



Escola Superior de Ciências Marinhas e Costeiras

Monografia para a Obtenção do Grau de Licenciatura em Geologia Marinha

**PROCESSAMENTO MULTITEMPORAL DE
IMAGENS LANDSAT PARA MONITORAMENTO
DE COBERTURA DE SOLO E DINÂMICA DA
LINHA DE COSTA NA REGIÃO DE MECÚFI-
CABO DELGADO**

Autor:

Deuclésio de Júbilo Alberto Massangaie

Quelimane, Setembro de 2019



Escola Superior de Ciências Marinhas e Costeiras

Monografia para a Obtenção do Grau de Licenciatura em Geologia Marinha

**PROCESSAMENTO MULTITEMPORAL DE
IMAGENS LANDSAT PARA MONITORAMENTO
DE COBERTURA DE SOLO E DINÂMICA DA
LINHA DE COSTA NA REGIÃO DE MECÚFI-
CABO DELGADO**

Autor:

Deuclésio de Júbilo Alberto Massangaie

Supervisor:

PHD. Hélder Arlindo Machaieie

Quelimane, Setembro de 2019

DEDICATÓRIA

Esta pesquisa fruto do meu próprio suor é dedicado ao meu Senhor Deus, conhecedor e criador de todas as coisas. A toda família Mahumane e Massangaie, mas especialmente aos meus progenitores e irmãos eternos de sangue, que são eles Félix Alberto Massangaie, Admira Mahumane, Delúvio Samon, Nilza da Graça, Domércio Massangaie e Juclêncio de Mérito.

Cientistas são todos academistas sábios e curiosos que não se contentam com o conhecimento íntimo consolidado, adaptado por (Deu, 2019)

AGRADECIMENTOS

Primordialmente sem ambiguidades, agradecer a Deus por ter me apoiado durante o percurso da vida e por ter almejado aquilo que hoje eu sou, por volta disso nunca deixarei de depositar inúmeras confianças para o resto da vida.

Agradecer também aos meus pais Félix Alberto Massangaie e Admira Mahumane pela Educação Moral e Cívica, pelo apoio incondicional em todas jornadas, quer do lado estudantil, assim como externo. Um abraço forte também para meus irmãos Delúvio Samon, Nilza da Graça, Domércio Massangaie e Juclêncio de Mérito, pois vocês são flores que nunca murcharão em pleno dos meus olhos.

Com todo amor e carinho ao meu supervisor PhD. Hélder Arlindo Machaieie, pelo entusiasmo protagonizado durante a realização dessa pesquisa e por ter aceite a supervisão. Ao MSc. César Hogueane, PhD. Eulália Mugabe, PhD Langa, MSc. Noca Furaca, Dr. Mabota Humberto, Dr. Banito, Dr^a. Anabela, Dr^a. Carlota, Professor Doutor Fialho, Professor Cátedro Hogueane, MSc. Feraz, Eng^a Joana, MSc. Pita, Dr. Yolanda e MSc. Saide, Dona Rita, Dona Maimuna, Sr Zacarias, Sr Salvador, Dona Bauque, Dona Arsénia e Dona Iranete pelo ensinamento na ESCMC.

Aos meus avôs: Alexandre Mahumane, Graça, Palmira, Adélia, Mucozane e Salmina. Em forma de reconhecimento agradecer aos meus tios e primos: Prima Gilberta, Tio Paristamo, Solí, Faruque, Xaxa, Emídio Maungane, Adérito, Tio Xavito, Tio Nelson, Tia Belarmina, Tia Bernência, Tia Zaida, Tia Alda, Prima Dulce, Primo Adolfo, Tio Taboa, Tia Zita, Tia Ana ,Lurdes, Tio Luis Mahumane, Tia Flávia, Tio Belito, Tio Olívio, Tio Calisto, Tia Belinha, Tio Casamula, Idálgo, Fidalgo, Edson, Dircélio, Gabito, Marlen, Dário e Flábia pelos momentos importantes e de lazer.

Meus amigos eternos desde os tempos remotos até ao corrente ano: Tia Manuela, tio Eroga, Chena, Finisia, Marta, José Jaime Nhantumbo, Alda, Celestino, R. Mapulende, Nélio, António Luis, Clácia, Mugadue, Marlen, Joel das Neves, Momed, Muhate, Belneves, Suraya, Adélia, Eduine, Laiwá, Muatama, Olinda, Abelardo, Luisa, Emília, Valdo, Caita, Zaurinha, Djury, Dichampse, Cornélio, Calú, Wilhamo, Babodji, Cheila, Idelson, Vitinho, Adolfo, Dominic, Líria, Joana, Pascual, Arsénia, Jésica , Criolayna, Miro, Dulcídio e Bevindo. A todos colegas do curso de Geologia, Oceanografia, Biologia e Química Marínha. Sem deixar de fora ilustres amigos do ginásio: Araujo, Lene, Cota Zema, Cota Fumo, Paulo, Mano Pai e outros que não pude citar pela insuficiência do espaço. Meus kanimambos pelas brincadeiras e trocas de experiências.

DECLARAÇÃO DE HONRA

Declaro que esta monografia nunca foi apresentada para obtenção de qualquer grau e que ela constitui o resultado do meu labor individual. Esta monografia é apresentada em cumprimento parcial dos requisitos de obtenção do grau de Licenciatura em Geologia Marinha, da Universidade Eduardo Mondlane.

Quelimane, Setembro de 2019

Assinatura

(Deuclésio de Júbilo Alberto Massangaie)

RESUMO

A partir da técnica denominada Sensoriamento Remoto, o presente trabalho objectiva analisar temporalmente as imagens Landsat para monitoramento de cobertura de solo e dinâmica da linha de costa na região de Mecúfi. A metodologia consistiu na aquisição de dados e Processamento Digital de Imagens (PDI): aquisição de dados foi feita na Plataforma online de Serviço Geológico dos Estados Unidos (USGS), onde fez-se o download de 2 cenas (imagens orbitais) de satélites Landsat 5-TM e Landsat 8-OLI numa séria temporal de 17anos, datadas para 14/08/2001 e 23/04/2018, âmbas na órbita 164, ponto 69 e selecionadas de acordo com menor cobertura de nuvens. O PDI envolveu três etapas nomeadamente: Pré-processamento, Processamento e Pós-processamento. O Pré-processamento consistiu na conversão de números digitais em valores de reflectância, recortes e extração máscaras, o Processamento consistiu nos contornos de linha de costa, composições coloridas no canal RGB, classificação supervisionada, cálculos de índices espectrais e cálculos que envolvem parâmetros estatísticos na planilha do Excel 2007 e Software estatístico Minitab 18. A última etapa de Pós-processamento fez-se uma avaliação da acurácia da classificação MAXVER. Os resultados foram apresentados em forma de tabelas, gráficos e mapas do uso e cobertura de solos. A região de Mecúfi enfoca progradações ou retrogradações da linha de costa em direcção ao continente, isso foi visualizado em mapas de escala 1:10.000 no ArcGis 10.5. A qualidade da avaliação do mapeamento MAXVER foi muito boa para exatidão global cerca de 62,7% e boa para Índice kappa com 55,3% em âmbos Sensores. Os valores mínimos e máximos de limiares de reflectância são cruciais para resolver problemas de discriminação dos alvos através dos algoritmos classificadores de imagens Landsat.

Palavras-chave: Região de Mecúfi; Sensoriamento Remoto; Linha de costa ; Uso e cobertura de solos .

ABSTRACT

Using the technique called Remote Sensing, the present work aims to analyze Landsat images for monitoring ground cover and shoreline dynamics in Mecúfi region. The methodology consisted of data acquisition and Digital Image Processing (PDI): The data acquisition was done on the US Geological Survey Online Platform (USGS), where 2 scenes (orbital images) of Landsat 5-TM and Landsat 8-OLI satellites were downloaded in a 17-year time series, dated to 08/14/2001 and 23/04/2018, both in orbit 164, point 69 and selected according to lower cloud cover. The PDI involved three steps namely: Preprocessing, Processing and Postprocessing. Preprocessing consisted of converting digital numbers into reflectance, clipping, and extracting masks, Processing consisted of shoreline outlines, RGB channel color compositions, supervised classification, spectral index calculations, and calculations involving statistical parameters in the Excel 2007 spreadsheet and Minitab 18 statistical Software. The last post-processing step was an evaluation of the accuracy of the MAXVER classification. The results were presented as tables, graphs and maps of land use and coverage. The Mecufi region focuses on shoreline progressions or retrogradations, which were visualized on 1: 10,000 scale maps in ArcGis 10.5. The quality of the MAXVER mapping assessment was very good for overall accuracy around 62.7% and good for kappa Index with 55.3% in both Sensors. Minimum and maximum reflectance threshold values are crucial for solving target discrimination problems through Landsat image classifying algorithms.

Key words: Region of Mecúfi ; Remote sensing; Shoreline; Land use and coverage.

LISTA DE ABREVIATURAS E SIGLAS

ESCMC	Escola Superior de Ciências Marinhas e Costeiras
LC	Linha da Costa
SR	Sensoriamento Remoto
ND	Números Digitais
NIR	Infravermelho Próximo
USGIS	Serviço Geológico dos Estados Unidos
ETM	Mapeador temático (Thematic Map)
OLI	Operacional Land Imager
SIG	Sistema de Informação Geográfica
PDI	Processamento digital de imagens
SWIR 1	Infravermelho médio
SWIR 2	Infravermelho distante
MAXVER	Máxima verossimilhança

LISTA DE TABELAS

Tabela 1: Regiões ou faixas do espectro electromagnético	5
Tabela 2: Qualidade da classificação segundo intervalos do Índice Kappa (Landis e Koch, 1977).....	15
Tabela 3: Bandas espectrais do Landsat 5 e Landsat 8 utilizadas no trabalho	20
Tabela 4: Delimitação das classes da cobertura de solo	23
Tabela 5: Representação matemática da matriz de confusão. Fonte: Congalton e Green (1999).....	25
Tabela 6: Quantificação das áreas dos alvos de uso e cobertura de solos para 2001-2018.....	35
Tabela 7: Matriz de confusão/tabela de contingência para 2001	36
Tabela 8: Matriz de confusão/tabela de contingência para 2018	37

LISTA DE FIGURAS

Figura 1: Tipos de dados em SIG (Ferreira, 2006)	10
Figura 2: Curvas de reflectância espectral (Swai e Davis 1978)	16
Figura 3: Localização da Área de Estudo	18
Figura 4: Fluxograma metodológico	21
Figura 5: Composição colorida RGB (6,5,4)	23
Figura 6: Representação matemática da matriz de confusão. Fonte: Congalton e Green (1999)	Error!
Bookmark not defined.	
Figura 7: Lista de melhores Composições coloridas.....	31
Figura 8: Mapa da banda do infravermelho próximo sem mudanças	32
Figura 9: Mapa de contornos digitalizados no Google Earth com mudanças	32
Figura 10: Gráfico da área A.....	33
Figura 11: Gráfico da área B.....	33
Figura 12: Mapa do uso e cobertura de solos para Sensor TM-2001.....	34
Figura 13: Mapa do uso e cobertura de solos para Sensor OLI-20.....	35
Figura 14: Gráficos dos valores mínimos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor TM-2001.....	40
Figura 15: Gráficos de valores máximos de limiares de reflectância para BI, NDWI,SLAVI e RATIO Sensor TM-2001.....	41
Figura 16: Gráficos dos valores mínimos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor OLI-2018	42
Figura 17: Gráficos dos valores máximos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor OLI-2018.....	Error! Bookmark not defined.

ÍNDICE

<i>Título</i>	<i>Pág</i>
I. INTRODUÇÃO E OBJECTIVOS	1
1.1 Introdução.....	1
1.2 Problemática	2
1.3 Justificativa.....	3
1.4 Objectivos.....	4
1.4.1 Objectivo Geral.....	4
1.4.2 Objectivos Específicos.....	4
II. EMBASAMENTO TEÓRICO.....	5
2.1 Sensoriamento Remoto.....	5
2.1.1 Princípios físicos em Sensoriamento Remoto	5
2.2.2 Sensores remotos	7
2.2.2.1 Passivos: não possuem fonte própria de radiação. Medem radiação solar refletida ou radiação emitida pelos alvos. Ex.: Sistemas fotográficos.	7
2.2.2.2 Activos: possuem sua própria fonte de radiação eletromagnética, trabalhando em faixas restritas do espectro. Ex.: Radares (Spring, 2006).	8
2.3.3 Resolução de Sensores.....	8
2.3.3.1 Resolução Espacial	8
2.3.3.2 Resolução Espectral.....	8
2.3.3.3 Resolução Radiométrica.....	8
2.3.3.4 Ciclo (Resolução Temporal).....	9
2.3.4 Satélites.....	9
2.3.5 Sistemas de Informacao Geografica (SIG)	9
2.3.6 Tipos de dados em SIG.....	10
2.3.6.1 Dados Matriciais.....	10
2.3.6.2 Dados Vectoriais.....	10
2.3.7 Processamento Digital de Imagens.....	11

2.3.7.1 Pré-processamento	11
2.3.7.2 Processamento	11
2.3.7.3 Pós-Processamento	13
2.3.8 Uso e Cobertura da terra	15
2.3.9 Comportamento espectral dos alvos	16
III. MATERIAL E MÉTODOS	18
3.1 Área de Estudo	18
3.2 Material.....	19
3.3 Métodos	19
3.3.1 Determinação das taxas de variação da linha de costa entre os anos 2003-2018	21
3.3.2 Mapeamento de cobertura de solo nos anos 2001 e 2018 usando o algoritmo máxima verossimilhança	22
3.3.3 Avaliação da acurácia do mapeamento MAXVER	24
3.3.3.1 Matriz de Confusão e Coeficiente de Concordância Kappa	25
3.3.4 Estimação de valores mínimos e máximos dos limiares de reflectância dos índices espectrais para discriminar os alvos.....	28
IV. RESULTADOS	32
4.1 Determinação das taxas de variação da linha de costa entre os anos 2003-2018	32
4.2 Mapeamento da cobertura de solos nos anos 2001 e 2018 usando o algoritmo máxima verossimilhança	34
4.3 Avaliação da acurácia do mapeamento MAXVER.....	36
4.4 Estimação de valores mínimos e máximos dos limiares de reflectância dos índices espectrais para discriminar os alvos	40
V. DISCUSSÃO	44
VI. CONCLUSÕES E RECOMENDAÇÕES.....	46
6.1 Conclusões.....	46
6.2 Recomendações.....	46
VII. REFERÊNCIAS BIBLIOGRÁFICAS.....	47
ANEXO I- Lista de índices espectrais calculados em níveis de cinza	50

I. INTRODUÇÃO E OBJECTIVOS

1.1 Introdução

De forma sintética, a expressão “uso da terra ou uso do solo” pode ser entendida como sendo a forma pela qual o espaço está sendo ocupado pelo homem (Rosa, 2007).

O uso e cobertura da terra é a informação mais acessível numa imagem de satélite, pois a mesma permite a visualização e identificação direta dos elementos geometricamente apresentados. Estes termos são primordiais para a compreensão dos padrões de organização do espaço, uma vez que suas tendências possam ser analisadas.

Zonas Costeiras abrangem uma complexidade de interfaces de corpos hídricos, continentais e atmosféricas, pois nessas interfaces podemos encontrar alvos principais da paisagem como: águas límpidas, águas turvas, solo nú, mangal, vegetação, pastagens, culturas, rochas e minerais com seu comportamento espectral característico.

Comportamento espectral consiste no conjunto números sucessivos de reflectância no espectro electromagnético. Outros autores especialistas em sensoriamento remoto inferem que comportamento espectral é o estudo de reflectância dos objectos naturais da terra.

As Praias são resultado de uma vasta acumulação de sedimentos inconsolidados controlados por acção de ondas e marés como aponta Jensen, (1949), diante destas acções, a região de Mecúfi se caracteriza por sofrer processo costeiro de erosão costeira, sendo este causador de progradação ou retrogradação da linha de costa. Segundo Langa (2007) na linha costeira verificam-se recuos significativos com implicações nas faixas marginais: perdas de areias, destruição de dunas e vegetação, danos nas obras de defesa existentes e aumento do risco de algumas construções a ser afectadas.

De acordo com (Hoguane, 2007), A linha da costa moçambicana tem um comprimento de cerca de 2700km e é caracterizada por albergar um vasto ambiente com fauna e flora.

A pesquisa do género é baseada em Sensoriamento Remoto, sendo arte e ciência de adquirir informações dos alvos ou objectos da superfície terrestre sem estar em contacto físico com os mesmos. A REM que incide a superfície terrestre, uma parte é absorvida, reflectida e transmitida, sendo que porção refletida interessa no sensoriamento remoto como inferi (Jensen, 1949).

1.2 Problemática

A pesquisa problematiza-se pelos impactos drásticos de cobertura de solo, tendências de retrogradações ou progradações da linha de costa que se fazem sentir na região de Mecúfi, pois acções antrópicas e naturais contribuem para que hajam inúmeras alterações dessas feições geológicas.

Factos erosivos acontecem com a retirada ou perda de algum material, no caso da retirada de vegetação, mangal e dinâmica de transportes eólicos, o solo fica exposto suscetível a inundações. De acordo com Jensen (1949) quando ocorrem actividades que perturbam a terra, partículas sólidas são transportadas pelo movimento de águas superficiais, por fluxos de rios e lagos.

Esses aspetos se registam frequentemente na natureza e o principal causador é o homem pela falta de conhecimentos de conservação da flora e fauna.

O mau uso do solo protagonizado pelas actividades humanas, intensificam-se no cotidiano principalmente quando se trata de zonas costeiras. Nesse sentido, os modelos de predição de perdas de solos são instrumentos eficientes para análise ambiental, pois em função das características do solo e do manejo local, pode ser estimada a perda de solo esperada para uma região (Moreira, 2003).

Trabalhos relacionados com cobertura de solos e dinâmica da linha de costa, nunca foram realizados na região de Mecúfi, o que pode dificultar na tomada de decisão concernente aos impactos que se fazem sentir nesta região.

1.3 Justificativa

As técnicas de Sensoriamento remoto são mais usadas nos países desenvolvidos, para um país em via de desenvolvimento como Moçambique é crucial explorar esta ciência como contributo na área de geociências, mapeando recursos naturais em escalas bem superiores num determinado espaço geográfico.

A partir dos dados coletados por sensores acoplados aos satélites podemos prever tendências ambientais no passado e no futuro, desde que estes apresentam uma resolução significativa.

Em pleno destas constatações, a ciência do sensoriamento remoto sendo multidisciplinar pode ser explorada em uma gama de áreas dependendo da aplicabilidade do usuário. Baseando-se em Crósta (1992) do ponto de vista técnico científico, as imagens de sensoriamento remoto vêm servindo de fonte para estudos de levantamentos geológicos, ambientais, cartográficos, florestais, urbanos, oceanográficos, entre outros.

Desta feita o presente trabalho tem como finalidade analisar temporalmente as imagens Landsat para monitoramento de cobertura de solo e dinâmica da linha de costa na região de Mecúfi.

1.4 Objectivos

1.4.1 Objectivo Geral

- ♣ Analisar temporalmente as imagens Landsat para monitoramento de cobertura de solo e dinâmica da linha de costa na região de Mecúfi.

1.4.2 Objectivos Específicos

- ♣ Determinar as taxas de variação da linha de costa entre os anos 2003- 2018
- ♣ Mapear a cobertura de solos nos anos 2001 e 2018 usando o algoritmo máxima verossimilhança
- ♣ Avaliar acurácia do mapeamento MAXVER
- ♣ Estimar valores mínimos e máximos dos limiares de reflectância dos índices espectrais para discriminar os alvos

II. EMBASAMENTO TEÓRICO

2.1 Sensoriamento Remoto

O Sensoriamento Remoto é uma ciência cujo conceito é passível de muitas interpretações.

Kramer (1996), define Sensoriamento Remoto com a medição ou aquisição de informações sobre algumas propriedades de um determinado objeto ou fenômeno sem contato físico. De acordo com Inpe (2006). As técnicas da detecção remota foram utilizadas com vários tipos de sensores e para várias aplicações em finalidades ambientais desde o princípio dos anos 60, sendo posteriormente ampliada sua capacidade, podendo ser usados para mapeamento detalhado da superfície da terra e para o monitoramento dos oceanos. A vantagem principal da detecção remota satélite dos oceanos é o fato de que fornece a monitoração em grande escala e simultânea de bacias inteiras.

2.1.1 Princípios físicos em Sensoriamento Remoto

O Sol constitui-se na mais importante fonte de radiação natural para a Terra. A radiação electromagnética (REM) é definida como sendo a forma de energia que se move à velocidade da luz, sendo em forma de ondas ou de partículas electromagnéticas, não necessitando de um meio material para se propagar no espaço.

A representação contínua da radiação electromagnética em termos de comprimento de onda, frequência ou energia é denominada espectro electromagnético. O espectro electromagnético é subdividido em faixas que representam regiões com características próprias, em termos de processos físicos de detecção de energia como pode ser observado na tabela a seguir:

Tabela 1: Regiões ou faixas do espectro electromagnético

Faixas espectrais ou regiões do espectro electromagnético	
1. Raios Cósmicos, raios γ : ($< 0,003 - 0,4 \mu\text{m}$);	5. Infravermelho Próximo: ($0,72 - 1,3 \mu\text{m}$);
2. Raios X: ($0,03 - 3,0 \text{ nm}$);	6. Infravermelho Médio: ($1,3 - 4,0 \mu\text{m}$);
3. Ultravioleta: ($0,003 - 0,4 \mu\text{m}$);	7. Infravermelho Distante: ($4,0 - 300 \mu\text{m}$);
4. Visível: ($0,4 - 0,72 \mu\text{m}$), azul ($0,45 - 0,50$)	8. Microondas: ($1,0 - 100 \text{ cm}$);

μm), verde (0,50 – 0,54 μm), vermelho (0,65 – 0,72 μm);	
	9. Ondas de Rádio: (> 100 cm).

Dentre essas divisões do espectro eletromagnético, as mais utilizadas em Sensoriamento Remoto compreendem as faixas do visível, infravermelho próximo, infravermelho médio, infravermelho distante e microondas. No entanto, as faixas mais utilizadas nessa pesquisa compreendem o vermelho do espectro visível e o infravermelho próximo. As considerações a respeito dessa utilização serão destacadas posteriormente.

No momento em que a radiação solar incide no topo da atmosfera, uma parte dessa radiação é espalhada ou refletida pelas partículas atmosféricas, outra parte atravessa a atmosfera e atinge o alvo; a partir daí, podemos observar três fenômenos que podem ocorrer com um fluxo de radiação eletromagnética ao interagir com um alvo, e que são de extrema importância para o Sensoriamento Remoto; dentre eles, Rosa (2007) destaca:

Reflectância: como sendo o quociente entre o fluxo de radiação refletida pelo alvo dividido pelo fluxo de radiação eletromagnética incidente, como pode ser observado na equação a seguir:

$$\rho = \frac{\phi_r}{\phi_i} \quad (1)$$

Em que:

ρ = é a reflectância;

ϕ_r = é o fluxo de radiação refletida ;

ϕ_i = é o fluxo de radiação incidente.

Transmitância: o fluxo de radiação transmitida pelo alvo dividido pelo fluxo de radiação incidente, expresso a seguir:

$$\rho = \frac{\phi_t}{\phi_i} \quad (2)$$

Em que:

ρ = é a reflectância;

ϕt = é o fluxo de radiação transmitida;

ϕi = é o fluxo de radiação incidente;

Absortância: é a razão entre o fluxo de radiação absorvida pelo alvo dividido pelo fluxo de radiação incidente:

$$\rho = \frac{\phi a}{\phi i} \quad (3)$$

Em que:

ρ = é a reflectância;

ϕa = é o fluxo de radiação absorvida;

ϕi = é o fluxo de radiação incidente.

É por meio da quantificação da absortância que o especialista em Sensoriamento Remoto poderá tirar conclusões importantes a respeito das condições de determinada cultura agrícola ou vegetação (Moreira, 2003). No entanto, quando se trata de Sensoriamento Remoto orbital ou suborbital, esta variável é geralmente estimada pela quantificação da parte refletida (por restrições tecnológicas dos equipamentos a bordo dos satélites orbitais ou em aeronaves) que registram somente a radiação refletida ou emitida pelos alvos da superfície terrestre.

2.2.2 Sensores remotos

Sensores remotos são sistemas fotográficos ou óptico-eletrônicos capazes de detectar e registrar, sob a forma de imagens ou não, o fluxo de energia radiante refletido ou emitido por objetos distantes (Spring, 2006). Em função da fonte de energia, podem ser classificados:

2.2.2.1 Passivos: não possuem fonte própria de radiação. Medem radiação solar refletida ou radiação emitida pelos alvos. Ex.: Sistemas fotográficos.

2.2.2.2 Activos: possuem sua própria fonte de radiação eletromagnética, trabalhando em faixas restritas do espectro. Ex.: Radares (Spring, 2006).

2.3.3 Resolução de Sensores

Resolução é uma medida de habilidade que um sistema sensor possui de distinguir entre respostas que são semelhantes espectralmente ou próximas espacialmente. A resolução pode ser classificada em espacial, espectral, radiométrica e temporal.

2.3.3.1 Resolução Espacial

Considerando Moreira (2001), resolução espacial refere-se ao campo de visada instantânea. No solo, pode ser definida como sendo a menor área de um terreno que um sistema sensor é capaz de individualizar.

De acordo com Kramer (1996), resolução espacial é a menor unidade de distância que pode ser discriminada por um sensor em medidas no alvo. É uma função da geometria entre o sensor e o alvo no instante da medida.

Pode também, resolução espacial ser a medida para a menor separação angular ou linear entre dois objetos. Esta resolução está diretamente relacionada com o tamanho do pixel, ou seja, uma área em metros no terreno que o sensor é capaz de registrar. Por exemplo, uma resolução de vinte metros implica que objetos distanciados entre si a menos de vinte metros, em geral não são discriminados pelo sistema.

2.3.3.2 Resolução Espectral

Segundo Moreira (2001), resolução espectral refere-se ao poder de resolução que o sensor tem para discriminar diferentes alvos sobre a superfície terrestre. Em outras palavras, refere-se à melhor ou à pior caracterização dos alvos em função da largura da banda espectral em que o sensor opera.

Ela é definida pelo número de bandas espectrais de um sistema sensor e pela largura do intervalo de comprimento de onda coberto para cada banda. Quanto maior o número de bandas e menor a largura do intervalo, maior é a resolução espectral de um sensor.

2.3.3.3 Resolução Radiométrica

De acordo com Moreira (2001), a radiação eletromagnética refletida ou emitida pelos alvos da superfície terrestre, possui valor de intensidade que difere de um alvo para outro. Entretanto, certos alvos apesar de serem diferentes, refletem ou emitem a radiação eletromagnética com valores de intensidade muito próximos entre si, tornando-se quase idênticos espectralmente. Assim, resolução

radiométrica de um sensor, refere-se à capacidade que este sensor tem de poder discriminar, numa área imageada, alvos com pequenas diferenças de radiação emitida ou refletida.

Resolução radiométrica é dada pelo número de níveis digitais, representando níveis de cinza, usados para expressar os dados coletados pelo sensor. Quanto maior o número de níveis, maior é a resolução radiométrica. O número de níveis é geralmente expresso em função do número de dígitos binários necessários para armazenar em forma digital o valor do nível máximo.

2.3.3.4 Ciclo (Resolução Temporal)

Por Moreira(2001), ciclo ou resolução temporal está relacionada com a repetitividade de observação de um sensor numa mesma área da superfície terrestre. Resolução temporal refere-se a frequência com que o sensor imageia uma determinada área. É também referida como periodicidade ou repetitividade (IBGE, 2001).

Sensores remotos que tem a habilidade registrar uma mesma cena em intervalos de tempo relativamente curtos geram uma série de dados com boa resolução temporal.

Em contraste, sistemas que só podem gerar imagens de uma determinada região em grandes intervalos produzem dados com uma resolução temporal ruim (Campbell, 2002).

2.3.4 Satélites

É chamado de satélite todo objecto que gira em torno de outro objecto. Ele é classificado em dois tipos: satélite natural e satélite artificial. Em astronomia, um exemplo de satélite natural é a Lua, Pois ela gira em torno da Terra. Já o satélite artificial, como o próprio nome diz, é um equipamento ou engenho construído pelo homem e dependendo da finalidade, desloca-se em órbita da Terra ou de outro astro. A órbita é o caminho que o satélite percorre (Florenzano, 2008).

2.3.5 Sistemas de Informacao Geografica (SIG)

Segundo Alves (1990), SIG são ferramentas projetadas para coletar, manipular e apresentar grandes volumes de dados espaciais. Aronoff (1989) define SIG como um sistema de que permite gerir base de dados computacional para capturar, armazenar, recuperar, analisar e visualizar dados espaciais. Camara *et al.*, (2002) define o termo SIG como sistemas que realizam o tratamento computacional de dados geográficos e recuperam as informações não apenas com base em suas características alfanuméricas, mas também através de sua localização espacial.

2.3.6 Tipos de dados em SIG

De acordo com Ferreira (2006) os dados geográficos podem ser do tipo vectorial ou matricial. A figura 1 abaixo ilustra dados geográficos armazenados em estrutura vectorial e em estrutura matricial.




Figura 1: Tipos de dados em SIG (Ferreira, 2006)

2.3.6.1 Dados Matriciais

A estrutura matricial consiste em uma matriz bi-dimensional, que pode ser matematicamente definida como sendo uma função $f(x, y)$, composta por linhas e colunas, onde cada elemento desta estrutura contem um numero inteiro ou real, podendo ser negativo ou positivo. Cada elemento da estrutura matricial recebe o nome de célula ou pixel pode representar qualquer elemento do mundo real, como temperatura, altitudes, solos e vegetação (Aronoff, 1995).

2.3.6.2 Dados Vectoriais

De acordo com Silva (2002), dados no formato vectorial podem ser armazenados como pontos, linhas e polígonos, onde os pontos definem localizações discretas de elementos geográficos demasiadamente pequenos para serem descritos como linhas ou áreas, as linhas são definidas como um conjunto ordenado de pontos interligados por segmentos de recta ou por linhas e são utilizadas na representação de objetos sem largura suficiente para serem consideradas áreas e as áreas são um conjunto ordenado de pontos interligados em que o primeiro ponto e o ultimo coincidem utilizados quase sempre na representação de zonas que possuem uniformemente uma dada propriedade, ou seja, figura fechada cujos limites encerram uma área homogénea.

2.3.7 Processamento Digital de Imagens

O Processamento Digital de Imagens (PDI) consiste na aplicação de uma série de técnicas e métodos, cujo objetivo principal é o de remover as barreiras impostas pela limitação do olho humano, facilitando a extração de informações a partir de imagens (CRÓSTA, 1992).

A razão de bandas, composição colorida, realce, segmentação, classificação, entre outras, são exemplos de técnicas que permitem a interpretação e análise das imagens. Para Lillesand (2004), o PDI envolve a manipulação e a interpretação de imagens digitais com a ajuda de computadores. Para este autor, o PDI é um tema extremamente vasto, o que frequentemente envolve procedimentos que podem ser matematicamente complexos. O PDI divide-se em três etapas: Pré- Processamento, Processamento e Pós-Processamento.

2.3.7.1 Pré-processamento

Quando uma imagem é captada no centro de recepção terrestre ou registada nas fitas magnéticas a bordo dos satélites, contem um certo número de distorções que devem ser corrigidas antes da sua análise ou interpretação deste modo o pré-processamento consiste na preparação dos dados brutos de modo a melhorar a sua qualidade, de entre as técnicas mais empregues (Ferreira, 2006).

✓ Correção atmosférica

A interferência atmosférica é um dos principais factores de degradação nas imagens, muitas vezes comprometendo a análise e interpretação das mesmas. A intensidade deste efeito depende do comprimento de onda, portanto, ele afecta de modo diferente a cada uma das bandas espectrais (Ouaidrari e Vermote, 1999). A correção da imagem pode ser feita por meio de modelos matemáticos baseados em parâmetros atmosféricos que normalmente são desconhecidos, dificultando a aplicação dos modelos. Estes parâmetros devem ser obtidos na hora e data de passagem do satélite, por meio de estações meteorológicas e isto é um procedimento difícil (Longley *et al.*, 2008).

2.3.7.2 Processamento

Esta fase do PDI consiste nas técnicas que tem por objetivo melhorar a qualidade visual das imagens. Ela está relacionada com a extração de informações das imagens, e inclui entre outras técnicas, a segmentação e classificação de imagens. O resultado de uma operação de análise de imagem é uma descrição da imagem de entrada (lista de propriedade do objeto; posição, tamanho, formato), um campo

vetorial representando o movimento de objetos em uma sequência de imagens, mapas ou uma representação gráfica.

✓ **Composição colorida**

Trata-se de um dos artifícios de maior utilidade na interpretação das informações da Detecção Remota. Ela é fundamental para uma boa identificação e discriminação dos alvos terrestres. O olho humano é capaz de discriminar mais facilmente matizes de cores do que tons de cinza. A composição colorida é produzida na tela do computador, ou em outro dispositivo qualquer, atribuindo-se as cores primárias (vermelha, verde e azul) a três bandas espectrais quaisquer. Este artifício é também conhecido como composição RGB (do inglês: Red, Green, Blue).

Associando, por exemplo, a banda 3 à cor vermelha (R), a banda 4 à cor verde (G) e a banda 5 à cor azul (B), produz-se uma composição colorida representada por 345 (RGB), (Novo, 2010).

✓ **Classificação supervisionada**

Longley *et al* (2008) salienta que, ao contrário da classificação não-supervisionada, a classificação supervisionada requer conhecimentos prévios das classes de alvos, a fim de classificar a imagem nas classes de interesse pré-fixadas pelo analista. O algoritmo necessita ser treinado para poder distinguir as classes uma das outras. Nesse processo o analista escolhe pequenas áreas de amostras na imagem, contendo poucas centenas de pixels que sejam bem representativo espectralmente, de padrões ou feições dos alvos por ele reconhecidos ou que podem ser identificados com a ajuda de outras fontes, tais como dados coletados no campo ou de mapas. É necessário o conhecimento dos dados e das classes de objetos que existem na área, antes de se iniciar o processo de classificação. Não há nenhuma restrição no número de classes a serem classificadas, apenas que o analista faça uma seleção de classes bem distintas porque, caso contrário, no final da classificação ocorrerá muita confusão entre as classes. Se o treinamento tiver uma boa precisão, as classes resultantes representam as categorias dos dados que o analista identificou originalmente. Também, para assegurar uma boa classificação, as imagens devem ser corrigidas dos efeitos atmosféricos.

2.3.7.3 Pós-Processamento

Última fase do PDI que consiste nos detalhes finais na imagem, para que esta venha a corresponder com um maior grau de confiabilidade ao que está representado. Como procedimentos empregados nesta fase tem-se a filtragem, suavização de erro, validação, etc.

Nos estudos envolvendo sensoriamento remoto o PDI se constitui em um conjunto de técnicas e métodos indispensáveis para o entendimento das informações obtidas através das imagens orbitais. As reflectâncias dos objetos/alvos presentes na superfície terrestre e na atmosfera, que são capturadas e registradas pelos sensores serão interpretadas a partir do PDI. Através deste, é possível identificar e diferenciar os objetos presentes em uma determinada imagem a partir da reflectância espectral dos objetos na faixa do espectro eletromagnético.

✓ **Validação da classificação**

De acordo com Lillesand et al., (2004) uma das últimas etapas da classificação digital de imagens é a da validação dos resultados da classificação. O que se busca nessa etapa é avaliar a precisão da classificação. Um resultado com 100% de precisão significa que todos os pixels da imagem foram classificados de forma correta, segundo um conjunto de amostras utilizadas para a classificação das mesmas. Um resultado com 50% de precisão significa que em teoria, metade dos pixels da imagem foi classificada corretamente.

Os mesmos autores afirmam que a precisão depende de uma série de fatores como a complexidade do terreno, as resoluções espaciais e espectrais do sistema sensor, o próprio algoritmo de classificação utilizado, a legenda utilizada no processo de classificação e o conjunto de dados que representam a verdade terrestre. Por exemplo, considera-se os resultados da classificação de imagens de satélite de um determinado município. Se a legenda for composta de duas classes, terra e água, a precisão tende a ser maior do que a de outra legenda composta por três classes de vegetação natural, formações campestres, savanas e três classes de uso da terra culturas agrícolas, pastagens cultivadas e reflorestamento, a precisão é normalmente expressa em termos de índice Kappa que é calculado a partir de matrizes de erros que expressam a concordância entre a imagem classificada e o conjunto de amostras de referência. A matriz de erros compara classe por classe. O número de linhas e o número de colunas dessa matriz devem ser iguais ao número de classes espectrais do estudo.

Segundo Congalton e Green (1999), em avaliações de mapeamentos, o índice Kappa geralmente varia de 0 a 1, sendo que 0 indica a ausência de concordância ou seja, a estimativa e a referência são estatisticamente independentes e 1 indica total concordância. Valores negativos do índice Kappa podem ocorrer quando a concordância encontrada é menor do que aquela devido ao acaso, embora isso raramente ocorra em classificação de imagem. O índice Kappa é uma medida da concordância real (indicada pelos elementos da diagonal da matriz de confusão) menos a possibilidade de concordância (indicada pelo produto das linhas e colunas totais, que não incluem entradas não reconhecidas).

Landis & Koch (1977) propõem uma escala de avaliação da qualidade da classificação. Esta escala está exposta na Tabela 2 abaixo.

Tabela 2: Qualidade da classificação segundo intervalos do Índice Kappa (Landis e Koch, 1977)

Valor do Índice Kappa	Qualidade da Classificação
<0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito Boa
0,80 – 1,00	Excelente

2.3.8 Uso e Cobertura da terra

Os conceitos relativos ao uso da terra e cobertura da terra são muito próximos, por isso, muitas vezes são usados indistintamente. Cobertura da terra está diretamente associada com tipos de cobertura natural ou artificial, que é de fato o que as imagens de sensoriamento remoto são capazes de registrar. Imagens não registram atividades diretamente. Cabe ao interprete buscar as associações de reflectâncias, texturas, estruturas e padrões de formas para derivar informações acerca das atividades de uso, a partir do que é basicamente informações de cobertura da terra (Filho et. al., 2007).

Novo (1989) explica que o “termo Uso da Terra refere-se a utilização cultural da terra, enquanto que o termo “cobertura da terra” ou “land cover” refere-se ao seu revestimento”.

A autora exemplifica esta diferenciação onde “áreas florestais que, embora sejam de um só tipo sob o ponto de vista de cobertura, podem ter diferentes usos: lazer, exploração de madeira, reservas biológicas etc.”

Entende-se por cobertura de terra os elementos da natureza como a vegetação (natural ou plantada), água, gelo, rocha nua, areia e superfícies similares, além das construções artificiais criadas pelo homem, que cobrem a superfície da terra (Anderson et al., 1979). Por sua vez uso da terra é definido segundo Lesson (1993) como sendo qualquer modificação do padrão da terra resultante de actividade humana.

2.3.9 Comportamento espectral dos alvos

Os objectos da superfície terrestre reflectem e absorvem selectivamente energia electromagnética, devido a sua diferente composição molecular. Esta característica, denominada resposta espectral dos objectos, permite identificá-los numa imagem de detecção remota (Antunes, 2012).

A radiação solar incidente na superfície terrestre interage de modo diferente com cada tipo de alvo. Esta diferença é determinada principalmente pelas diferentes composições físico-químicas dos objectos ou feições terrestres. Estes factores fazem com que cada alvo terrestre tenha sua própria assinatura espectral. Em outras palavras, cada alvo absorve ou reflecte de modo diferente cada uma das faixas do espectro da luz incidente (Fig. 2). Tanto a irradiância (REM que chega aos alvos) como a radiância (REM que deixa os alvos) são fortemente afectadas em suas trajectórias pelos componentes atmosféricos. Áreas nubladas, por exemplo, são impossíveis de serem imageadas por meio da luz solar.




Figura 2: Curvas de reflectância espectral (Swai e Davis 1978)

A água apresenta uma curva de reflectância espectral muito característica, devido ao facto de absorver totalmente a REM para comprimentos de onda acima do visível e logo não reflectir praticamente nenhuma radiação nos comprimentos de onda do infravermelho.

As curvas de reflectância espectral dos solos reflectem essencialmente o teor em água, a sua textura, a rugosidade da superfície, as características físicas e químicas dos seus constituintes e o teor em matéria orgânica.

O aumento do teor em água produz uma diminuição dos valores de reflectância dos solos diminuindo a amplitude da curva de reflectância espectral e acentuando ligeiramente o efeito das bandas de absorção.

A reflectância espectral da vegetação apresenta uma grande variação em função do comprimento de onda. No visível, a pigmentação domina a resposta espectral, sendo o teor em clorofila o factor mais condicionante. A clorofila absorve fortemente a REM nos comprimentos de onda de 0.45 a 0.65 μm . No infravermelho próximo a reflectância aumenta porque a vegetação absorve muito pouca radiação nessa banda. No Infravermelho médio a vegetação verde absorve fortemente a radiação nos comprimentos de onda 1.4, 1.9 e 2.7 μm devido à presença do alto teor em água.

III. MATERIAL E MÉTODOS

3.1 Área de Estudo

Mecúfi é um distrito que localiza-se na província de Cabo Delgado, zona norte de Moçambique ressaltando $13^{\circ} 20' 29''$ de latitude sul e $40^{\circ} 32' 49''$ de longitude Este. Tem limite, a norte com o município de Pemba e com o distrito de Pemba Metuge, a oeste com o distrito de Ancuabe, a sul e sudoeste com o distrito de Chiúre e a leste com o Oceano Índico.

A região de Mecúfi caracteriza-se por albergar principais recursos naturais de cobertura da superfície terrestre que podem ser monitorados a partir de estudos de Sensoriamento remoto (SR) como ilustra a figura 3 a seguir:

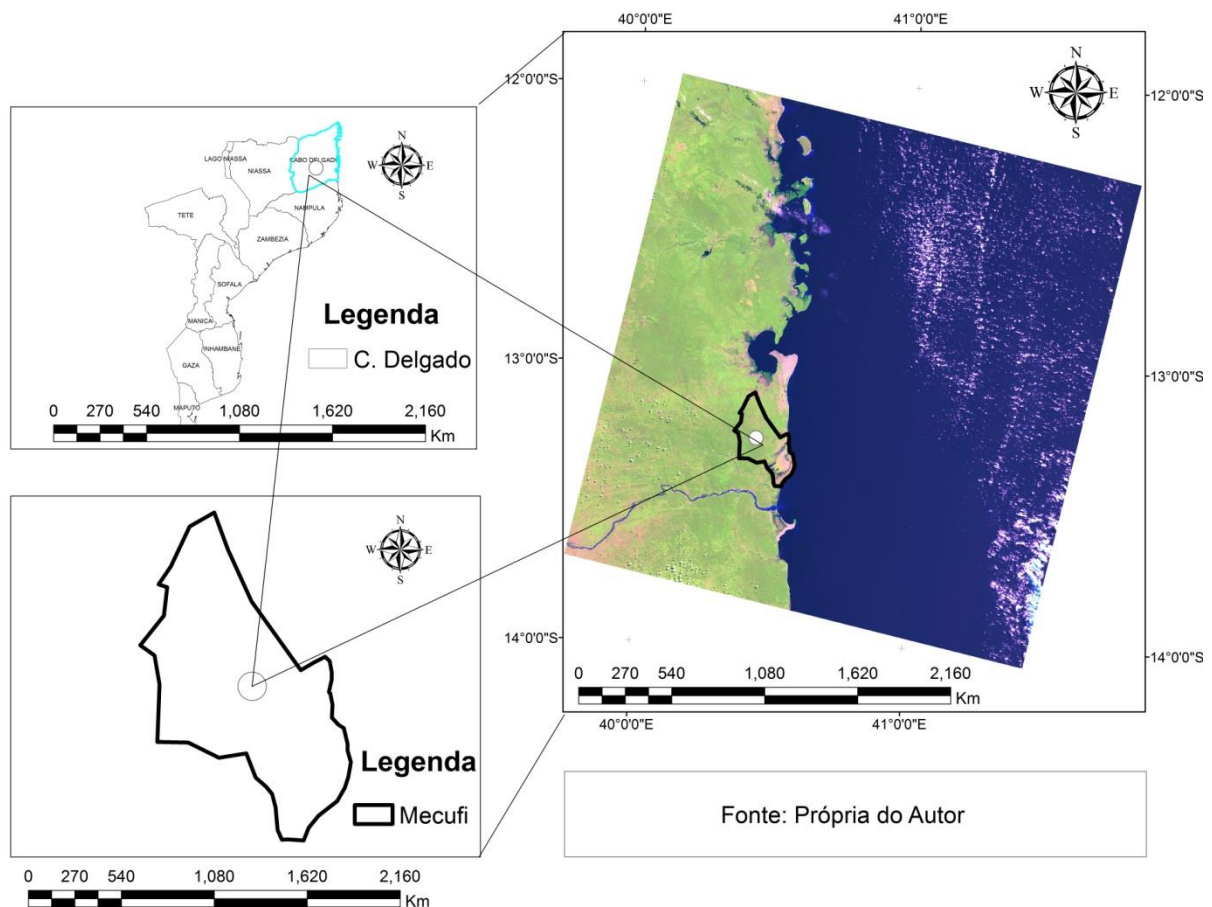


Figura 3: Localização da Área de Estudo

3.2 Material

Para a realização desta pesquisa foram usados os seguintes materiais:

- ⇒ O Software *Quantum Gis 2.14* para recortes e extração de máscaras da área a ser estudada;
- ⇒ *Shapefiles ou camadas vectoriais* oriundos da Divisão Administrativa de Moçambique;
- ⇒ O Software *ArcGis 10.5* para realizar o Processamento das cenas (imagens orbitais) de Landsat 5 Sensor TM e Landsat 8 Sensor OLI;
- ⇒ *Google Earth* para auxiliar no reconhecimento dos alvos de interesse, contornos da linha de costa e na validação dos dados;
- ⇒ *Planinha do Excel 2007 e Software Minitab 18* para cálculos de parâmetros estatísticos (valores mínimos, médios e máximos de reflectância para cada alvo de interesse);
- ⇒ Sistema Operacional *Windows 8.1* para armazenar os dados.

3.3 Métodos

De acordo com os objectivos propostos, a metodologia desta pesquisa consistiu na aquisição de dados e Processamento Digital de Imagens.

Na aquisição de dados, primordialmente fez-se o pré-registo para depois se proceder com o download de 2 cenas (imagens orbitais) de satélites Landsat 5-TM e Landsat 8-OLI numa série temporal de 17anos, datadas para 14/08/2001 e 23/04/2018, âmbas na órbita 164, ponto 69 e selecionadas de acordo com menor cobertura de nuvens. As bandas utilizadas no trabalho encontram-se patentes na tabela 3 a seguir:

Tabela 3: Bandas espectrais do Landsat 5 e Landsat 8 utilizadas no trabalho

Sensor TM		Âmbos Sensores			Sensor OLI	
Nº da Banda	Faixas espectrais (nm)	Resolução temporal	Resolução radiométrica	Resolução espacial	Nº da Banda	Faixas espectrais (nm)
1	485 (blue)	16 dias	16 bits	30 m	1	440 (coastal blue)
2	560 (green)	16 dias	16 bits	30 m	2	480 (blue)
3	660 (red)	16 dias	16 bits	30 m	3	560 (green)
4	830 (NIR)	16 dias	16 bits	30 m	4	655 (red)
5	1650 (SWIR-1)	16 dias	16 bits	30 m	5	865 (NIR)
7	2215 (SWIR-2)	16 dias	16 bits	30 m	6	1610 (SWIR-1)
		16 dias	16 bits	30 m	7	2200 (SWIR-2)

O PDI consistiu em 3 etapas nomeadamente: Pré-processamento, Processamento e Pós-processamento.

Para Pré-processamento fez-se a correção atmosférica no catálogo ESPA USGS e posteriormente reprojectadas para WGS 1984 UTM Zona 36S, conversão dos números digitais (ND) em valores de reflectância, recortes e extrações de máscaras de área de estudo. Para Processamento foram feitos, contornos da linha de costa, composições coloridas, mapeamentos a partir do algoritmo MAXVER da classificação supervisionada, cálculos de índices espectrais e cálculos de parâmetros estatísticos envolvendo valores mínimos, médios e máximos de reflectância de superfície para cada alvo e por fim Pós-processamento consistiu na avaliação da acurácia dos dados.

Os procedimentos realçados podem ser explicados a partir no fluxograma metodológico (figura 4) a seguir:

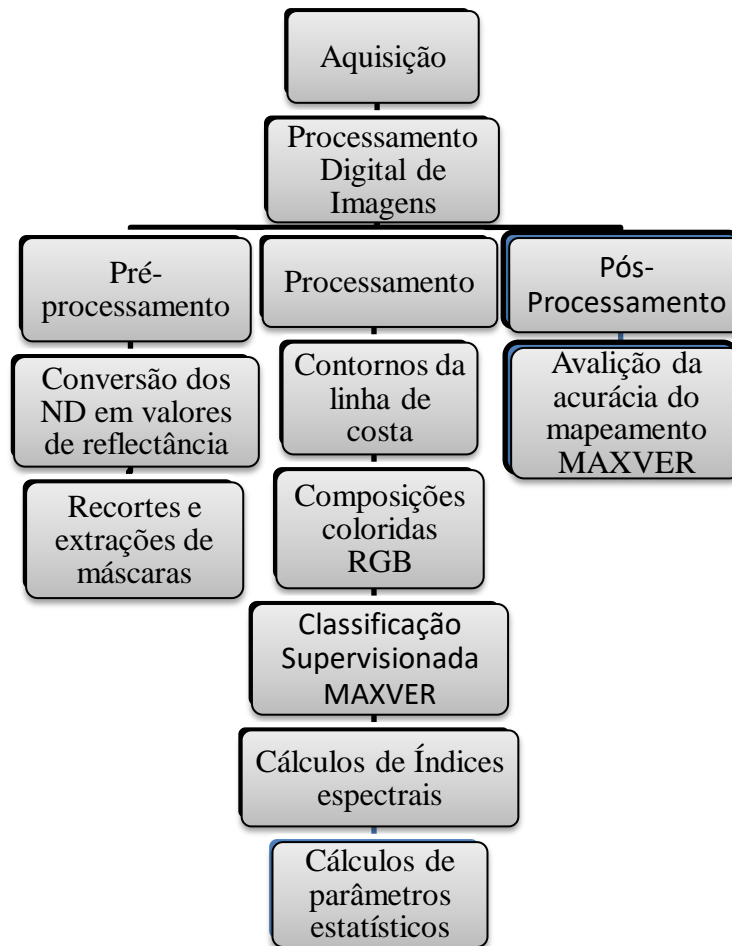


Figura 4: Fluxograma metodológico

3.3.1 Determinação das taxas de variação da linha de costa entre os anos 2003-2018

Criou-se shapefiles de linhas na ferramenta ArcCatalog e selecionou-se a banda do infravermelho próximo para sobrepor os contornos, assim sendo pelo facto de os corpos hídricos absorverem maiores radiações e os outros alvos refletirem a radiação incidente nessa banda, por outro lado pelo facto de não se notarem os materiais suspensos na coluna de água, pois estes atrapalham na delimitação de linha de costa. Por conseguinte os resultados não foram satisfatórios, recorreu-se ao Google Earth onde os contornos foram exportados no formato Kml para serem visualidos no ArcGIS 10.5.

De 2003-2010, a área A retrogradou com valor de 22,6m, no intervalo de 2010-2016 cerca de 30,5m, 2016-2018 a ferramenta ruler fez cerca de 5,8m e de 2003-2018 foi cerca de 59,5m de recuo.

Para área B, de 2003-2010 a ferramenta ruler marcou 4,5m, 2010-2016 houve uma retrogradação de 33,1m, 2016-2018 a distância foi de 12,6m e de 2003-2018 a houve uma erosão por cerca de 52,3m.

É de salientar que os critérios de delimitação de linha de costa basearam-se em identificar a linha que discrimina areia seca da húmida e adaptou-se a equação do movimento retilíneo uniforme (MRU) para determinar a velocidade de propagação da linha de costa ou taxas de variação.

$$s = s_0 + vt \quad (4)$$

Supondo que s_0 seja espaço inicial igual a zero, a expressão fica afinada para $v = \frac{s}{t}$ (5)

Onde: **v**- representa a velocidade de propagação da linha de costa, **s**- a distância de separação entre linhas e **t**- o tempo em anos.

3.3.2 Mapeamento de cobertura de solo nos anos 2001 e 2018 usando o algoritmo máxima verossimilhança

Foram acopladas todas bandas espectrais no canal RGB (red, green, blue), assim sendo selecionou-se a composição colorida 5,4,3 para Sensor TM e 6,5,4 para Sensor OLI de acordo com a metodologia proposta por Piroli *et al.*, (2002), sendo que esta combinação é utilizada para avaliação de recursos ambientais (Disperati *et al.*, 2003). Fez-se a coleta de 5 amostras de corpos hídricos, bancos submersos, área de cultivo, solos expostos, vegetação e mangal totalizando 30 pontos como ilustra a figura a seguir:




Figura 5: Composição colorida RGB (6,5,4). Ponto 1 representa solos expostos, ponto 2 vegetação, ponto 3 área de cultivo, ponto 4 bancos submersos e ponto 5 corpos hídricos.

As classes foram delimitadas de acordo com a tabela 4 a seguir:

Tabela 4: Delimitação das classes da cobertura de solo

Classes de cobertura de solo	Descrição
Corpos hídricos	São as feições referentes a lagos, lagoas e outros corpos d'água localizados na área interna do continente.
Bancos submersos	Consistem no acúmulo de areia no meio de um curso de água (como um rio) ou ao longo da costa marítima. Suas formações num rio se dão pelo depósito de aluvião, através de braços do rio. Nas praias os bancos podem se formar pelo fluxo e refluxo do mar ou pela ação das ondas.

Áreas de cultivo	Conjunto de plantações, como milho, arroz, batata, feijão, laranjeiras e coqueiros. Sendo elas tanto temporária quanto permanente.
Solos expostos	São solos que carecem de cobertura vegetal e por sua vez podem ser suscetíveis a inundações. Sendo eles secos e húmidos.
Vegetação	Conjunto de árvores de menor porte e grande porte. Capim e ervas com coloração verde.
Mangal	É um ecossistema costeiro, localizado na planície de maré que possui água salgada e são típicas de áreas estuarinas, com intensa diversidade de vida aquática.

Em seguida foram agrupados pixels de mesma classe homogênea na janela de treinamento e escolheu-se o algoritmo Máxima Verossimilhança que assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixel pertencer a uma classe específica. (INPE, 2006).

3.3.3 Avaliação da acurácia do mapeamento MAXVER

Foi feita uma amostragem aleatória correspondente a 30 pontos na ferramenta *Random Points* do ArcGis para cada alvo selecionado. Após a sobreposição dos pontos nas imagens classificadas, estes foram exportados para Google Earth (imagem de referência), onde se estabeleceu a confirmação semelhante a veracidade terrestre, devido a resolução que é tão maior em relação as imagens de Landsat. Geralmente a verificação é realizada em campo, no entanto, devido à inviabilidade de acesso à área optou-se neste método.

Aposterior confirmou-se no Google Earth as datas de cada cena (imagens orbitais) e em seguida elaborou-se a matriz de confusão ou tabela de contingência na planilha do excel.

3.3.3.1 Matriz de Confusão e Coeficiente de Concordância Kappa

Segundo Rennó et al. (1999), a matriz de confusão serve para avaliar os erros do resultado final da classificação (o mapa temático) em relação aos dados de referência (verdade do campo, amostras de teste ou outro mapa). Por um outro lado, a incerteza está relacionada às dúvidas surgidas durante o processo de classificação, no momento da atribuição do pixel ou objeto a uma determinada classe. Em outras palavras, a matriz de confusão serve para avaliar a qualidade do mapa, e a incerteza para avaliar a qualidade do processo de classificação.

Congalton e Green (1999), propuseram uma representação matemática da matriz de confusão segundo a tabela 5 a seguir:

Tabela 5: Representação matemática da matriz de confusão. Fonte: Congalton e Green (1999)

		$i = \text{colunas (referência)}$			Total da linha
		1	2	k	X_{i+}
$i = \text{linhas (classificação)}$	1	X_{11}	X_{12}	X_{1k}	X_{1+}
	2	X_{21}	X_{22}	X_{2k}	X_{2+}
	k	X_{k1}	X_{k2}	X_{kk}	X_{k+}
Total da coluna	X_{+j}	X_{+1}	X_{+2}	X_{+k}	N

Segundo Congalton e Green (1999), a matriz de confusão é um bom método para avaliar a qualidade da classificação, pois descreve a exatidão de cada classe com seus erros de comissão (quando um elemento é incluído em uma classe à qual ele não pertence) e omissão (quando um elemento é excluído da classe à qual pertence).

A partir da matriz de confusão, foi possível calcular algumas medidas descritivas como a exatidão global, exatidão do usuário, exatidão do produtor, índice kappa, erros de omissão e erros de inclusão.

A exatidão global (Eg) é a razão entre a soma de todos os elementos classificados corretamente pelo número total de elementos. Esta medida é calculada pela expressão:

$$Eg = \frac{\sum_{i=1}^r x_{ii}}{N} \quad (6)$$

Onde :

x_{ii} = Elementos da diagonal principal

r = Número de classes

N = Número total de amostras

A exatidão do usuário (Eu) é expressa pela razão do número de elementos classificados corretamente em uma classe pelo número total de elementos classificados na mesma.

Esta medida reflete os erros de comissão da classificação e indica a probabilidade de um elemento classificado em uma determinada categoria realmente pertencer à mesma (Lillesand e Kiefer, 1994). É calculada segundo a expressão:

$$Eu = \frac{x_{ii}}{x_{i+}} \quad (7)$$

Onde:

x_{ii} = Número de elementos classificados corretamente

x_{i+} = Total de elementos classificados para uma categoria i

A exatidão do produtor (Ep) é a razão entre o número de elementos classificados corretamente em uma determinada categoria pelo número de elementos de referência amostrados para a mesma categoria (Lillesand e Kiefer, 1994). Esta medida reflete os erros de omissão da classificação sendo expressa por:

$$Ep = \frac{x_{ii}}{x_{+i}} \quad (8)$$

Onde:

x_{ii} = Número de elementos classificados corretamente

x_{+i} = Total de elementos de referência amostrados para uma categoria i

Outra medida bastante conhecida e também calculada a partir da matriz de confusão é o coeficiente de concordância Kappa. Segundo Congalton e Green (1999), este coeficiente é baseado na diferença entre concordância observada (diagonal principal da matriz de confusão com a concordância entre a classificação e os dados de referência) e a chance de concordância entre os dados de referência e uma classificação aleatória (produto entre os totais marginais da matriz). O cálculo do Kappa é expresso por:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad (9)$$

Onde :

r = Número de classes

x_{ii} = Número de elementos classificados corretamente

x_{i+} = Total de elementos classificados para uma categoria i

x_{+1} = Total de elementos de referência amostrados para uma categoria i

N = Número total de amostras

No resultados de classificação distinguem-se dois tipos principais de erros: erros de omissão e erros de inclusão (Centeno, 2009).

Os erros de omissão são pixels pertencentes a uma dada classe que foram erroneamente classificados como sendo da outra, ou seja, foram omitidos da classe. Estes erros podem ser avaliados para cada classe dividindo-se o número de pixels incorretamente classificados da classe pela soma parcial da linha da mesma classe:

$$Eom_{(i)} = \frac{\sum l_{(i)} - di}{\sum l_{(i)}} \quad (10)$$

Onde :

$\sum l_{(i)}$: é a soma parcial da linha i ;

di : é o elemento da diagonal na linha i

Já os erros de inclusão correspondem aos pixels que sendo na realidade de outra classe, foram incluídos na classe considerada. Este erro pode ser medido por:

$$Ein_{(i)} = \frac{\sum c_{(i)} - di}{\sum c_{(i)}} \quad (11)$$

Onde:

$\sum c_{(i)}$: é a soma parcial da coluna i ;

di : é o elemento da diagonal na coluna i

Os erros de omissão e de inclusão são elementos que servem para avaliar quanto cada classe foi sub ou superestimada. A primeira estatística, erros de omissão serve para descrever com precisão uma determinada classe definida. Já a taxa de erros de inclusão indica quanto cada classe foi superestimada (Centeno,2009).

3.3.4 Estimação de valores mínimos e máximos dos limiares de reflectância dos índices espectrais para discriminar os alvos

Adaptou-se 2 modelos matemáticos para converter números digitais das bandas espectrais em valores de reflectância da superfície. O primeiro modelo consistiu em escalar as bandas na divisão pelo factor 10000 no sentido de reduzir os seus valores mínimos e máximos e o segundo modelo consistiu em condicionar as bandas escalas com finalidade de converter os valores negativos para positivos, com intuição de não atrapalhar na álgebra dos índices espectrais.

$$X_{escalado} = \frac{B_n}{10000} \quad (a)$$

Onde: **X** é resultado da banda escalada; n - número da banda; **B**- banda e 10000 constante.

$$Cond(X_{escalado} < 0,0x_{escalado}) \quad (b)$$

Onde: **Cond** é a condição e **X**- banda escalada

Usou-se banda da região do infravermelho próximo (NIR) e do vermelho (Red) para calcular índice de vegetação por diferença normalizada (NDVI) de acordo com a equação:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (12)$$

Este índice serve para ressaltar a vegetação e minimizar outros alvos. De acordo com Rouse et al., (1973) o NDVI é o índice que permite fazer análise da vegetação de uma determinada região, são bons indicadores para discriminar áreas verdes os seus valores variam de -1 a +1 em que superfícies cobertas por vegetação, esses valores são sempre positivos; enquanto em nuvens e em espelhos d'água, os valores são geralmente negativos, quanto mais próximo de 1, maior a densidade da cobertura vegetal, ou seja, ela se apresenta em seu estágio denso, húmida e bem desenvolvida, gradualmente esse valor diminui em uma vegetação menos densa (rala e esparsa), que apresenta valores positivos, mas não muito elevados.

Usou-se a banda da região do verde (Blue) e infravermelho próximo (NIR) para calcular índice de água por diferença normalizada (NDWI) de acordo com a equação abaixo:

$$NDWI = \frac{Green-NIR}{Green+NIR} \quad (13)$$

O valor de NDWI varia de -1 para 1. McFeeters (1996) definiu zero como o limiar. Isto é, o tipo de cobertura é água se $NDWI \geq 0$ e não água se $NDWI \leq 0$. O NDWI proposto por Mcfeeters permite: (1) maximizar a reflectância típica da água usando o comprimento de onda da luz verde (TM2); (2) minimizar a baixa reflectância dos corpos de água no infravermelho próximo (TM4); e (3) realçar o contraste entre a água e a superfície terrestre proporcionada pela banda infravermelha.

Usou-se a banda da região do infravermelho próximo (NIR) e do vermelho (RED) para calcular índice de vegetação RATIO segundo a equação:

$$RATIO = \frac{NIR}{RED} \quad (14)$$

De acordo com Eastman (1998), o Ratio Vegetation Index (RATIO) foi proposto por Rouse *et al.*, (1974) para separar vegetação verde de solo utilizando Imagem Landsat – MSS. O RATIO é produzido por uma simples divisão de valores de reflectância contidos em bandas do infravermelho próximo por aqueles contidos na banda do vermelho.

Usou-se a banda da região do infravermelho próximo (NIR) e do vermelho (Red) para calcular índice de vegetação ajustado por solos (SAVI) de acordo com a equação:

$$SAVI = \frac{NIR-RED}{NIR-RED+L} * (1 + L) \quad (15)$$

O Soil Adjusted Vegetation Index (SAVI) que foi proposto por Huete (1988) possui a propriedade de minimizar os efeitos do solo de fundo no sinal da vegetação ao incorporar uma constante de ajuste de solo, o fator L no denominador da equação NDVI. O fator L varia com a característica da reflectância do solo (calor e brilho) e vai variar dependendo da densidade da vegetação que se deseja analisar. Para vegetação muito baixa, é sugerido utilizar o fator $L = 1,0$, para vegetação intermediária $L = 0,5$, para altas densidades $L = 0,25$. A utilização do $L = 0$, valores do SAVI serão idênticos ao NDVI.

Onde: L representa variável de ajuste do solo

Usou-se banda do infravermelho de onda curta (SWIR), banda do vermelho (RED) e a banda do azul (BLUE) para calcular índice de solo exposto (BI) de acordo com a equação:

$$BI = \frac{[(SWIR+R)-(NIR+B)]}{[(SWIR+R)+(NIR+B)]} \quad (16)$$

Chen (2004) propôs este índice solo exposto (BI) para derivar terra nua.

Usou-se a banda da região do infravermelho próximo (NIR) e do verde (GREEN) para calcular índice de umidade por diferença normalizada (NDMI) de acordo com a equação abaixo:

$$NDMI = \frac{NIR-Green}{NIR+Green} \quad (17)$$

O Normalized Difference Moisture Index - NDMI está relacionado com a quantidade de umidade presente no dossel da vegetação, a partir dos canais do infravermelho próximo e da luz verde visível, que refletem mudanças em ambos o teor de água, e absolvem a radiação de energia refletida pelas bandas (Gao, 1996).

Os valores elevados de NDMI (em verde) correspondem ao alto conteúdo de água na vegetação. Valores baixos NDMI (em vermelho) correspondem ao baixo teor de água da vegetação (Stephanie, 2011).

Usou-se a banda do infravermelho médio (SWIR) e infravermelho próximo (NIR) para calcular índice de área construída por diferença normalizada.

$$NDBI = \frac{SWIR-NIR}{SWIR+NIR} \quad (18)$$

O NDBI (Normalized Difference Built-up Index) é um índice radiométrico desenvolvido para identificar áreas urbanas e construídas, tendo como base o grande incremento de resposta espectral das áreas construídas entre as bandas do infravermelho próximo e infravermelho médio.

Usou-se a banda do infravermelho distante (SWIR 2) e infravermelho próximo (NIR) para calcular índice urbano.

$$UI = \frac{SWIR\ 2 - NIR}{SWIR\ 2 + NIR} \quad (19)$$

Usou-se as bandas do infravermelho próximo (NIR), a banda do vermelho (RED) e banda do infravermelho médio (SWIR) para calcular índice específico de área foliar a seguir:

$$SLAVI = \frac{NIR}{RED + SWIR} \quad (20)$$

A posterior fez-se as melhores composições coloridas dos índices que ajudaram na separação dos alvos, no canal RGB (BI,RATIO,NDWI) e RGB (BI,SLAVI,NDWI), esta sequência está de acordo com a figura 6, da esquerda para direita.

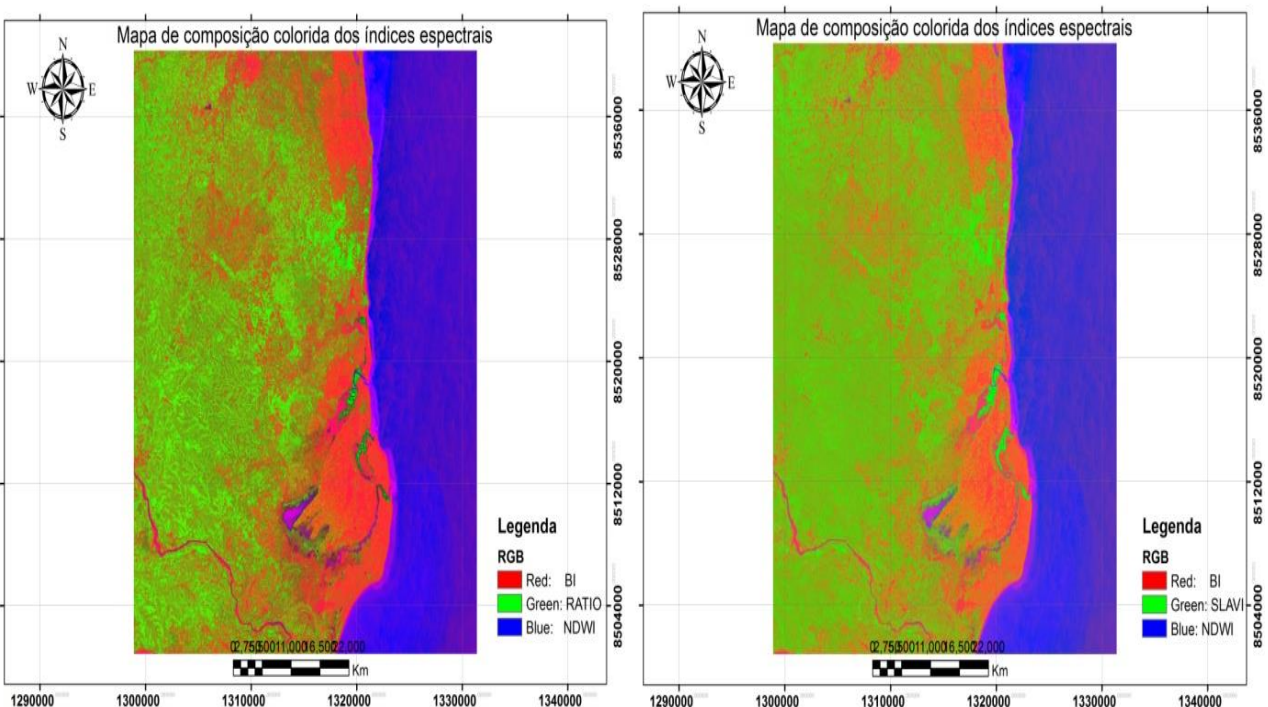


Figura 6: Lista de melhores composições coloridas RGB

IV. RESULTADOS

4.1 Determinação das taxas de variação da linha de costa entre os anos 2003-2018




Figura 7: Mapa da banda do infravermelho próximo sem mudanças

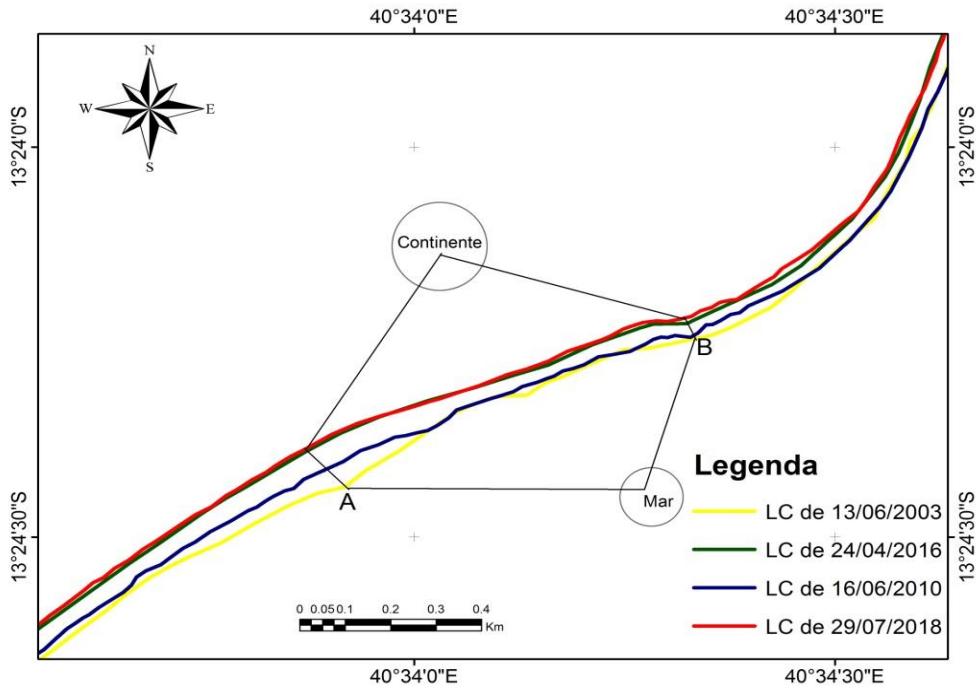


Figura 8: Mapa de contornos digitalizados no Google Earth com mudanças

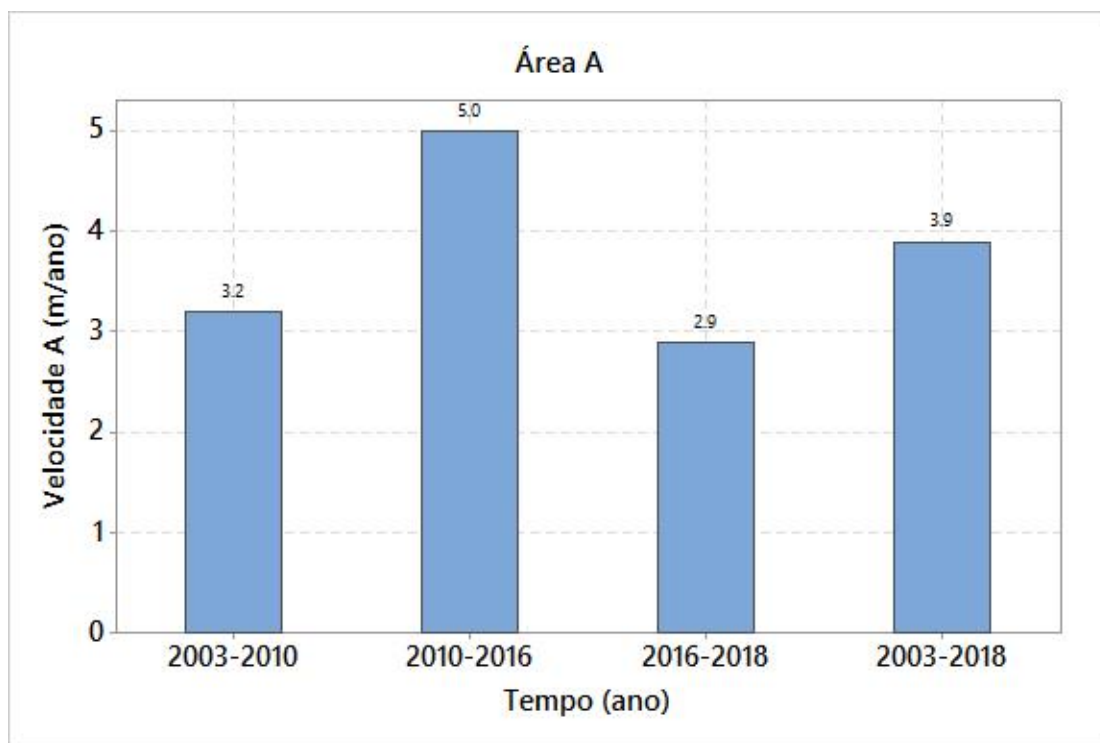


Figura 9: Gráfico da área A

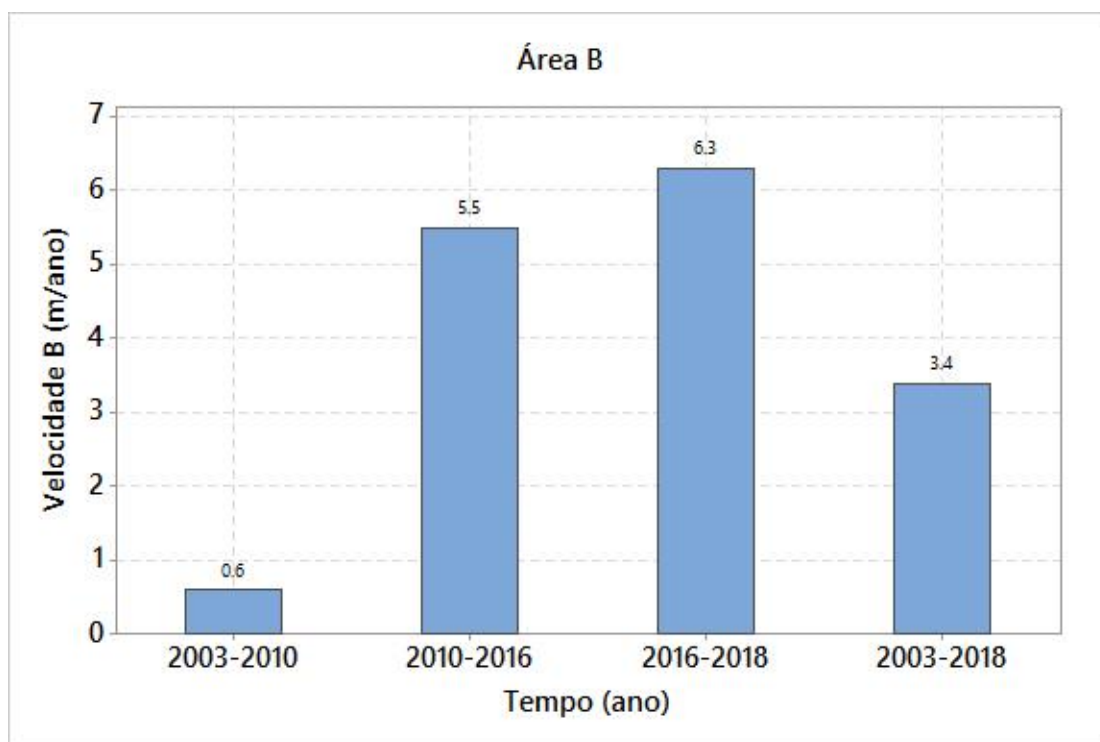


Figura 10: Gráfico da área B

Analisando a figura 10, o pico mínimo de recuo da linha de costa foi verificado no intervalo de 2016-2018 com uma taxa de 2,9m/ano e pico máximo no intervalo de 2010-2016 apontando uma taxa correspondente a 5m/ano da parte erodida.

De acordo com a figura 11, houve uma distinção em que o pico mínimo foi no intervalo 2003-2010 para 0,6m/ano e pico máximo de retrogradação em direcção ao continente fazendo 6,3m/ano no intervalo de 2016-2018.

4.2 Mapeamento da cobertura de solos nos anos 2001 e 2018 usando o algoritmo máxima verossimilhança

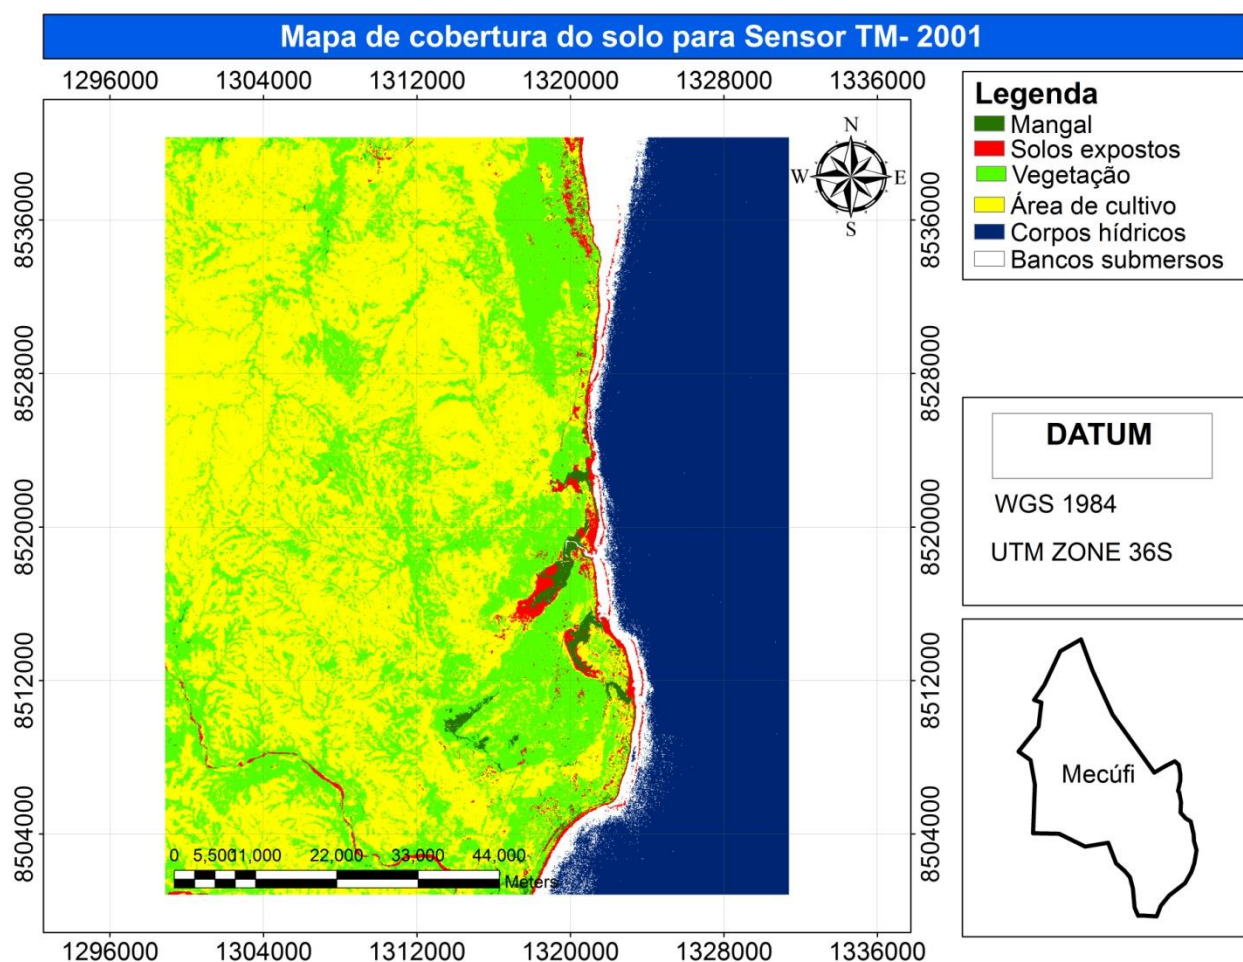


Figura 11: Mapa do uso e cobertura de solos para Sensor TM-2001

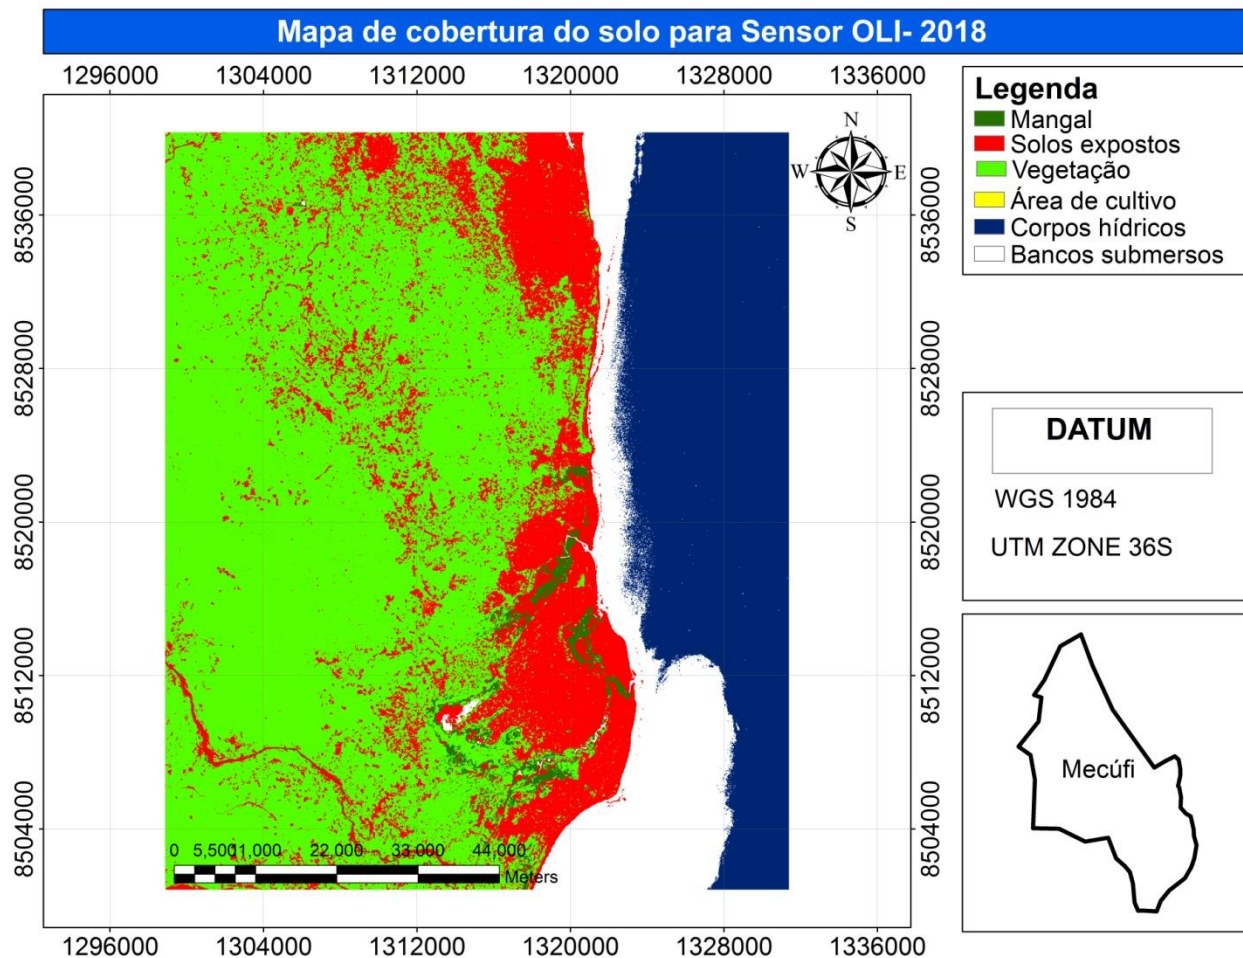


Figura 12: Mapa do uso e cobertura de solos para Sensor OLI-2018

Tabela 6: Quantificação das áreas dos alvos de uso e cobertura de solos para 2001-2018

Ano	2001		2018	
	Hectares (ha)	%	Hectares (ha)	%
Mangal	11,7	0,91	16,3	1,26
Solos expostos	20,5	1,59	221,2	17,2

Vegetação	300,2	23,3	649,8	50,6
Área de cultivo	558,9	43,5	1,04	0,08
Corpos hídricos	352,5	27,4	269,7	21
Bancos submersos	39,8	3,1	125,6	9,78
Total	1283,6	100	1283,64	100

As figuras 11, 12 e tabela 6, pode se inferir que em 2001 a classe de mangal ocupou cerca de 11,7 ha correspondendo (0,91%) da área total da imagem, para solos expostos quantificou-se 20,5 ha equivalendo (1,59%) da área total, a vegetação aponta 300,2 ha que corresponde (23,3%), área de cultivo 558,9 ha no percentual de (43,5%), corpos hídricos 352,5 ha no percentil de (27,4 %) e bancos submersos cerca de 39,8 ha correspondentes a (3,1%).

Para 2018, o mangal quantificou-se em 16,3 ha com percentual de (1,26%), solos expostos com 221,2 ha fazendo registo de (17.2%), vegetação cerca de 649,8 ha correspondendo (50,6%), a área de cultivo aponta 1,04 ha com percentil de (0,08%), corpos hídricos fazendo cerca de 269,7 ha com percentageml (21%) e por fim bancos submersos com 125,6 ha correspondendo (9,78%).

Comparando os dois resultados (2001-2018), o mangal executou um aumento de 4,6 ha fazendo um percentil de (0,35%), solos expostos apontam um aumento de 200,7 ha correspondendo a (15,61%), a vegetação mostra um aumento de 349,6 ha fazendo (27,3%) da área total, o que difere de área de cultivo reduzindo pelo factor de 557,86 ha para (43,42%) da área total, corpos hídricos também registam uma diminuição de 82,8 ha no percentil (64%) e por outro lado a classe de bancos submersos aumentam pelo factor 85,8 ha num valor de (6,68%).

4.3 Avaliação da acurácia do mapeamento MAXVER

Tabela 7: Matriz de confusão/tabela de contingência para 2001, onde M- representa mangal, SE- solos expostos, V- vegetação, AC- área de cultivo, CH- corpos hídricos e BS- bancos submersos totalizando 6 classes.

Em termos de medidas descritivas da acurácia: AP- acurácia do produtor, EO- erros de omissão, EG- exatidão global, AU- acurácia do usuário e EC- erros de comissão.

A exatidão global e índice kappa são indicadores para avaliar o nível de concordância entre a classificação gerada pelo algoritmo e dado de referência. A distinção entre estes, regista-se pelo facto de o primeiro refletir o pontos amostrais correctamente classificados e o segundo evidencia o pontos efectuados com sucesso e os erroneamente classificados.

Sensor TM - 2001									
	M	SE	V	AC	CH	BS	Total(usuário)	AU	EC
M	8	0	0	1	0	0	9	88,9%	11,1%
SE	3	19	0	0	0	0	22	86,4%	13,6%
V	5	0	17	6	0	0	28	60,7%	39,3%
AC	10	1	13	23	0	0	47	48,9%	51,1%
CH	0	0	0	0	30	14	44	68,2%	31,8%
BS	4	10	0	0	0	16	30	53,3%	46,7%
Total(produtor)	30	30	30	30	30	30	180		
AP	26,7%	63,3%	56,7%	76,7%	100,0%	53,3%			
EO	73,3%	36,7%	43,3%	23,3%	0,0%	46,7%			
EG	62,7%								
Índice kappa	55,3%								

Tabela 8: Matriz de confusão/tabela de contingência para 2018

Sensor OLI - 2018									
	M	SE	V	AC	CH	BS	Total(usuário)	AU	EC
M	11	0	0	0	0	0	11	100,0%	0,0%
SE	2	18	0	1	0	0	21	85,7%	14,3%
V	8	10	29	10	0	0	57	50,9%	49,1%
AC	9	2	1	19	0	0	31	61,3%	38,7%
CH	0	0	0	0	30	24	54	55,6%	44,4%
BS	0	0	0	0	0	6	6	100,0%	0,0%
Total(produtor)	30	30	30	30	30	30	180		
AP	36,7%	60,0%	96,7%	63,3%	100,0%	20,0%			
EO	63,3%	40,0%	3,3%	36,7%	0,0%	80,0%			
EG	62,7%								
Índice kappa	55,3%								

Os valores da diagonal principal, representam pontos que foram classificados correctamente pelo algoritmo MAXVER. Ignorando a diagonal principal, pode-se fazer uma análise também em termos de linhas e colunas em âmbas tabelas, na qual as linhas representam pontos amostrais que foram erroneamente incluídos numa categoria inexata (comissão) e as colunas representam pontos amostrais que foram erroneamente excluídos na categoria exata (omissão).

Fazendo referência a tabela do Sensor TM- 2001, num total de 180 pontos coletados para todas classes, 113 foram classificados com sucesso e 67 mal classificados. Estes resultados também se encontram patentes no Sensor OLI- 2018.

Houve uma convergência em âmbas tabelas no tange aos corpos hídricos, 100% da exatidão do produtor e 0,0 % para erros de omissão.

A classe de mangal registou 26,7% da acurácia do produtor e 73,3% foram omitidos e confundidos com a classe de área de cultivo.

A classe de solos expostos apresentou 63,3% da exatidão do produtor, o que significa que 36,7% das amostras omitidas e confundidas com bancos submersos.

Registou-se a exatidão do produtor para a classe de vegetação com cerca de 56,7% e 43,3% foram omitidos e confundidos com área de cultivo.

Área de cultivo tendo apresentado 76,7% da exatidão do produtor e 23,3% dos pontos omitidos e confundidos com vegetação.

Ao contrário dos bancos submersos com 53,3% da acurácia do produtor e 46,7% dos pontos omitidos e confundidos com corpos hídricos.

A análise feita concernente a exatidão do usuário, para a classe de mangal foi de 88,9% das amostras visitadas correctamente no Google Earth e 11,1% foram incluídas e confundidas com área de cultivo.

Na classe de solos expostos, 86,4% de exatidão do usuário e 13,6% dos pontos amostrais incluídos e confundidos com mangal.

A exatidão do usuário para classe de vegetação foi de 60,7% e 39,3% pixels foram incluídos e confundidos com área de cultivo.

Para área de cultivo no que concerne a exatidão do usuário, registou-se 48,9% e 51,1% dos pixels foram incluídos e confundidos com vegetação.

A classe de corpos hídricos apresenta acurácia do usuário tangente à 68,2% e 31,8% dos pontos amostrais incluídos e confundidos com bancos submersos.

Focalizando bancos submersos, a exatidão do usuário foi de 53,3% e 46,7% dos pixels foram erroneamente incluídos e confundidos com corpos hídricos.

A classe que apresentou maior exatidão quando se refere ao produtor foi de corpos hídricos fazendo 100% e menor exatidão mangal cobrindo cerca de 26,7%. Refletindo os erros de omissão, pode se inferir que o maior foi de mangal com 73,3% e menor erro para bancos submersos com cerca 0,0%.

Quando procura-se analisar maior acurácia do usuário, nota-se na classe de mangal fazendo 88,9% e menor exatidão ou acurácia para a categoria bancos submersos com 53,3%. Quanto aos erros de comissão, maior erro regista-se na classe de área de cultivo para 51,1% e menor erro na categoria de mangal fazendo 11,1%.

Houve também uma convergência referente aos dois Sensores, para acurácia global de 62,7% e 55,3% de índice de concordância kappa.

Já para Sensor OLI- 2018, os corpos hídricos apresentam 100% da acurácia do produtor e 0,0% dos erros de omissão, o mesmo registado para Sensor TM- 2001.

A classe de mangal aponta 36,7% da exatidão do produtor e 63,3% dos pontos coletados foram excluídos e confundidos com área de cultivo.

Para solos expostos, o cenário foi da acurácia do produtor apresentar 60% e 40% das amostras de referência omitidas e confundidas com a classe de vegetação.

Exatidão do produtor referente a categoria de vegetação é de 96,7% de acerto e 3,3% dos pixels omitidos e confundidos com área de cultivo.

Olhando para a categoria de área de cultivo, acurácia do produtor registou 63,3% e 36,7% dos pontos foram erroneamente excluídos e confundidos com vegetação.

No que concerne a classe dos bancos submersos, a exatidão do produtor aponta 20% e 80% dos pixels mal classificados e confundidos com corpos hídricos.

Na exatidão do usuário, as classes de mangal e bancos submersos apontam 100% dos pontos visitados perfeitamente no Google earth e 0,0% dos pontos destas classes significa que não houve nenhuma confusão.

Os solos expostos, apresentam 85,7% de exatidão do usuário, significando que 14,3% das amostras de referência foram erroneamente incluídas e confundidas com mangal.

A categoria de vegetação, enfoca para acurácia do consumidor fazendo 50,9% e 49,1% dos pixels incluídos e confundidos como solos expostos e área de cultivo.

Para a categoria destacada como área de cultivo, registou-se 61,3% e 38,7% dos pontos incluídos e confundidos como mangal.

A categoria denominada por corpos hídricos, fez cerca 55,6% e 44,4% dos pixels incluídos e confundidos são de bancos submersos.

Com base nos erros, notou-se maior erro de omissão para a classe de mangal com 63,3% e menor erro para corpos hídricos fazendo 0,0%.

A classe de mangal e bancos submersos obtiveram menor erro de comissão correspondente 0,0% na tabela de contingência. Ao passo que a categoria de vegetação aponta maior erro de 49,1%.

Outra análise estabelecida foi de exatidão global/geral com valor 62,7% e índice kappa fazendo 55,3%.

4.4 Estimação de valores mínimos e máximos dos limiares de reflectância dos índices espectrais para discriminar os alvos

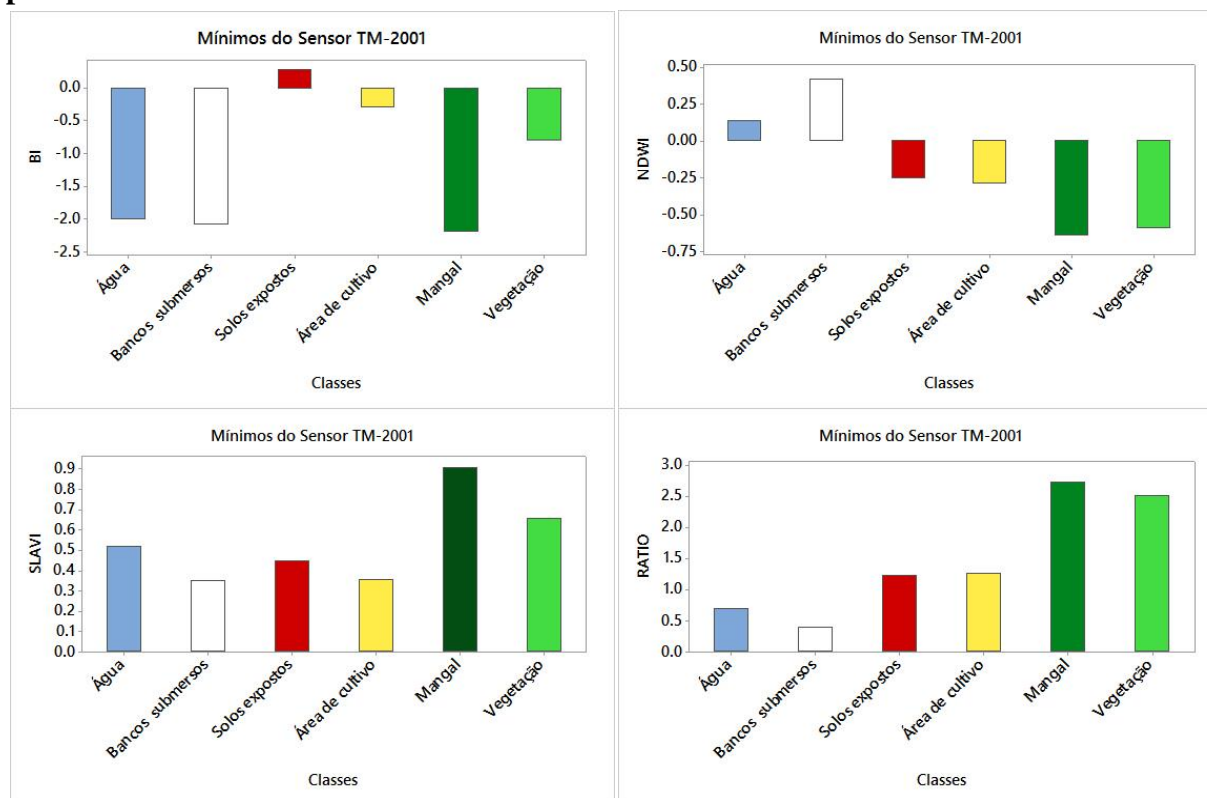


Figura 13: Gráficos dos valores mínimos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor TM-2001

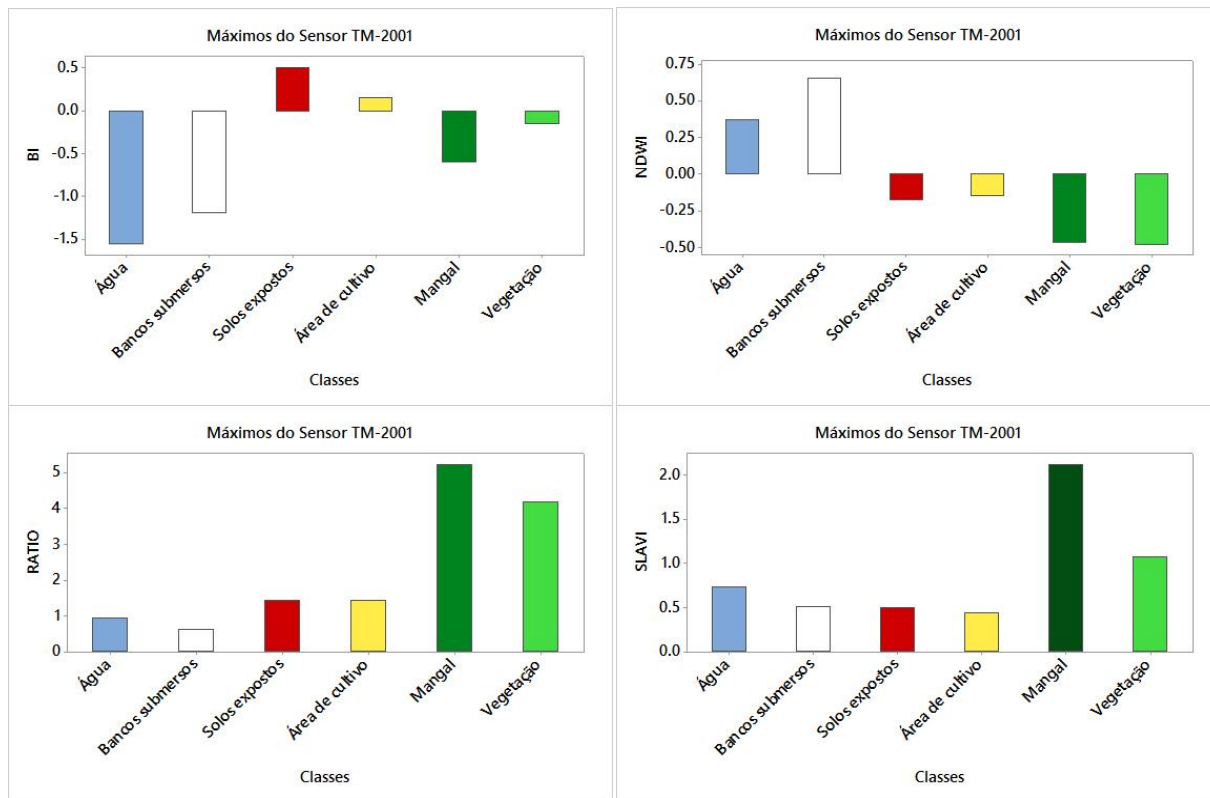


Figura 14: Gráficos dos valores máximos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor TM-2001

A análise dos resultados foi baseada no princípio físico da ondulatória, aplicando termo amplitude máxima com intuito de separar as classes de cobertura de solos.

Assim sendo usou-se o valores mínimos de BI para discriminar solos expostos dos outros alvos, valores mínimos de NDWI para separar corpos hídricos e bancos submersos das outras classes, valores mínimos do SLAVI e RATIO para maximizar todas classes .

Estimou-se valores máximos de BI para discriminar solos expostos e áreas de cultivo dos outros objectos, evidenciou-se NDWI para separar água e bancos submersos das outras classes e pegou-se SLAVI e RATIO para maximizar todas classes de cobertura.

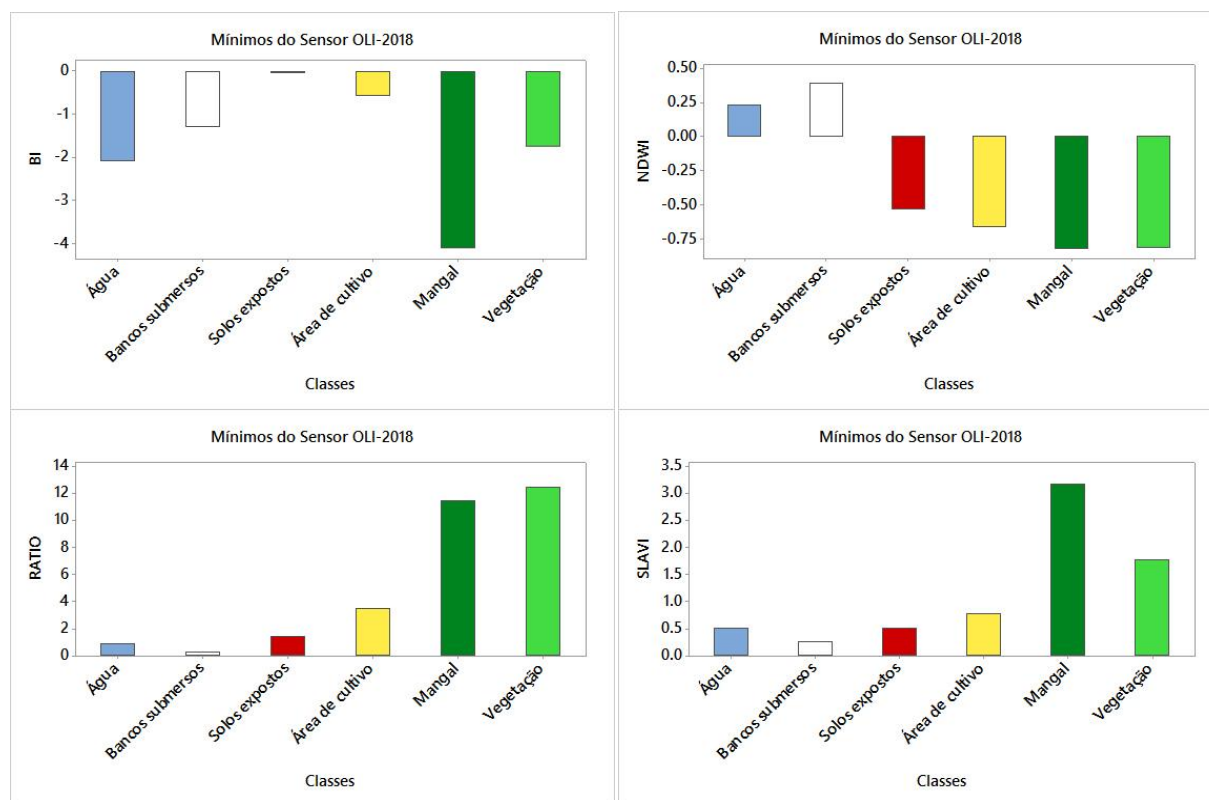


Figura 15: Gráficos dos valores mínimos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor OLI-2018

Aplicou-se o índice BI para realçar todos alvos, NDWI para separar água e bancos submersos das outras classes de cobertura de terra, SLAVI e RATIO para discriminar tudo.

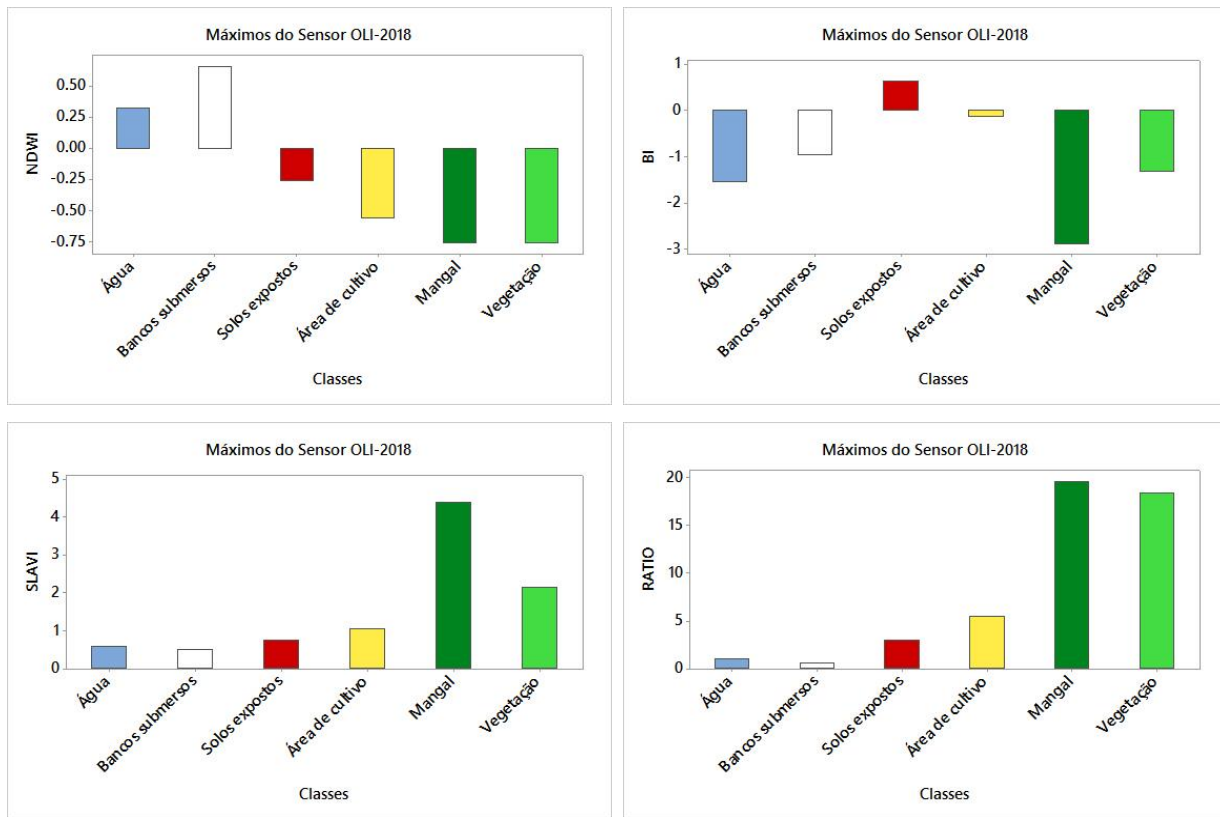


Figura 16: Gráficos dos valores máximos de limiares de reflectância para BI, NDWI, SLAVI e RATIO Sensor OLI-2018

O NDWI discriminou água e solos expostos das outras classes de cobertura, para BI notou-se a separação de solos expostos em relação aos outros alvos e por fim para SLAVI e RATIO discriminaram os seis objectos da terra.

V. DISCUSSÃO

Para contornos digitalizados na banda do infravermelho próximo em cada cena, não evidenciou-se nenhuma mudança significativa, isto pode estar associado à questões de resoluções espaciais das imagens de Landsat, que são tão baixas comparando com as do programa Google Earth. Ao Passo que para as áreas (A e B) identificadas e selecionadas no mesmo programa, apontou-se uma progradação ou retrogradação da linha de costa em relação ao continente sendo consequência do aumento do nível do mar ou riscos ambientais protagonizados pelo homem de acordo com o trabalho citado por Fernandes (2016) concernente análise multitemporal das mudanças ocorridas da linha de costa da Baía de Guanabara.

De acordo com a tabela 5, nota-se um avanço significativo da classe de vegetação, provavelmente houve déficit das áreas construídas pelas populações na região de Mecúfi. Resultado que também se obteve no trabalho realizado por Kleinpaul et al. (2005), onde ocorreu um aumento de 3.616,78 hectares (10,24%) na área de cobertura florestal da Bacia Arroio Grande em um período de 18 anos, e no trabalho de Sousa et al. (2007), onde concluíram que houve um aumento de 13,87% de vegetação densa e semidensa no município de Itaporanga em um mesmo período, e relacionaram o fato com a extinção da cotonicultura arbórea consequente migração da população rural para o meio urbano.

Estes resultados foram discrepantes por não terem ocorrido no levantamento realizado por Silva e Vieira (2007), no qual observaram uma diminuição significativa da vegetação no município de Uruçuí.

Houve um aumento também dos bancos submersos, provavelmente estes movem-se através de processos hidrodinâmicos, dos quais são considerados as marés, correntes de maré e ondas.

Ao passo que para área de cultivo houve uma diminuição drástica, o que significa que abundaram culturas temporárias em 2001. Por sua vez essas plantações confundiram-se com solos expostos pelo facto de as culturas terem sido temporárias e em 2018 elas confundiram-se com a vegetação pelo facto de terem se transformadas em permanentes.

Destacou-se maiores confusões para as classes de corpos hídricos e bancos submersos pelo facto da maré ser alta dificultando o algoritmo MAXVER. Por outro lado confusões de solos expostos com bancos submersos porque os bancos na maré vazante ficam emersos ou visualizados facilmente pelos sensores.

O algoritmo máxima verossimilhança não discriminou perfeitamente as classes de área de cultivo, solos expostos, mangal e vegetação. Eis o motivo da geração de muita confusão na matriz de erros, contribuindo com que a qualidade da classificação não ficasse excelente de acordo com a tabela estabelecida por (Landis & Koch, 1977).

A exatidão global do mapeamento e valor de coeficiente de concordância kappa registaram cerca de 62,7% e 55,3% em âmbos Sensores, provavelmente pode estar relacionado com a resolução do sensor, números de classes de interesse, número de amostras e procedimentos da própria classificação, tal como foi inferido por Lillesand M. T. et al., (2004).

Resultados melhores foram encontrados por Suarez & Candeias (2012), ao classificarem uma imagem Landsat 7 onde exatidão global foi de 96% e o índice Kappa 94%, representando um excelente grau de aceitação.

VI. CONCLUSÕES E RECOMENDAÇÕES

6.1 Conclusões

- ♣ Diante dos objectivos traçados conclui-se que ;
- ♣ As alterações de linha são notáveis com uma imagem de resolução maior em relação as imagens de Landsat 5 e 8;
- ♣ O desempenho da classificação MAXVER para imagens Landsat 5 e 8 foi considerada muito boa com exatidão global apresentando 62,7% e boa com índice kappa correspondente à 55,3% ;
- ♣ Como forma de resolver o problema, o método baseado em limiares de reflectância dos índices foi excelente.

6.2 Recomendações

- ♣ Para os próximos trabalhos do género recomenda-se para que usam outros satélites com uma resolução melhorada como caso do Satélite Sino-Brasileiro de recursos terrestres (CBERS); IKONOS; RAPIDEYE ou SENTINEL;
- ♣ No caso do estudante trabalhar com imagens de alta resolução espacial, que se faça a validação dos dados através do *in situ ou in loco*;
- ♣ Que façam plantios de árvores e obras de engenharia na região de Mecúfi;
- ♣ Se o autor estiver a manipular dados de Remote sensing com média resolução, recomenda-se que dado de referência tenha resolução mais elevada para se fazer a validação;
- ♣ Que se façam estudos usando diferentes algoritmos classificadores imagens de satélite Landsat.

VII. REFERÊNCIAS BIBLIOGRÁFICAS

- ✓ Langa, J. V. Q. (2007). *Problema na zona costeira de Moçambique com ênfase para a costa de Maputo*. Revista de Gestão Costeira Integrada 7 (1):33-44. pp-34 .
- ✓ Jensen, J.R. (1949). *Introductory digital image processing – a remote sensing perspective*. Third edition. University of South Carolina: Prentice Hall Series in Geographic Information Science, 2005, 526 p.
- ✓ Inpe (Instituto Nacional de Pesquisas Espaciais-Brasil), (2006). *Tutorial do SPRING*. São José dos Campos: INPE.
- ✓ Moreira, M.A. (2003). *Fundamentos de sensoriamento remoto e metodologia de aplicação*.UFG.
- ✓ Florenzano, T.G. (2008). *OS Satélites e suas Aplicações, série espacializando*. SindCT.
- ✓ Alves, D. S. (1990). *Sistemas de Informacao geografica In: Simposio Brasileiro de Geoprocessamento*, Sao Paulo.
- ✓ Aronoff, S. (1999). *Geographic Information Systems: A Management Perspective*. Ottawa: WDLpublications.
- ✓ Camara, G., Monteiro, A. M. V., Carvalho, M. S., Druck, S. (2002). *Analise Espacial de dadosGeograficos*, 2a edição.
- ✓ Ferreira et al., (2006). *Imagem de Satelite para Estudos Ambientais*. Sao Paulo: Oficina de textos.
- ✓ Silva, R. (2002). *Banco de Dados Geograficos: Uma Analise das Arquitecturas Dual (Spring) e Integrada (Oracle Spatial)*. Escola Politecnica da USP.
- ✓ Crósta, A. P. (1992). *Processamento Digital de Imagem de Sensoriamento Remoto*. Campinas São Paulo: IG/UNICAMP.
- ✓ Lillesand,T. M. (2004). *Remote Sensing and image interpretation*. 5. ed. New York: Wiley e Sons, 763p.
- ✓ Longlay, P.A, M.F. Goodchild, D.J. Maguire e David W.Rhind. (2008). *Manual of Geographic Information Systems*. 2nd edition, John Wiley & Sons Publishers.
- ✓ Kramer, H. J. (1996). *Observation of the Earth and Its Enviroment- Survey of Missions and Sensors*, 3ºedição, Editora Spring, Berlin.
- ✓ Moreira, M. (2001). *Fundamentos de sensoriamento remoto e metodologias de aplicação*. 241p.

- ✓ Campbell, J. B. (2002) *Introduction to Remote Sensing*. 4. ed. New York: The Guilford Press, 654p.
- ✓ Ibge, (2001). *Introdução ao processamento digital de imagens*. Primeira Divisão de Geociências do Nordeste, Rio de Janeiro: IBGE, 92p.
- ✓ McFeeters, S.K. (1996). *The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features*. International Journal of Remote Sensing, v.17, n.7, p.1425-1432.
- ✓ Eastman, J. R. (1998). *Idrisi for Windows-Manual do usuário*. Trad. HASENACK, H.; WEBER,E. Porto Alegre: UFRGS, Centro de Recursos Idrisi, Brasil.
- ✓ Chen, J. (2004). *An assessment of Landsat TM band6 thermal data for analyzing land cover in tropical dry forest regions* International Journal of Remote Sensing, 25(4), 689-706.
- ✓ Stephanie, H. (2011). *Normalized Difference Water Index-NDWI*. PRODUCT FACT SHEET: NDWI – EUROPE, Version 1.
- ✓ Gao, B.C. (1996). *NDWI – A Normalized Difference Water Index for remote sensing of vegetation liquid water from space*. Remote Sensing of Environment, v.58, p.257-266.
- ✓ Hogueane, A. M. (2007). *Perfil Diagnóstico da Zona Costeira de Moçambique*. Revista de Gestão Costeira integrada, UNIVALI, 7 (1), pp. 69-82.
- ✓ Spring. (2006). *Versão 4.3.3*. São José dos Campos: DPI/INPE.
- ✓ Sousa, R. F. et al. (2007). *Avaliação das Classes de Cobertura Vegetal e Mapeamento do Uso Atual dos Solos no Município de Itaporanga-PB*. Engenharia Ambiental – Espírito Santo do Pinhal, v. 4, n. 1, p. 80-88.
- ✓ ROSA, R. (2007). *Introdução ao sensoriamento remoto*. Uberlândia: Ed. UFU.
- ✓ FILHO, Milton da Costa; MENESES, Paulo Roberto; SANO, Edson Eyji. (2007). *Sistema de classificação de uso e cobertura da Terra na análise de imagens de satélite*. Revista Brasileira de Cartografia No 59/02.
- ✓ Novo, Evlyn Márcia L. de Moraes. (1989). *Sensoriamento Remoto: Princípios e Aplicações*. 2ª ed. São Paulo: Edgard Blücher,. 308 p.
- ✓ Crósta. Á. P. (1992). *Processamento Digital de Imagens de Sensoriamento Remoto*. ed. rev. Campinas – SP: IG/UNICAMP, p.170.
- ✓ Congalton, R. G. & Green, K. (1999). *Assessing the accuracy of remotely sensed data: principles and practices*. New York: Lewis Publishers.

- ✓ Lillesand, M. T. e Kiefer, W. R. (2004). *Remote sensing and image interpretation*. (5th ed), John Wiley and Sons, Inc, New York.
- ✓ Landis, J. R.; Koch, G. G. (1977). *The measurement of observer agreement for categorical data*. *Biometrics*, v.33, n.1.
- ✓ Swain, P. H.; Davis, S.M. (1978) Ed. *Remote Sensing: The Quantitative Approach*. New York, Mc.
- ✓ Vieira, G. (2012). *A detecção remota na investigação do grupo polar da universidade de Lisboa*.
- ✓ Rennó, C. D.; Sant'anna, S. J. S. ; Freitas, C. C . (1999). *Avaliação das incertezas nas classificações de máxima verossimilhança e contextual de modas condicionais iterativas*. In: GISBRASIL'99, 1999, Salvador. Anais.
- ✓ Centeno, J. A. S. (2009). *Sensoriamento e Processamento de Imagens Digitais*. Curitiba Ed. Curso de Pos Graduacao em Ciencias Geodesicas UFPR, 2a edição.
- ✓ CRÓSTA, A. P. (1992). *Processamento digital de imagens de sensoriamento remoto*. IG/UNICAMP. Campinas, SP.
- ✓ Suarez, A.F. e Candeias, A. L. B. (2012). *Avaliação de acurácia de classificação de dados de sensoriamento remoto para o município de Maragogipe*. In: IV SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DE GEOINFORMAÇÃO, Recife, PE, Brasil: Anais Recife: DEPART/CTG/UFPE, p. 001-0010.
- ✓ Fernandes, P.G.F. (2016). *Análise Multitemporal Das Mudanças Ocorridas Na Linha De Costa*. Dissertação de Pós-Graduação em Dinâmica dos Oceanos e da Terra, Baía De Guanabara.

ANEXO I- Lista de índices espectrais calculados em níveis de cinza

