



UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

MILENA DE ARAÚJO LIMOEIRO

**USO DE *GEOSPATIAL BIG DATA* PARA ANÁLISE DE
FAVORABILIDADE À RECOMPOSIÇÃO FLORESTAL EM REGIÕES
DEGRADADAS POR EXPLORAÇÃO *ONSHORE* DE PETRÓLEO E
GÁS**

Salvador
2020

MILENA DE ARAÚJO LIMOEIRO

**USO DE *GEOSPATIAL BIG DATA* PARA ANÁLISE DE
FAVORABILIDADE À RECOMPOSIÇÃO FLORESTAL EM REGIÕES
DEGRADADAS POR EXPLORAÇÃO *ONSHORE* DE PETRÓLEO E
GÁS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil, Escola Politécnica, Universidade Federal da Bahia, como requisito para obtenção do título de Mestre em Engenharia Civil.

Orientador: Prof. Dr. Mauro José Alixandrini Júnior

Salvador

2020

L734 Limoeiro, Milena de Araújo.
Uso de *geospatial big data* para análise de favorabilidade à recomposição florestal em regiões degradadas por exploração *onshore* de petróleo e gás/ Milena de Araújo Limoeiro. – Salvador, 2020.
106 f.: il. color.

Orientador: Prof. Dr. Mauro José Alixandrini Junior.

Dissertação (mestrado) – Universidade Federal da Bahia. Escola Politécnica, 2020.

1. Petróleo e gás - exploração. 2. Geoprocessamento. 3. Sensoriamento remoto. 4. Revegetação. 5. *Geospatial big data*. I. Alixandrini Junior, Mauro José. II. Universidade Federal da Bahia. III. Título.

CDD: 665.5

MEMBROS DA BANCA EXAMINADORA DA DISSERTAÇÃO DE MESTRADO DE

MILENA ARAÚJO LIMOEIRO

APRESENTADA AO MESTRADO EM ENGENHARIA CIVIL, DA UNIVERSIDADE FEDERAL DA BAHIA, EM 11 DE NOVEMBRO DE 2020.

BANCA EXAMINADORA




Prof.(a) Dr.(a) **Mauro José Alixandrini Júnior**
Orientador

PPEC-UFBA



Prof.(a) Dr.(a) **Júlio Cezar Pedrassoli**
PPEC-UFBA



Prof.(a) Dr.(a) **Fernanda Puga Carvalho**
PPEC-UFBA



Prof.(a) Dr.(a) **Carla Bernadete Madureira Cruz**
PPGEO/UFRJ

AGRADECIMENTOS

Agradeço à Deus, por todos os planos dele em minha vida, que são perfeitos e agradáveis. À minha família, por todo amor, apoio, carinho, cuidado, compreensão, orações e incentivo. Em especial ao meu filho, Miguel, por me ensinar tanto sobre o amor e mostrar que essa é a minha força para prosseguir, mesmo nas adversidades.

Ao meu orientador, Mauro Alixandrini, pela honra em ser orientada por ele, por acreditar em mim, pela paciência, compreensão e por toda a sabedoria comigo compartilhada ao longo dessa jornada. Às professoras Carla Cruz, Fernanda Puga e Vivian Fernandes e ao professor Júlio, por aceitarem o convite de participar da minha banca de qualificação e/ou defesa e por contribuírem de forma tão amável e grandiosa para o aperfeiçoamento desta pesquisa. A todos os professores e funcionários da UFBA, por toda a dedicação e a insistência em lutar pela universidade pública a fim de garantir ensino, pesquisa e extensão em tempos tão tormentosos. Em especial, àqueles ligados ao PPEC.

Aos meus colegas de trabalho do IF Baiano, por toda força, apoio e incentivo, especialmente aos companheiros do NUGRI, o melhor núcleo do campus Uruçuca. Aos amigos, cujo companheirismo foi fundamental. E a todos que, de boa vontade, ajudaram-me a chegar até aqui.

Tudo tem o seu tempo determinado, e há tempo para todo o propósito debaixo do céu (Eclesiastes 3:1).

RESUMO

Atualmente o volume de dados oriundos do sensoriamento remoto disponível para ser utilizado cresce de forma exponencial e o uso *geospatial big data* passou a atrair cada vez mais a atenção da comunidade científica por suas inúmeras possibilidades de aplicação na solução dos mais diversos tipos de problemas. Paralelamente, a alteração do cenário mundial de exploração *onshore* (em regiões continentais) de petróleo e gás natural, que ocorreu em função da intensificação de jazidas em regiões predominantemente tropicais, trouxe uma nova problemática ligada ao fato de que essas regiões se mostram muito mais suscetíveis à degradação em função de características intrínsecas à exploração desses minerais. Posto isto, este trabalho tem como objetivo geral propor uma metodologia para a avaliação da favorabilidade à recomposição florestal para áreas degradadas pela exploração de petróleo *onshore* com uso de *geospatial big data*, sendo realizado um estudo de caso no campo de Água Grande, que fica localizado entre os municípios de Catu e Pojuca, no estado da Bahia. Para tal finalidade foram utilizados dados de modelos digitais de elevação, uso e cobertura do solo, hidrografia e climáticos. Além disto, foram enumerados sete indicadores, cada um associado a uma camada de informação, aos quais foram atribuídos pesos e notas para suas classes por especialistas. Em seguida, essas camadas de informações foram sobrepostas utilizando a álgebra de mapas, gerando como saída o mapa de favorabilidade a recomposição florestal. O objetivo principal do trabalho foi alcançado sendo possível observar que a escolha das áreas para a realização de projetos de reflorestamento pode ser mais assertiva com a utilização de um modelo que represente a favorabilidade à recomposição florestal na região. Dentre os indicadores utilizados, o uso da terra, a proximidade com áreas de formação florestal e a proximidade a corpos d'água, foram considerados aqueles como maior impacto para a hierarquização de regiões mais ou menos favoráveis ao reflorestamento, enquanto que os indicadores de proximidade com áreas urbanas, geomorfologia e intensidade de exposição ao Sol foram considerados de menor impacto. Por fim, ressalta-se que a metodologia desenvolvida neste trabalho pode ser replicada em qualquer região e assim oferecer um subsídio para a escolha mais estratégica de áreas candidatas ao reflorestamento.

Palavras-chave: *Geospatial big data*. Mapa de favorabilidade. Recomposição florestal.

ABSTRACT

Currently, the volume of data originating from remote sensing available to be used grows exponentially and the geospatial use of big data has started to attract more and more attention from the scientific community due to the countless possibilities of application in solving the most diverse types of problems. In parallel, the change in the world scenario of *onshore* exploration (in continental regions) of oil and natural gas, due to the intensification of deposits in predominantly tropical regions, brought a new problem linked to the fact that these regions are much more susceptible to degradation in function of intrinsic characteristics to the exploration of these minerals. Therefore, this work has as general objective to propose a methodology to evaluate the favorability to the forest restoration for impacted or degraded areas by onshore oil exploration with the use of *geospatial big data*, so a case study was carried out in the Água Grande field, which is located between the municipalities of Catu and Pojuca, Bahia. For this purpose, data from digital models of elevation, land use and cover, hydrography and climate were used. In addition, seven indicators were listed, each associated with a layer of information, to which weights and grades were assigned to their to your levels by experts. Then these layers of information were superimposed using map algebra, generating as output the favorability map for forest restoration. The main objective of the work was achieved and it was possible to observe that the choice of areas for the realization of reforestation projects can be more assertive with the use of a model that represents the favorability to forest restoration in the region. Among the indicators used, land use, proximity to areas of forest formation and proximity to water bodies were considered to have the greatest impact on the hierarchy of regions more or less favorable to reforestation, while indicators of proximity to urban areas, geomorphology and intensity of exposure to the sun were considered to have the least impact. Finally, it is important to note that the methodology developed in this work can be replicated in any region and thus offer a subsidy for the more strategic choice of areas that are candidates for reforestation.

Keywords: Geospatial big data. Map of favorability. Forest restoration.

LISTA DE FIGURAS

Figura 1 - Classificações dos problemas de tomadas de decisões multicritérios	24
Figura 2 - Principais esquemas de amostragem utilizados	29
Figura 3 - Indicadores utilizados pelo autor	34
Figura 4 - Fluxograma da determinação de favorabilidade à recuperação florestal ..	35
Figura 5 - Distribuição dos indivíduos de <i>Guarea guidonia</i> na microbacia experimental	37
Figura 6 - Posicionamento da <i>G. guidonia</i> em relação às zonas hidrogenéticas (A), elevação do terreno (B), exposição do relevo (C), declividade (D), superfície de curvatura (E) e presença de afloramentos rochosos (F) na microbacia	38
Figura 7 - Disposição de biomas e temas transversais utilizadas no MapBiomas	41
Figura 8 - Etapas da classificação MapBiomas	41
Figura 9 - Demonstração do produto MapBiomas para o campo de Água Grande -BA	43
Figura 10 - Esquematisação do SRTM	44
Figura 11 - Localização da área de estudo	48
Figura 12 - Panorâmica da região de Água Grande	49
Figura 13 - Fluxograma da metodologia de pesquisa	51
Figura 14 - Diferença entre os modelos ASTER, ALOS E SRTM	59
Figura 15 - Histograma da diferença entre os modelos ASTER e SRTM.....	61
Figura 16 - Histograma da diferença entre os modelos ASTER e ALOS	62
Figura 17 - Histograma da diferença entre os modelos ALOS e SRTM	63
Figura 18 - Diferença entre os modelos ALOS, ASTER, SRTM e SEI	65
Figura 19 - Histograma da diferença entre os modelos ALOS e SEI	68
Figura 20 - Histograma da diferença entre os modelos ASTER e SEI	69
Figura 21 - Histograma da diferença entre os modelos SRTM e SEI.....	70
Figura 22 - Mapa de favorabilidade à recomposição florestal	75
Figura 23 - Histograma de áreas degradadas por favorabilidade à recomposição florestal.....	76
Figura 24 - Gráfico de distribuição percentual do uso da terra.....	78
Figura 25 - Gráfico de distribuição percentual da geomorfologia	79
Figura 26 - Gráfico de distribuição percentual da declividade	80
Figura 27 - Gráfico de distribuição percentual da exposição ao Sol.....	81

Figura 28 - Gráfico de distribuição percentual da proximidade a áreas urbanas	82
Figura 29 - Gráfico de distribuição percentual da proximidade a corpos d'água.....	83
Figura 30 - Gráfico de distribuição percentual da proximidade a áreas de formação florestal.....	84

LISTA DE QUADROS

Quadro 1 - As etapas de avaliação nos métodos.....	25
Quadro 2 - Taxonomia dos métodos de classificação de imagens	27
Quadro 3 - Matriz de confusão para um problema de classificação com duas classes	30
Quadro 4 - Classificação para valores do índice kappa	31
Quadro 5 - Teste U de Mann-Whitney.....	85

LISTA DE TABELAS

Tabela 1 - Dados sobre os modelos ALOS, ASTER e SRTM	52
Tabela 2 - Dados sobre os modelos ALOS, ASTER, SRTM e SEI	53
Tabela 3 - Medidas de dispersão dos modelos ALOS, ASTER e SRTM para a área de estudo	58
Tabela 4 - Medidas de dispersão das diferenças entre os modelos ASTER, ALOS e SRTM para a área de estudo	60
Tabela 5 - Medidas de dispersão dos modelos ALOS, ASTER, SRTM e SEI para a área de estudo	64
Tabela 6 - Medidas de dispersão das diferenças entre os modelos ALOS, ASTER, SRTM e SEI para a área de estudo	66
Tabela 7 - Notas de cada classe para o indicador uso da terra	71
Tabela 8 - Notas de cada classe para o indicador proximidade com áreas urbanas	71
Tabela 9 - Notas de cada classe para o indicador proximidade com áreas de formação florestal.....	72
Tabela 10 - Notas de cada classe para o indicador proximidade com corpos d'água	72
Tabela 11 - Notas de cada classe para o indicador geomorfologia.....	73
Tabela 12 - Notas de cada classe para o indicador declividade.....	73
Tabela 13 - Notas de cada classe para o indicador intensidade de exposição ao Sol	73
Tabela 14 - Notas de cada classe do fator sazonal.....	74

LISTA DE ABREVIATURAS E SIGLAS

ALOS	<i>Advanced Land Observing Satellite</i>
ANP	Agência Nacional de Petróleo, Gás Natural e Biocombustíveis
ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
BA	Bahia
BDG	Banco de Dados Geográficos
Conama	Conselho Nacional do Meio Ambiente
DNPM	Departamento Nacional da Produção Mineral
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
EOSDIS	<i>Earth Observing System Data and Information System</i>
GB	<i>Gigabyte</i>
GBDOA	<i>Geospatial Big Data Open Access</i>
GHz	<i>Gigahertz</i>
GPS	<i>Global Positioning System</i>
Grid	Grade retangular regular de valores
ha	<i>Hectare</i>
HD	<i>Hard Disk</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IFBaiano	Instituto Federal de Educação, Ciência e Tecnologia Baiano
ITP	Instituto de Pesquisas Tecnológicas de São Paulo
Landsat	<i>Land Remote Sensing Satellite</i>
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MSS	<i>Multispectral Scanner System</i>
ONG	Organização não governamental
NGA	<i>National Geospatial-Intelligence Agency</i>
PB	<i>Petabyte</i>
RAM	<i>Random Access Memory</i>
SEI	Superintendência de Estudos Econômicos e Sociais da Bahia
SIG	Sistema de Informação Geográfica
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SRTM	<i>Shuttle Radar Topography Mission</i>

TB	<i>Terabyte</i>
TM	<i>Thematic Mapper</i>
VNIR	<i>Visible and Near-Infrared</i>
WGS	<i>World Geodetic System</i>

SUMÁRIO

1 INTRODUÇÃO	13
2 REFERENCIAL TEÓRICO	17
2.1 Exploração de petróleo e gás <i>onshore</i> na Bahia	17
2.2 Geoprocessamento e sensoriamento remoto	19
2.2.1 Álgebra de mapas	21
2.2.2 Análise de decisão multicritério baseada em SIG	22
2.2.3 Classificação de imagens	26
2.3 Favorabilidade à recomposição florestal	32
2.3.1 Metodologia utilizada por Seabra (2012)	33
2.3.2 Metodologia utilizada por Baylão Júnior (2014)	36
2.4 <i>Geospatial big data</i>	38
2.4.1 MapBiomass	40
2.4.2 <i>Shuttle Radar Topography Mission</i>	43
2.4.3 <i>Advanced Land Observing Satellite</i>	45
2.4.5 <i>WorldClim</i>	46
3 MATERIAIS E MÉTODOS	47
3.1 Local de estudo	47
3.2 Materiais	49
3.3 Métodos	50
3.3.1 Modelo digital de elevação	52
3.3.1 Mapa de favorabilidade à recomposição florestal	54
4 ANÁLISES E RESULTADOS	58
4.1 Comparação dos modelos digitais de elevação	58
4.2 Mapa de favorabilidade à recomposição florestal e características das regiões candidatas ao reflorestamento	71
5 CONCLUSÃO	86

6 CONSIDERAÇÕES FINAIS	89
REFERÊNCIAS	92
APÊNDICES	104
APÊNDICE A – Questionário de pesquisa com especialistas	104

1 INTRODUÇÃO

Nas últimas décadas, o cenário mundial de exploração *onshore* (em regiões continentais) de petróleo e gás natural alterou-se em função da intensificação de jazidas em regiões predominantemente tropicais. Essas regiões mostram-se muito mais suscetíveis à degradação em função de características intrínsecas à exploração desses minerais, isso porque as jazidas acontecem em regiões extensas do continente e são exploradas com auxílio de uma rede densa de poços.

Segundo Barbosa (2017), dentre os impactos gerados pela atividade minerária, podem ser citados a modificação do relevo, a degradação do solo e da biodiversidade, e o solo remanescente com baixo teor de matéria orgânica; sendo que esses impactos perduram inclusive após o término da atividade quando não são empregadas técnicas adequadas de operação e controle. Além disso, devido à ramificação da exploração, multiplicam-se os relacionamentos de impactos ambientais. Impactos antrópicos, derivados da produção de alimentos ou da urbanização, podem associar-se a impactos derivados de etapas da exploração de petróleo e gás e disparar processos muito mais graves de degradação.

É sabido que as atividades de mineração podem ser citadas como um dos fatores que frequentemente causam mudanças dramáticas nas paisagens, particularmente nos locais em seu entorno, onde a recomposição florestal é importante para minimizar e mitigar os efeitos ambientais e assim permitir novos usos da terra (AL-RUZOUQ; AL RAWASHDEH, 2014). Como forma de diminuir esses impactos, a resolução Conama nº 237/97 estabelece a necessidade da formulação de um plano de recuperação de áreas degradadas nas áreas onde ocorre exploração de minério (BRASIL, 1997). Ressalte-se que a Lei nº 9.985, de 18 de julho de 2000, em seu artigo 2º, define recuperação como sendo a restituição de um ecossistema ou de uma população silvestre degradada a uma condição não degradada, que pode ser diferente de sua condição original; e restauração como sendo a restituição de um ecossistema ou de uma população silvestre degradada o mais próximo possível da sua condição original (BRASIL, 2000).

Dentre as atividades desenvolvidas visando à recuperação da área degradada, tem-se a recomposição florestal, que consiste no plantio de vegetação nativa de determinada região a fim de recompor o que foi desmatado. De acordo com Seabra (2012), uma área considerada favorável à recuperação florestal apresenta

características abióticas¹, bióticas² e socioeconômicas, que oferecem boas condições para que ocorra o processo de recuperação florestal.

No entanto, nas atividades de extração de petróleo e gás, a extensão característica das áreas de exploração, e, por consequência, das áreas passíveis a degradação, traz uma problemática relacionada as atividades de recuperação, visto que para o sucesso em sua execução há a necessidade de realizar um bom planejamento. Como subsídio para esse planejamento, é preciso dispor de dados que retratem as características da área com fidedignidade, mas levantamentos em campo de grandes áreas tendem a ser mais demorados e, conseqüentemente, mais dispendiosos. Essa problemática agrava-se em regiões tropicais, onde as características de clima e vegetação tornam ainda mais difíceis e onerosas a execução de observações de campo.

Embora a escolha estratégica de áreas mais favoráveis para iniciar o processo de recuperação seja um facilitador para o sucesso da atividade, essa escolha demanda conhecimento da área e das características do espaço geográfico, um levantamento de dados custoso e de difícil sistematização por técnicas diretas (observação *in loco*). Como alternativa a esse problema relacionado ao uso de técnicas de coleta direta, existem as técnicas de sensoriamento remoto do ambiente, capazes de propiciar cobertura de extensas regiões de forma sistemática.

Hoje, é possível contar com um universo muito grande de informação remota em escala global disponível no chamado *geospatial big data*. Li *et al.* (2016) entendem que o termo *big data* pode ser definido de forma geral como um conjunto de dados que possui grandes volumes de dados. Segundo Lee e Kang (2015), os dados geoespaciais sempre foram *big data* e, de acordo com Li (2019), o termo *geospatial big data* refere-se a um tipo específico de *big data* que contém informações de localização. Ressalta-se que por volta dos anos 2000 estimava-se que cerca de 80% dos dados digitais gerados possuíam uma referência geoespacial (MACEACHREN & KRAAK, 2001)

Segundo Robinson *et al.* (2017), o *geospatial big data* apresenta um novo conjunto de desafios e oportunidades para pesquisadores cartográficos, que precisam focar seus esforços contemporâneos em um trabalho que se conecta a disciplinas externas e se baseia em problemas que são importantes para a humanidade e sua

¹ relacionadas aos aspectos físicos, químicos, físico-químicos ou geológicos do ambiente.

² relacionadas às comunidades vivas do ecossistema.

sustentabilidade. Nesse contexto, destaca-se a importância da utilização desses dados com o objetivo de buscar novas respostas para questões atuais que demandam diferentes abordagens para sua resolução.

Vários trabalhos vêm empregando análises espaciais através de dados oriundos de sensoriamento remoto com o objetivo de auxiliar em decisões estratégicas sobre fenômenos relacionados ao espaço geográfico. Florenzano (2002) destaca que o uso do sensoriamento remoto permite o estudo tanto dos fenômenos naturais dinâmicos do meio ambiente como dos fenômenos antrópicos.

Portanto, é possível compreender que o uso do *geospatial big data* associado a técnicas de análises espaciais pode trazer grandes benefícios para o estabelecimento do processo de recomposição florestal, pois facilita a identificação de áreas potencialmente mais favoráveis. Considerando que o conhecimento da distribuição espacial da favorabilidade à recomposição florestal é importante para definir quais são as estratégias que serão adotadas para garantir a realização de um projeto de recuperação mais eficiente e eficaz, tem-se a ideia central desta pesquisa, que visa verificar a viabilidade da obtenção dessas informações com o uso do *geospatial big data*.

Desta forma, foi trabalhada a seguinte hipótese: é possível gerar um mapa de favorabilidade à recomposição florestal em zonas tropicais degradadas por exploração de petróleo e gás *onshore* com base em dados *geospatial big data open access* (GBDOA). O objetivo geral desta pesquisa é propor uma metodologia para avaliação da favorabilidade à recomposição florestal com uso de GBDOA.

De forma específica, pretendeu-se:

- a. analisar os modelos digitais de elevação do ALOS, ASTER e SRTM;
- b. gerar um mapa de favorabilidade a recomposição florestal para o campo de Água Grande, que fica entre os municípios de Catu e Pojuca, no estado da Bahia.
- c. identificar critérios preferenciais para hierarquização de regiões mais ou menos favoráveis ao reflorestamento e analisar as características espaciais e atributos das regiões candidatas ao reflorestamento.

Esta pesquisa é dividida em outras cinco seções, além desta introdução. Na segunda seção, é apresentada toda a fundamentação teórica necessária para facilitar a compreensão do trabalho, sendo realizada uma contextualização sobre a

exploração de petróleo e gás *onshore* na Bahia seguida de uma abordagem sobre a temática do geoprocessamento e sensoriamento remoto com foco nas especificidades mais ativamente utilizadas na metodologia, que são a álgebra de mapas, a análise de decisão multicritério baseada em SIG e a classificação de imagens. Ainda nesta segunda seção é abordada a questão da favorabilidade à recomposição florestal e o conceito de *geospatial big data*, com uma breve descrição dos dados utilizados. Na seção seguinte é descrito o procedimento metodológico utilizado e como ocorreu o desenvolvimento prático da pesquisa, apresenta-se a área de estudo, os dados, equipamentos e softwares utilizados e, também, são detalhadas as etapas e procedimentos realizados para atingir cada um dos objetivos propostos. Na quarta seção tem-se a apresentação dos resultados alcançados, sendo expostas as observações realizadas a partir da comparação entre os modelos digitais de elevação e uma análise sobre o mapa de favorabilidade à recomposição florestal obtido, bem como das características das regiões candidatas ao reflorestamento. Em seguida são discutidas as conclusões obtidas pela análise dos resultados e ,por fim, na última seção são apresentadas as considerações finais.

2 REFERENCIAL TEÓRICO

2.1 Exploração de petróleo e gás *onshore* na Bahia

A Bahia é o estado precursor na história da exploração de petróleo no Brasil. De acordo com informações do portal da Petrobras na internet (PETROBRAS, 2006a), a primeira descoberta de petróleo no país foi realizada pela Divisão de Fomento da Produção Mineral, órgão do Departamento Nacional da Produção Mineral (DNPM), em 21 de março de 1939, no poço de petróleo DNPM-163, localizado em Lobato, no Recôncavo Baiano.

Essa descoberta, embora considerada subcomercial, foi a catalizadora para novas prospecções de espaços para exploração, culminando na criação do primeiro campo comercial de petróleo *onshore* do país na cidade de Candeias, Bahia, em 1941 (PETROBRAS, 2006b). Nesse período, ainda foram descobertos os campos de gás natural de Aratu e de petróleo em Itaparica (PETROBRAS, 2006a). Além disso, visando resguardar os direitos na União sobre a propriedade de todas as jazidas de petróleo e gás natural, foi emitido o Decreto-Lei nº 3.236, de 7 de maio de 1941, que institui o regime legal das jazidas de petróleo e gases naturais, de rochas betuminosas e pirobetuminosas e dá outras providências (BRASIL, 1941).

Segundo os dados da Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP), até o fim de 2019, dos 380 campos em fase de produção no Brasil, 279 eram campos terrestres (ANP, 2020). Esses campos de produção estão distribuídos em bacias sedimentares e, dentre essas bacias, as mais produtivas para a produção terrestre de petróleo são a bacia do Recôncavo, localizada no centro-leste do estado da Bahia, e a bacia do Solimões, localizada a sudoeste de Manaus (AM). De acordo com a Coordenação de Fomento à Mineração, Petróleo e Gás, a Bahia é o segundo maior produtor de petróleo e o terceiro maior de gás natural *onshore* do Brasil (BAHIA, 2019).

As informações presentes no Anuário Estatístico Brasileiro do Petróleo, Gás Natural e Biocombustíveis 2020 demonstram que, em 31 de dezembro de 2019, existiam na Bahia 99 campos na fase de produção, desse total 97 eram campos terrestres e apenas 2 eram campos marítimos (ANP, 2020). Salienta-se que qualquer atividade que o ser humano exerça com relação, direta ou indireta, ao uso de recursos naturais provoca um impacto ambiental. Martins *et al.* (2015, p. 70) afirmam que:

A exploração e produção de petróleo, como outras atividades econômicas que utilizam recursos naturais, apresentam impactos ambientais positivos e negativos. Todas as etapas de produção da indústria petrolífera, desde a perfuração ao refino, causam impactos ao meio ambiente. Ao se falar em impacto ambiental, é comum que seja feita uma relação direta com grandes desastres ambientais acarretados pelo rompimento de oleodutos ou poços marítimos, os quais são sempre expostos pela mídia através de imagens de aves agonizando cobertas de óleo e peixes mortos, por exemplo. Porém, sabemos que o impacto ambiental tanto pode ser de caráter negativo quanto positivo. Não se pode negar o volume de negócios que proporcionados com o desenvolvimento da exploração e produção de petróleo, impulsionando toda a cadeia de bens e serviços, trazendo tecnologia, capacitação e grandes oportunidades de empregos e rendas.

Entende-se impacto ambiental como modificação do meio ambiente, tanto adversa como benéfica, total ou parcialmente, resultante de aspectos ambientais de uma organização (ABNT, 2015). Deve-se considerar também o disposto pelo Conselho Nacional do Meio Ambiente (Conama), através da resolução 001, de 23 de janeiro de 1986 (BRASIL, 1986), que aponta:

Artigo 1º - Para efeito desta Resolução, considera-se impacto ambiental qualquer alteração das propriedades físicas, químicas e biológicas do meio ambiente, causada por qualquer forma de matéria ou energia resultante das atividades humanas que, direta ou indiretamente, afetam:

- I - a saúde, a segurança e o bem-estar da população;
- II - as atividades sociais e econômicas;
- III - a biota;
- IV - as condições estéticas e sanitárias do meio ambiente;
- V - a qualidade dos recursos ambientais.

Outro aspecto a se considerar trata da definição do que vem a ser degradação ambiental. Dessa maneira, deve-se observar a definição da Lei nº 6.938, de 31 de agosto de 1981, que dispõe sobre a Política Nacional do Meio Ambiente, seus fins e mecanismos de formulação e aplicação, e dá outras providências, mais precisamente em seu artigo 3º, inciso II, que define: “degradação da qualidade ambiental, a alteração adversa das características do meio ambiente” (BRASIL, 1981). Depreende-se que legalmente os termos impacto e degradação são usados com o mesmo sentido.

De acordo com Aquino e Costa (2011, p. 3):

Esses riscos ambientais que podem advir da atividade de perfuração de um poço de petróleo podem ser identificados como os agentes físicos, químicos, biológicos, ergonômicos e de acidentes/mecânicos [...]. Os danos também se estendem à fauna e flora devido à remoção da vegetação no local onde será perfurado o poço; erosão provocada pela destruição da vegetação; agressões ao meio ambiente causadas pelos resíduos dos fluidos de perfuração, fragmentos das rochas (cascalhos) perfuradas dispostos em diques de perfuração e/ou percolação de contaminantes para lençóis freáticos; e contaminação dos lençóis freáticos e aquíferos subterrâneos, causada por perdas dos fluidos de perfuração para as formações geológicas durante a perfuração.

Os impactos decorrentes da operação em condições normais das atividades (instalação, operação e desativação da atividade) são denominados efetivos ou reais, já os impactos decorrentes de um eventual vazamento acidental de óleo são chamados potenciais (AECOM, 2011). Entretanto, ressalta-se que a abordagem utilizada neste trabalho tem foco na ocorrência de degradação física, mais especificamente a supressão de vegetação e ocorrência de processos erosivos.

2.2 Geoprocessamento e sensoriamento remoto

O termo geoprocessamento está relacionado com a área do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento e análise de informações geográficas (D'ALGE, 2004; PIROLI, 2010). Segundo Caldas (2006), o geoprocessamento constitui, hoje, uma ferramenta primordial para as etapas de levantamento e processamento de informações relacionadas a questões ambientais, visto que, utilizando programas específicos, é possível efetuar interpolações ou sobreposições de dados levantados ou já existentes, gerando de forma rápida e eficiente uma série de novas informações relevantes.

Os instrumentos computacionais do geoprocessamento, chamados de Sistemas de Informações Geográficas (SIGs), permitem a realização de análises complexas ao integrar dados de diversas fontes e ao criar bancos de dados georreferenciados, tornando possível ainda a automatização da produção de documentos cartográficos (CÂMARA; MEDEIROS, 1998). De acordo com Câmara *et al.* (2004), dentre os componentes de um SIG, tem-se:

- a) interface com o usuário;
- b) entrada e integração de dados;
- c) funções de processamento gráfico e de imagens;
- d) visualização e plotagem;
- e) armazenamento e recuperação de dados.

Os sistemas de informação geográficas têm sido muito utilizados em aplicações ambientais e uma das grandes vantagens é permitir a sobreposição de informações para gerar novas informações. Para Florenzano (2002) as técnicas modernas de captação de imagens associadas aos novos sistemas de informações geográficas facilitam a obtenção de uma grande quantidade de dados, muitas vezes impossíveis de serem obtidos sem a utilização dessas técnicas.

Fitz (2008) define o SIG como um conjunto poderoso de ferramentas computacionais que permitem a integração de dados, equipamentos e pessoas com a finalidade de coletar, armazenar, recuperar, transformar, visualizar e analisar dados sobre o mundo real, que estejam espacialmente referenciados a um sistema de coordenadas, para um objetivo específico. Para Teixeira, Moretti e Christofolletti (1992), é um sistema que utiliza uma base de dados computadorizada que contém informação espacial, sobre a qual atua uma série de operadores espaciais.

Entre as contribuições mais relevantes da modelagem de dados em geoprocessamento, estão: a integração das imagens de sensoriamento remoto e modelos digitais de elevação com mapas temáticos; suporte para representações geométricas múltiplas de uma mesma entidade do mundo real; e coexistência de representações vetorial e matricial num mesmo sistema (CÂMARA; MEDEIROS, 1998). As imagens de sensores remotos são cada vez mais utilizadas para elaboração de diferentes tipos de mapas temáticos após passarem por um processo de interpretação (FLORENZANO, 2002).

O sensoriamento remoto pode ser definido como uma técnica de medição ou aquisição de informações referentes a natureza, propriedade e estado de um objeto ou fenômeno, através de um dispositivo que faz a captação e o registro a energia refletida ou emitida por esses alvos sem que esteja em contato físico com eles (JENSEN, 2007; NOVO; PONZONI, 2001; SILVA; SERGANTINE, 2015). Segundo Câmara e Medeiros (1998), nos países de grande dimensão e com carência de informações adequadas para tomada de decisões sobre problemas urbanos e ambientais, o geoprocessamento apresenta um enorme potencial, principalmente se

baseado em tecnologias de custo relativamente baixo, em que o conhecimento é adquirido localmente.

Atualmente, é cada vez maior o volume de dados oriundos do sensoriamento remoto disponíveis para serem utilizados. De acordo com o relatório métrico anual de 2019 do Sistema de Observação e Dados do Sistema de Observação da Terra da Nasa (EOSDIS), a essa época o órgão gerenciava mais de 33 petabytes (PB) de dados, sendo adicionados cerca de 20 terabytes (TB) em seus arquivos todos os dias (NASA, 2019). Para exemplificar, Blumenfeld (2015) elucida ainda que 1 PB é equivalente a cerca de 20 milhões de arquivos de quatro gavetas preenchidos com texto e que, mesmo quando se vai para a próxima ordem mais baixa de magnitude de dados – o terabyte –, ainda estamos lidando com uma quantidade imensa de dados.

2.2.1 Álgebra de mapas

O termo álgebra de mapas é bastante antigo na literatura e, de acordo com Berry (1987), é similar a álgebra tradicional, onde as operações primitivas, como, por exemplo, adição, subtração ou exponenciação, são sequenciadas de forma lógica para variáveis específicas a fim de formar as equações. No entanto, na álgebra de mapas, as variáveis são mapas inteiros representados por conjuntos de números organizados. Para Barbosa (1997), o termo é utilizado para denotar o conjunto de operadores que manipulam campos geográficos, como imagens, mapas temáticos e modelos de terreno.

Carvalho e Silva (2008) explicam que o processo consiste na realização de operações primitivas lógicas sobre um conjunto de mapas de uma base cartográfica comum, onde cada mapa é uma variável sujeita a operações matemáticas tradicionais e, como é realizada em estrutura matricial, a unidade básica de processamento é o pixel. Tomlin (1994) ressalta que todos os dados associados a uma determinada área geográfica de interesse são armazenados na forma de um mapa de fator único em que cada localização está associada a uma característica registrada, sendo que todos os mapas de entrada foram considerados para representar a mesma área geográfica, na mesma escala, orientação e projeção.

Segundo Barbosa *et al.* (1998), isso ocorre através de uma linguagem especializada para realizar operações, que tem tanto um sentido matemático quanto cartográfico e espacial, sendo que essas operações podem ser pontuais (tem-se por

resultado um mapa que é função apenas dos valores dos mapas de entrada), de vizinhança (o resultado é um mapa cujos valores dependem da vizinhança da localização considerada) ou zonais (quando considera-se uma região específica de um mapa de entrada com restrições dadas por outro mapa). Dadas as variáveis algébricas do mapa que representa as características geográficas com valores numéricos, é possível processar essas características com funções matemáticas (TOMLIN, 1994). Cavazzana *et al.* (2018) destacam a álgebra de mapas como a ferramenta ideal para realizar análises sobre um banco de dados geográficos contendo informações do ambiente, pois permite que os dados sejam alterados e recalculados conforme o surgimento de novas demandas.

2.2.2 Análise de decisão multicritério baseada em SIG

A análise de decisão multicritério é uma abordagem estruturada para analisar problemas com vários critérios e alternativas com o objetivo de ajudar na realização de tomadas de decisões consistentes, ao observar os fatores objetivos e subjetivos em consideração (MUSTAJOJKI; HÄMÄLÄINEN, 2007). Já os sistemas de informação geográfica são capazes de gerenciar informações, possibilitando a integração de várias camadas de informações e, a partir dessas, gerar novas camadas (SAHNOUN *et al.*, 2011). Segundo Cowen (1988), o SIG é frequentemente reconhecido como um sistema de apoio à decisão que envolve a integração de dados espacialmente referenciados em um ambiente de solução de problemas. Dessa forma, a integração de sistemas de informação geográfica e de métodos de decisão multicritério vem proporcionando inúmeros benefícios para a resolução de problemas de planejamento e gerenciamento do mundo real (ZAMBON *et al.*, 2005).


As técnicas de análise multicritério, juntamente com os sistemas de informações geográficas, podem ajudar a categorizar, examinar e organizar adequadamente as informações acessíveis sobre possibilidades de escolha para o planejamento espacial (ZABIHI *et al.*, 2019). Os problemas de decisão espacial normalmente envolvem um grande conjunto de alternativas viáveis e critérios de avaliação múltiplos, conflitantes e incomensuráveis (MALCZEWSKI, 2007). O método de análise de decisão multicritério baseado em SIG é um sistema inteligente que utiliza e converte dados espaciais e não espaciais em informações valiosas, que, com o

juízo de valor do tomador de decisão, pode ser usado para tomar uma decisão crítica (ZABIHI *et al.*, 2019).

Segundo Malczewski (2007), é possível distinguir três dicotomias dentro da análise de decisão multicritério baseada em SIG (ver figura 1). São elas:

- a) análise de decisão multiobjetivo *versus* análise de decisão com vários atributos: o autor elucida que critério é um termo genérico que inclui o conceito de atributo e objetivo, portanto a análise de decisão multicritério é usada como o termo geral, que inclui tanto a tomada de decisão multiatributo (problemas discretos, que possuem um número limitado e predeterminado de alternativas) quanto a multiobjetivo (problemas contínuos, em que a melhor solução pode ser encontrada em qualquer lugar da região de soluções viáveis);
- b) tomada de decisão individual *versus* tomada de decisão de grupo: de acordo com o autor, se houver uma única estrutura de preferência por objetivos, o problema será chamado de um problema de único tomador de decisão, independentemente do número de indivíduos realmente envolvidos. Por outro lado, se os grupos de interesse são caracterizados por diferentes estruturas de preferência por objetivos, o problema passa a ser o da tomada de decisões em grupo;
- c) decisões sob certeza *versus* decisões sob incerteza: segundo o autor, se o tomador de decisão possui perfeito conhecimento do ambiente de decisão, a decisão é tomada sob condições de certeza (tomada de decisão determinística). Mas quando a decisão envolve alguns aspectos desconhecidos ou muito difíceis de prever, ocorre a decisão em condições de incerteza, que pode ser uma decisão probabilística ou difusa. No entanto, em geral, as decisões espaciais são modeladas como ocorrendo sob uma condição de certeza, seja devido à insuficiência de dados ou porque a incerteza é tão remota que pode ser desconsiderada.

Figura 1 - Classificações dos problemas de tomadas de decisões multicritérios



Fonte: Adaptado de Malczewski (2007)

De acordo com Drobne e Lisec (2009), nos casos dos problemas de decisões espaciais, os atributos são propriedades das entidades; mais especificamente, um atributo é uma quantidade ou qualidade mensurável de uma entidade geográfica ou da relação entre entidades geográficas. Lai e Hopkins (1989) elencaram as etapas a serem realizadas em alguns dos métodos mais utilizados na análise de decisão multiatributo, conforme demonstrado no quadro 1, a seguir.

Quadro 1 - As etapas de avaliação nos métodos

Teoria da utilidade multiatributo
1) Estimar funções de valor unidimensionais.
2) Dadas as funções de valor unidimensionais, obter a escala para os atributos.
3) Aplicar a regra de decisão da função de valor para classificar alternativas.
Ponderação e classificação
1) Atribuir pesos de importância relativa aos atributos.
2) Selecionar funções de transformação unidimensionais para transformar as pontuações brutas em pontuações.
3) Aplicar a regra de decisão aditiva para classificar as alternativas.
Processo analítico hierárquico
1) Construir matrizes de comparação aos pares de alternativas em relação aos atributos e de atributos em relação ao foco geral.
2) Derivar pesos transformados das matrizes por meio da abordagem do vetor próprio.
3) Aplicar a regra de decisão aditiva para classificar alternativas.
Análise de concordância
1) Atribuir pesos de importância relativa aos atributos.
2) Construir a matriz de concordância.
3) Transformar a matriz de concordância em uma matriz de dissimilaridade.
4) Aplicar a técnica de dimensionamento multidimensional para procurar uma configuração mais adequada.
5) Classificar as alternativas de acordo com a configuração.
Cálculo de alternativas equivalentes
1) Eliminar alternativas dominadas.
2) Selecionar uma alternativa promissora com a maior probabilidade de ser dominante.
3) Selecionar outra alternativa a ser comparada com a alternativa promissora
4) Fazer julgamentos de escolhas pareadas entre os atributos da alternativa promissora, de modo que uma alternativa domine as outras.
5) Deletar alternativas dominadas.
6) Parar quando sobrar apenas uma alternativa, caso contrário, repetir os passos.

Fonte: Lai; Hopkins (1989)

As alternativas são avaliadas por um número de indivíduos (tomadores de decisão ou grupos de interesse), sendo tipicamente caracterizados por preferências quanto à importância relativa de critérios com base nos quais as alternativas são avaliadas (MALCZEWSKI, 2007). Moreira *et al.* (2004) destacam que, do ponto de vista conceitual, os modelos gerados podem ser vistos como uma combinação do conjunto de dados de entrada através de uma função que pode tomar muitas formas diferentes e têm seus relacionamentos expressados com base no conhecimento teórico ou empírico. Os autores ressaltam ainda que nos modelos teóricos são utilizados princípios físicos e químicos e equações da natureza. Já nos modelos

empíricos, são utilizados relacionamentos estatísticos ou heurísticos, sendo que os modelos empíricos podem ser divididos em modelos baseados em conhecimento (que são implementados a partir da opinião de especialistas) ou modelos baseados em dados (que são implementados a partir de um conjunto de dados observados).

2.2.3 Classificação de imagens

A classificação de imagens consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe (VENTURIERI; SANTOS, 1998). O pixel é atribuído a uma classe se satisfaz um determinado conjunto de regras para caber nessa classe. Se o usuário for capaz de separar as classes com base nos dados de treinamento, então as classes são conhecidas, do contrário, são desconhecidas (THAKUR; MAHESHWARI, 2017).

Segundo Lu e Weng (2007), a pesquisa na área do sensoriamento remoto com foco na classificação de imagens há muito tempo vem atraindo a atenção da comunidade pois os resultados da classificação são a base para muitas aplicações ambientais e socioeconômicas. Dey *et al.* (2014), ressaltam que o principal objetivo da classificação de imagens é a identificação precisa das características presentes na imagem. Thakur e Maheshwari (2017) reafirmam essa ideia ao declararem que a classificação de imagens é um passo importante para a identificação de objetos e análises das imagens.

Recorre-se à classificação de imagens quando há a necessidade de obter padrões dos tipos de superfície terrestre por intermédio da extração de informações importantes nas imagens de forma automatizada para a criação de mapas temáticos na região de interesse (MONTEIRO, 2015). Essa automatização pode ser realizada de diferentes formas, e no quadro a seguir é demonstrada a taxonomia dos métodos de classificação de imagens.

Quadro 2 - Taxonomia dos métodos de classificação de imagens

Critérios	Categorias	Características
Uso ou não de amostras de treinamento	Classificação supervisionada	As classes de cobertura do solo são definidas. São usados dados de referência como amostras de treinamento. As assinaturas geradas a partir das amostras de treinamento são usadas para treinar o classificador para classificar os dados espectrais em um mapa temático.
	Classificação não supervisionada	Algoritmos baseados em cluster são usados para particionar a imagem espectral em uma série de classes espectrais com base nas informações estatísticas inerentes à imagem. Nenhuma definição prévia das classes é usada. O analista é responsável por rotular e mesclar as classes espectrais em classes significativas.
Uso ou não de parâmetros como vetor médio e matriz de covariância	Classificação paramétrica	A distribuição gaussiana é assumida. Os parâmetros (por exemplos, vetor médio e matriz de covariância) são frequentemente gerados a partir de amostras de treinamento.
	Classificação não paramétrica	Nenhuma suposição sobre os dados é necessária. Classificadores não paramétricos não empregam parâmetros estatísticos para calcular a separação de classes.
Tipo de informação de pixel utilizada	Classificação por pixel	Classificadores tradicionais normalmente desenvolvem uma assinatura combinando os espectros de todos os pixels do conjunto de treinamento de um determinado recurso. A assinatura resultante contém as contribuições de todos os materiais presentes nos pixels do conjunto de treinamento, ignorando os problemas de pixels mistos.
	Classificação subpixel	O valor espectral de cada pixel é considerado uma combinação linear ou não linear de materiais puros definidos (ou membros finais), fornecendo uma associação proporcional de cada pixel para cada membro final.
Tipo de informação de pixel utilizada	Classificação orientada a objeto	A segmentação de imagens mescla pixels em objetos e a classificação é realizada com base nos objetos, em vez de um pixel individual. Nenhum dado de vetorial em SIG é utilizado.
	Classificação por campo	O SIG desempenha um papel importante na classificação por campo, integrando dados <i>raster</i> e vetoriais em uma classificação. Os dados vetoriais são frequentemente usados para subdividir uma imagem em parcelas, e a classificação é baseada nas parcelas, evitando a variação espectral inerente a uma mesma classe.


Decisão definitiva ou não sobre o pertencimento a uma classe como dado de saída	Classificação pela lógica clássica	Toma-se uma decisão definitiva sobre a classe de cobertura do solo em que cada pixel é alocado para uma única classe.
	Classificação pela lógica fuzzy	Fornece-se para cada pixel uma medida do grau de similaridade de cada classe.
Uso ou não de informação espacial	Classificação espectral	A informação espectral pura é usada na classificação de imagens.
	Classificação contextual	A informação do pixel espacialmente vizinho é usada na classificação da imagem.
	Classificação espectro contextual	A informação espectral e espacial é usada na classificação. Classificadores paramétricos ou não paramétricos são usados para gerar imagens de classificação inicial e, em seguida, classificadores contextuais são implementados na imagem classificada.

Fonte: Adaptado de Lu e Weng (2007)

Vale *et al.* (2018) advertem que, embora o processo de classificação de imagens seja, aparentemente, um procedimento simples, existem muitos fatores que podem interferir na qualidade dos resultados. Portanto, a classificação de imagens deve ser vista como um processo estatístico e probabilístico que tenta ao máximo aproximar o mapa digital à realidade. As principais etapas da classificação de imagem podem incluir a determinação de um sistema de classificação adequado, seleção de amostras de treinamento, pré-processamento de imagem, extração de informações, seleção de abordagens de classificação adequadas, processamento de pós-classificação e avaliação de precisão (LU; WENG, 2007).

Na avaliação de precisão, o produto é comparado com dados de maior qualidade (dados de referência). Como geralmente é impraticável coletar dados de referência para toda a região de estudo, os dados de referência comumente são coletados por meio de uma abordagem baseada em amostra a fim de permitir uma interpretação cuidadosa de áreas específicas do mapa (FINEGOLD ET AL., 2016). Na figura a seguir, pode ser visualizado um exemplo dos principais esquemas de amostragem utilizados na avaliação de precisão, bem como suas vantagens e desvantagens.

Figura 2 - Principais esquemas de amostragem utilizados



Fonte: Banko (1998).

Banko (1998) afirma que, embora a amostragem aleatória seja estatisticamente segura, ela pode não ser adequada para pequenas áreas, por gerar a necessidade de um menor número de pontos e haver um maior risco de que algumas áreas não sejam representadas. Nesse sentido, a amostragem aleatória estratificada garante a representatividade de todas as áreas por estabelecer uma quantidade mínima de pontos para cada área, no entanto, demanda a necessidade de um conhecimento prévio sobre a distribuição dos dados. Já a amostragem sistemática tem como maior benefício a distribuição uniforme dos dados, porém não é muito adequada para dados que apresentem algum tipo de autocorrelação espacial. Por fim, tem-se a amostragem em grupo que apresenta uma boa relação de custo-benefício, mas pode não ser tão adequada quando há muita homogeneidade entre os pixels pertencentes a um mesmo grupo.

De acordo com Foody (2002), muitas metodologias de avaliação de precisão da classificação de uma imagem foram discutidas na literatura de sensoriamento remoto. No entanto, o mais amplamente divulgado e usado pode ser derivado da matriz de confusão ou matriz de erro, que é a abordagem mais comumente empregada para avaliar a classificação por pixel. Congalton (2000) ressalta que, desde a década de 1980, a matriz de erro tornou-se uma ferramenta comum para representar a acurácia de categoriais individuais de um mapa. Segundo Visa *et al.* (2011), uma matriz de confusão de tamanho $n \times n$ associada a um classificador mostra

a classificação prevista e real, onde n é o número de classes diferentes, sendo demonstrado, no quadro 3 a seguir, um exemplo de uma matriz de confusão para $n = 2$, cujas entradas têm os seguintes significados:

- I. A é o número de previsões positivas corretas (verdadeiros positivos);
- II. B é o número de previsões negativas incorretas (falsos negativos);
- III. C é o número de previsões positivas incorretas (falsos positivos);
- IV. D é o número de previsões negativas corretas (verdadeiros negativos).

Quadro 3 - Matriz de confusão para um problema de classificação com duas classes

	Positivo previsto	Negativo previsto
Positivo de referência	A	B
Negativo de referência	C	D

Fonte: Visa *et al.* (2011).

Santra e Christy (2012) afirmam que muitos termos podem ser derivados da matriz de confusão. Dentre esses, Ferreira, Dantas e Morais (2007) citam alguns dos mais famosos, descritos a seguir:

- a) Exatidão global (G) – Proporção entre o número total de elementos sobre o número de elementos que foram classificados corretamente, que pode ser determinada pela equação:

$$G = \frac{\sum_{i=1}^c X_{ii}}{n} \quad (1)$$

- b) Erro de omissão (Eo) - Proporção de elementos que pertencem a uma classe e foram classificados incorretamente em outras classes, que pode ser determinada pela equação:

$$E_o = \frac{X_{i+} - X_{ii}}{X_{i+}} \quad (2)$$

- c) Erro de comissão (Ec) - Proporção de elementos que não pertencem a uma classe e foram classificados incorretamente como pertencentes a esta classe, que pode ser determinada pela equação:

$$E_c = \frac{X_{+i} - X_{ii}}{X_{+i}} \quad (3)$$

- d) Índice kappa (k) - Estimativa da diferença entre a concordância dos dados de referência e a classificação automática, e a probabilidade desta concordância ser aleatória, que pode ser determinado pela equação:

$$k = \frac{n \sum_{i=1}^c X_{ii} - \sum_{i=1}^c X_{i+} X_{+i}}{n^2 - \sum_{i=1}^c X_{i+} X_{+i}} \quad (4)$$

Onde:

X_{ii} = elementos da diagonal principal na posição ii ;

n = soma total de elementos;

X_{i+} = soma total dos elementos da linha i ;

X_{+i} = soma total dos elementos da coluna i .

Com relação ao cálculo da exatidão global determinada com base na equação 1, previamente exposta, Santra e Christy (2012) ressaltam que essa pode não ser uma medida de desempenho adequada quando o número de casos de uma classe é muito maior do que o número de outra. Pois, por exemplo, ao supor um problema de classificação com duas classes em que haja 1.000 casos, sendo 995 deles pertencentes à classe X e apenas 5 positivos pertencentes à classe Y, se o sistema classificar todos eles como X, a precisão seria de 99,5%, embora o classificador tenha errado todos os casos pertencentes a Y.

Com relação aos valores aceitáveis para o índice kappa, Landis e Koch (1977) fizeram uma avaliação e subdivisão conforme quadro 4, a seguir.

Quadro 4 - Classificação para valores do índice kappa

Índice kappa	Qualidade
< 0.00	Péssimo
0.00 – 0.20	Muito ruim
0.21 – 0.40	Ruim
0.41 – 0.60	Moderado
0.61 – 0.80	Bom
0.81 – 1.00	Muito bom

Fonte: Landis e Koch (1977)

No entanto, os próprios autores deixaram claro que a classificação proposta se tratava de uma classificação arbitrária que serviria apenas como exemplo para gerar referências na discussão de um problema específico com o qual estavam trabalhando.

2.3 Favorabilidade à recomposição florestal

Seabra (2012) definiu favorabilidade à recomposição florestal como a capacidade do geossistema em restabelecer as condições estruturais e de funcionamento necessárias para que ocorra a recuperação de áreas degradadas. Dessa forma, o autor considera que uma área tida como favorável à recuperação florestal apresenta características abióticas, bióticas e socioeconômicas que oferecem boas condições para que ocorra o processo de recuperação florestal.

Nesta temática Lins (2011) analisou a favorabilidade para ocorrência de *Euterpe edulis Martius* identificando com base nas experiências registradas na literatura a relação e o grau de contribuição entre determinados parâmetros espaciais na qualidade de habitat para a manutenção das populações naturais da espécie. Na pesquisa a autora utilizou os seguintes parâmetros: tamanho do fragmento e estágio sucessional, proximidade à rede hidrográfica, altitude, curvatura, orientação da encosta, contraste de borda, proximidade entre os fragmentos florestais e proximidade da presença antrópica.

Freitas (2015) identificou áreas mais favoráveis para o cultivo do mogno-africano pela aplicação do método análise de multicritério. Para realizar a quantificação do grau de favorabilidade para o cultivo bem sucedido da espécie estudada foram consideradas as seguintes variáveis: temperatura, precipitação, pedologia, hidrografia, áreas prioritárias para recuperação e conservação além das unidades de conservação e declividade.

Já Teixeira (2018) estimou a favorabilidade de açazais nativos através da modelagem de distribuições de espécies, por meio dos métodos de pesos de evidência e análise multicritério. Para identificar os ambientes favoráveis a ocorrência da espécie-alvo do estudo a autora utilizou dados de vegetação, pedologia, precipitação anual, temperatura média anual, áreas sujeitas a inundação e áreas desmatadas, sendo que para cada classe das variáveis estudadas foi atribuída uma nota de 0 a 10 em função da sua importância para ocorrência da espécie.

Nos tópicos a seguir serão abordadas de forma mais detalhada as metodologias utilizadas por Seabra (2012) e Baylão Júnior (2014) que foram norteadoras para o desenvolvimento desta pesquisa.

2.3.1 Metodologia utilizada por Seabra (2012)

Na presente metodologia, o autor realizou a determinação da favorabilidade à recuperação florestal através de 16 indicadores que foram utilizados como base para a formulação do modelo de favorabilidade. Além disto, foi realizada também a análise da evolução do uso e cobertura da terra, bem como a determinação e delimitação de diferentes unidades de análise da paisagem.

Para a análise da evolução do uso e cobertura da terra na área de estudo, Seabra (2012) utilizou mapas, na escala 1:100.000, gerados pela técnica de classificação orientada a objetos. Para a geração destes mapas foram utilizadas imagens com resolução espacial de 30 metros dos anos de 1975, 1985, 1995 e 2010, sendo a mais antiga uma imagem do satélite *Landsat 4 MSS (Multispectral Scanner System)* e as demais do satélite *Landsat 5 TM (Thematic Mapper)*.

O autor observou que a representação dos elementos e componentes da paisagem constituem uma ferramenta importante para investigações ambientais, pois se apresenta como um instrumento essencial para a compreensão de aspectos relacionados à origem e à dinâmica dos geossistemas. A metodologia proposta por Seabra (2012) foi além de simples caracterização e espacialização desses fatores, pois também realizou uma análise das estruturas vertical, horizontal e vetorial da paisagem. Para tal finalidade foi feita a construção de gráficos e matrizes de relacionamento, da sobreposição de temas, da quantificação de atributos temáticos e de análises métricas dos componentes da paisagem. Em seguida, esses resultados foram incorporados ao Banco de Dados Geográficos (BDG), onde foram processados e utilizados na determinação da favorabilidade à recuperação florestal.

Para determinar a favorabilidade à recuperação florestal foi construído um modelo baseado em indicadores abióticos, bióticos e socioeconômicos da área de estudo. Esses indicadores foram utilizados para classificar as áreas segundo o seu grau de favorabilidade à recuperação através do uso de ferramentas de geoprocessamento. Os indicadores utilizados, bem como sua forma de determinação, podem ser vistos na figura 3, a seguir. Foram utilizados parâmetros relacionados a geologia, clima, geomorfologia, solos, declividade, hidrografia, vegetação e uso e ocupação do solo, com o objetivo de construir esses indicadores a fim de fornecer os subsídios necessários para a realização de diagnósticos e levantamentos que

possibilitem a classificação de unidades de paisagem segundo a sua favorabilidade à recuperação florestal.


Figura 3 - Indicadores utilizados pelo autor

Indicadores	Determinação
1 - Litologia	Questionário/Especialistas
2 - Solo	Questionário/Especialistas
3 - Clima	Questionário/Especialistas
4- Exposição ao Vento (orientação)	Questionário/Especialistas
5 - Exposição ao Sol	Questionário/Especialistas
6 - Forma do Terreno	Questionário/Especialistas
7 - Declividade	Questionário/Especialistas
8 - Altitude	Questionário/Especialistas
9 - Disponibilidade Hídrica Superficial	Questionário/Especialistas
10 - Histórico do Uso e Cobertura da Terra	Questionário/Especialistas
11 - Grau de Transformação Antrópica	Questionário/Especialistas
12 - Domínio Geomorfológico	Questionário/Especialistas
13 - Dimensão do Fragmento de Uso	Pesquisa Bibliográfica
14 - Proximidade com Fragmentos Florestais	Pesquisa Bibliográfica
15 - Pressão Populacional	Pesquisa Bibliográfica
16 - Proteção Legal	Pesquisa Bibliográfica

Fonte: Seabra (2012)

Definidos os indicadores, foram aplicados questionários a um grupo de especialistas e utilizou-se análise multicriterial, onde pesos e notas foram atribuídos para os temas e classes arrolados no modelo. Os indicadores 13, 14, 15 e 16 foram adicionados posteriormente e por isso suas notas e pesos foram atribuídas com base em pesquisa bibliográfica. Por fim, a favorabilidade foi mapeada a partir de uma grade retangular regular de valores (Grid), ou seja, em superfície contínua, e foi calculada para as unidades de paisagem (regiões, grupos e tipologias de paisagem). De forma resumida, a metodologia proposta pelo autor segue esquematizada no fluxograma a seguir (figura 4).

Figura 4 - Fluxograma da determinação de favorabilidade à recuperação florestal



Fonte: Seabra (2012)

Os resultados da análise da evolução do uso e cobertura da terra reforçaram a hipótese de que a proximidade e o contexto das áreas degradadas em relação às coberturas naturais são preponderantes para a ocorrência de recuperação florestal. O autor concluiu que, para a área de estudo, os processos de recuperação tendem a ocorrer mais facilmente nas "clareiras", nos vales intramontanhosos e nas bordas de grandes fragmentos florestais. Além disso, Seabra (2012) também percebeu que nas áreas em que o processo de desmatamento é mais recente a recuperação tende a

ocorrer com maior frequência, levando-o a concluir que as áreas de desmatamento recente têm maior favorabilidade à recuperação.

2.3.2 Metodologia utilizada por Baylão Júnior (2014)

O objetivo do trabalho de Baylão Júnior (2014) foi analisar a restauração florestal espontânea a partir dos efeitos de nucleação da *Guarea guidonia* (L.) Sleumer na vertente atlântica da Serra do Mar, Piraí, RJ, diante da importância dessa espécie como provável facilitadora da restauração florestal espontânea de ecossistemas perturbados. Nesse contexto, o trabalho foi dividido em três capítulos, sendo eles: capítulo 1, com a caracterização dos principais parâmetros físicos determinantes na sua distribuição espacial; capítulo 2, com a caracterização da composição florística e estrutural sob sua copa dentro de fragmento florestal originado a partir de pastagens abandonadas; e capítulo 3, com a quantificação da serrapilheira acumulada e da sua capacidade de retenção hídrica. Sendo que, no presente trabalho, a abordagem da revisão será limitada ao capítulo 1, capítulo ao qual a temática possui maior correção com a pesquisa desenvolvida.

Para caracterizar os principais parâmetros físicos determinantes na distribuição espacial da *G. guidonia*, o autor considerou espécies existentes na área de estudo com circunferência à altura do peito maiores que 90 cm e com a primeira ramificação do fuste ocorrendo até 2,00 m de altura como unidades amostrais. Esses critérios foram definidos com a finalidade de priorizar os indivíduos que propiciaram o início do processo de formação do atual remanescente florestal. Além disso, as unidades amostrais foram agrupadas em três tratamentos, sendo eles: T1 – vertente norte na área conservada; T2 – vertente norte na área perturbada; e T3 – vertente sul na área perturbada.


Os indivíduos de *G. guidonia* amostrados foram georreferenciados em campo com uso de GPS modelo Garmim 76csx. Para cada indivíduo amostral, foram coletadas características em seu entorno das condições dos seguintes fatores ecológicos:

- a) exposição;
- b) elevação;
- c) declividade;

- d) superfícies de curvatura;
- e) zonas hidrogenéticas;
- f) afloramentos rochosos.

As espécies amostrais georreferenciadas foram localizadas sobre base digital obtida pelo software ArcMap 10, utilizando o modelo digital de elevação do terreno gerado a partir das bases 1:50.000 do Instituto Brasileiro de Geografia e Estatística (IBGE) e usos oriundos da restituição da imagem GeoEye do ano de 2009. De acordo com Baylão Júnior (2014), foram levantados um total de 38 indivíduos (ver figura 5), sendo 9 na área conservada e 29 na área perturbada e, com a ferramenta “surface” do ArcMap 10, foram gerados mapas de exposição, declividade, elevação e forma das vertentes, que permitiram relacionar a localização dos indivíduos de *G. guidonia* sob esses fatores abióticos.

Figura 5 - Distribuição dos indivíduos de *Guarea guidonia* na microbacia experimental




Fonte: Baylão Júnior (2014)

As preferências ecológicas da *G. guidonia* foram obtidas através da análise de frequência de ocorrência da espécie nos diferentes setores da microbacia experimental e as diferenças entre essas frequências foram analisadas através do teste do qui-quadrado. Com base nos dados da análise de frequência de ocorrência da espécie nos diferentes setores da microbacia experimental, foram identificados os fatores ambientais que melhor explicam a distribuição da espécie na microbacia. Na

figura 6, a seguir, pode ser visualizado o posicionamento das espécies de *G. guidonia* amostradas em relação aos seis fatores ecológicos analisados pelo autor.

Figura 6 - Posicionamento da *G. guidonia* em relação às zonas hidrogenéticas (A), elevação do terreno (B), exposição do relevo (C), declividade (D), superfície de curvatura (E) e presença de afloramentos rochosos (F) na microbacia



Fonte: Baylão Júnior (2014)

2.4 Geospatial big data

Na última década, o *big data* tornou-se um forte foco de interesse global, atraindo cada vez mais a atenção da academia, indústria, governo e outras organizações (LI *et al.*, 2015). De acordo com Chen, Mao e Liu (2014), o termo *big data* ainda não possui definições claras e pode ser definido de formas diferentes nas perspectivas industriais, de pesquisa e acadêmicas, Robinson *et al.* (2017) reafirmam

essa ideia ao destacar que a definição de *big data* é nebulosa. No entanto, Li *et al.* (2016) entendem que, em geral, o termo *big data* pode ser definido como um conjunto de dados, estruturado ou não estruturado, que possui grandes volumes de dados, que não podem ser facilmente obtidos, armazenados, manipulados, analisados, administrados e visualizados pelas tecnologias tradicionais de hardware, software e banco de dados.

Laney (2001) trouxe que as principais características do *big data* poderiam ser resumidas em 3v's, sendo estes volume, velocidade e variedade. Posteriormente Xu e Yang (2014) acrescentaram mais dois v's a essas características, sendo estes a veracidade e o valor. Já Khan, Uddin e Gupta (2014) trazem uma abordagem sobre os 7v's do *big data* acrescentando a importância de se considerar a validade dos dados que, diferentemente da veracidade, está relacionado à precisão e acurácia do dado com relação ao uso pretendido. Os autores trazem ainda uma discussão sobre a volatilidade, que se torna importante justamente devido ao volume, velocidade e variedade dos dados e também abordam o valor como sendo o v mais especial, por ser obtido como resultado do processamento do *big data*.

Nos últimos anos, juntamente com a disponibilidade de novos sensores, surgiram novas maneiras de coletar dados geoespaciais, levando a fontes de dados completamente novas e diferentes tipos de dados de natureza geográfica (Li *et al.*, 2015). Para Holt (2017), dados geoespaciais sempre foram considerados *big data*, muito embora grandes bancos de dados espaciais talvez já não sejam mais suficientes para se qualificarem como *big data* de acordo com as definições atuais. Lee e Kang (2015) afirmam que o termo *geospatial big data* refere-se tipicamente a conjuntos de dados espaciais que excedem capacidade dos sistemas de computação existentes. Já segundo Li (2019), o termo refere-se a um tipo específico de *big data* que contém informações de localização.

De acordo com Robinson *et al.* (2017), o *geospatial big data* pode ser separado em duas categorias: a primeira é o *big data* geolocalizado, em que a localização é um atributo acessório adicional como, por exemplo, pontos, como localizações de smartphones ou endereços de clientes de sistemas de inteligência de negócios. A segunda categoria é espacialmente fundamentada, na qual localização, forma, tamanho, orientação e relações espaciais são partes integrantes dos dados, como, por exemplos, dados provenientes de fontes, como redes de sensores, imagens de

alta resolução de drones e satélites, e produtos resultantes de mapeamentos com *laser scanner*.

Vale destacar que, no âmbito geoespacial desde a invenção e implementação de satélites, o volume de dados tem sido um grande desafio (LI *et al.*, 2010). No entanto, Holt (2017) entende que, com o aumento da disponibilidade de dados detectados por satélites, é preciso pensar não apenas como gerenciar quantidades cada vez maiores de dados, mas, principalmente, como permitir que esses dados sejam vinculados a outros dados.

Nos subtópicos seguintes, será realizada uma abordagem sobre os produtos que foram utilizados na pesquisa como dados de entrada. Esses dados, além de terem as principais características elencadas por Laney (2001) para serem enquadrados na categoria de *geospatial big data*, possuem outra característica muito importante que é a possibilidade de se integrarem a outros dados e viabilizarem criação de uma grande quantidade de novos dados e novas camadas de informações.


2.4.1 MapBiomias

O projeto MapBiomias³ surgiu de uma iniciativa multi-institucional que envolve universidades, organizações não governamentais (ONGs) e empresas de tecnologia. Esse projeto tem a finalidade de mapear anualmente a cobertura e o uso do solo no Brasil, e todos os mapas do projeto são produzidos com base na classificação pixel a pixel de imagens de satélite da série *Landsat*. De acordo com a plataforma on-line do projeto MapBiomias (2019), o processo é realizado com o uso de *machine learning*⁴ através do *Google Earth Engine*, sendo utilizadas como referência para organização das etapas às cartas de 1º de latitude x 1,5º de longitude disponibilizadas pelo IBGE. Além disso, as equipes de programadores, especialistas de sensoriamento remoto e especialistas em conservação e uso da terra são organizadas em times para cada bioma e tema transversal, conforme representado na figura 7.

³ Site do projeto: <https://mapbiomas.org/>

⁴ No português: aprendizado de máquina; refere-se à técnica que permite a automatização da tomada de decisão a partir de inteligência artificial e *big data*.

Figura 7 - Disposição de biomas e temas transversais utilizadas no MapBiomias



Fonte: MapBiomias.org

Na plataforma on-line do projeto, são explicados todos os passos do processo de classificação que se inicia com as imagens de satélite *Landsat*, com resolução espacial de 30 metros. Essas imagens são disponibilizadas de forma gratuita na plataforma *Google Earth Engine*, com uma série temporal de mais de 30 anos. Para cobrir toda a extensão do território brasileiro, são necessárias 380 imagens e um total de mais de 9 bilhões de pixels de 30 x 30 metros. A figura 8 ilustra de forma resumida como são elaborados os produtos do MapBiomias.

Figura 8 - Etapas da classificação MapBiomias



Fonte: Mapbiomas.org

De acordo com MapBiomias (2019), o conjunto dos mosaicos gerados é salvo como uma coleção de dados dentro da plataforma do *Google Earth Engine* e são utilizados tanto como fonte de parâmetros para o algoritmo que classifica as imagens,


quanto para a coleta de amostras de treinamento e avaliação de acurácia por interpretação visual. É também a partir desse mosaico que é gerada a composição RGB⁵ que pode ser visualizada como imagem de fundo na plataforma MapBiomas.

Em seguida, a partir desses mosaicos, as equipes responsáveis por cada bioma e de cada tema transversal produzem um mapa de cada classe de cobertura e uso do solo. Nessa classificação, é utilizado um classificador automático disponibilizado na nuvem de processadores da *Google* que é baseado em *machine learning* e, para cada tema a ser classificado, as máquinas recebem um treinamento com amostras dos alvos que podem ser obtidas através de mapas de referência ou por interpretação visual das imagens *Landsat*.

Após a classificação, são aplicados os filtros espaciais e temporais para melhorar a qualidade do produto. Os filtros espaciais têm o objetivo de melhorar a consistência espacial dos dados através da eliminação de pixels isolados ou de borda; já os filtros temporais visam reduzir as inconsistências temporais, com foco para as mudanças de classe impossíveis ou não permitidas e para corrigir falhas por excesso de nuvem ou falta de dados. Na etapa de integração, os mapas de cada classe são integrados a fim de se formar um mapa único que representa a cobertura e o uso do solo em todo o território para cada ano. Esse mapa integrado passa por mais uma etapa de filtragem espacial e, por fim, são realizadas as análises estatísticas e de acurácia da classificação.

⁵ Abreviatura do sistema aditivo de cores que utiliza o vermelho, o verde e o azul para representar uma vasta gama de cores no espectro visível.

Figura 9 - Demonstração do produto MapBiomias para o campo de Água Grande -BA



Fonte: MapBiomias com adaptação da autora.


2.4.2 Shuttle Radar Topography Mission

A missão SRTM (do inglês, *Shuttle Radar Topography Mission*) foi um projeto oriundo de uma colaboração entre a Nasa (*National Aeronautics and Space Administration*) e NGA (*National Geospatial-Intelligence Agency*), que coletou dados de radar que foram utilizados para gerar um produto de dados topográficos de latitudes menores que 60° (RODRÍGUEZ *et al.*, 2005). Rabus *et al.* (2003) afirmam que a missão SRTM fornece um modelo digital de elevação (MDE) global de alta qualidade em níveis de resolução de 1 e 3 segundos de arco, que cobre a terra entre as latitudes

60° N e 57° S e é produzido com uma única técnica de interferometria⁶ por radar de abertura sintética.

Todos os dados para a geração do produto foram adquiridos durante um período de apenas onze dias e isso foi possível porque o sistema radar realizou uma varredura ativa da superfície da Terra, independente da escuridão ou da cobertura de nuvens (RABUS *et al.*, 2003). De acordo com Farr *et al.* (2007), o SRTM utilizou dois radares de abertura sintética (ver figura 10), um sistema de banda C (5,6 cm; C-RADAR) e um sistema de banda X (3,1 cm; X-RADAR), sendo o laboratório de propulsão a jato da Nasa (JPL) o responsável pelo C-RADAR e o centro aeroespacial alemão (DLR) o responsável pelo X-RADAR.

Figura 10 - Esquematização do SRTM



Fonte: Rabus *et al.* (2003)

O C-RADAR teve como objetivo principal gerar cobertura de mapeamento contígua, conforme exigido pelos objetivos da missão, e o X-RADAR gerava dados em faixas discretas, com 50 km de largura, que ofereciam cobertura quase contígua em latitudes mais altas (FARR *et al.*, 2007). Ainda de acordo com os autores, duas categorias de produtos diferentes são geradas a partir dos dados SRTM, sendo essas

⁶ Técnica de medidas e análises de ondas baseada no fenômeno da interferência (sobreposição de duas ou mais ondas de entrada gerando onda de saída diferente).

o MDE interferométrico, que explora a diferença no ângulo de visão entre as antenas, e os produtos de imagem, derivados de dados registrados pela antena interna.

O MDE é fornecido em coordenadas geográficas, com um espaçamento horizontal de um arco-segundo, com o valor da elevação dado em metros e o produto possuindo uma resolução espacial de 90 metros. O sistema de referência WGS 84 (*World Geodetic System 1984*) é utilizado tanto como referência horizontal como vertical, o que significa que são fornecidas as altitudes elipsoidais. O modelo apresenta uma precisão vertical de 16 metros absolutos e 6 metros de precisão relativa, sendo que a precisão relativa descreve o erro em uma escala local de 200 km, enquanto o valor absoluto representa o erro ao considerar a missão como um todo (FARR *et al.*, 2007).

2.4.3 *Advanced Land Observing Satellite*

De acordo com Shimada *et al.* (2014), a missão *Advanced Land Observing Satellite* (ALOS) foi lançada em 24 de janeiro de 2006 e esteve em operação até 22 de abril de 2011. O programa de observação por satélites japonês consiste em duas séries correspondentes a dois diferentes objetivos de observação: uma para observações atmosféricas e marinhas e outra para observações terrestres.

O principal objetivo do ALOS é contribuir para a cartografia, observação regional, monitoramento de desastres e levantamento de recursos naturais através da utilização de tecnologias avançadas de observação terrestre. Segundo o guia de usuário do ALOS, o satélite foi equipado com três sensores de observação terrestre, um sensor pancromático, para realizar precisas medições de elevação terrestre, e um sensor na faixa do visível e outro na faixa do infravermelho próximo, para observar a cobertura da superfície terrestre. Além disso, um radar de abertura sintética para permitir observações terrestres tanto durante o dia quando durante a noite, independente das condições climáticas. O MDE proveniente dos dados ALOS possui uma resolução espacial de 12,5 metros e precisão nominal de 7 metros.

2.4.4 *Advanced Spaceborne Thermal Emission and Reflection Radiometer*

O MDE do *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) é o conjunto de dados topográficos com melhor resolução espacial da superfície terrestre que é disponibilizado gratuitamente, cobrindo a superfície da terra entre as latitudes 83° N até 83° S (ABRAMS, 2016). O MDE do ASTER é gerado a partir dos dados das bandas 3N e 3B do subsistema do VNIR (*visible and near-infrared* ou visível e infravermelho próximo, em português), essas bandas adquirem dados na faixa do infravermelho próximo, variando entre 0,78 a 0,86 micrômetros (SEABRA, 2012).

A partir das imagens brutas disponibilizadas nos níveis de processamento 1A ou 1B, são gerados os modelos digitais de elevação e as cenas cobrem áreas com a extensão de 1° x 1°. Os dados de elevação do ASTER são disponibilizados com resolução espacial de 30 metros, sistema de coordenadas geográficas e sistema de referência WGS 84. A precisão nominal desse dado varia entre 15 e 20 metros.

2.4.5 *WorldClim*

De acordo com Marchi et al. (2019), o conjunto de dados *WorldClim* é provavelmente o conjunto de dados climáticos mais famoso do mundo. Além de possuir cobertura global, os dados são disponibilizados de forma gratuita no sistema de referência WGS 84 e possui uma resolução de 30 segundos de arco, o que representa aproximadamente 1 km no Equador.

Segundo Fick e Hijmans (2017), os dados foram agregados no intervalo temporal de 1970 a 2000 e foram utilizados como base os dados de até 60 mil estações meteorológicas, associados a informações extraídas de imagens de satélites. Dentre as informações disponibilizadas pelo modelo, têm-se a temperatura mensal mínima, média e máxima, precipitação, radiação solar, pressão de vapor e velocidade do vento.


3 MATERIAIS E MÉTODOS

3.1 Local de estudo

O local escolhido para a realização do estudo de caso desenvolvido neste trabalho foi o campo de Água Grande, que está localizado nos municípios de Pojuca e Catu, estado da Bahia. O campo é delimitado por uma poligonal de, aproximadamente, 56 km², e está situado entre as coordenadas UTM (zona 24 S – sistema de referência Aratu): 566388 m e 575597 m E, e 8638210 m e 8627301 m N. Este campo representa apenas uma pequena parcela dentre as áreas de potencial exploração existentes no país.

De acordo com a Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP), o Brasil possui 29 bacias sedimentares com interesse para pesquisa de hidrocarbonetos (ANP, 2020), dentre os quais tem-se o petróleo e o gás natural. Essas bacias ocupam uma área total de 7,175 milhões de km². No que tange às áreas já com produção consolidada, informações do Anuário Estatístico Brasileiro do Petróleo, Gás Natural e Biocombustíveis 2020 divulgado pela ANP mostram, que no ano de 2019, existiam 380 campos em fase de produção, dos quais 101 em mar e 279 em terra (ANP, 2020).

Figura 11 - Localização da área de estudo



Fonte: Elaborado pela autora.

Segundo o Mapeamento Geoambiental – Ativo Sul, de 2009, feito pela Petrobras (PETROBRAS, 2009), o campo de Água Grande está inserido nas seguintes unidades geoambientais: tabuleiros dissecados em arenitos e folhelhos, colinas dissecadas em arenitos e folhelhos, planícies fluviais e terraços e tabuleiros costeiros. As unidades de tabuleiros dissecados em arenitos e folhelhos e colinas dissecadas em arenitos e folhelhos são as mais representativas da área, recobrendo grande parte dela. A geologia local trata-se de rochas sedimentares clásticas litificadas, sedimentos inconsolidados e rochas sedimentares clásticas pouco litificadas. O solo predominante é o cambissolo háplico, textura argilosa, havendo também o argissolo vermelho-amarelo, textura média argilosa.

Ainda de acordo com este mapeamento, quanto ao uso e à ocupação do solo, o campo de Água Grande possui uma área de 5.691,33 hectares (ha). Dentre esses, 2.500,08 (ha) referem-se à vegetação. A zona urbana ocupa uma área de 51,64 (ha). A área ocupada por outros usos, tais como pastagens, agricultura, silvicultura e outros, é de 2.624,21 (ha), sendo esse aspecto o mais expressivo de Água Grande. As áreas

degradadas correspondem a 515,40 (ha) do total, aproximadamente 9% do total da área do campo. Das áreas degradadas, 49,9% correspondem às erosões laminares; 46,5% correspondem aos solos expostos; 3,1% correspondem aos rios assoreados; 0,3% correspondem às voçorocas e 0,2% aos sulcos.

Figura 12 - Panorâmica da região de Água Grande



Fonte: Mapeamento Geoambiental - Ativo Sul (2009)

3.2 Materiais


Para o desenvolvimento da pesquisa, foram utilizados os seguintes materiais:

- a. classificação da cobertura de solo MapBiomas;
- b. MDE SRTM;
- c. MDE ALOS;
- d. MDE ASTER;
- e. MDE da SEI;
- f. dados de hidrografia do IBGE;
- g. dados climáticos do WorldClim;
- h. softwares de sistema de informações geográficas (QGIS e ArcGIS);
- i. computador institucional do IF Baiano, processador Intel Core i5 2.6 GHz RAM 4.0 GB e HD 500 GB.

3.3 Métodos

A metodologia da pesquisa incluiu, primeiramente, a realização de algumas análises sobre os modelos de elevação do SRTM, ALOS e ASTER, tendo como objetivo verificar a qualidade desses dados e escolher o que melhor se adequou às necessidades da aplicação. Posteriormente, foi realizada a elaboração do mapa de favorabilidade à recomposição florestal. Este mapa foi elaborado com base em sete indicadores, aos quais foram atribuídos pesos e notas para suas classes por especialistas na área de reflorestamento. Para cada indicador, foi utilizada uma camada de informação baseada em um dado geoespacial *opensource*. Um resumo da metodologia pode ser visualizado na figura 13, a seguir, e nos próximos tópicos há uma descrição mais detalhada das principais etapas que compuseram o processo.

Figura 13 - Fluxograma da metodologia de pesquisa



Fonte: Elaborado pela autora.

O fluxograma demonstrado acima foi montado com base nas metodologias desenvolvidas por Seabra (2012) e Baylão Júnior (2014), sendo realizadas algumas adaptações a fim de se adequar a proposta do trabalho de utilização de dados abertos. A etapa de comparação entre os modelos digitais de elevação foi acrescentada, pois, diante da redundância de dados, houve o entendimento de que a comparação entre esses seria importante a fim de embasar a escolha do modelo a ser utilizado.

3.3.1 Modelo digital de elevação

Pela análise do modelo digital de elevação de uma determinada região, é possível realizar diversos estudos e obter vários produtos derivados que podem contribuir com pesquisas nos mais diversos campos da ciência. No entanto, é preciso estar atento à qualidade dos resultados, visto que eles podem variar em função do MDE utilizado. Isso acontece porque os modelos são aproximações da realidade e, portanto, estão sujeitos a incertezas que tendem a se propagar nos estudos e produtos derivados.

Por isso, com o objetivo de escolher o modelo que represente de forma mais fidedigna uma região a ser estudada, é importante analisar e comparar os diferentes produtos disponíveis. As análises sobre os modelos digitais de elevação (MDEs) foram realizadas considerando toda a extensão da área de estudo, representando uma área de, aproximadamente, 56 km². Nessas análises, foram utilizados os modelos ALOS, ASTER e SRTM (ver tabela 1), todos eles são *open access* e podem ser adquiridos por qualquer usuário.

Tabela 1 - Dados sobre os modelos ALOS, ASTER e SRTM

	ALOS	ASTER	SRTM
Ano	2007	2011	2000/2001
Resolução espacial	12,5 m	30 m	90 m
Precisão nominal vertical	7 m	15 a 20 m	16 m

Fonte: Elaborada pela autora.

Os três dados *raster* foram importados para um ambiente SIG, no software QGIS, versão 2.14, e atribui-se a todos o mesmo sistema de referência, SIRGAS 2000. A primeira análise realizada foi a observação dos valores mínimos, médios e máximos para a altitude do terreno na área de estudo de acordo com cada modelo. Em seguida, a fim de analisar quantitativamente o grau de adequação dos modelos para além dos valores mínimos, médios e máximos, foi realizada também uma análise baseada na subtração de imagens. Para tal, foram consideradas três combinações possíveis de

diferença entre os modelos, de modo que cada modelo fosse comparado com os outros dois.

Tomando como base as imagens das diferenças entre os modelos analisados, foram extraídas algumas informações estatísticas como valor mínimo, máximo, médio, mediana, desvio padrão e 1º e 3º quartis. Essas medidas de dispersão foram calculadas com o objetivo de analisar melhor o comportamento e distribuição dos dados. Além disso, considerando a precisão nominal vertical de cada modelo informada na tabela 1, foi feito um histograma a fim de verificar a quantidade de ocorrência de valores dessas diferenças em função da soma das precisões de cada par de modelos analisados. Esses histogramas foram construídos com o objetivo de avaliar como as diferenças entre altitudes encontradas se comportam em relação à precisão vertical anunciada pelos modelos, visto que o comportamento esperado é de que para a maioria dos pontos essa diferença esteja próxima de zero. E, caso ocorram diferenças maiores que zero, espera-se que esses valores, em módulo, não sejam superiores à soma das precisões dos dois modelos.

Posteriormente, os modelos ALOS, ASTER e SRTM, que são gerados a partir de imagens de satélite, foram comparados com um modelo digital de superfície gerado a partir de imagens adquiridas num voo fotogramétrico (ver tabela 2). Esse modelo gerado a partir de fotogrametria é um dado na escala 1:25.000 que foi disponibilizado pela Superintendência de Estudos Econômicos e Sociais da Bahia (SEI - BA). Ressalta-se que o modelo disponibilizado pela SEI-BA foi considerado como um dado de referência pois, além ter sido gerado por técnicas de aerofotogrametria, é um dado oficial.

Tabela 2 - Dados sobre os modelos ALOS, ASTER, SRTM e SEI

	ALOS	ASTER	SRTM	SEI
Ano	2007	2011	2000/2001	2010
Resolução espacial	12,5 m	30 m	90 m	5 m
Precisão nominal vertical	7 m	15 a 20 m	16 m	3,4 m

Fonte: Elaborada pela autora.

Com esses dados, foram realizadas análises semelhantes às realizadas na etapa anterior, sendo que na primeira análise foi feita a observação dos valores mínimos, máximos e médios para a altitude do terreno na área de estudo de acordo com cada modelo. Em seguida, foi realizada a análise baseada na subtração das imagens, sendo consideradas três combinações de diferença entre o modelo da SEI e cada um dos modelos oriundos de imagens de satélite analisados, considerando que o dado da SEI é o dado mais confiável.

Utilizando como base as informações das imagens resultantes das diferenças entre os modelos, foram também extraídas algumas informações estatísticas (valor mínimo, máximo, médio, mediana, desvio padrão e 1º e 3º quartis das diferenças encontradas). Vale ressaltar que para essa tarefa foi utilizada uma grade regular de pontos com espaçamento de 30 metros, a fim de compatibilizar as análises em todos os modelos e facilitar a extração das informações. E, por fim, considerando a precisão nominal vertical de cada modelo informada na tabela 2, foi feito um histograma a fim de verificar a ocorrência de valores dessas diferenças em função da soma das precisões de cada par de modelos analisados. Sendo que, nesse caso, os histogramas têm o objetivo de viabilizar a avaliação do comportamento das diferenças entre altitudes encontradas com relação à precisão vertical anunciada, levando em consideração que o modelo digital de superfície (MDS) da SEI é um dado de maior confiabilidade.

3.3.1 Mapa de favorabilidade à recomposição florestal

Por fim, o mapa de favorabilidade à recomposição florestal foi elaborado com base nos fundamentos da análise multicritério e álgebra de mapas, sendo utilizados os seguintes indicadores:

- 1) uso da terra;
- 2) proximidade a áreas urbanas;
- 3) proximidade a áreas de formação florestal;
- 4) proximidade a corpos d'água;
- 5) geomorfologia;
- 6) declividade;
- 7) intensidade de exposição ao Sol.

As camadas de informação de cada um desses indicadores foram construídas utilizando dados abertos e gratuitos, conforme descrito a seguir.

- a) Indicador 1 – Uso da terra: neste indicador, foi utilizado como dado de entrada o modelo de cobertura do solo do MapBiomias. Para extrair as informações de cada classe de uso, foi utilizado um filtro com o valor respectivo de cada classe, sendo gerada uma imagem binária para cada classe de uso da terra;
- b) Indicador 2 – Proximidade com áreas urbanas: neste indicador, foi utilizado como dado de entrada a classe Infraestrutura Urbana do modelo MapBiomias. As informações desta classe foram extraídas do modelo por processo de filtragem. Em seguida, esse dado foi vetorizado e, a partir desse vetor, foram feitos buffers com as distâncias predeterminadas (0 a 50 metros, 50 a 100 metros, 100 a 300 metros, 300 a 600 metros e acima de 600 metros). Por fim, os buffers foram utilizados como máscara para criar imagens binárias para cada classe de distância;
- c) Indicador 3 – Proximidade com áreas de formação florestal: neste indicador, foi utilizado como dado de entrada a classe Formação Florestal do modelo MapBiomias. As informações desta classe foram extraídas do modelo por processo de filtragem. Em seguida, esse dado foi vetorizado e, a partir desse vetor, foram feitos buffers com as distâncias predeterminadas (0 a 50 metros, 50 a 100 metros, 100 a 300 metros, 300 a 600 metros e acima de 600 metros). Por fim, os buffers foram utilizados como máscara para criar imagens binárias para cada classe de distância;
- d) Indicador 4 – Proximidade com corpos d'água: neste indicador, foi utilizado como dado de entrada o arquivo vetorial de hidrografia disponibilizado pelo IBGE e, a partir desse vetor, foram feitos buffers com as distâncias predeterminadas (0 a 50 metros, 50 a 100 metros, 100 a 300 metros, 300 a 600 metros e acima de 600 metros). Por fim, os buffers foram utilizados como máscara para criar imagens binárias para cada classe de distância;
- e) Indicador 5 – Geomorfologia: a camada deste indicador foi construída com base no dado do modelo digital de elevação ALOS. Através desse modelo, foram geradas as camadas de declividade e amplitude de relevo, usadas para a determinação da geomorfologia. A regra para a definição das classes geomorfológicas foi criada através de uma adaptação da metodologia sugerida

pelo Instituto de Pesquisas Tecnológicas de São Paulo (ITP) para melhor se adequar à área de estudo, sendo definidas as seguintes classes e regras:

- I. Relevo plano a colinoso: declividade variando entre 0% e 15% e amplitude de relevo menor que 40 metros;
- II. Morrotes: declividades maiores que 15% e amplitude de relevo variando entre 40 e 100 metros;
- III. Morros: declividades maiores que 15% e amplitude de relevo maiores que 100 metros;
- IV. Planaltos: declividades menores que 15% e amplitude de relevo maiores que 40 metros.

Com o auxílio da calculadora *raster* do software QGIS, as regras citadas acima foram aplicadas aos dados de declividade e amplitude de relevo, gerando uma camada *raster* binária para cada classe geomorfológica.

f) Indicador 6 – Declividade: a camada deste indicador foi construída com base no dado do modelo digital de elevação ALOS, sendo que, através de filtragem, foi gerada uma imagem binária para cada classe predefinida. As classes deste indicador foram construídas de acordo com as divisões sugeridas pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa), sendo elas:

- I. 0% a 3%;
- II. 3% a 8%;
- III. 8% a 20%;
- IV. 20% a 45%;
- V. 45% a 75%.

g) Indicador 7 – Intensidade de exposição ao Sol: a camada deste indicador foi construída com base no dado do modelo digital de elevação ALOS, sendo considerada a incidência solar do solstício de verão. A intensidade de exposição ao Sol foi classificada em baixa, moderada e alta e para cada classe foi gerada uma imagem binária.

Sendo conhecidos todos os indicadores e suas respectivas classes, foi realizada uma pesquisa com especialistas na área de reflorestamento com diferentes formações (engenheiros ambientais, engenheiros agrônomos e geógrafos) a fim de se identificar os critérios preferenciais para hierarquização das regiões mais ou menos favoráveis ao reflorestamento. Para cada um dos indicadores utilizados no estudo,

cada especialista foi convidado a atribuir um peso na composição do mapa e, para cada uma das classes desses indicadores, uma nota de influência (ver apêndice A).

Os pesos foram atribuídos em uma escala de 1 a 5, onde 1 representa que o indicador tem o menor peso para influenciar a favorabilidade à recomposição florestal na área e 5 representa que o indicador tem o peso máximo. Já as classes foram avaliadas em uma escala de 0 a 10, onde 0 representa que a classe não tem nenhuma preferência e 10 que a classe tem preferência máxima. Os pesos e notas finais utilizados para a elaboração do mapa foram as modas dos valores obtidos na pesquisa, ou, no caso de não haver moda, a mediana desses valores.

Foi ainda incluído na pesquisa um fator sazonal, que, por ser sazonal, não será incluído no modelo, mas tem o objetivo de avaliar as melhores épocas do ano para iniciar ou consolidar as ações de reflorestamento de acordo com a umidade do mês. Os dados utilizados como base para a construção desse fator são do WorldClim, que é um conjunto gratuito de camadas climáticas globais. Foram avaliados os dados de precipitação e temperatura média, a fim de conhecer quais meses poderiam ser considerados secos, úmidos, muito úmidos ou hiperúmidos na região.

4 ANÁLISES E RESULTADOS

4.1 Comparação dos modelos digitais de elevação

Na tabela 3, a seguir, podem ser visualizados os resultados da observação dos valores mínimos, máximos e médios para a altitude do terreno na área de estudo, de acordo com as informações extraídas dos modelos ALOS, ASTER e SRTM.


Tabela 3 - Medidas de dispersão dos modelos ALOS, ASTER e SRTM para a área de estudo

	ALOS	ASTER	SRTM
Valor mínimo	43 m	16 m	57 m
Valor máximo	181 m	321 m	188 m
Valor médio	102 m	121 m	114 m

Fonte: Elaborada pela autora.

Da tabela 3, pode-se perceber que existe uma diferença de 19 metros entre o valor médio obtido pelos modelos ASTER e ALOS, enquanto que o valor médio do modelo SRTM encontra-se mais próximo a ambos, sendo 7 metros superior ao ASTER e 12 metros inferior ao SRTM. Ao analisar o valor máximo, a maior diferença encontrada também fica entre os dados ASTER e ALOS, sendo essa diferença de 140 metros. O modelo SRTM, quando comparado ao ASTER neste quesito, também apresenta uma elevada diferença de 133 metros, com o mesmo sentido. Já quando comparado ao ALOS, o valor máximo apresentado pelo SRTM está apenas 7 metros superior. No que tange ao valor mínimo, a maior diferença encontrada é de 41 metros e fica entre os modelos ASTER e SRTM. Em seguida, tem-se 27 metros de diferença entre os modelos ASTER e ALOS e 14 metros de diferença entre os modelos ALOS e SRTM. A seguir, na figura 14, podem ser visualizados os resultados das subtrações de imagens considerando as três combinações possíveis de diferença entre os modelos, de modo que cada modelo fosse comparado com os outros dois.

Figura 14 - Diferença entre os modelos ASTER, ALOS E SRTM



Fonte: Elaborada pela autora.

Da observação da figura 14 percebe-se que na imagem resultante da diferença entre os modelos ASTER e SRTM é possível identificar que existem algumas áreas ao oeste que concentram grandes diferenças entre os valores de altitude e, de forma curiosa, essas áreas não apresentam um comportamento uniforme, visto que na mesma proximidade em que há elevadas diferenças positivas entre os modelos também é possível encontrar elevadas diferenças negativas. Ao leste da região, não há predominância de diferenças acentuadas.

Ao analisar a imagem resultante da diferença entre os modelos ASTER e ALOS também é possível observar algumas áreas relativamente próximas que concentram grandes diferenças de altitude em sentidos opostos. Em contrapartida, excluindo-se essas áreas, o restante da imagem apresenta um comportamento uniforme das diferenças, apontando uma tendência de que as altitudes observadas no modelo ASTER tendem a ser superiores às altitudes observadas no modelo ALOS.

Já a análise visual da imagem resultante da diferença entre os modelos ALOS e SRTM não permite que seja identificado nenhum padrão espacial de ocorrência de grandes diferenças, visto que elas ocorrem por toda a área. No entanto, é possível observar que os pontos de maior coincidência entre esses modelos, onde as diferenças estão próximas de zero, possuem uma característica geométrica que se assemelha à hidrografia da região. Além disso, pode-se observar também que há uma maior tendência de que as altitudes observadas no modelo SRTM sejam superiores às altitudes observadas no modelo ALOS.

Com base nas imagens das diferenças entre os modelos apresentadas na figura 14 foram extraídas algumas informações estatísticas como valor mínimo, máximo, médio, mediana, desvio padrão e 1º e 3º quartis, conforme demonstrado na tabela 4, a seguir.

Tabela 4 - Medidas de dispersão das diferenças entre os modelos ASTER, ALOS e SRTM para a área de estudo

SEM MÓDULO	ASTER – SRTM	ASTER – ALOS	ALOS – SRTM
Valor mínimo	-131,00 m	-101,00 m	-71,00 m
Valor máximo	220,00 m	240,00 m	47,00 m
Valor médio	7,02 m	18,75 m	-12,01 m
Mediana	6,00 m	17,00 m	-12,00m
Desvio padrão	16,59	13,13	13,58
1º quartil	-2,0 m	14,0 m	-21,00 m
3º quartil	14,00 m	20,0 m	-4,00 m

Fonte: Elaborada pela autora.

De acordo com os dados apresentados na tabela 4, pode-se perceber que as maiores diferenças de altitude para um mesmo ponto foram encontradas nas imagens de diferença entre os modelos ASTER e ALOS, e ASTER e SRTM, sendo essas diferenças de, respectivamente, 240 e 220 metros, no sentido positivo, e 101 e 131 metros, no sentido contrário. Já quando se observa valores na diferença entre os modelos ALOS e SRTM, a maior diferença de altitude para um mesmo ponto é de 47 metros, no sentido positivo, e 47 metros, no sentido contrário.


Ao observar o valor médio das diferenças de altitude, a menor média numérica, desconsiderando-se o sentido desta, fica para a diferença entre os modelos ASTER e SRTM, sendo ela de 7,02 metros; seguida pelas diferenças entre os modelos ALOS e

SRTM, com uma média de -12,01 metros, e ASTER e ALOS, com uma média de 18,75 metros. Em relação à dispersão dos dados, a diferença entre os modelos ASTER e ALOS aparece com um menor desvio padrão, de 13,13; seguida da diferença entre os modelos ALOS e SRTM, com um desvio padrão de 13,58; e ASTER e SRTM, com um desvio padrão de 16,59.

Ao analisar a simetria dos dados, percebe-se que a diferença entre os modelos ASTER e SRTM, que apresentou a menor média desconsiderando-se o sentido, sendo essa de 7,02 metros, apresenta uma mediana de 6,00 metros. Portanto, o gráfico de distribuição dessas diferenças em torno da média apresenta uma assimetria à direita, visto que o valor da média é maior que o valor da mediana. A diferença entre os modelos ASTER e ALOS apresenta uma média de 18,75 metros e uma mediana de 17,00 metros, caracterizando também uma assimetria à direita no gráfico de distribuição em torno da média dessas diferenças. Já a diferença entre os modelos ALOS e SRTM apresenta uma média de -12,01 metros e uma mediana de 12,00 metros e, devido à proximidade entre os valores da média e da mediana, o gráfico de distribuição dessas diferenças em torno da média tende a se mostrar de forma bastante simétrica.

Considerando a precisão nominal vertical de cada modelo (ver tabela 1) foram construídos os histogramas a seguir (figuras 15, 16 e 17) que permitem verificar a ocorrência de valores dessas diferenças em função da soma das precisões de cada par dos modelos analisados.


Figura 15 - Histograma da diferença entre os modelos ASTER e SRTM



Fonte: Elaborada pela autora.

Ao analisar o histograma das diferenças entre os modelos ASTER e SRTM por precisão nominal, percebe-se que aproximadamente 95,9% das diferenças estão no intervalo entre -36 e 36 metros. Considerando que 36 metros é a soma da precisão nominal dos modelos, diferenças de altitude dentro desse intervalo tendem a ser esperadas. Nos intervalos entre -72 e 36 metros e entre 36 e 72 metros, que representam diferenças maiores que a soma da precisão nominal dos modelos limitadas a até 2 vezes esse valor, tem-se um percentual de aproximadamente 3,5% das diferenças. Nos intervalos entre -108 e -72 metros e entre 72 e 108 metros, que representam diferenças maiores que o dobro da soma da precisão nominal dos modelos limitadas ao triplo dessa soma, tem-se um percentual de aproximadamente 0,4% das diferenças. E, acima do triplo da soma da precisão nominal dos modelos, ou seja, valores menores que -108 metros e maiores 108 metros, tem-se um percentual de cerca de 0,2% das diferenças. Pode-se ainda observar que, embora haja uma maior tendência de que as diferenças ocorram em um sentido, é possível encontrar a ocorrência de grandes diferenças (maiores que o triplo da soma da precisão nominal dos modelos) em ambos os sentidos.

Figura 16 - Histograma da diferença entre os modelos ASTER e ALOS




Fonte: Elaborada pela autora.

Ao analisar o histograma das diferenças entre os modelos ASTER e ALOS por precisão nominal, percebe-se que aproximadamente 86,4% das diferenças estão no intervalo entre -27 e 27 metros. Como 27 metros é a soma da precisão nominal dos

modelos, diferenças de altitude dentro desse intervalo tendem a ser esperadas. Nos intervalos entre -54 e -27 metros e entre 27 e 54 metros, que representam diferenças maiores que a soma da precisão nominal dos modelos limitadas a até 2 vezes esse valor, tem-se um percentual de aproximadamente 12,2% das diferenças. Nos intervalos entre -81 e -54 metros e entre 54 e 81 metros, que representam diferenças maiores que o dobro da soma da precisão nominal dos modelos limitadas ao triplo dessa soma, tem-se um percentual de aproximadamente 0,9% das diferenças. E, acima do triplo da soma da precisão nominal dos modelos, ou seja, valores menores que -81 metros e maiores 81 metros, tem-se um percentual de cerca de 0,5% das diferenças. Além disso, pode-se observar que, embora haja uma maior tendência de que as diferenças ocorram em um sentido, é possível observar a ocorrência de grandes diferenças (maiores que o triplo da soma da precisão nominal dos modelos) em ambos os sentidos.

Figura 17 - Histograma da diferença entre os modelos ALOS e SRTM



Fonte: Elaborada pela autora.

Ao analisar o histograma das diferenças entre os modelos ALOS e SRTM por precisão nominal, percebe-se que aproximadamente 80,1% das diferenças estão no intervalo entre -23 e 23 metros. Como 23 metros é a soma da precisão nominal dos modelos, diferenças de altitude dentro desse intervalo tendem a ser esperadas. Nos intervalos entre -46 e -23 metros e entre 23 e 46 metros, que representam diferenças maiores que a soma da precisão nominal dos modelos limitadas a até 2 vezes esse

valor, tem-se um percentual de aproximadamente 19,3% das diferenças. Nos intervalos entre -69 e -46 metros e entre 46 e 69 metros, que representam diferenças maiores que o dobro da soma da precisão nominal dos modelos limitadas ao triplo dessa soma, tem-se um percentual de aproximadamente 0,6% das diferenças. E, acima do triplo da soma da precisão nominal dos modelos, ou seja, valores menores que -61 metros e maiores 61 metros, o percentual de diferenças pode ser considerado desprezível. Além disso, pode-se observar que há uma maior tendência de que as diferenças ocorram em um sentido e, apenas nesse sentido, é possível observar um percentual significativo de diferenças maiores que o dobro da soma da precisão nominal dos modelos.

Quando os modelos ALOS, ASTER e SRTM, que são gerados a partir de imagens de satélite, foram comparados com um modelo digital de superfície da SEI, gerado a partir de imagens adquiridas num voo fotogramétrico, foram observados os valores mínimos, máximos e médios para a altitude do terreno na área de estudo dispostos na tabela 5.

Tabela 5 - Medidas de dispersão dos modelos ALOS, ASTER, SRTM e SEI para a área de estudo

	ALOS	ASTER	SRTM	SEI
Valor mínimo	43 m	16 m	57 m	61 m
Valor máximo	181 m	321 m	188 m	199 m
Valor médio	114 m	121 m	102 m	115 m


Fonte: Elaborada pela autora.

Da tabela 5, pode-se perceber que existe uma diferença de apenas 1 metro entre o valor médio obtido pelos modelos ALOS e SEI, enquanto que o valor médio do modelo ASTER é 6 metros superior ao valor médio do modelo da SEI e o valor médio do modelo SRTM é 13 metros inferior. Ao analisar o valor máximo, o valor obtido pelo modelo ALOS é 18 metros inferior ao valor máximo obtido no modelo da SEI, enquanto que o valor máximo obtido pelo modelo ASTER é 122 metros superior e o valor máximo obtido pelo modelo SRTM é 11 metros inferior. No que tange ao valor mínimo, o modelo ALOS fornece um valor 18 metros inferior ao modelo da SEI,

o modelo ASTER fornece um valor 45 metros inferior e o modelo SRTM fornece um valor 4 metros inferior.

A seguir, na figura 18, podem ser visualizados os resultados das subtrações de imagens da diferença entre os modelos ALOS, ASTER e SRTM com o modelo da SEI, sendo considerado o modelo da SEI como dado de referência.

Figura 18 - Diferença entre os modelos ALOS, ASTER, SRTM e SEI



Fonte: Elaborada pela autora.

Da observação da figura 18, percebe-se que na imagem resultante da diferença entre os modelos ALOS e SEI, é possível observar que existe uma tendência que prevalece em toda a região de que os valores de altitude obtidas pelo modelo ALOS sejam superiores aos valores obtidos pelo modelo da SEI. Ao analisar a imagem resultante da diferença entre os modelos ASTER e SEI é possível identificar extensas regiões onde os modelos possuem maior correlação, mas ao mesmo tempo é possível observar que algumas áreas relativamente próximas concentram grandes diferenças de altitude em sentidos opostos. Já a análise visual da imagem resultante da diferença entre os modelos SRTM e SEI não permite que seja identificado nenhum padrão espacial de ocorrência de grandes diferenças, visto que elas ocorrem por toda a área. No entanto, é possível observar que os pontos de maior coincidência entre esses modelos, onde as diferenças estão próximas de zero, possuem uma característica geométrica que se assemelha à hidrografia da região.

Com base nas imagens das diferenças entre os modelos apresentadas na figura 18 foram extraídas algumas informações estatísticas como valor mínimo,

máximo, médio, mediana, desvio padrão e 1º e 3º quartis, conforme demonstrado na tabela 6, a seguir.

Tabela 6 - Medidas de dispersão das diferenças entre os modelos ALOS, ASTER, SRTM e SEI para a área de estudo

SEM MÓDULO	ALOS-SEI	ASTER-SEI	SRTM-SEI
Valor mínimo	-61,68 m	-117,99 m	-68,59 m
Valor máximo	13,81 m	229,42 m	60,32 m
Valor médio	-12,71 m	6,04 m	-0,69 m
Mediana	-12,92 m	4,59 m	-0,49 m
Desvio padrão	4,94	13,82	14,70 m
1º quartil	-15,63 m	-0,12 m	-9,68 m
3º quartil	-10,05 m	9,90 m	8,38 m

Fonte: Elaborada pela autora.

De acordo com os dados apresentados na tabela 6, pode-se perceber que as maiores diferenças de altitude para um mesmo ponto foram encontradas nas imagens de diferença entre os modelos ASTER e SEI, sendo essas diferenças de 229,42 metros, no sentido positivo, e 117,99 metros, no sentido contrário. Quando se observa esses valores na diferença entre os modelos SRTM e SEI, a maior diferença de altitude para um mesmo ponto é de 60,32 metros, no sentido positivo, e 68,59 metros, no sentido contrário. Já ao observar-se esses valores na diferença entre os modelos ALOS e SEI, a maior diferença de altitude para um mesmo ponto é de 13,81 metros, no sentido positivo, e 61,68 metros, no sentido contrário.

Ao observar-se o valor médio das diferenças de altitude, a menor média numérica, desconsiderando-se o sentido desta, fica para a diferença entre os modelos SRTM e SEI, sendo ela de -0,69 metros; seguida pelas diferenças entre os modelos ASTER e SEI, com uma média de 6,04 metros, e ALOS e SEI, com uma média de -

12,71 metros. Em relação à dispersão dos dados, a diferença entre os modelos ALOS e SEI aparece com um menor desvio padrão, de 4,94; seguida da diferença entre os modelos ASTER e SEI, com um desvio padrão de 13,82; e SRTM e SEI, com um desvio padrão de 14,70.

Como nesta análise o modelo da SEI está servindo como um dado de referência devido ao fato de ter uma melhor precisão da determinação dos dados, esses valores de média e desvio padrão acima servem como balizadores para indicar quais modelos analisados tendem a ter uma maior adequação à realidade. O modelo ALOS, que quando comparado ao modelo da SEI apresenta uma diferença média de -12,94 metros com desvio de 4,94, é um modelo que tende a apresentar uma maior correlação e constância da distribuição das suas diferenças. O valor médio negativo (-12,94 metros) indica que as altitudes do modelo ALOS tendem a apresentar valores menores que os obtidos pelo modelo da SEI. No entanto, o desvio padrão relativamente baixo (4,94) indica que esse comportamento tende a ser constante ao longo da imagem. Portanto, o modelo ALOS tende a ser o mais confiável para a extração de informações relacionadas a diferenças de nível entre pontos numa mesma área.


O modelo ASTER, quando comparado ao modelo da SEI, apresenta uma diferença média de 6,04 metros com desvio de 13,82; o valor médio positivo (6,04 metros) indica que as altitudes do modelo ALOS tendem a apresentar valores maiores que os obtidos pelo modelo da SEI. No entanto, o desvio padrão relativamente alto (13,82) indica que esse comportamento tende a sofrer consideráveis variações ao longo da imagem. O modelo SRTM, quando comparado ao modelo da SEI, apresenta uma diferença média de -0,69 metros e desvio de 14,70. Esse valor de média próximo a zero (-0,69 metros), associado ao desvio padrão relativamente alto (14,70), indica que as diferenças presentes no modelo SRTM tendem a se anular ao longo da área de estudo.

Ao analisar a simetria dos dados, percebe-se que a diferença entre os modelos ALOS e SEI apresentou uma média de -12,71 metros e mediana de -12,92 metros, e, devido à proximidade entre os valores da média e da mediana, o gráfico de distribuição dessas diferenças em torno da média tende a se mostrar de forma aproximadamente simétrica com leve assimetria à esquerda. A diferença entre os modelos ASTER e SEI apresenta uma média de 6,04 metros e uma mediana de 4,59 metros e, considerando que o valor da média é maior que a mediana, a distribuição dessas diferenças em

torno da média apresenta uma assimetria à direita. Já a diferença entre os modelos SRTM e o da SEI apresenta uma média de -0,69 metros e uma mediana de -0,49 metros e, portanto, a sua distribuição em torno da média tende a se mostrar de forma aproximadamente simétrica, com leve assimetria à esquerda.

Considerando a precisão nominal vertical de cada modelo (ver tabela 2) foram construídos os histogramas a seguir (figuras 19, 20 e 21) que permitem verificar a ocorrência dos valores das diferenças de altitude encontradas entre os modelos em função da soma das precisões de cada par de modelos analisados.

Figura 19 - Histograma da diferença entre os modelos ALOS e SEI




Fonte: Elaborada pela autora.

Ao analisar o histograma das diferenças entre os modelos ALOS e SEI por precisão nominal, percebe-se que apenas cerca de 28,3% das diferenças estão no intervalo entre -10,4 e 10,4 metros. Como 10,4 metros é a soma da precisão nominal dos modelos, esperava-se que o maior percentual de diferenças de altitude estivesse concentrado dentro desse intervalo. No intervalo entre -20,8 e -10,4 metros, que representa diferenças maiores que a soma da precisão nominal dos modelos limitadas a até duas vezes esse valor no sentido negativo, tem-se um percentual de aproximadamente 67,0% das diferenças. Já ao considerar esse intervalo no sentido contrário, ou seja, entre 10,4 e 20,8 metros, existe um percentual de apenas 0,01% das diferenças. No intervalo entre -31,2 e -20,8, que representam diferenças maiores que o dobro da soma da precisão nominal dos modelos limitadas ao triplo dessa soma

no sentido negativo, tem-se um percentual de aproximadamente 4,5% metros das diferenças. Já ao considerar esse intervalo no sentido contrário, ou seja, entre 20,8 e 31,2 metros, não há ocorrências. E, acima do triplo da soma da precisão nominal dos modelos, ou seja, valores menores que -31,2 metros e maiores 31,2 metros, tem-se um percentual de cerca de 0,16% das diferenças para valores menores que -31,2 metros e nenhuma ocorrência para valores maiores que 31,2 metros.

Figura 20 - Histograma da diferença entre os modelos ASTER e SEI




Fonte: Elaborada pela autora.

Ao analisar o histograma das diferenças entre os modelos ASTER e SEI por precisão nominal, percebe-se que aproximadamente 91,45% das diferenças estão no intervalo entre -23,4 e 23,4 metros. Como 23,4 metros é a soma da precisão nominal dos modelos, diferenças de altitude dentro desse intervalo tendem a ser esperadas. Nos intervalos entre -46,8 e -23,4 metros, que representa diferenças maiores que a soma da precisão nominal dos modelos limitadas a até 2 vezes esse valor no sentido negativo, tem-se um percentual de aproximadamente 0,76% das diferenças. Já ao considerar esse intervalo no sentido contrário, ou seja, entre 23,4 e 46,8 metros, existe um percentual de 6,57% das diferenças. No intervalo entre -70,2 e -46,8, que representam diferenças maiores que o dobro da soma da precisão nominal dos modelos limitadas ao triplo dessa soma no sentido negativo, tem-se um percentual de aproximadamente 0,13% metros das diferenças. Já ao considerar esse intervalo no sentido contrário, ou seja, entre 46,8 e 70,2 metros, existe um percentual de aproximadamente 0,57%. E, acima do triplo da soma da precisão nominal dos

modelos, ou seja, valores de diferenças menores que -70,2 metros e maiores 70,2 metros, tem-se um percentual de cerca de 0,05% das diferenças menores que -70,2 metros e 0,47% maiores que 70,2 metros.

Figura 21 - Histograma da diferença entre os modelos SRTM e SEI



Fonte: Elaborada pela autora.

Ao analisar o histograma das diferenças entre os modelos SRTM e SEI por precisão nominal, percebe-se que aproximadamente 81,26% das diferenças estão no intervalo entre -19,4 e 19,4 metros. Como 19,4 metros é a soma da precisão nominal dos modelos, diferenças de altitude dentro desse intervalo tendem a ser esperadas. Nos intervalos entre -38,8 e -19,4 metros, que representa diferenças maiores que a soma da precisão nominal dos modelos limitadas a até 2 vezes esse valor no sentido negativo, tem-se um percentual de aproximadamente 9,73% das diferenças. Já ao considerar esse intervalo no sentido contrário, ou seja, entre 19,4 e 38,8 metros, existe um percentual de 8,10% das diferenças.

No intervalo entre -58,2 e -38,8 metros, que representam diferenças maiores que o dobro da soma da precisão nominal dos modelos limitadas ao triplo dessa soma no sentido negativo, tem-se um percentual de aproximadamente 0,63% das diferenças. Já ao considerar esse intervalo no sentido contrário, ou seja, entre 38,8 e 58,2 metros, existe um percentual de aproximadamente 0,07%. E, acima do triplo da soma da precisão nominal dos modelos, ou seja, valores menores que -58,2 metros e maiores 58,2 metros, tem-se um percentual de cerca de 0,01% das diferenças para valores menores que -58,2 metros e 0,01% para valores maiores que 58,2 metros.

4.2 Mapa de favorabilidade à recomposição florestal e características das regiões candidatas ao reflorestamento

A elaboração deste mapa foi baseada nas modas ou, para os casos em que não pode ser detectada a moda, medianas dos pesos atribuídos para cada indicador, bem como as respectivas notas de cada classe. Esses valores foram calculados com base nas respostas dos especialistas que contribuíram com a pesquisa, sendo obtidos os seguintes resultados:

Indicador 1 – Uso da terra: peso considerado para este indicador foi igual a 5; as classes são mostradas na tabela 7, a seguir, bem como suas respectivas notas.

Tabela 7 - Notas de cada classe para o indicador uso da terra

Classe	Nota
Formação Florestal	10
Infraestrutura Urbana	5
Mosaico de Agricultura ou Pastagem	5
Outra Área não Vegetada	4
Pastagem	3

Fonte: Elaborada pela autora.

Indicador 2 – Proximidade com áreas urbanas: o peso considerado para este indicador foi igual a 3; as classes são mostradas na tabela 8, a seguir, bem como suas respectivas notas.

Tabela 8 - Notas de cada classe para o indicador proximidade com áreas urbanas

Classes	Nota
0 a 50 metros	5
50 a 100 metros	7
100 a 300 metros	8
300 a 600 metros	8
> 600 metros	10

Fonte: Elaborada pela autora.

Indicador 3 – Proximidade com áreas de formação florestal: o peso considerado para este indicador foi igual a 5; as classes são mostradas na tabela 9, a seguir, bem como suas respectivas notas.

Tabela 9 - Notas de cada classe para o indicador proximidade com áreas de formação florestal

Classes	Nota
0 a 50 metros	10
50 a 100 metros	5
100 a 300 metros	8
300 a 600 metros	8
> 600 metros	6

Fonte: Elaborada pela autora.

Indicador 4 – Proximidade com corpos d'água: o peso considerado para este indicador foi igual a 5; as classes são mostradas na tabela 10, a seguir, bem como suas respectivas notas.

Tabela 10 - Notas de cada classe para o indicador proximidade com corpos d'água

Classes	Nota
0 a 50 metros	10
50 a 100 metros	10
100 a 300 metros	10
300 a 600 metros	8
> 600 metros	8

Fonte: Elaborada pela autora.

Indicador 5 – Geomorfologia: o peso considerado para este indicador foi igual a 3; as classes e suas respectivas notas são mostradas na tabela 11, a seguir.

Tabela 11 - Notas de cada classe para o indicador geomorfologia

Classes	Nota
Plano a colinoso	10
Morrotes	8
Morros	8
Planalto	10

Fonte: Elaborada pela autora.

Indicador 6 – Declividade: o peso considerado para este indicador foi igual a 4; as classes e suas respectivas notas são mostradas na tabela 12, a seguir.

Tabela 12 - Notas de cada classe para o indicador declividade

Classes	Nota
0 a 3	10
3 a 8	5
8 a 20	8
20 a 45	8
45 a 75	10

Fonte: Elaborada pela autora.

Indicador 7 – Intensidade de exposição ao Sol: o peso considerado para este indicador foi igual a 3; as classes e suas respectivas notas são mostradas na tabela 13, a seguir.

Tabela 13 - Notas de cada classe para o indicador intensidade de exposição ao Sol

Classes	Nota
Baixa	10
Moderada	9
Alta	8

Fonte: Elaborada pela autora.

Fator sazonal – A camada deste indicador foi construída com base nos dados de precipitação e temperatura média do WorldClim. A correlação desses dados

mostrou que, na área de estudo, não há a ocorrência de meses secos, mas apenas de meses úmidos, muito úmidos e hiperúmidos. As notas para essas classes são mostradas na tabela 14, a seguir.


Tabela 14 - Notas de cada classe do fator sazonal

Classes	Nota
Úmido	8
Muito úmido	8
Hiperúmido	10

Fonte: Elaborada pela autora.

Por fim, após serem conhecidos os valores de todos os pesos e notas das classes dos indicadores escolhidos, as camadas foram compatibilizadas com relação ao seu sistema de referência e, através das álgebras de mapas, foi gerado o mapa de favorabilidade à recomposição florestal da área de estudo com o auxílio do software QGIS, conforme pode ser visto na figura 22, a seguir.

Figura 22 - Mapa de favorabilidade à recomposição florestal




Dados utilizados na elaboração do mapa:
 Hidrografia IBGE (2010)
 MapBiomass (2017)
 Modelo digital de superfície ALOS (2007)

Fonte: Elaborada pela autora.

Ao correlacionar as informações do mapa de favorabilidade obtido com o arquivo de áreas degradadas pelas atividades de mineração no campo de Água Grande, pode-se verificar, conforme demonstrado na figura 23, a distribuição de frequência da ocorrência das áreas candidatas ao reflorestamento com relação à favorabilidade para recomposição florestal.

Figura 23 - Histograma da ocorrência de áreas degradadas com relação ao nível de favorabilidade à recomposição florestal da região



Fonte: Elaborada pela autora.

Para analisar as características espaciais e atributos das regiões candidatas ao reflorestamento, foram escolhidas aleatoriamente duas áreas do arquivo de áreas degradadas. Para tal finalidade, foi escolhida uma área localizada entre as regiões com maior favorabilidade à recomposição florestal e outra área situada em uma região de menor favorabilidade, sendo encontrados os seguintes dados:

- a) Área degradada localizada em região com favorabilidade à recomposição florestal muito baixa:
- I. Uso da terra: pastagem;
 - II. Proximidade a áreas urbanas: 100 a 300 metros;
 - III. Proximidade a áreas de formação florestal: 50 a 100 metros;
 - IV. Proximidade a corpos d'água: maior que 600 metros;
 - V. Geomorfologia: planalto;

VI. Declividade: 3% a 8%;

VII. Intensidade de exposição ao Sol: baixa.

b) Área degradada localizada em região com favorabilidade à recomposição florestal muito alta:

I. Uso da terra: formação florestal;

II. Proximidade a áreas urbanas: maior que 600 metros;

III. Proximidade a áreas de formação florestal: 0 a 50 metros;

IV. Proximidade a corpos d'água: 50 a 100 metros;


V. Geomorfologia: morrotes;

VI. Declividade: 45% a 75%;

VII. Intensidade de exposição ao Sol: baixa.

Entende-se que, se a distribuição das áreas degradadas ocorrer de forma aleatória, não haverá diferença significativa entre a frequência de ocorrência de uma determinada classe ao longo de toda a área de estudo com relação à ocorrência dessa mesma classe quando analisada apenas as áreas degradadas. A fim de se observar esse comportamento, foi analisada a distribuição percentual da ocorrência de cada classe dos indicadores considerando a extensão de áreas degradadas e a área total do estudo, conforme demonstrado nas figuras de 25 a 31, a seguir.

Figura 24 - Gráfico de distribuição percentual do uso da terra




Fonte: Elaborada pela autora.

Conforme pode ser visualizado na figura 24, com relação ao indicador de uso da terra para a classe de formação florestal, houve um percentual de ocorrência de 56,5% para as áreas degradadas *versus* 60,9% para a área total; para a classe Pastagem, houve um percentual de ocorrência de 41% para as áreas degradadas *versus* 34,7% para a área total. Para a classe Mosaico de Agricultura e Pastagem, houve um percentual de ocorrência de 1,9% para as áreas degradadas *versus* 1,8% para a área total. Para a classe Outra Área não Vegetada, houve um percentual de ocorrência de 0,3% para as áreas degradadas *versus* 1,7% para a área total. E para a classe Infraestrutura Urbana, houve um percentual de ocorrência de 0,3% para as áreas degradadas *versus* 0,9% para a área total.

A maior diferença absoluta ocorreu para a classe de Pastagem, onde o percentual de ocorrência de áreas degradadas é 6,3% superior à ocorrência desta classe na extensão da área de estudo. Uma possível explicação para essa ocorrência é o fato de que áreas de pastagem são mais susceptíveis a degradação devido aos impactos gerados pela própria natureza dessa atividade que, conforme afirmam Rocha Júnior, Silva e Guimarães (2013), podem resultar em alterações físicas, químicas e biológicas no solo. Já a maior diferença proporcional ocorreu para a classe

Outra Área não Vegetada, onde a ocorrência de áreas degradadas é mais de cinco vezes menor que a ocorrência da classe na extensão da área de estudo.

Figura 25 - Gráfico de distribuição percentual da geomorfologia




Fonte: Elaborada pela autora.

A figura 25 mostra que, com relação ao indicador de geomorfologia para a classe de Relevo Plano a Colinoso, houve um percentual de ocorrência de 15,9% para as áreas degradadas *versus* 22,0% para a área total. Para a classe de Morrotes, houve um percentual de ocorrência de 50,7% para as áreas degradadas *versus* 47,9% para a área total. Para a classe Planaltos, houve um percentual de ocorrência de 30,8% para as áreas degradadas *versus* 27,2% para a área total. E para a classe Morros, houve um percentual de ocorrência de 2,6% para as áreas degradadas *versus* 2,9% para a área.

A maior diferença absoluta ocorreu para a classe de Relevo Plano a Colinoso, onde o percentual de ocorrência de áreas degradadas é 6,1% inferior à ocorrência desta classe na extensão da área de estudo. Essa diferença pode estar relacionada ao fato de que áreas com relevo plano a colinoso comumente apresentam baixo nível de degradação (CANDIDO; BARBOSA; SILVA, 2002; SA; RICHÉ; FOTIUS, 2004). E, proporcionalmente, não houve nenhuma diferença muito significativa.

Figura 26 - Gráfico de distribuição percentual da declividade




Fonte: Elaborada pela autora.

Para o indicador de declividade (ver figura 26), tem-se que, para a classe de 0% a 3%, houve um percentual de ocorrência de 2,4% para as áreas degradadas *versus* 3,4% para a área total. Para a classe de 3% a 8%, houve um percentual de ocorrência de 16,7% para as áreas degradadas *versus* 19,2% para a área total. Para a classe de 8% a 20%, houve um percentual de ocorrência de 46,3% para as áreas degradadas *versus* 45,2% para a área total. Para a classe de 20% a 45%, houve um percentual de ocorrência de 33,9% para as áreas degradadas *versus* 31,5% para a área total. E para a classe 45% a 75%, houve um percentual de 0,7% para ambas as áreas.

As maiores diferenças absolutas ocorreram para a classe de 3% a 8%, onde o percentual de ocorrência de áreas degradadas é 2,5% inferior à ocorrência desta classe na extensão da área de estudo, e para a classe a de 20% a 45%, onde o percentual de ocorrência de áreas degradadas é 2,4% superior à ocorrência desta classe na extensão da área de estudo. Essas diferenças estão em conformidade com os resultados obtidos por Crepani et al. (2001) e Zhang et al. (2015) que demonstram que há ocorrência de processos erosivos mais intensos em áreas de maiores declives.

Também estão de acordo com o disposto por Araújo et al. (2013) que avaliou a influência da declividade sobre os processos erosivos que contribuem para a degradação ambiental identificando que as áreas com maiores declividades estão mais susceptíveis a essa ocorrência. Todavia vale observar que as áreas excessivamente declivosas (declividades maiores que 45%) estão mais protegidas por se enquadrarem como áreas de preservação permanente conforme disposto pela Lei 12.651, de 25 de Maio de 2012.


Figura 27 - Gráfico de distribuição percentual da exposição ao Sol



Fonte: Elaborada pela autora.

Quanto à exposição ao Sol (ver figura 27), tem-se que para a classe de baixa exposição houve um percentual de ocorrência de 48,5% para as áreas degradadas *versus* 50,0% para a área total. Para a classe de média exposição, houve um percentual de ocorrência de 50,8% para as áreas degradadas *versus* 48,9% para a área total. Para a classe de alta exposição houve um percentual de ocorrência de 0,7% para as áreas degradadas *versus* 1,1% para a área total. Para nenhuma das classes, houve diferença absoluta superior a 2%.

Figura 28 - Gráfico de distribuição percentual da proximidade a áreas urbanas




Fonte: Elaborada pela autora.

A análise da figura 28 mostra que para o indicador de proximidade a áreas urbanas tem-se que para a classe de 0 a 50 m houve um percentual de ocorrência de 1,0% para as áreas degradadas *versus* 3,4% para a área total. Para a classe de 50 m a 100 m, houve um percentual de ocorrência de 0,6% para as áreas degradadas *versus* 1,6% para a área total. Para a classe de 100 m a 300 m, houve um percentual de ocorrência de 7,0% para as áreas degradadas *versus* 9,7% para a área total. Para a classe de 300 m a 600 m, houve um percentual de ocorrência de 10,8% para as áreas degradadas *versus* 13,1% para a área total. E, para a classe maior que 600 m, houve um percentual de 80,6% para as áreas degradadas *versus* 72,3% para a área total.

A maior diferença absoluta ocorreu para a classe maior que 600 m, onde o percentual de ocorrência de áreas degradadas é 8,3% superior à ocorrência desta classe na extensão da área de estudo. Embora essa observação fuja do padrão esperado, conforme disposto por Ameen & Mourshed (2017), de maior ocorrência de degradação em localidades mais próximas a áreas urbanas, neste caso específico esse fato pode estar relacionado com a localização dos poços de exploração.


Figura 29 - Gráfico de distribuição percentual da proximidade a corpos d'água



Fonte: Elaborada pela autora.

Já com relação ao indicador de proximidade a corpos d'água tem-se que para as classes de 0 a 50 m e 50 a 100 m houve um percentual de ocorrência de 1,1% para as áreas degradadas *versus* 1,3 % para a área total; para a classe de 100 a 300 m houve um percentual de ocorrência de 4,0% para as áreas degradadas *versus* 5,0% para a área total; para a classe de 300 a 600 m houve um percentual de ocorrência de 5,9% para as áreas degradadas *versus* 7,3% para a área total; e para a classe maior que 600 m houve um percentual de 87,9% para as áreas degradadas *versus* 85,2% para a área total. A maior diferença absoluta ocorreu para a classe maior que 600 m onde o percentual de ocorrência de áreas degradadas é 2,7% superior a ocorrência desta classe na extensão da área de estudo. Essa diferença pode estar relacionada com a menor disponibilidade hídrica nas áreas mais afastadas dos corpos d'água.

Figura 30 - Gráfico de distribuição percentual da proximidade a áreas de formação florestal



Por fim, com relação ao indicador de proximidade a áreas de formação florestal, tem-se que, para as classes de 0 a 50 m, houve um percentual de ocorrência de 88,6% para as áreas degradadas *versus* 88,3% para a área total. E, para a classe de 50 m a 100 m, houve um percentual de ocorrência de 11,4% para as áreas degradadas *versus* 11,7% para a área total, não havendo grandes diferenças entre elas. Entretanto, segundo Almeida (2016), a proximidade da área degradada a fragmentos florestais pode acelerar a regeneração natural da área através da migração de propágulos.

Para os indicadores cujas variáveis são quantitativas ou qualitativas ordinais, a exemplo da declividade, exposição ao Sol, proximidade a áreas urbanas, proximidade a corpos d'água e proximidade a áreas de formação florestal, foi realizado o teste U de Mann-Whitney⁷, considerando um nível de significância de 0,05%, conforme descrito no quadro 5, a seguir.

⁷ Teste estatístico não paramétrico utilizado para averiguar se a distribuição de uma variável contínua ou qualitativa ordinal é a mesma em duas populações independentes.

Quadro 5 - Teste U de Mann-Whitney

Indicador	Hipótese nula	Decisão
Declividade	A distribuição das classes de declividade é a mesma entre áreas degradadas e áreas não degradadas	Rejeitar a hipótese nula
Exposição ao Sol	A distribuição das classes de exposição ao Sol é a mesma entre áreas degradadas e áreas não degradadas	Rejeitar a hipótese nula
Proximidade a áreas urbanas	A distribuição das classes de proximidade a áreas urbanas é a mesma entre áreas degradadas e áreas não degradadas	Rejeitar a hipótese nula
Proximidade a corpos d'água	A distribuição das classes de proximidade a corpos d'água é a mesma entre áreas degradadas e áreas não degradadas	Rejeitar a hipótese nula
Proximidade a áreas de formação florestal	A distribuição das classes de proximidade a áreas de formação florestal é a mesma entre áreas degradadas e áreas não degradadas	Aceitar a hipótese nula

Fonte: Elaborada pela autora.

Do quadro 6, percebe-se que, para os indicadores de declividade, exposição ao Sol, proximidade a áreas urbanas e proximidade a corpos d'água, há uma diferença estatisticamente significativa entre a distribuição de suas classes em áreas degradadas e áreas não degradadas. Sendo assim, para esses indicadores, tem-se aceita a hipótese alternativa de que a distribuição de suas classes não é a mesma entre áreas degradadas e áreas não degradadas.

5 CONCLUSÃO

Com relação a comparação dos modelos digitais de elevação, ao analisar as médias e desvios das diferenças de elevação, considerando o modelo da SEI como um dado de referência, percebe-se que o modelo ALOS tende a apresentar uma maior correlação e constância da distribuição de suas diferenças. Essa observação é reafirmada pela análise dos histogramas das diferenças entre os modelos ALOS e SEI, que demonstram que para o modelo ALOS, embora haja uma tendência de apresentar valores de altitudes menores que o modelo da SEI, só há ocorrência de pontos com diferenças superiores ao dobro da soma da precisão nominal em apenas um sentido.

O modelo ASTER, apesar de apresentar uma tendência de maior ocorrência de valores de altitude superiores ao modelo SEI, tem uma concentração significativa e desproporcional de diferenças em todos os intervalos analisados para ambos os lados. Já no modelo SRTM, a concentração de diferença ao longo dos intervalos analisados é aproximadamente proporcional e tende a diminuir bastante (aproximadamente 0,2%) para valores acima do triplo da soma das precisões nominais. Ao ponderar todos os fatos anteriormente elencados, o modelo ALOS foi escolhido como o modelo digital de superfície a ser utilizado na elaboração do mapa.

A partir do mapa de favorabilidade foi possível perceber que existe uma concentração de áreas muito favoráveis na região da vizinhança do Rio Catu. No geral os centroides de áreas degradadas localizadas em regiões muito favoráveis tiveram uma representatividade considerável ao longo da área de estudo, representando um total de 15% de toda a área. Se considerarmos o grupo das regiões de favorabilidade alta e muito alta, tem-se que essas áreas juntas somam um total de 57% de toda a área mapeada, o que representa uma quantidade considerável de áreas que podem ser trabalhadas com maior chance de sucesso.

Observou-se que o conhecimento dos critérios e fatores que podem influenciar no estabelecimento de processos de degradação é muito importante pois serve como base para uma melhor tratativa processos. Os sistemas de informações geográficas se destacam como ferramenta bastante útil para a obtenção dessas informações por viabilizar a realização de análises espaciais e permitir o manuseio de diferentes camadas de informações a fim de identificar as características predominantes nessas regiões. As análises realizadas demonstraram um indicativo de não aleatoriedade na

distribuição de áreas degradadas na área de estudo, isto porque, para alguns critérios analisados há uma diferença significativa no percentual de ocorrência de áreas degradadas em suas classes quando comparadas a área total

No que tange à geomorfologia percebeu-se uma tendência de menor ocorrência de áreas degradadas nas classes de relevo plano a colinoso, para a declividade percebeu-se uma tendência de menor ocorrência de áreas degradadas na classe de declividade que varia entre 3% a 8% e maior ocorrência na classe de declividade que varia entre 20 a 45%. Ao analisar a proximidade com áreas urbanas percebeu-se que há uma maior tendência de ocorrência de áreas degradadas em áreas com distancias maiores que 600 m as áreas urbanas. Neste caso específico, entende-se que esse resultado possa estar relacionado com a localização dos poços de exploração no campo de Água Grande, que não estão próximos das áreas urbanas. Para a proximidade com corpos d'água foi identificada uma maior ocorrência de áreas degradadas nas regiões com distância superior a 600 metros e para a proximidade a áreas de formação florestal não foram encontradas diferenças significativas na distribuição das áreas degradadas com relação as classes analisadas.

Com o prévio conhecimento dessas características a elaboração de projetos de recuperação posteriores pode ser mais assertiva, pois viabiliza a estruturação de um plano mais direcionado as particularidades da região garantindo a utilização de uma estratégia mais eficiente e eficaz. Com isso, pode-se melhor empregar os recursos utilizados e viabilizar a recuperação de um número maior de áreas. Além disso, esse produto pode ser utilizado na etapa anterior à escolha dos locais de exploração para que, quando possível, sejam escolhidas áreas com maior potencial de recomposição, visando facilitar o processo posterior. Tem-se, então, aceita a hipótese de pesquisa, visto que os resultados demonstraram que é possível gerar um mapa de favorabilidade à recomposição florestal em zonas tropicais degradadas por exploração de petróleo e gás *onshore* com base em dados *geospatial big data open access*.

Dentre os sete indicadores utilizados na pesquisa, foram identificados, de acordo com a opinião dos especialistas consultados, aqueles preferenciais para hierarquização de regiões mais ou menos favoráveis ao reflorestamento. O uso da terra, a proximidade com áreas de formação florestal e a proximidade a corpos d'água apareceram como os indicadores de maior impacto, obtendo peso máximo na construção do mapa, sendo este igual a 5. O uso da terra, que se destacou como um indicador de grande influência no processo, pode ter sua alta influência explicada, pois

o uso da terra é um fator fundamental na definição de metodologias para o estabelecimento da recomposição florestal, bem como na quantidade de interferência necessária para o sucesso do processo.

A proximidade com áreas de formação florestal também teve importância acentuada, sendo áreas mais próximas consideradas mais favoráveis. Essa importância pode estar associada pelo fato de viabilizar o aumento da continuidade da vegetação preexistente e, como consequência, aumentar também as possibilidades de troca genética. A proximidade a corpos d'água também se mostrou bastante relevante, sendo consideradas as áreas mais próximas aos corpos d'água mais adequadas. Essa preferência pode ser justificada devido ao fato de a água ser essencial para o desenvolvimento e a manutenção da vegetação. Além disso, tem-se também a maior necessidade de proteção nessas áreas devido à presença dos recursos hídricos.

Em seguida, obtendo peso 4, vem o indicador declividade. Neste caso, as áreas com declives um pouco mais acentuados foram consideradas mais adequadas. Um fator que pode justificar essa preferência é a maior necessidade de proteção ao solo nessas áreas. Também entra nesta questão a maior dificuldade de mecanização para a implantação do processo produtivo em áreas com declives mais acentuados. Por fim, obtendo peso 3, tem-se os indicadores de proximidades com áreas urbanas, geomorfologia e intensidade de exposição ao Sol. Para as áreas urbanas, foi considerado que quanto mais distante, melhor; para a geomorfologia foram preferidas as classes de relevo plano a colinoso e planalto; e com relação a intensidade a exposição ao Sol foi considerado que quanto mais baixa, melhor.

6 CONSIDERAÇÕES FINAIS

A utilização da análise de decisão multicritério com a consulta de opinião a especialistas foi considerada como uma boa opção para a categorização da favorabilidade. O método de decisão multicritério baseado em SIG pôde ser destacado como um método que possui elevado potencial de aplicação e agrega valor ao planejamento e gestão do meio ambiente por permitir analisar e trabalhar com as mais diversas camadas de informações existentes gerando como resultado um produto que sirva como subsídio para nortear a tomada de decisão.

Deve-se compreender que uma vez conhecida as áreas mais favoráveis a recomposição florestal é importante que, posteriormente, seja realizada uma análise de prioridade a recomposição. Essa análise visa identificar quais áreas precisam de uma intervenção mais urgente considerando que são mais importantes do ponto de vista ambiental como, por exemplo, as áreas de nascentes. Desta forma, pode-se garantir uma melhor destinação dos recursos e um maior ganho para o meio ambiente.

Ressalta-se muitos outros indicadores podem ser utilizados na determinação a favorabilidade a recomposição florestal. Dentre eles, pode-se citar, por exemplo, a litologia, as zonas hidrogenéticas, o tipo de solo, a exposição ao vento, a forma do terreno, histórico do uso e cobertura da terra e o histórico de degradação. Neste estudo, devido as limitações de tempo e de dados, visto que o principal objetivo foi trabalhar exclusivamente com dados abertos oriundos do sensoriamento remoto, esses indicadores não foram considerados.

Existe a necessidade da realização de outras pesquisas que visem obter a validação dos resultados obtidos neste trabalho. Entende-se que um possível caminho para essa validação seria a iniciação das atividades de reflorestamento em áreas com diferentes níveis de favorabilidade a afim de observar se, de fato, esses processos tendem a ocorrer com maior facilidade nas áreas com maiores níveis de favorabilidade. Outro caminho seria o acompanhamento temporal das áreas mais favoráveis com o intuito de verificar se já existem processos de recuperação que foram naturalmente iniciados nessas regiões.

As análises dos modelos digitais de elevação, que também foram resultados muito importantes deste trabalho, demonstraram um padrão de comportamento desses produtos na área de estudo e serviram como subsídio para a escolha do

modelo a ser utilizado na elaboração do mapa de favorabilidade. Inclusive há o horizonte de realização de mais análises sobre esses produtos contemplando diferentes regiões do país com o objetivo de obter dados suficientes para indicar se o padrão de comportamento encontrado na área de estudo se estende ao longo de toda a extensão do território brasileiro.

Com o uso de *geospatial big data open access* é possível replicar a metodologia proposta nesta pesquisa em qualquer região e assim oferecer um subsídio para a escolha estratégica de áreas candidatas ao reflorestamento. Sugere-se que sejam realizados trabalhos com o objetivo de desenvolver um código no *Google Earth Engine* a fim de otimizar a geração do mapa de favorabilidade. Os critérios envolvidos, bem como as definições dos pesos e notas, podem variar de acordo com as particularidades de cada região. No entanto, é preciso atentar-se para a qualidade dos dados que serão utilizados como base para a construção do modelo, visto que quaisquer inconsistências existentes nos dados de entrada que não sejam tratadas serão propagadas para o resultado final.

No Brasil, considerando os 279 campos terrestres em fase produção existentes até o fim de 2019, tem-se muitas possibilidades de aplicação da metodologia utilizada nesta pesquisa a fim de otimizar o processo de recuperação das áreas degradadas. Inclui-se também a possibilidade de aplicar essa metodologia nos blocos em fase de exploração e nos campos em desenvolvimento da produção, já com o objetivo de estudar a possibilidade de realizar perfurações dos poços em áreas mais favoráveis a recuperação florestal a fim de minimizar os esforços posteriores.

No que tange a quantidade de blocos em fase de exploração e aos campos em desenvolvimento existentes no Brasil, segundo a ANP (2020) até o final de 2019 existiam 130 blocos terrestres em fase de exploração, 01 bloco em fase de exploração localizado em terra e mar e 43 campos terrestres em desenvolvimento. Estes números demonstram o potencial de aplicações desta pesquisa que podem realizadas no país. Se consideramos o cenário mundial de exploração *on-shore* multiplicam-se as possibilidades de aplicações e desenvolvimentos de estudos nesta temática.

É possível vislumbrar um cenário de aplicação do uso de *geospatial big data open access* de forma que sirvam de subsídio para o planejamento, monitoramento e tomada de decisão de questões relacionadas ao meio ambiente. Além disto, esses dados são também passíveis de utilização em pesquisas de fragilidade ambiental e

em estudos na área de ecologia de paisagem, principalmente aqueles relacionados a modelagem de corredores ecológicos.

Deve-se considerar também a possibilidade de agregar os estudos de ecologia de paisagem e a existência de corredores ecológicos na determinação da favorabilidade a recomposição florestal de uma área. Visto que essas temáticas são bastante importantes do ponto de vista ambiental por possibilitar a análise das possibilidades de conexão entre fragmentos florestais para garantir a conservação de espécies e manutenção da biodiversidade em paisagens fragmentadas.

REFERÊNCIAS

- ABRAMS, M. ASTER Global DEM Version 3, and new ASTER Water Body Dataset. In: ISPRS CONGRESS, 23., 2016, Praga, República Checa. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Volume XLI-B4., Praga, República Checa, 2016. Disponível em: https://www.researchgate.net/publication/303954787_ASTER_GLOBAL_DEM_VERSION_3_AND_NEW_ASTER_WATER_BODY_DATASET. Acesso em 9 set. 2020.
- AECON. **Relatório de impacto ambiental** - Desenvolvimento e escoamento da produção de petróleo bloco bm-c-41, bacia de campos. 2011. Disponível em: https://iema.es.gov.br/Media/iema/Downloads/RIMAS/RIMAS_2011/Produ%C3%A7%C3%A3o%20de%20Petr%C3%B3leo/Rima%20BM-C-41.pdf. Acesso em: 10 dez. 2018.
- AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS (ANP). **Anuário estatístico brasileiro do petróleo, gás natural e biocombustíveis**: 2020. Rio de Janeiro, 2020. Disponível em: <http://www.anp.gov.br/publicacoes/anuario-estatistico/5809-anuario-estatistico-2020>. Acesso em: 22 ago. 2020.
- ALMEIDA, D.S. Modelos de recuperação ambiental. In: **Recuperação ambiental da Mata Atlântica**, 3a ed. Ilhéus, Bahia: Editus. 2016. Disponível em: <http://books.scielo.org/id/8xvf4/pdf/almeida-9788574554402-09.pdf>. Acessado em 14 de outubro 2020.
- AL-RUZOUQ, R; AL RAWASHDEH, S. Geomatics for Rehabilitation of Mining Area in Mahis, Jordan. **Journal of Geographic Information System**, 6, p. 123-134, 2014. Disponível em: <https://pdfs.semanticscholar.org/017e/43f0fe2d4f0c7fa1c3f730395605690907a7.pdf>. Acesso em 9 set. 2020.
- AMEEN, R.F.M.; MOURSHED, M. Urban environmental challenges in developing countries-A stakeholder perspective, **Habitat International**, V. 64. 2017. Disponível em: https://www.researchgate.net/publication/316105272_Urban_environmental_challenges_in_developing_countries-A_stakeholder_perspective. Acessado em 14 de outubro 2020.
- ARAÚJO, I.N.F.; MELO, J.F.G.; MARINHO, A.P.F; SILVA, R.D.; RIBEIRO, A.C.S.; CUNHA, G.K.G.; CUNHA, K.P.V. Influência da declividade na erosão e degradação ambiental do Médio Piranhas Potiguar. **Anais do Congresso Brasileiro de Gestão Ambiental e Sustentabilidade**, v. 6. 2018. Disponível em: <http://eventos.ecogestaobrasil.net/congestas2018/trabalhos/pdf/congestas2018-et-04-001.pdf>. Acessado em 14 de outubro de 2020.
- AQUINO, F. N. P. M.; COSTA, L. F. L. G. Riscos ambientais em uma sonda de perfuração de petróleo *onshore* na unidade de negócios-RN/CE- Mossoró/RN. **HOLOS**, Ano 27, Vol. 3, 2011. Disponível em:

<http://www2.ifrn.edu.br/ojs/index.php/HOLOS/article/view/587>. Acesso em 9 set. 2020.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR ISO 14001**: Sistema de gestão ambiental: especificação e diretrizes para uso. Rio de Janeiro, 2015. Disponível em: <http://www2.mma.gov.br/port/conama/res/res86/res0186.html>. Acesso em 09/12/2018. Acesso em: 10 dez. 2018.

BAHIA. Secretaria de Desenvolvimento Econômico. Coordenação de Fomento à Mineração, Petróleo e Gás. In: Petróleo e Gás. **Informe Executivo**. Salvador, nov. 2019. Disponível em: <http://www.sde.ba.gov.br/wp-content/uploads/2020/02/Informe-Executivo-Petroleo-e-gas-Novembro-2019-vf.pdf>. Acesso em: 1 set. 2020.

BANKO, G. **A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data and of Methods Including Remote Sensing Data in Forest Inventory**. International Institute for Applied Systems Analysis: Laxenburg, Austria, 1998. Disponível em: <http://pure.iiasa.ac.at/id/eprint/5570/1/IR-98-081.pdf>. Acesso em: 1 set. 2020.

BARBOSA, C. C. F. **Álgebra de mapas e suas aplicações em sensoriamento remoto e geoprocessamento**. 1997. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1997. Disponível em: <http://mtc-m12.sid.inpe.br/col/dpi.inpe.br/banon/1998/05.07.15.37/doc/publicacao.pdf>. Acesso em: 1 set. 2020.

BARBOSA, C. C. F.; CÂMARA, G.; MEDEIROS, J. S.; CREPANI, E.; NOVO, E.; CORDEIRO, J. P. Operadores Zonais em Álgebra de Mapas e Sua Aplicação a Zoneamento Ecológico Econômico. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9., 1998, Santos. **Anais [...]**. Santos, 1998. Disponível em: <http://www.dpi.inpe.br/gilberto/papers/sbsr98.pdf>. Acesso em: 1 set. 2020.

BARBOSA, M. S. A. **Recomposição florestal de área de preservação permanente no bairro grama em juiz de fora – MG**. 2017. Trabalho Final de Curso. Faculdade de Engenharia da UFJF. 2017. Disponível em: <https://www.ufjf.br/engsanitariaeambiental/files/2014/02/TFC.pdf>. Acesso em 9 set. 2020.

BAYLÃO JUNIOR, Hiram Feijó. **Análise da restauração florestal espontânea a partir dos efeitos de nucleação da *Guarea guidonia* (L.) Sleumer na vertente atlântica da Serra do Mar, Piraí, RJ – Brasil**. 2014. Tese (Doutorado em Ciências Ambientais e Florestais) – Universidade Federal Rural do Rio de Janeiro, Seropédica, 2014. Disponível em: <https://tede.ufrj.br/jspui/bitstream/jspui/3034/2/2014%20-%20Hiram%20Feij%c3%b3%20Bayl%c3%a3o%20Junior.pdf>. Acesso em 9 de set. 2020.

BERRY, J. K. Computer-Assisted Map Analysis: Potential and Pitfalls. **PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING**, vol. 53, n. 10,

1405-1410, 1987. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1987journal/oct/1987_oct_1405-1410.pdf. Acesso em: 1 set. 2020.

BLUMENFELD, J. **Getting Petabytes to People: How EOSDIS Facilitates Earth Observing Data Discovery and Use**. 2015. Disponível em: <https://earthdata.nasa.gov/getting-petabytes-to-people-how-theeosdis-facilitates-earth-observing-data-discovery-and-use>. Acesso em: 23 jul. 2020.

BRASIL. **Decreto-Lei nº 3.236, de 7 de maio de 1941**. Institui o regime legal das jazidas de petróleo e gases naturais, de rochas betuminosas e piro-betuminosas e dá outras providências. Brasília, 1941. Disponível em: <https://www2.camara.leg.br/legin/fed/declei/1940-1949/decreto-lei-3236-7-maio-1941-413329-norma-pe.html>. Acesso em: 21 ago. 2020.

BRASIL. **Lei nº 9.985, de 18 de julho de 2000**. Regulamenta o art. 225, § 1º, incisos I, II, III e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências. Brasília, 2000. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/19985.htm. Acesso em: 21 ago. 2020.

BRASIL. **Lei nº 6.938, de 31 de agosto de 1981**. Dispõe sobre a Política Nacional do Meio Ambiente, seus fins e mecanismos de formulação e aplicação, e dá outras providências. Brasília, 1981. Disponível em: <https://www2.camara.leg.br/legin/fed/lei/1980-1987/lei-6938-31-agosto-1981-366135-norma-actualizada-pl.html>. Acesso em: 10 dez. 2018.

BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Dispõe sobre a proteção da vegetação nativa; altera as Leis nºs 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nºs 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória nº 2.166-67, de 24 de agosto de 2001; e dá outras providências. Brasília, 2012. Disponível em: <https://www2.camara.leg.br/legin/fed/lei/2012/lei-12651-25-maio-2012-613076-norma-pl.html>. Acesso em: 04 set. 2020.

BRASIL. **Resolução CONAMA nº 001, de 23 de janeiro de 1986**. Brasília, 1986. Disponível em: <http://www2.mma.gov.br/port/conama/res/res86/res0186.html>. Acesso em: 10 dez. 2018.

BRASIL. **Resolução nº 237, de 1997**. Dispõe sobre licenciamento ambiental; competência da União, Estados e Municípios; listagem de atividades sujeitas ao licenciamento; Estudos Ambientais, Estudo de Impacto Ambiental e Relatório de Impacto Ambiental. Disponível em: <http://www.mma.gov.br/port/conama/res/res97/res23797.html>. Acesso em: 18 jun. 2020.

CALDAS, A. J. F. S. **Geoprocessamento e análise ambiental para determinação de corredores de habitat na Serra da Concórdia, Vale do Paraíba – RJ**. 2006. Dissertação (Mestrado em Ciências Ambientais e Florestais) – Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2006. Disponível em:

<http://www.if.ufrjr.br/pgcaf/pdfdt/Dissertacao%20Aiga%20Caldas.pdf>. Acesso em 9 de set. 2020.

CANDIDO, H. G; BARBOSA, M. P.; SILVA, M. J. Avaliação da degradação ambiental de parte do Seridó Paraibano. Campina Grande: **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 6, n. 2, 2002. Disponível em: https://www.scielo.br/scielo.php?pid=S1415-43662002000200031&script=sci_arttext. Acesso em 9 de set. 2020.

CÂMARA, G.; MEDEIROS, J. S. Mapas e suas representações computacionais. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas: aplicações na agricultura**. Brasília: Embrapa, 1998.

CÂMARA, Gilberto; MONTEIRO, Antônio Miguel Vieira; DRUCK, Suzana; CARVALHO, Marília Sá. Análise Espacial e Geoprocessamento. In: CAMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. São José dos Campos, INPE, 2004. Disponível em: <http://www.dpi.inpe.br/gilberto/livro/analise/cap1-intro.pdf>. Acesso em 9 set. 2020.

CARVALHO, S. S; SILVA, B. C. N. Modelagem cartográfica para identificação de níveis de desenvolvimento: o exemplo de Salvador-Bahia e de sua região metropolitana. In: COLÓQUIO INTERNACIONAL DE GEOCRÍTICA, 10., Barcelona, 2008. **Anais[...]**, Barcelona, 2008. Disponível em: <http://www.ub.edu/geocrit/-xcol/151.htm>. Acesso em: 1 set. 2020.

CAVAZZANA, Guilherme Henrique; LASTORIA, Giancarlo; DALMAS, Fabrício Bau; GABAS, Sandra Garcia; PARANHOS FILHO, Antonio Conceição. Maps Algebra Application to Obtain Natural and Environmental Vulnerability of Flooding Areas. **Anuário do Instituto de Geociências** – UFRJ, Vol. 41 - 1, 255-264, 2018. Disponível em: <https://revistas.ufrj.br/index.php/aigeo/article/view/27741>. Acesso em 9 set. 2020.

CHEN, M.; MAO, S.; LIU, Y. Big Data: A Survey. **Mobile Networks and Applications**, 19(2), 171-209, 2014. Disponível em: https://www.researchgate.net/publication/263480370_Big_data_A_survey. Acesso em 9 set. 2020.

CONGALTON, R. G. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire**, 10, 321-328, 2000. Disponível em: https://www.researchgate.net/publication/220040678_Accuracy_assessment_and_validation_of_remotely_sensed_and_other_spatial_information. Acesso em 9 set. 2020.

COWEN, D. J. GIS versus CAD versus DBMS: What are the differences?. **Photogrammetric engineering and remote sensing**, Vol. 54, n. 11, p. 1551-1555, 1988. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1988journal/nov/1988_nov_1551-1555.pdf. Acesso em 9 set. 2020.

CREPANI, Edison; MEDEIROS, José Simeão de; HERNANDEZ FILHO, Pedro; FLORENZANO, Teresa Gallotti; DUARTE, Valdete; BARBOSA, Cláudio Clemente Faria. **Sensoriamento remoto e geoprocessamento aplicados ao zoneamento ecológico-econômico e ao ordenamento territorial**. São José dos Campos, INPE, 2001. Disponível em: <http://sap.ccst.inpe.br/artigos/CrepaneEtAl.pdf>. Acesso em 9 set. 2020.

D'ALGE, Júlio César Lima. Cartografia para Geoprocessamento. In: CAMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. São José dos Campos, INPE, 2004. Disponível em: <http://www.dpi.inpe.br/gilberto/livro/introd/cap6-cartografia.pdf>. Acesso em 9 set. 2020.

DEY, N.; MISHRA, G.; KAR, J.; CHAKRABORTY, S.; NATH, S. S. **A survey of image classification methods and techniques**. In: INTERNATIONAL CONFERENCE ON CONTROL, INSTRUMENTATION, COMMUNICATION AND COMPUTATIONAL TECHNOLOGIES, 2014. Disponível em: https://www.researchgate.net/publication/269984702_A_survey_of_image_classification_methods_and_techniques. Acesso em 9 set. 2020.

DROBNE, Samo; LISEC, Anka. Multi-attribute Decision Analysis in GIS: Weighted Linear Combination and Ordered Weighted Averaging. **Informatica**, Slovenia, 33, p. 459-474, 2009. Disponível em: <http://www.informatica.si/index.php/informatica/article/view/263/260>. Acesso em 9 set. 2020.

FARR, T. G.; ROSEN, P. A.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S.; KOBRICK, M.; PALLER, M.; RODRIGUEZ, E.; ROTH, L.; SEAL, D.; SHAFFER, S.; SHIMADA, J.; UMLAND, J.; WERNER, M.; OSKIN, M.; BURBANK, D.; ALSDORF, D. The Shuttle Radar Topography Mission. **Rev. Geophys.**, 45, 2007. Disponível em: https://www2.jpl.nasa.gov/srtm/SRTM_paper.pdf. Acesso em: 8 dez. 2018.

FERREIRA, E.; DANTAS, A. A. A.; MORAIS, A. R. Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no município de Lavras, MG. In: Simpósio Brasileiro de Sensoriamento Remoto, 13., Florianópolis, Brasil, 21-26 abril 2007, **Anais[...]**, Florianópolis: INPE, 2007. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.10.14.40/doc/887-894.pdf>. Acesso em 9 set. 2020.

FICK, Steve; HIJMANS, Robert. WorldClim 2: New 1-km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, 2017. Disponível em: https://www.researchgate.net/publication/316999789_WorldClim_2_New_1-km_spatial_resolution_climate_surfaces_for_global_land_areas. Acesso em 9 set. 2020.

FINEGOLD, Y.; ORTMANN, A.; LINDQUIST, E.; D'ANNUNZIO, R.; SANDKER, M. **Map Accuracy Assessment and Area Estimation: A Practical Guide**. Food and Agriculture Organization of the United Nations: Rome, 2016. Disponível em: <http://www.fao.org/3/a-i5601e.pdf>. Acesso em 9 set. 2020.

FITZ, P. R. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002. 97p.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, 80, p. 185-201, 2002. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425701002954>. Acesso em 9 de set. 2020.

FREITAS, Laylla Gabrielle Borges Correia. **Identificação e estudo das áreas favoráveis para o cultivo da Khaya Ivorensis A. Chev. (mogno africano) no estado de Minas Gerais, utilizando modelagem ambiental e análise multicritério**. Dissertação (mestrado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2015. Disponível em: https://repositorio.ufmg.br/bitstream/1843/IGCM-9WUQP2/1/laylla_gabrielle.pdf. Acesso em 15 de nov. 2020.

HOLT, IAN. **Geospatial Big Data**. GIM Internacional, 2017. Disponível em: <https://www.gim-international.com/content/article/geospatial-big-data-2?output=pdf>. Acesso em: 12 jun. 2020.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective**. 2 ed. New Jersey: Pearson Prentice Hall, 2007.

KHAN, M. Ali-ud-din; UDDIN, Muhammad Fahim; GUPTA, Navarun. **Seven V's of Big Data - Understanding Big Data to extract Value**. Proceedings of the 2014 Zone 1 Conference of the American Society for Engineering Education, Bridgeport, p. 1-5, 2014. Disponível em: <https://ieeexplore.ieee.org/document/6820689/>. Acesso em 9 set. 2020.

LAI, Shih-Kung; HOPKINS, Lewis. The meanings of trade-offs in multiattribute evaluation methods: A comparison. **Environment and Planning B: Planning and Design**, 16, 155-170, 1989. Disponível em: https://www.researchgate.net/publication/23540654_The_meanings_of_trade-offs_in_multiattribute_evaluation_methods_A_comparison. Acesso em 9 set. 2020.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, Washington, v. 33, n. 3, p.159-179, 1977. Disponível em: https://www.jstor.org/stable/2529310?seq=1#metadata_info_tab_contents. Acesso em 9 set. 2020.

LANEY, Doug. **Data Management: Controlling Data Volume, Velocity, and Variety**. 2001. Disponível em: <https://blogs.gartner.com/doug-laney/files/2012/01/ad949-3D-Data-Management-Controlling-Data-Volume-Velocity-and-Variety.pdf>. Acesso em 05 set. 2020.

LEE, Jae-Gil; KANG, Minseo. Geospatial Big Data: Challenges and Opportunities. **Big Data Research**, v. 2, p. 74-81, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214579615000040>. Acesso em 9 set. 2020.

LI, Jie; HUMPHREY, Marty; AGARWAL, Deborah; JACKSON, Keith; INGEN, Catharine; RYU, Youngryel. eScience in the Cloud: A MODIS Satellite Data Reprojection and Reduction Pipeline in the Windows Azure Platform. **Parallel & Distributed Processing (IPDPS), IEEE International Symposium on**, Atlanta, EUA, 2010.

LI, S.; DRAGICEVIC, S.; ANTON, F.; SESTER, M.; WINTER, S.; COLTEKIN, A.; CHENG, T. Geospatial Big Data Handling Theory and Methods: A Review and Research Challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, 115, p. 119-133, 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271615002439>. Acesso em 9 set. 2020.

LI, Songnian; DRAGICEVIC, Suzana; ANTON, François; SESTER, Monika; WINTER, Stephan; COLTEKIN, Arzu; PETTIT, Christopher; JIANG, Bin; HAWORTH, James; STEIN, Alfred; CHENG, T. Geospatial Big Data Handling Theory and Methods: A Review and Research Challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, 115, p. 119-133, 2015. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271615002439>. Acesso em 9 set. 2020.

LI, Zhenlong. Geospatial Big Data Handling with High Performance Computing: Current Approaches and Future Directions. **High Performance Computing for Geospatial Applications**. Publisher: Springer 2019. Disponível em: https://www.researchgate.net/publication/334413087_Geospatial_Big_Data_Handling_with_High_Performance_Computing_Current_Approaches_and_Future_Direction. Acesso em 9 set. 2020.

LINS, Daniela Barbosa da Silva. **Conservação de fragmentos florestais interpretada por parâmetros espaciais relacionados a uma espécie-alvo**. Campinas, SP. Dissertação de Mestrado - Universidade Estadual de Campinas, Faculdade de Engenharia Civil, Arquitetura e Urbanismo.

LIU, C.; HUANG, X.; ZHU, Z.; CHEN, H.; TANG, X.; GONG, J. Automatic extraction of built-up area from ZY3 multi-view satellite imagery: Analysis of 45 global cities. **Remote Sensing of Environment**, volume 226, 2019, p. 51-73. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425719301245>. Acesso em 9 set. 2020.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, Volume 28, 2007. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431160600746456>. Acesso em 9 set. 2020.

MACEACHREN, A.M.; KRAAK, M. Research challenges in geovisualization. **Cartography and Geographic Information Systems**, volume. 28, nº 1, 2001, p.3-12. Disponível em: <<https://www.tandfonline.com/doi/pdf/10.1559/152304001782173970?needAccess=true>> Acessado em 13 nov. 2020.

MALCZEWSKI, J. GIS-based multicriteria decision analysis: a survey of the literature. **International Journal of Geographical Information Science**, 20:7, 703-726, 2007. DOI: 10.1080/13658810600661508. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/13658810600661508>. Acesso em 9 set. 2020.

MAPBIOMAS. **Projeto MapBiomas**: Coleção 3.0 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil. [S.l.]: 2019. Disponível em: <<http://mapbiomas.org/>>. Acesso em: 15 out. 2019.

MARCHI, Maurizio; SINJUR, Iztok; BOZZANO, Michele; WESTERGRENN, Marjana. Evaluating WorldClim Version 1 (1961–1990) as the Baseline for Sustainable Use of Forest and Environmental Resources in a Changing Climate. **Sustainability**, 2019. Disponível em: <https://www.mdpi.com/2071-1050/11/11/3043/htm>. Acesso em 9 set. 2020.

MARTINS, Silas Sarkiz da Silva; AZEVEDO, Matheus Oliveira de; SILVA, Mikaias Pereira da; SILVA, Valdenildo Pedro da. Produção de petróleo e impactos ambientais: algumas considerações. **HOLOS**, [S.l.], v. 6, p. 54-76, dez. 2015. ISSN 1807-1600. Disponível em: <http://www2.ifrn.edu.br/ojs/index.php/HOLOS/article/view/2201>. Acesso em: 10 dez. 2018.

MONTEIRO, F. P. **ClasSIS: uma metodologia para classificação supervisionada de imagens de satélite em áreas de assentamento localizados na Amazônia**. 2015. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pará, Instituto de Tecnologia, Belém, 2015. Disponível em: http://repositorio.ufpa.br/jspui/bitstream/2011/7646/1/Dissertacao_ClassisMetodologiaClassificacao.pdf, Acesso em 9 set. 2020.

MOREIRA, F. R.; BARBOSA, C.; CAMARA, G.; ALMEIDA FILHO, R. Inferência geográfica e suporte a decisão. In: CAMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. São José dos Campos: INPE, 2004. Disponível em: <http://www.dpi.inpe.br/gilberto/livro/introd/cap9-inferencia.pdf>. Acesso em 9 set. 2020.

MUSTAJOKI, J; HÄMÄLÄINEN, R. P. Smart-Swaps - A decision support system for multicriteria decision analysis with the even swaps method. **Decision Support Systems**, 44, 313-325, 2007. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0167923607000723>. Acesso em 9 set. 2020.

NASA. Relatório métrico anual da Nasa. EUA: 2019. Disponível em: <https://earthdata.nasa.gov/eosdis/system-performance/eosdis-annual-metrics-reports>. Acesso em: 1 set. 2020.

NOVO, Evlyn Márcia Leão de Moraes; PONZONI, Flávio Jorge. **Introdução ao Sensoriamento Remoto**. São José dos Campos, INPE, 2001. Disponível em: http://www.dpi.inpe.br/Miguel/AlunosPG/Jarvis/SR_DPI7.pdf. Acesso em 9 set. 2020.

PETROBRAS. **A história do petróleo**: dos pioneiros à Petrobras. 2006a. Disponível em: https://www.agenciapetrobras.com.br/Materia/ExibirMateria?p_materia=1262. Acesso em: 1 set. 2020.

PETROBRAS. **Bahia deu berço e escola ao petróleo brasileiro**. 2006b. Disponível em: https://www.agenciapetrobras.com.br/Materia/ExibirMateria?p_materia=1304. Acesso em: 1 set. 2020.

PETROBRAS. **Mapeamento Geoambiental dos Campos de Produção Ativo Sul, Bacia do Recôncavo**. Editora: E&P, Salvador. V. 1. Junho, 2009.

PIROLI, E. L. **Introdução ao geoprocessamento**. Ourinhos, UNESP, 2010. Disponível em: http://vampira.ourinhos.unesp.br:8080/cediap/material/livro_introducao_ao_geoprocessamento.pdf. Acesso em 9 set. 2020.

RABUS, Bernhard; EINEDER, Michael; ROTH, Achim; BAMLER, Richard. The shuttle radar topography mission: a new class of digital elevation models acquired by spaceborne radar. **ISPRS Journal of Photogrammetry & Remote Sensing**, 57, 241-262, 2003. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271602001247>. Acesso em 9 set. 2020.

ROBINSON, Anthony; DEMŠAR, Urška; MOORE, Antoni; BUCKLEY, Aileen; JIANG, Bin; FIELD, Kenneth; M-J, Kraak; CAMBOIM, Silvana; SLUTER, Claudia. Geospatial big data and cartography: research challenges and opportunities for making maps that matter. **International Journal of Cartography**, 3:sup1, 32-60, 2017. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/23729333.2016.1278151>. Acesso em 9 set. 2020.

ROCHA JÚNIOR, Paulo Roberto; SILVA, Victor Maurício; GUIMARÃES, Gabriel Pinto. Degradação de pastagens brasileiras e técnicas de recuperação. **Enciclopédia Biosfera**, Centro Científico Conhecer Goiânia, v.9, n.17, 952-968, 2013. Disponível em: <http://www.conhecer.org.br/enciclop/2013b/CIENCIAS%20AGRARIAS/DEGRADACA O.pdf>. Acesso em 9 set. 2020.

RODRÍGUEZ, E.; MORRIS, C. S.; BELZ, J. E.; CHAPIN, E. C.; MARTIN, J. M.; DAFFER, W.; HENSLEY, S. An assessment of the SRTM topographic products. **Technical Report JPL D-31639**, Jet Propulsion Laboratory, Pasadena, California, 143p., 2005. Disponível em: https://www2.jpl.nasa.gov/srtm/SRTM_D31639.pdf. Acesso em: 8 dez. 2018.

SA, I.B.; RICHE, G.R.; FOTIUS, G.A. As paisagens e o processo de degradação do semi-árido nordestino. In: Silva JMC, Tabarelli M, Fonseca MT, Lins LV

Biodiversidade da Caatinga: áreas e ações prioritárias para a conservação.

Brasília, DF: Ministério do Meio Ambiente: Universidade Federal de Pernambuco.

2004. Disponível em:

http://www.cpatsa.embrapa.br/public_eletronica/downloads/OPB1733.pdf. Acessado em 14 de outubro de 2020.

SAHNOUN, Houda; SERBAJI, Mohamed; KARRAY, Boubaker; MEDHIOUB, Khaled. GIS and multi-criteria analysis to select potential sites of agro-industrial complex.

Environmental Earth Sciences, 66, 2011. Disponível em:

[https://www.researchgate.net/publication/257793581_GIS_and_multi-](https://www.researchgate.net/publication/257793581_GIS_and_multi-criteria_analysis_to_select_potential_sites_of_agro-industrial_complex)

[criteria_analysis_to_select_potential_sites_of_agro-industrial_complex](https://www.researchgate.net/publication/257793581_GIS_and_multi-criteria_analysis_to_select_potential_sites_of_agro-industrial_complex). Acesso em 9 set. 2020.

SANTRA, A. K.; CHRISTY, C. J. Genetic Algorithm and Confusion Matrix for Document Clustering. **IJCSI International Journal of Computer Science Issues**,

Vol. 9, N. 2, 2012. Disponível em: <https://ijcsi.org/papers/IJCSI-9-1-2-322-328.pdf>.

Acesso em 9 set. 2020.

SEABRA, Vinicius da Silva. **Análise da paisagem em apoio aos estudos de favorabilidade à recuperação florestal na bacia hidrográfica do rio São João.**

2012. Tese (Doutorado em Geografia) – Universidade Federal do Rio de Janeiro -

UFRJ, Instituto de Geociências, Programa de Pós-Graduação em Geografia, 2012.

Disponível em: <http://objdig.ufrj.br/16/teses/777886.pdf>. Acesso em 9 set. 2020.

SILVA, I.; SEGANTINE, P. **Topografia para Engenharia - Teoria e Prática de Geomática.** Rio de Janeiro, Elsevier, 2015.

SHIMADA, Masanobu; TAKUYA, Itoh; TAKESHI, Motohka; MANABU, Watanabe; TOMOHIRO, Shiraishi; RAJESH, Thapa; RICHARD, Lucas. New global forest/non-forest maps from ALOS PALSAR data (2007–2010). **Remote Sensing of Environment**,

155, 2014. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0034425714001527>. Acesso em 9 set. 2020.

TEIXEIRA, A. L. A.; MORETTI, E.; CHRISTOFOLETTI, A. **Introdução aos Sistemas de Informação Geográfica.** Rio Claro-SP: Edição do Autor, 1992.

TEIXEIRA, Isabella Lorenzini da Silva. **Potencial produtivo e econômico do açaí (Euterpe Oleracea Mart.) no estado do Pará.** Dissertação (mestrado) –

Universidade Federal de Minas Gerais, Departamento de Cartografia, 2018.

Disponível em: [https://repositorio.ufmg.br/bitstream/1843/EQVA-](https://repositorio.ufmg.br/bitstream/1843/EQVA-BBWE4U/1/disserta__o_isabella_lorenzini___folha_de_aprova__o.pdf)

[BBWE4U/1/disserta__o_isabella_lorenzini___folha_de_aprova__o.pdf](https://repositorio.ufmg.br/bitstream/1843/EQVA-BBWE4U/1/disserta__o_isabella_lorenzini___folha_de_aprova__o.pdf). Acessado em 15 nov. 2020.

THAKUR, N; MAHESHWARI, D. A review of image classification techniques.

International Research Journal of Engineering and Technology (IRJET), V. 4,

2017. Disponível em: <https://www.irjet.net/archives/V4/i11/IRJET-V4I11287.pdf>. Acesso em 9 set. 2020.

TOMLIN, C. D. Map algebra: one perspective. *Landscape and Urban Planning*, 3-12, 1994. Disponível em: http://www.dpi.inpe.br/gilberto/references/tomlin_map_algebra.pdf. Acesso em: 1 set 2020.

VALE, J. R. B; COSTA, J. A.; SANTOS, J. F.; SILVA, E. L. S.; FAVACHO, A. T. Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia, Pará. **InterEspaço Revista de Geografia e Interdisciplinaridade**, Grajaú/MA, v. 4, n. 13, 26-44, 2018. Disponível em: <http://www.periodicoseltronicos.ufma.br/index.php/interespaco/article/view/7884/5289>. Acesso em 9 set. 2020.

VENTURIERI, A.; SANTOS, J. R. dos. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. (Ed.). **Sistema de informações geográficas: aplicações na agricultura**. 2. ed. rev. amp. Brasília, DF: EMBRAPA-SPI; Planaltina, DF: EMBRAPA-CPAC, 1998. p. 351-371. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/iris@1912/2005/07.20.11.17/doc/INPE-6977.pdf>. Acesso em 9 set. 2020.

VISA, S.; RAMSAY, B.; RALESCU, A.; KNAAP, E. Confusion Matrix-based Feature Selection. In: CONFERENCE: PROCEEDINGS OF THE 22ND MIDWEST ARTIFICIAL INTELLIGENCE AND COGNITIVE SCIENCE CONFERENCE, 22., 2011, Cincinnati, Ohio, USA, April 16-17, 2011. Disponível em: <http://ceur-ws.org/Vol-710/paper37.pdf>. Acesso em: 9 set. 2020.

XU, C; YANG, C. Introduction to big geospatial data research. **Journal Annals of GIS**, Volume 20, 227-232, 2014. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/19475683.2014.938775>. Acesso em 9 set. 2020.

ZABIHI, Hasan; ALIZADEH, Mohsen; LANGAT, Philip; KARAMI, Mohammadreza; SHAHABI, Himan; AHMAD, Anuar; SAID, Mohamad; LEE, Saro. GIS Multi-Criteria Analysis by Ordered Weighted Averaging (OWA): Toward an Integrated Citrus Management Strategy. **Sustainability**, 11, 2019. Disponível em: https://www.researchgate.net/publication/331168918_GIS_Multi-Criteria_Analysis_by_Ordered_Weighted_Averaging_OWA_Toward_an_Integrated_Citrus_Management_Strategy. Acesso em 9 set. 2020.

ZAMBON, Kátia; CARNEIRO, Adriano; RODRIGUES DA SILVA, Antônio Néelson; NEGRI, Jean. Análise de decisão multicritério na localização de usinas termoelétricas utilizando SIG. **Pesquisa Operacional**, Rio de Janeiro, v. 25, n. 2, p. 183-199, 2005. Disponível em: https://www.scielo.br/scielo.php?pid=S0101-74382005000200002&script=sci_abstract&tlng=pt. Acesso em 9 set. 2020.

ZHANG, Z.; SHENG, L.; YANG, J.; CHEN, X.; KONG, L.; WANGAN, B. Effects of land use and slope gradient on soil erosion in a red soil hilly watershed of southern

China. **Sustainability**, 7, 2015. Disponível em:

https://www.researchgate.net/publication/283333316_Effects_of_Land_Use_and_Slope_Gradient_on_Soil_Erosion_in_a_Red_Soil_Hilly_Watershed_of_Southern_China.

Acessado em 14 de outubro de 2020.

APÊNDICIES

APÊNDICE A – QUESTIONÁRIO DE PESQUISA COM ESPECIALISTAS

AVALIAÇÃO DE INDICADORES DE FAVORABILIDADE A RECOMPOSIÇÃO FLORESTAL

ÁREA DE ESTUDO: CAMPO DE ÁGUA GRANDE

MUNICÍPIOS DE ABRANGÊNCIA: CATU-BA E POJUCA-BA

Este questionário de pesquisa tem como objetivo identificar os critérios preferenciais para hierarquização de regiões mais ou menos favoráveis ao reflorestamento a fim de viabilizar a elaboração de um mapa de favorabilidade a recomposição florestal. A área de estudo é o campo de Água Grande, localizado nos municípios de Catu e Pojuca, no estado da Bahia, e é uma região que foi fortemente impactada pela exploração *onshore* de petróleo e gás.

Para tal finalidade foram enumerados 07 indicadores que devem ser avaliados com relação ao seu peso na composição do mapa, sendo que cada indicador possui classes, aos quais devem ser avaliadas com relação a sua nota de influência. Os pesos devem ser avaliados em uma escala de 1 a 5, onde 1 representa que o indicador tem o menor peso para a influenciar a favorabilidade a recomposição florestal na área e 5 representa que o indicador tem o peso máximo. Já as classes devem ser avaliadas em uma escala de 0 a 10, onde 0 representa que a classe não tem nenhuma preferencialidade e 10 que a classe tem preferencialidade máxima. Por fim, existe ainda um fator sazonal cujas classes devem ser avaliadas a fim de se identificar os períodos mais favoráveis para a recomposição florestal na área.

Ao final do questionário existe um campo de observações e comentários, no qual podem ser colocadas quaisquer informações consideradas relevantes sobre a avaliação dos indicadores, classes, notas e pesos atribuídos, bem como justificativas e pontuações sobre a possível existência de algum fator relevante não citado e/ou redundância de fatores.

INDICADOR 01 – USO DO SOLO

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
FORMAÇÃO FLORESTAL	
INFRAESTRUTURA URBANA	
MOSAICO DE AGRICULTURA E PASTAGEM	
OUTRA ÁREA NÃO VEGETADA	
PASTAGEM	
RIO, LAGO E OCEANO	

INDICADOR 02 – PROXIMIDADE COM ÁREAS URBANAS

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
0 A 50 METROS	
50 A 100 METROS	
100 A 300 METROS	
300 A 600 METROS	
> 600 METROS	

INDICADOR 03 – PROXIMIDADE COM ÁREAS DE FORMAÇÃO FLORESTAL

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
0 A 50 METROS	
50 A 100 METROS	
100 A 300 METROS	
300 A 600 METROS	
> 600 METROS	

INDICADOR 04 – PROXIMIDADE COM CORPOS D'ÁGUA

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
0 A 50 METROS	
50 A 100 METROS	
100 A 300 METROS	
300 A 600 METROS	
> 600 METROS	

INDICADOR 05 – GEOMORFOLOGIA

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
PLANO A COLINOSO	
MORROTOS	
MORROS	
PLANALTO	

INDICADOR 06 – DECLIVIDADE

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
0 A 3	
3 A 8	
8 A 20	
20 A 45	
45 A 75	
> 75	

INDICADOR 07 – INTENSIDADE DE EXPOSIÇÃO AO SOL

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
BAIXA	
MODERADA	
ALTA	

FATOR SAZONAL 01 – CLIMA

PESO (1-5): _____

CLASSE	NOTA (0 – 10)
ÚMIDO	
MUITO ÚMIDO	
HIPERÚMIDO	

OBSERVAÇÕES E COMENTÁRIOS:
