



UNIVERSIDADE FEDERAL DE SERGIPE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA

PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS

KAREN ARIADNE LEITE SANTOS

**DINÂMICA DA LINHA DE COSTA E MAPEAMENTO DO USO
DA TERRA NO LITORAL CENTRAL DO ESTADO DE
SERGIPE ENTRE OS ANOS DE 1988 E 2019**

SÃO CRISTÓVÃO-SE

2021

KAREN ARIADNE LEITE SANTOS

**DINÂMICA DA LINHA DE COSTA E MAPEAMENTO DO USO DA
TERRA NO LITORAL CENTRAL DO ESTADO DE SERGIPE ENTRE
OS ANOS DE 1988 E 2019**

Dissertação apresentada ao Programa de Pós-graduação em Recursos Hídricos como um dos requisitos básicos para obtenção do título de Mestre em Recursos Hídricos.

Orientador: Prof. Dr. André Quintão de Almeida

SÃO CRISTÓVÃO-SE

2021

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL
UNIVERSIDADE FEDERAL DE SERGIPE**

S237d Santos, Karen Ariadne Leite
Dinâmica da linha de costa e mapeamento de uso da terra no litoral central do estado de Sergipe entre os anos de 1988 e 2019 / Karen Ariadne Leite Santos ; orientador André Quintão de Almeida. -- São Cristóvão, 2021.
113 f. : il.

Dissertação (mestrado em Recursos Hídricos) - Universidade Federal de Sergipe, 2021.

1. Recursos hídricos. 2. Proteção ambiental. 3. Costa. 4. Erosão de praias. 5. Google Earth. 6. Solos - Sergipe (SE). I. Almeida, André Quintão de, orient. II. Título.

CDU: 556.18(813.7)

KAREN ARIADNE LEITE SANTOS

**DINÂMICA DA LINHA DE COSTA E MAPEAMENTO DO USO DA TERRA NO
LITORAL CENTRAL DO ESTADO DE SERGIPE ENTRE OS ANOS DE 1988
E 2019**

Dissertação apresentada ao Programa de Pós-graduação em Recursos Hídricos como um dos requisitos básicos para obtenção do título de Mestre em Recursos Hídricos.

APROVADA:



Documento assinado digitalmente
ANDRE QUINTAO DE ALMEIDA
Data: 06/04/2022 20:27:05-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. André Quintão de Almeida (Orientador- UFS)
Programa de Pós-Graduação em Recursos Hídricos (PRORH)



Documento assinado digitalmente
PAULO SERGIO DE REZENDE NASCIMENTO
Data: 06/04/2022 08:20:43-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. Paulo Sérgio de Rezende Nascimento – Membro externo
Programa de Pós-Graduação em Geociências e Análise de Bacias (PGAB)



Documento assinado digitalmente
Diego Campana Loureiro
Data: 06/04/2022 15:27:25-0300
Verifique em <https://verificador.iti.br>

Prof. Dr. Diego Campana Loureiro – Membro externo
Departamento de Engenharia Agrícola (DEAGRI)

SÃO CRISTÓVÃO-SE

2021

*Dedico este trabalho aos meus pais, irmãos, filho e esposo, por
todo apoio, carinho e dedicação durante todas as etapas da
minha vida.*

AGRADECIMENTOS

A Deus e todas as forças do universo, por possibilitar a minha existência.

Ao meu orientador, prof. Dr. André Quintão de Almeida, por toda orientação, dedicação, suporte, orientações/aulas particulares, amizade ao longo do curso e parceria no desenvolvimento desta dissertação. Será a minha referência de profissional que têm satisfação em transmitir os conhecimentos e viver a trajetória acadêmica com mais leveza e simplicidade. Obrigada por me ajudar a “não deixar a peteca cair”.

Aos professores do Programa de Pós-graduação em Recursos Hídricos (PRORH), em especial à professora Adnivia Monteiro, que acompanhou a nossa escrita, desenvoltura, tensão e superação durante as disciplinas de Metodologia e Seminários.

A todos os professores que contribuíram com esse trabalho, de forma direta ou indireta, professores que participaram das bancas examinadoras, aos professores Doutores Antônio Garcia, Marcus Cruz e Walter Folly, mesmo com a mudança de projeto, todo conhecimento adquirido ao longo da caminhada foi agregado nesta pesquisa. Aos professores doutores Paulo Sérgio e Diego Campana Loureiro, que aceitaram nosso convite para darem críticas, sugestões e contribuições valiosas.

Aos colegas do Laboratório de Geoprocessamento e Sensoriamento Remoto (SERGEO) e ao grupo de estudo Observando a Floresta do Espaço (OFE), pelo aprendizado, agradabilíssimo convívio e compartilhamento de idéias, especialmente aos colegas Karina Milagres e Wesley Santos.

Aos meus companheiros de curso, especialmente aos colegas Rosa Helena, Ângelis, Kerlen, Samuel e Franklin pelos bons momentos de discussão, distração e boas refeições no RESUN.

Aos meus Pais, Maria José e Antônio Carlos por fazerem possível essa realização, à minha irmã Morgana, por todo apoio, ensinamentos, parceria, carinho nos momentos de fragilidade e por não me deixar desacreditar. Ao meu irmão Massao, pelo companheirismo. Ao meu esposo Michel pelo respeito e paciência. Ao meu filho, pequeno Zaki, que me trouxe luz e força para conseguir concluir. Ele esteve ao meu lado, dentro e fora da barriga durante toda a produção deste trabalho. Agradeço especialmente a minha mãe por sempre acreditar em mim e dessa vez dedicar todo tempo que foi possível, para fazer isso possível.

Obrigada a todos!

RESUMO

Zonas Costeiras caracterizam-se por apresentar alta densidade populacional, grande desenvolvimento urbano, turístico e industrial. No litoral central do Estado de Sergipe a cobertura e uso da terra é constantemente alterada pela dinâmica marinha e terrestre devido a atuação de processos de origem natural e antrópico. Hoje estão disponíveis inúmeras técnicas de estudo que permitem identificar e estimar alterações no espaço de forma automática, rápida e pouco onerosa. O presente trabalho tem como objetivos principais avaliar a partir de imagens de satélite em área litorânea: (1) o desempenho de três algoritmos de aprendizagem de máquina na classificação de uso e cobertura da terra; (2) a variação da linha de costa por digitalização automática. Os dados originais foram cenas multitemporais do satélite Landsat 5 e 8. Para a classificação, adicionalmente a composição colorida, foram gerados mais três conjuntos de dados: (1) composição com índices de vegetação; (2) composição com métricas de textura e (3) composição com índice de vegetação e métrica de textura. Foram selecionadas 8 classes de uso e cobertura da terra e 450 amostras, subdivididas em treinamento (70%) e validação (30%). A acurácia foi avaliada pelo método matriz de confusão. A variação da linha de costa foi analisada por mapeamento multitemporal realizado com a ferramenta *Digital Shoreline Analysis System*. Os valores de taxa e envelope de variação da linha de costa foram estimados ao longo dos anos em três setores da região metropolitana, dois no município de Aracaju e um no município da Barra dos Coqueiros. As taxas foram obtidas por dois métodos diferentes: taxa por regressão linear e taxa por ponto de terminação. Desse modo, observa-se que a respeito do desempenho da classificação, as maiores acurácias foram produzidas por Floresta Aleatória (0,88 a 0,99), seguido de Máquina de Vetor de Suporte (0,87 a 0,99) e Redes Neurais Artificiais (0,73 a 0,94). A variação da linha de costa, apresentou taxas entre -10,99 e 18,44 m.ano⁻¹ e predominou o comportamento de acreção ao longo do tempo. O envelope de variação da linha de costa resultou em menor valor na Maré de Apicum localizada no Bairro Coroa do Meio (4,19 m) e maior valor na Atalaia Nova, na Barra dos Coqueiros (562,85 m). A classificação mostrou uma tendência de aumento da área urbana e redução da vegetação e faixa de praia. Diante da proximidade dos valores de acurácia obtidos, mais estudos são necessários para avaliar o potencial dos 3 classificadores. Por outro lado, a detecção da variação da linha de costa evidenciou uma tendência predominante de acreção nos três setores analisados. O que permite concluir que a linha de costa teve maior proporção de acreção e cedeu espaço para o crescimento da área urbana, em detrimento das classes naturais vegetação e faixa de praia. Desta forma, podemos concluir que as imagens da série Landsat foram úteis para captar as alterações ao longo dos anos. Esses resultados permitiram identificar a dinâmica da área costeira em médio a longo prazo e avaliar possíveis tendências do comportamento a erosão, estabilidade ou acreção.

PALAVRAS-CHAVE: Aprendizagem de máquina. Linha de Costa. Google Earth Engine. Erosão Costeira.

ABSTRACT

Coastal zones are characterized by the high population density, high urban development, tourist potential, and industrial development. On the central coast of Sergipe, the land-cover and land-use have been frequently altered because of natural and anthropic origins by marine and terrestrial dynamics. Nowadays, numerous study techniques allow us to quickly and cheaply identify and estimate how this area changes. The present work evaluates satellite images in a coastal area: (1) the performance of three machine-learning algorithms in land use and land cover classification; (2) shoreline variation by automatic digitization. The original data were multi-temporal scenes from the Landsat 5 and 8 satellite. For the classification, three more data sets were generated in addition to the color composition: (1) composition with vegetation indices, (2) composition with texture metrics, and (3) composition with vegetation index and texture metrics. I selected 450 samples of eight classes of land-use and land-cover subdivided into training (70%) and validation (30%). I assessed the accuracy using the confusion matrix method. I analyzed the shoreline variation through multi-temporal mapping performed with the *Digital Shoreline Analysis System* tool. The shoreline variation rate and envelope values were estimated over the years in three sectors of the metropolitan region, two in the municipality of Aracaju and one in the municipality of Barra dos Coqueiros. The rates were obtained through two different methods: linear regression and endpoint. In addition, the highest accuracies were produced through Random Forest (0.88 to 0.99), followed by Support Vector Machine (0.87 to 0.99) and Networks Artificial Neural (0.73 to 0.94). The variation of the coastline presented that rates ranged between -10.99 and 18.44 m.year⁻¹, and the accretion behavior predominated over time. The shoreline variation envelope resulted in a lower value in Maré de Apicum located in the Coroa do Meio neighborhood (4.19 m) and a higher value in Atalaia Nova in Barra dos Coqueiros (562.85 m). The classification showed an increasing trend in the urban area and a vegetation reduction and beach strips. After considering the obtained values, more studies are needed to assess the potential of the 3 classifiers. The classification showed a trend towards an increase in the urban area and a reduction in vegetation and beach strips. Given the proximity of the accuracy values obtained, more studies are needed to assess the potential of the 3 classifiers. On the other hand, the detection of shoreline variation showed a predominant trend of accretion in the three analyzed sectors. Therefore, we may conclude that the coastline had a higher proportion of accretion that allowed the growth of the urban area, to the detriment of the natural vegetation and beach strip. Finally, I conclude that the Landsat series images were useful to capture the changes over the past years. These results enabled me to identify the dynamics of the coastal area in a medium to long term and to assess possible trends in behaviors towards erosion, stability, or accretion.

KEYWORDS: Machine learning. Coastline. Google Earth Engine. Coastal Erosion.

LISTA DE FIGURAS

Figura 1- Fluxograma metodológico aplicado para classificar o uso e cobertura da terra na área de estudo com uso de aprendizagem de máquina.....	23
Figura 2- Mapa de localização da área de estudo (em vermelho) na América do Sul (a), mais precisamente no litoral central do Estado de Sergipe (b), entre as cidades de Aracaju e Barra dos Coqueiros, nas adjacências da foz do Rio Sergipe(c).	24
Figura 3- Composição colorida (R = banda do vermelho, G = banda do verde e B = banda do azul) das imagens Landsat utilizadas neste estudo. (a) 21 de dezembro de 1988 (Landsat 5), (b) 04 de dezembro de 1999 (Landsat 5), (c) 29 de setembro de 2010 (Landsat 5) e (d) 04 de julho de 2019 (Landsat 8), adquiridas no Google Earth Engine(GEE).	27
Figura 4- Mapas de Uso e Cobertura da Terra classificados por Floresta Aleatória com dados do ano de 1988, com os 4 diferentes conjunto de dados: (a) Conjunto 1(composição colorida); (b) Conjunto 2(Comp com IV); (c) Conjunto 3(Comp com MT); (d) Conjunto 4 (Comp, IV e MT).	34
Figura 5- Mapas de Uso e Cobertura da Terra classificados por diferentes métodos testados ao longo de 3 décadas na área de estudo com o conjunto de dados 1(composição original RGBNIR) para (a) Random forest (1988), (b) Random forest (1999), (c) Random forest (2010), (d) Random forest (2019), (e) Suport Vector Machine (1988), (f) Suport Vector Machine (1999), (g) Suport Vector Machine (2010), (h) Suport Vector Machine (2019), (i) Artificial Neural Network (1988), (j) Artificial Neural Network (1999),(l) Artificial Neural Network (2010), (m) Artificial Neural Network (2019).....	36
Figura 6- Mapas de Uso e Cobertura da Terra classificados por diferentes métodos testados ao longo de 3 décadas na área de estudo com o conjunto de dados 4 (composição original RGBNIR+ Índices de Vegetação+ Métricas de Textura) para (a) Random forest (1988), (b) Random forest (1999), (c) Random forest (2010), (d) Random forest (2019), (e) Suport Vector Machine (1988), (f) Suport Vector Machine (1999), (g) Suport Vector Machine (2010), (h) Suport Vector Machine (2019), (i) Artificial Neural Network (1988), (j) Artificial Neural Network (1999),(l) Artificial Neural Network (2010), (m) Artificial Neural Network (2019).	37
Figura 7- Percentagem de alteração de uso e cobertura da terra entre os anos de 1988 e 2019 na área de estudo	47

Figura 8- Fluxograma do processamento dos dados digitais de imagens de satélite para análise da variação da linha de costa e classificação de uso e ocupação da terra.	63
Figura 9 - Mapa de localização da área de estudo (em vermelho) na América do Sul (a), mais precisamente no litoral central do Estado de Sergipe (b), entre as cidades de Aracaju e Barra dos Coqueiros, nas adjacências da foz do Rio Sergipe(c).	64
Figura 10- Linha de Costa do Litoral Central do Estado de Sergipe em composição colorida (R = banda do vermelho, G = banda do verde e B = banda do azul) das imagens Landsat utilizadas neste estudo. (a) 21 de dezembro de 1988 (Landsat 5), (b) 04 de dezembro de 1999 (Landsat 5), (c) 29 de setembro de 2010 (Landsat 5) e (d) 04 de julho de 2019 (Landsat 8), adquiridas no Google Earth Engine (GEE).	67
Figura 11- Mapa de linha de base, linha de costa e transectos para análise de mudanças na linha de costa ao longo da costa central de Sergipe. Em a) setor 1: Praias de Atalaia, Artistas e Coroa do Meio; Em B) setor 2: Trecho entre os bairros 13 de julho, Jardins e Farolândia; Em C) setor 3: Praia da Costa, Praia da Atalaia Nova e foz do Rio Sergipe e em D) a localização desses setores.	69
Figura 12-: Evolução da linha de costa entre 1988 e 2019 no setor 1 do estudo (Orla de Atalaia e Coroa do Meio). (a) classificação por MVS para o ano de 1988 e comportamento da linha de costa pelo método LRR; (b) taxa de variação mensurada pelos métodos EPR e LRR;(c) classificação por MVS para o ano de 2019 e comportamento da linha de costa pelo método LRR.	74
Figura 13- a) Envelope de mudança da linha costeira (SCE), b) Movimento líquido da linha costeira (NSM) e c) taxa anual de mudança por ponto de terminação (EPR) nos 3 setores em estudo conforme a localização na figura d.	75
Figura 14- Evolução da linha de costa entre 1988 e 2019 no setor 2 do estudo (Bairro 13 de julho). (a) classificação por MVS para o ano de 1988 e comportamento da linha de costa pelo método LRR; (b) taxa de variação mensurada pelos métodos EPR e LRR; (c) classificação por MVS para o ano de 2019 e comportamento da linha de costa pelo método LRR.	78
Figura 15 - Evolução da linha de costa entre 1988 e 2019 no setor 3 do estudo (Barra dos Coqueiros). (a) classificação por MVS para o ano de 1988 e comportamento da linha de costa pelo método LRR; (b) taxa de variação mensurada pelos métodos EPR e LRR;(c) classificação por MVS para o ano de 2019 e comportamento da linha de costa pelo método LRR.	80

Figura 16 - Correlação entre as taxas de variação da linha de costa obtidas por diferentes métodos (EPR, LRR) para as transectos do (a) setor 1 – Orla de Atalaia e Coroa do Meio, (b) Setor 2- Bairro 13 de Julho; e (c) setor 3 – Barra dos Coqueiros.

.....81

LISTA DE TABELAS

Tabela 1- Descrição das bandas do satélite LANDSAT 5 e 8 usadas neste estudo (TM = Thematic Mapper, OLI = Operational Land Imager, Res= resolução).	26
Tabela 2- Características das classes de uso e cobertura da terra adotadas nesse estudo.	28
Tabela 3- Número de amostras utilizados em cada classe para a classificação supervisionada.	29
Tabela 1 - Resumo dos atributos dos índices de vegetação espectrais e medidas de textura de imagem derivadas de imagens Landsat 5 e 8, selecionados para o estudo.	31
Tabela 5- Qualidade das classificações para cada conjunto dos dados estudado, expressas pelos índices de Coeficiente Kappa e Acurácia Global.	34
Tabela 6- Porcentagem de cobertura de área de diferentes classes de uso e cobertura da terra na área de estudo para os conjuntos de dados de melhores resultados (conjunto 1 e 4). FA= Floresta aleatória, MVS= Máquinas de vetores de Suporte, RNA= Redes Neurais Artificiais.	38
Tabela 7- Nível geral de precisão dos classificadores utilizados nesse estudo para os melhores conjuntos de dados.	41
Tabela 8- Acurácia do Usuário e Produtor para o conjunto de dados 1	42
Tabela 9- Acurácia do Usuário e Produtor para o conjunto de dados 4	43
Tabela 10- Quantificação das alterações de uso e cobertura da terra e suas respectivas percentagens, no trecho do litoral central de Sergipe associado a foz do rio Sergipe, Brasil, entre os anos de 1988 e 2019.	47
Tabela 11- Descrição das bandas do satélite LANDSAT 5 e 8 usadas neste estudo. (TM = Thematic Mapper, OLI = Operational Land Imager, Res= resolução).	66
Tabela 12 – Síntese das informações sobre estatísticas aplicadas para detectar a variação da linha de costa.	70
Tabela 13- Taxa de variação e classificação <i>do comportamento da linha costeira com base em taxa de ponto de terminação</i> (end point rate) e taxa de regressão linear (<i>linear regression rate</i>)	71
Tabela 14- Range de valores de taxa de variação da linha de costa obtidos pelo método da taxa do ponto de terminação (EPR) e regressão linear (LRR) nos anos de 1988, 1999, 2010 e 2019 na área de estudo.	73

Tabela 15- Range de valores do envelope de variação da linha de costa ao longo dos trechos da (1) Orla de Atalaia e Coroa do Meio, (2) bairro 13 de julho e (3) entre as praias do Porto e Praia da Costa, entre os anos de 1988 e 2019.....	75
Tabela 16- Porcentagem de cobertura de área de diferentes classes de uso e cobertura da terra na área de estudo gerado por modelo de classificação supervisionado Máquina de Vetores de Suporte em dados de composição RGB-NIR de imagens LANDSAT 5 e 8.	82

LISTA DE ABREVIATURAS E SIGLAS

AG	ACURÁCIA GERAL
AM	APRENDIZAGEM DE MÁQUINA
AP	ACURÁCIA DO PRODUTOR
ASM	SEGUNDO MOMENTO ANGULAR
AU	ACURÁCIA DO USUÁRIO
CAPES	COORDENAÇÃO DE APERFEIÇOAMENTO DE PESSOAL DE NÍVEL SUPERIOR
CO	CONTRASTE
DIS	DISSIMILARIDADE
DVI	ÍNDICE DE DIFERENÇA DE VEGETAÇÃO
EA	ERRO DE ALOCAÇÃO
EC	ERRO DE COMISSÃO
ENT	ENTROPIA
EO	ERRO DE OMISSÃO
EQ	ERRO DE QUANTIDADE
GEE	GOOGLE EARTH ENGINE
GEMI	GLOBAL DE MONITORAMENTO AMBIENTAL
GLCM	GREY LEVEL CO-OCCURRENCE MATRIX
GNDVI	ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADA VERDE
HOM	HOMOGENEIDADE
IV	ÍNDICE DE VEGETAÇÃO
K	KAPPA
MED	MÉDIA
MSAVI2	SEGUNDO ÍNDICE DE VEGETAÇÃO AJUSTADO;
MSR	RELAÇÃO MODIFICADA SIMPLES
MVS	MÁQUINA VETORES DE SUPORTE
NDV	ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADA
NIR	NEAR INFRARED REFLECTANCE
OLI	OPERATIONAL LAND IMAGER
OSAVI	ÍNDICE DE VEGETAÇÃO AJUSTADO AO SOLO
QGIS	QUANTUMGIS
RDVI	ÍNDICE DE VEGETAÇÃO DE DIFERENÇA NORMALIZADO

RF RANDOM FOREST

RGB RED, GREEN, BLUE

RMA REGIÃO METROPOLITANA DE ARACAJU

RNA REDES NEURAIS ARTIFICIAS

SAVI ÍNDICE DE VEGETAÇÃO ADAPTADA AO SOLO

SE SERGIPE

SERGEO LABORATÓRIO DE SENSORIAMENTO REMOTO E
GEOPROCESSAMENTO DA UFS

SIG SISTEMA DE INFORMAÇÃO GEOGRÁFICA

SR SENSORIAMENTO REMOTO

SR SIMPLES RAZÃO

TM THEMATIC MAPPER

TVI ÍNDICE TRIANGULAR DE VEGETAÇÃO.

UFS UNIVERSIDADE FEDERAL DE SERGIPE

USGS UNITED STATES GEOLOGICAL SURVEY (SERVIÇO GEOLÓGICO DOS
ESTADOS UNIDOS)

VAR VARIÂNCIA

SUMÁRIO

CAPÍTULO 1: Uso de algoritmos de aprendizagem de máquina para classificação de uso e cobertura da terra em área litorânea do Estado de Sergipe	19
1.1 INTRODUÇÃO	20
1.2 MATERIAL E MÉTODOS	23
1.2.1 Área de estudo	24
1.2.2 Materiais utilizados	26
1.2.3 Métodos empregados	28
1.2.3.1 Definição das classes de uso e das amostras de treinamento	28
1.2.3.2 Variáveis utilizadas nos modelos de classificação	29
1.2.3.3 Validação da classificação	33
1.3 RESULTADOS	33
1.3.1 Análise dos atributos selecionados	33
1.3.2 Mapeamento e precisão os modelos de classificação	35
1.3.3 Acurácia dos modelos	40
1.3.4 Alterações dinâmicas do uso e cobertura da terra na área entre os anos de 1988 e 2019	47
1.4 CONCLUSÃO	48
1.5 AGRADECIMENTOS	49
1.6 REFERÊNCIAS BIBLIOGRÁFICAS	50
CAPÍTULO 2: Variação da linha de costa por mapeamento multitemporal com imagens Landsat: Um estudo de caso para o Litoral Central do estado de Sergipe entre os anos de 1988 a 2019	59
2.1 INTRODUÇÃO	60
2.2 MATERIAL E MÉTODOS	62
2.2.1 Localização e caracterização da área de estudo	63
2.2.2 Materiais utilizados	66

2.2.2.1 Dados de satélite Landsat.....	66
2.2.3 Métodos empregados.....	67
2.2.3.1 Mapeamento multitemporal da linha de costa.....	67
2.2.3.2 Estatística da variação da linha de costa.....	68
2.2.4 Classificação de uso e ocupação da terra	71
2.3 RESULTADOS E DISCUSSÃO.....	72
2.3.1 Setor da Orla de Atalaia e Coroa do Meio (Aracaju)	73
2.3.2 Setor do Bairro 13 de Julho (Aracaju)	77
2.3.3 Setor das praias da Atalaia Nova, Praia da Costa e margem esquerda da foz do rio Sergipe (Barra dos Coqueiros)	79
2.3.4 Mudanças de uso e cobertura da terra associados a variação da linha de costa na área de estudo:	82
2.4 CONSIDERAÇÕES FINAIS	84
2.5 AGRADECIMENTOS	85
2.6. REFERÊNCIAS BIBLIOGRÁFICAS.....	85
APÊNDICE A- TABELA SÍNTESE DOS RESULTADOS SOBRE A DETECÇÃO AUTOMÁTICA DA VARIAÇÃO DA LINHA DE COSTA, OBTIDOS PARA A ÁREA DE ESTUDO ENTRE OS ANOS DE 1988 E 2019.....	95
APÊNDICE B - SÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 1988	96
APÊNDICE C- VISÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 1999	97
APÊNDICE D- VISÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 2010	98

APÊNDICE E- VISÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 2019	99
ANEXO A - CLASSES DE USO E COBERTURA DA TERRA MAPEADAS, DESCRIÇÃO E CLASSIFICAÇÃO DE ACORDO COM O IBGE, FAO E O RELATÓRIO DE EMISSÕES DE GEE- MAPBIOMAS	102
ANEXO B - SCRIPT DE PROCESSAMENTO EM CLASSIFICAÇÃO DE IMAGENS EM R	103
ANEXO C - SCRIPT DO PROCESSAMENTO DE IV'S E MT'S EM R.....	107
ANEXO D- SCRIPT DE AQUISIÇÃO DE IMAGENS LANDSAT NO GOOGLE EARTH ENGINE	112

APRESENTAÇÃO

A presente dissertação de mestrado intitulada “DINÂMICA DA LINHA DE COSTA E MAPEAMENTO DO USO DA TERRA NO LITORAL CENTRAL DO ESTADO DE SERGIPE ENTRE OS ANOS DE 1988 E 2019” tem como objetivos principais: (1) estimar as alterações do uso e cobertura da terra com uso de imagens Landsat TM e OLI, por algoritmos de classificação Floresta Aleatória(FA), Máquina de Vetores de Suporte (MVS) e Redes Neurais Artificiais (RNA), entre os anos de 1988 e 2019; (2), avaliar a partir de imagens de satélite a variação da linha de costa no litoral central do estado de Sergipe, associado a foz do rio Sergipe, entre os anos de 1988 e 2019, com uso de mapeamento automático.

A dissertação está estruturada em dois capítulos. O primeiro corresponde ao artigo intitulado: “Uso de algoritmos de aprendizagem de máquina para classificação de uso e cobertura da terra em área litorânea do Estado de Sergipe”. Esse artigo avalia o desempenho de três classificadores não paramétricos para o mapeamento da cobertura da terra em área litorânea com uso de imagens multitemporais do satélite Landsat.

O segundo capítulo consiste no artigo intitulado “Variação da linha de costa por mapeamento multitemporal com imagens LANDSAT: um estudo de caso para o litoral central do Estado de Sergipe entre os anos de 1988 a 2019”. Nesse artigo foi avaliada a variação da linha de costa no litoral central do estado de Sergipe, associado a foz do rio Sergipe, por mapeamento digital automático com uso do mesmo conjunto de dados Landsat utilizados no capítulo 1.

CAPÍTULO 1: Uso de algoritmos de aprendizagem de máquina para classificação de uso e cobertura da terra em área litorânea do Estado de Sergipe

RESUMO

Essa pesquisa propõe comparar a eficiência de três algoritmos de aprendizagem de máquina para classificação de uso e cobertura da terra em área litorânea e estuarina do estado de Sergipe. Os algoritmos utilizados foram: Floresta Aleatória, Máquina de Vetores de Suporte e Redes Neurais Artificiais. A área de estudo, na Região Metropolitana de Aracaju, é litorânea, altamente urbanizada e cercada por corpos hídricos. O conjunto de dados utilizados foram cenas multitemporais dos satélites Landsat 5 e 8 em composição colorida RGBNIR. Adicionalmente a composição colorida, foram gerados mais três conjuntos de dados: (i) composição com índices de vegetação; (ii) composição com métricas de textura e (iii), composição com índice de vegetação e métricas de textura. Foram selecionadas 8 classes de uso e cobertura da terra, nomeadas de área urbana, corpos d'água, praia seca, vegetação, pastagem, outras áreas não vegetadas, ondas e praia molhada. Cada classe foi representada por 10 a 100 amostras aleatórias, totalizando 450 amostras por imagem de satélite, subdivididas em treinamento (70%) e validação (30%). A acurácia foi avaliada pelo método matriz de confusão, por meio das estatísticas acurácia global, índice *kappa*, acurácia do produtor, acurácia do usuário, erro de omissão e erro de comissão. Os resultados mostraram que as maiores acurácias foram produzidas por Floresta Aleatória (0,88 a 0,99), seguido de Máquina de Vetor de Suporte (0,87 a 0,99) e o menor valor foi obtido por Redes Neurais Artificiais (0,73 a 0,94). Com os resultados obtidos atesta-se a qualidade dos classificadores para a finalidade proposta e diante da proximidade dos valores recomenda-se a realização de mais estudos para avaliar o potencial dos classificadores.

PALAVRAS-CHAVE: Landsat 5. Landsat 8. Zona costeira. Foz do Rio Sergipe. Classificação Supervisionada, Google Earth Engine.

1.1 INTRODUÇÃO

Sabe-se que a cobertura e uso da terra em regiões costeiras é altamente dinâmica devido a processos marinhos e terrestres, frequentemente controlados por atividades naturais e antrópicas (KALIRAJ *et al.*, 2017). A Zona Costeira do Estado de Sergipe, a qual inclui os municípios de Aracaju e Barra dos Coqueiros, não foge a essa regra, passando por inúmeros processos de alteração da paisagem e por consequência, apresentando uma série de impactos que comprometem o seu equilíbrio natural (ARAÚJO, 2012). Diante do exposto acima, fica evidente que o monitoramento do uso e cobertura da terra em regiões costeiras é de fundamental importância para o planejamento e gestão dessas áreas. Em função disso, diferentes fontes de dados de sensoriamento remoto e diversas ferramentas vêm sendo utilizadas para mapear as regiões costeiras, com destaque para os métodos baseados em aprendizado de máquinas (AM).

A aprendizagem de máquinas é uma abordagem não paramétrica para regressão e/ou classificação de sistemas lineares (LARY *et al.*, 2016). Os métodos aplicados com AM para classificação de imagens de satélite têm sido foco de diversos estudos, como na avaliação do desempenho dos algoritmos Floresta aleatória, máquinas de vetor de suporte e aprendizagem profunda em uma paisagem complexa (ABDI, 2019); identificação dos algoritmos floresta aleatória e redes neurais artificiais como os melhores classificadores (TALUKDAR *et al.*, 2020); na análise dos diferentes algoritmos considerando a escolha do melhor, quantidade e qualidade de dados de treinamento, seleção e otimização de parâmetros (MAXWELL; WARNER; FANG, 2018); no uso de diferentes conjuntos de dados derivados de Radar de abertura sintética para obter a melhor classificação de uso e cobertura do solo; outros trabalhos revisam a aplicação de diferentes algoritmos para lidar com as geociências e o sensoriamento remoto (LARY *et al.*, 2016).

Essas pesquisas apresentam alta eficiência e eficácia em diferentes aplicações. Estudos sobre a alteração no uso e cobertura da terra produzidos com AM tornaram-se cada vez mais frequentes e aceitos, como por exemplo, a classificação de uso e cobertura da terra realizada pelo Projeto de Mapeamento Anual do Uso e Cobertura da Terra no Brasil (MapBiomass), desde 2015 para mostrar a dinâmica do uso do solo do Brasil e em outros países tropicais, em imagens Landsat (SOUZA *et*

al., 2020). Existem diversos algoritmos de classificação de imagens baseado em AM, com destaque para Floresta aleatória (FA) (BREIMAN, 2001), Máquina de Vetores de Suporte (MVS) (CORTES; VAPNIK, 1995) e Redes Neurais Artificiais (RNA) (BENEDIKTSSON; SWAIN; ERSOY, 1990).

O método FA funciona com a combinação de árvores de decisão (BREIMAN, 2001). Esse classificador é utilizado para ajustes de modelos de regressão e para aplicações em sensoriamento remoto (THONFELD *et al.*, 2020; DINIZ *et al.*, 2020; PARENTE *et al.*, 2019; BELGIU; DRĂGUȚ, 2016; NITZE; BARRETT; CAWKWELL, 2015). Na classificação de dados de sensoriamento remoto, FA é usado para dados geográficos de múltiplas origens (PAL; MATHER, 2005). O seu classificador utiliza as ferramentas de reamostragem *bagging* ou *boosting*, para formar um conjunto de classificadores de árvore de classificação e regressão (BREIMAN, 2001), em um conjunto de variáveis categóricas ou contínuas (WOZNICKI *et al.*, 2019).

O método MVS é uma técnica de aprendizagem de máquina supervisionada, não paramétrica, binário e baseado na função Kernel (CORTES; VAPNIK, 1995). Nos últimos anos também tem sido muito usada em aplicações de sensoriamento remoto (HUANG; DAVIS; TOWNSHEND, 2002; PAL; MATHER, 2005; SZUSTER; CHEN; BORGER, 2011; MOUNTRAKIS; IM; OGOLE, 2011; MAXWELL; WARNER; FANG, 2018; SYIFA *et al.*, 2019; SHEYKMOUSA, 2020). O MVS é fundamentado na teoria de aprendizagem estatística (CORTES; VAPNIK, 1995) e possibilita a análise dos dados e reconhecimento de padrões usados para a classificação e análise de regressão. A essência da classificação MVS, está nos conceitos de (1) hiperplano de separação; (2) hiperplano de margem máxima; (3) o soft margem; (4) a função Kernel (NOBLE, 2006). Seu objetivo principal é determinar a localização dos limites de decisão que produzem a separação ideal de classes (CORTES; VAPNIK, 1995). A descrição matemática detalhada do método e os aspectos computacionais podem ser encontrados em Cortes e Vapnik (1995).

A classificação por RNA constitui a técnica de aprendizagem de máquinas mais largamente utilizada (ATKINSON; TATNALL, 1997), especialmente em aplicações relacionadas ao SR (BENEDIKTSSON; SWAIN; ERSOY, 1990; MILLER; KAMINSKY; RANA, 1995; DIXON; CANDADE, 2008). A classificação de uso da terra está entre as aplicações mais comuns das redes neurais (ATKINSON; TATNALL, 1997). A técnica é de distribuição livre e não depende de nenhum conhecimento prévio sobre as

distribuições estatísticas das classes nas fontes de dados. O método determina quanto de peso cada fonte de dados deve ter na classificação. Um conjunto de pesos descrevem a rede neural, e esses pesos são calculados em um procedimento de treinamento iterativo (BENEDIKTSSON; SWAIN; ERSOY, 1990).

Vários estudos de classificação de imagens de SR com métodos de aprendizado de máquinas vêm sendo realizados. Pal e Mather (2005), observaram que o método MVS alcança maior nível de precisão se comparado ao classificador paramétrico de Máxima Verossimilhança e o não paramétrico RNA. Além disso, o MVS apresenta a vantagem de poder ser usado com pequeno conjunto de dados de treinamento e obter bons resultados (PAL; MATHER, 2005; MOUNTRAKIS; IM; OGOLE, 2011). No entanto, ainda não existe uma definição do melhor método a ser utilizado em regiões costeiras, assim como na zona costeira do Estado de Sergipe. Cabe destacar que o sucesso da classificação não depende apenas do algoritmo utilizado, e sim de uma soma de fatores, como a quantidade, qualidade e distribuição das amostras de treinamento, dentre outros (MAXWELL; WARNER; FANG, 2018).


Sabe-se que os problemas ambientais estão frequentemente relacionados com as alterações de uso da terra, desta forma o mapeamento das mudanças de uso e cobertura da terra devem fornecer informações importantes para a análise do processo evolutivo dessas áreas, gestão ambiental e planejamento territorial. O litoral central do estado de Sergipe passou por diversas mudanças ao longo das últimas décadas, associadas a setores expostos a alta variabilidade natural e ao desenvolvimento urbano. Por isso, é de grande relevância a realização de estudos de detecção das alterações do uso e ocupação da terra como atividade de monitoramento e gestão de áreas.

Nesse contexto, o objetivo principal deste estudo foi de avaliar o desempenho de três algoritmos de classificação de imagens Landsat com base em técnicas de processamento digital de imagens e avaliar as alterações de uso e cobertura da terra o longo dos anos de 1988 e 2019 na região da zona costeira central do Estado de Sergipe.

1.2 MATERIAL E MÉTODOS

No presente estudo, foram avaliados três diferentes métodos de classificação de imagens de SR em dados da série Landsat a partir de algoritmos de AM. Para tal, a abordagem metodológica empregada envolveu as seguintes etapas: (1) seleção de imagens de satélite; (2) processamento das imagens de satélite; (3) seleção de dados de treinamento; (4) classificação do uso e cobertura da terra nas imagens de satélite; (5) acurácia dos modelos de classificação e (6) análise estatística dos resultados (Figura 1).

Figura 1- Fluxograma metodológico aplicado para classificar o uso e cobertura da terra na área de estudo com uso de aprendizagem de máquina.



Fonte: Elaborada pelos autores.


Os métodos de classificação foram empregados em imagens Landsat 5 e 8, adquiridas por meio do *Google Earth Engine* (GEE). O processamento e classificação das imagens foram feitos no software R (R CORE TEAM, 2018). As amostras e treinamento foram selecionadas sobre as imagens Landsat na composição RGBNIR

com a demarcação de pontos em arquivo vetorial no software livre QGIS (QGIS DEVELOPMENT CORE TEAM, 2020).

1.2.1 Área de estudo

A área de estudo está situada entre as coordenadas $37^{\circ}00'50''$ e $37^{\circ}03'08''$ de longitude Oeste e $10^{\circ}59'15''$ e $10^{\circ}55'38''$ de latitude Sul, no litoral central do estado de Sergipe, nas adjacências a Foz do rio Sergipe. Abrange parte dos municípios de Aracaju (6,8%) e Barra dos Coqueiros (8,7%), em um trecho de significativa importância da região Metropolitana de Aracaju (RMA), correspondente a aproximadamente 32 km² de área e 6 km de extensão de faixa litorânea (Figura 2).

Figura 2- Mapa de localização da área de estudo (em vermelho) na América do Sul (a), mais precisamente no litoral central do Estado de Sergipe (b), entre as cidades de Aracaju e Barra dos Coqueiros, nas adjacências da foz do Rio Sergipe(c).



Fonte: Elaborada pelos autores.

A região enquadra-se no tipo climático As', segundo a classificação de Köppen-Geiger (1928), classificado como tropical seco no verão, caracterizado por ser um clima úmido, quente com estação seca no verão (KOTTEK *et al.*, 2006). O período chuvoso é compreendido entre abril e agosto, concentrado nos meses de maio, junho e julho (ARAÚJO *et al.*, 2010). O litoral em estudo tem a ocorrência de ventos alísios que vêm do Atlântico e penetram no continente proporcionando totais pluviométricos anuais mais elevados entre 1200 e 1600 mm diminuindo em direção ao interior (CRUZ, 2009) e temperatura média anual entre 24°C e 26° C (JACOMINE; MONTENEGRO; RIBEIRO, 1975).

A geologia da área equivale aos depósitos das Formações Superficiais Cenozoicas que recobre a Bacia Sedimentar Sergipe/Alagoas (SANTOS; MARTINS; NEVES, 1988), formados pela variação da linha de costa, por processos de regressão e transgressão marinha (BITTENCOURT *et al.*, 1983). Ao longo desses depósitos são desenvolvidas as unidades geomorfológicas de idades holocênicas e pleistocênicas da Planície Costeira sob a forma de terraços marinhos, depósitos de mangues e depósitos eólicos, com altitudes máximas de 4 metros acima do nível do mar (BITTENCOURT *et al.*, 1983; DOMINGUEZ; BITTENCOURT; MARTIN, 1992).

Na área predomina o solo Espodossolos e em menor proporção são encontrados os Neossolos formados por areias quartzosas distróficas e Gleissolos constituído por areias quartzosas e solos indiscriminados de mangue (JACOMINE; MONTENEGRO; RIBEIRO, 1975; SERGIPE, 2015; SANTOS *et al.*, 2018). O terreno é drenado pelo rio Sergipe e seu afluente Poxim localizado na margem direita da foz do rio Sergipe, na porção Aracajuana (SERGIPE, 2015). A vazão média da desembocadura do rio Sergipe é de 13,84 m³/seg (SEMARH, 2010).

As condições ambientais naturais citadas nos parágrafos anteriores vêm passando por profundas alterações nas últimas décadas. Os ecossistemas presentes na área de estudo estão sendo modificados, sobretudo devido à pressão antrópica. Dentre eles, destacam-se o manguezal na extensão do Bairro 13 de julho (SANTOS, 2012; SANTOS, 2014; SANTOS; SOUZA, 2016; WANDERLEY, 2013), Dunas, terraços marinhos e vegetação restinga no litoral (JESUS; ANDRADE, 2018, SILVA, 2019a; SILVA, 2019b) e toda a área envolvida na dinâmica da Foz do rio Sergipe que passa por inúmeros episódios de erosão e acreção ao longo dos anos

(WANDERLEY, 2006, BITTENCOURT; OLIVEIRA; DOMINGUEZ *et al.*, 2006; RODRIGUES *et al.*, 2015; VALENZUELA, 2018; DINIZ *et al.*, 2020).

1.2.2 Materiais utilizados

Para o mapeamento de uso e cobertura da terra foram selecionadas imagens de 1988, 1999, 2010 e 2019, adquiridas pelos sensores *Thematic Mapper* (TM) e *Operational Land Imager* (OLI) a bordo dos satélites Landsat 5 e 8, respectivamente (Tabela 1).

Tabela 1- Descrição das bandas do satélite LANDSAT 5 e 8 usadas neste estudo (TM = Thematic Mapper, OLI = Operational Land Imager, Res= resolução).

Satélite/ sensor	Bandas espectrais	Data	Orbita/ponto	Comprimento de onda
LANDSAT 5 TM	B1			0,45-0,52 μm
	B2	21/12/88	215/68	0,50-0,60 μm
	B3	04/12/99	215/67	0,63-0,69 μm
	B4	29/09/10		0,76-0,90 μm
LANDSAT 8 OLI	B2			0,45-0,51 μm
	B3			0,53-0,59 μm
	B4	04/07/19	215/67	0,64-0,67 μm
	B5			0,85-0,88 μm

Fonte: Adaptado de USGS (2020a) e USGS (2020b).

As imagens foram obtidas por meio da plataforma GEE (GORELICK *et al.*, 2017) no nível de processamento 2A, com valores de reflectância de superfície (USGS, 2020a; USGS, 2020b). As imagens foram selecionadas em função da menor presença de nuvens, considerando para este estudo um valor máximo de 10% de cobertura de nuvens na cena (Figura 3).

Figura 3- Composição colorida (R = banda do vermelho, G = banda do verde e B = banda do azul) das imagens Landsat utilizadas neste estudo. (a) 21 de dezembro de 1988 (Landsat 5), (b) 04 de dezembro de 1999 (Landsat 5), (c) 29 de setembro de 2010 (Landsat 5) e (d) 04 de julho de 2019 (Landsat 8), adquiridas no Google Earth Engine(GEE).



Fonte: GORELICK *et al.*, 2017

1.2.3 Métodos empregados

1.2.3.1 Definição das classes de uso e das amostras de treinamento

Inicialmente, foram consideradas oito classes no mapeamento de uso e cobertura da terra. A adoção das classes foi baseada na heterogeneidade espacial da área de estudo, critérios estabelecidos em manuais técnicos de mapeamento de uso e cobertura da terra (IBGE, 2013), Manual técnico da vegetação (IBGE, 2012), artigos, dissertações e teses que desenvolveram pesquisa na área de estudo.

Posteriormente as classes foram agrupadas em 6, agregando as subclasses relacionadas para harmonizar o aspecto visual do mapa. Resultaram em, nomeadamente: (1) área urbana, (2) corpos d'água, (3) faixa de praia, (4) vegetação, (5) pastagem e (6) Outras áreas não vegetadas. As classes ondas e praia molhada foram incorporadas em água e faixa de praia, respectivamente, já que só foram criadas a fim de capturar heterogeneidades dos pixels, mas tratam-se da mesma classe, conforme o agrupamento realizado (Tabela 2 e anexo A).

Tabela 2- Características das classes de uso e cobertura da terra adotadas nesse estudo.

Classe	Nome	Descrição
1	Área urbana	Área urbanizada com edificações. São áreas onde predomina superfícies não vegetadas, incluindo estradas, vias e construções.
2	Corpos d'Água	Corpo d'água, oceano, rios, lagoas, lagoas, represas, reservatórios e outros corpos d'água.
3	Praia seca	Faixa de praia com areia seca. Trata-se de área de cordões arenosos, de coloração branco brilhante, onde não há o predomínio de vegetação.
4	Vegetação	Área com vegetação natural; Mangue equivalente a formações florestais, densas, sempre-verdes, frequentemente inundadas pela maré e associadas ao ecossistema costeiro de Manguezal.
5	Pastagem	Área de pastagem, com atividades agropastoris. Essas áreas estão predominantemente plantadas, vinculadas a atividade agropecuária.
6	Outras áreas não vegetadas	Solo exposto ou superfícies arenosas
7	Ondas	Espraiamento das ondas
8	Praia molhada	Faixa de areia molhada, equivale a porção de areia de praia molhada limitada entre a água do mar e a linha limite da areia seca.

Fonte: Adaptado de MAPBIOMAS, 2020.

As imagens foram classificadas com base em 450 amostras pontuais de treinamento coletadas para cada ano da análise, selecionadas manualmente na composição colorida (Tabela 3). Nesse trabalho, as amostras foram extraídas por amostragem aleatória a partir de um arquivo vetorial, espacialmente alocados nos pixels da imagem. O valor resultante do cruzamento entre o ponto de treinamento e as bandas espectrais é o dado de entrada para o processo de classificação com uso de AM.

As amostras foram selecionadas usando a composição colorida, considerando o conhecimento da tipologia de classes na área de estudo em imagens de satélite de boa resolução e representatividade em área de cada classe. A seleção das amostras foi realizada sobre as imagens Landsat 5 e 8 importadas no software QGIS, distribuídas em 8 classes de uso e ocupação da terra: (1) Área urbana, (2) Corpos d'água, (3) Praia seca (4) Vegetação, (5) Pastagem, (6) Outras áreas não vegetadas, (7) Ondas, (8) Praia molhada. As amostras de treinamento foram divididas aleatoriamente em um conjunto de 70% de amostras de treinamento (315) um conjunto de 30% de amostras de validação (135).

Tabela 3- Número de amostras utilizados em cada classe para a classificação supervisionada.

Classes/amostras	Área urbana	Corpos d' Água	Praia Seca	Vegetação	Pastagem	Outras áreas não vegetadas	Ondas	Praia molhada	Total
Nº de amostras de treinamento	65	100	65	65	45	10	60	40	450

Fonte: Elaborada pelos autores.

1.2.3.2 Variáveis utilizadas nos modelos de classificação

A classificação supervisionada foi realizada por meio dos modelos Floresta Aleatória (BREIMAN, 2001), Máquina de Vetores de Suporte (CORTES; VAPNIK, 1995) e Redes Neurais (ATKINSON; TATNALL, 1997). Todo processamento dos dados foi realizado no software livre R (R CORE TEAM, 2018), com uso do código disponibilizado por Abdi (2019) (Anexo B), a partir da execução do pacote *Caret* (KUHN, 2008).

Os modelos de classificação foram implementados a partir de diferentes bases de dados e organizados em quatro conjuntos. O primeiro conjunto foi derivado das bandas da composição colorida (Conjunto 1). O segundo pacote de dados é formado pela união do primeiro com os índices de vegetação (IV) estimados (Conjunto 2). São eles: NDVI, DVI, OSAVI, SR, MSR, GEMI, MSAVI2, RDVI, SAVI, GNDVI, TVI. Já o terceiro (Conjunto 3) é formado por composição colorida (conjunto 1) com as métricas de textura estimadas para todas as bandas do LANDSAT 5 ou 8.

As métricas de textura foram geradas com base em algumas das feições determinados por HARALICK et al. (1973) que foram extraídas da matriz de co-ocorrência dos níveis de cinza. São elas: média, variância, homogeneidade, contraste, dissimilaridade, entropia e segundo momento angular. Para análise, foi adotada uma janela fixa de tamanho 3 x 3, calculadas usando o pacote Matrix de Co-Ocorrência de Nível de cinza (Grey Level Co-occurrence Matrix (GLCM) implementado em linguagem R (R CORE TEAM, 2018). Por fim, no quarto grupo essas métricas de textura foram estimadas para todas as bandas e índices de vegetação supracitados, conforme descrito na Tabela 4. O cálculo destas variáveis foi feito conforme código executado no programa R (R CORE TEAM, 2018), disposto no anexo B e descritos na Tabela 4.

Tabela 4 - Resumo dos atributos dos índices de vegetação espectrais e medidas de textura de imagem derivadas de imagens Landsat 5 e 8, selecionados para o estudo.

Base de dados	Fonte de dados extraídos	Conjunto de dados				Variável de interesse	Descrição	Equação
		1	2	3	4			
Landsat 5(TM)	Bandas para composição					B1 B2 B3 B4	Azul Verde Vermelho NIR (Infravermelho próximo)	-
	Índice de vegetação (IV)					NDVI (ROUSE <i>et al.</i> , 1974)	$\frac{B4 - B3}{B4 + B3}$	1
						RDVI (ROUJEAN & BREON, 1995)	$\sqrt{(B4 - B3) / (B4 + B3)}$	2
						OSAVI (RONDEAUX, G., STEVEN, M., & BARET, F., 1996)	$\frac{B4 - B3}{B4 + B3 + 0,16}$	3
						SR (JORDAN, 1969)	$\frac{B4}{B3}$	4
						MSR (QI <i>et al.</i> , 1994)	$\frac{B4}{B3} - 1 \sqrt{\left(\frac{B4}{B3}\right)} + 1$	5
						GEMI (PINTY, B., VERSTRAETE, M. M. (1992)	$n * (1 - 0,25 * n) - \left(\frac{B3 - 0,125}{1 - B3}\right)$ Onde $n = \frac{2 * (B4^2 - B3^2) + 1,5 * B4 + 0,5 * B3}{(B4 + B3 + 0,5)}$	6
						MSAVI2 (QI <i>et al.</i> , 1994)	$0,5 * ((B4 + 1) - \sqrt{2 * (B4 + 1)^2 - 8(B4 - B3)})$	7
						RDVI (ROUJEAN; BREON, 1995)	$(NDVI * DVI)^{0,5}$	8
						SAVI (HUETE, A. R., 1988)	$\frac{B4 - B3}{B4 + B3 + L} * (1 + L)$ onde L=0,5	9
						GNDVI (GITELSON <i>et al.</i> , 1996)	$\frac{B4 - B2}{B4 + B2}$	10
						TVI (ROUSE <i>et al.</i> , 1974)	$\sqrt{\frac{B4 - B3}{B4 + B3}} + 0,5$	11
								(continua)

(conclusão)						
Base de dados	Fonte de dados extraídos	Conjunto de dados				Equação
		1	2	3	Variável de interesse	
	Métricas de textura (Haralick <i>et al.</i> , 1973)				Média (MED)	$\sum_{i,j=0}^{N-1} IP_{i,j}$ 12
					Variância (VAR)	$\frac{\sum_{i,j} (x_{ij} - \mu)^2}{n - 1}$ 13
					Homogeneidade (HOM)	$\sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1 + (i - j)^2}$ 14
					Contraste (CO)	$\sum_{i,j=0}^{N-1} IP_{i,j} (I - J)^2$ 15
					Dissimilaridade (DIS)	$\sum_{i,j=0}^{N-1} i P_{i,j} I - J $ 16
					Entropia (ENT)	$\sum_{i,j=0}^{N-1} i P_{i,j} (-\ln P_{i,j})$ 17
					segundo momento angular (ASM)	$\sum_{i,j=0}^{N-1} IP_{i,j}^2$ 18
Landsat 8(OLI)	Bandas para composição				B2	*Ver descrição do item acima dos dados Landsat 5" -
					B3	
					B4	
					B5	
	IV				*Ver descrição do item acima dos dados Landsat 5	*Ver descrição do item acima dos dados Landsat 5 -
	Métricas de textura (Haralick <i>et al.</i> , 1973)				(MED)	*Ver descrição do item acima dos dados Landsat 5 -
					(VAR)	
					(HOM)	
					(CO)	
					(DIS)	
					(ENT)	
					ASM)	

*Onde em Landsat 5, B1- banda 1 azul; B2- banda 2 verde; B3- banda 3 vermelho; B4- banda 4 infravermelho próximo; Em Landsat 8, B2- banda 2 azul; B3- banda 3 verde; B4- banda 4 vermelho; B5- banda 5 infravermelho próximo; NDVI- Índice de vegetação de diferença normalizada; DVI- índice de diferença de vegetação; OSAVI- índice de vegetação ajustado ao solo; SR- simples razão; MSR: relação modificada simples; GNDVI- Índice de vegetação de diferença normalizada verde; MSAVI2- Segundo índice de vegetação ajustado; NDI - índice de infravermelho de diferença normalizado; RDVI- Índice de Vegetação Diferencial Renormalizado; SAVI: Índice de vegetação adaptada ao solo; TVI: índice triangular de vegetação.

1.2.3.3 Validação da classificação

A precisão dos mapas foi avaliada por meio da matriz de erro também conhecida como matriz de confusão (CONGALTON, 1991; OLOFSSON *et al.*, 2014, FINEGOLD *et al.*, 2016) gerada no software R (R CORE TEAM, 2018) com uso do pacote Caret (KUHN, 2020). A matriz de erro é uma matriz quadrada de números estabelecida em linhas (dados classificados) e colunas (dados de referência) que expressam o número de unidades de amostras atribuído a uma categoria específica em relação a categoria real (OLOFSSON *et al.*, 2014).

Neste trabalho foram calculadas as métricas a seguir: acurácia global (AG), acurácia do produtor (AP), acurácia do usuário (AU), erro de omissão (EO) e erro de comissão (EC) (OLOFSSON *et al.*, 2014). O detalhamento dos resultados permitiu também calcular as estatísticas dos erros de quantidade (EQ) e erros de alocação (EA) (PONTIUS; MILLONES, 2011). A descrição das métricas e estatísticas apresentadas podem ser visto nos trabalhos de Congalton (1991), Olofsson *et al.* (2014), Pontius e Millones (2011).

1.3 RESULTADOS

1.3.1 Análise dos atributos selecionados

Para os dados Landsat 5 (anos de 1988, 1999 e 2010), a composição colorida (conjunto 1) apresentou os melhores resultados, com acurácia geral de 98,98% para 1988 e 99,14% para 1999, exceto classificação do ano de 2010, que teve maior valor de acurácia (AG= 99,14%) a partir de dados do conjunto 2. A segunda melhor classificação para 1988 (AG=97,43%) e 1999 (AG=98,29%) foi obtida com os dados oriundos da combinação de todos os atributos (conjunto 4). Ambos resultados foram processados no classificador Floresta Aleatória (Tabela 5).


Já os dados Landsat 8 (ano de 2019) apresentaram os melhores resultados com dados do conjunto 2 e 3 no modelo FA e com o conjunto de dados 4 no modelo MVS, ambos com acurácia global de 99,15% (Tabela 5). Em síntese, a análise da acurácia obtida para todos os dados, mostra que os melhores resultados estão presentes no conjunto de dados 1 e 2, porém visualmente os melhores resultados concentram-se no conjunto de dados 4, visto a suavização dos pixels e bordas nos mapas gerados (Figura 4).

Tabela 5- Qualidade das classificações para cada conjunto dos dados estudado, expressas pelos índices de Coeficiente Kappa e Acurácia Global.

Dados/ano	Comp (Conjunto 1)	K	AG	Comp+IVs (Conjunto 2)	K	AG	Comp+MT (Conjunto 3)	K	AG	Comp+IVs+MT (Conjunto 4)	K	AG
RF												
anos	1988	0,985	0,983	1988	0,898	0,880	1988	0,920	0,906	1988	0,978	0,974
	1999	0,993	0,991	1999	0,971	0,966	1999	0,978	0,974	1999	0,985	0,983
	2010	0,942	0,931	2010	0,993	0,991	2010	0,942	0,932	2010	0,956	0,949
	2019	0,964	0,958	2019	0,993	0,992	2019	0,993	0,992	2019	0,986	0,983
MVS												
anos	1988	0,934	0,923	1988	0,920	0,906	1988	0,891	0,871	1988	0,927	0,914
	1999	0,949	0,940	1999	0,942	0,931	1999	0,964	0,957	1999	0,978	0,974
	2010	0,912	0,897	2010	0,985	0,983	2010	0,927	0,915	2010	0,964	0,957
	2019	0,978	0,975	2019	0,978	0,975	2019	0,978	0,974	2019	0,993	0,992
RNA												
anos	1988	0,876	0,853	1988	0,898	0,880	1988	0,803	0,768	1988	0,825	0,793
	1999	0,839	0,810	1999	0,912	0,897	1999	0,774	0,734	1999	0,810	0,778
	2010	0,832	0,801	2010	0,920	0,905	2010	0,869	0,846	2010	0,854	0,828
	2019	0,906	0,889	2019	0,935	0,923	2019	0,819	0,786	2019	0,949	0,940

Onde, K= coeficiente Kappa; AG= Acurácia global; Comp= composição colorida; IVs= índice de vegetação; MT= métricas de textura.

Figura 4- Mapas de Uso e Cobertura da Terra classificados por Floresta Aleatória com dados do ano de 1988, com os 4 diferentes conjuntos de dados: (a) Conjunto 1 (composição colorida); (b) Conjunto 2 (Comp com IV); (c) Conjunto 3 (Comp com MT); (d) Conjunto 4 (Comp, IV e MT).




Fonte: Elaborada pelos autores.

1.3.2 Mapeamento e precisão os modelos de classificação

A fim de visualizar o potencial dos três classificadores, foram avaliados os resultados dos dois conjuntos de dados que tiveram resultados mais satisfatórios, como já mencionado no tópico anterior, o conjunto 1 e o conjunto 4, respectivamente a composição colorida e o conjunto que contém todos os atributos.


O processamento e classificação das imagens de satélite com uso dos modelos FA, MVS e RNA, permitiram a análise das mudanças ocorridas na paisagem entre os anos de 1988, 1999, 2010 e 2019 (Figura 5 e 6). As estimativas de áreas classificadas apresentam variações que podem ser visualizadas na tabela 6.

Figura 5- Mapas de Uso e Cobertura da Terra classificados por diferentes métodos testados ao longo de 3 décadas na área de estudo com o conjunto de dados 1 (composição original RGBNIR) para (a) Random forest (1988), (b) Random forest (1999), (c) Random forest (2010), (d) Random forest (2019), (e) Suport Vector Machine (1988), (f) Suport Vector Machine (1999), (g) Suport Vector Machine (2010), (h) Suport Vector Machine (2019), (i) Artificial Neural Network (1988), (j) Artificial Neural Network (1999), (l) Artificial Neural Network (2010), (m) Artificial Neural Network (2019).



Fonte: Elaborada pelos autores.

Figura 6- Mapas de Uso e Cobertura da Terra classificados por diferentes métodos testados ao longo de 3 décadas na área de estudo com o conjunto de dados 4 (composição original RGBNIR+ Índices de Vegetação+ Métricas de Textura) para (a) Random forest (1988), (b) Random forest (1999), (c) Random forest (2010), (d) Random forest (2019), (e) Suport Vector Machine (1988), (f) Suport Vector Machine (1999), (g) Suport Vector Machine (2010), (h) Suport Vector Machine (2019), (i) Artificial Neural Network (1988), (j) Artificial Neural Network (1999), (l) Artificial Neural Network (2010), (m) Artificial Neural Network (2019).



Legenda

Área Urbana	Faixa de praia seca	Pastagem	ondas	Faixa de praia molhada
Água	Vegetação	Área exposta		

0 1 2 km



Projeção UTM- SIRGAS 2000- 24S



Fonte: Elaborada pelos autores.

Tabela 6- Porcentagem de cobertura de área de diferentes classes de uso e cobertura da terra na área de estudo para os conjuntos de dados de melhores resultados (conjunto 1 e 4). FA= Floresta aleatória, MVS= Máquinas de vetores de Suporte, RNA= Redes Neurais Artificiais.

Classes /métodos	Dados	Área urbana		Água		Praia seca		Vegetação		Pastagem		Outras áreas não vegetadas		Ondas		Praia Molhada		Total
		km²	%	km²	%	km²	%	km²	%	km²	%	km²	%	km²	%	km²	%	km²
FA																		
1988		5,97	18,34	16,12	49,51	1,34	4,12	2,86	8,77	3,39	10,42	0,06	0,17	0,92	2,82	1,91	5,85	32,56
1999		7,64	23,45	14,19	43,58	1,38	4,23	2,71	8,32	3,62	11,11	0,31	0,95	1,98	6,09	0,74	2,27	32,57
2010		7,71	23,63	15,06	46,19	0,78	2,40	2,37	7,26	3,62	11,09	0,07	0,21	2,17	6,65	0,84	2,57	32,61
2019		8,00	24,52	15,69	48,07	0,91	2,79	2,08	6,38	3,38	10,35	0,10	0,31	1,58	4,83	0,90	2,75	32,63
MVS																		
1988	Conjun to 1	5,39	16,58	16,13	49,59	1,36	4,19	3,09	9,50	3,79	11,64	-	-	1,12	3,45	1,64	5,04	32,52
1999		7,03	21,62	14,61	44,95	1,38	4,23	2,94	9,04	3,46	10,63	0,00	0,01	1,94	5,97	1,15	3,55	32,50
2010		7,75	23,80	15,25	46,85	0,74	2,27	3,09	9,50	3,17	9,74	0,05	0,14	1,79	5,50	0,72	2,20	32,55
2019		8,16	25,03	15,68	48,10	0,85	2,61	2,56	7,86	2,96	9,09	0,06	0,18	1,37	4,20	0,96	2,93	32,60
RNA																		
1988		4,86	14,93	17,64	54,20	1,31	4,01	4,47	13,73	1,74	5,35	-	-	1,14	3,49	1,39	4,27	32,54
1999		6,71	20,61	14,47	44,44	1,51	4,64	4,49	13,79	1,32	4,05	-	-	3,13	9,61	0,93	2,86	32,56
2010		6,98	21,42	16,10	49,41	0,90	2,75	4,73	14,51	1,32	4,06	-	-	1,81	5,54	0,76	2,32	32,59
2019		6,75	20,67	16,40	50,23	1,19	3,65	3,49	10,68	2,82	8,64	-	-	1,24	3,80	0,76	2,33	32,64
FA																		
1988		6,10	18,77	15,47	47,57	1,46	4,47	3,17	9,75	3,17	9,74	0,05	0,17	1,71	5,25	1,39	4,28	32,52
1999		7,18	22,07	14,83	45,60	1,39	4,26	3,13	9,64	2,19	6,72	0,15	0,46	1,90	5,84	1,76	5,41	32,52
2010		7,40	22,75	14,74	45,30	1,24	3,81	3,01	9,24	2,49	7,66	0,09	0,26	2,05	6,31	1,52	4,67	32,54
2019		5,90	18,14	14,04	43,18	1,14	3,51	4,19	12,89	3,00	9,24	0,13	0,41	2,83	8,69	1,28	3,95	32,52
MVS																		
1988	Conjun to 4	6,10	18,77	15,47	47,57	1,46	4,47	3,17	9,75	3,17	9,74	0,05	0,17	1,71	5,25	1,39	4,28	32,52
1999		6,94	21,36	14,73	45,31	1,36	4,18	3,43	10,54	2,48	7,63	0,36	1,11	1,70	5,24	1,51	4,64	32,51
2010		7,42	22,80	13,84	42,55	0,88	2,72	3,36	10,33	2,69	8,27	0,20	0,61	2,44	7,50	1,70	5,23	32,52
2019		7,48	23,00	14,30	43,97	0,95	2,92	3,88	11,91	1,96	6,02	0,25	0,78	2,39	7,34	1,32	4,05	32,53
RNA																		
1988		8,38	25,78	12,18	37,46	1,60	4,91	4,21	12,96	0,25	0,77	-	-	5,17	15,89	0,73	2,23	32,51
1999		8,40	25,84	9,00	27,69	1,34	4,11	4,39	13,49	0,83	2,54	-	-	7,46	22,94	1,11	3,40	32,52
2010		6,73	20,70	14,26	43,87	1,41	4,33	3,71	11,40	2,74	8,42	0,09	0,29	3,27	10,05	0,30	0,94	32,51
2019		5,90	18,14	14,04	43,18	1,14	3,51	4,19	12,89	3,00	9,24	0,13	0,41	2,83	8,69	1,28	3,95	32,52

Fonte: Elaborada pelos autores.

Os resultados obtidos retratam, no geral, o aumento da área urbana e diminuição das classes de água, vegetação, pastagem e faixa de praia ao longo do tempo. Essas alterações devem-se principalmente ao crescimento populacional desenfreado, típico de áreas litorâneas e podem ser corroboradas pelo percentual de aumento populacional de 36,3% entre 1989 (418.617 hab.) e 2019 (657.013 hab.) na cidade de Aracaju e aumento de 64% na cidade de Barra dos Coqueiros passando de

11.017 habitantes em 1989 para 30.407 habitantes em 2019 (IBGE, 1989; IBGE, 2019).

Quando considerados todos os modelos, os dados obtidos mostram a predominância das classes área urbana (entre 14,9% a 25,83%) e água (entre 27,68 % a 54,2%), onde juntas perfazem mais de 50% da área em todos os anos analisados. O comportamento pode ser ilustrado nas figuras 4 e 5. Vale ressaltar que os valores da classe ondas para todos os modelos e anos (entre 2,8 a 22,94%) foram agregados a classe água, já que é individualizada para representar o espriamento das ondas, que tem resposta espectral diferente da água nas imagens de satélite, mas equivalem a mesma classe, dessa forma a água total alcança porcentagens entre 49,6% e 57,7% para todos os anos analisados nos diferentes modelos de classificação.

A predominância da classe água é justificada visualmente, já que a área é caracterizada como litorânea e estuarina, marcada pela presença predominante do oceano Atlântico, foz do rio Sergipe e diversos canais naturais e artificializados (PMA/SEPLOG, 2014).

As classes menos representadas foram outras áreas não vegetadas (variou de 0% a 11%) e faixa de praia (4,46 % a 9,96%), a última correspondente a soma das classes praia molhada (0,93% a 5,85%) e praia seca (2,27% a 4,9%), segmentadas para melhor representação da categoria, assim como feito para as classes ondas e água.

Considerado os modelos processados com os dados da composição colorida, observa-se relação inversamente proporcional ao longo dos anos entre as classes área urbana (RF= 18,3 % a 24,5%; MVS=16,5% a 25 %; RNA= 14,9 % a 21,4%) e vegetação (RF= 8,7% a 6,3%; MVS=9,5% a 7,8%; RNA= 13,7% a 10,6 %). Esta diminui em todos os modelos à medida que a área urbana se intensifica. Já os resultados processados com o conjunto 4 não mostraram a relação bem definida.

Dessa forma, os resultados apresentados na tabela 6, refletem o aumento da área urbana em todo o período, que deve ocorrer devido a especulação imobiliária e consequentemente ocorre a diminuição da vegetação ao longo dos anos. Nesse sentido, Valenzuela (2018) apresenta resultados que mostram redução de manchas de vegetação na RMA entre os anos de 1990 e 2015. Fernandes *et al.*, (2017), também menciona que fragmentos florestais da região costeira de Sergipe tiveram

redução em tamanho, ocasionando fragilidade a processos de erosão e assoreamento.

Em estudo na RMA, Valenzuela (2018), constata um aumento para o dobro na proporção de área de solo exposto de 2015 em relação ao ano de 1991. A autora também identifica aumento da classe adensamento urbano e alteração menos significativas, nas classes corpos d'água e mangue.

As áreas mapeadas como corpos d'água apresentaram estabilidade ao longo dos anos analisados, evidenciada pela baixa redução de 0,7% entre 1988 e 2019. Considera-se que a pequena variação existente da classe água pode acontecer em resposta as alterações climáticas ocorridas nas diferentes datas estudadas, principalmente relacionadas a variação da linha de costa no litoral e variação da maré na planície de maré da Maré de Apicum no bairro 13 de julho.

A classe faixa de praia apresentou redução ao longo dos anos de 1988 a 2019. A redução máxima de 4,4% foi obtida através do modelo FA, seguida por redução de 3,6% no MVS e menor redução no modelo RNA (2,31%).

1.3.3 Acurácia dos modelos

A acurácia global derivada da matriz de erro para os três algoritmos nos anos de 1988, 1999, 2010 e 2019 apresentou altos valores, conforme mostrado na tabela 7. Os apêndices F e G ilustram a matriz para cada ano e modelo estudado, com dados do conjunto 1 e 4.

O algoritmo FA resultou nas melhores acurácias globais para todos os anos analisados (0,8802 a 0,9915), seguido pelo modelo MVS (0,871 a 0,9915) e por último o RNA (0,734 a 0,9404) com valores mais inferiores (Tabela 7). A acurácia global e índice *kappa* mais elevados foram respectivamente 0,9915 e 0,992 dos modelos FA e MVS no ano de 2019. O menor valor de acurácia global e índice *kappa* foi de 0,7775 e 0,8102, produzidos pelo modelo RNA para o ano de 1999.

Tabela 7- Nível geral de precisão dos classificadores utilizados nesse estudo para os melhores conjuntos de dados.

Modelo	Comp(Conjunto 1)/anos	K	AG	Comp+IV+MT(Conjunto 4) /anos	K	AG
RF	1988	0,985	0,983	1988	0,978	0,974
	1999	0,993	0,991	1999	0,985	0,983
	2010	0,942	0,931	2010	0,956	0,949
	2019	0,964	0,958	2019	0,986	0,983
MVS	1988	0,934	0,923	1988	0,927	0,914
	1999	0,949	0,940	1999	0,978	0,974
	2010	0,912	0,897	2010	0,964	0,957
	2019	0,978	0,975	2019	0,993	0,992
RNA	1988	0,876	0,853	1988	0,825	0,793
	1999	0,839	0,810	1999	0,810	0,778
	2010	0,832	0,801	2010	0,854	0,828
	2019	0,906	0,889	2019	0,949	0,940

Fonte: Elaborada pelos autores.

Estes resultados são considerados consistentes e estão entre intervalos de valores de acurácia global considerados excelentes (LILLESAND; KIEFER; CHIPMAN, 2015) ou o mínimo exigido em mapeamentos (JENSEN,1986), e coeficiente *kappa* quase perfeito (LANDIS; KOCH, 1977).

A acurácia de cada classe pode ser observada nos resultados de acurácias do usuário e do produtor, assim como os respectivos erros por exclusão (erro de omissão) e erros por inclusão (erro de comissão) (Tabelas 8 e 9). Essas estatísticas ocorreram em altos valores, o que indica uma alta precisão no número de pixels classificados corretamente por classe.

Tabela 8- Acurácia do Usuário e Produtor para o conjunto de dados 1

Classes	1988				1999				2010				2019			
	AP(%)	EO(%)	AU(%)	EC(%)	AP(%)	EO(%)	AU(%)	EC(%)	AP(%)	EO(%)	AU(%)	EC(%)	AP(%)	EO(%)	AU(%)	EC(%)
RF																
Área urbana	90,91	9,09	100,00	0,00	100,00	0	95	5	95,00	5,00	95,00	5,00	95,00	5,00	95,00	5,00
Água	100,00	0,00	100,00	0,00	100,00	0	100	0	100,00	0,00	100,00	0,00	100,00	0,00	96,77	3,23
Praia_seca	100,00	0,00	100,00	0,00	100,00	0	100	0	100,00	0,00	95,24	4,76	95,00	5,00	100,00	0,00
Vegetação	100,00	0,00	100,00	0,00	100,00	0	100	0	90,00	10,00	85,71	14,29	90,00	10,00	100,00	0,00
Pastagem	100,00	0,00	92,86	7,14	100,00	0	100	0	71,43	28,57	83,33	16,67	100,00	0,00	93,33	6,67
Outras áreas																
não vegetadas	100,00	0,00	66,67	33,33	67	33	100	0	66,67	33,33	100,00	0,00	100,00	0,00	100,00	0,00
Ondas	100,00	0,00	100,00	0,00	100	0	100	0	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00
Praia_molhada	100,00	0,00	100,00	0,00	100	0	100	0	100,00	0,00	92,31	7,69	91,67	8,33	84,62	15,38
MSV																
Área urbana	80,00	20,00	88,89	11,11	100	0	91	9	95,00	5,00	95,00	5,00	100,00	0,00	100,00	0,00
Água	100,00	0,00	100,00	0,00	100	0	97	3	100,00	0,00	96,77	3,23	100,00	0,00	96,77	3,23
Praia_seca	100,00	0,00	80,00	20,00	100	0	95	5	100,00	0,00	95,24	4,76	95,00	5,00	100,00	0,00
Vegetação	100,00	0,00	95,24	4,76	95	5	95	5	90,00	10,00	75,00	25,00	90,00	10,00	100,00	0,00
Pastagem	85,71	14,29	92,31	7,69	93	7	93	7	50,00	50,00	77,78	22,22	100,00	0,00	93,33	6,67
Outras áreas																
não vegetadas	0,00	100,00	0,00	0,00	0	100	0	0	66,67	33,33	100,00	0,00	100,00	0,00	100,00	0,00
Ondas	100,00	0,00	100,00	0,00	94	6	100	0	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00
Praia_molhada	100,00	0,00	100,00	0,00	92	8	92	8	91,67	8,33	91,67	8,33	100,00	0,00	92,31	7,69
RNA																
Área urbana	90,00	10,00	78,26	21,74	100	0	71	29	95	5	83	17	100,00	0,00	71,43	28,57
Água	100,00	0,00	96,77	3,23	100	0	94	6	100	0	91	9	100,00	0,00	93,75	6,25
Praia_seca	95,00	5,00	86,36	13,64	95	5	100	0	100	0	95	5	95,00	5,00	100,00	0,00
Vegetação	100,00	0,00	71,43	28,57	80	20	100	0	85	15	59	41	80,00	20,00	100,00	0,00
Pastagem	35,71	64,29	100,00	0,00	100	0	88	13	7	93	33	67	100,00	0,00	87,50	12,50
Outras áreas																
não vegetadas	0,00	100,00	0,00	0,00	0	100	0	0	0	100	0	0	0,00	100,00	0,00	0,00
Ondas	100,00	0,00	100,00	0,00	100	0	95	5	100	0	100	0	100,00	0,00	95,00	5,00
Praia_molhada	83,33	16,67	100,00	0,00	58	42	100	0	75	25	90	10	58,33	41,67	100,00	0,00

AU= acurácia do usuário; EO= erro de omissão; AP= acurácia do produtor; EC= erro de comissão.

Tabela 9- Acurácia do Usuário e Produtor para o conjunto de dados 4

Classes	1988				1999				2010				2019			
	AP(%)	EO(%)	AU(%)	EC(%)	AP(%)	EO(%)	AU(%)	EC(%)	AP(%)	EO(%)	AU(%)	EC(%)	AP(%)	EO(%)	AU(%)	EC(%)
RF																
Área urbana	95,00	5,00	95,00	5,00	95,00	5,00	100,00	0,00	90,00	10,00	94,74	5,26	100,00	0,00	100,00	0,00
Água	96,67	3,33	100,00	0,00	100,00	0,00	96,77	3,23	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00
Praia_seca	100,00	0,00	95,24	4,76	100,00	0,00	95,24	4,76	100,00	0,00	86,96	13,04	100,00	0,00	95,24	4,76
Vegetação	100,00	0,00	100,00	0,00	95,00	5,00	100,00	0,00	100,00	0,00	95,24	4,76	100,00	0,00	95,24	4,76
Pastagem	92,86	7,14	92,86	7,14	100,00	0,00	100,00	0,00	92,86	7,14	100,00	0,00	92,86	7,14	100,00	0,00
Outras áreas não vegetadas	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	33,33	66,67	100,00	0,00	100,00	0,00	100,00	0,00
Ondas	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	94,44	5,56	100,00	0,00	100,00	0,00	100,00	0,00
Praia_molhada	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	92,31	7,69	91,67	8,33	100,00	0,00
MSV																
Área urbana	85,00	15,00	85,00	15,00	95,00	5,00	100,00	0,00	90,00	10,00	85,71	14,29	100,00	0,00	100,00	0,00
Água	96,70	3,33	100,00	0,00	100,00	0,00	96,77	3,23	100,00	0,00	100,00	0,00	100,00	0,00	96,77	3,23
Praia_seca	100,00	0,00	83,33	16,67	100,00	0,00	95,24	4,76	95,00	5,00	90,48	9,52	100,00	0,00	100,00	0,00
Vegetação	100,00	0,00	95,24	4,76	90,00	10,00	100,00	0,00	100,00	0,00	100,00	0,00	95,00	5,00	100,00	0,00
Pastagem	78,60	21,40	91,67	8,33	100,00	0,00	93,33	6,67	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00
Outras áreas não vegetadas	0,00	100,00	0,00	0,00	100,00	0,00	100,00	0,00	33,33	66,67	100,00	0,00	100,00	0,00	100,00	0,00
Ondas	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00
Praia_molhada	100,00	0,00	92,31	7,69	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00	100,00	0,00
RNA																
Área urbana	90,00	10,00	58,06	41,94	95,00	5,00	82,61	17,39	75,00	25,00	83,33	16,67	95,00	5,00	90,48	9,52
Água	93,33	6,67	96,55	3,45	63,33	36,67	95,00	5,00	100,00	0,00	93,75	6,25	100,00	0,00	96,77	3,23
Praia_seca	100,00	0,00	80,00	20,00	100,00	0,00	95,24	4,76	85,00	15,00	85,00	15,00	90,00	10,00	90,00	10,00
Vegetação	95,00	5,00	90,48	9,52	95,00	5,00	67,86	32,14	80,00	20,00	84,21	15,79	95,00	5,00	100,00	0,00
Pastagem	0,00	100,00	0,00	100,00	28,57	71,43	100,00	0,00	78,57	21,43	68,75	31,25	100,00	0,00	100,00	0,00
Área n vegetada	0,00	100,00	0,00	0,00	0,00	100,00	0,00	0,00	33,33	66,67	50,00	50,00	33,33	66,67	100,00	0,00
Ondas	94,44	5,56	94,44	5,56	100,00	0,00	62,07	37,93	94,44	5,56	85,00	15,00	100,00	0,00	100,00	0,00
Praia_molhada	91,67	8,33	91,67	8,33	100,00	0,00	100,00	0,00	83,33	16,67	100,00	0,00	91,67	8,33	84,62	15,38

AU= acurácia do usuário; EO= erro de omissão; AP= acurácia do produtor; EC= erro de comissão.

O conjunto de dados 1, apresentou subestimação entre 0% nas classes água e ondas e 100 % na classe outras áreas não vegetadas. A superestimação variou entre 0% e 33% com valores distribuídos de forma indiscriminada entre todas as classes. Já o conjunto de dados 4, apresentou subestimação entre 0% na classe praia seca e 100% na classe outras áreas não vegetadas. Nesse conjunto de dados a superestimação foi menor nas classes outras áreas não vegetadas, ondas e praia molhada, processadas por RF e maior nas classes área urbana e pastagem processadas por RNA. Nessa análise, observa-se, em grande maioria, os valores de omissão e inclusão mais altos são atribuídos a classe outras áreas não vegetadas.

A acurácia do produtor, que indica a probabilidade de um pixel de referência ter sido classificado corretamente (CONGALTON, 1991), teve valores entre 0% e 100%. As classes água, ondas, praia molhada e praia seca, tiveram os melhores valores de AP para os 3 modelos de classificação, ao longo dos anos e com uso dos dois conjuntos de dados. As classes área urbana, vegetação e pastagem apresentaram valores intermediários, variando de acordo com o modelo de classificação e o conjunto de dados usado. Já a classe outras áreas não vegetadas, teve maior parte dos resultados com 0% de AP (Tabelas 8 e 9).

A acurácia do usuário, que consiste na probabilidade de um pixel classificado no mapa representar a categoria no solo (CONGALTON, 1991), apresentou resultados acima de 50%, exceto para a classe solo exposto que teve AU de 0% nos resultados processados por RNA e em alguns casos por MVS (Tabela 9). A AU do conjunto de dados 4, nos anos de 2010 e 2019, foi exceção e atingiu o valor mínimo de 50% e 84 % respectivamente nesses anos, para a classe solo exposto.

O modelo RF foi o que gerou as maiores precisões para a classe de maior confusão, a outras áreas não vegetadas (AP= 83,33% a 100%). Já o RNA apresentou o pior desempenho para a captura desta classe com AP mínima de 0% e máxima de 33,33%.

As acurácias do usuário mais baixas dentre todas os anos e modelos analisados foram das classes solo exposto e pastagem. Os mapas gerados são visualmente similares, exceto o processado com RNA. Esse modelo apresenta grande discrepância visual das classes vegetação e pastagem em relação aos demais modelos gerados e a imagens de satélite utilizadas.

A matriz de erro de todos os dados processados com RNA, mostram que as classes pastagem e outras áreas não vegetadas foram as que apresentaram maior parte dos pixels confundidos com outras classes. No caso da classe pastagem, houve confusão com as classes vegetação e área urbana. Já a classe outras áreas não vegetadas apresentaram confusão frequente com a classe área urbana e faixa de praia.

Comportamento semelhante ocorre em estudo realizado na RMA para os anos de 1990 e 2015 por Valenzuela, et al. (2019). A autora obteve acurácia global de 83% e índice *Kappa* de 0,80. Nesse estudo a matriz de erro indicou maior confusão entre as classes restinga, pastagem/cultivo, mangue e floresta. A menor confusão com outras classes foi da classe corpos d'água, estando de acordo com o que ocorre nesta pesquisa.

As classes que apresentaram o AP e AU mais altos são facilmente diferenciadas das demais, já as classes de menor acurácia apresentam grande confusão espectral com outras classes, a exemplo da classe solo exposto, comente confundida com área urbana devido a semelhança espectral dos pixels.

Estudos realizados com o objetivo de comparar as precisões dos métodos FA, MVS e RNA para classificação de uso e ocupação da terra (MAO *et al.*, 2020), mostram que dentre os três modelos de aprendizagem de máquinas, o FA alcançou os melhores resultados para a precisão geral e índice *kappa*, seguido por valores próximos do modelo MVS e por último valores inferiores do modelo RNA.

Abdi (2019), estudou o desempenho de quatro modelos de classificação em paisagem complexa com uso de dados do satélite Sentinel, sendo dois deles o FA e o MVS para geração de mapa com 8 classes. Na sua análise o MVS alcançou a maior acurácia geral (0,758) e o FA ficou em terceiro lugar com AG de 0,739. Todos os modelos apresentaram valores de acurácia satisfatórios e muito próximos entre si.

Zeferino *et al.* (2020), adicionou dados ambientais a composição original, afim de melhorar a precisão da classificação de uso e cobertura da terra da região amazônica com modelo RF. Os autores obtiveram acurácia global de 91% e índice *kappa* de 0,88 na composição original e após a adição de outras variáveis alcançou

um AG de 94% e *kappa* de 0,92, provando que a adição de dados a composição colorida pode melhorar a precisão da classificação.

Sheykhmousa *et al.* (2020), revisou mais de 250 artigos em pares e destaca que MVS e FA apresentam um desempenho similar relativamente alto em termos de precisão da classificação, onde o MSV tem como vantagem sua capacidade de lidar com problemas de altas dimensão e amostras de treinamento limitadas, já o FA apresenta facilidade no uso. Segundo Huang, Davis e Townshend (2002) as maiores precisões do MVS devem ser atribuídas à sua capacidade de localizar um hiperplano de separação ideal.

Pal e Mather (2005), compararam os resultados obtidos através dos métodos de Máxima Verossimilhança (MAXVER), RNA e MVS, em dados multiespectrais e hiperspectrais (DAIS) em áreas da Espanha e Inglaterra. Em seus resultados o MVS apresentou maior precisão de classificação e o algoritmo pôde ser usado com pequeno conjunto de dados de treinamento.

Fernandes *et al.* (2020), avaliou as mudanças no uso e cobertura da terra no estado de Sergipe, em região semiárida, durante 25 anos com uso do algoritmo de classificação supervisionada MAXVER. O estudo alcançou acurácias globais de 94,2%, índice *kappa* de 93% e identificou uma tendência geral de aumento de áreas urbanizadas, pastagens, terras expostas e redução de áreas de vegetação.

Barros *et al.* (2020), avaliou a eficiência do método RNA em uma bacia hidrográfica do estado de Sergipe. O autor comparou os resultados com o modelo MAXVER e obteve valores de exatidão global de 94%, demonstrando eficiência do método de classificação.

Feita a análise, percebe-se que neste trabalho, o algoritmo FA apresentou melhores acurácias (0,8802 a 0,9915) e em relação as classes, as que obtiveram as maiores precisões são aquelas que foram facilmente distinguidas nas imagens de satélite como água, ondas, vegetação e faixa de praia. Por outro lado, classes com menores precisões são as que tiveram uma variação considerável na intensidade relativa da reflectância de cada pixel.

1.3.4 Alterações dinâmicas do uso e cobertura da terra na área entre os anos de 1988 e 2019

A tabela 10 apresenta os resultados obtidos na classificação supervisionada para as alterações de uso e ocupação da terra ao longo dos anos com o classificador Floresta Aleatória e conjunto de dados 1. Ambos foram escolhidos para tal abordagem por apresentarem os melhores valores de acurácia global, índice *kappa* e por demonstrarem nos resultados correlações coerentes entre as classes.

Pode-se observar através da mediana dos resultados dos dados da composição colorida, aumento da área urbana em 6,18%, redução de água em 0,57 %, redução de 2,3% da vegetação, redução de 0,07% de pastagem, redução de 4,43% de faixa de praia e aumento de 0,14 % da outras áreas não vegetadas ao longo de todo o tempo (Tabela 10). Em síntese, tais resultados revelam aumento da área urbana, causado por processos de antropização, relacionados a diminuição das classes vegetação e faixa de praia.

Tabela 10- Quantificação das alterações de uso e cobertura da terra e suas respectivas percentagens, no trecho do litoral central de Sergipe associado a foz do rio Sergipe, Brasil, entre os anos de 1988 e 2019.

Classes /anos	1988	1988	2019	2019	Alteração 1988-2019
	Área (km ²)	Área (%)	Área (km ²)	Área (%)	(%)
Área urbana	5,97	18,34	8,00	24,52	6,18
Água	17,04	52,33	17,26	52,91	0,57
Faixa de Praia	3,25	9,97	1,81	5,53	-4,43
Vegetação	2,86	8,77	2,08	6,38	-2,39
Pastagem	3,39	10,42	3,38	10,35	-0,07
Outras áreas não vegetadas	0,06	0,17	0,10	0,31	0,14
Total	32,56	100,00	32,63	100,00	

Fonte: Elaborado pelos autores.

O mapeamento mostra que as alterações mais relevantes entre os anos de 1988 e 2019, correspondem às áreas urbanas, faixa de praia e áreas de vegetação. As classes água e pastagem mantiveram a proporção de áreas ao longo dos anos e a classe outras áreas não vegetadas apresentou um leve aumento de 0,14%.

Áreas caracterizadas pela presença de mangue não foram individualizadas nesse estudo e estão inclusas na classe vegetação, contudo apresenta visualmente o mesmo comportamento de decréscimo retratado por áreas com vegetação ao longo dos anos estudados. Nascimento (2008) afirma que quaisquer alterações atuantes nos manguezais podem provocar desequilíbrios e, dependendo do grau de interferência, podem chegar a destruí-los. Essa interferência é claramente observada com o aumento da classe área urbana que ocupou áreas que a princípio eram ocupadas por mangue.

A região de mangue diminuiu devido práticas como assoreamento, desenvolvimento de carcinicultura ou o aterramento total ou parcial em descumprimento da legislação ambiental com a prática de ocupações de áreas irregulares (DUARTE; REZENDE, 2019).

Comportamento contrário ocorre somente na extensão do bairro 13 de julho, onde o mangue se desenvolve por influência de intervenções antrópicas realizadas para contenção à erosão, como pode ser observado o aumento na proporção das áreas ao longo dos anos.

1.4 CONCLUSÃO

Os quatro algoritmos avaliados resultaram em acurácias gerais entre 0,73 e 0,99. A mais alta acurácia da classificação foi produzida pelo algoritmo Floresta aleatória (0,88 a 0,99) e o menor desempenho foi produzido por Redes Neurais Artificiais (0,73 a 0,94).

O processamento dos dados com os três diferentes métodos retrata o aumento da área urbana e diminuição das classes de água, vegetação, pastagem e faixa de praia ao longo do tempo. Essas alterações devem-se principalmente ao crescimento populacional e supressão da vegetação, típico de áreas litorâneas urbanizadas, industrializadas e economicamente desenvolvidas.

A análise dos diferentes conjuntos de dados tornou os resultados mais eficientes, apresentando aumento na acurácia geral. O uso de Índices de Vegetação não demonstrou os maiores resultados de acurácia. Esse fato pode estar associado a variedade de classes presentes que não são bem representadas com uso de IV,

contudo recomenda-se que os índices sejam utilizados com o foco na reanálise da classe vegetação, na busca do detalhamento e diferenciação dos tipos de vegetação, como por exemplo o mangue, que têm grande relevância no contexto da área.

O conjunto de dados que incluíram os IV e Métricas de Textura resultaram em bons valores de acurácia, e nos melhores resultados visuais dos mapas gerados. Essa composição atuou como uma espécie de filtragem, removendo os pixels que estavam isolados e suavizando as bordas.

E finalmente, as estatísticas acurácia do produtor, acurácia do usuário e os erros de omissão e inclusão, expressaram a eficácia dos modelos em cada classe. A abordagem permitiu identificar que as maiores precisões ocorreram nas classes água, ondas, vegetação e faixa de praia. Essas classes são facilmente distinguidas nas imagens de satélite, por isso é menor a confusão entre dados da matriz. Por outro lado, as classes com menores precisões, como solo exposto e pastagem, foram as que tiveram uma variação considerável na intensidade relativa da reflectância de cada pixel e por isso foram mais difíceis de serem classificadas corretamente pelo algoritmo.

1.5 AGRADECIMENTOS

A Universidade Federal de Sergipe (UFS), ao Programa de Pós-Graduação em Recursos Hídricos (PRORH-UFS), ao Laboratório de Sensoriamento Remoto e Geoprocessamento (SERGEO), ao grupo de Sensoriamento Remoto “OFE” pelo conhecimento adquirido ao longo da execução do trabalho e a Coordenação de Aperfeiçoamento de Pessoal (CAPES) pela concessão da bolsa de estudo da primeira autora.

1.6 REFERÊNCIAS BIBLIOGRÁFICAS

ABDI, A. M. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. **GIScience & Remote Sensing**, 57: 1, 1-20, Aug 2019. DOI: 10.1080 / 15481603.2019.165044.

ARAÚJO, H. M. D. Cobertura Vegetal, Uso do solo e ocupação da terra na bacia costeira do rio Sergipe. 2012. Disponível em:<<http://observatoriogeograficoamericalatina.org.mx/egal12/Procsosmbientales/Impactoambiental/19.pdf>>. Acesso em: 05 janeiro 2021.

ARAÚJO, H. M. D., SOUZA, A. C., COSTA, J. D. J.; SANTOS, G. J. D. O Clima de Aracaju na interface com a geomorfologia de encostas. **Scientia Plena**, Aracaju, v. 6, n. 8, ago. 2010. Disponível em: <<http://www.scientiaplena.org.br/ojs/index.php/sp/article/viewFile/75/45>>. Acesso em: 20 maio 2019.

ATKINSON, P. M.; TATNALL, A. R. L. Introduction Neural networks in remote sensing, **International Journal of Remote Sensing**, 18:4, 699-709. 1997. DOI: 10.1080/014311697218700.

BARROS, G. V. P et al. Eficiência de Redes Neurais Artificiais na Classificação de Uso e do Solo da Bacia Hidrográfica do Rio Japarutuba – SE. **Revista Brasileira de Meteorologia**, v. 35, n. Especial, p. 823 - 833, 2020.

BELGIU, M.; DRĂGUȚ L. Random forests in remote sensing: a review of applications and future directions **ISPRS J. Photogramm. Remote Sens.**, 114, pp. 24-31. 2016.

BENEDIKTSSON, J. A., SWAIN, P. H. E ERSOY, O. K., Neural Network Approaches Versus Statistical Methods In: Classification of Multisource Remote Sensing Data. in **IEEE Transactions on Geoscience and Remote Sensing**, vol. 28, no. 4, pp. 540-552, July 1990, DOI: 10.1109/TGRS.1990.572944.

BITTENCOURT, A.C.S.P.; MARTIN, L.; DOMINGUEZ, J.M.L.; FERREIRA, Y. de A. Evolução paleogeográfica quaternária da costa do estado de Sergipe e da costa sul do estado de Alagoas. **Revista Brasileira de Geociências**, v.13, p. 93-97. 1983.
BITTENCOURT, Abílio; OLIVEIRA, Marta Becker de; DOMINGUEZ, José Maria Landim. Erosão e Progradação do Litoral Brasileiro-Sergipe. In: Dieter Muehe. (Org.). **Erosão e Progradação do Litoral Brasileiro**. 2ed.Brasília: Ministério do Meio Ambiente, 2006, v., p. 213-218.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5–32. 2001. DOI: <https://doi.org/10.1023/A:1010933404324>.

CONGALTON, RUSSELL G., A review of assessing the accuracy of classifications of remotely sensed data, **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, ISSN 0034-4257, 1991. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).

CORTES, C; VAPNIK, V. Support vector machine. **Mach. Learn**, v. 20, p. 273–297. **1995**.

CRUZ, M. A. S. Regionalização de precipitações médias e prováveis mensais e anuais no estado de Sergipe. Aracaju: Embrapa Tabuleiros Costeiros, 2009.

DINIZ, M.T.M.; SILVA, D.S.; SANTOS, J.R.; SOUZA, R.M., AND SILVA, J.P. Variation of the coastline between the years of 1984 and 2017 in the State of Sergipe, Northeast Region, Brazil. *In*: Malvárez, G. and Navas, F. (eds.), *Global Coastal Issues of 2020*. **Journal of Coastal Research**, Special Issue No. 95, pp. 458–462. Coconut Creek (Florida), 2020. ISSN 0749-0208.

DIXON, B.; CANDADE, Nivedita. Multispectral landuse classification using neural networks and support vector machines: one or the other, or both?. **International Journal of Remote Sensing**, v. 29, n. 4, p. 1185-1206, 2008.

DOMINGUEZ J.M.L, BITTENCOURT A.C.S.P., MARTIN L. Controls on Quaternary coastal evolution of the east-northeastern coast of Brazil: roles of sea-level history, trade winds and climate. **Sedimentary Geology**, 80:213-232. 1992.

DUARTE, T.L.S; REZENDE, V.A. Degradação dos manguezais em Aracaju/SE (Brasil): impactos socioeconômicos na atividade de catador do caranguejo-uçá (*Ucides cordatus*). **Revista Brasileira de Meio Ambiente**, v. 7, n. 1, 2019. DOI: <https://doi.org/10.5281/zenodo.3522468>.

FERNANDES, M.; FERNANDES, M.; ALMEIDA, A.; GONZAGA, M. I. S.; GONÇALVES, F. Ecologia da Paisagem de uma Bacia Hidrográfica dos Tabuleiros Costeiros do Brasil. **Floresta e Ambiente, Seropédica**, v. 24, 2017. Disponível em: <https://www.scielo.br/j/loram/a/JXxQHsGFLrQ9PT4sYHf55Vg/?format=pdf&lang=pt>. Acesso em: 15 de abril de 2019. DOI: <http://dx.doi.org/10.1590/2179-8087.025015>.

FERNANDES, M. M., FERNANDES, M. R. D. M., GARCIA, J. R., MATRICARDI, E. A. T., DE ALMEIDA, A. Q., & PINTO, A. S. Assessment of land use and land cover

changes and valuation of carbon stocks in the Sergipe semiarid region, Brazil: 1992–2030. **Land Use Policy**, 99. 2020.

FINEGOLD, Y, ORTMANN A, LINDQUIST E, D'ANNUNZIO R, SANDKER M. **Map Accuracy Assessment and Area Estimation: A Practical Guide.** Rome: Food and Agriculture Organization of the United Nations. 2016.

GITELSON, A.A., KAUFMAN, Y.J., MERZLYAK, M.N., Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, p. 289–298. 1996.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.* 2017, 202, 18–27.

HARALICK, RM, SHANMUGAM, K., DINSTEIN, I., Textural Features for Im-Classificação de idade. *IEEE Transactions on Systems, Man, and Cybernetics SMC-3*, 610–621. doi:10.1109 / TSMC.1973.4309314. nome da conferência: IEEE 455 Transactions on Systems, Man, and Cybernetics. 1973.

HUANG, C., DAVIS, L. S.; TOWNSHEND, J. R. G., An assessment of support vector machines for land cover classification, **Int. J. Remote Sens.**, vol. 23, pp. 725-749, 2002.

HUETE, A.R., A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309. 1988. DOI: [http://dx.doi.org/10.1016/0034-4257\(88\)90106-X](http://dx.doi.org/10.1016/0034-4257(88)90106-X).

IBGE – Instituto Brasileiro de Geografia e Estatística. Estimativa de População - 1989. Rio de Janeiro. 1989.

IBGE – Instituto Brasileiro de Geografia e Estatística. Estimativa de População - 2019. Rio de Janeiro. 2019.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Censo Brasileiro de 2010. Rio de Janeiro: IBGE, 2012. Disponível em: <https://www.ibge.gov.br/> Acesso em: 02 fev. 2021.

IBGE- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Manual Técnico de Uso da Terra. Rio de Janeiro: IBGE. n. 7, 3ª edição. 2013.

JACOMINE, P.K.T.; MONTENEGRO, J.O. & RIBEIRO, M.R. Levantamento exploratório – reconhecimento de solos do Estado de Sergipe. Recife, **Empresa Brasileira de Pesquisa Agropecuária**, 1975. 506p.

JENSEN, J.R. **Introductory Digital Image Processing**. New Jersey: Prentice Hall, 1986. 379 p.

JESUS, L.V; ANDRADE, A.C.S. **Taxas de variação da linha de costa e faixas de proteção nas áreas contíguas à desembocadura do rio Sergipe, Aracaju, Sergipe**. Pesquisa em Geociências, v. 45, p. 1-17, 2018. DOI: 10.22456/1807-9806.91389.

JORDAN, C. F. Derivation of leaf area index from quality of light on the Forest floor. **Ecology**, 50:663-666, 1969.

KALIRAJ, S.; CHANDRASEKAR, N.; RAMACHANDRAN, K.; SRINIVAS, Y.; SARAVANAN, S. Coastal landuse and land cover change and transformations of Kanyakumari coast, India using remote sensing and GIS. Egypt. J. **Remote Sens. Space Sci**. 2017, 20, 169–185.

KÖPPEN, W. Köppen-Geiger Map of World Climates. 1928.

KOTTEK M., GRIESER J., BECK C., RUDOLF B., RUBEL F., World Map of the Köppen-Geiger climate classification updated. **Meteorologische Zeitschrift**., 15, 259-263. 2006. DOI: 10.1127/0941-2948/2006/0130.

KUHN, MAX. **Caret: Classification and Regression Training**. R package version 6.0-86. 2020. Disponível em: < <https://CRAN.R-project.org/package=caret>>.

KUHN, MAX. "Building Predictive Models in R Using the caret Package," **Journal of Statistical Software**, Foundation for Open Access Statistics, vol. 28(i05). 2008.

LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data. Washington, USA. **Biometrics**, v. 33, n. 1, p. 159-1174, 1977.

LARY, D.J., ALAVI, A.H., GANDOMI, A.H., & WALKER, A.L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, 7, 3-10. 2016.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Remote sensing and image interpretation. **Wiley**. 7th Edition. ISBN: 978-1-118-34328-9. 2015.

MAO, W.; LU, D.; HOU, L.; LIU, X.; YUE, W. Comparison of Machine-Learning Methods for Urban Land-Use Mapping in Hangzhou City, China. **Remote Sens.** 12, 2817. 2020.

MAPBIOMAS. Projeto Mapbiomas. **Coleção [versão 5] da Série Anual de Mapas e Cobertura e Uso de solo do Brasil**. Disponível em: <https://mapbiomas.org/o-projeto>. Acesso em: 10 jan. 2020.

MAXWELL, A.E.; WARNER, T.A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. *Int. J. Remote Sens.* 2018, 39, 2784–2817, DOI: 10.1080/01431161.2018.1433343.

MILLER, D.M., KAMINSKY, E.J., RANA, S., Neural-network classification of remote-sensing data. *Computers & Geosciences* 21 (3), 377 – 386. 1995.

MOUNTRAKIS, Giorgos; IM, Jungho; OGOLE, Caesar. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247-259, 2011.

NASCIMENTO, S. A. **Ecofisiologia do Manguezal**. Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos (Org.). Sergipe: Degrase.2008.

NITZE, I.; BARRETT, B.; CAWKWELL, F. Temporal optimisation of image acquisition for land cover classification with Random Forest and MODIS time-series. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, p.136–146. DOI:10.1016/j.jag.2014.08.001.

NOBLE, W.S. What is a support vector machine? **Nature Biotechnology** 24, 1564–1567. 2006.

OLOFSSON, P.; FOODY, G.M.; HEROLD, M.; STEHMAN, S.V.; WOODCOCK, C.E.; WULDER, M.A. Good practices for estimating area and assessing accuracy of land change. **Remote Sens. Environ.** 2014, v.148, p.42–57.

PAL, M., MATHER, P.M. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, v. 26, n.5, p.1007–101. 2005.

PARENTE, L.; MESQUITA, V.; MIZIARA, F.; BAUMANN, L.; FERREIRA, L. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sens. Environ.** 2019, 232, 111301.

PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation from satellites. **Vegetatio**, 101(1), 15-20.1992.

PMA/SEPLOG. SECRETARIA MUNICIPAL DE PLANEJAMENTO, ORÇAMENTO E GESTÃO. (SEPLOG). Diagnóstico da Cidade de Aracaju. Relatório Final. Etapa 03. Aracaju: 2014.

PONTIUS, R. G.; MILLONES, M. Death to kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, 32, 4407–4429. 2011.

QGIS Development Core Team, QGIS Geographic Information System. A Free and Open Source Geographic Information Sistem. 2020. Disponível em: <https://www.qgis.org/en/site/>.

QI, J., CHEHBOUNI, A., HUETE, A. R., KERR, Y. H., & SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote sensing of environment**, v. 48, n. 2, p.119-126. 1994.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Austria. Available online at <https://www.R-project.org/>. 2018.

RODRIGUES, T.K., JESUS L.V., SILVA, M.G., PEREIRA, D.A.S., FEITOSA, E.S.S., ANDRADE, A.C.S., DOMINGUEZ, J.M.L. & LAVENERE-WANDERLEY, A.A.O. Deltas de Maré Vazante e Erosão Costeira na Atalaia Velha e no Mosqueiro, Aracaju (SE) no período de 1965 a 2008. **Scientia Plena**, 11: 1-7. 2015

RONDEAUX, G., STEVEN, M., & BARET, F. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95-107. 1996.

ROUJEAN, J. L.; BREON, F. M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote sensing of Environment*, v. 51, n. 3, p. 375-384. 1995.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS**. In: FREDEN, S. C.; MERCANTI, E. P.; BECKER, M. (ed.). Third Earth Resources Technology Satellite – 1 Symposium. v. I: Technical Presentations, NASA SP-351. Washington, DC: 1974. p. 309-317.

SANTOS, R.A., MARTINS, A.A.M., NEVES, J.P., 1998. Geologia e recursos minerais do estado de Sergipe. Brazil, Brazilian Geological Survey (CPRM), Salvador.

SANTOS, G. C. Dinâmica da paisagem costeira da Coroa do Meio e Atalaia – Aracaju/SE. 2012. 152f. Dissertação (Mestrado em Geografia) – Universidade Federal de Sergipe, São Cristóvão, SE, 2012.

SANTOS G. C. Derivações antropogênicas e Evolução do manguezal nos bairros 13 de julho e Jardins em Aracaju-SE. **Revista Brasileira de Geografia Física**, v. 7, n. 2, p. 278-290. 2014.

SANTOS, G. C. D., & SOUZA, R. M. E. Morfodinâmica do pontal arenoso e interferências na evolução da planície de maré na desembocadura do rio Sergipe – Aracaju/SE. **Revista Brasileira de Geomorfologia**, 17(4). 2016.

SANTOS, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.C.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; ALMEIDA, J.A.; CUNHA, T.J.F.; OLIVEIRA, J. B. **Sistema Brasileiro de Classificação de Solos**. 5. ed. rev. e ampl. Brasília, DF: Embrapa, p. 590, 2018.

SEMARH. Elaboração do Plano Estadual de Recursos Hídricos. Estudo, análise e Proposta de divisão hidrográfica de Sergipe em Unidades de Planejamento e Bacias Hidrográficas (RE-2). SERGIPE: 2010.

SERGIPE. Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos. **Atlas digital sobre recursos hídricos**. Aracaju: SEMARH, 2015.

SHEYKHOUSA, M., MAHDIANPARI, M., GHANBARI, H., MOHAMMADIMANESH, F., GHAMISI, P., & HOMAYOUNI, S. Support Vector Machine vs. Random Forest for Remote Sensing Image Classification: A Meta-analysis and systematic review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**. 2020.

SILVA, D.S. **Indicadores das oscilações da linha de costa nas praias de Aracaju-SE entre os anos 2013-2018 e sua relação com as Derivações antrópogênicas.** 2019a. 108 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação e pesquisa programa de pós-graduação em desenvolvimento e meio ambiente nível mestrado, São Cristóvão.

SILVA, V. R. C. DA. **Comportamento da linha de costa nas praias do Mosqueiro, dos Naufragos e da Atalaia, município de Aracaju, Sergipe.** São Cristóvão, SE, 2019b. Monografia (graduação em Geologia) – Curso de Geologia, Departamento de Geologia, Centro de Ciências Exatas e Tecnologia, Universidade Federal de Sergipe, São Cristóvão.

SOUZA, C.M.; Z. SHIMBO, J.; ROSA, M.R.; PARENTE, L.L.; A. ALENCAR, A.; RUDORFF, B.F.T.; HASENACK, H.; MATSUMOTO, M.; G. FERREIRA, L.; SOUZA-FILHO, P.W.M.; *et al.* Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sens.**, v.12, p. 735. 2020

SYIFA, M.; PARK, S.J.; ACHMAD, A.R.; LEE, C.-W.; EOM, J. Flood Mapping Using Remote Sensing Imagery and Artificial Intelligence Techniques: A Case Study in Brumadinho, Brazil. *J. Coast. Res.* 2019, 90, 197–204.

SZUSTER, B.W., CHEN, Q., BORGER, M. A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Applied Geography* 31, 525–532, 2011.

TALUKDAR, S.; SINGHA, P.; MAHATO, S.; SHAHFAHAD; PARCEIROS.; LIOU, Y.-A.; RAHMAN, A. Land-Use Land-Cover Classification por Machine Learning Classifiers for Satellite Observations — A Review. *Remote Sens.* v.12 , p.1135. 2020. DOI: <https://doi.org/10.3390/rs12071135>.

THONFELD, F. STEINBACH S., MURO J., KIRIMI F. Long-term land use/land cover change assessment of the Kilombero catchment in Tanzania using random forest classification and robust change vector analysis. **Remote Sens.**, v.12., p. 1057, 2020.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 4-5 TM collection 2 level 2 data format control book - Version 4.0.** September 2020a. Disponível em: https://d9-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/s3fs-public/atoms/files/LSDS-1336_Landsat4-5-TM-C2-L2-DFCB-v4.pdf. Acesso em: 11 nov. 2021.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 8-9 Operational Land Imager (OLI) - Thermal Infrared Sensor (TIRS) Collection 2 Level 2 (L2) Data Format Control Book (DFCB) - Version 6.0.** September 2020b. Disponível em: https://d9-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/s3fs-public/atoms/files/LSDS-1328_Landsat8-9-OLI-TIRS-C2-L2-DFCB-v6.pdf. Acesso em: 11 nov. 2021.

VALENZUELA, G. B. **Análise multi-temporal da fragmentação da paisagem da Região Metropolitana de Aracaju.** 2018. Dissertação de Mestrado. Universidade Federal de Pernambuco. 76 folhas.

VALENZUELA, Gabriela Bispo; GONCALVES, Rodrigo Mikosz; SOUSA, Paulo Henrique Gomes de Oliveira; QUEIROZ, Heithor Alexandre de Araújo. Fragmentação da paisagem na região metropolitana de Aracaju-SE, Brasil. **Revista Brasileira de Cartografia**, v. 71, n.3, p. 647-678, 2019.

WANDERLEY, L.L. Paisagem da janela: Esse nosso Inconstante Rio Sergipe e a Evolução de sua Foz. In: Alves J.P.H. (ed.) **Rio Sergipe: importância, vulnerabilidade e preservação.** São Cristóvão: Editora UFS, p.: 165-194. 2006.

WANDERLEY, L.L. A dinâmica geomorfológica e urbano- ambiental do sistema flúvio-marinho rio Sergipe-rio Poxim, em Aracaju, Sergipe, nordeste do Brasil. **Revista Geonordeste, Ano XXIV**, n.2, p. 56-80, 2013.

WOZNICKI, S. A., BAYNES, J., PANLASIGUI, S., MEHAFFEY, M., AND NEALE, A.: Development of a spatially complete floodplain map of the conterminous United States using random forest, **Science of the total environment**, 647, 942–953, 2019.

ZOLLINI, S.; ALICANDRO, M.; CUEVAS-GONZÁLEZ, M.; BAIOCCHI, V.; DOMINICI, D.; BUSCEMA, P.M. Shoreline Extraction Based on an Active Connection Matrix (ACM) Image Enhancement Strategy. *J. Mar. Sci. Eng.* **2020**, v. 8, n.9. DOI: <https://doi.org/10.3390/jmse8010009>.

ZEFERINO, L.B.; DE SOUZA, L.F.T.; DO AMARAL, C.H.; FILHO, E.I.F.; DE OLIVEIRA, T.S. Does environmental data increase the accuracy of land use and land cover classification? **Int. J. Appl. Earth Obs. Geoinf.** 2020, 91, 102128.

CAPÍTULO 2: Variação da linha de costa por mapeamento multitemporal com imagens Landsat: Um estudo de caso para o Litoral Central do estado de Sergipe entre os anos de 1988 a 2019

RESUMO

A análise da variação da linha de costa é de grande relevância, já que representam áreas extremamente sensíveis a mudanças naturais e ao impacto das atividades antrópicas. Ferramentas modernas automatizam o mapeamento da variação da linha de costa por detecção automática em dados multitemporais com uso de técnicas de sensoriamento remoto e geoprocessamento aliados a análise estatística dos dados. Hoje, dentre tantas fontes de dados utilizadas, as imagens de satélite da série Landsat oferecem uma gama de vantagens visto o acesso livre ao dado e a possibilidade de processar o conjunto de dados em plataforma baseada em nuvem com capacidade de processamento de dados espaciais de escala regional a planetária. Portanto, esse estudo teve como objetivo principal avaliar a partir de imagens de satélite a variação da linha de costa no litoral central do estado de Sergipe, associado a foz do rio Sergipe, entre as décadas de 1988 e 2019. A variação da linha de costa foi analisada por mapeamento multitemporal em imagens de Satélite da série Landsat, com resolução espacial de 30 metros, realizado com a ferramenta *Digital Shoreline Analysis System*. Os valores de taxa e envelope de variação da linha de costa foram estimados ao longo dos anos em três setores da região metropolitana, dois no município de Aracaju e um no município da Barra dos Coqueiros. As taxas foram obtidas por dois diferentes métodos: taxa por regressão linear e taxa por ponto de terminação. Em todos os setores, a taxa de variação apresentou valores entre -10,99 e 18,44 m.ano⁻¹ e predominou o comportamento de acresção ao longo do tempo. O envelope de variação da linha de costa apresentou menores valores em um dos transectos localizada na Maré de Apicum no bairro Coroa do Meio (4,19 m) e maiores valores em um dos transectos localizado na Praia da Atalaia Nova, na Barra dos Coqueiros (562,85 m). Podemos concluir que as imagens da série Landsat conseguiram modelar a variação da linha de costa e que existe uma tendência predominante de acresção nos três setores para o intervalo de tempo analisado. Esses resultados permitiram identificar a dinâmica da área costeira em médio a longo prazo e avaliar possíveis tendências do comportamento a erosão, estabilidade ou acresção.

Palavras-chave: Erosão costeira. Linha de costa. Google Earth Engine. Orla de Atalaia. Praia da Atalaia Nova.

2.1 INTRODUÇÃO

As zonas costeiras são áreas altamente dinâmicas que ocorrem na interface entre os principais sistemas naturais da terra e seus agentes ambientais como ondas, marés e ventos (DAVIDSON-ARNOTT, 2010). Segundo o autor, elas também se comportam como zonas de transferência de material dos sedimentos que são erodidos ou acumulados ao continente, quando ocorre a variação da linha de costa.

Em termos legais, a zona costeira é definida como uma faixa marítima de interação do ar, do mar e da terra, com 12 milhas náuticas de largura, e por uma faixa terrestre com 50 km de largura a partir da linha de costa. No Brasil, a zona costeira compreende cerca de 535.000 km² (MUEHE, 2018; BRASIL, 2004, BRASIL, 1988, MMA/SQA; MP/SQU, 2004). O litoral Brasileiro tem em torno de 26,6% da população total do país, concentradas em regiões costeiras banhadas pelo mar ou em regiões estuarinas (IBGE, 2010). Já que esse ambiente é naturalmente complexo, a ocupação humana de forma desordenada desencadeia maior fragilidade ambiental nos ecossistemas presentes.

As praias arenosas, representam grande parte da zona costeira do Brasil, e nas últimas décadas têm sofrido processo de erosão (LUIJENDIJK *et al.*, 2018). Da mesma forma, no litoral sergipano, tem sido identificada uma maior variabilidade no comportamento da linha de costa e a ocorrência frequente de eventos erosivos, contrariando a tendência progradacional do modelo tradicional (BITTENCOURT; OLIVIERA; DOMINGUEZ *et al.*, 2006). No estado de Sergipe, a zona costeira é formada por uma planície costeira que tem modelo clássico de formação de costas que avançam em direção ao oceano, caracterizada por apresentar tendência progradacional da linha de costa (DOMINGUEZ; BITTENCOURT; MARTIN, 1992), expondo uma ampla planície arenosa de depósitos praias.

O estudo de eventos costeiros e variação da linha de costa, é geralmente realizado em uma série de dados temporais, obtidos por diferentes técnicas (SMITH; ZARILLO, 1990; MOORE, 2000; BOAK; TURNER, 2005; ALESHEIKH *et al.*, 2007, GENS, 2010) como a análise de fotografias aéreas (STAFFORD; LANGFELDER, 1971; DOLAN; HAYDEN; HEYWOOD, 1978), imagens de satélite ópticas (LIU *et al.*,

2017; YADAV *et al.*, 2018; VOS *et al.*, 2019), imagens de radar (ZOLLINI *et al.*, 2020; DOMINICI; ZOLLINI, 2020) ou dados obtidos em campo (SMITH; ZARILLO, 1990). A compilação desses dados e vetorização das informações para uma série temporal, demanda tempo e capacidade de processamento de máquinas, contudo com os avanços tecnológicos, hoje é possível automatizar essa rotina com uso do sensoriamento remoto, geoprocessamento, programação computacional e ferramentas afins.

Estudos vêm sendo implementados com tecnologia para análise de dados em nuvem, denominada de GEE (*Google Earth Engine*), sem a necessidade de dispendar grandes capacidades computacionais e de tempo. A plataforma, que foi concebida com a finalidade de dar suporte a questões ligadas a sociedade e proteção ambiental, realiza processamento de dados em nuvem para análises geoespaciais em escala planetária (GORELIK *et al.*, 2016). Através dessa ferramenta é possível ter acesso coleções de dados geoespaciais pré-processados, a exemplo dos produtos do satélite Landsat.

Atualmente existem softwares disponíveis para realizar a análise da variação da linha de costa, fundamentada em princípios de processamento digital de imagens (THIELER *et al.*, 2009; VOS *et al.*, 2019; CASSIE, 2020, ALMEIDA *et al.*, 2021). O *Digital Shoreline Analysis System* (DSAS), é um módulo de extensão no ArcGIS 10.4-10.6, desenvolvido originalmente na década de 1990, que permite ao usuário calcular estatísticas de taxa e mudança da linha de costa, a partir de dados históricos, (THIELER *et al.*, 2009), alterando os parâmetros necessários a cada situação.

A variação da linha de costa têm sido objeto de diversos estudos em todo o mundo (BOAK; TURNER, 2005; MOORE, 2000; LUIJENDIJK *et al.*, 2018; VOS *et al.*, 2019; AMARO *et al.*, 2014). No litoral central do estado de Sergipe alguns trabalhos já abordaram a temática até o momento (JESUS; ANDRADE, 2018; JESUS, 2016; OLIVEIRA, 2003; SILVA, 2019a, SILVA, 2019b; RODRIGUES, 2008), contudo poucos fizeram o uso técnicas de detecção da variação da linha de costa automática para expressar a mudança em um contínuo intervalo de espaço e tempo (JESUS; ANDRADE, 2018; JESUS, 2016; SILVA, 2019b). Em outros setores do estado, como no litoral Norte e Sul, Santos (2021); Santos (2019); Silva (2019b) e Correia (2020) utilizaram técnicas automatizadas para investigação da variação da linha de costa e

processos de erosão. Essa pesquisa trará uma primeira contribuição sobre a variação da linha de costa abrangendo os 3 setores influenciados pela dinâmica da foz do rio Sergipe ao longo de 3 décadas (1988 a 2019): (1) Praia de Atalaia e Coroa do Meio em Aracaju; (2) 13 de julho e Jardins em Aracaju e (3) Praia da Atalaia Nova e Praia da Costa na Barra dos Coqueiros.

Considerando que as alterações costeiras, podem acarretar em desaparecimento de praias, afetando o desenvolvimento urbano, turístico e econômico de uma região (SOUZA, 2009); e que a região analisada neste estudo passou por eventos erosivos ao longo das últimas décadas, que ocasionou em perdas de estruturas urbanas e naturais, o monitoramento da variação da linha de costa auxilia no planejamento e gestão das áreas costeiras de área altamente urbanizada e multável.

Diante disso, o presente trabalho se propõe a apresentar os resultados inéditos de dados de satélites processados automaticamente para detecção e análise da linha de costa das praias do litoral central do Estado de Sergipe e região da foz do rio Sergipe, abrangendo praias dos municípios de Aracaju e Barra dos Coqueiros ao longo do ambiente costeiro e estuarino.


2.2 MATERIAL E MÉTODOS

A metodologia para análise da variação da linha de costa utilizada neste estudo tem sido empregada por diversos pesquisadores do mundo (NASSAR, 2018; KERMANI, 2016; PHILIP; KWASI; KUFOGBE, 2013; OYEDOTUN, 2014; THIELER e DANFORTH, 1994), alguns no Brasil (FERREIRA *et al.*, 2021; MIRANDA *et al.*, 2020; CARVALHO *et al.*, 2020; ALBUQUERQUE *et al.*, 2013) e outros em Sergipe (SANTOS, 2021; SANTOS, 2019; SILVA, 2019b; CORREIA, 2020). Neste estudo, essa abordagem é aplicada de forma inédita ao longo da área de estudo, por fim os resultados serão analisados junto ao mapeamento realizado sobre a dinâmica de uso e ocupação da terra.

A execução do trabalho envolveu as seguintes etapas: (1) Aquisição de imagens de satélite LANDSAT na plataforma Google Earth Engine (GEE) (GORELICK

et al., 2017); (2) mapeamento multitemporal da linha de costa no programa *Digital Shoreline Analysis System* (DSAS) (HIMMELSTOSS *et al.*, 2018; THIELER *et al.*, 2009); (3) análise estatística da taxa de variação da linha de costa e cálculo do envelope de variação da linha de costa (THIELER *et al.*, 2009) entre os anos de 1988 e 2019 e (4) tipos de uso e cobertura da terra associados a variação da linha de costa, gerado por modelo de classificação por Máquina de Vetores de Suporte (MVS) (CORTES; VAPNIK, 1995) durante o intervalo de tempo analisado. O fluxograma que descreve a análise digital da linha de costa e a classificação das imagens é apresentado na figura 7

Figura 7- Fluxograma do processamento dos dados digitais de imagens de satélite para análise da variação da linha de costa e classificação de uso e ocupação da terra.




Fonte: Elaborada pelos autores.

2.2.1 Localização e caracterização da área de estudo

A área de estudo está situada entre as coordenadas 37°00'50", 37°03'08" de longitude oeste e 10°59'15", 10°55' 38" de latitude Sul, no litoral central do estado de Sergipe, associado a Foz do rio Sergipe. Abrange parte dos municípios de Aracaju

(6,8 %) e Barra dos Coqueiros (8,7%), em um trecho de significativa importância da Região Metropolitana de Aracaju (RMA), correspondente a aproximadamente 32 km² de área e 6 km de extensão de faixa litorânea. A área compreende as Praias da Atalaia, Praia dos Artistas e Coroa do Meio localizadas no município de Aracaju (setor 1); trecho dos bairros 13 de julho, Jardins e Farolândia em Aracaju (setor 2) e as Praias do Porto, Praia da Costa no município de Barra dos Coqueiros (setor 3) (figura 8).

Figura 8 - Mapa de localização da área de estudo (em vermelho) na América do Sul (a), mais precisamente no litoral central do Estado de Sergipe (b), entre as cidades de Aracaju e Barra dos Coqueiros, nas adjacências da foz do Rio Sergipe(c).



Fonte: Elaborada pelos autores.

A região enquadra-se no tipo climático As', segundo a classificação de Köppen-Geiger (1928), classificado como tropical seco no verão, caracterizado por ser um clima úmido, quente com estação seca no verão (KOTTEK *et al.*, 2006). O período chuvoso é compreendido entre abril e agosto, concentrado nos meses de maio, junho e julho (CRUZ, 2009). O litoral em estudo tem a ocorrência de ventos

alísios que vêm do Atlântico e penetram no continente propiciando totais pluviométricos anuais mais elevados entre 1200 e 1600 mm diminuindo em direção ao interior c) e temperatura média anual entre 24°C e 26° C (JACOMINE; MONTENEGRO; RIBEIRO, 1975).

A geologia da área equivale aos depósitos das Formações Superficiais Cenozoicas que recobrem a Bacia Sedimentar Sergipe/ Alagoas (SANTOS; MARTINS; NEVES, 1998), formados pela variação da linha de costa, por processos de regressão e transgressão marinha (BITTENCOURT *et al.*, 1983). Ao longo desses depósitos são desenvolvidas as unidades geomorfológicas de idades holocênicas e pleistocênicas da Planície Costeira sob a forma de terraços marinhos, depósitos de mangues e depósitos eólicos, com altitudes máximas de 4 metros acima do nível do mar (BITTENCOURT *et al.*, 1983; DOMINGUEZ; BITTENCOURT; MARTIN, 1992).

Na área predomina o solo Espodossolos e em menor proporção são encontrados os Neossolos formados por areias quartzosas distróficas e Gleissolos constituído por areias quartzosas e solos indiscriminados de mangue (JACOMINE; MONTENEGRO; RIBEIRO, 1975; SERGIPE, 2015; SANTOS *et al.*, 2018). O terreno é drenado pelo rio Sergipe e seu afluente Poxim, na margem direita da foz do rio Sergipe, na porção Aracajuana da área (SERGIPE, 2015). A vazão média da desembocadura do rio Sergipe é de 13,84 m³/seg (SEMARH, 2010).

Os dados meteorológicos da região indicam que ventos de leste e sudeste dominam durante todo o ano. Ventos de SE ocorrem principalmente na estação chuvosa, enquanto que ventos de NE e E predominam no período seco (BARBOSA; DOMINGUES, 2004).

As praias são tipicamente dissipativas, resultante da combinação de maior exposição à energia das ondas (ausência de construções de recifes e *beachrock*) e predominância de areia fina (DOMINGUES, 2016). Na região Nordeste do Brasil, as ondas têm a direção predominante de E, SE e S e apresentam alturas que variam entre 1 a 3 m, a depender da estação do ano (PIANCA; MAZZINI; SIEGLE, 2010), gerando corrente longitudinal de sedimentos no sentido predominante de NE para SW (OLIVEIRA, 2003). As marés que afetam a área de estudo são do tipo mesomarés, semiduras, com maiores amplitudes nos meses de março, abril, agosto e setembro, em torno de 2 metros (DHN, 2021).

2.2.2 Materiais utilizados

2.2.2.1 Dados de satélite Landsat

Para o mapeamento da variação da linha de costa e classificação do uso e cobertura da terra foram utilizadas imagens dos anos de 1988, 1999, 2010 e 2019, adquiridas pelos sensores Thematic Mapper (TM) e Operational Land Imager (OLI) a bordo dos satélites Landsat 5 e 8, respectivamente (Tabela 11). As imagens foram obtidas nos dias 21 de dezembro de 1988, 04 de dezembro de 1999, 29 de setembro de 2010 e 04 de julho de 2019 (Figura 9 9).

Tabela 11- Descrição das bandas do satélite LANDSAT 5 e 8 usadas neste estudo. (TM = Thematic Mapper, OLI = Operational Land Imager, Res= resolução)

Satélite	Nº de Imagens	Bandas	Data	Orbita/ponto	Res. Espacial	λ
LANDSAT 5 TM	3	B1	21/12/88 04/12/99 29/09/10	215/68 215/67	30 m	0,45-0,52 μm
		B2			30 m	0,50-0,60 μm
		B3			30 m	0,63-0,69 μm
		B4			30 m	0,76-0,90 μm
LANDSAT 8 OLI	1	B2	04/07/19	215/67	30 m	0,45-0,51 μm
		B3			30 m	0,53-0,59 μm
		B4			30 m	0,64-0,67 μm
		B5			30 m	0,85-0,88 μm

Res. = resolução; λ = Comprimento de onda.

Fonte: Adaptada de USGS (2020a) e USGS (2020b).

As imagens foram obtidas por meio da plataforma GEE (GORELICK *et al.*, 2017) no nível de processamento 2A, georreferenciadas e com valores de reflectância de superfície (SR) (USGS, 2020a; USGS, 2020b). Foi definida uma porcentagem máxima de 10% em cobertura de nuvens como critério de seleção dos dados utilizados.

Figura 9- Linha de Costa do Litoral Central do Estado de Sergipe em composição colorida (R = banda do vermelho, G = banda do verde e B = banda do azul) das imagens Landsat utilizadas neste estudo. (a) 21 de dezembro de 1988 (Landsat 5), (b) 04 de dezembro de 1999 (Landsat 5), (c) 29 de setembro de 2010 (Landsat 5) e (d) 04 de julho de 2019 (Landsat 8), adquiridas no Google Earth Engine (GEE).



Fonte: GORELICK *et al.*, 2017

2.2.3 Métodos empregados

2.2.3.1 Mapeamento multitemporal da linha de costa

Para o mapeamento da variação temporal da linha de costa no *Digital Shoreline Analysis System* (DSAS) (HIMMELSTOSS *et al.*, 2018; THIELER *et al.*, 2009) foram realizadas as seguintes etapas: (1) Delimitação das linhas costeiras dos respectivos anos (1988 – linha azul, 1999- linha marrom clara, 2010 - linha rosa, 2019- linha azul clara), (2) criação de linha de base (linha preta), (3) geração automática dos transectos (linha marrom escura), e (4) cálculo estatístico das mudanças da linha costeira.


O indicador de linha de costa adotado neste trabalho foi o limite terra/água indicado na imagem de satélite pela variação na cor, e que indica a borda de água instantânea (STAFFORD; LANGFELDER, 1971; BOAK; TURNER, 2005).

A linha base (*baseline*) foi delineada na porção do continente (*onshore*) para as imagens das quatro datas, estando totalmente a oeste do conjunto de linhas de costa delimitadas. A base de dados foi gerada no Software ArcGis e posteriormente analisado com a ferramenta *Digital Shoreline Analysis System* (DSAS), desenvolvida pela United States Geological Survey em 1990 e desde então aprimorada. A ferramenta funciona como extensão no software ArcGIS, e tem como ponto de partida os transectos gerados pelo DSAS no cálculo da taxa de movimento e variação da linha de costa (THIELER *et al.*, 2009).

2.2.3.2 Estatística da variação da linha de costa

A taxa de variação da linha de costa ao longo dos três setores foi calculada em 423 transectos gerados perpendiculares à linha de costa com equidistância de 50 metros entre si e extensão de 650 metros (linhas marrons escuras na figura 10).

Figura 10- Mapa de linha de base, linha de costa e transectos para análise de mudanças na linha de costa ao longo da costa central de Sergipe. Em a) setor 1: Praias de Atalaia, Artistas e Coroa do Meio; Em B) setor 2: Trecho entre os bairros 13 de julho, Jardins e Farolândia; Em C) setor 3: Praia da Costa, Praia da Atalaia Nova e foz do Rio Sergipe e em D) a localização desses setores.



Fonte: Imagem do Google Earth de 2021.

Foram utilizadas quatro técnicas para análise estatística dos dados, taxa de regressão linear (*linear regression rate* - LRR), taxa de ponto de terminação (*end point*

rate - EPR), movimento líquido da linha de costa (*Net Shoreline Movement*- NSM) e envelope de variação da linha de costa (*shoreline change envelope* - SCE) (THIELER *et al.*, 2009) (Figura 11 e tabela 12).

Tabela 12 – Síntese das informações sobre estatísticas aplicadas para detectar a variação da linha de costa.

Estatística do DSAS	Descrição	Equação
NSM- Net Shoreline Movement (Movimento líquido da linha de costa)	Distância, em metros, entre as linhas costeiras mais antigas e mais novas para cada transecto.	-
SCE- Shoreline Change Envelope (Envelope de Variação da Linha de Costa)	Equivale a distância em metros, relativa a maior distância entre todas as linhas de costa que cruzam determinado transecto.	-
EPR- End Point Rate (Taxa de ponto de terminação)	$EPR = \frac{NSM (m)}{Tempo decorrido (anos)}$	1
Equação de regressão linear com a forma:		
LRR – Linear Regression Rate (Taxa de regressão linear)	$L = b + mx,$ Onde (L) representa a distância (m), da linha de base, (x) intervalo de datas costeiras (anos), (m) a inclinação da linha instalada (m/ano) (ou seja, representa a taxa de mudança costeira, LRR) e (b) é o y-intercept.	2

Fonte: Adaptada de Himmelstoss *et al.*, 2018.

A taxa de variação da linha de costa foi obtida pelos métodos EPR e LRR. A EPR expressa o movimento entre a linha de costa mais antiga e a mais recente ao longo do tempo decorrido (THIELER *et al.*, 2009). Já o método LRR, inclui os dados de todas as datas, gerando a linha de tendência para todos os pontos, equivalente a inclinação da reta da regressão (THIELER *et al.*, 2009). O NSM corresponde a distância, em metros, entre a linha de costa mais antiga e a mais recente para cada

transecto. O SCE indica a maior distância entre as linhas de costa mapeadas, independente do tempo (THIELER *et al.*, 2009).

Valores positivos de EPR, LRR e NMS indicam o deslocamento da linha de costa em direção ao mar, já valores negativos indicam o deslocamento em direção ao continente (THIELER *et al.*, 2009). As taxas de variação da posição da linha de costa nos respectivos anos, calculados para o litoral central do Estado de Sergipe foram distribuídas segundo as classes acrescida ($> +0,5$ m.ano⁻¹), estável ($+0,5$ a $-0,5$ m.ano⁻¹), erodida ($-0,5$ a -1 m.ano⁻¹), intensamente erodida (-1 a -3 m.ano⁻¹), erosão severa (-3 a -5 m.ano⁻¹) e erosão extrema (< -5 m.ano⁻¹) (LUIJENDIJK *et al.*, 2018) em cada transecto mapeada (Tabela 13).

Tabela 13- Taxa de variação e classificação do comportamento da linha costeira com base em taxa de ponto de terminação (end point rate) e taxa de regressão linear (linear regression rate)

Classes	Taxa de variação (m/ano ⁻¹)	Classificação
1	$>+0,5$	Acrescida
2	$>-0,5<0,5$	Estável
3	$>-1<-0,5$	Erodida
4	$>-3<-1$	Erosão intensa
5	$>-5<-3$	Erosão severa
6	<-5	Erosão Extrema

Fonte: LUIJENDIJK *et al.*, 2018.

2.2.4 Classificação de uso e ocupação da terra

Como suporte a análise da variação da linha de costa, a dinâmica de uso da terra da área de estudo entre os anos de 1988, 1999, 2010 e 2019 foi avaliada através de mapas de uso e cobertura da terra.

Os mapas de uso e cobertura da terra foram gerados por classificação supervisionada com o modelo de classificação não paramétrico) Máquina de Vetores de Suporte (MVS) (CORTES; VAPNIK, 1995), no software R (R CORE TEAM, 2018), com uso do código fornecido por Abdi (2019), a partir da execução do pacote caret (KUHN, 2008).

O classificador foi treinado com 70% das amostras e os 30% restantes foram utilizados no processo de validação. As classes geradas foram agrupadas em 6 principais para otimizar o cálculo de proporção de áreas e fidelizar o aspecto visual dos mapas. São elas: nomeadamente (1) área urbana, (2) corpos d'água, (3) faixa de praia, (4) vegetação, (5) pastagem e (6) Outras áreas não vegetadas. As classes ondas e praia molhada foram incorporadas em água e faixa de praia, respectivamente, já que só foram criadas a fim de capturar heterogeneidades dos pixels devido a dinâmica dos processos naturais atuantes. A adoção das classes foi baseada na heterogeneidade espacial da área de estudo, critérios estabelecidos em manuais técnicos de mapeamento de uso e cobertura da terra (IBGE, 2013), manual técnico da vegetação (IBGE, 2012), artigos, dissertações e teses que desenvolveram pesquisa na área de estudo.

A matriz de erro (CONGALTON, 1991; OLOFSSON *et al.*, 2014, FINEGOLD *et al.*, 2016) foi utilizada para validar a classificação do uso da terra. A validação foi estimada pelo valor de Acurácia global (AG) (OLOFSSON *et al.*, 2014) e índice *kappa* (LANDIS; KOCH, 1977). O detalhamento do cálculo para obter tais métricas pode visto nos trabalhos de Congalton (1991), Olofsson *et al.* (2014), Pontius e Millones (2011) e Landis e Koch(1977).

2.3 RESULTADOS E DISCUSSÃO

A tabela 14 apresenta as mudanças na linha de costa ocorridas entre o período de 1988 a 2019 (31 anos), baseadas nos parâmetros EPR e LRR em cada um dos setores analisados. O range de valores negativos a positivos indicam erosão (diminuição da área do continente) e acresção (aumento de área do continente), respectivamente.

Tabela 14- Range de valores de taxa de variação da linha de costa obtidos pelo método da taxa do ponto de terminação (EPR) e regressão linear (LRR) nos anos de 1988, 1999, 2010 e 2019 na área de estudo.

PRAIAS	Orla de Atalaia à Coroa do Meio	13 de julho	Barra dos Coqueiros
Número total de transectos	211	104	108
Range EPR (m.ano ⁻¹)	-8,89 - +8,73	-6,76 – +3,36	- 6,9 – +18,44
Média EPR (m.ano ⁻¹)	1,53	0,11	0,98
Número de transectos por EPR (erosão, acresção)	(85,121)	(29, 75)	(41,67)
Range LRR (m.ano ⁻¹)	-10,99 - +8,53	-8,62 – +2,8	-7,05 - 15,5
Média LRR (m.ano ⁻¹)	1,25	-0,76	0,36
Número de transectos por LRR (erosão, acresção)	(63,148)	(49, 55)	(48,60)
Comportamento (dominante)	Acresção	Acresção	Acresção


Fonte: Organizada pelos autores.

2.3.1 Setor da Orla de Atalaia e Coroa do Meio (Aracaju)

Entre as praias da Orla de Atalaia, praia dos Artistas e o bairro Coroa do Meio a taxa de variação da linha de costa, entre anos de 1988 e 2019 apresentou valores médios de 1,53 m.ano⁻¹ pelo método EPR, e 1,25 m.ano⁻¹ pelo método LRR (Tabela 14 14).

Considerando os resultados obtidos pelo método LRR no período em análise, a linha de costa exibe predominância de recuo nas proximidades da Coroa do Meio e predomínio de acúmulo na extensão da Praia de Atalaia (Figura 11). A máxima erosão foi identificada no transecto 125 (-10,99 m.ano⁻¹) localizada no pontal arenoso da Coroa do Meio, e o acúmulo máximo foi ao longo do transecto 3 (8,53 m.ano⁻¹) próximo aos arcos da Praia de Atalaia. Verifica-se que ao longo do setor predomina o comportamento de acresção (66.34%), embora também ocorra alguns segmentos em estabilidade e em erosão (erosão, intensa erosão e extrema erosão).


Figura 11-: Evolução da linha de costa entre 1988 e 2019 no setor 1 do estudo (Orla de Atalaia e Coroa do Meio). (a) classificação por MVS para o ano de 1988 e comportamento da linha de costa pelo método LRR; (b) taxa de variação mensurada pelos métodos EPR e LRR; (c) classificação por MVS para o ano de 2019 e comportamento da linha de costa pelo método LRR.



Fonte: Organizada pelos autores.

O envelope de variação da linha de costa apresentou variação máxima de 410,24 metros, localizado no pontal arenoso da Coroa do Meio. Esse foi o ponto de maior variabilidade (maior recuo e maior avanço) ao longo do trecho (A média do SCE (*shoreline change envelope*) ao longo do trecho foi de 98,94 metros (Tabela 15). Essa métrica representa a variação total da linha de costa, sem referência ao tempo.

Figura 12- a) Envelope de mudança da linha costeira (SCE), b) Movimento líquido da linha costeira (NSM) e c) taxa anual de mudança por ponto de terminação (EPR) nos 3 setores em estudo conforme a localização na figura d.



Fonte: Organização dos autores.

Tabela 15- Range de valores do envelope de variação da linha de costa ao longo dos trechos da (1) Orla de Atalaia e Coroa do Meio, (2) bairro 13 de julho e (3) entre as praias do Porto e Praia da Costa, entre os anos de 1988 e 2019

PRAIAS	Orla de Atalaia e Coroa do Meio (m)	13 de julho(m)	Barra dos Coqueiros (m)
Range do SCE (m.ano ⁻¹)	4,19 - 410,24	8,32 - 394,19	39,75 - 562,85
Média do SCE (m.ano ⁻¹)	98,94	117,24	133,34

Fonte: Organização dos autores.

A longo prazo, a costa do estado de Sergipe tem sido considerada em significativa progradação (DOMINGUEZ, 1996), motivada pelo aporte sedimentar do

Rio São Francisco e pelo abaixamento do nível do mar (DOMINGUEZ, 1996). Contudo, estudos mais recentes demonstram que a curto e médio prazo pode-se identificar setores com alternância entre acreção e erosão (SILVA, 2019a; JESUS; ANDRADE, 2018; RODRIGUES *et al.*, 2015; OLIVEIRA, 2003; BITTENCOURT; OLIVEIRA; DOMINGUEZ, 2006), sendo estes considerados de alta variabilidade (BITTENCOURT; OLIVEIRA; DOMINGUEZ, 2006).

A margem direita da foz do rio Sergipe é um exemplo de trecho de alta variabilidade (BITTENCOURT; OLIVEIRA; DOMINGUEZ, 2006), onde se encontra em erosão, mapeado nesta pesquisa como de extrema erosão. Possíveis causas desse comportamento estão relacionadas a dinâmica da foz do Rio Sergipe e o seu delta de maré vazante já relatado por Oliveira (2003), Bittencourt, Oliveira e Dominguez (2006), Rodrigues (2008) e Rodrigues *et al.* (2015).

A área da margem direita do rio Sergipe tem o histórico de ocorrência de eventos erosivos severos anteriores a 1990 (RODRIGUES *et al.*, 2015), entre 2007 e 2008 e entre 2012 e 2013 (JESUS; ANDRADE, 2018). Como resposta a esses eventos erosivos, foram realizadas obras de contenção na Praia dos Artistas, Bairro Coroa do meio e no lado oposto do rio, situado na praia da Atalaia Nova, município de barra dos Coqueiros, com instalação de estruturas em molhe e espigão (WANDERLEY, 2006). Esses eventos foram identificados em grande parte no mapeamento multitemporal desse estudo. Os eventos que não foram detectados tratam-se de intervalos de mais curto prazo que não foram identificados ou foram superpostos por tendências evolutivas dos anos posteriores.

Quando se trata do padrão progradacional (linha de costa em acreção ou acumulação), em médio prazo, entre os anos de 1988 e 2019, a Praia de Atalaia apresenta contínuo trecho com tendência de acreção, resultantes de avanços na linha de costa após erosão registrada na linha de costa de 2010. Esse fato ressalta a grande capacidade de recuperação das praias após evento de erosão severa demonstrada por Jesus e Andrade (2018); Silva (2019a) e Silva (2019b) quando apresentaram evidências de pós praia, escarpa inativa e praia larga com berma bem desenvolvida nos anos posteriores aos episódios de erosão entre a Praia dos Artistas e de Atalaia.


No arco praial da Orla de Atalaia, a jusante da foz do rio Sergipe, foi mapeado o acúmulo na linha de costa. Esse trecho foi classificado a longo prazo como linha de costa em equilíbrio por não sofrer grandes alterações (BITTENCOURT; OLIVEIRA; DOMINGUEZ, 2006, DINIZ *et al.*, 2020). Entretanto, a curto prazo, já foi identificada variação sazonal de erosão e reconstrução do prisma praial (BITTENCOURT; OLIVEIRA; DOMINGUEZ, 2006). Nesta pesquisa esse trecho é caracterizado predominantemente em acresção, apresentando desta forma, resultados que corroboram estudos já realizados por Silva (2019a); Jesus e Andrade (2018) e Rodrigues *et al.* (2015) que mostram valores de taxa de variação positiva e evidências de acúmulo no trecho em determinados períodos.

2.3.2 Setor do Bairro 13 de Julho (Aracaju)

Esse setor abrange o trecho as margens do canal abortado do rio Sergipe, localizado entre os bairros 13 de julho, Jardins, Inácio Barbosa e Farolândia, também conhecido como Maré de Apicum (SANTOS, 2012). O local apresenta taxa de variação média de $0,11 \text{ m.ano}^{-1}$ pelo método EPR e $-0,76 \text{ m.ano}^{-1}$ pelo método LRR.

Conforme o método LRR, o setor apresentou maior taxa de erosão na transecto 19 ($-8,62 \text{ m.ano}^{-1}$), defronte ao calçadão da Praia Formosa e ao Mirante da 13 de julho, e máximo acréscimo nas proximidades da Maré de Apicum, na transecto 98 ($2,8 \text{ m.ano}^{-1}$). Predomina no trecho o comportamento de acresção (52,88%), havendo também pontos de estabilidade e erosão (erosão, erosão intensa, erosão severa e erosão extrema) (Figura 13).

Figura 13- Evolução da linha de costa entre 1988 e 2019 no setor 2 do estudo (Bairro 13 de julho). (a) classificação por MVS para o ano de 1988 e comportamento da linha de costa pelo método LRR; (b) taxa de variação mensurada pelos métodos EPR e LRR; (c) classificação por MVS para o ano de 2019 e comportamento da linha de costa pelo método LRR.



Fonte: Organizada pelos autores.

Ao longo do intervalo de tempo analisado, as altas taxas de erosão são principalmente devido ao recuo identificado na direção do calçadão da Praia Formosa na imagem do ano de 2010. Esse recuo vem sendo justificada como resposta a erosão que ocorreu entre 2004 e 2014 no pontal arenoso da coroa do meio (SANTOS, 2012), reduzindo a área da planície de maré desprovida de mangue e aumentando a área colonizada por mangue na região adjacente ao calçadão da Praia Formosa. Isso se deve ao fato de que com a erosão do pontal arenoso da coroa do meio, a área defronte ficou desprotegida e passou a ser exposta a ação direta de agentes fluviomarinheiros e suscetíveis a erosão (SANTOS, 2012; SANTOS, 2014, SANTOS; SOUZA, 2016). Ao longo dos 31 anos analisados, houve um recuo estimado de 206,4 metros no trecho do Calçadão da Praia Formosa.


Na desembocadura do rio Poxim, adjacente a Maré de Apicum, foram detectadas altas taxas de recuo e acréscimo que ocorrem devido a variação da maré no ponto. Assim, nesse trecho a variação morfológica apresentada não retrata o comportamento de erosão e acreção da linha de costa, mas sim de áreas emersas e submersas devido a subida e descida da maré.

O setor 2 teve envelope de variação da linha de costa (SCE) médio de 117,24 m. A maior variação ocorreu ao longo do pontal arenoso da Coroa do Meio (394,19m), já os menores valores de SCE (<200 m) estão concentrados na extensão da Maré de Apicum (Figura 12 e tabela15)

2.3.3 Setor das praias da Atalaia Nova, Praia da Costa e margem esquerda da foz do rio Sergipe (Barra dos Coqueiros)

O trecho da Barra dos Coqueiros apresentou taxa de variação média de 0,98 m.ano⁻¹ pelo método EPR; 0,36 m.ano⁻¹ pelo método LRR. Conforme os valores mensurados por LRR, no trecho predomina o comportamento de acreção (55.56%), com valor máximo de acreção na transecto 54 (15,5 m.ano⁻¹) na praia da Atalaia Nova e valor máximo de erosão nas proximidades do transecto 23 (-7,05 m.ano⁻¹) localizado na margem esquerda do Rio Sergipe que fica na direção oposta ao pontal arenoso da Coroa do Meio e da Planície de Maré do Bairro 13 de julho (Figura 14).

Figura 14 - Evolução da linha de costa entre 1988 e 2019 no setor 3 do estudo (Barra dos Coqueiros). (a) classificação por MVS para o ano de 1988 e comportamento da linha de costa pelo método LRR; (b) taxa de variação mensurada pelos métodos EPR e LRR; (c) classificação por MVS para o ano de 2019 e comportamento da linha de costa pelo método LRR.



Fonte: Organizada pelos autores.

O setor 3 teve envelope de variação da linha de costa (SCE) médio de 133,34 m. A maior distância entre as linhas de costa mapeadas ocorreu no transecto 54 (562,85 m), ao longo da Praia de Atalaia Nova, já os menores valores de SCE (<200 m) estão concentrados na extensão da margem esquerda da foz do Rio Sergipe e na extensão da Praia da Costa, sendo estes os pontos de menor variação da linha de costa (Tabela 15). Os maiores valores de SCE (transecto 47 a 57) no setor, indicam que o trecho passou por episódios de erosão e acresção ao longo do tempo e apresentam alta variabilidade, devido à proximidade da desembocadura associada a dinâmica do delta de maré vazante, conforme relatado por Bittencourt, Oliveira e Dominguez (2006) (Figura 12).


A tendência progradacional identificada na área da Atalaia Nova, desde o transecto 51 até o transecto 108, já foi relatada em outros trabalhos, relacionada a instalação

do molhe para contenção a erosão na margem esquerda da foz do rio Sergipe (WANDERLEY, 2006; BITTENCOURT; OLIVEIRA; DOMINGUEZ, 2006; RODRIGUES, 2008; SANTANA, 2008; CEHOP, 2009; ALVES, 2010, LEITE; ALVES, 2017). Ocorrendo desta forma um crescimento artificial da praia de Atalaia motivada pela construção do molhe na Atalaia Nova e no Porto Inácio Barbosa (FONTES *et al.*, 2006).

Nota-se que, no geral, os valores de taxa de variação por ambos os métodos apresentam uma relação linear positiva com coeficiente de correlação mínimo de 0,679, no setor 2 do Bairro 13 de julho, intermediário no setor 1 da Praia de Atalaia e Coroa do Meio (0,9367) e máxima correlação no setor 3 do Município de Barra dos Coqueiros (0,9757) (Figura 15Figura 15).

A mais baixa correlação obtida a partir de dados do setor 2, é reflexo do acentuado recuo impresso na linha de costa do ano de 2010. Como o método EPR considera somente a linha de costa mais antiga e mais recente ao longo do tempo analisado, e o comportamento erosivo é atribuído principalmente a linha de costa de 2010 (intermediária), esse registro só foi capturado pelo método LRR, gerando maior dispersão entre os resultados nesse setor (Figura 15Figura 15)

Figura 15 - Correlação entre as taxas de variação da linha de costa obtidas por diferentes métodos (EPR, LRR) para as transectos do (a) setor 1 – Orla de Atalaia e Coroa do Meio, (b) Setor 2- Bairro 13 de Julho; e (c) setor 3 – Barra dos Coqueiros.



Fonte: Organização dos autores.

2.3.4 Mudanças de uso e cobertura da terra associados a variação da linha de costa na área de estudo:

Conforme o modelo de classificação gerado com uso do algoritmo Máquina de Vetor de Suporte (CORTES; VAPNIK, 1995), na composição RGB+NIR da Landsat 5 e 8 de 1988 a 2019, a área de estudo passou por um intenso processo de urbanização e como consequência ocorreu redução das classes vegetação e da classe outras áreas não vegetadas. A classe faixa de praia reduziu em função do aumento da área urbana e houve um sutil aumento da classe pastagem (Tabela 16). A acurácia geral (AG) da classificação e o índice *kappa*(K), variaram entre 0,89 e 0,99 (AG) e 0,87 e 0,99 respectivamente.

Tabela 16- Porcentagem de cobertura de área de diferentes classes de uso e cobertura da terra na área de estudo gerado por modelo de classificação supervisionado Máquina de Vetores de Suporte em dados de composição RGB-NIR de imagens LANDSAT 5 e 8.

Classes/ anos	Área urbana		Água		Faixa de Praia		Vegetação		Pastagem		Outras áreas não vegetadas		Total km²
	km²	%	km²	%	km²	%	km²	%	km²	%	km²	%	
1988	5,97	18,34	17,04	52,33	3,25	9,97	2,86	8,77	3,39	10,42	0,06	0,17	32,56
1999	7,64	23,45	16,18	49,67	2,12	6,5	2,71	8,32	3,62	11,11	0,31	0,95	32,57
2010	7,71	23,63	17,23	52,84	1,62	4,97	2,37	7,26	3,62	11,09	0,07	0,21	32,61
2019	8	24,52	17,26	52,91	1,81	5,53	2,08	6,38	3,38	10,35	0,1	0,31	32,63

Fonte: Organização dos autores.

O aumento da área urbana está relacionado a processos de urbanização, influenciados pela instalação de intervenções antrópicas (aprofundamento do canal, obras de contenção à erosão, urbanização) e por processos naturais (RODRIGUES, 2008, WANDERLEY, 2006). Esses processos causam erosão da linha de costa envolvendo trechos dos 3 setores em análise. Na região ocorreu a migração de bancos arenosos que originaram o pontal arenoso da Coroa do Meio e a migração lateral do talvegue do canal do rio Sergipe com deslocamento para SW (RODRIGUES, 2008).

Em pesquisa sobre as principais transformações ocorridas na paisagem costeira da Coroa do Meio e da Atalaia entre os anos de 1955 e 2008, Santos e Andrade (2013), concluíram que a expansão humana acompanhou as mudanças na configuração da linha de costa. Por consequência, quando a linha de costa avançou

a área urbana expandiu, já quando a linha recuou, sofreu episódios de erosão e a ocupação urbana foi prejudicada. Desta forma, ocorre o aumento da área urbana à medida que há um avanço da faixa de praia e o inverso com a diminuição do limite entre área antropizada e faixa de praia, conforme ocorrem episódios erosivos e recuo da linha de costa. Por isso é também de extrema relevância a adoção de faixas de proteção destinada a atenuar os impactos presentes e futuros do recuo da linha de costa (BRASIL, 2018)

Nesse sentido, a classificação por MVS mostra que a classe faixa de praia, que se refere as subclasses praia seca e praia molhada, apresentou redução de 4,5%. Esse percentual de redução pode ser atribuído a um erro da classificação por confusão de classes, na área da Praia Formosa que deveria ter sido classificado em 1988 como água e não praia molhada. Outro fator preponderante para a redução de área da classe em oposição ao caráter de ampliação da linha de costa é o exposto no parágrafo anterior, que diz respeito a acresção a faixa de praia concomitante ao desenvolvimento da urbanização, por consequência, redução em área da faixa de praia.

Além das alterações na faixa de praia, as intervenções antrópicas também atuaram sobre o desenvolvimento do manguezal dos bairros 13 de julho e Jardins. Neste caso, a presença de estruturas de contenção a erosão no Bairro Coroa do Meio, ocasiona o isolamento da área das margens do rio Sergipe, por ação das ondas, acarretando na colonização e posterior expansão do mangue (SANTOS, 2012; SANTOS, 2014; SANTOS; SOUZA, 2016). Esse fato fica evidente nas classificações geradas, onde a vegetação em torno do bairro 13 de julho passou a aumentar ao longo dos 31 anos (Figura 13Figura 13), contrariando, por este motivo o padrão que geralmente se procede de diminuição do manguezal devido ao aumento intervenções antrópicas (ICMBIO, 2018).

No setor da Barra dos Coqueiros as alterações na linha de costa defronte para o oceano e na margem esquerda da Foz do rio Sergipe, motivam a instalação de estrutura de contenção a erosão. Segundo Wanderley (2006), o molhe da Atalaia nova foi projetado na década de 1990 (LEITE; ALVES, 2017), e foi estendido no decorrer do tempo para conter os episódios erosivos (WANDERLEY, 2006). O trecho passou por intensificação de processo acrescia-a a jusante da construção do molhe, como

mostra a classificação do ano de 1999 e posteriormente, com o aumento da extensão do molhe para SE, essa praia fluvial passa a não mais existir (RODRIGUES, 2008).

2.4 CONSIDERAÇÕES FINAIS

Os resultados da análise da variação da linha de costa ao longo da área de estudo e período analisado, mostram que 59,52 % dos transectos foram submetidos a acresção com avanço máximo de 562,85 metros (transecto 54 – setor3), enquanto 40,48% foram sujeitos a erosão com recuo máximo de 271,35 metros (transecto 125 – setor 1). As maiores taxas de variação ocorreram no setor 3 (-7,05 a +15,5 m/ano⁻¹), enquanto o setor 2 teve variação intermediária (-8.62 a +2,8 m/ano⁻¹) e mais baixos valores ocorreram no trecho do setor 1 (-10,99 a 8,53 m/ano⁻¹).

A análise do envelope da variação da linha de costa durante os anos de 1988 a 2019, demonstrou valores médios de 98,94 m no trecho entre a Orla da Atalaia e Coroa do Meio, 117,24 m no trecho do bairro 13 de julho e 133.34 m no trecho localizado na Barra dos Coqueiros. O ponto de menor variação da linha de costa ocorreu na *transecto* 198, na Coroa do Meio, localidade Maré de Apicum (4,19 m). Já o ponto de maior variação espacial da linha de costa ocorreu na *transecto* 54 com valor de 562,85 metros na Praia da Atalaia Nova na Barra dos Coqueiros. Sua alta variabilidade está associada à sua posição, na foz do rio Sergipe, sendo influenciado pela dinâmica de maré vazante e pelo deslocamento do canal fluvial ao longo do tempo.

Os resultados apresentados indicam maiores variabilidade da linha de costa na margem esquerda do rio Sergipe. Os resultados também mostram que os agentes antrópicos instalados na área exercem forte influência nas alterações, quando somado ao dinamismo natural típico de área de estuário.

O modelo de classificação de uso e ocupação da terra ao longo dos 31 anos, gerado por Máquina de Vetores de Suporte, mostra que a área de estudo passou por um intenso processo de urbanização e isso ocasionou a redução da classe faixa de praia (4,5%). A acurácia geral (AG) da classificação e o índice kappa (K) desta classificação variaram entre 0,89 a 0,99 (AG) e 0,87 a 0,99 respectivamente, considerados bons.

Portanto, os resultados apresentam a dinâmica da área costeira ao longo de 3 décadas e permitem identificar o comportamento predominante de acreção, quando considerada toda a faixa temporal em análise. Ressalta-se a relevância dessa pesquisa como uma primeira contribuição sobre a variação da linha de costa abrangendo região influenciada pela dinâmica da foz do rio Sergipe ao longo de 3 décadas (1988 a 2019); o entendimento dos resultados quando analisados juntos a classificação de uso e ocupação da terra e por fim, a aplicabilidade da ferramenta como subsídio ao planejamento de áreas costeiras, especialmente na área do estudo, a qual está em constante alteração.

2.5 AGRADECIMENTOS

A Universidade federal de Sergipe (UFS), ao Programa de Pós-Graduação em Recursos Hídricos (PRORH-UFS), ao Laboratório de Sensoriamento Remoto e Geoprocessamento (SERGEO) por disponibilizar a licença do Programa ArcGis 10.5, ao grupo de Sensoriamento Remoto “OFE” pelo conhecimento adquirido ao longo da execução do trabalho e a Coordenação de Aperfeiçoamento de Pessoal (CAPES) pela concessão da bolsa de estudo da primeira autora.

2.6. REFERÊNCIAS BIBLIOGRÁFICAS

ABDI, A. M. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. **GIScience & Remote Sensing**, v. 57, n. 1, p. 1-20, Aug. 2019. DOI: 10.1080 / 15481603.2019.165044.

ALBUQUERQUE, M., ESPINOZA, J., TEIXEIRA, P., DE OLIVEIRA, A., CORRÊA, I., & CALLIARI, L. Erosion or coastal variability: An evaluation of the DSAS and the change polygon methods for the determination of erosive processes on sandy beaches. **Journal of Coastal Research**, v. 65, n. 2, p. 1710-1714. Jan. 2013. DOI: <https://doi.org/10.2112/SI65-289.1>.

ALESHEIKH, A.A.; GHORBANALI, A.; NOURI, N. Coastline change detection using remote sensing. *Int. J. Environ. Sci. Technol*, v. 4, p. 61–66, 2007.

ALMEIDA, L.P., DE OLIVEIRA, I.E., LYRA, R., DAZZI, R.L.S., MARTINS, V.G., DA FONTOURA KLEIN, A.H., 2021. Coastal analyst system from space imagery engine (CASSIE): shoreline management module. **Environ. Model. Software**, v.140, 105033, 2021. DOI: <https://doi.org/10.1016/j.envsoft.2021.105033>.

ALVES, N. M. S. **Análise geoambiental e socioeconômica dos municípios costeiros do litoral norte do estado de Sergipe – Diagnóstico como subsídio ao ordenamento e gestão do território**. 2010. 348 f. Tese (Doutorado em Geografia) – Núcleo de Pós-Graduação em Geografia, Pró-Reitoria de Pós-Graduação e Pesquisa, Universidade Federal de Sergipe, São Cristóvão.

AMARO, V.E.; GOMES, L.R.S.; LIMA, F.G.F; SCUDELARI, A.C.; NEVES, C.F.; BUSMAN, D.V.; SANTOS, A.L.S. Multitemporal Analysis of Coastal Erosion Based on Multisource Satellite Images, Ponta Negra Beach, Natal City, Northeastern Brazil. **Marine Geodesy** [Published online: 19 Jun 2014]. DOI: 10.1080/01490419.2014.904257.

BARBOSA, L. M.; DOMINGUEZ, J. M. L. Coastal Dune Fields at the São Francisco River Strandplain, Northeastern Brazil: morphology and environmental controls. **Earth Surface Processes and Landforms**, v. 29, p. 443-456., 2004.

BITTENCOURT, A.; OLIVEIRA, M. B. de; DOMINGUEZ, J. M. L. Erosão e Progradação do Litoral Brasileiro-Sergipe. In: Dieter Muehe. (Org.). **Erosão e Progradação do Litoral Brasileiro**. 2ed.Brasília: Ministério do Meio Ambiente, 2006, v.1, p. 213-218.

BITTENCOURT, A.C.S.P.; MARTIN, L.; DOMINGUEZ, J.M.L.; FERREIRA, Y. de A. Evolução paleogeográfica quaternária da costa do estado de Sergipe e da costa sul do estado de Alagoas. **Revista Brasileira de Geociências**, v.13, p. 93-97. 1983.

BOAK, E.H., TURNER, I.L., Shoreline definition and detection: A review. **Journal of Coastal Research**, v. 21, n.4, p. 688–703. 2005.

BRASIL. **Constituição da República Federativa do Brasil**, de 05.10.1988. Brasília, 1988. Disponível em: <http://www.planalto.gov.br/ccivil_03/constituicao.htm>. Acesso em: 3 ago. 2021.

BRASIL. Decreto No 5.300, de 07 de dezembro de 2004. Regulamenta a Lei No 7.661, de 16 de maio de 1988, que institui o Plano Nacional de Gerenciamento Costeiro PNGC, dispõe sobre regras de uso e ocupação da zona costeira e estabelece critérios de gestão da orla marítima, e dá outras providências. Brasília, DF: **Diário Oficial da**

União (DOU), 08/12/2004. Disponível em: http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2004/Decreto/D5300.htm. Acesso em: 3 ago. 2021.

BRASIL. Grupo de Integração do Gerenciamento Costeiro – GI-GERCO/CIRM. **Guia de Diretrizes de Prevenção e Proteção à Erosão Costeira** – Brasília/DF, 2018. Disponível em: http://www.mma.gov.br/images/arquivo/80342/Final_Guia_de_Diretrizes_09112018.df2018. Acesso em: 3 ago. 2021.

BREIMAN, L. Random Forests. **Machine Learning** 45, 5–32. 2001.DOI: <https://doi.org/10.1023/A:1010933404324>.

CARVALHO, B.C., DALBOSCO, A.L.P., GUERRA, J.V., Shoreline position change and the relationship to annual and interannual meteo-oceanographic conditions in Southeastern Brazil. **Estuar. Coast. Shelf Sci.** 235, 106582. 2020. Disponível em: <https://doi.org/10.1016/j.ecss.2020.106582>. Acessado em: 10 de setembro de 2021.

CEHOP. Companhia Estadual de Habitação e Obras Públicas; Terra Viva Consultoria em Meio Ambiente e Geologia. **RIMA –Relatório de Impacto Ambiental**. Projeto de Urbanização da Orla de Atalaia Nova trechos V, VI, VII e VIII. Aracaju, 2009.

COASTAL ANALYSIS VIA SATELLITE IMAGERY ENGINE – CASSIE. **Uma ferramenta para análise costeira via mecanismo de imagens de satélite**. 2020. Disponível em: <https://cassie-stable.herokuapp.com/> Acesso em: 17/02/2020.

CONGALTON, RUSSELL G., A review of assessing the accuracy of classifications of remotely sensed data, **Remote Sensing of Environment**, v. 37, n.1, 1991, p. 35-46, ISSN 0034-4257, DOI: [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).

CORREIA, I. O. **Faixas de proteção à erosão costeira no delta do Rio São Francisco**. 50 f. Dissertação (Mestrado em Geociências e Análise de Bacias) - Universidade Federal de Sergipe, São Cristóvão, SE, 2020.

CORTES, C; VAPNIK, V. Support vector machine. **Mach. Learn.** 20, 273–297. **1995**.

CRUZ, M.A.S. Regionalização de precipitação médias e prováveis mensais e anuais no estado de Sergipe. **Boletim de Pesquisa**. EMBRAPA, 2009.

DAVIDSON-ARNOTT, R., 2010. Introduction to Coastal Processes and Geomorphology. Cambridge University Press.

DINIZ, M.T.M.; SILVA, D.S.; SANTOS, J.R.; SOUZA, R.M., AND SILVA, J.P. Variation of the coastline between the years of 1984 and 2017 in the State of Sergipe, Northeast Region, Brazil. In: Malvárez, G. and Navas, F. (eds.), *Global Coastal Issues of 2020. Journal of Coastal Research*, Special Issue n. 95, p. 458–462. Coconut Creek (Florida), ISSN 0749-0208.

Diretoria de Hidrografia e Navegação - DHN. **TÁBUAS DE MARÉ**. Marinha do Brasil. Disponível em: <http://www.mar.mil.br>. Acesso em: 25/08/2021.

DOLAN, R., HAYDEN, B. AND HEYWOOD, J. A New Photogrammetric Method for Determining Shoreline Erosion. **Coastal Engineering**, 2, 21-39. 1978. DOI: [https://doi.org/10.1016/0378-3839\(78\)90003-0](https://doi.org/10.1016/0378-3839(78)90003-0).

DOMINGUEZ, J.M.L, BITTENCOURT A.C.S.P., MARTIN L. Controls on Quaternary coastal evolution of the east-northeastern coast of Brazil: roles of sea-level history, trade winds and climate. **Sedimentary Geology**, 80:213-232. 1992.

DOMINGUEZ, J.M.L, BITTENCOURT A.C.S.P., NASCIMENTO A.S., NASCIMENTO L. The sandy beaches of the states of Sergipe and Alagoas. In: Short AD, Klein AHF (eds) Brazilian beach systems, **Coastal research library**. Springer, Dordrecht, pp 281- 305. 2006.

DOMINGUEZ, J.M.L., The São Francisco strandplain: a paradigm for wave-dominated deltas? In: DE BAPTIST, M. and JACOBS, P. (eds.), **Geology of Siliciclastic Shelf Seas**. London: Geological Society of London Special Publication 117, pp. 217–231. 1996.

DOMINICI D., ZOLLINI S. Remote Sensing in Coastline Detection. **Journal of Marine Science and Engineering**. 2020, v. 8, n.7, p.498. DOI: <https://doi.org/10.3390/jmse8070498>.

FERREIRA, T. A. B.; SILVA, A.G. A. DA; PEREZ, Y. A. R.; STATTEGGER, K.; VITAL H. 2021. Evaluation of decadal shoreline changes along the Parnaíba Delta (NE Brazil) using satellite images and statistical methods. **Ocean & Coastal Management**. Volume 202, 2021. DOI: <https://doi.org/10.1016/j.ocecoaman.2020.105513>.

FINEGOLD, Y., ORTMANN, A., LINDQUIST, E., D'ANNUNZIO, R., & SANDKER, M., **Map Accuracy Assessment and Area Estimation: A Practical Guide**. Rome: Food and Agriculture Organization of the United Nations. 2016.

FONTES, A.L.; SANTOS, M. A.; LIMA, E. S.; CORREIA, A.L.F. Caracterização sedimentar e morfodinâmica do litoral norte do Estado de Sergipe - contribuição ao ordenamento territorial. Resumo expandido. **VI Simpósio Nacional de Geomorfologia**. Goiânia. 10p., 2006.

GENS, R. Remote sensing of coastlines: detection, extraction and monitoring. **International Journal of Remote Sensing**, v. 31, p. 1819 - 1836. 2010. GORELICK, N; HANCHER, M; DIXON, M; ILYUSHCHENKO, S; THAU, D; MOORE, R. Google earth engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, n. 1, v. 202. p. 18-27, 2017. DOI: 10.1016/j.rse.2017.06.031.

HIMMELSTOSS, E.A., HENDERSON, R.E., KRATZMANN, M.G., AND FARRIS, A.S., Digital Shoreline Analysis System (DSAS) version 5.0 user guide: U.S. **Geological Survey Open-File Report**, p. 2018–1179, 110 p., 2018. DOI: <https://doi.org/10.3133/ofr20181179>.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Manual técnico da vegetação brasileira: sistema fitogeográfico: inventário das formações florestais e campestres: técnicas e manejo de coleções botânicas: procedimentos para mapeamentos**. 2. Ed. Ver. E ampl. Rio de Janeiro, 2012. 267 p. (Manuais técnicos em geociências, n. 1). Disponível em: <biblioteca.ibge.gov.br/visualizacao/livros/liv63011.pdf>. Acesso em: 25 jan. 2021. IBGE – Instituto Brasileiro de Geografia e Estatística. **Manual Técnico de Uso da Terra**. Número 7. 3ª Edição. Rio de Janeiro: IBGE. 2013. 178p.

IBGE- Instituto Brasileiro de Geografia e Estatística. **Censo Brasileiro de 2010**. Rio de Janeiro: IBGE, 2010. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. ICMBio. Instituto Chico Mendes de Conservação da Biodiversidade. **Atlas dos manguezais do Brasil**. Brasília: Instituto Chico Mendes de Conservação da Biodiversidade, 2018. 2018 p.179. Disponível em: https://www.icmbio.gov.br/portal/images/stories/manguezais/atlas_dos_manguezais_d_brasil.pdf. Acesso em: 20 de jan. de 2021.

JACOMINE, P.K.T.; MONTENEGRO, J.O.; RIBEIRO, M.R. **Levantamento exploratório-reconhecimento de solos do Estado de Sergipe** Recife: EMBRAPA; CPP; SUDENE; DRN; MA; CONTAP; USAID; ETA, 1975. 506p.

JESUS, L.V. **Dinâmica das praias (Artista e Atalaia) e da linha de costa contígua a desembocadura do rio Sergipe, Aracaju, Sergipe**. Dissertação (Mestrado em Geociências). Programa de Pós-Graduação em Geociências e Análises de Bacias, Universidade Federal de Sergipe, São Cristóvão. 2016. 98p.

JESUS, L.V; ANDRADE, A.C.S. Taxas de variação da linha de costa e faixas de proteção nas áreas contíguas à desembocadura do rio Sergipe, Aracaju, Sergipe. **Pesquisa em Geociências**, v. 45, p. 1-17, 2018. DOI: 10.22456/1807-9806.91389.

KERMANI S., BOUTIBA M., GUENDOUZ M., GUETTOUCHE M. S, KHELFANI D. Detection and analysis of shoreline changes using geospatial tools and automatic computation: Case of Jijelian sandy coast (East Algeria). **Ocean & Coastal Management**, 132:46-58. 2016.

KOTTEK M., GRIESER J., BECK C., RUDOLF B., RUBEL F., World Map of the Köppen-Geiger climate classification updated. *Meteorologische Zeitschrift.*, 15, 259-263. 2006. DOI: 10.1127/0941-2948/2006/0130.

KUHN, MAX. Building Predictive Models in R Using the caret Package. *Journal of Statistical Software, Foundation for Open Access Statistics*, vol. 28(i05). 2008.
KUHN, MAX. Caret: Classification and Regression Training. R package version 6.0-86. 2020. <https://CRAN.R-project.org/package=caret>.

LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data. Washington, USA. *Biometrics*, v. 33, n. 1, p. 159-1174, 1977.

LEITE L.S, ALVES N.M DE SOUZA. Dinâmica da planície costeira nos limites da praia de atalaia nova, Barra dos Coqueiros/SE. **Os Desafios da Geografia Física na Fronteira do Conhecimento** v. 1 (2017): EBOOK, 2017.

LIU, CHUN; XIAO, YINGYING; YANG, JIAN. A coastline detection method in polarimetric SAR images mixing the region-based and edge-based active contour models. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 7, p. 3735-3747, 2017.

LUIJENDIJK, A.; HAGENAARS, G.; RANASINGHE, R.; BAART, F; GENNADII, D; ARNINKHOF, S. The State of the World's Beaches. *Scientific Reports*, v. 8, n. 1, p. 6641, 2018. Nature Publishing Group.

MIRANDA I.M., TOLDO E.E.J.R., KLEIN A.H.F., VIEIRA DA SILVA G. Shoreline evolution of lagoon sandy spits and adjacent beaches, Lagoa dos Patos, Brazil. **J Coast Res**, v.35, n.5, p.1010–1023 Coconut Creek (Florida), 2020. ISSN 0749-0208. MMA/SQA; MP/SQU. Projeto Orla: Subsídios para um Projeto de Gestão. Ministério do Meio Ambiente e Ministério do Planejamento, Orçamento e Gestão. Brasília, DF, 2004.

MOORE, L.J. Shoreline mapping techniques. **Journal of Coastal Research**, 16(1): 111-114. 2000.

MUEHE, Dieter. Panorama da Erosão Costeira no Brasil. Brasília: **Ministério do Meio Ambiente (MMA)**, 2018.

Nassar, K., Mahmod, W. E., Fath, H., Masria, A., Nadaoka, K., & Negm, A. Shoreline change detection using DSAS technique: Case of North Sinai coast, Egypt. **Mar. Georesour. Geotech.** p. 1-15, 2018.

OLIVEIRA, M. B. **Caracterização da linha de costa do Estado de Sergipe – Brasil**. Curso de Pós-Graduação em Geologia, Dissertação de Mestrado, IGeo/UFBA, 2003. 102p.

OLOFSSON, P.; FOODY, G.M.; HEROLD, M.; STEHMAN, S.V.; WOODCOCK, C.E.; WULDER, M.A. Good practices for estimating area and assessing accuracy of land change. *Remote Sens. Environ.* 2014, 148, 42–57.

OYEDOTUN, T.D.T. Shoreline geometry: DSAS as a tool for historical trend analysis. **Geomorphological Techniques-British Society for Geomorphology**, v. 2, p. 3-12, 2014.

PHILIP, N.Q.; KWASI, A.A.; KUFOGBE, S.K. Medium resolution satellite images as a tool for monitoring shoreline change: A case study of the Eastern coast of Ghana. *J. Coast. Res.* 2013, 65, 511–520.

PIANCA, C.; MAZZINI, P.L.; SIEGLE, E. Brazilian offshore wave climate based on NWW3 reanalysis. **Journal of Oceanography**, 2010, 58(1): 53-70.

PONTIUS, R. G.; MILLONES, M. Death to kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, p. 4407–4429. 2011.

R CORE TEAM. **R: A language and environment for statistical computing. R Foundation for Statistical Computing**, Vienna, Austria. 2018. Available online at <https://www.R-project.org/>.

RODRIGUES, T. K. **Análise das mudanças da linha de costa das principais desembocaduras do estado de Sergipe, com ênfase no rio Sergipe**. 2008. 91 f. Dissertação (Mestrado em Geologia) –Curso de Pós-Graduação em Geologia, Instituto de Geociências, Universidade Federal da Bahia, Salvador.

RODRIGUES, T.K., JESUS L.V., SILVA, M.G., PEREIRA, D.A.S., FEITOSA, E.S.S., ANDRADE, A.C.S., DOMINGUEZ, J.M.L. & LAVENERE-WANDERLEY, A.A.O. 2015. Deltas de Maré Vazante e Erosão Costeira na Atalaia Velha e no Mosqueiro, Aracaju (SE) no período de 1965 a 2008. **Scientia Plena**, 11: 1-7.

SANTANA, L. B. de. **Análise Geoambiental dos municípios costeiros de Barra dos Coqueiros e Pirambu (SE)**. 2008. 111 f. Dissertação (Mestrado em Geografia) – Núcleo de Pós-Graduação em Geografia, Pró-Reitoria de Pós-Graduação e Pesquisa, Universidade Federal de Sergipe, São Cristóvão.

SANTOS G. C. Derivações antropogênicas e Evolução do manguezal nos bairros 13 de julho e Jardins em Aracaju-SE. **Revista Brasileira de Geografia Física** 7(2):278-290. 2014.

SANTOS, G C dos; ANDRADE, A. C. S. EXPANSÃO DA OCUPAÇÃO HUMANA E EVOLUÇÃO DA LINHA DE COSTA NA COROA DO MEIO E ATALAIA/ARACAJU-SE. **Revista GeoNordeste**, n. 3, 2013.

SANTOS, G. C. D.; SOUZA, R. M. E. Morfodinâmica do pontal arenoso e interferências na evolução da planície de maré na desembocadura do rio Sergipe – Aracaju/SE. **Revista Brasileira de Geomorfologia**, v.17, n.4. 2016.

SANTOS, G. C. **Dinâmica da paisagem costeira da Coroa do Meio e Atalaia – Aracaju/SE**. 2012. 152f. Dissertação (Mestrado em Geografia) – Universidade Federal de Sergipe, São Cristóvão, SE, 2012.

SANTOS, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.C.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; ALMEIDA, J.A.; CUNHA, T.J.F.; OLIVEIRA, J. B. **Sistema Brasileiro de Classificação de Solos**. 5. ed. rev. e ampl. Brasília, DF: Embrapa, p. 590, 2018.

SANTOS, J. P. da S. **LINHA DE COSTA E FAIXA DE PROTEÇÃO À EROÇÃO COSTEIRA: ESTUDO DE CASO NAS PRAIAS DO SACO, DO ABAÍS E DA CAUEIRA, SUL DE SERGIPE.** 2019. 61 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Geociências e Análise de Bacias, Universidade Federal de Sergipe, São Cristóvão, 2019.

SANTOS, J. P. DA S., ANDRADE, A. C. DA S., NASCIMENTO, P. S. DE R.; RAMOS, L. P. EROÇÃO COSTEIRA E FAIXAS DE RECUO EM PRAIAS ARENOSAS DO SUL DE SERGIPE, BRASIL. **Geosciences= Geociências**, v. 40, n. 04, p. 1047-1061, 2021.

SANTOS, R.A., MARTINS, A.A.M., NEVES, J.P. **Geologia e recursos minerais do estado de Sergipe.** Brazil, Brazilian Geological Survey (CPRM), Salvador. 1998.

SERGIPE. Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos. **Atlas digital sobre recursos hídricos.** Aracaju: SEMARH, 2015.

SILVA, D.S. **Indicadores das oscilações da linha de costa nas praias de Aracaju-SE entre os anos 2013-2018 e sua relação com as Derivações antrópogênicas.** 2019a. 108 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação e pesquisa programa de pós-graduação em desenvolvimento e meio ambiente nível mestrado, São Cristóvão.

SILVA, V. R. C. DA. **Comportamento da linha de costa nas praias do Mosqueiro, dos Naufragos e da Atalaia, município de Aracaju, Sergipe. São Cristóvão, SE,** 2019b. Monografia (graduação em Geologia) – Curso de Geologia, Departamento de Geologia, Centro de Ciências Exatas e Tecnologia, Universidade Federal de Sergipe, São Cristóvão.

SMITH, G.; ZARILLO, G. 1990. Calculating long-term shoreline recession rates using aerial photographic and beach profiling techniques. **Journal of Coastal Research**, v. 6, n.1, p. 111-120, 1990.

SOUZA, C.R. de G. A Erosão Costeira e os Desafios da Gestão Costeira no Brasil. **Revista da Gestão Costeira Integrada**, v.9, n.1, p.17-37, 2009. Acessado em 2020 .

STAFFORD, D.B. and LANGFELDER, J., Air photo survey of coastal erosion. **Photogrammetric Engineering**, v. 37, p. 565-575, 1971.

THIELER, E. R; HIMMELSTOSS, E.A; ZICHICHI, J.L; ERGUL, A. **The Digital Shoreline Analysis System (DSAS) version 4.0 – An ArcGIS extension for calculating shoreline change**. US Geological Survey Report nº 2008-1278, 79p. 2009.

THIELER, E.R.; DANFORTH, W.W., Historical shoreline mapping (II): Applications of the Digital Shoreline Mapping and Analysis Systems (DSMS/DSAS) to shoreline change mapping in Puerto Rico. **Journal of Coastal Research**, v.10, n. 3, p. 600-620, 1994.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 4-5 TM collection 2 level 2 data format control book - Version 4.0**. September 2020a. Disponível em: https://d9-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/s3fs-public/atoms/files/LSDS-1336_Landsat4-5-TM-C2-L2-DFCB-v4.pdf. Acesso em: 11 nov. 2021.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 8-9 Operational Land Imager (OLI) - Thermal Infrared Sensor (TIRS) Collection 2 Level 2 (L2) Data Format Control Book (DFCB) - Version 6.0**. September 2020b. Disponível em: https://d9-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/s3fs-public/atoms/files/LSDS-1328_Landsat8-9-OLI-TIRS-C2-L2-DFCB-v6.pdf. Acesso em: 11 nov. 2021.

VOS, K., SPLINTER, K. D., HARLEY, M. D., SIMMONS, J. A., & TURNER, I. L. CoastSat: A google earth engine-enabled python toolkit to extract shorelines from publicly available satellite imagery. **Environmental Modelling & Software**. v. 122, p.1–7. 2019. DOI: <https://doi.org/10.1016/j.envsoft.2019.104528>.

WANDERLEY, L.L. Paisagem da janela: Esse nosso Inconstante Rio Sergipe e a Evolução de sua Foz. In: Alves J.P.H. (ed.) **Rio Sergipe: importância, vulnerabilidade e preservação**. São Cristóvão: Editora UFS, 2006, p.: 165-194.
YADAV, Arunkumar; DODAMANI, Basavanand M.; DWARAKISH, G. S. Shoreline analysis using Landsat-8 satellite image. **ISH Journal of Hydraulic Engineering**, v. 27, n. 3, p. 347-355, 2018.

ZOLLINI, S.; ALICANDRO, M.; CUEVAS-GONZÁLEZ, M.; BAIOCCHI, V.; DOMINICI, D.; BUSCEMA, P.M. Shoreline Extraction Based on an Active Connection Matrix (ACM) Image Enhancement Strategy. **J. Mar. Sci. Eng.** 2020, 8, 9. <https://doi.org/10.3390/jmse8010009>.


APÊNDICE A- TABELA SÍNTESE DOS RESULTADOS SOBRE A DETECÇÃO AUTOMÁTICA DA VARIAÇÃO DA LINHA DE COSTA, OBTIDOS PARA A ÁREA DE ESTUDO ENTRE OS ANOS DE 1988 E 2019

PRAIAS	Orla de Atalaia e Coroa do Meio (m)	13 de julho(m)	Barra dos Coqueiros (m)
Número de transectos(total)	211	104	108
Média			
EPR (m.ano ⁻¹)	1.53	0.11	0.98
LRR (m.ano ⁻¹)	1.25	-0.76	0.36
Máximo			
EPR(m.ano ⁻¹)	8.73	3.36	18.44
LRR (m.ano ⁻¹)	8.53	2.8	15.5
Mínimo			
EPR(m.ano ⁻¹)	-8.89	-6.76	-6.9
LRR(m.ano ⁻¹)	-10.99	-8.62	-7.05
Total de transectos com registro de erosão			
EPR	85	29	41
LRR	63	49	48
Total de transects com registro de acreção			
EPR	121	75	67
LRR	148	55	60
Registro de erosão nas transects (%)			
EPR	41.26%	27.88%	37.96%
LRR	29.86%	47.12%	44.44%
Registro de acreção nas transects (%)			
EPR	58.74%	72.12%	62.04%
LRR	70.14%	52.88%	55.56%
Range do SCE (m.ano ⁻¹)	3,18-376,93	9,43-445,06	9,88-556,14
Média do SCE (m.ano ⁻¹)	112,49	107,8	122,2

Fonte: Organização dos autores.


Fonte: Organização dos autores.

APÊNDICE C- VISÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 1999




Fonte: Organização dos autores.

APÊNDICE D- VISÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 2010



Fonte: Organização dos autores.

APÊNDICE E- VISÃO GERAL DAS AMOSTRAS SELECIONADAS PARA CLASSIFICAÇÃO SUPERVISIONADA E MODELOS DE CLASSIFICAÇÃO GERADOS COM DIFERENTES CLASSIFICADORES E CONJUNTOS DE DADOS DO ANO DE 2019



Fonte: Organização dos autores.

APÊNDICE F- MATRIZ DE ERRO DA CLASSIFICAÇÃO PELOS ALGORITMOS FLORESTA ALEATÓRIA, MÁQUINA DE VETORES DE SUPORTE E REDES NEURAIS ARTIFICIAIS COM OS DADOS DA COMPOSIÇÃO COLORIDA.

RF- 1988

ConfusiMatrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	20	0	0	0	1	1	0	22	90.909	9.0909	
I	2	0	30	0	0	0	0	0	30	100	0	
A	3	0	0	20	0	0	0	0	20	100.000	0.000	
S	4	0	0	0	20	0	0	0	20	100	0	
I	5	0	0	0	0	13	0	0	13	100	0	
F	6	0	0	0	0	2	0	0	2	100	0	
C	7	0	0	0	0	0	18	0	18	100	0	
A	8	0	0	0	0	0	0	12	12	100	0	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	100	100	100	100	92.9	66.7	100	100			EQ(%) 2,000
e	EO(%)	0	0	0	0	7.14	33.3	0	0			EA(%) -0,540

MVS- 1988

Confusion Matrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	16	0	0	0	1	1	0	18	88.8889	11.111	
I	2	0	30	0	0	0	0	0	30	100	0	
A	3	3	0	20	0	0	2	0	25	80.000	20.000	
S	4	0	0	0	20	1	0	0	21	95.2381	4.7619	
I	5	1	0	0	0	12	0	0	13	92.30769	7.6923	
F	6	0	0	0	0	0	0	0	0	#DIV/0!	#DIV/0!	
C	7	0	0	0	0	0	18	0	18	100	0	
A	8	0	0	0	0	0	0	12	12	100	0	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	80	100	100	100	86	0	100	100			EQ(%) 6,000
e	EO(%)	20	0	0	0	14	100	0	0			EA(%) 0,569

RNA-1988

Confusion Matrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	18	0	1	0	1	2	0	23	78.261	21.739	
I	2	0	30	0	0	0	0	0	30	96.774	3.2258	
A	3	2	0	19	0	0	1	0	22	86.364	13.636	
S	4	0	0	0	20	8	0	0	28	71.429	28.571	
I	5	0	0	0	0	5	0	0	5	100	0	
F	6	0	0	0	0	0	0	0	0	#DIV/0!	#DIV/0!	
C	7	0	0	0	0	0	18	0	18	100	0	
A	8	0	0	0	0	0	0	10	10	100	0	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	90	100	95	100	35.7	0	100	83.3			EQ(%) 14,000
e	EO(%)	10	0	5	0	64.3	100	0	16.7			EA(%) -1,591

RF- 1999

ConfusiMatrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	20	0	0	0	1	0	0	21	95.238	4.7619	
I	2	0	30	0	0	0	0	0	30	100	0	
A	3	0	0	20	0	0	0	0	20	100.000	0.000	
S	4	0	0	0	20	0	0	0	20	100	0	
I	5	0	0	0	0	14	0	0	14	100	0	
F	6	0	0	0	0	2	0	0	2	100	0	
C	7	0	0	0	0	0	18	0	18	100	0	
A	8	0	0	0	0	0	0	12	12	100	0	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	100	100	100	100	66.7	100	100				EQ(%) 1,000
e	EO(%)	0	0	0	0	33.3	0	0				EA(%) -0,270

MVS- 1999

Confusion Matrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	20	0	0	0	0	2	0	22	90.909	9.0909	
I	2	0	30	0	0	0	0	1	31	96.774	3.2258	
A	3	0	0	20	0	0	0	0	20	100.000	0.000	
S	4	0	0	0	19	1	0	0	20	95	5	
I	5	0	0	0	1	13	0	0	14	92.857	7.1429	
F	6	0	0	0	0	0	0	0	0	#DIV/0!	#DIV/0!	
C	7	0	0	0	0	0	17	0	17	100	0	
A	8	0	0	0	0	0	1	11	12	91.667	8.3333	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	100	100	100	95	92.9	0	94	91.7			EQ(%) 4,000
e	EO(%)	0	0	0	5	7.14	100	5.5556	8.33			EA(%) 1,109

RNA-1999

Confusion Matrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	20	0	1	0	0	3	0	24	71.429	28.571	
I	2	0	30	0	2	0	0	0	32	93.75	6.25	
A	3	0	0	19	0	0	0	0	19	100.000	0.000	
S	4	0	0	0	16	0	0	0	16	100	0	
I	5	0	0	0	2	14	0	0	16	87.5	12.5	
F	6	0	0	0	0	0	0	0	0	#DIV/0!	#DIV/0!	
C	7	0	0	0	0	0	19	1	20	95	5	
A	8	0	0	0	0	0	0	7	7	100	0	
o	Σ	20	30	20	20	14	3	19	138			
M	AP(%)	100	100	95	80	100	0	100	58.3			EQ(%) 13,000
e	EO(%)	0	0	5	20	0	100	0	41.7			EA(%) -3,580

RF- 2010

ConfusiMatrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	19	0	0	0	0	0	1	20	95	5	
I	2	0	30	0	0	0	0	0	30	100	0	
A	3	1	0	20	0	0	0	0	21	95.238	4.762	
S	4	0	0	0	18	3	0	0	21	85.714	14.286	
I	5	0	0	0	2	10	0	0	12	83.333	16.667	
F	6	0	0	0	0	2	0	0	2	100	0	
C	7	0	0	0	0	0	18	0	18	100	0	
A	8	0	0	0	0	0	1	12	13	92.308	7.6923	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	95	100	100	90	71.4	66.7	100	100			EQ(%) 3,000
e	EO(%)	5	0	0	10	28.6	33.3	0	0			EA(%) 2,839

MVS- 2010

Confusion Matrix and Statistics												
Referência												
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
C	1	19	0	0	0	1	0	0	20	95	5	
I	2	0	30	0	0	0	0	1	31	96.774	3.2258	
A	3	1	0	20	0	0	0	0	21	95.238	4.762	
S	4	0	0	0	18	6	0	0	24	75	25	
I	5	0	0	0	2	7	0	0	9	77.778	22.222	
F	6	0	0	0	0	0	2	0	2	100	0	
C	7	0	0	0	0	0	18	0	18	100	0	
A	8	0	0	0	0	0	1	11	12	91.667	8.3333	
o	Σ	20	30	20	20	14	3	18	137			
M	AP(%)	95	100	100	90	50	66.7	100	91.7			EQ(%) 6,000
e	EO(%)	5	0	0	10	50	33.3	0	8.33			EA(%) 2,759

RNA-2010

Confusion Matrix and Statistics												
Referência										Métricas		
Classes	1	2	3	4	5	6	7	8	Σ	AU(%)	EC(%)	
Classificação	1	19	0	0	0	1	2	0	23	82,609	17,391	
	2	0	30	0	1	0	0	2	33	90,909	9,0909	
	3	1	0	20	0	0	0	0	21	95,238	4,762	
	4	0	0	0	17	12	0	0	29	58,621	41,379	
	5	0	0	0	2	1	0	0	3	33,333	66,667	
	6	0	0	0	0	0	0	0	0	#DIV/0!	#DIV/0!	
	7	0	0	0	0	0	0	18	18	100	0	
	8	0	0	0	0	0	1	0	9	10	90	10
Σ	20	30	20	20	14	3	18	12	137			
AP(%)	95	100	100	85	7,14	0	100	75		EQ(%)	16,000	
EO(%)	5	0	0	15	92,9	100	0	25		EA(%)	0,788	

APÊNDICE G- Matriz de erro da classificação pelos algoritmos Floresta Aleatória, Máquina de Vetores de Suporte e Redes Neurais Artificiais com o conjunto de dados 4.

RF- 1988

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	19	0	0	0	1	0	0	0	20	95 5
2	0	29	0	0	0	0	0	0	29	100 0
3	1	0	20	0	0	0	0	0	21	95.238 4.762
4	0	0	0	20	0	0	0	0	20	100 0
5	0	1	0	0	13	0	0	0	14	92.857 7.1429
6	0	0	0	0	0	3	0	0	3	100 0
7	0	0	0	0	0	0	18	0	18	100 0
8	0	0	0	0	0	0	0	12	12	100 0
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	95	96.7	100	100	92.9	100	100	100		EQ(%) 1,000
EO(%)	5	3.33	0	0	7.14	0	0	0		EA(%) 1,190

MVS- 1988

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	17	0	0	0	2	1	0	0	20	85 15
2	0	29	0	0	0	0	0	0	29	100 0
3	2	0	20	0	0	0	0	0	24	83.333 16.667
4	0	0	0	20	1	0	0	0	21	95.238 4.7619
5	0	1	0	0	11	0	0	0	12	91.667 8.3333
6	0	0	0	0	0	0	0	0	0	#DIV/0! #DIV/0!
7	0	0	0	0	0	0	18	0	18	100 0
8	1	0	0	0	0	0	0	12	13	92.308 7.6923
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	85	96.7	100	100	78.6	0	100	100		EQ(%) 6,000
EO(%)	15	3.33	0	0	21.4	100	0	0		EA(%) 1,299

RNA-1988

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	18	1	0	0	12	0	0	0	31	58.065 41.935
2	0	28	0	0	0	0	1	0	29	96.552 3.4483
3	1	0	20	0	0	0	0	0	21	80.000 20.000
4	0	0	0	19	2	0	0	0	21	90.476 9.5238
5	0	0	0	1	0	0	0	0	1	0 100
6	0	0	0	0	0	0	0	0	0	#DIV/0! #DIV/0!
7	0	1	0	0	0	0	17	0	18	94.444 5.5556
8	1	0	0	0	0	0	0	11	12	91.667 8.3333
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	90	93.3	100	95	0	0	94	91.7		EQ(%) 17,000
EO(%)	10	6.67	0	5	100	100	5.5556	8.33		EA(%) 0,518

RF- 1999

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	19	0	0	0	0	0	0	0	19	100 0
2	0	30	0	1	0	0	0	0	31	96.774 3.2258
3	1	0	20	0	0	0	0	0	21	95.238 4.762
4	0	0	0	19	0	0	0	0	19	100 0
5	0	0	0	0	14	0	0	0	14	100 0
6	0	0	0	0	0	3	0	0	3	100 0
7	0	0	0	0	0	0	18	0	18	100 0
8	0	0	0	0	0	0	0	12	12	100 0
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	95	96.7	100	95	100	100	100	100		EQ(%) 2,000
EO(%)	5	0	0	5	0	0	0	0		EA(%) -0,540

MVS- 1999

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	19	0	0	0	0	0	0	0	19	100 0
2	0	30	0	1	0	0	0	0	31	96.774 3.2258
3	1	0	20	0	0	0	0	0	21	95.238 4.762
4	0	0	0	18	0	0	0	0	18	100 0
5	0	0	0	1	14	0	0	0	15	93.333 6.6667
6	0	0	0	0	0	3	0	0	3	100 0
7	0	0	0	0	0	0	18	0	18	100 0
8	0	0	0	0	0	0	0	12	12	100 0
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	95	100	100	90	100	100	100	100		EQ(%) 3,000
EO(%)	5	0	0	10	0	0	0	0		EA(%) -0,810

RNA-1999

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	19	0	0	0	1	3	0	0	23	82.609 17.391
2	0	19	0	1	0	0	0	0	20	95 5
3	1	0	20	0	0	0	0	0	21	95.238 4.762
4	0	0	0	19	0	0	0	0	19	67.857 32.143
5	0	0	0	0	4	0	0	0	4	100 0
6	0	0	0	0	0	0	0	0	0	#DIV/0! #DIV/0!
7	0	11	0	0	0	0	18	0	29	62.069 37.931
8	0	0	0	0	0	0	0	12	12	100 0
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	95	63.3	100	95	28.6	0	100	100		EQ(%) 23,000
EO(%)	5	36.7	0	5	71.4	100	0	0		EA(%) -4,022

RF- 2010

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	18	0	0	0	1	0	0	0	19	94.737 5.2632
2	0	30	0	0	0	0	0	0	30	100 0
3	2	0	20	0	0	1	0	0	23	86.957 13.043
4	0	0	0	20	1	0	0	0	21	95.238 4.7619
5	0	0	0	0	13	0	0	0	13	100 0
6	0	0	0	0	0	1	0	0	1	100 0
7	0	0	0	0	0	0	17	0	17	100 0
8	0	0	0	0	0	0	0	12	12	92.308 7.6923
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	90	100	100	100	92.9	33.3	94	100		EQ(%) 5,000
EO(%)	10	0	0	0	7.14	66.7	5.5556	0		EA(%) -0,620

MVS- 2010

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	18	0	1	0	0	2	0	0	21	85.714 14.286
2	0	30	0	0	0	0	0	0	30	100 0
3	2	0	19	0	0	0	0	0	21	90.476 9.524
4	0	0	0	20	0	0	0	0	20	100 0
5	0	0	0	0	14	0	0	0	14	100 0
6	0	0	0	0	0	1	0	0	1	100 0
7	0	0	0	0	0	0	18	0	18	100 0
8	0	0	0	0	0	0	0	12	12	100 0
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	90	100	95	100	100	33.3	100	100		EQ(%) 2,000
EO(%)	10	0	5	0	0	66.7	0	0		EA(%) 1,650

RNA-2010

ConfusionMatrix and Statistics										
Referência										
Classes	1	2	3	4	5	6	7	8	Σ	Métricas
										AU(%) EC(%)
1	15	0	2	0	0	1	0	0	18	83.333 16.667
2	1	30	0	0	0	0	1	0	32	93.75 6.25
3	1	0	17	0	0	0	1	0	20	85.000 15.000
4	0	0	0	16	3	0	0	0	19	84.211 15.789
5	1	0	0	4	11	0	0	0	16	68.75 31.25
6	1	0	0	0	0	1	0	0	2	50 50
7	1	0	1	0	0	0	17	1	20	85 15
8	0	0	0	0	0	0	0	10	10	100 0
Σ	20	30	20	20	14	3	18	12	137	
AP(%)	75	100	85	80	78.6	33.3	94	83.3		EQ(%) 6,000
EO(%)	25	0	15	20	21.4	66.7	5.5556	16.7		EA(%) 8,599

RF- 2019

ConfusionMatrix and Statistics											
Referencia										Metricas	
Classes	1	2	3	4	5	6	7	8	Σ	APQ(%)	EQ(%)
Cassini	1	20	0	0	0	0	0	0	20	100	0
	2	0	30	0	0	0	0	0	30	100	0
	3	0	0	20	0	0	0	0	21	95,238	4,762
	4	0	0	0	20	1	0	0	21	95,238	4,7619
	5	0	0	0	0	13	0	0	13	100	0
	6	0	0	0	0	0	3	0	3	100	0
	7	0	0	0	0	0	0	19	19	100	0
	8	0	0	0	0	0	0	0	11	11	100
Σ	20	30	20	20	14	3	19	12	138		
APQ(%)	100	100	100	100	92,9	100	100	91,7		EQ(%)	2,000
EQ(%)	0	0	0	0	7,14	0	0	8,33		EQ(%)	-0,551

ANEXO A - CLASSES DE USO E COBERTURA DA TERRA MAPEADAS, DESCRIÇÃO E CLASSIFICAÇÃO DE ACORDO COM O IBGE, FAO E O RELATÓRIO DE EMISSÕES DE GEE- MAPBIOMAS

Classe	Nível I	Bioma	Descrição	Classes IBGE	Classes FAO	Classes inventário Nacional de Emissões de GEE
Floresta	Formação savânica	Caatinga	Tipos de vegetação com predomínio de espécies de dossel semi-contínuo-Savana-Estépica Arborizada, Savana Arborizada.	Ta, Sa	FDP, FSP, FDM, FSM	FMN, FM
Agricultura	Pastagem	Caatinga	Área de pastagem, predominantemente plantadas, vinculadas a atividade agropecuária. As áreas de pastagem natural são predominantemente classificadas como formação campestre que podem ou não ser pastejadas.	AP, PE, PS	OP, OG	Ap
Outras áreas não vegetadas	Infraestrutura urbana		Áreas urbanizadas com predomínio de superfície não vegetadas, incluindo estradas, vias e construções.	AU		S
Corpos d'água	Lagos		Rios, lagos, represas, reservatórios e outros corpos d'água		IRP, IRS, IL, ID	A, Res

Fonte: Adaptado de Souza *et al.*, 2020.

ANEXO B - SCRIPT DE PROCESSAMENTO EM CLASSIFICAÇÃO DE IMAGENS EM R

```
#####
#####
# title: Machine learning
# purpose: Implementing a machine learning workflow in R
# author : Abdulhakim M. Abdi (Twitter: @HakimAbdi / www.hakimabdi.com)
# input : A multi-temporal raster stack of Sentinel-2 data comprising scenes from four dates
# output : One classified land cover map from each of three machine learning algorithms
# Note 1 : This brief tutorial assumes that you are already well-grounded in R concepts and are
#         : familiar with image classification procedure and terminology
# Reference : Please cite Abdi (2020): "Land cover and land use classification performance of
machine learning
: algorithms in a boreal landscape using Sentinel-2 data" in GIScience & Remote Sensing if you find
this
#         : tutorial useful in a publication.
# Reference URL : https://doi.org/10.1080/15481603.2019.1650447
#####
#####

#rm(list = ls(all.names = TRUE)) # will clear all objects, including hidden objects
#gc() # free up memory and report memory usage

# set working directory. This will be the directory where all the unzipped files are located
setwd("C:/Users/ANDRE Q ALMEIDA/Desktop/PROJETOKAREN")

# instalar todos esses pacotes

# load required libraries (Note: if these packages are not installed, then install them first and then load)
# rgdal: a comprehensive repository for handling spatial data
# raster: for the manipulation of raster data
# caret: for the machine learning algorithms
# sp: for the manipulation of spatial objects
# nnet: Artificial Neural Network
# randomForest: Random Forest
# kernlab: Support Vector Machines
# e1071: provides miscellaneous functions required by the caret package
install.packages("pacman"); pacman::p_load(rgdal,raster,caret,sp,nnet,randomForest,kernlab,e1071)
install.packages("kernlab")
install.packages("spatialEco")
install.packages("sf")
#### RECOMENDO ESSE SITE KAREN (https://www.neonscience.org/ds-tags/raster-data)

#carregar os pacotes instalados
# Load the Sentinel-2 stack of the study area
library(raster)
library(kernlab)
library(lattice)
library(ggplot2)
library(rgdal)
require(spatialEco)
library(sp)
library(sf)

#s2data = stack("S2StackSmall.tif")
s2data = stack("1988_SIRGAS_mask.tif")
plotRGB(s2data,r = 3, g = 2, b = 1, scale=800,
```

```

stretch = "lin")
# Name the layers of the Sentinel-2 stack based on previously saved information
names(s2data) = as.character(read.csv("S2StackSmall_Names.csv")[,1])

# Load the sample data
# Alternatively, you can use the supplied orthophotos to generate a new set of training and validation
data
# Your samples layer must have a column for each image in the raster stack, a column for the land
cover class that point represents, an X and Y column
# You can create such a sample file using QGIS or another GIS software
#amostras de treinamento

#samples = read.csv("Samples.csv")

#extrair valores do RASTER
amostras<-readOGR("Classepto_1988.shp")
plot(amostras, add=T, col="red")
extrc<-extract(s2data,amostras, fun=mean, sp=T, df=T, weights = T, cellnumbers=T)
tmp = st_intersection(st_as_sf(amostras), st_as_sf(extrc))
pts4 = as(tmp, "Spatial")

dataFrameAmostras<-data.frame(pts4)
summary(dataFrameAmostras)
names(dataFrameAmostras)
samples<-dataFrameAmostras[, c(5:11,1)]
names(samples)=c("x","y","cells","BA","BV", "BRED", "BNIR", "class")
names(samples)

# Split the data frame into 70-30 by class
trainx = list()
evalx = list()
for (i in 1:9){ # loop through all eight classes# TEMOS 9 CLASSES
  cls = samples[samples$class == i,]
  smpl <- floor(0.70 * nrow(cls))
  tt <- sample(seq_len(nrow(cls)), size = smpl)
  trainx[[i]] <- cls[tt,]
  evalx[[i]] <- cls[-tt,]
}

# combine them all into training and evaluation data frames
trn = do.call(rbind, trainx)
eva = do.call(rbind, evalx)
dataFrameTree<-data.frame(eva)
write.table(dataFrameTree,file="C:/Users/KAREN
ALMEIDA/Desktop/projtoembrapa/pontos_treina.csv",row.names=T)
#o ARQUIVO TREINA.CSV DEVE SER EDITADO NO EXCEL, retirando a primeira coluna, importado
no QGIS e SALVO EM SHAPEFILE (salvar o arquivo shapefile como treinamento)

# Set up a resampling method in the model training process
tc <- trainControl(method = "repeatedcv", # repeated cross-validation of the training data
  number = 10, # number of folds
  repeats = 5, # number of repeats
  allowParallel = TRUE, # allow use of multiple cores if specified in training
  verboseIter = TRUE) # view the training iterations

# Generate a grid search of candidate hyper-parameter values for inclusion into the models training
# These hyper-parameter values are examples. You will need a more complex tuning process to achieve
high accuracies
# For example, you can play around with the parameters to see which combinations gives you the
highest accuracy.

```



```

nnet.grid = expand.grid(size = seq(from = 2, to = 10, by = 2), # number of neurons units in the hidden
layer
decay = seq(from = 0.1, to = 0.5, by = 0.1)) # regularization parameter to avoid over-fitting

rf.grid <- expand.grid(mtry=1:20) # number of variables available for splitting at each tree node

svm.grid <- expand.grid(sigma=seq(from = 0.01, to = 0.10, by = 0.02), # controls for non-linearity in the
hyperplane
C=seq(from = 2, to = 10, by = 2)) # controls the influence of each support vector

## Begin training the models. It took my laptop 8 minutes to train all three algorithms
# Train the neural network model
nnet_model <- caret::train(x = trn[, (5:ncol(trn)-1)], y = as.factor(as.integer(as.factor(trn$class))),
method = "nnet", metric="Accuracy", trainControl = tc, tuneGrid = nnet.grid)

# Train the random forest model
rf_model <- caret::train(x = trn[, (5:ncol(trn)-1)], y = as.factor(as.integer(as.factor(trn$class))),
method = "rf", metric="Accuracy", trainControl = tc, tuneGrid = rf.grid)

# Train the support vector machines model
svm_model <- caret::train(x = trn[, (5:ncol(trn)-1)], y = as.factor(as.integer(as.factor(trn$class))),
method = "svmRadialSigma", metric="Accuracy", trainControl = tc, tuneGrid = svm.grid)

## Apply the models to data. It took my laptop 2 minutes to apply all three models
# Apply the neural network model to the Sentinel-2 data.
nnet_prediction = raster::predict(s2data, model=nnet_model)

# Apply the random forest model to the Sentinel-2 data
rf_prediction = raster::predict(s2data, model=rf_model)

# Apply the support vector machines model to the Sentinel-2 data
svm_prediction = raster::predict(s2data, model=svm_model)

# Convert the evaluation data into a spatial object using the X and Y coordinates and extract predicted
values

#ABRINDO O SHAPE DE TREINAMENTO
eva.spE<-readOGR("treinamento.shp")

## Superimpose evaluation points on the predicted classification and extract the values
# neural network
nnet_Eval = extract(nnet_prediction, eva.spE)
plot(nnet_prediction)
plot(eva.spE, add=T)
# random forest
rf_Eval = extract(rf_prediction, eva.spE)
# support vector machines
svm_Eval = extract(svm_prediction, eva.spE)

# Create an error matrix for each of the classifiers
nnet_errorM = confusionMatrix(as.factor(nnet_Eval),as.factor(eva$class)) # nnet is a poor classifier, so
it will not capture all the classes
rf_errorM = confusionMatrix(as.factor(rf_Eval),as.factor(eva$class))
svm_errorM = confusionMatrix(as.factor(svm_Eval),as.factor(eva$class))

# Plot the results next to one another along with the 2018 NMD dataset for comparison
#nmd2018 = raster("NMD_S2Small.tif") # load NMD dataset (Nationella Marktaeckedata, Swedish
National Land Cover Dataset)

```

```
#crs(nmd2018) <- crs(nnet_prediction) # Correct the coordinate reference system so it matches with the
rest
rstack = stack(nnet_prediction, rf_prediction, svm_prediction) # combine the layers into one stack
names(rstack) = c("Single Layer Neural Network", "Random Forest", "Support Vector Machines") #, #
name the stack
plot(rstack) # plot it!

writeRaster(nnet_prediction, filename="class1988RN.tif", format="GTiff", overwrite=TRUE)
writeRaster(rf_prediction, filename="class1988RF.tif", format="GTiff", overwrite=TRUE)
writeRaster(svm_prediction, filename="class1988ML.tif", format="GTiff", overwrite=TRUE)

# Congratulations! You conducted your first machine learning classification in R.
# Please cite the paper referred to at the beginning if you use any part of this script in a publication.
Thank you! :-)
```

ANEXO C - SCRIPT DO PROCESSAMENTO DE IV'S E MT'S EM R

#All code sections start with loading the same packages:

#Calling packages

```
library("sp")
```

```
library(" raster ")
```

```
library("rgdal")
```

```
library("maptools")
```

```
library(" lattice ")
```

```
library(" tcltk ")
```

```
library("glcm")
```

#B.1 Texture analysis

Reading in the data and creating a RasterLayer object

```
raw_classification <- raster(file .choose())
```

```
# _____ TEXTURE ANALYSIS _____ #
```

Vector for different window sizes

```
window <- c(3,5,7,9)
```

Textural features used in the analysis

```
text_features <- c("variance", "homogeneity", "entropy", "second_moment")
```

#directions : shifts of 0, 45, 90 and 135 degrees

```
direction <- list(c(0,1), c(1,1), c(1,0), c(1,-1))
```

Calculating the GLCMs

```
for (w in window) {
```

```
  stacks <-          glcm(raw_classification, n_grey = 13, window = c(w, w), shift = direction,
    statistics = text_features, na_opt="ignore", na_val=NA, scale_factor=1,
    asinteger=FALSE)
```

na_opt here: NA values will be ignored

the 4 different textural features are saved in different layers of the stack

```
if (w==3) {
```

```
  variance_3 <- stacks[[1]]
```

```
  homogeneity_3 <- stacks[[2]]
```

```
  entropy_3 <- stacks[[3]]
```

```
  second_moment_3 <- stacks[[4]]
```

```
} else if (w==5) {
```

```
  variance_5 <- stacks[[1]]
```

```
  homogeneity_5 <- stacks[[2]]
```

```
  entropy_5 <- stacks[[3]]
```

```
  second_moment_5 <- stacks[[4]]
```

```
} else if (w==7) {
```



```

variance_7 <- stacks[[1]]
homogeneity_7 <- stacks[[2]]
entropy_7 <- stacks[[3]]
second_moment_7 <- stacks[[4]]
} else if (w==9) {
variance_9 <- stacks[[1]]
homogeneity_9 <- stacks[[2]]
entropy_9 <- stacks[[3]]
second_moment_9 <- stacks[[4]]
}
}

# Writing of the new textures
writeRaster(variance_3, 'D:\\Analyse\\variance_3x3.tif')
writeRaster(variance_5, 'D:\\Analyse\\variance_5x5.tif')
writeRaster(variance_7, 'D:\\Analyse\\variance_7x7.tif')
writeRaster(variance_9, 'D:\\Analyse\\variance_9x9.tif')
writeRaster(homogeneity_3, 'D:\\Analyse\\homogeneity_3x3.tif')
writeRaster(homogeneity_5, 'D:\\Analyse\\homogeneity_5x5.tif')
writeRaster(homogeneity_7, 'D:\\Analyse\\homogeneity_7x7.tif')
writeRaster(homogeneity_9, 'D:\\Analyse\\homogeneity_9x9.tif')
writeRaster(entropy_3, 'D:\\Analyse\\entropy_3x3.tif')
writeRaster(entropy_5, 'D:\\Analyse\\entropy_5x5.tif')
writeRaster(entropy_7, 'D:\\Analyse\\entropy_7x7.tif')
writeRaster(entropy_9, 'D:\\Analyse\\entropy_9x9.tif')
writeRaster(second_moment_3, 'D:\\Analyse\\asm_3x3.tif')
writeRaster(second_moment_5, 'D:\\Analyse\\asm_5x5.tif')
writeRaster(second_moment_7, 'D:\\Analyse\\asm_7x7.tif')
writeRaster(second_moment_9, 'D:\\Analyse\\asm_9x9.tif')
# _____ ITERATION OF ASM _____ #
# Window size: 3x3
w <- 3
# Textural feature
text_features <- "second_moment"
# Directions : shifts of 0, 45, 90, and 135 degrees
direction <- list(c(0,1), c(1,1), c(1,0), c(1,-1))
# _____ Calculating the GLCMs for an ASM texture
# _____ Iteration 0
asm_from_asm <- glcm(raw_classification, n_grey = 9, window = c(w, w), shift =
direction, statistics = text_features, na_opt="ignore", na_val=NA, scale_factor=1,
asinteger=FALSE)

```

```
#n_grey set to 9 because there are values from 1 to 9 in the classification
writeRaster(asm_from_asm, 'D:\\Analyse\\asm_from_asm__iter0__raw.tif')
# ____ Iteration 1 to 5: homogeneity texture applied to the previous homogeneity texture
# ____ then assigns the result to variable which includes the number of the iteration
for (i in 1:5) {
  asm_from_asm <- glcm(asm_from_asm, n_grey = 13, window = c(w, w), shift =
  direction, statistics = text_features, na_opt="ignore", na_val=NA, scale_factor=1,
  asinteger=FALSE)
  writeRaster(asm_from_asm,
  paste("D:\\Analyse\\asm_from_asm__iter",i,"__raw.tif",sep=""))
}
```

```
# Reading in the 3x3 ASM texture (not iterated )
asm_3x3_raw <- raster(file.choose())
# Setting a threshold , here 0.9
threshold <- matrix(c(0, 0.9, 0, 0.9, 1, 1), ncol=3, byrow=TRUE)
#if there are overlapping ranges, the first time a number is within a range determines
the reclassification value
# Reassign values
asm_from_asm__iter0__raw_binary <- reclassify(asm_3x3_raw, threshold)
writeRaster(asm_from_asm__iter1__raw_binary,
"D:\\Analyse\\asm_from_asm__iter0__raw_binary_ts09.tif")
```

#B.2.2 Applying a majority filter

The majority filter has been applied with the "focal" function of the "raster" package, which implements a moving window. Therein the function "modal" has been used, which reports the most frequent value of sample results.

```
# Reading in the ASM texture with the uncertainties
asm <- raster(file.choose())
asm_binary <- raster(file.choose()) # binary with threshold 0.9
# ____ Window size: 5x5
window = matrix(1,nrow = 5,ncol = 5)
# Majority filter on the grey-scale texture
asm__majority <- focal(asm, w=window, fun=modal)
writeRaster(asm__majority, 'D:\\Analyse\\asm_3x3__majority_5x5.tif')
# Majority filter on the binary texture
asm__majority <- focal(asm_binary, w=window, fun=modal)
writeRaster(asm__majority, 'D:\\Analyse\\asm_3x3_bin_ts90__majority_5x5.tif')
```

```
# ____ Window size: 3x3
window = matrix(1,nrow = 3,ncol = 3)
# Majority filter on the grey-scale texture
asm__majority <- focal(asm, w=window, fun=modal)
writeRaster(asm__majority, 'D:\\Analyse\\asm_3x3__majority_3x3.tif')
# Majority filter on the binary texture
asm__majority <- focal(asm_binary, w=window, fun=modal)
writeRaster(asm__majority, 'D:\\Analyse\\asm_3x3_bin_ts90__majority_3x3.tif')
# ____ Window size: 3x3, iterated , binary
window = matrix(1,nrow = 3,ncol = 3)
# Majority filter on the binary texture , zeroth iteration
asm_bin_majority <- focal(asm_binary, w=window, fun=modal)
# Majority filter on the previous texture map, iteration 1 to 4
for (i in 1:4) {
  asm_bin_majority <- focal(asm_bin_majority, w=window, fun=modal)
}
writeRaster(asm_bin_majority,
' D:\\Analyse\\majority_3x3_iter4__from_asm_3x3_bin_ts90.tif')
```

##B.3 Area calculation

The raw classification as stated in section 3.1 had class numbers (or values) from 1 to 9. Based on the binary uncertainty map it was decided for every pixel whether its class identity is kept or not. A zero means the class was probably wrongly classified and should be deleted from the map; a one means it was probably correct and should be kept. By multiplying every pixel in the raw classification by the value in the binary uncertainty map, all pixels with the value zero were eliminated from the classification.

Afterwards, the number of pixels that remained in each class could be counted separately with the function "freq" of the "raster" package.

Reading in the data

```
raw_classification <- raster(file.choose()) #Initial classification , 6 classes
asm_3x3_bin_90 <- raster(file.choose()) #Angular Second Moment, 3x3 window,
binary version (threshold 0.9)
asm_3x3_majority <- raster(file.choose()) #Majority filter of the Angular Second
Moment, 3x3 window, binary version (threshold 0.9)
# _____ MATRIX MULTIPLICATION _____ #
# Raw_classification has class numbers from 1 to 9. The uncertainty map indicates if the
class is kept or not (0=deleted, 1=kept)
# a*b: elementwise operation
certain_areas_asm <- raw_classification * asm_3x3_bin_90
certain_areas_majority_asm <- raw_classification * asm_3x3_majority
```

```
# Writing of the new maps
writeRaster(certain_areas_asm, 'D:\\Ergebnisse\\certain_area__asm_3x3_from_ts90.tif')
writeRaster(certain_areas_majority_asm,
' D:\\Ergebnisse\\certain_area__majority_3x3_from_asm_3x3_ts90.tif')
# _____ COUNTING AREAS _____ #
# Check the resolution
show(raw_classification)
# Frequency
# How often does each value in the classification occur?
freq(raw_classification )
freq(certain_areas_asm)
freq(certain_areas_majority_asm)
```

ANEXO D- SCRIPT DE AQUISIÇÃO DE IMAGENS LANDSAT NO GOOGLE EARTH ENGINE

```
Map.setCenter(-37.04536092543946,-10.938664285887635,11);
var OLI1 = ee.Image("LANDSAT/LT05/C01/T2_SR /LT05_215068_19881221");
var OLI2 = ee.Image("LANDSAT/LT05/C01/T2_SR /LT05_215067_19991204");
var OLI3 = ee.Image("LANDSAT/LT05/C01/T2_SR /LT05_215068_19991204");
var OLI4 = ee.Image("LANDSAT/LT05/C01/T2_SR/LT05_215067_20100929");
var OLI5 = ee.Image("LANDSAT/LT05/C01/T2_SR/LT05_215068_20100929");
var OLI6 = ee.Image("LANDSAT/LT05/C01/T2_SR/LC08_215067_20190704");
var OLI7 = ee.Image("LANDSAT/LT05/C01/T2_SR /LC08_215068_20190704");
```

```
//var OLI = ee.ImageCollection (LANDSAT/LT05/C01/T2_SR)
//.filterDate('1988-12-01','2020-01-01')
//.filterMetadata('CLOUD_COVER', 'less_than', 10)
```

```
Map.addLayer(OLI1, {bands: 'B3,B2,B1'});
Map.addLayer(OLI2, {bands: 'B3,B2,B1'});
Map.addLayer(OLI3, {bands: 'B3,B2,B1'});
Map.addLayer(OLI4, {bands: 'B3,B2,B1'});
Map.addLayer(OLI5, {bands: 'B3,B2,B1'});
Map.addLayer(OLI6, {bands: 'B4,B3,B2'});
Map.addLayer(OLI7, {bands: 'B4,B3,B2'});
```

```
Export.image.toDrive({
  image: OLI1,
  description: '1988',
  folder:'LANDSAT_MESTRADO',
  region:geometry,
  scale: 30,
  crs:'EPSG:4326',
  maxPixels: 100000000,
});
```

```
Export.image.toDrive({
  image: OLI2,
  description: '1999',
  folder:'LANDSAT_MESTRADO',
  region:geometry,
  scale: 30,
  crs:'EPSG:4326',
  maxPixels: 1000000000000
});
```

```
Export.image.toDrive({
  image: OLI3,
  description: '19992',
  folder:'LANDSAT_MESTRADO',
  region:geometry,
  scale: 30,
  crs:'EPSG:4326',
  maxPixels: 1000000000000
});
```

```
Export.image.toDrive({
  image: OLI4,
  description: '2010',
```

```

    folder:'LANDSAT_MESTRADO',
    region:geometry,
    scale: 30,
    crs:'EPSG:4326',
    maxPixels: 1000000000000
  });

```

```

Export.image.toDrive({
  image: OLI5,
  description: '20102',
  folder:'LANDSAT_MESTRADO',
  region:geometry,
  scale: 30,
  crs:'EPSG:4326',
  maxPixels: 1000000000000
});

```

```

Export.image.toDrive({
  image: OLI6,
  description: '2019',
  folder:'LANDSAT_MESTRADO',
  region:geometry,
  scale: 30,
  crs:'EPSG:4326',
  maxPixels: 1000000000000
});

```

```

Export.image.toDrive({
  image: OLI7,
  description: '20192',
  folder:'LANDSAT_MESTRADO',
  region:geometry,
  scale: 30,
  crs:'EPSG:4326',
  maxPixels: 1000000000000
});

```