho obteve um refinamento na seleção e emprego analítico das bandas disponíveis que melhor destacam as rochas carbonáticas. A inclusão das assinaturas espectrais coletadas nas análises foi um fator determinante para o comportamento do índice espectral, assim como, a variação dos cenários supostos.

Vale ressaltar que a modelagem de um índice é uma tarefa sujeita à forma de interpretação dos dados, conseqüentemente, a aplicação das análises sugeridas no trabalho permitiram pontuar com maior detalhe as características espectrais das rochas carbonáticas.

O índice proposto apresentou um resultado conforme o esperado, alta correlação com o GT (83.2%) e baixo desvio padrão na análise pixel a pixel. No entanto, foram definidos no trabalho apenas os parâmetros referentes a imagens Landsat 8, para estendê-lo para outros sensores recomenda-se alguns ajustes, sendo eles:

1. Definir a reflectância das rochas carbonáticas na imagem para as bandas que correspondem ao azul e SWIR 2 no sensor, para isso basta identificar visualmente um pixel da imagem que representa o material carbonático e coletar as informações do pixel.
2. Ajustar os valores de ponto de máxima da equação, onde  $t_x$  seria a reflectância representado no pixel para a banda azul multiplicado por 3 e  $t_y$  a reflectância representado no pixel para a banda que corresponde ao SWIR 2.

Para consolidação do modelo proposto para o índice, é sugerido testes aplicando o índice com variações da área de estudo e aplicações para dados de outros sensores aplicando os ajustes supramencionados.



## REFERÊNCIAS

- ALEXANDER, C. Normalised difference spectral indices and urban land cover as indicators of land surface temperature (Ist). **International Journal of Applied Earth Observation and Geoinformation**, [S.l.], v. 86, p. 102013, 2020.
- ARAÚJO, A. I. P. d. Simulação de geração e propagação de fraturas em rochas empregando técnicas especiais em elementos finitos. , [S.l.], 2019.
- ARVOR, D. et al. Advances in geographic object-based image analysis with ontologies: a review of main contributions and limitations from a remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l.], v. 82, p. 125–137, 2013.
- ASADZADEH, S.; SOUZA FILHO, C. R. de. A review on spectral processing methods for geological remote sensing. **International journal of applied earth observation and geoinformation**, [S.l.], v. 47, p. 69–90, 2016.
- BAGNOLI, E. O lajedo de soledade, apodi (rn): um exemplo de preservação do patrimônio cultural brasileiro. **Revista de Arqueologia**, [S.l.], v. 8, n. 1, p. 239–253, 1994.
- BAISSA, R. et al. Using hypspx swir-320m hyperspectral data for the identification and mapping of minerals in hand specimens of carbonate rocks from the ankloute formation (agadir basin, western morocco). **Journal of African Earth Sciences**, [S.l.], v. 61, n. 1, p. 1–9, 2011.
- BARSI, J. A. et al. The spectral response of the landsat-8 operational land imager. **Remote Sensing**, [S.l.], v. 6, n. 10, p. 10232–10251, 2014.
- BASSO, M.; KURODA, M. C.; VIDAL, A. C. Análise geológica e petrofísica de um bloco de travertino como análogo de reservatório de hidrocarbonetos. **Geologia USP. Série Científica**, [S.l.], v. 17, n. 2, p. 211–221, 2017.
- BEDINI, E. The use of hyperspectral remote sensing for mineral exploration: a review. **Journal of Hyperspectral Remote Sensing**, [S.l.], v. 7, n. 4, p. 189–211, 2017.
- BERNARDO, N. M. R. Análise do potencial do sensor oli (operational land imager) a bordo do landsat-8 em estimar a concentração de sólidos totais em suspensão no reservatório de barra bonita. , [S.l.], 2015.
- BREIMAN, L. et al. **Classification and Regression Trees**, Wadsworth and Brooks/Cole, Monterey, CA, [S.l.], 1984.
- CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. [S.l.]: Guilford Press, 2011.
- CORRÊA, A. d. F. **A extração do petróleo da camada pré-sal brasileira: desafios e oportunidades**. [S.l.]: Advir, 2013.
- COSTA, H. da. **Ensaio mecânicos**. [S.l.: s.n.], 2019.
- CROWLEY, J. K. Visible and near-infrared spectra of carbonate rocks: reflectance variations related to petrographic texture and impurities. **Journal of Geophysical Research: Solid Earth**, [S.l.], v. 91, n. B5, p. 5001–5012, 1986.

DUCART, D. F. et al. Mapping iron oxides with landsat-8/oli and eo-1/hyperion imagery from the serra norte iron deposits in the carajás mineral province, brazil. **Brazilian Journal of Geology**, [S.l.], v. 46, n. 3, p. 331–349, 2016.

EARTH observing-1: ten years of innovation. [S.l.]: NASA, 2010.

EHRENBERG, S.; NADEAU, P. Sandstone vs. carbonate petroleum reservoirs: a global perspective on porosity-depth and porosity-permeability relationships. **AAPG bulletin**, [S.l.], v. 89, n. 4, p. 435–445, 2005.

FERREIRA, J. et al. The importance of outcrop reservoir characterization in oil-industry facies modelling workflows-a case study from the middle jurassic of the maciço calcário estremenho, portugal. In: ABU DHABI INTERNATIONAL PETROLEUM EXHIBITION & CONFERENCE, 2016. **Anais...** [S.l.: s.n.], 2016.

GAFFEY, S. J. Spectral reflectance of carbonate minerals in the visible and near infrared (0.35-2.55 microns); calcite, aragonite, and dolomite. **American Mineralogist**, [S.l.], v. 71, n. 1-2, p. 151–162, 1986.

GALO, M. et al. Aspectos relacionados com o fenômeno de mistura espectral e ambiguidade na classificação usando redes neurais artificiais. **Anais. Presidente Prudente: Simpósio Brasileiro de Geomática**, [S.l.], p. 150–161, 2002.

GE, W. et al. Lithological classification using sentinel-2a data in the shibanjing ophiolite complex in inner mongolia, china. **Remote Sensing**, [S.l.], v. 10, n. 4, p. 638, 2018.

GONZAGA, L. et al. Immersive virtual fieldwork: advances for the petroleum industry. In: IEEE CONFERENCE ON VIRTUAL REALITY AND 3D USER INTERFACES (VR), 2018., 2018. **Anais...** [S.l.: s.n.], 2018. p. 561–562.

HAN, J.; KAMBER, M.; PEI, J. Data mining concepts and techniques third edition. **The Morgan Kaufmann Series in Data Management Systems**, [S.l.], v. 5, n. 4, p. 83–124, 2011.

KINGSTON, M. Spectral reflectance properties of kimberlites, carbonatites: implications for remote sensing for exploration. In: **Kimberlites and related rocks**. [S.l.]: Blackwell Melbourne, 1989. p. 1135–1145.

KUMAR, V.; YARRAKULA, K. Enhancement of limestone mineral identification using hyperion imagery: a case study from tirunelveli district, tamil nadu, south india. **Arabian Journal of Geosciences**, [S.l.], v. 12, n. 2, p. 38, 2019.

KURZ, T. H. et al. Hyperspectral image analysis of different carbonate lithologies (limestone, karst and hydrothermal dolomites): the pozalagua quarry case study (cantabria, north-west spain). **Sedimentology**, [S.l.], v. 59, n. 2, p. 623–645, 2012.

LANDSAT 8 data users handbook now available. [S.l.]: NASA, 2015.

LINAJE, V. A. de; KHAN, S. D.; BHATTACHARYA, J. Study of carbonate concretions using imaging spectroscopy in the frontier formation, wyoming. **International journal of applied earth observation and geoinformation**, [S.l.], v. 66, p. 82–92, 2018.

METZ, M. et al. A note on spectral data simulation. **Chemometrics and Intelligent Laboratory Systems**, [S.l.], v. 200, p. 103979, 2020.

- MISHRA, S. et al. Aviris-ng data for geological applications in southeastern parts of aravalli fold belt, rajasthan. In: MULTIDISCIPLINARY DIGITAL PUBLISHING INSTITUTE PROCEEDINGS, 2019. **Anais...** [S.l.: s.n.], 2019. v. 24, n. 1, p. 16.
- MULLER, M. et al. A quantitative analysis on different carbonate indicators based on spaceborne data in a controlled karst area. In: IGARSS 2020-2020 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2020. **Anais...** [S.l.: s.n.], 2020. p. 5207–5210.
- NINOMIYA, Y. Mapping quartz, carbonate minerals, and mafic-ultramafic rocks using remotely sensed multispectral thermal infrared aster data. In: THERMOSENSE XXIV, 2002. **Anais...** [S.l.: s.n.], 2002. v. 4710, p. 191–202.
- OLIVEIRA, J. et al. O gênero mecaster (echinodermata: spatangoida) do cretáceo superior da formação jandaíra, bacia potiguar, nordeste do brasil. **Scientia Plena**, [S.l.], v. 9, n. 8, p. 1–17, 2013.
- OTAZU, X. et al. Introduction of sensor spectral response into image fusion methods. application to wavelet-based methods. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v. 43, n. 10, p. 2376–2385, 2005.
- PAN, Z. et al. Research on hyperspectral identification of altered minerals in yemaquan west gold field, xinjiang. **Sustainability**, [S.l.], v. 11, n. 2, p. 428, 2019.
- PEDROSA, S. A.; MENESES, P. R.; CARMELO, A. C. Espectrorradiometria de reflectância de rochas carbonáticas na região do infravermelho de ondas curtas. **Brazilian Journal of Geology**, [S.l.], v. 40, n. 4, p. 593–599, 2010.
- PEI, J. et al. Analysis of landsat-8 oli imagery for estimating exposed bedrock fractions in typical karst regions of southwest china using a karst bare-rock index. **Remote Sensing**, [S.l.], v. 10, n. 9, p. 1321, 2018.
- PESSOA NETO, O. et al. Bacia potiguar: boletim de geociencias da petrobras, v. 15. , [S.l.], 2007.
- POUR, A. B.; HASHIM, M. Aster, ali and hyperion sensors data for lithological mapping and ore minerals exploration. **SpringerPlus**, [S.l.], v. 3, n. 1, p. 130, 2014.
- RAJENDRAN, S.; NASIR, S. Aster spectral sensitivity of carbonate rocks–study in sultanate of oman. **Advances in Space Research**, [S.l.], v. 53, n. 4, p. 656–673, 2014.
- RAMAKRISHNAN, D.; BHARTI, R. Hyperspectral remote sensing and geological applications. **Current science**, [S.l.], p. 879–891, 2015.
- SCAFUTTO, R. D. M.; SOUZA FILHO, C. R. de; OLIVEIRA, W. J. de. Hyperspectral remote sensing detection of petroleum hydrocarbons in mixtures with mineral substrates: implications for onshore exploration and monitoring. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S.l.], v. 128, p. 146–157, 2017.
- SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote sensing**, [S.l.], v. 29, n. 1, p. 16–20, 1991.

SOARES, U. M.; ROSSETI, E.; CASSAB, R. d. C. T. Bacias sedimentares brasileiras: bacia potiguar. **Fundação Paleontológica Phoenix**, [S.l.], v. 56, 2003.

SPECTRAL response of the operational land imager in-band, band-average relative spectral response. [S.l.]: NASA, 2014.

STEINBERG, D. Cart: classification and regression trees. **The top ten algorithms in data mining**, [S.l.], v. 9, p. 179, 2009.

TEIXEIRA, J. B. et al. Petrografia de rochas reservatório areníticas e relação com diferentes técnicas de obtenção de parâmetros petrofísicos. , [S.l.], 2017.

TIBANA, P.; TERRA, G. Seqüências carbonáticas do cretáceo na bacia potiguar. **Boletim Técnico da Petrobrás**, [S.l.], v. 24, n. 3, p. 174–183, 1981.

TRANSON, J. et al. Survey of hyperspectral earth observation applications from space in the sentinel-2 context. **Remote Sensing**, [S.l.], v. 10, n. 2, p. 157, 2018.

VERSTRAETE, M. M.; PINTY, B. Designing optimal spectral indexes for remote sensing applications. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v. 34, n. 5, p. 1254–1265, 1996.

WU, X. et al. Top 10 algorithms in data mining. **Knowledge and information systems**, [S.l.], v. 14, n. 1, p. 1–37, 2008.

XIE, X. et al. Spectral indices for estimating exposed carbonate rock fraction in karst areas of southwest china. **IEEE Geoscience and Remote Sensing Letters**, [S.l.], v. 12, n. 9, p. 1988–1992, 2015.

YUE, Y. et al. Spectral indices for estimating ecological indicators of karst rocky desertification. **International Journal of Remote Sensing**, [S.l.], v. 31, n. 8, p. 2115–2122, 2010.

ZAINI, N. **Infrared carbonate rock chemistry characterization**. 2019. Tese (Doutorado em Ciência da Computação) — University of Twente, 2019.

**APÊNDICE A – ARTIGO PUBLICADO**

# A QUANTITATIVE ANALYSIS ON DIFFERENT CARBONATE INDICATORS BASED ON SPACEBORNE DATA IN A CONTROLLED KARST AREA

M. Muller<sup>1</sup>, V. F. Sales<sup>1</sup>, D. C. Zanotta<sup>1</sup>, A. Marques Jr<sup>1</sup>, T. T. Guimarães<sup>1</sup>  
L. Bachi<sup>1</sup>, E. M. Souza<sup>1,2</sup>, D. Brum<sup>1</sup>, L. Gonzaga Jr<sup>1</sup>, M. R. Veronez<sup>1</sup>, C. L. Cazarin<sup>3</sup>

<sup>1</sup> Vizlab, X-Reality & GeoInformatics Lab - Graduate Program in Applied Computing  
UNISINOS University, Rio Grande do Sul, Brazil

<sup>2</sup> Department of Statistics, State University of Maringa, Parana, Brazil

<sup>3</sup>CENPES - PETROBRAS, Rio de Janeiro, Brazil

## ABSTRACT

New sensors aboard recently launched satellites have induced the development of several measures aimed to indicate the presence of many materials over the Earth. Karsts are places rich in carbonate rocks and present large economic and environmental importance. This paper aimed at assessing the performance and consistency of different carbonate estimators derived from orbital images acquired over a controlled karst area. Experiments were assisted by a multi-scaled reference data built through a high spatial resolution Unmanned Aerial Vehicle (UAV) image acquired over the selected area. Results show a considerable unconformity among selected measures and better performance presented by indices exploiting measures along visible and infrared spectral regions.

**Index Terms**— Carbonate rocks, spectral indices, mixing model, petroleum, geology.

## 1. INTRODUCTION

Karst is a landform that arises from the dissolution of carbonate rocks. The study of karst is considered of prime importance in petroleum geology, since as much as 50 % of the world's hydrocarbon reserves are located in karst systems [1]. The most effective way of estimating land cover and land degradation in karst areas is the traditional in-situ investigations by experts. Among many drawbacks, it is very time consuming, labor-intensive, and susceptible to the interpreter's bias. Some sites are still unreachable by conventional field survey [2]. Remote sensing techniques provide an important way of knowing the characteristics of many natural targets.

For many applications, Spectral Mixture Analysis (SMA) and Spectral Indices (SI) provide the translation from radiometric measures to meaningful data for analysts. Karst minerals usually present discernible patterns in either spectral

regions Short Wave Infrared (SWIR) and Thermal Infrared (TIR) (e.g.[2, 3, 4]).

Although indices for hyperspectral sensors have been proven effective to a certain degree, their usage in multispectral images presents serious limitations. Even though, some researches have made efforts to overcome these limitations by proposing special formulations based on subtle features present on the spectral behavior of carbonate rocks.

The most popular sensor used to this end is the Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) [2] because of its great availability of channels in SWIR and TIR. However, increased attention has been given to the orbital sensors OLI-TIRS-Landsat-8 [3] and the MSI-Sentinel-2 [3].

Many studies have focused on the development of special formulations to estimate the amount of each material inside image pixels acquired from spaceborne platforms through indices [2, 3], as well as through Spectral Mixture Models (SMM), [3]. Each suggested index varies depending on the number and the position of the available channels. Moreover, most rock-related indices are site-specific and, thus, not well applicable when altering the study areas.

In this study, SMM and three selected spectral indices based on either SWIR or TIR specific characteristics of carbonate rocks were applied using ASTER, Sentinel-2, and Landsat-8 data over a well-known area located at Apodi city, Brazil. The area is composed of carbonate rocks and other targets and was exhaustively studied in the field survey that occurred on 19 Oct 2019. The aim is to evaluate (1) the differences among the results reached by each approach in order to understand the real bias involved and (2) the correspondence between estimates made from NIR/SWIR and TIR data.

## 2. BACKGROUND AND DATASETS

Remote-sensing for lithologic mapping using SWIR and TIR spectral signatures is usually performed by indices varying from two to many spectral channels [2]. The more the spec-

This research was funded by PETROBRAS and ANP grant number 4600556376 and 4600583791, and by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001.

tral characteristics of the sensor used are detailed, the best is the accuracy of the results reached by the index. The ASTER sensor aboard TERRA satellite has five thermal channels mainly responsible for recognizing the characteristics of minerals over the earth through their emissivity spectra in the thermal infrared region (8-12  $\mu\text{m}$ ). As demonstrated by [2], channels 13 (10.25 - 10.95  $\mu\text{m}$ ) and 14 (10.95 - 11.65  $\mu\text{m}$ ) have special positioning to determine the presence of carbonate (karst) rocks, as in channel 14 the emissivity presented by carbonates is slightly lower than in channel 13 (about 11.3  $\mu\text{m}$ ) [2], as can be seen in Fig. 1(a). This fact led to the main thermal ratio used for carbonate rocks (Eq. 1):

$$CI_1 = \frac{D_{13}}{D_{14}}. \quad (1)$$

Although the index proposed in Eq. 1 has proven to be an effective carbonate estimator, the features of interest are very narrow located at the spectrum and only thermal channels from Aster sensor are able to catch the particular characteristic. As an example, Landsat 8 thermal channels 10 (10.6 - 11.19  $\mu\text{m}$ ) and 11 (11.50 - 12.51  $\mu\text{m}$ ) are out of the range where the feature of interest is placed (about 11.3  $\mu\text{m}$ ). Another limitation by this index is the large size of the pixels in TIR images, which makes the study of small areas unfeasible

More recently, with the launching of Landsat 8 (2013) and Sentinel 2 (2015), indices based on different regions of the spectrum, such as NIR and SWIR, were suggested exploiting other spectral characteristics of carbonate targets. The features are mainly caused by carbonate ions present in the rocks in zones of visible and NIR. Fig. 1(b) shows the reflective behavior of the two main minerals present in carbonate rocks, calcite and dolomite, as measured in the laboratory.

As can be seen, there is a difference between the visible and NIR responses for either dolomite and calcite. This state is particularly different from most of the targets found nearby carbonate deposits, such as vegetation, soil, and different minerals. The other convenient ratio used to highlight the carbonate areas is the ratio between channels blue and NIR [3]:

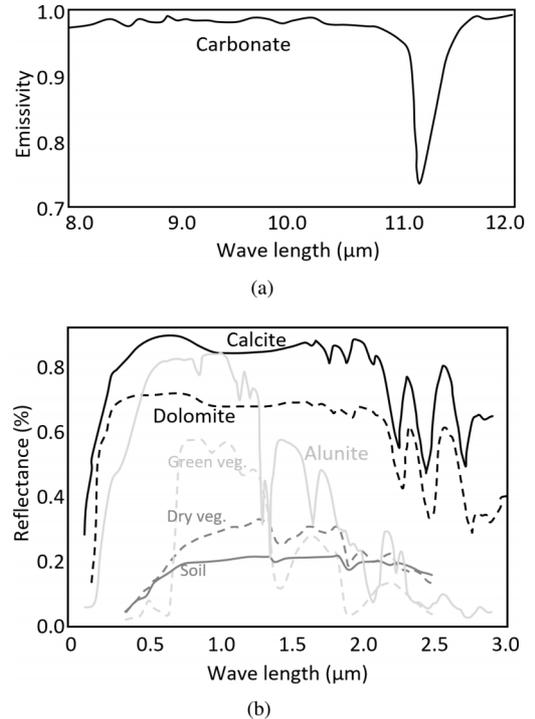
$$CI_2 = \rho_{blue} / \rho_{NIR}. \quad (2)$$

Also covering the reflective zone of the spectrum, one index called *KBRI* using SWIR and NIR regions is available for karst rocks [7]:

$$CI_3 = \frac{\rho_{SWIR} - \rho_{NIR}}{20 \times \sqrt{\rho_{SWIR} + \rho_{NIR}}}, \quad (3)$$

where  $\rho_{SWIR}$  is the reflectance in the SWIR channel and  $\rho_{NIR}$  is the reflectance in the NIR channel. The original formulation was developed for OLI-Landsat-8.

For simplicity, we applied the Linear Spectral Mixture Model (LSMM) for the comparative unmixing analysis. Two endmembers were chosen directly on the image: bare soil and karst. The image data used were an MSI-Sentinel-2B, an



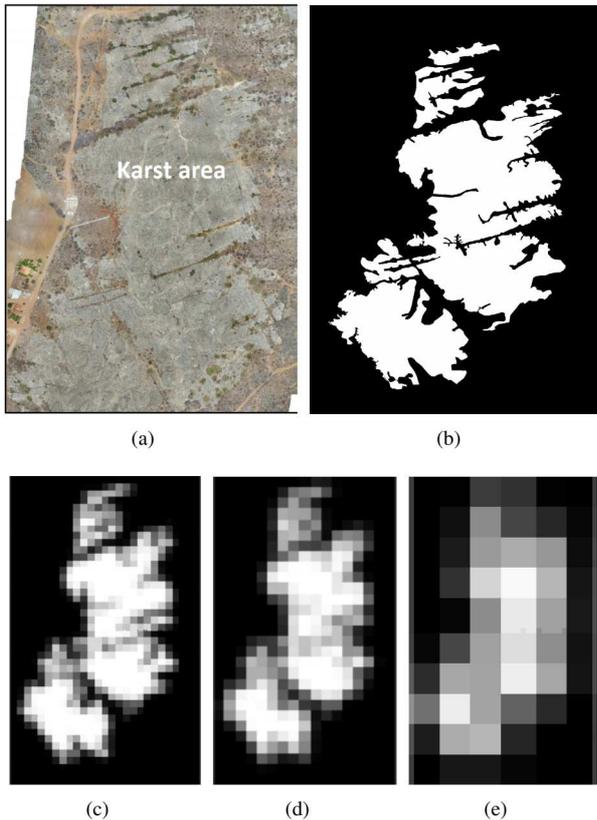
**Fig. 1.** (a) Emissivity spectra near TIR from general carbonate rocks. Data from [5]. (b) Reflectance spectra for visible and NIR regions of calcite (solid black), dolomite (dashed black), dry vegetation (dashed gray), soil (solid gray), Alunite (solid light gray), green vegetation (dashed light gray). Data from [6].

ASTER-TERRA, and an OLI-Landsat-8 acquired on 02 Nov 2018, 27 Nov 2018 and 21 Nov 2018, respectively.

Although the selected formulations greatly differ from one another, it is initially expected they present similar outcomes indicating the presence of carbonate rocks. In order to assess their performances, each approach was used separately over an image covering a controlled karst area located in the northeast of Brazil (Fig. 2(a)), acquired on 19 Oct 2019 with a UAV system adjusted to a spatial resolution of 0.025 m. The corresponding image was used to prepare a Ground Truth (GT) used to compare each result with the same reference image, however, with the scale adjustment. The adjustments were made by re-scaling the original data according to spatial resolution of each input image (Fig. 2(c-e)).

### 3. RESULTS AND ANALYSIS

The computed indices and the unmixing outcomes were directly compared to each corresponding version of the GT created. The results were organized in scatterplots confronting the indices (or fraction) and the percentage occupied by karst according to the reference image, pixel by pixel (Fig. 3). The resulting index/fraction images are also depicted in Fig.



**Fig. 2.** (a) Karst area (light gray region) composed mainly by calcite with some dolomite areas. (b) Ground truth generated from visual interpretation aided by an expert in the field. (c),(d),(e) corresponding GT from (b) re-scaled to match sizes of different images used as input, 44x27 (Sentinel-2B), 29x17 (Landsat-8) and 10x6 (ASTER-TERRA), respectively.

3. The thermal index computed for ASTER image (Eq. 1) showed a moderate correlation ( $R$ ) when compared to the ground truth. The index suggested by [7] (Eq. 3), based in the NIR and SWIR regions, presented a very weak correlation with the GT. Conversely, the visible-NIR index suggested by [3] (Eq. 2) presented a high correlation with reference data for both, Landsat and Sentinel. Concerning the fraction images computed for Landsat and Sentinel, the results were positive, however, not as precise as the visible-NIR index.

Table 1 depicts the relationship among the computed indices/fractions each other. The values were generated by re-scaling each index/fraction estimation to the lower spatial resolution available (ASTER), and then compared two by two. As said before, the indices were expected to generate similar results. However, as can be seen, some of them produced very disparate estimations. This result leads us to conclude the indices (or at least some of them) have to be very carefully considered since they can underestimate or overestimate the actual accuracy.

#### 4. CONCLUSIONS

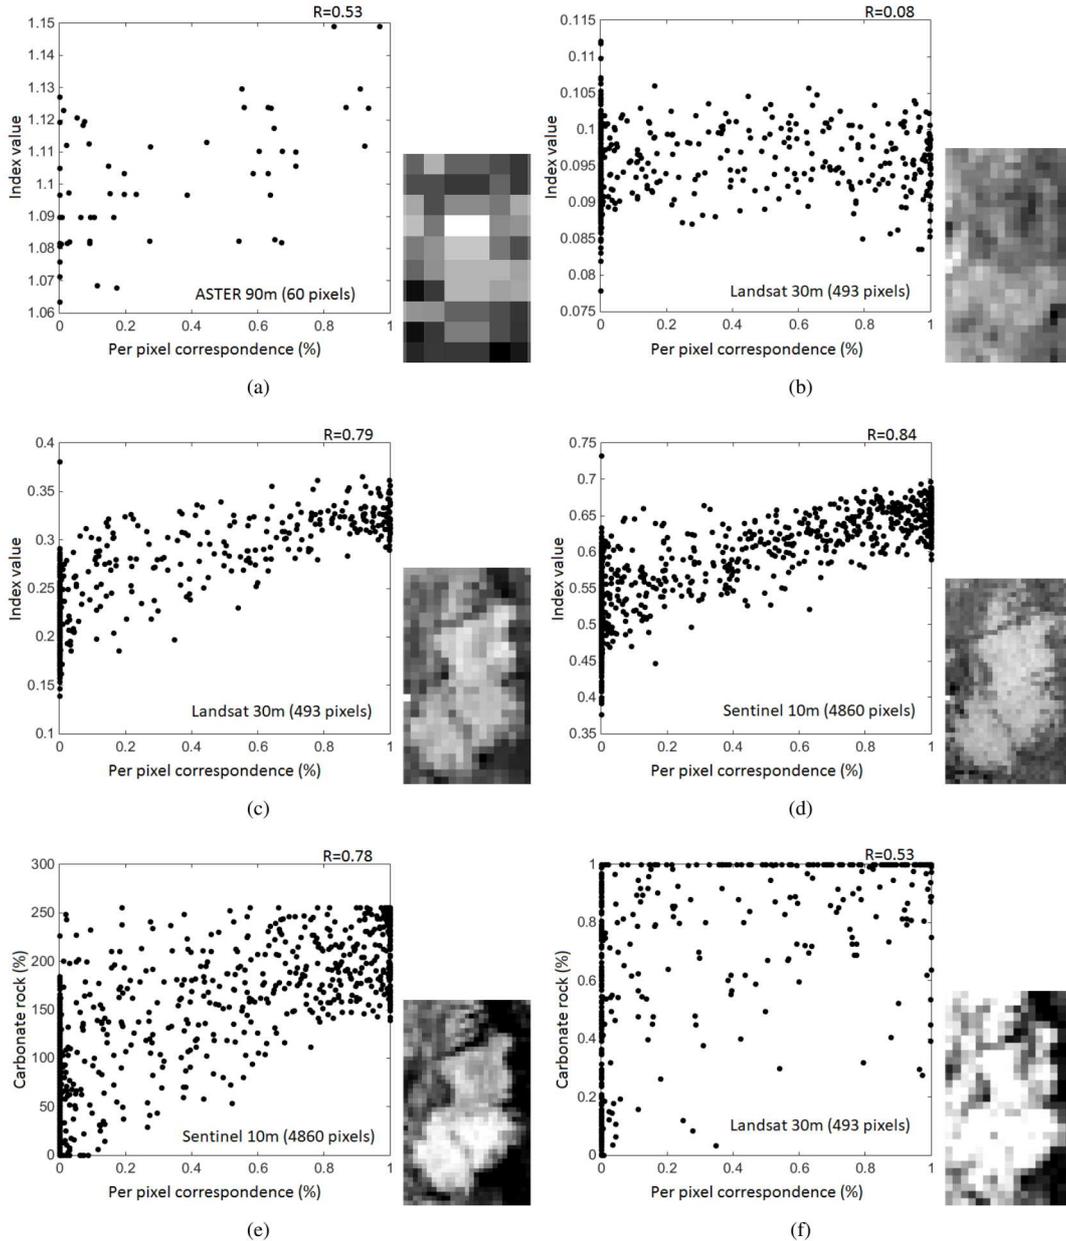
This paper was intended to perform a quantitative analysis over indices used to estimate the presence of carbonate rocks with different sensors. The comparisons were made according to reference data and among each other. The results showed the best performance according to the reference data was achieved by the index based on the visible and NIR channels. The strong dissimilarity found among the selected formulations warn for the careful use of indices and suggest further studying including different site variations of carbonate rocks. The performance of the index using visible and NIR channels ( $C_2$ ) and the consistency between the application in both Landsat and Sentinel images indicate the adequacy of this measure.

#### 5. REFERENCES

- [1] Derek Ford, "Jovan cvijić and the founding of karst geomorphology," *Environmental Geology*, vol. 51, no. 5, pp. 675–684, 2007.
- [2] Yoshiki Ninomiya, "Mapping quartz, carbonate minerals, and mafic-ultramafic rocks using remotely sensed multispectral thermal infrared aster data," in *Thermosense XXIV*. International Society for Optics and Photonics, 2002, vol. 4710, pp. 191–202.
- [3] Xiangjian Xie, Peijun Du, Junshi Xia, and Jieqiong Luo, "Spectral indices for estimating exposed carbonate rock fraction in karst areas of southwest china," *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 9, pp. 1988–1992, 2015.
- [4] Wenyan Ge, Qiuming Cheng, Linhai Jing, Costas Armenakis, and Haifeng Ding, "Lithological discrimination using aster and sentinel-2a in the shibanjing ophiolite complex of beishan orogenic in inner mongolia, china," *Advances in Space Research*, vol. 62, no. 7, pp. 1702–1716, 2018.
- [5] Yoshiki Ninomiya and Bihong FU, "Potential applicability of aster thermal infrared multispectral data on estimation of  $SiO_2$  content in surface rocks," *Journal of The Remote Sensing Society of Japan*, vol. 19, no. 5, pp. 440–453, 1999.
- [6] Andrew N Rencz and Robert A Ryerson, *Manual of Remote Sensing, Remote Sensing for the Earth Sciences*, vol. 3, John Wiley & Sons, 1999.
- [7] Jie Pei, Li Wang, Ni Huang, Jing Geng, Jianhua Cao, and Zheng Niu, "Analysis of landsat-8 oli imagery for estimating exposed bedrock fractions in typical karst regions of southwest china using a karst bare-rock index," *Remote Sensing*, vol. 10, no. 9, pp. 1321, 2018.

**Table 1.** Comparison among all the tested measures.

	$C_1$ -ASTER	$C_3$ -OLI	$C_2$ -OLI	$C_2$ -SEN	LSMM-SEN	LSMM-OLI
$C_1$ -ASTER	1	-0.02	0.53	0.6	0.44	0.37
$C_3$ -OLI	-0.02	1	0.26	-0.008	0.55	0.73
$C_2$ -OLI	0.53	0.26	1	0.92	0.91	0.81
$C_2$ -SEN	0.6	-0.008	0.92	1	0.8	0.59
LSMM-SEN	0.44	0.55	0.91	0.8	1	0.89
LSMA-OLI	0.37	0.73	0.81		0.89	1



**Fig. 3.** Scatter plots estimated index/fraction versus reference data and corresponding images produced by models. (a) ASTER TIR Eq. (1), (b) Landsat KBRI (Eq. 3), (c) Landsat visible-NIR (Eq. 2), (d) Sentinel visible-NIR (Eq. 2), (e) Sentinel LSMM karst fraction, (f) Landsat LSMM karst fraction.