

Diego Hemkemeier Silva

**METODOLOGIA PARA CLASSIFICAÇÃO DE IMAGENS DE
SATÉLITE EM NUVEM, COM APOIO DE APLICATIVO
MÓVEL**

Dissertação submetida ao Programa de Mestrado Profissional em Perícias Criminais Ambientais da Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Perícias Criminais Ambientais.

Orientador: Prof. Dr. Alexandre Siminski.

Coorientador: Prof. Dr. Alexandre ten Caten.

Florianópolis
2018

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Silva, Diego Hemkemeier
Metodologia para classificação de imagens de
satélite em nuvem, com apoio de aplicativo móvel /
Diego Hemkemeier Silva ; orientador, Alexandre
Siminski, coorientador, Alexandre Ten Caten, 2018.
138 p.

Dissertação (mestrado profissional) -
Universidade Federal de Santa Catarina, Centro de
Ciências Biológicas, Programa de Pós-Graduação em
Perícias Criminais Ambientais, Florianópolis, 2018.

Inclui referências.

1. Perícias Criminais Ambientais. 2. Mata
Atlântica. 3. Sentinel 2. 4. Google Earth Engine. I.
Siminski, Alexandre. II. Caten, Alexandre Ten. III.
Universidade Federal de Santa Catarina. Programa de
Pós-Graduação em Perícias Criminais Ambientais. IV.
Título.

“Metodologia para classificação de imagens de satélite em nuvem, com apoio de aplicativo móvel”

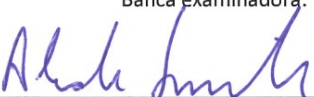
Por

Diego Hemkemeier Silva


Dissertação julgada e aprovada em sua forma final pelos membros titulares da Banca Examinadora (004/2018/PPGMPPA) do Programa de Pós-Graduação em Mestrado Profissional em Perícias Criminais Ambientais - UFSC.

Prof.(a) Dr.(a) Carlos Henrique Lemos Soares
Coordenador(a) do Programa de Pós-Graduação em Mestrado Profissional em
Perícias Criminais Ambientais

Banca examinadora:



Dr.(a) Alexandre Siminski (Universidade Federal de Santa Catarina)
Orientador(a)



Dr.(a) Silvio Luis Rafaeli Neto (Universidade do Estado de Santa Catarina)



Dr.(a) Eduardo Marques Martins (Universidade Federal de Santa Catarina)



Dr.(a) Roberto Fabris Goerl (Universidade Federal de Santa Catarina)

Florianópolis, 23 de novembro de 2018.

À Thalyta, aos meus pais Maria de Fátima e Adilton, à Ane e à Helena.

AGRADECIMENTOS

O agradecimento às pessoas que são a base de tudo e me mostram o rumo a seguir. Em especial, à minha amada esposa, Thalyta, por todos os momentos de ensinamento, aprendizado, dedicação, paciência, cumplicidade, incentivo, alegria e paz. Obrigado por me apoiar sempre. Aos meus amados pais, Maria de Fátima e Adilton, vocês deram o amor, a educação, o respeito e todos os outros ensinamentos que fizeram de mim a pessoa que hoje sou. Só tenho motivos para agradecer. Obrigado à minha irmã, Anelise, pelo carinho, parceria, cumplicidade. Agradeço a oportunidade de ser tio e padrinho: você nos trouxe a alegria através da amada Helena.

Ao Dr. Alexandre Siminski, pelo apoio, parceria, ensinamento e tutoria sem iguais. Sempre será um exemplo a ser seguido, como servidor público, profissional e ser humano. Agradeço a honra pelo aceite como orientado e por ter convivido durante esse tempo. Conte comigo sempre que for necessário.

Ao Dr. Alexandre ten Caten, obrigado por aceitar a coorientação e transmitir muito conhecimento técnico e visões importantes sobre os temas abordados. Que seu entusiasmo pela ciência, responsável e qualificada, continue a incentivar os seus alunos e todos que o rodeiam.

A todos os meus familiares, em especial à Dra. Luizita Henckemaier pelo convívio, incentivo para a realização deste mestrado e por me ensinar como um profissional e servidor público deve ser.

Ao Dr. Silvio Luis Rafaeli Neto pela amizade, ensinamentos e por ter dado as oportunidades profissionais que hoje me trazem até aqui.

Ao Glênio Bruck de Andrade, um dos mais inteligentes e competentes profissionais que já conheci, o meu muito obrigado por me presentear com sua amizade, conselhos e convívio.

Ao IMA/SC por permitir que fosse possível a realização do mestrado.

Ao Dr. Roberto Fabris Goerl e Dr. Eduardo Martins pelo aceite em participar da banca e pelos conselhos importantes para o enriquecimento deste trabalho.

Aos demais professores e colegas do Mestrado Profissional em Perícias Criminais Ambientais. Meu muito obrigado pela duradoura e rica parceria.

À Universidade Federal de Santa Catarina (UFSC) pela disponibilização do programa.

A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo.

(Albert Einstein)

RESUMO

A classificação de imagens de satélites é uma importante ferramenta para mensurar, qualificar, mapear e gerir uma determinada área de interesse. Neste trabalho é proposta uma metodologia para a classificação supervisionada, composta por três aspectos principais: a utilização de imagens provenientes do satélite Sentinel 2 (S-2), o processamento em servidores remotos (nuvem) através da plataforma Google Earth Engine (GEE) e, por último, o aplicativo móvel que visa a otimização da coleta de amostras para o treinamento dos algoritmos classificadores. A metodologia proposta foi aplicada na Floresta Ombrófila Mista (FOM), localizada no bioma Mata Atlântica, em Santa Catarina. Testou-se a capacidade de processamento e utilização da plataforma GEE para nove tipos de mosaicos S-2, com 10, 20 e 30 metros de resolução espacial e três períodos de aquisição distintos, que contemplam 2027, 715 e 587 cenas para a área da FOM. De forma complementar, realizou-se, para cada uma das nove imagens, o processamento com os classificadores *Support Vector Machine* (SVM) e *Random Forest* (RF). O desempenho do GEE foi positivo por proporcionar a rápida e eficiente criação dos mosaicos e da imagem classificada, além de exigir estrutura computacional simplificada para a elaboração do produto final, visto que o processamento é realizado nos servidores remotos que o comportam. As imagens S-2 possuem bandas que auxiliam na classificação da vegetação, além de possuírem boa resolução espacial para a obtenção de produtos em grandes áreas (entre 10 e 60 metros). O aplicativo foi utilizado em dispositivos móveis e viabilizou a coleta de coordenadas geográficas e demais atributos das amostras utilizadas para o treinamento dos algoritmos classificadores. A metodologia será proposta ao Instituto do Meio Ambiente de Santa Catarina (IMA/SC) para que novos dados sejam coletados por agentes fiscais e licenciadores, especialistas na área ambiental. Os produtos advindos da metodologia proposta podem ser utilizados na elaboração de políticas públicas para o meio ambiente em Santa Catarina.

Palavras-chave: Mata Atlântica. Sentinel 2. Google Earth Engine.

ABSTRACT

Satellite image classification is an important tool for measuring, qualifying, mapping and managing a particular area of interest. This work proposes a methodology for the supervised classification, composed of three main aspects: the use of images from the Sentinel 2 (S-2) satellite, the processing in remote servers (cloud) through the Google Earth Engine (GEE) platform and the mobile application that aims to optimize the collection of samples for the training of classifier algorithms. The proposed methodology was applied in the Mixed Ombrophilous Forest (FOM), located in the Atlantic Forest biome, in Santa Catarina. The GEE platform's processing and utilization capacity was tested for nine S-2 mosaics, with 10, 20 and 30 meters of spatial resolution and three distinct acquisition periods, including 2027, 715 and 587 scenes for the FOM area. In addition, the nine images were processed with the Support Vector Machine (SVM) and Random Forest (RF) classifiers. The GEE performance was positive because it provided the fast and efficient creation of the mosaics and the classified image, besides requiring a simplified computational structure for the elaboration of the final product, considering the processing is carried out on the remote servers of GEE. The S-2 images have bands that help in the classification of vegetation, besides having good spatial resolution for obtaining products in large areas (between 10 and 60 meters). The application was used in mobile devices and optimized the capture of geographic coordinates and other attributes of the samples used to train the classifiers. The methodology will be proposed to the Institute of the Environment of Santa Catarina (IMA/SC) so that new data are collected by fiscal agents and licensors, specialists in the environmental area. The products derived from the proposed methodology can be used in the elaboration of public policies for the environment in Santa Catarina.

Keywords: Atlantic Forest. Sentinel 2. Google Earth Engine.

LISTA DE FIGURAS

Figura 1 – Distribuição dos biomas do Brasil.	32
Figura 2 – Mapa da FOM em Santa Catarina, representada pela cor verde.	33
Figura 3 – Perfil esquemático da FOM, também conhecida como Mata-de-Araucária.	34
Figura 4 – Esquema ilustrando a aquisição de informações por meio do SR.	38
Figura 5 – Representação gráfica do espectro eletromagnético e a resposta de diferentes alvos.	39
Figura 6 – Típica curva espectral de reflectância e seus picos de absorção para estruturas da vegetação.	40
Figura 7 – Representação do algoritmo RF.	42
Figura 8 – Representação do algoritmo SVM.	43
Figura 9 – Fundamentos da matriz de confusão.	44
Figura 10 – Bandas e comprimentos de onda dos satélites S-2 e Landsat 7 e 8.	47
Figura 11 – Interface do aplicativo GEE.	49
Figura 12 – Metodologia proposta para a classificação de imagens, utilizando o GEE, aplicativo móvel e imagens S-2.	52
Figura 13 – Fluxo de execução dos programas (scripts) para a obtenção da imagem classificada.	56
Figura 14 – Órbitas 124 (a), 81 (b) e 38 (c) do S-2 sobre a área de abrangência da FOM.	57
Figura 15 – Mosaicos com períodos de aquisição distintos.	59
Figura 16 – Função ee.Reducer do GEE.	61
Figura 17 – Mosaico S-2, delimitado pela FOM e sem nuvens e/ou sombras.	62
Figura 18 – Banda 10, enfatizando as nuvens alta altitude, em comparação com a composição RGB (4-3-2).	63
Figura 19 – Mapa gerado pelo script para a construção do mosaico.	63
Figura 20 – Mapa gerado pelo script para a construção do mosaico e a apresentação em múltiplas telas vinculadas (a e b).	64
Figura 21 – Parte do código utilizado, mostrando o método de programação visual.	66
Figura 22 – Cores atribuídas às classes de uso e cobertura da terra.	68
Figura 23 – Mapa com a localização das amostras coletadas em campo.	69
Figura 24 – Registro de locais com as classes de uso e ocupação da terra utilizadas.	70

Figura 25 – Composição do S-2 (RGB) (a) e a imagem A1 classificada por RF(b).....	75
Figura 26 – Identificação dos aplicativos Completo (a) e Simplificado (b), respectivamente, após a instalação.....	78
Figura 27 – Seções de gerenciamento da coleta atual, na tela “Nova coleta” do aplicativo Completo.....	80
Figura 28 – Tela “Nova coleta” na versão simplificada do aplicativo..	81
Figura 29 – Ferramenta <i>Fusion Tables</i> para armazenamento das informações obtidas em campo através do aplicativo.....	82
Figura 30 – Mapa das amostras com exemplo de ponto coletado através do aplicativo. Ficam associados à geometria todas as outras informações adquiridas na tela “Nova coleta”.....	82

LISTA DE QUADROS

Quadro 1 – Parâmetros quantitativos para a classificação dos estádios sucessionais da vegetação.	36
Quadro 2 – Valor do índice Kappa e o grau de concordância.....	44
Quadro 3 – Bandas espectrais para os sensores do satélite S-2A e S-2B.	46
Quadro 4 – Funções adicionadas ao script.....	54
Quadro 5 – Imagem, período de aquisição e resolução espacial.....	60
Quadro 6 – Telas do aplicativo e suas respectivas funções.....	79

LISTA DE TABELAS

Tabela 1– Tempo estimado para processamento das imagens utilizadas na classificação (média de cinco solicitações).	73
Tabela 2 – Coeficiente Kappa e de PG da classificação para os algoritmos SVM e RF.	74

LISTA DE ABREVIATURAS E SIGLAS

AM – Aprendizado de Máquina
APP – Área de Preservação Permanente
CAR – Cadastro Ambiental Rural
CART – Classification and Regression Tree
CONAMA – Conselho Nacional do Meio Ambiente
CSV – Comma Separated Values
DAP – Diâmetro a Altura do Peito
DT – Decision Tree
ESA – European Space Agency
FOM – Floresta Ombrófila Mista
GEE – Google Earth Engine
GeoTIFF – Georeferenced Tagged Image File Format
IBGE – Instituto Brasileiro de Geografia e Estatística
IMA – Instituto do Meio Ambiente
JPEG - Joint Photographic Experts Group
JSON – JavaScript Object Notation
L8 – Landsat 8
MA – Mata Atlântica
MAXVER – Máxima Verossimilhança
MIT – Massachusetts Institute of Technology
NASA – National Aeronautics Space Administration
PG – Precisão Global
PRA – Programa de Regularização Ambiental
RAM – Random Access Memory
RE – Red-Edge
REM – Radiação Eletromagnética
RF – Random Forest
RGB – Red, Green e Blue
RPA – Remotely Piloted Aircraft
S-2 – Sentinel 2
SC – Santa Catarina
SNUC – Sistema Nacional de Unidades de Conservação
SR – Sensoriamento Remoto
SVM – Support Vector Machine

SUMÁRIO

1	INTRODUÇÃO	27
1.1	OBJETIVOS	29
1.1.1	Objetivo Geral	29
1.1.2	Objetivos Específicos	29
2	FUNDAMENTAÇÃO TEÓRICA	31
2.1	O BIOMA MATA ATLÂNTICA	31
2.1.1	Floresta Ombrófila Mista (FOM)	32
2.1.2	Estágios Sucessionais da Vegetação	34
2.2	O SENSORIAMENTO REMOTO NA ANÁLISE DA VEGETAÇÃO	37
2.2.1	O espectro eletromagnético e sua relação com o sensoriamento da superfície terrestre	38
2.2.2	O SR como ferramenta para a classificação de feições da superfície terrestre	40
2.2.2.1	Classificação supervisionada	41
2.2.2.2	Classificação não-supervisionada	41
2.2.2.3	Métodos de classificação baseados no Aprendizado de Máquina (AM)	41
2.2.2.4	Métodos para a avaliação da classificação de imagens	43
2.3	O PROGRAMA COPERNICUS DA AGÊNCIA ESPACIAL EUROPEIA (ESA)	45
2.3.1	A missão Sentinel 2 (S-2) e suas aplicações para a análise da superfície terrestre	45
2.4	A COMPUTAÇÃO EM NUVEM E SUA APLICABILIDADE NO SR	48
2.4.1	A ferramenta de processamento em nuvem GEE	48
3	METODOLOGIA	51
3.1	ÁREA DE ESTUDO	53
3.2	O GEE PARA O PROCESSAMENTO DOS DADOS	53
3.3	IMAGENS SENTINEL 2 (ESA)	57
3.3.1	Mosaico e tratamento das sombras e nuvens	57
3.4	DESENVOLVIMENTO DO APLICATIVO MÓVEL PARA COLETA DE DADOS	65
3.5	A CLASSIFICAÇÃO DAS IMAGENS DE SATÉLITE	67
3.5.1	Definição das classes	67
3.5.2	Treinamento dos algoritmos classificadores	69

3.5.3	Algoritmos classificadores	70
3.5.4	Métodos para validação da classificação	70
3.6	A INTERFACE CUSTOMIZADA PARA A PRODUÇÃO DOS MAPAS TEMÁTICOS E DISPONIBILIZAÇÃO DOS SCRIPTS	72
4	RESULTADOS E DISCUSSÃO	73
4.1	CLASSIFICAÇÃO E GERAÇÃO DOS MOSAICOS	73
4.1.1	Processamento para a geração dos mosaicos	73
4.1.2	Dados obtidos a partir da classificação	74
4.2	APLICATIVO PARA A COLETA DAS AMOSTRAS DE TREINAMENTO	77
5	CONSIDERAÇÕES FINAIS	83
	REFERÊNCIAS	86
	APÊNDICE A – SCRIPT MOSAICO	97
	APÊNDICE B – SCRIPT MOSAICO EM MÚLTIPLAS TELAS	104
	APÊNDICE C – SCRIPT CLASSIFICAÇÃO SVM E RF. ..	112
	APÊNDICE D – SCRIPT MENSURAÇÃO DA CLASSIFICAÇÃO	124
	APÊNDICE E – TELAS DO APLICATIVO COMPLETO	131

1 INTRODUÇÃO

A Mata Atlântica é um dos mais importantes ecossistemas florestais do mundo, especialmente por apresentar uma grande diversidade de fitofisionomias e aspectos bióticos. Este bioma ocorre em áreas de intensa ocupação e/ou uso alternativo do solo, como o litoral brasileiro, do Rio Grande do Norte ao Rio Grande do Sul, e em áreas de acentuada atividade agropecuária no interior dos estados de Santa Catarina, Rio Grande do Sul, Paraná, Minas Gerais, Bahia, São Paulo e Mato Grosso do Sul. A Floresta Ombrófila Mista (FOM) é um dos ecossistemas associados ao bioma Mata Atlântica de ocorrência na região Sul do Brasil, caracterizado pela ocorrência marcante da *Araucaria angustifolia* (Bertol.) Kuntze (pinheiro-do-paraná). A FOM possui relevância histórica por apresentar espécies de considerável valor econômico, principalmente ligadas ao uso da madeira proveniente de espécies arbóreas singulares, como a *Araucaria angustifolia* e *Ocotea porosa* (Nees) Barroso. Nessa região pode-se citar, como fatores para a redução da biodiversidade e da área de florestas originais da região, a intensidade de exploração madeireira, uso alternativo do solo e a ampliação das zonas urbanas (MEDEIROS; SAVI; BRITO, 2005). Além disso, especificamente nas áreas contempladas pelo Planalto Serrano Catarinense, há uma estratégica região onde são necessários estudos sobre a conservação, devido à existência de pontos de recarga do Aquífero Guarani (KLAUBERG et al., 2011). Tais afirmações, além da necessidade de caracterização desta fitofisionomia para a execução de políticas públicas, foram relevantes para a escolha da FOM como área onde será testada a metodologia proposta neste trabalho.

Aliando as necessidades de gestão ambiental da Mata Atlântica e sua conservação por parte dos órgãos de governo, surgem as tecnologias ou, mais especificamente, as geotecnologias, que são ferramentas capazes de criar, gerar e organizar dados e informações para subsidiar as políticas públicas relacionadas ao bioma. A partir de técnicas aprimoradas de Sensoriamento Remoto (SR), é possível monitorar o uso da terra e descrever a vegetação (SANTOS, 2009). Assim, as imagens de satélite têm papel fundamental no monitoramento e na geração de métricas específicas, como tamanho de polígonos, forma e conectividade da floresta.

A partir da interpretação de imagens provenientes de mecanismos aerotransportados ou orbitais, é possível realizar o mapeamento da cobertura e uso do solo, em concomitância com a análise de peças técnicas cartográficas e trabalhos de campo (FRANCISCO; ALMEIDA,

2012). Os mapas que apresentam o uso da terra e sua cobertura são instrumentos que auxiliam na promoção do desenvolvimento sustentável e são imprescindíveis para o planejamento regional ou local e, portanto, essenciais para a tomada de decisão (FILHO; MENESES; SANO, 2007). A produção de informações geralmente se baseia na classificação dessas imagens e que são realizadas, na maioria das vezes, de forma automatizada por algoritmos computacionais que evoluíram significativamente ao longo do tempo. Essas informações ainda podem auxiliar o estudo de florística, fitossociologia, recuperação ambiental, proteção ambiental e estabelecimento de áreas prioritárias para preservação (ALBRECHT et al., 2009).

Um dos principais problemas encontrados para o manuseio e processamento das imagens de satélite é a necessidade de dispositivos computacionais com alta capacidade de armazenamento e processamento de dados, além de programas/aplicativos de computador específicos (muitas vezes proprietários) para o tratamento dos dados, georreferenciamento das imagens e classificação. Nos últimos anos, programas computacionais de código aberto e/ou gratuitos auxiliaram na popularização e melhor disseminação do geoprocessamento e SR por imagens de satélite. No entanto, ainda persiste a necessidade de uma estrutura mais robusta para o processamento de grandes volumes de dados (*big data*) por parte de universidades, pesquisadores e empresas, sejam elas públicas ou privadas.

Com o advento da internet, sua evolução e o posterior surgimento da computação em nuvem, inúmeras vantagens em relação ao uso do SR foram obtidas. Um dos maiores exemplos é a facilidade de processamento e armazenagem de imagens de satélites de forma remota, conectando o usuário a um servidor em nuvem. Nesse cenário, surge a ferramenta Google Earth Engine (GEE), desenvolvida pela empresa Google Inc. que será uma das bases para a metodologia proposta neste trabalho. O serviço possibilita o processamento de imagens orbitais diretamente nos servidores remotos, eximindo os usuários da necessidade de recursos computacionais com robustas capacidades.

A associação entre o SR, a classificação de imagens orbitais e as informações de campo são essenciais para um efetivo resultado na criação de produtos cartográficos. Uma das etapas mais importantes e que dispendem esforços é a coleta de amostras para treinamento com a finalidade de apresentar aos classificadores (algoritmos) automáticos aquilo que se pretende buscar nas imagens. Para tanto, desenvolveu-se, nesta proposta metodológica, dois aplicativos móveis que possibilitam a

coleta de dados para aprimoramento e verificação dos resultados obtidos com base nas imagens de satélite e na ferramenta GEE.

Na fundamentação teórica, serão apresentados os aspectos relacionados à Mata Atlântica (MA), suas fitofisionomias e formas de classificação conforme a Resolução CONAMA nº 04/94. Em seguida, serão abordados temas sobre o SR e sua importância para o meio ambiente, o potencial das imagens Sentinel 2 (S-2), a computação em nuvem, os aplicativos móveis para a coleta de amostras e, por último, a sintetização de todos estes aspectos em uma metodologia para classificação do uso e ocupação da terra.

Conhecer, classificar e mensurar a vegetação é essencial para que a gestão do meio ambiente seja realizada da forma como preconizada na Constituição Federal. Atualmente, há poucos produtos técnicos disponíveis que possibilitam essas caracterizações para grandes áreas e, por isso, buscou-se a elaboração da metodologia aqui proposta buscando atender à essa demanda. Em Santa Catarina, o Instituto do Meio Ambiente (IMA/SC) é o órgão responsável pela gestão ambiental e aplicação das políticas de Estado na área, desempenhando as atividades de licenciamento, fiscalização, auditoria e administração das unidades de conservação estaduais. Os produtos obtidos por meio da metodologia proposta servirão como bases para as políticas e ações de gestão realizadas pelo órgão.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Propor uma metodologia para a classificação do uso e ocupação da terra, para grandes áreas, com recursos computacionais reduzidos e de rápida execução.

1.1.2 Objetivos Específicos

- a) Desenvolver uma metodologia para analisar os remanescentes florestais;
- b) Apresentar as possibilidades da computação em nuvem para o processamento de imagens orbitais;
- c) Desenvolver e disponibilizar um aplicativo móvel para smartphones e tablets que possibilite a coleta de amostras para treinamento de classificações supervisionadas, que opere sem

internet e seja utilizável por mais de um usuário, concomitantemente;

- d) Disponibilizar mosaicos de imagens georreferenciadas dos satélites Sentinel-2 (A e B), livres de nuvens e normalizadas;
- e) Propor ao IMA/SC uma metodologia para a criação mapas temáticos para a gestão ambiental e análise do comportamento da vegetação ao longo do tempo;
- f) Classificar os estágios sucessionais da FOM, existente no estado de Santa Catarina, por meio de imagens Sentinel 2.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 O BIOMA MATA ATLÂNTICA

O bioma Mata Atlântica (MA) é considerado, internacionalmente, como um dos mais ameaçados ambientes naturais do mundo. Martinelli; Moraes, (2013) enfatizam que o Cerrado e a MA estão entre os 35 *hotspots* (pontos críticos para conservação) do cenário mundial, além de estar entre os cinco mais ameaçados.

Diversas frentes preservacionistas buscam a estabilização ou, pelo menos, reduzir o impacto constante sobre o bioma. Pode-se citar, como principais iniciativas governamentais a regulamentação, especialmente a federal, relacionada à preservação do meio ambiente. Em 2000, foi instituído o Sistema Nacional de Unidades de Conservação (SNUC), através da Lei Federal nº 9.985, de 18 de julho de 2000 (BRASIL, 2000), regulamentada pelo Decreto Federal 4.430, de 22 de agosto de 2002, definindo a importância e a regulação legal das unidades de conservação (CRUZ et al., 2007). Em 2006, surgiu outro marco diretor sobre a conservação da MA: a Lei Federal 11.428, de 22 de dezembro, regulamentada em 2008, pelo Decreto Federal 6.660, de 21 de novembro. Este evento norteou as diretrizes as legislações infra e políticas públicas relacionadas ao tema. A Lei da MA (11.428/06), como também é conhecida a regra, possui em seu primeiro artigo o objetivo do Legislador no momento de sua concepção:

Art. 1º A conservação, a proteção, a regeneração e a utilização do Bioma Mata Atlântica, patrimônio nacional, observarão o que estabelece esta Lei, bem como a legislação ambiental vigente, em especial a Lei no 4.771, de 15 de setembro de 1965 (BRASIL, 2006).

Os principais motivos pelos quais o bioma é considerado um dos cinco *hotspots* mundiais é o fato de possuir elevado grau de endemismo de espécies. A alta biodiversidade de fauna, flora e ambientes, também é um dos fatores que inclui estas áreas como sensíveis e com risco de perdas ambientais consideráveis ao longo do tempo. Cruz et al., (2007), citam as fitofisionomias existentes no bioma, variando entre manguezais e restingas, até florestas ombrófilas e estacionais. A Figura 1 representa a distribuição dos biomas sobre o território brasileiro, inclusive a MA.

Figura 1 – Distribuição dos biomas do Brasil.



Fonte: IBGE (2018).

2.1.1 Floresta Ombrófila Mista (FOM)

Três regiões fitoecológicas podem ser encontradas no estado de Santa Catarina: a Floresta Estacional Decidual, a Floresta Ombrófila Mista (FOM) e a Floresta Ombrófila Densa (VIBRANS et al. 2013). Considerando as fitofisionomias da MA, destaca-se a FOM, que possui como dominantes em sua composição florística, espécies primitivas como *Drymis brasiliensis* Miers (casca-de-anta), *Araucaria angustifolia* (Bertol.) Kuntze (pinheiro-do-paraná) e *Podocarpus lambertii* Klotzsch ex Endl. (pinho-bravo) (IBGE, 2012). A FOM ocupou, inicialmente, cerca de 45% do território de Santa Catarina e, atualmente cobre aproximadamente 25%, de sua área original (VIBRANS et al. 2013), redução esta possivelmente explicada pelo valor madeireiro das espécies que a compõem, o avanço da agropecuária e a conversão do solo para

estabelecimento de monocultivos silviculturais com espécies exóticas. Além disso, destacam-se também subprodutos advindos desta floresta, como a semente de *Araucaria angustifolia* (Bertol.) Kuntze (pinheiro-do-paraná) e as folhas de *Ilex paraguariensis* St. Hil. (erva-mate), fortemente relacionados à atividade comercial regional (SIMINSKI et al., 2013). Em Santa Catarina, sua distribuição ocorre na área de Planalto, estendendo-se da divisa do Rio Grande do Sul até o Paraná. A Figura 2 apresenta o mapa da FOM em Santa Catarina.

Figura 2 – Mapa da FOM em Santa Catarina, representada pela cor verde.




Fonte: o autor, adaptado de Klein (1978a).

Diante do exposto, é importante que a flora da FOM seja estudada e analisada ao longo do tempo, verificando sua evolução, bem como o estágio em que se encontram os seus remanescentes. Vibrans *et al.* (2010), consideram ser importantes para a política que envolve a questão florestal, o conhecimento da extensão territorial da cobertura, composição florística, estrutura e estado de conservação da floresta.

A FOM abrange uma área de 42.851 km² (KLEIN, 1978b) e é importante por se tratar de ecossistema único e com características peculiares, inclusive àquelas relacionadas ao potencial madeireiro. A Figura 3 apresenta o perfil esquemático característico da FOM, desde sua porção aluvial até a altomontana.

Figura 3 – Perfil esquemático da FOM, também conhecida como Mata-de-Araucária.



Fonte: Veloso et al. (1991).

A FOM é uma das tipologias mais ameaçadas por possuir cerca de 0,7% da área original composta pelos estágios primário e, provavelmente, avançados também (MMA, 2002 *apud* MEDEIROS; SAVI; BRITO, 2005). No entanto, há pouca fonte de dados disponíveis que contabilizam a dinâmica destes remanescentes no Brasil, especialmente contemplando grandes áreas, como a ocupada pela FOM.

Neste cenário, faz-se necessária a produção de dados que possibilitem a análise da vegetação existente na FOM. A metodologia proposta, visa a produção de informações com vistas à análise da vegetação na FOM, por meio de mapas temáticos para a gestão florestal na região fitoecológica, além de servir como mecanismo para o estudo, análise e homologação do Cadastro Ambiental Rural (CAR).

2.1.2 Estágios Sucessionais da Vegetação

Em 1993, o Conselho Nacional de Meio Ambiente (CONAMA) estabeleceu uma série de parâmetros para a análise da sucessão da MA. Trata-se da Resolução nº 10, de 1 de outubro de 1993, que define os quesitos básicos para a análise da vegetação, com base no seu estágio de desenvolvimento (BRASIL, 1993). Considerando as especificidades regionais do Brasil e, também, com o intuito de orientar os procedimentos de licenciamento ambiental no estado de Santa Catarina, publicou-se a Resolução CONAMA nº 04/94 que definiu a

[...] vegetação primária e secundária nos estágios inicial, médio e avançado de regeneração da Mata

Atlântica, a fim de orientar os procedimentos de licenciamento de atividades florestais no estado de Santa Catarina (BRASIL, 1994).

A referida resolução exige a observação de parâmetros, indicativos e critérios qualitativos e quantitativos para a caracterização da floresta (SIMINSKI; FANTINI; REIS, 2013). Tal regramento direciona legalmente, até os dias atuais, a forma com que a vegetação existente em todo o território catarinense deve ser classificada, levando-se em consideração o seu porte, desenvolvimento e qualificação quanto à presença de espécies. Inicialmente, há a divisão entre dois estratos: Vegetação Primária ou Secundária. O CONAMA, define:

Art. 1º Vegetação primária é aquela de máxima expressão local, com grande diversidade biológica, sendo os efeitos das ações antrópicas mínimos, a ponto de não afetar significativamente suas características originais de estrutura e de espécies, onde são observadas área basal média superior a 20,00 m²/ha, DAP médio superior a 25 cm e altura total média superior a 20 m.

Art. 2º Vegetação secundária ou em regeneração é aquela resultante dos processos naturais de sucessão, após supressão total ou parcial da vegetação primária por ações antrópicas ou causas naturais, podendo ocorrer árvores remanescentes da vegetação primária (BRASIL, 1994).

Portanto, os artigos 1º e 2º definem a vegetação primária ou se já possui algum tipo de intervenção, então classificada como secundária ou em regeneração. A Resolução baseia-se nos processos naturais de sucessão da vegetação e, hierarquicamente, enquadra todas aquelas que sofreram algum tipo de intervenção, ou seja, secundárias, em outros três tipos de subdivisões ou estágios: inicial, médio ou avançado. Essa classificação fundamenta-se em parâmetros quantitativos e qualitativos do dossel.

Quantitativamente, é possível definir os estágios sucessionais conforme apresentado no Quadro 1.

Quadro 1 – Parâmetros quantitativos para a classificação dos estágios sucessionais da vegetação.

Estágio	Parâmetros Quantitativos		
	Área basal média (m ² /ha)	Altura total média (m)	Diâmetro à Altura do Peito (DAP) médio (cm)
Inicial	até 8	até 4	até 8
Médio	até 15	até 12	até 15
Avançado	até 20	até 20	até 25
Primário	superior a 20	superior a 20	superior a 25

Fonte: BRASIL (1994).

Além dos parâmetros quantitativos, passíveis de obtenção por meio de inventários florestais, Brasil (1994) também considera outros parâmetros (qualitativos) para a classificação dos estágios sucessionais do fragmento florestal. Como exemplos, pode-se citar a presença ou não de sub-bosque, espécies indicadoras, serrapilheira, entre outros aspectos (BRASIL, 1994).

Em todas as 155 unidades amostrais inventariadas na FOM, por meio do Inventário Florístico Florestal de Santa Catarina, encontrou-se nos remanescentes florestais estudados algum tipo de alteração na sua estrutura, ocasionada pelas ações antrópicas diretas ou indiretas (VIBRANS *et al.*, 2013), o que justifica, entre outros aspectos, a importância do estudo da vegetação, seus estágios de regeneração atuais e passados.


2.2 O SENSORIAMENTO REMOTO NA ANÁLISE DA VEGETAÇÃO

O SR é uma importante ferramenta para a obtenção de informações do uso e ocupação da terra, condições meteorológicas, poluição atmosférica, informações sobre altimetria, entre outros, sejam elas realizadas por meio de veículos orbitais, aviões, balões e, mais recentemente, até mesmo por drones (ou ARPs - Aeronaves Remotamente Pilotadas). A base de uso do SR, especialmente o orbital, é a captura e análise da energia eletromagnética emitida ou refletida pela superfície, levando-se em conta o uso de sensores específicos (LEDA, 2016). Ao considerar as especificidades de emissão e reflexão dos diversos alvos existentes na Terra, é possível obter respostas que possibilitam a aquisição de informações espaciais únicas, especialmente quando direcionadas ao estudo da vegetação.

Atualmente, mais profissionais, entre eles, pesquisadores, ambientalistas, ligados ao setor privado ou governamental, aderem ao uso do SR como ferramenta para o planejamento e compreensão dos fenômenos que ocorrem em determinada área. A utilização de modelos que descrevem a cobertura vegetal alcançam resultados satisfatórios na avaliação do grau de transformação da paisagem, o que possibilita uma grande quantidade de análises e cruzamento dos dados obtidos (ROSÁRIO et al., 2009). Outro exemplo interessante é a utilização das referidas técnicas na quantificação da biomassa florestal, visto que a radiação eletromagnética (REM) refletida por dosséis, registrada por sensores remotos, é resultante de um universo de fatores espectrais destes alvo (folhas, galhos, troncos), além de outros relacionados a geometria de iluminação e de visada, como parâmetros biofísicos (como a densidade e a distribuição, por exemplo) (PONZONI, 1993).

Florenzano (2002) ilustra a aquisição das informações por meio do SR orbital (Figura 4).

Figura 4 – Esquema ilustrando a aquisição de informações por meio do SR.



Fonte: Florenzano (2002).

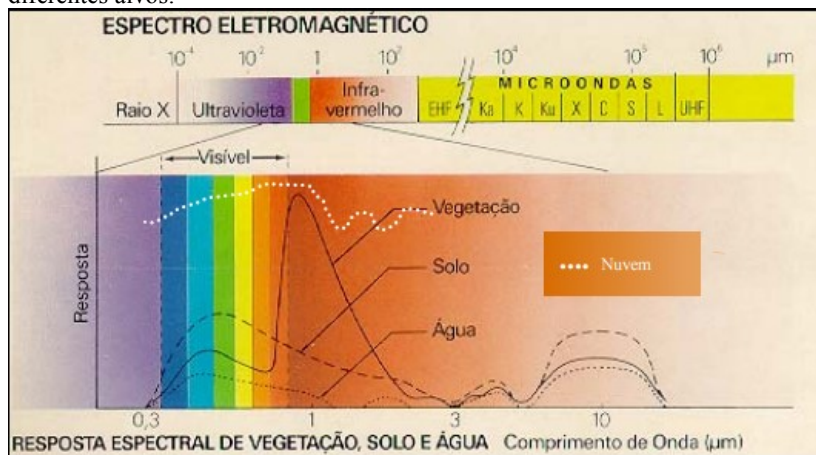
2.2.1 O espectro eletromagnético e sua relação com o sensoriamento da superfície terrestre

Em 1664, Isaac Newton entendeu a natureza da luz branca, composta por um conjunto de diferentes cores e que, se dividida por um prisma, forma um espectro de arco-íris. No entanto, além daquilo que os olhos humanos podem observar, há um espectro muito maior e que contempla o infravermelho, o ultravioleta, os raios-X, as ondas de rádio, entre outras. Essa energia, representada pelo espectro eletromagnético (Figura 5) é ordenada em função do seu comprimento de onda e possui comportamentos e interações peculiares com os sensores remotos e os objetos existentes na superfície da Terra.

Quando a REM incide sobre qualquer feição na superfície terrestre, três tipos de reações podem acontecer com essa energia: a reflexão, a absorção e/ou transmissão (AGGARWAL, 2003). As estruturas física e química desses alvos possuem respostas características quando interagem com a energia eletromagnética, revelando comportamentos diferentes (LUCHIARI, 2001). Esta reação, obtida a partir de um objeto, é chamada de comportamento espectral (ou resposta espectral) e pode ser definida como os valores obtidos entre a interação objeto-energia ao longo do espectro eletromagnético. Essas informações devem ser analisadas e entendidas para que haja a caracterização adequada da superfície alvo, incluindo a influência da

atmosfera. O comportamento espectral de objetos terrestres, como as rochas, os solos e a água, possui características que permitem a aquisição de dados para aplicações específicas. Em relação às rochas, por exemplo, o comportamento é determinado pelos minerais que as compõem e, nos solos, a matéria orgânica, umidade, textura, estrutura e composição mineral são fatores que, combinados, determinam a resposta espectral (MORAES, 2002). A água, em condições naturais, pode apresentar diferentes comportamentos espectrais devido ao seu estado físico e outros componentes, como pigmentos fotossintetizantes e matéria orgânica dissolvida (BARBOSA, 2003).

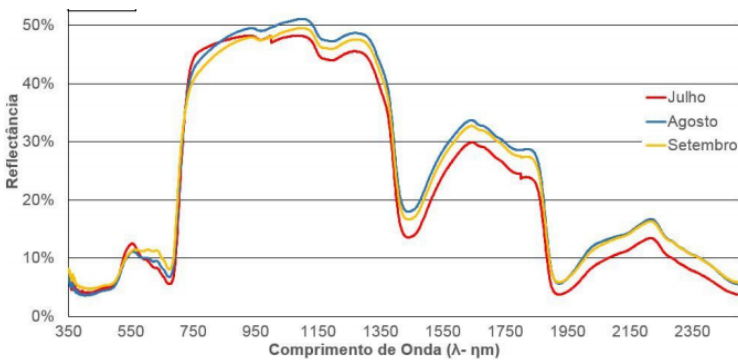
Figura 5 – Representação gráfica do espectro eletromagnético e a resposta de diferentes alvos.



Fonte: Moraes (2002).

Em relação à vegetação, há interações para as diferentes faixas do espectro eletromagnético, permitindo que diversas informações sobre as propriedades dos vegetais sejam detectadas (GOMES, 2017). A vegetação com vigor possui uma curva característica em relação aos comprimentos de onda: na faixa do visível, por exemplo, a reflectância é menor e, quando considerada a região do infravermelho próximo, os valores são mais expressivos (Figura 6). A resposta dada por um sensor remoto sobre a vegetação não pode ser explicada somente pelas características do próprio vegetal, mas por outros fatores como a fonte de radiação, espalhamento atmosférico, características do dossel e das folhas, a umidade, sombra, entre outros (AZEVEDO et al., 2013).

Figura 6 – Típica curva espectral de reflectância e seus picos de absorção para estruturas da vegetação.



Fonte: Fernandes et al. (2013).

2.2.2 O SR como ferramenta para a classificação de feições da superfície terrestre

A classificação de imagens, provenientes do SR, pode ser definida como conjunto de técnicas que possibilitam executar algoritmos computacionais para a interpretação das características contidas em uma imagem (matriz), facilitando o mapeamento temático em grandes extensões. A complexidade da paisagem a ser classificada, as técnicas de processamento equivocadas ou um tratamento inadequado dos dados podem fornecer informações controversas ou indevidas de determinado local.

Por isso, é importante que o usuário possua pleno controle sobre cada uma das etapas do processo de classificação. Os principais passos para o procedimento incluem, pelo menos, a determinação de um sistema de classificação adequado, seleção de amostras de treinamento (no caso das supervisionadas), pré-processamento de imagens, extração de características, seleção de abordagens de classificação adequadas, processamento, pós-classificação e avaliação de precisão (LU; WENG, 2007).

Os dados base para a classificação devem ser estudados e compreendidos pelo pesquisador, pois em várias situações as limitações de uma imagem de satélite podem afetar diretamente a qualidade do produto. A natureza do mapeamento temático será produzida de acordo

com os objetivos da classificação e a escala de trabalho. Para o presente estudo, será apresentada a metodologia para a geração de mapa temático de vegetação e métodos para a coleta de amostras de treinamento, além de técnica para o processamento em nuvem.

2.2.2.1 Classificação supervisionada

Esse tipo de classificação digital possui como principal característica a aquisição e fornecimento de amostras para treinamento do algoritmo. Os pixels das imagens são inseridos em categorias apresentando, ao algoritmo classificador, informações numéricas de cada um dos alvos de interesse (SAMIZAVA, 2009). Basicamente, todos os pixels informados pelos usuários são comparados entre si, estatisticamente, e agrupados na categoria numericamente definida como mais próxima. Na classificação supervisionada, o número de classes e a quantidade de amostras utilizadas para treinamento são fatores críticos a serem levados em consideração (RUIZ; CATEN; DALMOLIN, 2014). Os algoritmos para classificação supervisionada mais comuns são: Paralelepípedo, Distância de Mahalanobis, Distância Mínima e Máxima-verossimilhança (SANTOS; LIMA, 2018); Mapeamento por Ângulo Espectral, Árvores de Decisão, Redes Neurais e o Support Vector Machine (SVM) (FERNANDES et al., 2009).

2.2.2.2 Classificação não-supervisionada

A classificação é não-supervisionada quando, em princípio, o algoritmo classificador não utiliza qualquer conhecimento sobre os temas da imagem, não sendo necessária a intervenção do analista (DAINESE, 2001). Pixels com características semelhantes são agrupados para formar uma classe, baseando-se em análises estatísticas. Os algoritmos mais utilizados para este tipo de classificação são o K-Media e Iseog (DAINESE, 2001).

2.2.2.3 Métodos de classificação baseados no Aprendizado de Máquina (AM)

Os métodos para classificação de imagens baseados em AM possuem características que os diferenciam dos outros algoritmos classificadores. Independentemente do uso em imagens de satélite, estes métodos são utilizados amplamente nas mais diversas áreas, como medicina, segurança pública, tecnologia da informação, entre outros. O


AM tem por objetivo desenvolver máquinas inteligentes, através de métodos, técnicas e ferramentas que utilizam amostras e permitem o treinamento de algoritmos (SOUSA et al., 2010).

Atualmente, os métodos não-paramétricos de aprendizado de máquina têm recebido crescente atenção nos estudos de classificação, até mesmo, na discriminação de espécies vegetais (DENG et al., 2016). O uso dessas técnicas é recente e um amplo campo para pesquisa continua incipiente e aberto para a construção de conhecimento através da pesquisa.

Li; Im; Beier (2013) investigaram três cenários utilizando aprendizado de máquina diferentes para a classificação da vegetação nas florestas no estado de Nova Iorque: Decision Tree (DT), Random Forest (RF) e SVM, e concluíram que as duas últimas possuem maiores precisões na classificação.

O RF (BREIMAN, 2001) é um algoritmo de aprendizagem supervisionada e utiliza o princípio da combinação de árvores de decisão múltiplas no momento do treinamento, gerando uma predição média das árvores individuais. O termo “Floresta” está baseado no uso das várias árvores de decisão, que são combinadas para se obter uma predição mais estável e com maior acurácia (Figura 7).

Figura 7 – Representação do algoritmo RF.




Fonte: Verikas et al. (2016).

Já o método SVM está baseado na técnica da Teoria de Aprendizado Estatístico (CORTES; VAPNIK, 1995). Atua na construção de uma linha que separa os dados entre duas classes.

Geralmente, esta divisão é chamada de hiperplano e busca aumentar a distância do último ponto próximo em relação às classes (Figura 8).

Figura 8 – Representação do algoritmo SVM.



Fonte: Zhou et al. (2016).

Sothe et al. (2017) encontraram, para áreas no município de Urubici, no estado de Santa Catarina, valores para índices Kappa de 0,9 com imagens Landsat 8 (L8) da NASA e, para o satélite Sentinel 2 (S-2) da ESA, 0,98, utilizando o SVM. Testes com algoritmos classificadores e indicaram que os métodos RF e SVM, para imagens Landsat 8 (L8), forneceram satisfatórios valores de acurácia e de índice Kappa, acima de outros, como o Classification and Regression Trees (CART), Redes Neurais Artificiais (RNA) e Máxima Verossimilhança (MAXVER) (MONTEIRO; FRANCÊS; SANTANA, 2015).

2.2.2.4 Métodos para a avaliação da classificação de imagens

Os métodos mais utilizados para a avaliação do produto final e dos algoritmos classificadores são a matriz de confusão e o índice Kappa. A primeira mostra o comportamento do algoritmo, especialmente em relação à sua reação perante a previsões realizadas de forma equivocada. É apresentada em formato de tabela, onde as linhas representam os valores previstos e as colunas fornecem os valores reais (Figura 9).

Figura 9 – Fundamentos da matriz de confusão.

		Valor Previsto	
		Positivo	Negativo
Valor Verdadeiro	Negativo	Verdadeiros Positivos	Falsos Negativos
	Positivo	Falsos Positivos	Verdadeiros Negativos

Fonte: Andreoni (2014).

O índice Kappa pode ser considerado como uma medida associativista para representar e descrever o grau de concordância na classificação. Apresenta os percentuais de acerto por tema, variando de 0 a 1. Landis; Koch, (1977) apresentam a classificação, segundo o grau de concordância, a partir do índice (Quadro 2). Os índices representam, de forma geral, parâmetros para a avaliação da classificação.

Quadro 2 – Valor do índice Kappa e o grau de concordância.

Índice Kappa	Grau de concordância
0,00 a 0,20	Fracó
0,21 a 0,40	Razoável
0,41 a 0,60	Moderado
0,61 a 0,80	Bom
0,81 a 1,00	Quase perfeito

Fonte: Adaptado de Landis; Koch (1977).

2.3 O PROGRAMA COPERNICUS DA AGÊNCIA ESPACIAL EUROPEIA (ESA).

O programa Copernicus é uma iniciativa europeia que visa a implementação de serviços com base em dados recebidos por uma constelação de satélites de observação da Terra e outras informações terrestres. Possui como principais atividades as missões Sentinel, que colocam em órbita veículos equipados por sensores estrategicamente elaborados para a pesquisa e observação de questões relacionadas à atmosfera, ambientes marinhos, uso do solo, alterações climáticas, gerenciamento de emergências e segurança. As missões Sentinel colocarão em órbita sete modelos de satélite com específicos sensores embarcados para a observação da Terra visando, principalmente, o monitoramento da cobertura e uso do solo e as mudanças climáticas (ESA, 2018a).

2.3.1 A missão Sentinel 2 (S-2) e suas aplicações para a análise da superfície terrestre

A missão S-2 (um dos componentes espaciais da constelação) contempla um par de satélites em órbita polar, divididos 180° entre si (ESA, 2018a) e possui como característica uma carga útil de instrumento ótico, com 13 bandas espectrais, algumas delas específicas para a análise do comportamento da vegetação. Possui, ainda, bandas com resolução espacial de 10, 20 e 60 metros e faixa orbital de 290 km (ESA, 2018a). Tais características fazem com que o S-2 seja, atualmente, um dos principais satélites disponíveis para a observação do uso e ocupação da terra, especialmente quando há a necessidade de estudos sobre a vegetação e boa resolução temporal. O instrumento multiespectral MSI, acoplado ao S-2, possui comprimentos de onda específicos e estrategicamente concebidos para essas aplicações (Quadro 3).

Quadro 3 – Bandas espectrais para os sensores do satélite S-2A e S-2B.

Banda	S-2A		S-2B		Resolução espacial (m)
	Comprimento de onda central (nm)	Largura de banda (nm)	Comprimento de onda central (nm)	Largura de banda (nm)	
1 (Aerossol)	443,9	27	442,3	45	60
2 (Azul)	496,6	98	492,1	98	10
3 (Verde)	560,0	45	559,0	46	10
4 (Vermelho)	664,5	38	665,0	39	10
5 (Red Edge 1)	703,9	19	703,8	20	20
6 (Red Edge 2)	740,2	18	739,1	18	20
7 (Red Edge 3)	782,5	28	779,7	28	20
8 (Infravermelho próximo)	835,1	145	833,0	133	10
8a (Red Edge 4)	864,8	33	864,0	32	20
9 (Vapor de água)	945,0	26	943,2	27	60
10 (Cirrus)	1373,5	75	1376,9	76	60
11 (Infravermelho ondas curtas 1)	1613,7	143	1610,4	141	20
12 (Infravermelho ondas curtas 2)	2202,4	242	2185,5	238	20

Fonte: ESA (2018a).


Uma das características que tornam o S-2 um importante instrumento para o monitoramento da vegetação é a presença de três bandas Red-Edge (RE), relevantes na interação REM-Planta, que estão centradas em 704, 740 e 782 nm (DELEGIDO et al., 2011). O MSI, instrumento a bordo do S-2, possibilita a obtenção de dados nas regiões do RE, em uma resolução espacial maior, em relação a outros satélites existentes para a análise da vegetação (FRAMPTON et al., 2013). A importância das bandas na obtenção de produtos precisos relacionados à clorofila do dossel e do índice de área foliar (DELEGIDO et al., 2011). Além disso, é possível estudar, de forma adequada, a fenologia e o crescimento da vegetação, entre outros aspectos (IMMITZER et al., 2016; NG et al., 2017).

Outra característica do S-2, além da resolução temporal e das possibilidades de análise da vegetação, é a disponibilização de quatro bandas (B02, B03, B04 e B08) com resolução espacial de 10 metros

(ESA, 2018a). Essa característica permite uma análise da paisagem, ampla e detalhada de determinada região.

Produtos semelhantes ao S-2 também estão disponíveis, gratuitamente, para processamento. Um deles é o Landsat 8, fornecido pela Agência Espacial Norte Americana (NASA). Ambos podem ser complementares dependendo do uso a ser buscado. No entanto, algumas características do S-2, como já citado anteriormente, proporcionam maiores possibilidades na aquisição de informações sobre a ocupação da terra. A Figura 10 ilustra a comparação entre os satélites S-2 e os Landsat 7 e 8.

Figura 10 – Bandas e comprimentos de onda dos satélites S-2 e Landsat 7 e 8.



Fonte: NASA (2015).

A alta taxa de aquisição de imagens e repetição de sensores de satélite permitem o uso de técnicas que detectem as alterações no terreno e perturbações (ASNER, 2013). Apesar dos lançamentos relativamente recentes, muitos pesquisadores já aprovaram e comprovaram as capacidades do S-2 para o monitoramento da vegetação natural, mapear queimadas e geologia (BONTEMPS et al., 2015; WHYTE; FERENTINOS; PETROPOULOS, 2018) e corpos d'água (DÖRNHÖFER et al., 2016).

2.4 A COMPUTAÇÃO EM NUVEM E SUA APLICABILIDADE NO SR

A cada dia, com a evolução da tecnologia da informação, os sistemas computacionais de alto desempenho e os chamados supercomputadores estão se tornando cada vez mais acessíveis (NEMANI et al., 2011). Associada a isso, a computação em nuvem pode ser considerada hoje como uma tecnologia universalmente disponível como se fosse uma *commodity* (GORELICK et al., 2017). Uma ferramenta muito utilizada atualmente é a plataforma fornecida pela empresa Google Inc., denominada Google Earth Engine (GEE) e disponibiliza um vasto arquivo de dados e ferramentas para processamento de produtos do SR. O uso da computação em nuvem facilita a manipulação e o processamento da grande e crescente quantidade de dados disponíveis de sensores, resoluções espaciais e temporais (RAVANELLI et al., 2018).

2.4.1 A ferramenta de processamento em nuvem GEE

Pode-se conceituar a ferramenta GEE como uma plataforma de SR com capacidade de rápida análise de dados globais e com potencial para fornecer, por meio da computação em nuvem, recursos para estudo de imagens satelitais dos últimos 40 anos (PATEL et al., 2015).

O GEE pode ser definido como uma plataforma de tecnologia que permite monitorar e quantificar as mudanças da Terra, em grande escala, por meio de um considerável catálogo de dados para observação global (MOORE; HANSEN, 2011). Processamentos que levariam semanas em computadores comuns, hoje podem ser realizados em segundos, a partir de um dispositivo móvel, como um smartphone ou tablet. Kumar et al., (2018) analisaram que o GEE foi utilizado em, somente, 300 artigos até 2017, na maior parte com dados do Landsat e por instituições de países desenvolvidos. Indicaram também que 19 trabalhos tiveram como temática o uso dos dados Sentinel 1 (S-1) e S-2 até o ano de 2017. Isso reforça o potencial desta tecnologia para as características intrínsecas da vegetação brasileira e com base nas já comprovadas vantagens do S-2 para a análise destes alvos.

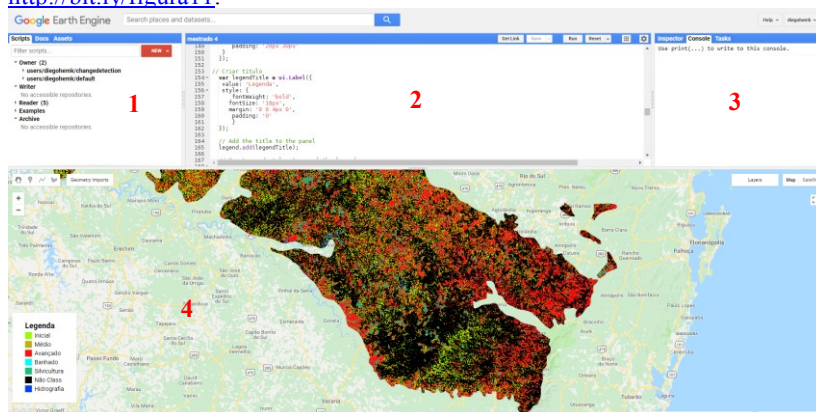
Limitações como a armazenagem, processamento de dados, *download*, normalmente comuns em análises de grande quantidade de informações (*big data*) são superados facilmente com a tecnologia (GORELICK et al., 2017; RAVANELLI et al., 2018). A combinação de dados massivos, algoritmos e linguagens computacionais, além da

estrutura em nuvem, oferecem vantagens de velocidade, facilidade de uso e colaboração, bem como, transparência em dados e métodos (MOORE; HANSEN, 2011).

De modo geral, é possível afirmar que o SR passa por uma mudança disruptiva, uma alteração de paradigma na utilização dos dados. Pesquisas que anteriormente necessitavam de elevados recursos computacionais, considerável tempo de processamento e tratamento de dados, atualmente são rapidamente disponibilizados por sistemas de processamento em nuvem. A aplicação desses mecanismos para a preservação ambiental, por meio da detecção de mudanças e classificação da vegetação, permite análises e obtenção de informações importantes para a preservação ambiental. Fatores como o crescimento de áreas urbanas e demandas globais por *commodities* agrícolas causam pressão sobre os remanescentes florestais em busca do aumento da produção pela expansão da área de cultivo (CARDILLE; BENNETT, 2010) e essas ferramentas podem auxiliar, de forma eficaz, o monitoramento ambiental.

A interface geral da ferramenta é apresentada na Figura 11 e contempla a área para armazenagem de scripts e exemplos (1), editor de códigos (2), console para apresentação de mensagens do sistema, inspetor e gerenciador de tarefas (3), e mapa de visualização (4).

Figura 11– Interface do aplicativo GEE. A figura encontra-se disponível em: <http://bit.ly/figura11>.



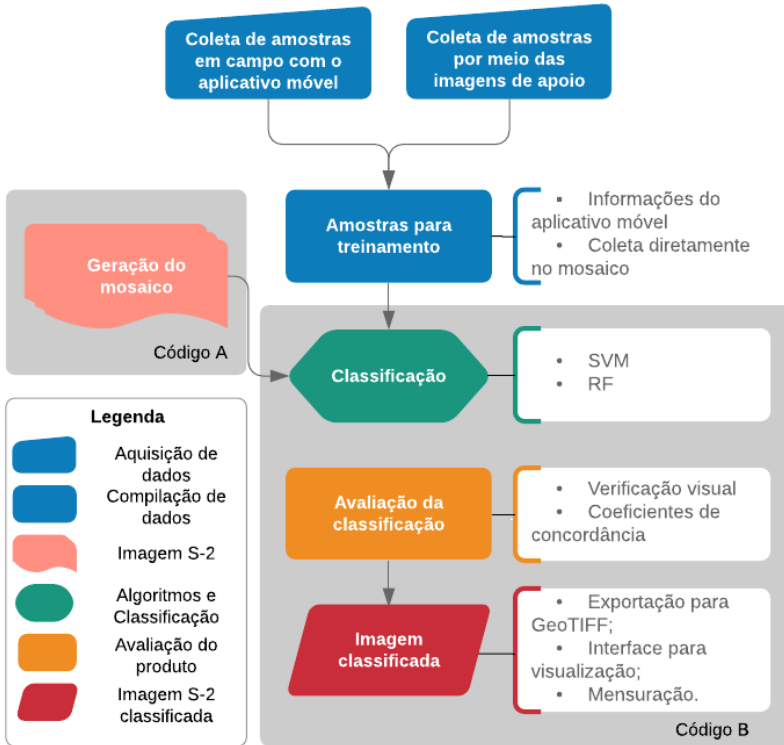
Fonte: o autor, com a utilização do GEE (GORELICK et al., 2017) e imagens S-2 (ESA, 2018a).

Além das vantagens citadas, operações matemáticas, análises estatísticas simples, geoestatística, aprendizado de máquina e processamento de imagens em geral, são operações passíveis de serem realizadas a partir do GEE, além da possibilidade de exportação (nos formatos GeoTIFF e TFRecord) de todo o material produzido.

3 METODOLOGIA

A metodologia utilizada na dissertação apresenta um conjunto de ferramentas tecnológicas que possibilitam um grande potencial para o uso do SR no estudo do uso e ocupação da terra. Trata-se da união de plataforma, sensor, aplicativo móvel, algoritmos e scripts customizados para que pesquisadores, estudantes e instituições possam analisar, em grande escala e ao longo do tempo, as mudanças e características do ambiente objeto de estudo. O presente trabalho será, portanto, uma alternativa que busca a classificação de imagens de forma rápida e com pouca demanda de recursos computacionais para processamento de dados. A Figura 12 apresenta a sequência metodológica de uso das ferramentas e técnicas. Ela não inclui a fase de desenvolvimento do aplicativo por tratar exclusivamente da metodologia ou rotina para a classificação proposta, já considerando o aplicativo móvel como desenvolvido para o uso.

Figura 12 – Metodologia proposta para a classificação de imagens, utilizando o GEE, aplicativo móvel e imagens S-2.



Fonte: o autor.

3.1 ÁREA DE ESTUDO

Os princípios da metodologia proposta foram elaborados para o uso em quaisquer tipos de ambientes onde exista a necessidade de uma classificação supervisionada. No entanto, para testar a sua aplicabilidade, foi utilizada a área ocupada pela FOM (Figura 2) no estado de Santa Catarina e definida por Klein (1978a).

3.2 O GEE PARA O PROCESSAMENTO DOS DADOS

Para a aquisição e processamento das imagens, geração das informações e classificação supervisionada foi utilizada a plataforma GEE, disponível online, que possibilita a customização de tarefas de processamento em servidores remotos. O sistema permite o comando, através do usuário, e as ações são realizadas remotamente nos servidores disponibilizados gratuitamente pela empresa. A ferramenta é oferecida para pesquisa e uso não comercial e suas principais aplicações estão relacionadas com a classificação de imagens, detecção de desmatamento, análise temporal de informações ambientais e estimativa de biomassa (GORELICK et al., 2017).

Todas as imagens inseridas e disponibilizadas pela aplicação devem possuir parâmetros mínimos para uso, como a disponibilidade e erro posicional, por exemplo. O sistema permite a criação de programas com base nas linguagens JavaScript e Python, o que permite ao usuário o desenvolvimento de programação processual (GORELICK et al., 2017). Toda a organização dos dados e processamento nos servidores passa por um sofisticado mecanismo de organização, operando em paralelo e com limites máximos para as solicitações dos usuários individuais.

O processamento das imagens e a customização de parte da metodologia apresentada neste trabalho seguiram um fluxo (programa), desenvolvido na linguagem JavaScript.

O script se divide em três partes principais: geração das imagens (script mosaico e mosaico com múltiplas telas), classificação e mensuração da classificação. Para o primeiro, foi elaborado um código com aproximadamente 200 linhas e, para o segundo, cerca de 380 linhas. Neles, foram adicionadas as funções indicadas no Quadro 4. Os códigos completos podem ser encontrados nos Apêndices A, B, C e D ou no repositório http://bit.ly/codigos_gee.

Quadro 4 – Funções adicionadas ao script.

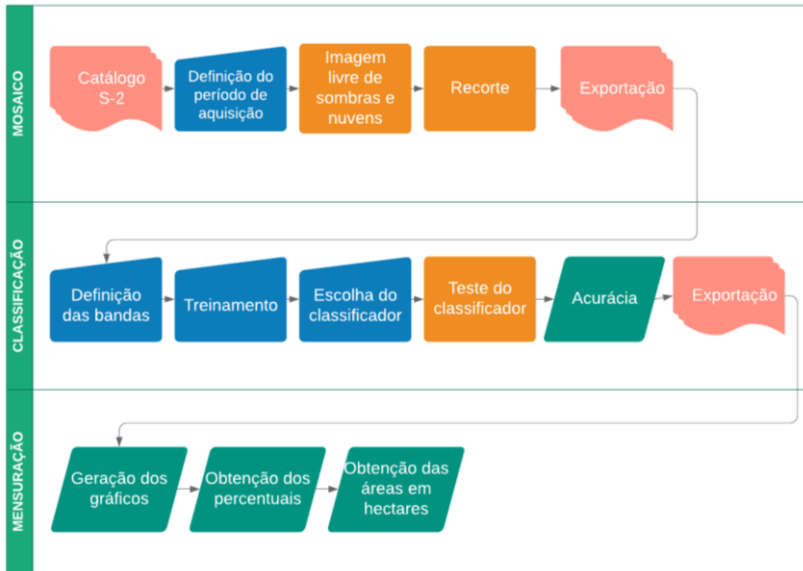
Código	Função	Descrição
Geração do mosaico (detalhado no Apêndice A)	Customização do mapa de fundo	Adição da imagem de satélite do Google como padrão de observação e criação de uma nova camada para visualização de locais.
	Supressão das nuvens e sombras	Utilização de código específico para a redução do efeito de nuvens e sombras.
	Número de imagens utilizadas	Função inserida para visualizar a quantidade de cenas utilizadas no processamento para a geração do mosaico.
	Exportar imagem como Asset	Realiza a exportação da imagem como arquivo para processamento no próprio GEE. Este procedimento pode ser realizado com base em toda a extensão ou uma geometria específica a partir da criação de um polígono diretamente no mapa.
Geração do mosaico com a função de múltiplas telas (detalhado no Apêndice B)	Todas as funções do gerador de mosaico, porém com a função de visualização de múltiplas telas.	A funcionalidade de visualização em múltiplas telas auxilia na análise do mosaico a ser gerado. Permite a visão entre quatro composições coloridas, conforme mostrado na Figura 20.
Classificação (detalhado no Apêndice C)	Customização do mapa de fundo	Adição da imagem de satélite do Google como padrão de observação. Criação de uma nova camada para visualização de locais.
	Fixar centro do mapa e escala inicial	Essa função permite configurar a tela de localização padrão todas as vezes que o código for executado.
	Visualização da composição RGB	É adicionada uma camada previamente configurada para a visualização da imagem a ser processada.

Código	Função	Descrição
Classificação (detalhado no Apêndice C)	Classificação e validação do algoritmo classificador	Nessa seção são fornecidos os parâmetros relacionados ao algoritmo classificador e sua configuração, além dos coeficientes de concordância (matriz de confusão, precisão global, coeficiente Kappa, precisão do usuário e produtor).
	Exportação dos coeficientes de concordância	Permite a exportação de todos os parâmetros de precisão obtidos pela classificação. É possível baixar arquivos nos formatos CSV e JSON.
	Legenda	Cria a legenda do mapa.
	Camadas complementares	Adiciona camadas que possibilitam a análise dos alvos.
	Estatísticas da imagem classificada	Adiciona os valores, em percentual, de todas as classes e cria dois gráficos com o número de pixels por classe e área (em hectares) por classe.
	Exportação da imagem classificada	Permite exportar a imagem já classificada em diversos formatos, inclusive GeoTIFF e GeoTIFF cloud-optimized. É possível exportar toda a área da FOM, uma área de um polígono desenhado diretamente no mapa ou importado como camada para o GEE.
Mensuração (detalhado no Apêndice D)	Painel de gráficos	Permite a inserção de dois gráficos idênticos aos existentes na seção “Classificação” para que posteriormente possam ser visualizados como um “app” do GEE ou no aplicativo móvel.
	Estatísticas da classificação	Adiciona os valores, em percentual, das classes ao console do GEE.
	Apresentação da imagem classificada	É adicionada uma camada com parâmetros previamente configurados para a apresentação da imagem classificada.

Fonte: o autor.

A Figura 13 apresenta todas as etapas utilizadas neste trabalho para testar a classificação da vegetação que compõe a FOM, existente em Santa Catarina.

Figura 13 – Fluxo de execução dos programas (scripts) para a obtenção da imagem classificada.



Legenda




Fonte: o autor.

3.3 IMAGENS SENTINEL 2 (ESA)

Foram utilizadas imagens provenientes da constelação Sentinel, do programa Copernicus, disponibilizadas pela ESA. No GEE, as imagens S-2 (A e B) são disponibilizadas no formato JPEG2000 e atualizadas no banco de dados do GEE a cada dois dias (GOOGLE, 2018a).

Como base para a classificação gerou-se mosaicos, diretamente no GEE, com períodos de aquisição diferentes visando a equalização e obtenção de imagens sem nuvens e/ou sombras. Foram contabilizadas a quantidade de cenas utilizadas para cada período, bem como, o tempo médio para a geração das imagens. O intuito foi de estimar o diferencial do processamento online em relação ao tratamento de imagens convencional, por meio do computador. Para a formação do mosaico foram utilizadas três órbitas do S-2, com 290 km cada uma (Figura 14).

Figura 14 – Órbitas 124 (a), 81 (b) e 38 (c) do S-2 sobre a área de abrangência da FOM.



Fonte: o autor.

3.3.1 Mosaico e tratamento das sombras e nuvens

A presença de nuvens, sombras e da neve influenciam significativamente na qualidade dos mosaicos (ROY et al., 2010; ZHU;

WOODCOCK, 2012). A capacidade de detectar e isolar com precisão a forma das nuvens tem um impacto significativo em diversas aplicações com imagens de satélites, acentuando-se quando é realizado o mapeamento e/ou a classificação (ZHANG; GUINDON; CIHLAR, 2002). O GEE disponibiliza o algoritmo FMASK (ZHU; WOODCOCK, 2012) para a utilização com a coleção de imagens Landsat, ferramenta esta ainda não disponível para o S-2. Portanto, buscou-se para este trabalho métodos que tivessem, através do GEE, a aplicação de técnicas semelhantes àquela disponível para o satélite Landsat.

Foi possível, com o auxílio da documentação existente e da comunidade de desenvolvedores, elaborar um programa, em Javascript, que permitiu a criação dos mosaicos de imagens sem a presença de nuvens e sombras. O procedimento realiza a identificação e recorte de pixels, substituindo-os com outra imagem, do mesmo satélite, disponível em outra data (preferencialmente mais recente). Para que isso ocorra, é necessário que o usuário selecione um período ideal, entre as datas inicial e final, para que o servidor remoto possa substituir, com o repositório disponível, todos os locais afetados por sombras e/ou nuvens em meio ao mosaico. Solari (2017) também utilizou uma técnica semelhante e afirma que a utilização de valores medianos elimina pixels com ruídos causados por névoas, nuvem ou sombra que não tenham sido removidos pelo algoritmo. A Figura 15 apresenta a criação de mosaicos com períodos (intervalos) de aquisição das imagens entre 01/12/2017 e 01/01/2018 (a) e 01/12/2017 e 01/07/2018 (b). É possível perceber no mosaico (a) os pixels subtraídos das imagens por serem considerados, automaticamente, como nuvens ou sombras. A seta vermelha exemplifica uma área com estas características, identificada e suprimida do mosaico. O fato de não haver, no período (a) outra imagem para a reposição, fez com que o espaço fosse apresentado como “sem dados”.

Figura 15 – Mosaicos com períodos de aquisição distintos.



Fonte: o autor, com a utilização do GEE (GORELICK et al., 2017) e de imagens S-2 (ESA, 2018a).

Para analisar a eficiência do processamento em nuvem e a influência da imagem (devido aos distintos períodos) sobre a classificação, foram gerados mosaicos com seguintes características:

- Entre 01/01/2017 e 19/10/2018, identificado pelo prefixo A;
- Entre 01/01/2017 e 01/01/2018, identificado pelo prefixo B;
- Entre 01/11/2017 e 01/04/2018, identificado pelo prefixo C.

Para cada um dos períodos definidos, foram criados arquivos com resoluções espaciais diferentes, de 10, 20 e 30 metros, identificados pelos sufixos 1, 2 e 3, respectivamente. Portanto, foram geradas e testadas nove imagens (Quadro 5), contemplando a área da FOM. Ao

classificar todas as diferentes imagens, foram mantidas as mesmas amostras de treinamento entre todos os procedimentos. Também foi mensurado o tempo que o GEE utiliza para entregar a mapa e exportar o arquivo da imagem. Para cada um dos procedimentos, foram coletadas cinco medidas de tempo, em diferentes horários do dia.

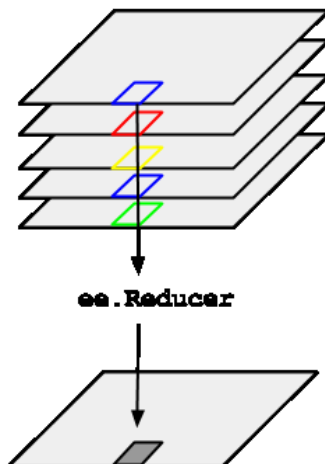
Quadro 5 – Imagem, período de aquisição e resolução espacial.

Imagem	Período	Resolução espacial (m)
A1	01/01/2017 a 19/10/2018	10
A2		20
A3		30
B1	01/01/2017 a 01/01/2018	10
B2		20
B3		30
C1	01/11/2017 a 01/04/2018	10
C2		20
C3		30

Fonte: o autor.

Considerando a resolução temporal do S-2 (máximo de cinco dias, a partir de março de 2017), foi possível uma considerável quantidade de cenas disponível no acervo, permitindo o preenchimento dos locais onde há períodos longos com presença de nuvens e/ou sombras. Para gerar uma única imagem, usou-se a função do GEE “ee.Reducer”, permitindo a redução de uma coleção de imagens (Figura 16) a um valor mediano ao longo do tempo, gerando um único arquivo (GOOGLE, 2018a).

Figura 16 – Função ee.Reducer do GEE.




Fonte: Google (2018a).

Para a metodologia proposta, o usuário poderá alterar as datas relacionadas dos períodos de aquisição inicial e final das imagens para a construção do mosaico. A metodologia proposta permite a realização de outros testes, por meio da customização de datas e algoritmos classificadores.

O mosaico de imagens utilizado manteve, em todos os processamentos e resultados, o recorte estabelecido por Klein (1978a) para a área de FOM no estado de Santa Catarina. A Figura 17 a apresenta o mosaico recortado pela feição FOM (KLEIN, 1978a), imagens S-2 A e S-2 B (ESA, 2018a), com a função “`ee.Reducer`” (GORELICK et al., 2017) e programa (script) para minimização dos efeitos de nuvens e sombras.

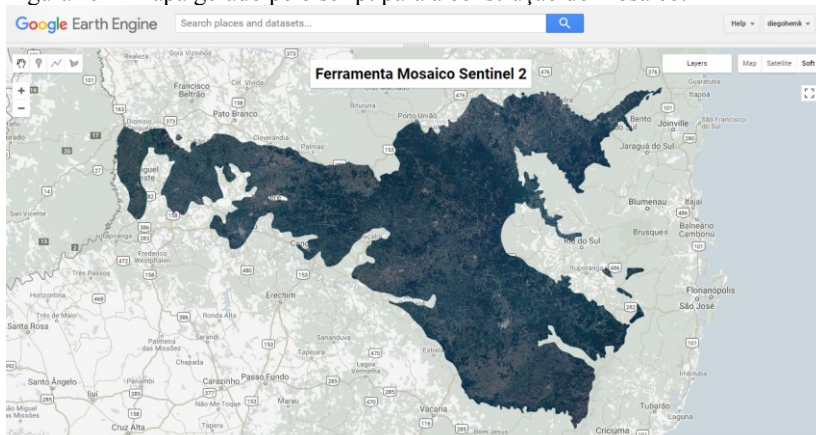
Figura 18 – Banda 10, enfatizando as nuvens alta altitude, em comparação com a composição RGB (4-3-2).



Fonte: o autor.

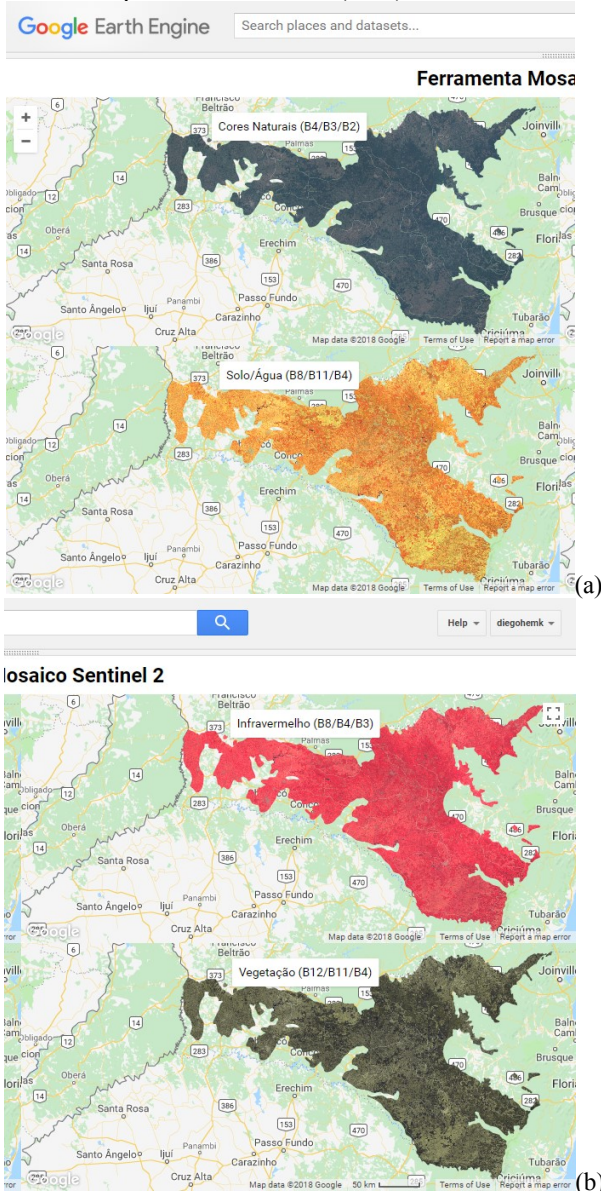
Todo o processamento dos mosaicos é obtido a partir de dois scripts, construídos para esta proposta de metodologia e são apresentados nos Apêndices A e B. O primeiro, contempla a criação do mosaico propriamente dito (Figura 19) e, o segundo, permite a criação do mosaico e um mapa com múltiplas composições coloridas que facilitam a análise da imagem a ser gerada Figura 20.

Figura 19 – Mapa gerado pelo script para a construção do mosaico.



Fonte: o autor, com o uso do GEE (GORELICK et al., 2017) e imagens S-2 (ESA, 2018a).

Figura 20 – Mapa gerado pelo script para a construção do mosaico e a apresentação em múltiplas telas vinculadas (a e b).



Fonte: o autor, com o uso do GEE (GORELICK et al., 2017) e imagens S-2 (ESA, 2018a).

3.4 DESENVOLVIMENTO DO APLICATIVO MÓVEL PARA COLETA DE DADOS

Para a metodologia proposta neste trabalho foi desenvolvido um aplicativo móvel que coleta as amostras para treinamento do algoritmo classificador. As funcionalidades incluem a captura de informações descritivas do local e as coordenadas geográficas, além do funcionamento offline e o posterior envio a um banco de dados para armazenamento na nuvem (online).

A plataforma utilizada para a construção do aplicativo móvel foi a Thunkable (<http://app.thunkable.com>), um serviço baseado no código-fonte do *MIT App Inventor* (POKRESS; VEIGA, 2013), que permite o desenvolvimento de ferramentas para sistemas operacionais Android, por meio de programação visual. A Figura 21 apresenta parte do código elaborado para a construção do aplicativo, contemplando a apresentação e registro da precisão, coordenadas, endereço e altitude, sempre que houver uma alteração no posicionamento.

Figura 21 – Parte do código utilizado, mostrando o método de programação visual.

```

when LocationSensor1 . Location Changed
  latitude longitude altitude speed
do
  set Precisione . Text . to join LocationSensor1 . Accuracy . metros
  set Lat . Text . to get latitude
  call TinyDB2 . Store Value
    tag lat
    value To Store get latitude
  set Lon . Text . to get longitude
  call TinyDB2 . Store Value
    tag long
    value To Store get longitude
  set Address . Text . to LocationSensor1 . Current Address
  call TinyDB2 . Store Value
    tag add
    value To Store LocationSensor1 . Current Address
  set Saty . Text . to join LocationSensor1 . Altitude . metros
  call TinyDB2 . Store Value
    tag at
    value To Store LocationSensor1 . Altitude

```

Fonte: o autor.

Para o armazenamento dos dados obtidos a partir do aplicativo, foi utilizada a ferramenta Fusion Tables (GONZALEZ et al., 2010), um banco de dados online, com a funcionalidade de compartilhamento, exportação gerenciamento e edição dos dados por mais de um usuário.

3.5 A CLASSIFICAÇÃO DAS IMAGENS DE SATÉLITE

Com base nos mosaicos obtidos a partir dos métodos apresentados, buscou-se a classificação supervisionada com o objetivo principal de testar a metodologia proposta.

3.5.1 Definição das classes

Como princípio básico na definição das classes, buscou-se a aplicação prática da Resolução CONAMA 04/94, que


Define vegetação primária e secundária nos estágios inicial, médio e avançado de regeneração da Mata Atlântica, a fim de orientar os procedimentos de licenciamento de atividades florestais no estado de Santa Catarina (BRASIL, 1994).

Portanto, foram diferenciadas as classes Estágio Avançado/Primária, Estágio Médio e Estágio Inicial. Considerando o objetivo buscado pela separação das classes, não foram diferenciados os estágios “Avançado” e “Primário”, pelos seguintes aspectos:

- a) Florestas primárias compõem uma pequena parte do contexto a ser analisado;
- b) Dificuldade dos sensores multiespectrais em distinguir as duas classes;
- c) Ambos os estágios são importantes para a preservação pois possuem maturidade estrutural/biodiversidade diferenciados.

Além dos estágios sucessionais, foram definidas outras classes de cobertura da terra, também de relevância para a análise ambiental. As denominações e cores que representam os temas são apresentados na Figura 22.

Figura 22 –Cores atribuídas às classes de uso e cobertura da terra.



Fonte: o autor.

A presença da silvicultura com espécies exóticas também foi medida por meio da classificação. Economicamente importante para as regiões contempladas pela FOM, representa boa parte do solo ocupado nessas áreas.

Os ambientes ocupados por campos nativos, conhecidos na região como Campos de Lages, Campos de Altitude, localizados na localidade de Coxilha Rica não foram estratificados neste levantamento. Regiões no município de Água Doce (SC) também possuem extensas áreas com este tipo de vegetação nativa. Os motivos para a não classificação destas áreas neste trabalho é o fato de possuírem comportamento característico nos períodos de inverno e verão e resolução CONAMA (BRASIL, 2010) específica para sua caracterização, fatores estes que demandam critérios diferenciados para a seleção do mosaico e da coleta de amostras.

A áreas de agricultura não foram contempladas no mapeamento temático por possuírem características que aumentariam, em demasia, a complexidade da classificação supervisionada, especialmente por sua sazonalidade e variação ao longo do tempo. O potencial das imagens de satélite S-2 para quantificação do uso agrícola, são atestadas por vários autores (CLEVERS; GITELSON, 2013; DELEGIDO et al., 2011; IMMITZER et al., 2016; VERRELST et al., 2012). O estudo dessas classes será sugerido em futuros trabalhos, utilizando a metodologia aqui proposta.

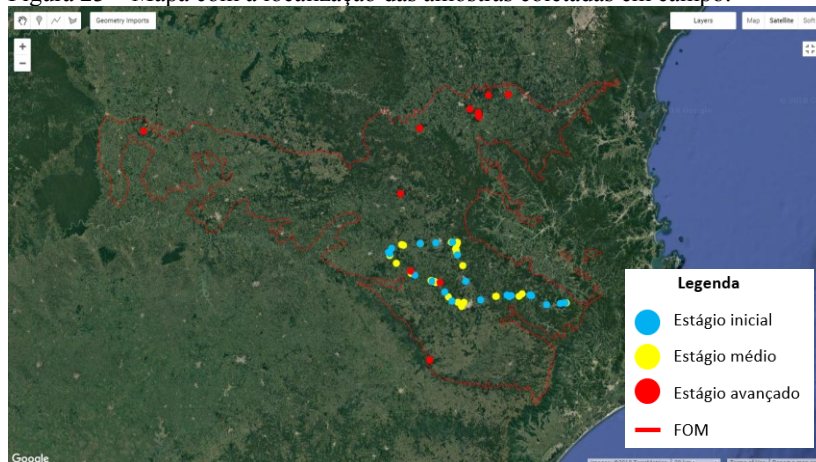
Agricultura, banhado e campo nativo foram, portanto, agrupados no tema “Outras Classes”. No entanto, a metodologia permite a classificação desses usos e/ou coberturas do solo em trabalhos futuros.

3.5.2 Treinamento dos algoritmos classificadores

A classificação supervisionada possui, como premissa, a apresentação de informações ao algoritmo classificador para que seja realizado o treinamento, visando a geração do mapa temático. A metodologia proposta, que contempla a coleta das informações com base em um aplicativo móvel, facilita o gerenciamento das amostras, especialmente para os especialistas que realizarão as coletas em campo.

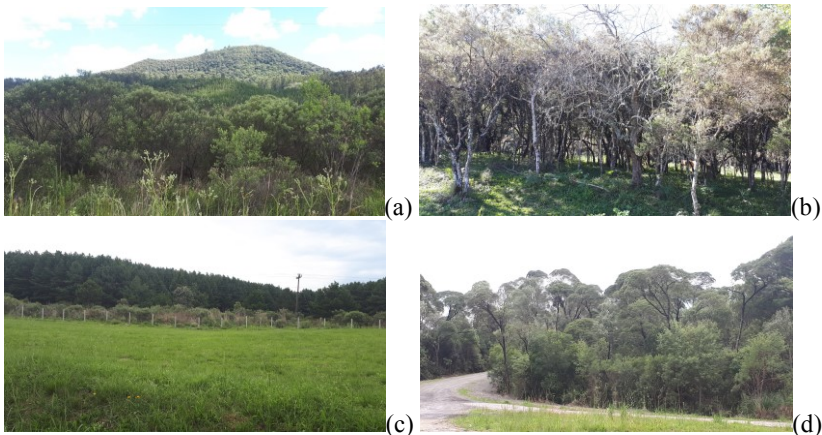
Para treinar o usuário na coleta de amostras pela imagem, foram realizadas incursões em parte das regiões contempladas pelas BR-282 e BR-116, conforme Figuras 23 e 24. As referidas amostras serviram como base para o treinamento do usuário quanto à correspondência da realidade e a percepção sobre o mosaico produzido. De maneira complementar, foram adquiridas amostras também por meio de imagens de satélite com alta resolução. As amostras vermelhas apresentadas na Figura 23 são provenientes do Inventário Florístico Florestal de Santa Catarina (IFFSC) (VIBRANS et al. 2013) e são locais com vegetação em estágio avançado. Os pontos em cores ciano e amarelo representam, respectivamente, locais com vegetação em estágios sucessionais inicial e médio. A Figura 24 apresenta amostras de estágio inicial e silvicultura (a), estágio médio (b e d) e outras classes e reflorestamento (c).

Figura 23 – Mapa com a localização das amostras coletadas em campo.



Fonte: o autor, com o uso do GEE (GORELICK et al., 2017).

Figura 24 – Registro de locais com as classes de uso e ocupação da terra utilizadas.



Fonte: o autor.

3.5.3 Algoritmos classificadores

Para a metodologia proposta, utilizou-se os classificadores *Random Forest (RF)* e o *Support Vector Machine (SVM)*. Autores testaram ambos sobre as imagens S-2 e obtiveram resultados satisfatórios, superiores aos obtidos com o L8. Sothe et al. (2017) testaram, na FOM, S-2 e L8 em vários cenários, incluindo variáveis como textura, índices, além da seleção de diferentes grupos de bandas. O melhor resultado foi obtido com a combinação de todas as bandas do S-2, SVM e nenhuma outra variável complementar (como a textura e o índice de vegetação).

Para testar o desempenho do GEE, do aplicativo móvel e da metodologia como um todo, estruturou-se o estudo de caso considerando como base para a classificação as bandas provenientes do S-2, sem analisar os índices de vegetação e parâmetros texturais.

3.5.4 Métodos para validação da classificação

Na metodologia proposta serão disponibilizados cinco parâmetros para avaliação da classificação obtida: o índice Kappa, a Matriz de Confusão, a precisão geral e a precisão dos pontos de vista do usuário e do produtor. Estes, representam os métodos mais utilizados para a verificação da precisão, considerando os erros e acertos dos algoritmos.

Todos os parâmetros para análise são passíveis de exportação nos formatos CSV ou JSON, conforme script disponibilizado.

Para a obtenção dos parâmetros foi inserido na metodologia o treinamento do algoritmo classificador a partir de amostragem aleatória. Assim, ao executar o código, 30% das amostras de treinamento serão utilizadas para a validação e os outros 70% para a classificação da imagem propriamente dita.

3.6 A INTERFACE CUSTOMIZADA PARA A PRODUÇÃO DOS MAPAS TEMÁTICOS E DISPONIBILIZAÇÃO DOS SCRIPTS

O GEE permite a programação e a customização da interface de trabalho. Desenvolveu-se, um script customizado para facilitar a alteração de uma classificação já existente e/ou a criação de uma nova. As principais funcionalidades construídas através do script contemplam as seguintes ferramentas:

- Ajustes do período a ser considerado para a construção do mosaico S-2;
- Seleção do algoritmo classificador desejado;
- Ajuste da transparência das camadas;
- Seleção de outras camadas para visualização.

Ao executar o script disponibilizado no Apêndice C, a classificação é executada necessitando, apenas, do GEE em execução.

O GEE permite que seja criado um repositório para gerenciamento dos códigos escritos na plataforma. Os scripts que geram os mosaicos, realizam a classificação das imagens e o que apresenta as medidas, estão disponíveis a partir do endereço http://bit.ly/codigos_gee. Por meio desta página é possível copiar ou clonar o conteúdo e analisar os registros de alteração do código ao longo do tempo.

4 RESULTADOS E DISCUSSÃO

4.1 CLASSIFICAÇÃO E GERAÇÃO DOS MOSAICOS

Em métodos tradicionais de classificação de imagens, é importante levar em consideração a estrutura computacional e o tempo necessários para o processamento e armazenagem dos dados. As atividades que contemplam a aquisição (download) das imagens de um servidor, a instalação de aplicativos para processamento, o registro e ortoretificação e o provável tempo de espera para a criação do produto final são fatores a serem considerados diante da metodologia aqui proposta.

4.1.1 Processamento para a geração dos mosaicos

Foram contabilizados os tempos de apresentação e exportação dos nove mosaicos utilizados no estudo de caso (Tabela 1).

Tabela 1– Tempo estimado para processamento das imagens utilizadas na classificação (média de cinco solicitações).

Imagem	Tempo para apresentação (segundos)	Exportação (minutos)	Quantidade de cenas
A1		180	
A2	62	150	2027
A3		127	
B1		115	
B2	39	90	715
B3		72	
C1		60	
C2	8	57	587
C3		38	

Fonte: o autor.

A coluna “Tempo para apresentação” (Tabela 1) contempla as funções de acesso às imagens, análise e supressão de nuvens, redução, recorte de acordo com o limite da FOM e apresentação na tela. Já a coluna “Quantidade de cenas” é o número de imagens utilizadas no servidor para a composição do mosaico em relação ao tempo informado.

4.1.2 Dados obtidos a partir da classificação

A seguir serão apresentados os resultados provenientes das classificações para cada um dos mosaicos em relação aos algoritmos SVM e RF (Tabela 2), considerando os nove mosaicos e os coeficientes Kappa e de Precisão Global (PG).

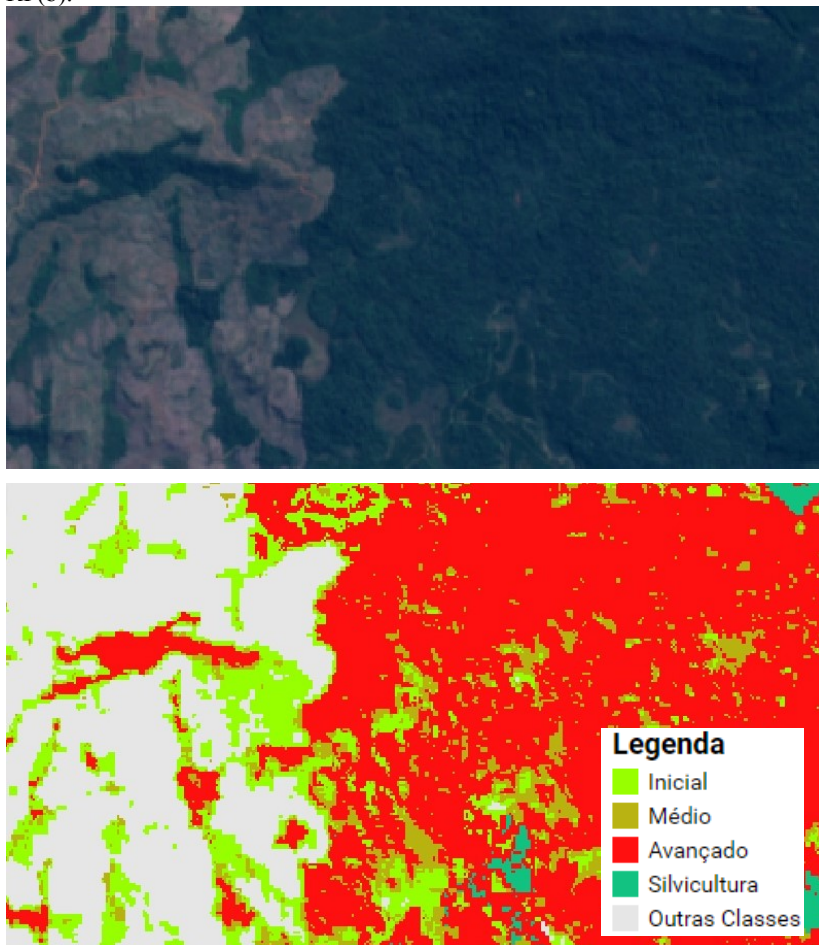
Tabela 2 – Coeficiente Kappa e de PG da classificação para os algoritmos SVM e RF.

Coeficiente	A1	A2	A3	B1	B2	B3	C1	C2	C3
Kappa SVM	90,52	87,42	81,56	83,75	78,77	78,01	87,01	82,98	80,16
Kappa RF	97,98	97,40	97,30	92,40	91,16	90,87	83,39	84,37	85,55
PG SVM	92,48	89,96	85,12	87,14	83,15	82,84	89,75	86,28	84,29
PG RF	97,91	97,93	98,86	93,93	92,97	92,63	86,59	87,74	88,53

Fonte: o autor.

A Tabela 2 traz as informações relacionadas aos parâmetros de precisão da classificação. Analisando o Kappa e PG, o RF não foi superior ao SVM somente na imagem C1, que possui como características o período de aquisição entre 01/11/2017 e 01/04/2018, com 10 m de resolução espacial. Com o SVM observa-se uma tendência de redução no valor dos coeficientes ao diminuir o período de aquisição e a resolução espacial. Entende-se que o SVM não necessariamente será um bom classificador em amostragens que sejam complexas e estejam disponíveis em grande quantidade. Nessas situações, o RF (Figura 25) possui a tendência em oferecer melhores resultados dada a sua robustez em dados complexos. A Figura 25 ilustra a Composição do S-2 (RGB) e a imagem A1 classificada por RF, apresentando os temas “Outras classes”, “Avançado”, “Médio”, “Inicial” e “Reflorestamento”

Figura 25 – Composição do S-2 (RGB) (a) e a imagem A1 classificada por RF(b).



Fonte: o autor, com o uso do GEE (GORELICK et al., 2017) e imagens S-2 (ESA, 2018a).

As matrizes de confusão obtidas com o processamento indicam diminuições na precisão entre as classes estágio inicial, médio e avançado. Esse fato já era esperado, considerando a semelhança dos padrões encontrados os fragmentos florestais, especialmente no que concerne à diferenciação do médio para avançado.

Na classificação de imagens, um dos temas de maior facilidade para identificação e diferenciação é a hidrografia por apresentar

respostas espectrais específicas. Além disso, sua discriminação no mapeamento temático também possibilita outros tipos de estudos e análise, especialmente relacionados ao estudo de Áreas de Preservação Permanente (APP), por exemplo.

O fato de possuir grande capacidade de processamento e armazenagem, faz do GEE uma importante ferramenta para o tratamento de dados, especialmente os relacionados ao SR. A possibilidade de customização dos parâmetros e sequências/fluxos de trabalho também é um dos pontos fortes da ferramenta. O modelo metodológico proposto visa criar uma rotina para a aplicação do GEE com a alimentação constante dos dados coletados em campo por profissionais especialistas, principalmente em áreas correlatas ao estudo da vegetação. A metodologia propõe a rotina de aquisição de amostras como essencial para o aprimoramento do mapa classificado. A rapidez no processamento permite que testes e experimentos sejam realizados com maior frequência e possibilitem a busca por subprodutos mais adequados à realidade dos órgãos ambientais.

Outra aplicação importante da metodologia é a possibilidade de utilização da imagem classificada para a análise do CAR. A automação do procedimento de homologação é essencial considerando-se a quantidade de dados a serem verificados no estado.


4.2 APLICATIVO PARA A COLETA DAS AMOSTRAS DE TREINAMENTO

Um dos princípios da classificação supervisionada é a coleta de amostras para treinamento do algoritmo classificador, visando uma melhor acurácia dos dados. O erro na coleta ou identificação das amostragens interfere diretamente na qualidade do produto obtido após o processamento. As estimativas de acurácia estão diretamente relacionadas ao número e qualidade de amostras para treinamento coletadas (CONGALTON, 1991).

Os métodos para aquisição dessas informações são variados. A experiência do especialista, análise de fotografias aéreas ou imagens de satélite, além da coleta em campo, são métodos comumente utilizados para obter os dados de treinamento. Correia et al., (2007) utilizaram fotos aéreas e informações de técnico experiente de campo para a aquisição das amostras. Muitas vezes, mesmo com coletas bem definidas e claras, o técnico classificador pode confundir e errar a qualificação dos temas.

Considerando esses aspectos, é relevante que as amostras para o treinamento e posterior realização da classificação, sejam as mais fidedignas possíveis, visto que há a potencial interferência no mapeamento das classes temáticas. Para tanto, desenvolveu-se um aplicativo móvel, em duas versões, passível de instalação em dispositivos (tablets e smartphones), que visa o auxílio na coleta das informações em campo e seus atributos para posterior conferência e adição ao processo de classificação. Os arquivos no formato APK, para instalação em dispositivos Android, estão disponíveis a partir do endereço http://bit.ly/app_completoesimplificado e possuem, após instalados, os ícones apresentados na Figura 26, de acordo com a respectiva versão.

Figura 26 – Identificação dos aplicativos Completo (a) e Simplificado (b), respectivamente, após a instalação.



Fonte: o autor.

Para que o aplicativo possua plena aplicabilidade, e atenda às necessidades do especialista de campo, buscou-se implantar a funcionalidade de armazenamento dos dados sem que fosse obrigatória a estrutura de internet ou qualquer sinal de comunicação entre o dispositivo e o banco de dados que recebe as informações, ou seja, o sistema funciona no formato offline. O Quadro 6 apresenta as telas e funcionalidades do aplicativo móvel.

Considerando que a função principal do aplicativo móvel é ser disponibilizado para equipes, especialmente no IMA/SC, é importante que o sistema funcione com plena performance na maioria dos dispositivos móveis existentes, independentemente da sua capacidade de processamento e memória RAM. Por isso, é apresentada uma versão simplificada (Figura 26.b), diferindo do aplicativo principal, essencialmente, no aspecto visual e nas funções visualização de mapa e endereço presentes na tela “Nova coleta” (Figura 28). Todas as telas, de ambos os aplicativos, são disponibilizadas no Apêndice E.

Quadro 6 – Telas do aplicativo e suas respectivas funções.

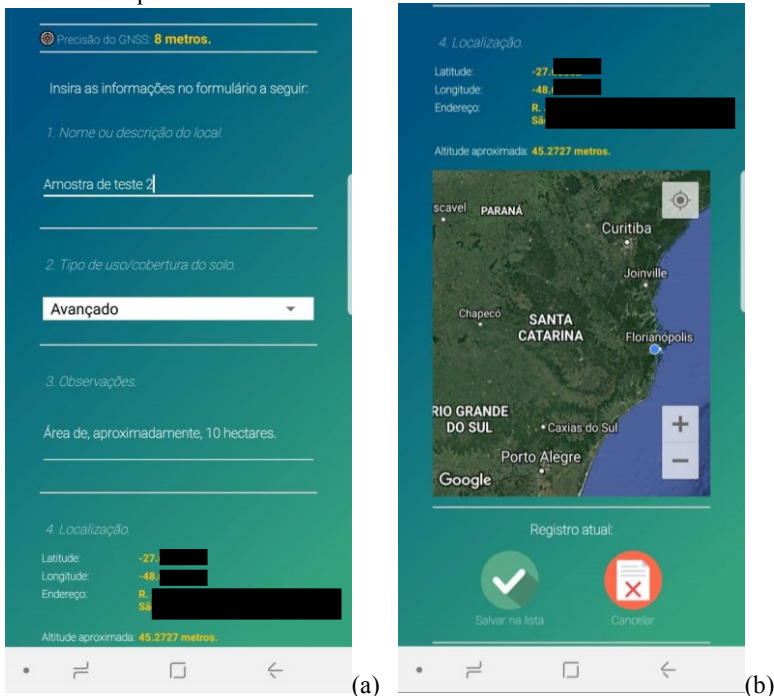
Tela	Função
Abertura	Identificar o aplicativo.
Login	Verificar as credenciais do usuário.
Cadastro	Solicitar novo cadastro de usuário para a utilização do aplicativo. O administrador possui a permissão para autorizar ou não o cadastro de usuário.
Menu principal	Permite o acesso a todas as funcionalidades, incluindo as informações sobre o aplicativo. É possível acessar as funções de “Nova coleta”, “Consultar classificação”, “Legislação”, “Estimativa de altura” e “Sobre”.
Nova coleta	Permite a coleta de informações relacionadas a amostra para treinamento do algoritmo classificador (Figura 27). Os dados coletados são: Nome ou descrição da amostra, Tipo de uso/cobertura do solo (Inicial, Médio, Avançado, Banhado, Agricultura, Campo nativo, Reflorestamento, Hidrografia, Outras Classes), Observações, Localização (coleta automática da Latitude, Longitude, Endereço – quando houver e Altitude aproximada). Adicionalmente, além das informações de localização, é fornecida a precisão do receptor GNSS no momento da coleta e um mapa de localização atual com imagem de satélite de alta resolução ao fundo. Ainda, nesta tela, é possível salvar ou cancelar o registro atual, visualizar as informações salvas em uma listagem, além de suprimir um registro já salvo ou enviar para o banco de dados online as informações coletadas presentes na referida lista.
Consultar classificação	Essa função permite a visualização da imagem classificada diretamente no GEE.
Legislação	Permite consultar a Resolução CONAMA 04/94, que define os parâmetros para a classificação da vegetação por meio dos seus estágios sucessionais.
Estimativa de altura	Considerando que a altura do dossel é uma das medidas para a definição do estágio da vegetação, é fornecida a ferramenta que possibilita estimar a altura de objetos, com base no cálculo trigonométrico utilizado em triângulos retângulos, onde é obtido o cateto oposto a partir do adjacente em relação à tangente de um determinado ângulo.
Sobre	Apresenta informações sobre os Termos de Uso, contato e detalhamento do cálculo realizado pela função “Estimativa de altura”.

Fonte: o autor.

O aplicativo desenvolvido para realizar a coleta de amostras possibilitou a otimização e a redução no tempo de aquisição das informações. A funcionalidade de captura de pontos, juntamente com seus respectivos atributos e o envio dos dados a um servidor remoto, facilitará a coleta das amostras por meio de equipes. Foram coletados, aproximadamente, 50 pontos para a realização dos testes e aprimoramento do aplicativo. Parte dos dados adquiridos foram utilizados para o treinamento da classificação.

A Figura 27 apresenta a tela para aquisição de informações sobre um possível ponto a ser amostrado (a), a visualização da localização e, também, salvar ou cancelar o registro atual (b).

Figura 27 – Seções de gerenciamento da coleta atual, na tela “Nova coleta” do aplicativo Completo.



Fonte: o autor.

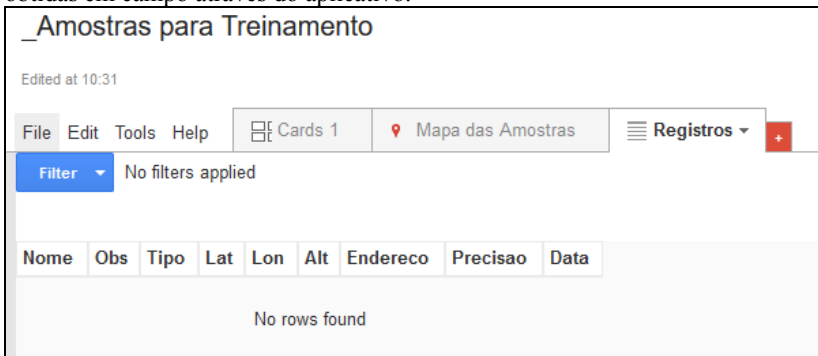
Figura 28 – Tela “Nova coleta” na versão simplificada do aplicativo.

<p>Precisão do GNSS:</p> <p>Insira as informações no formulário a seguir:</p> <p>1. Nome ou descrição do local:</p> <p>Identifique a amostra.</p> <p>2. Tipo de uso/cobertura do solo:</p> <p>Inicial ▼</p> <p>3. Observações:</p> <p>Informe nesse campo informações sobre o local.</p> <p>4. Localização:</p> <p>Latitude:</p>	<p>4. Localização:</p> <p>Latitude:</p> <p>Longitude:</p> <hr/> <p>Registro atual:</p> <p>Salvar</p> <p>Cancelar</p> <hr/> <p>Gerenciar registros gravados:</p> <p>Enviar lista para o banco de dados</p> <p>Apagar registro selecionado na lista</p>
---	--

Fonte: o autor.

Após o preenchimento na tela “Nova coleta”, é necessário o comando do usuário para que os dados sejam enviados para a nuvem, em uma tabela Fusion Tables (GONZALEZ et al., 2010) permitindo, assim, o armazenamento para posterior gerenciamento online das informações. O mecanismo Fusion Tables (Figura 29) ainda permite o uso colaborativo e instantâneo entre dois ou mais usuários.

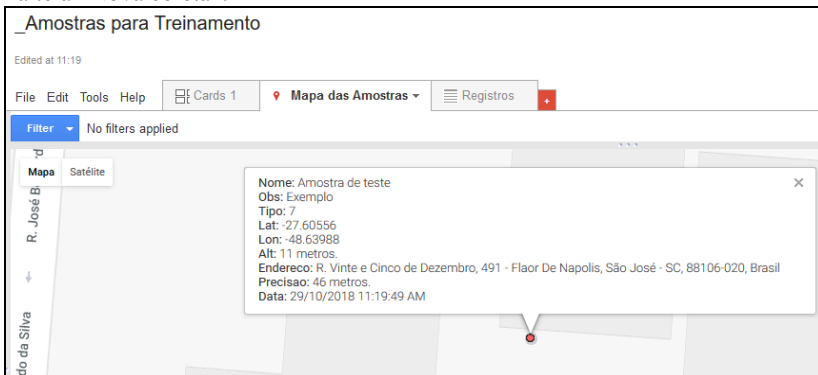
Figura 29 – Ferramenta Fusion Tables para armazenamento das informações obtidas em campo através do aplicativo.



Fonte: o autor, com uso da ferramenta Fusion Tables (GONZALEZ et al., 2010).

Por meio das abas “Cards 1”, “Mapa das Amostras” e “Registros”, é possível visualizar as informações em formato de cartões, pontos em um mapa e tabela de dados, respectivamente (Figura 30).

Figura 30 – Mapa das amostras com exemplo de ponto coletado através do aplicativo. Ficam associados à geometria todas as outras informações adquiridas na tela “Nova coleta”.



Fonte: o autor, com uso da ferramenta Fusion Tables (GONZALEZ et al., 2010).

Após uma análise qualitativa, as informações adicionadas à Fusion Tables são vinculadas automaticamente ao script de classificação no GEE, permitindo a inserção dos dados coletados pelo aplicativo.

5 CONSIDERAÇÕES FINAIS

A classificação automatizada de imagens proporciona a possibilidade de mensurar, conhecer e qualificar os tipos de uso e ocupação da terra existentes, principalmente em grandes extensões. No entanto, é uma tarefa complexa e que exige conhecimento técnico e uma base de imagens e amostras para treinamento qualificada. Dados sobre o uso e ocupação da terra são escassos, especialmente no âmbito da administração pública. O intuito dessa metodologia é proporcionar aos órgãos de governo e demais instituições uma ferramenta para a obtenção de classificações fidedignas e que proporcionem meios para a gestão ambiental de determinado local. As técnicas aqui propostas serão apresentadas ao IMA/SC, órgão responsável pela gestão ambiental do estado de Santa Catarina. Buscando o apoio de equipes com profissionais especialistas da instituição, hoje presentes em todo o estado, será possível aprimorar os dados ao longo do tempo, principalmente através do aplicativo proposto nesse trabalho e que subsidiará as classificações supervisionadas futuras.

Para realizar o teste da metodologia buscou-se a FOM por ocupar quase metade do estado e, também, por ser alvo de intensa degradação ambiental ao longo dos anos. A região de campo nativo foi alocada no tema “Outras classes” por possuir características e normatização específica. No entanto, não se vislumbram impedimentos para que a metodologia seja aplicada para estes alvos. Não menos importante, é sugerida a análise dos campos nativos existentes em Santa Catarina, em estudos futuros, considerando a vulnerabilidade deste ambiente também pela atividade antrópica.

Sugere-se, também como um estudo futuro, a classificação dos banhados por serem áreas de relevante interesse ecológico, esse tipo de ambiente figura entre os mais produtivos e importantes do mundo, com elevadas taxas de diversidade biológica e impacto ambiental (MELLER, 2011). Além disso, entende-se que a vegetação existente nesses ambientes, quando não sofreram intervenção antrópica, representam a máxima expressão possível da vegetação e se configuram, portanto, como primária de acordo com a legislação.

Índices de vegetação, de umidade e parâmetros texturais devem ser testados para que sejam aproveitadas, ao máximo, as ferramentas aqui apresentadas. Imagens de radar, como o Sentinel 1 também possuem potencial para a melhoria dos resultados.

Foi possível apresentar o potencial da computação em nuvem para o processamento de imagens em maior quantidade, resultando em uma menor necessidade de recursos computacionais.

O aplicativo móvel desempenhou importante papel na coleta das amostras de treinamento e possibilitará algumas vantagens importantes: a possibilidade de equipes utilizarem para a coleta em diferentes locais e concomitantemente, proporcionar agilidade na aquisição das informações referentes a uma amostra e a possibilidade de utilização no modo offline para o posterior envio a um banco de dados online. Salienta-se que cuidados em relação a acurácia posicional e distanciamento do alvo objeto de captura devem ser considerados no momento da aquisição do ponto, a fim de evitar dados que não representam a realidade em campo.

REFERÊNCIAS

- AGGARWAL, S. Principles of Remote Sensing. In: SIVAKUMAR, M. V. K. et al (Ed.). **Satellite Remote Sensing and GIS Applications in Agricultural Meteorology**. Genebra: Bishen Singh Mahendra Pal Singh, 2003. p. 23-38.
- ALBRECHT, L. P. et al. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Scientia Agraria**, v. 10, p. 191–198, 2009.
- ANDREONI, M. **An intrusion detection and prevention architecture for software defined networking**, 2014.
- ASNER, G. P. Geography of forest disturbance. **Proceedings of the National Academy of Sciences of the United States of America**, v. 110, n. 10, p. 3711–2, 5 mar. 2013.
- AZEVEDO, P. V. et al. Avaliação da reflectância e do saldo de radiação sobre um cultivo de videira europeia. 18 nov. 2013.
- BARBOSA, C. C. F. et al. Caracterização espectral das massas d'água amazônicas. Simpósio Brasileiro de Sensoriamento Remoto, v. 11, p. 2419-2425, 2003. Disponível em: <
https://www.researchgate.net/profile/Evlyn_Novo/publication/255637083_CHARACTERIZACAO_ESPECTRAL_DAS_MASSAS_D%27AGUA_AMAZONICAS/links/54804b690cf25b80dd70a31c/CARACTERIZACAO-ESPECTRAL-DAS-MASSAS-DAGUA-AMAZONICAS.pdf> Acesso em: 1 fev. 2019.
- BONTEMPS, S. et al. **Sentinel-2 for agriculture: Supporting global agriculture monitoring**. 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...IEEE**, jul. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7326748/>>. Acesso em: 2 out. 2018.
- 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, Disponível em: http://www.planalto.gov.br/ccivil_03/LEIS/L9985.htm. Acesso em: 01 fev. 2018.

BRASIL. **Lei nº 11.428, de 22 de dezembro de 2006.** Dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica, e dá outras providências. Brasília, Disponível em:

<http://www.planalto.gov.br/ccivil_03/_Ato2004-2006/2006/Lei/L11428.htm>. Acesso em: 01 fev. 2018.

BRASIL. Ministério do Meio Ambiente (MMA). Conselho Nacional do Meio Ambiente (CONAMA). **Resolução CONAMA nº 04, de 4 de maio de 1994.** Define vegetação primária e secundária nos estágios inicial, médio e avançado de regeneração da Mata Atlântica, a fim de orientar os procedimentos de licenciamento de atividades florestais no estado de Santa Catarina. Brasília, Disponível em: <

<http://www2.mma.gov.br/port/conama/legiabre.cfm?codlegi=145>>. Acesso em: 01 jan. 2018.

BRASIL. Ministério do Meio Ambiente (MMA). Conselho Nacional do Meio Ambiente (CONAMA). **Resolução CONAMA nº 10, de 1 de outubro de 1993.** Estabelece os parâmetros básicos para análise dos estágios de sucessão de Mata Atlântica. Brasília, Disponível em:

<<http://www2.mma.gov.br/port/conama/legiabre.cfm?codlegi=135>>. Acesso em: 01 jan. 2018.

BRASIL. Ministério do Meio Ambiente (MMA). Conselho Nacional do Meio Ambiente (CONAMA). **Resolução CONAMA nº 423, de 12 de abril de 2010.** Dispõe sobre parâmetros básicos para identificação e análise da vegetação primária e dos estágios sucessionais da vegetação secundária nos Campos de Altitude associados ou abrangidos pela Mata Atlântica.

Brasília, Disponível em: <

<http://www2.mma.gov.br/port/conama/legiabre.cfm?codlegi=628>>. Acesso em: 01 jan. 2018.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

CARDILLE, J. A.; BENNETT, E. M. Tropical teleconnections. **Nature Geoscience**, v. 3, n. 3, p. 154–155, 1 mar. 2010.

CLEVERS, J. G. P. W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344–351, 1 ago. 2013.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1 jul. 1991.

CORREIA, V. R. DE M. et al. Uma aplicação do sensoriamento remoto para a investigação de endemias urbanas. **Cadernos de Saúde Pública**, v. 23, n. 5, p. 1015–1028, maio 2007.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297, set. 1995.

CRUZ, C. B. M. et al. Classificação orientada a objetos no mapeamento dos remanescentes da cobertura vegetal do bioma Mata Atlântica, na escala 1:250.000. **Anais XIII Simposio Brasileiro de Sensoriamento remoto**, n. May 2014, p. 5691–5698, 2007.

DAINESE, R. C. [UNESP]. Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não supervisionada e análise visual. **Aleph**, p. 186 f. : il., 9 fev. 2001.

DELEGIDO, J. et al. Evaluation of Sentinel-2 Red-Edge Bands for Empirical Estimation of Green LAI and Chlorophyll Content. **Sensors**, v. 11, n. 7, p. 7063–7081, 8 jul. 2011.

DENG, S. et al. Comparison of Tree Species Classifications at the Individual Tree Level by Combining ALS Data and RGB Images Using Different Algorithms. **Remote Sensing**, v. 8, n. 12, p. 1034, 19 dez. 2016.

DÖRNHÖFER, K. et al. Water Constituents and Water Depth Retrieval from Sentinel-2^a - A First Evaluation in an Oligotrophic Lake. **Remote Sensing**, v. 8, n. 11, p. 941, 11 nov. 2016.

ESA. **Sentinel**. Disponível em:
<<https://sentinel.esa.int/web/sentinel/home>>. Acesso em: 2 set. 2018a.

ESA. **Level-1C Cloud Masks - Sentinel-2 MSI Technical Guide - Sentinel Online**. Disponível em:
<<https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/level-1c/cloud-masks>>. Acesso em: 5 maio. 2018b.

FERNANDES, A. T. et al. **Espetrorradiometria foliar na determinação de déficit hídrico em espécies de cerrado stricto sensu no Parque Nacional de Chapada dos Guimarães/MT**. 2015. Disponível em: <http://www.infoteca.inf.br/sbsr/smarty/templates/arquivos_template/upload_arquivos/acervo/docs/p1579.pdf>. Acesso em: 29 out. 2018.

FERNANDES, R. et al. **O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2**. 2009. Disponível em: <<http://glcf.umiacs.umd.edu/index.shtml>>. Acesso em: 2 out. 2018.

FLORENZANO, T.G. (2002) Imagens de satélite para estudos ambientais. São Paulo, Oficina de Textos.

FILHO, M. D. C.; MENESES, P. R.; SANO, E. E. Sistema de classificação de uso e cobertura da terra com base na análise de imagens de satélite. **Revista Brasileira de Cartografia**, v. 59, n. 2, p. 171–179, 2007.

FRAMPTON, W. J. et al. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 83–92, 1 ago. 2013.

FRANCISCO, C. N.; ALMEIDA, C. M. DE. Interpretação de imagens orbitais por meio de sistema especialista para o mapeamento de cobertura da terra em região montanhosa. **Sociedade & Natureza**, v. 24, p. 283–302, 2012.

GOMES, D. F. **Uso de imagens Sentinel-2 na identificação de áreas com infestação do capim-annoni-2 no Complexo Eólico Cerro Chato, Santana do Livramento, RS**. 2017.

GONZALEZ, H. et al. **Google fusion tables**. Proceedings of the 2010 international conference on Management of data - SIGMOD '10. **Anais...**New York, New York, USA: ACM Press, 2010. Disponível em: <<http://portal.acm.org/citation.cfm?doid=1807167.1807286>>. Acesso em: 5 out. 2018.

GOOGLE. **Google Cloud Platform: Sentinel-2 Data**. 2018. Disponível em: <<https://cloud.google.com/storage/docs/public-datasets/sentinel-2>>. Acesso em: 01 set. 2018a.

GOOGLE (Org.). **Cloud masking Sentinel 2**. 2018. Disponível em: <<https://groups.google.com/forum/#!msg/google-earth-engine-developers/i63DS-Dg8Sg/PJBEgSfYCgAJ>>. Acesso em: 10 jan. 2018b.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 1 dez. 2017.

IBGE. Biomas brasileiros. Disponível em: <<https://cnae.ibge.gov.br/images/7a12/mapas/Brasil/biomas.pdf>>. Acesso em: 01 dez. 2018.

IBGE. **Manual Técnico da Vegetação Brasileira**. 2. ed. Rio de Janeiro: IBGE, 2012.

IMMITZER, M. et al. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. **Remote Sensing**, v. 8, n. 3, p. 166, 23 fev. 2016.

KLAUBERG, C. et al. Florística e estrutura de um fragmento de Floresta Ombrófila Mista no Planalto Catarinense. **Biotemas**, v. 23, n. 1, p. 35–47, 26 abr. 2011.

KLEIN, R. M. Mapa fitogeográfico de Santa Catarina. Itajaí: Herbário Barbosa Rodrigues, 1978b.

KLEIN, R. M. Regiões Fitoecológicas. 1978a. Versão digitalizada pelo projeto IFFSC. Disponível em <www.iff.sc.gov.br>. Acesso em: 21 de jan. de 2019.

KUMAR, L. et al. Google Earth Engine Applications Since Inception: Usage, Trends, and Potential. **Remote Sensing**, v. 10, n. 10, p. 1509, 20 set. 2018.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159, mar. 1977.

LEDA, V. C. [UNESP]. **Modelagem da produtividade de cana-de-açúcar utilizando índices de vegetação**. [s.l.] Universidade Estadual Paulista (UNESP), 28 jul. 2016.

LI, M.; IM, J.; BEIER, C. Machine learning approaches for forest classification and change analysis using multi-temporal Landsat TM images over Huntington Wildlife Forest. **GIScience & Remote Sensing**, v. 50, n. 4, p. 361–384, 25 ago. 2013.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, n. 5, p. 823–870, mar. 2007.

LUCHIARI, A. Identificação da cobertura vegetal em áreas urbanas por meio de produtos de sensoriamento remoto e de um Sistema de Informação Geográfica. **Geography Department, University of Sao Paulo**, v. 14, p. 47–58, 2001.

MARTINELLI, G.; MORAES, M. A. Livro vermelho da flora do Brasil. ... **de Conservação da Flora, Rio de ...**, p. 1100, 2013.

MEDEIROS, J. DE D.; SAVI, M.; BRITO, B. F. A. DE. Seleção de áreas para criação de Unidades de Conservação na Floresta Ombrófila Mista. **Biotemas**, v. 18, n. 2, p. 33–50, 1 jan. 2005.

MELLER, J. Mapeamento de áreas úmidas e banhados na microbacia do rio Amandaú, região noroeste do Rio Grande do Sul. 19 abr. 2011.

MONTEIRO, F. P.; FRANCÊS, C. R. L.; SANTANA, Á. L. **ClasSIS: uma metodologia para classificação supervisionada de imagens de satélite em áreas de assentamento localizados na Amazônia**. 2015. 82 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal do Pará, Belém, 2015. Disponível em: <<http://ppgee.propesp.ufpa.br/ARQUIVOS/dissertacoes/FLAVIA%20PESSOA%20MONTEIRO.pdf>>. Acesso em: 01 nov. 2018.

MOORE, R. T.; HANSEN, M. C. Google Earth Engine: a new cloud-computing platform for global-scale earth observation data and analysis. **American Geophysical Union, Fall Meeting 2011, abstract id. IN43C-02**, 2011.

MORAES, E.C. **Fundamentos de Sensoriamento Remoto**, São José dos Campos, 2002.
Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMor aes.pdf>. Acesso em: 01 fev. 2019.

NASA. **Sentinel-2A Launches - Our Compliments & Our Complements** «**Landsat Science**. Disponível em: <<https://landsat.gsfc.nasa.gov/sentinel-2a-launches-our-compliments-our-complements/>>. Acesso em: 2 set. 2018.

NEMANI, R. et al. Collaborative Supercomputing for Global Change Science. **Eos, Transactions American Geophysical Union**, v. 92, n. 13, p. 109, 29 mar. 2011.

NG, W. et al. Assessing the Potential of Sentinel-2 and Pléiades Data for the Detection of *Prosopis* and *Vachellia* spp. in Kenya. **Remote Sensing**, v. 9, n. 1, p. 74, 16 jan. 2017.

NOVGORODOVA, Ganna. **Concerning the light. Remote sensing basics**. 2015. Disponível em: <<http://www.50northspatial.org/concerning-the-light/>>. Acesso em: 01 fev. 2018.

PATEL, N. N. et al. Multitemporal settlement and population mapping from Landsat using Google Earth Engine. **International Journal of Applied Earth Observation and Geoinformation**, v. 35, p. 199–208, 1 mar. 2015.

POKRESS, S. C.; VEIGA, J. J. D. MIT App Inventor: Enabling Personal Mobile Computing. 7 out. 2013.

PONZONI, F. J. Aplicação do modelo Sail no estudo da reflectancia espectral de dosseis de mudas de eucalyptus Sp. e de aspidosperma Sp. 1993.

PRABHAKAR, M.; PRASAD, Y. G.; RAO, M. N. Remote Sensing of Biotic Stress in Crop Plants and Its Applications for Pest Management. In: **Crop Stress and its Management: Perspectives and Strategies**. Dordrecht: Springer Netherlands, 2012. p. 517–545.

RAVANELLI, R. et al. Monitoring the Impact of Land Cover Change on Surface Urban Heat Island through Google Earth Engine: Proposal of a Global Methodology, First Applications and Problems. **Remote Sensing**, v. 10, n. 9, p. 1488, 18 set. 2018.

ROSÁRIO, L. S. DO et al. Análise Orientada a Objeto no Mapeamento dos Estágios Sucessionais da Vegetação na Escala 1: 25.000 - Um Estudo de Caso da Rebio União, RJ. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, p. 7119–7126, 25 abr. 2009.

ROY, D. P. et al. Web-enabled Landsat Data (WELD): Landsat ETM+ composited mosaics of the conterminous United States. **Remote Sensing of Environment**, v. 114, n. 1, p. 35–49, 15 jan. 2010.

RUIZ, L. F. C.; CATEN, A. TEN; DALMOLIN, R. S. D. Árvore de decisão e a densidade mínima de amostras no mapeamento da cobertura da terra. **Ciência Rural**, v. 44, n. 6, p. 1001–1007, jun. 2014.

SAMIZAVA, T. M. SIG e sensoriamento remoto aplicado ao estudo dos processos de inundação e mapeamento da cobertura vegetal na planície fluvial do alto Rio Paraná. 2009.

SANTOS, A. L. C. Diagnóstico dos fragmentos de mata atlântica de Sergipe através de sensoriamento remoto. 15 abr. 2009.

SANTOS, L.; LIMA, P. Comparação entre diferentes algoritmos de classificação supervisionada no mapeamento temático de uma bacia hidrográfica. **TreeDimensional**, v. 3, n. 5, 9 jun. 2018.

SIMINSKI, A.; FANTINI, A. C.; REIS, M. S. Classificação da vegetação secundária em estágios de regeneração da Mata Atlântica em Santa Catarina. **Ciência Florestal**, v. 23, n. 3, 30 ago. 2013.

SOLARI, R. A. F. Aplicação de métodos de classificação supervisionada em imagens do Sentinel-2, como suporte ao cadastro ambiental rural. 2017. 150 f., il. Dissertação (Mestrado em Ciências Ambientais)—Universidade de Brasília, Brasília, 2017.

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 Data to Map Successional Forest Stages in a Subtropical Forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, p. 838, 13 ago. 2017.

SOUSA, B. F. S. et al. **Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma caatinga**. Revista Brasileira de Cartografia, Rio de Janeiro, v. 2, n. 62, p. 385-399, 2010. Disponível em: <<http://lsie.unb.br/rbc/index.php/rbc/article/view/501/527>>. Acesso em: 01 fev. 2019.

VELOSO, H. P. et al. **Classificação da vegetação brasileira, adaptada a um sistema universal**. [s.l.] Ministério da Economia, Fazenda e Planejamento, Fundação Instituto Brasileiro de Geografia e Estatística, Diretoria de Geociências, Departamento de Recursos Naturais e Estudos Ambientais, 1991.

VERIKAS, A. et al. Electromyographic Patterns during Golf Swing: Activation Sequence Profiling and Prediction of Shot Effectiveness. **Sensors**, v. 16, n. 4, p. 592, 23 abr. 2016.

VERRELST, J. et al. Machine learning regression algorithms for biophysical parameter retrieval: Opportunities for Sentinel-2 and -3. **Remote Sensing of Environment**, v. 118, p. 127–139, 15 mar. 2012.

VIBRANS, A. C. et al. Inventário florístico florestal de Santa Catarina (IFFSC): aspectos metodológicos e operacionais. **Pesquisa Florestal Brasileira**, Colombo, v. 30, n. 64, p. 291, ago. 2010. ISSN 1983-2605. Disponível em:
<<https://pfb.cnpf.embrapa.br/pfb/index.php/pfb/article/view/96/141>>. Acesso em: 30 set. 2018.

VIBRANS, A. C. et al. **Inventário Florístico Florestal de Santa Catarina**: Resultados Resumidos. Blumenau: Universidade Regional de Blumenau, 2013. 37 p. Disponível em:
<http://ciram.epagri.sc.gov.br/ciram_arquivos/arquivos/iff/pdf/resultadosresumidosiff2013.pdf>. Acesso em: 01 maio 2018.

VUOLO, F. et al. How much does multi-temporal Sentinel-2 data improve crop type classification? **International Journal of Applied Earth Observation and Geoinformation**, v. 72, p. 122–130, 1 out. 2018.

WHYTE, A.; FERENTINOS, K. P.; PETROPOULOS, G. P. A new synergistic approach for monitoring wetlands using Sentinels -1 and 2 data with object-based machine learning algorithms. **Environmental Modelling & Software**, v. 104, p. 40–54, 1 jun. 2018.

ZHANG, Y.; GUINDON, B.; CIHLAR, J. An image transform to characterize and compensate for spatial variations in thin cloud contamination of Landsat images. **Remote Sensing of Environment**, v. 82, n. 2–3, p. 173–187, 1 out. 2002.

ZHOU, Q. et al. Design and Implementation of Foot-Mounted Inertial Sensor Based Wearable Electronic Device for Game Play Application. **Sensors**, v. 16, n. 10, p. 1752, 21 out. 2016.

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, p. 83–94, 15 mar. 2012.

APÊNDICE A – Script Mosaico

Apêndice A – Script com a rotina construída para a geração do mosaico S-2.

Este código está disponível a partir do repositório do GEE:

http://bit.ly/codigos_gee para clonagem e listagem de alterações (logs).

/* INFORMAÇÕES GERAIS SOBRE O SCRIPT

1. Todas as linhas que iniciam com //, são utilizadas para comentários e informações relacionadas ao código. Elas sempre aparecerão na cor verde. Em alguns casos, podem representar uma linha desabilitada.

2. As linhas comentadas com o título no formato
// -----
// Texto
// -----
indicam uma seção/tópico específico do código e representa a função ou descrição do script.

3. Ao executar o código, o painel "Console" do GEE apresentará todas as informações requisitadas pela função "print". O painel "Tasks" do GEE possibilitará o download da imagem.

4. Linhas customizáveis
Algumas linhas podem ser customizadas no script para que seja possível a configuração de parâmetros. A seguir, são descritas as funções de cada uma:

- Linhas 168 ou 169 - configure o centro (em graus decimais) da visualização inicial do mapa e a sua escala.
- Linhas com o termo "scale" - o parâmetro "scale" define a escala de um determinado resultado.
- Linhas com o termo "print" - é possível habilitar ou não informações a serem mostradas no Console do GEE
- Linhas com o termo "region": é possível definir uma região específica para a obtenção de dados da análise ou desabilitar a

```

linha para que o parâmetro padrão seja utilizado.
*/

// -----
// Customização do mapa de fundo
// -----

// Configurar a imagem de satélite do Google como
padrão e criar novo mapa de fundo.
var styles = {
  'Soft': [
    {
      featureType: 'all',
      stylers: [
        { saturation: -80 }
      ]
    }, {
      featureType: 'road.arterial',
      elementType: 'geometry',
      stylers: [
        { hue: '#00ffee' },
        { saturation: 50 }
      ]
    }, {
      featureType: 'poi.business',
      elementType: 'labels',
      stylers: [
        { visibility: 'off' }
      ]
    }
  ]
};
Map.setOptions('satellite', styles);

// -----
// Seleção das imagens e definição dos parâmetros
para a formação do mosaico
// -----

/* Código para construção de mosaicos sem nuvens e
sombras, considerando um
determinado período de aquisição.
Quanto maior o intervalo entre datas, maior a

```


possibilidade de se encontrar uma imagem sem nuvens/sombra para substituir regiões com nuvem/sombra. As datas podem ser alteradas nas linhas 134 e 135. A camada que delimita o mosaico pode ser alterada na linha 133. Partes do código foram produzidas por outros membros da comunidade GGE ao redor do mundo. Construíram parte do código os desenvolvedores da comunidade internacional Gennadii Donchyts, Nick Clinton e Sam Murphy*/

```
// Substituição das nuvens e sombras por outras
imagens do acervo:
function sentinel2toa(img) {
  var toa =
img.select(['B1','B2','B3','B4','B5','B6','B8A','B9
','B10','B11','B12'],
           ['aerosol_B1','blue_B2',
'green_B3',
'red_B4','red1_B5','red2_B6','red4_B8A','h2o_B9',
'cirrus_B10','swirl_B11','swir2_B12'])
           .divide(10000)

.addBands(img.select(['QA60']))

.set('solar_azimuth',img.get('MEAN_SOLAR_AZIMUTH_ANG
LE'))

.set('solar_zenith',img.get('MEAN_SOLAR_ZENITH_ANGL
E'))
  return toa
}

function ESAcloud(toa) {

var qa = toa.select('QA60');

// B10 and 11 são nuvens e cirrus, respectivamente.
var cloudBitMask = Math.pow(2, 10);
var cirrusBitMask = Math.pow(2, 11);
```

```

// Considera nuvem se ambos forem "0".
var clear = qa.bitwiseAnd(cloudBitMask).eq(0).and(
    qa.bitwiseAnd(cirrusBitMask).eq(0));
var cloud = clear.eq(0)
    return cloud
}

function shadowMask(toa,cloud){
// Geometria solar com base nos metadados das
imagens (radians):
    var azimuth =
ee.Number(toa.get('solar_azimuth')).multiply(Math.P
I).divide(180.0).add(ee.Number(0.5).multiply(Math.P
I));
    var zenith =
ee.Number(0.5).multiply(Math.PI).subtract(ee.Number
(toa.get('solar_zenith')).multiply(Math.PI).divide(
180.0));

// Estima onde as sombras de nuvens estão, com base
na geometria do sol:
    var nominalScale =
cloud.projection().nominalScale();
    var cloudHeights =
ee.List.sequence(200,10000,500);
    var shadows =
cloudHeights.map(function(cloudHeight){
    cloudHeight = ee.Number(cloudHeight);
    var shadowVector =
zenith.tan().multiply(cloudHeight);
    var x =
azimuth.cos().multiply(shadowVector).divide(nominal
Scale).round();
    var y =
azimuth.sin().multiply(shadowVector).divide(nominal
Scale).round();
    return cloud.changeProj(cloud.projection(),
cloud.projection().translate(x, y));
});
    var potentialShadow =
ee.ImageCollection.fromImages(shadows).max();

//Detecção de pixels escuros:

```

```

    var darkPixels =
toa.normalizedDifference(['green_B3',
'swir2_B12']).gt(0.25).rename(['dark_pixels']);

// Os potenciais pixels de sombra são escuros:
    var shadow =
potentialShadow.and(darkPixels).rename('shadows');
    return shadow
}

function cloud_and_shadow_mask(img) {
    var toa = sentinel2toa(img);
    var cloud = ESAcloud(toa);
    var shadow = shadowMask(toa,cloud);
    var mask = cloud.or(shadow).eq(0);
    return toa.updateMask(mask);
}

//Inserção dos parâmetros do usuário:
    var ombrofilaMista =
ee.FeatureCollection("ft:14IVbSmF8rt6CgSLocydpuWyDL
2cU_bcje74QXImW");
    var startDate = ee.Date('2017-01-01')
    var stopDate = ee.Date('2018-10-19')
    var images = ee.ImageCollection('COPERNICUS/S2')
        .filterBounds(ombrofilaMista)
        .filterDate(startDate, stopDate)
    var masked_images =
images.map(cloud_and_shadow_mask)
    var median = masked_images.median()
    var clip = median.clipToCollection
(ombrofilaMista);

// -----
//  Inserção das camadas amostradas em campo e
//  retiradas do IFFSC ()
// -----

var amostras = ee.FeatureCollection('ft:1iA1I_schx-
kCywaQXaclrXYW0NymR-10g3ewBLdc')
var medio = (amostras)
    .filter(ee.Filter.eq("Estagio", "MEDIO"));

```

```

var inicial = (amostras)
    .filter(ee.Filter.eq("Estagio", "INICIAL"));

// -----
// -----
// Mostrar no Console os parâmetros e o número de
// imagens utilizadas para a constituição do mosaico.
// -----
// -----

print('Parâmetros do mosaico gerado: ', clip);
print('Número de imagens utilizadas: ', images);

// -----
// Configuração da visão inicial do mapa
// -----

//Centralizar a visualização inicial em um ponto e
//zoom específicos:
Map.setCenter(-51.3,-27.5,7); //Visão geral
//Map.setCenter(-50.130615234375,-
27.756659183807788,13); //Outra visualização

// -----
// Seleção das imagens e definição dos parâmetros
// de visualização
// -----

//Parâmetros para a visualização da composição
//colorida:
Map.addLayer(clip,{bands:['red_B4','green_B3','blue
_B2'], min:0.03, max:0.20495},'Mosaico', false)

// Adicionar uma barra de título:
Map.add(ui.Label(
    'Ferramenta Mosaico Sentinel 2', {fontWeight:
'bold', fontSize: '24px'}));

// -----
// Exportação do mosaico

```

```
// -----  
// Exportação padrão configurada para asset e  
// envolvendo a visualização atual do mapa.  
// As configurações podem ser alteradas na janela  
// de exportação:  
  
Export.image.toAsset({  
  image: clip,  
  description: '010117_191018_30m',  
  assetId: 'mosaic_010117_191018_10m_S2',  
  scale: 30,  
  maxPixels: 1e13,  
  //region: fom //sem considerar a região o GEE  
  adotará a parte visível como imagem a ser  
  exportada.  
});
```

APÊNDICE B – Script Mosaico em Múltiplas Telas

Apêndice B – Script com a rotina construída para a geração do mosaico S-2 com o arranjo em múltiplas telas. Este código está disponível a partir do repositório do GEE: http://bit.ly/codigos_gee para clonagem e listagem de alterações (logs).

```
/* INFORMAÇÕES GERAIS SOBRE O SCRIPT
```

1. Todas as linhas que iniciam com //, são utilizadas para comentários e informações relacionadas ao código. Elas sempre aparecerão na cor verde. Em alguns casos, podem representar uma linha desabilitada.

2. As linhas comentadas com o título no formato

```
// -----  
// Texto  
// -----
```

 indicam uma seção/tópico específico do código e representa a função ou descrição do script.

3. Ao executar o código, o painel "Console" do GEE apresentará todas as informações requisitadas pela função "print". O painel "Tasks" do GEE possibilitará o download da imagem.

4. Linhas customizáveis
 Algumas linhas podem ser customizadas no script para que seja possível a configuração de parâmetros. A seguir, são descritas as funções de cada uma:

- Linha 210 - configure o centro (em graus decimais) da visualização inicial do mapa e a sua escala.
- Linhas com o termo "scale" - o parâmetro "scale" define a escala de um determinado resultado.
- Linhas com o termo "print" - é possível habilitar ou não informações a serem mostradas no Console do GEE
- Linhas com o termo "region": é possível definir uma região específica para a

```

    obtenção de dados da análise ou desabilitar a
    linha para que o parâmetro padrão seja utilizado.
    */

// -----
// Customização do mapa de fundo
// -----

// Configurar a imagem de satélite do Google como
// padrão e criar novo mapa de fundo.
var styles = {
  'Soft': [
    {
      featureType: 'all',
      stylers: [
        { saturation: -80 }
      ]
    },{
      featureType: 'road.arterial',
      elementType: 'geometry',
      stylers: [
        { hue: '#00ffee' },
        { saturation: 50 }
      ]
    },{
      featureType: 'poi.business',
      elementType: 'labels',
      stylers: [
        { visibility: 'off' }
      ]
    }
  ]
};
Map.setOptions('satellite', styles);

// -----
// Seleção das imagens e definição dos parâmetros
// para a formação do mosaico
// -----

/* Código para construção de mosaicos sem nuvens e
sombras, considerando um
determinado período de aquisição.

```

Quanto maior o intervalo entre datas, maior a possibilidade de se encontrar uma imagem sem nuvens/sombra para substituir regiões com nuvem/sombra.

As datas podem ser alteradas nas linhas 134 e 135.

A camada que delimita o

mosaico pode ser alterada na linha 133.

Partes do código foram produzidas por outros membros da comunidade GGE ao redor do mundo.

Construíram parte do código os desenvolvedores da comunidade internacional Gennadii Donchyts, Nick Clinton e Sam Murphy*/

```
// Substituição das nuvens e sombras por outras
imagens do acervo:
function sentinel2toa(img) {
  var toa =
img.select(['B1','B2','B3','B4','B5','B6','B8A','B9
','B10','B11','B12'],
           ['aerosol_B1','blue_B2',
'green_B3',
'red_B4','red1_B5','red2_B6','red4_B8A','h2o_B9',
'cirrus_B10','swirl_B11','swirl2_B12'])
           .divide(10000)

.addBands(img.select(['QA60']))

.set('solar_azimuth',img.get('MEAN_SOLAR_AZIMUTH_ANG
LE'))

.set('solar_zenith',img.get('MEAN_SOLAR_ZENITH_ANGL
E'))
  return toa
}

function ESAcloud(toa) {

var qa = toa.select('QA60');

// B10 and 11 são nuvens e cirrus, respectivamente.
var cloudBitMask = Math.pow(2, 10);
var cirrusBitMask = Math.pow(2, 11);
```



```

// Considera nuvem se ambos forem "0".
var clear = qa.bitwiseAnd(cloudBitMask).eq(0).and(
    qa.bitwiseAnd(cirrusBitMask).eq(0));
var cloud = clear.eq(0)
    return cloud
}

function shadowMask(toa,cloud){
// Geometria solar com base nos metadados das
imagens (radians):
    var azimuth =
ee.Number(toa.get('solar_azimuth')).multiply(Math.P
I).divide(180.0).add(ee.Number(0.5).multiply(Math.P
I));
    var zenith =
ee.Number(0.5).multiply(Math.PI).subtract(ee.Number
(toa.get('solar_zenith')).multiply(Math.PI).divide(
180.0));

// Estima onde as sombras de nuvens estão, com base
na geometria do sol:
    var nominalScale =
cloud.projection().nominalScale();
    var cloudHeights =
ee.List.sequence(200,10000,500);
    var shadows =
cloudHeights.map(function(cloudHeight){
    cloudHeight = ee.Number(cloudHeight);
    var shadowVector =
zenith.tan().multiply(cloudHeight);
    var x =
azimuth.cos().multiply(shadowVector).divide(nominal
Scale).round();
    var y =
azimuth.sin().multiply(shadowVector).divide(nominal
Scale).round();
    return cloud.changeProj(cloud.projection(),
cloud.projection().translate(x, y));
});
    var potentialShadow =
ee.ImageCollection.fromImages(shadows).max();

```

```

//Detecção de pixels escuros:
var darkPixels =
toa.normalizedDifference(['green_B3',
'swir2_B12']).gt(0.25).rename(['dark_pixels']);

// Os potenciais pixels de sombra são escuros:
var shadow =
potentialShadow.and(darkPixels).rename('shadows');
return shadow
}

function cloud_and_shadow_mask(img) {
var toa = sentinel2toa(img);
var cloud = ESAcloud(toa);
var shadow = shadowMask(toa,cloud);
var mask = cloud.or(shadow).eq(0);
return toa.updateMask(mask);
}

//Inserção dos parâmetros do usuário:
var ombrofilaMista =
ee.FeatureCollection("ft:14IVbSmF8rt6CgSLocydpuWyDL
2cU_bcje74QXImW");
var startDate = ee.Date('2017-01-01')
var stopDate = ee.Date('2018-10-19')
var images = ee.ImageCollection('COPERNICUS/S2')
//
.filterBounds(ombrofilaMista)
.filterDate(startDate, stopDate)
var masked_images =
images.map(cloud_and_shadow_mask)
var median = masked_images.median()
var clip = median.clipToCollection
(ombrofilaMista);

// -----
// Inserção das camadas amostradas em campo e
// retiradas do IFFSC ()
// -----

var amostras = ee.FeatureCollection('ft:1iA1I_schx-
kCywaQXaclrXYW0NymR-10g3ewBLdc')

```

```

var medio = (amostras)
    .filter(ee.Filter.eq("Estagio", "MEDIO"));
var inicial = (amostras)
    .filter(ee.Filter.eq("Estagio", "INICIAL"));

// -----
// -----
//  Mostrar no Console os parâmetros e o número de
//  imagens utilizadas para a constituição do mosaico.
//  -----
// -----

print('Parâmetros do mosaico gerado: ', clip);
print('Número de imagens utilizadas: ', images);

// -----
// -----
//  Criação da visualização múltipla
//  -----
// -----

// Cada uma dos mapas possui um nome e parâmetro de
// visualização. Eles podem ser alterados de acordo
// com a demanda.
var MAP_PARAMS = {
  'Coréis Naturais (B4/B3/B2)': ['red_B4',
  'green_B3', 'blue_B2'],
  'Solo/Água (B8/B11/B4)': ['red4_B8A',
  'swirl_B11', 'red_B4'],
  'Infravermelho (B8/B4/B3)': ['red4_B8A',
  'red_B4', 'green_B3'],
  'Vegetação (B12/B11/B4)': ['swir2_B12',
  'swir2_B12', 'red_B4']
};

// Parâmetro de visualização compartilhado entre as
// imagens. Para contrastes diferentes, altere
// "gamma", "min" e "max":
function getVisualization(bands) {
  return {gamma: 1.3, min: 0, max: 0.3, bands:
bands};
}

```

```

}

// Criar uma mapa para cada opção de visualização:
var maps = [];
Object.keys(MAP_PARAMS).forEach(function(name) {
    var map = ui.Map();
    map.add(ui.Label(name));
    map.addLayer(clip,
getVisualization(MAP_PARAMS[name]), name);
    map.setControlVisibility(false);
    maps.push(map);
});

var linker = ui.Map.Linker(maps);

// Habilitar o zoom no canto esquerdo superior
(maps 0):
maps[0].setControlVisibility({zoomControl: true});

// Habilitar a escala (maps 3):
maps[3].setControlVisibility({scaleControl: true});

// Habilitar a opção de tela cheia (maps 2)
maps[2].setControlVisibility({fullscreenControl:
true});

// Criar a grade de mapas:
var mapGrid = ui.Panel(
    [
        ui.Panel([maps[0], maps[1]], null, {stretch:
'both'}),
        ui.Panel([maps[2], maps[3]], null, {stretch:
'both'})
    ],
    ui.Panel.Layout.Flow('horizontal'), {stretch:
'both'});

// Centralizar o mapa em uma escala e coordenada
pré-definidas:
maps[0].setCenter(-51.3,-27.5,7);

// Criar um título para o mapa:
var title = ui.Label('Sentinel 2', {

```

```

    stretch: 'horizontal',
    textAlign: 'center',
    fontWeight: 'bold',
    fontSize: '24px'
  });

  // Adicionar os mapas e o título à ui.root.
  ui.root.widgets().reset([title, mapGrid]);
  ui.root.setLayout(ui.Panel.Layout.Flow('vertical'))
  ;

  // -----
  //  Exportação do mosaico
  // -----
  // Exportação padrão configurada para asset e
  // envolvendo a visualização atual do mapa.
  // As configurações podem ser alteradas na janela
  // de exportação:

  Export.image.toAsset({
    image: clip,
    description: '010117_191018_30m',
    assetId: 'mosaic_010117_191018_10m_S2',
    scale: 30,
    maxPixels: 1e13,
    //region: fom //sem considerar a região o GEE
    adotará a parte visível como imagem a ser
    exportada.
  });

```

APÊNDICE C – Script Classificação SVM e RF

Apêndice C – Script com a rotina elaborada para a geração da classificação com SVM ou RF. Este código está disponível a partir do repositório do GEE: http://bit.ly/codigos_gee para clonagem e listagem de alterações (logs).

/* INFORMAÇÕES GERAIS SOBRE O SCRIPT

1. Todas as linhas que iniciam com //, são utilizadas para comentários e informações relacionadas ao código. Elas sempre aparecerão na cor verde. Em alguns casos, podem representar uma linha desabilitada.

2. As linhas comentadas com o título no formato
 // -----
 // Texto
 // -----

indicam uma seção/tópico específico do código e representa a função ou descrição do script.

3. Ao executar o código, o painel "Console" do GEE apresentará todas as informações requisitadas pela função "print". O painel "Tasks" do GEE possibilitará o download da imagem classificada e, também, de uma tabela dos coeficientes de concordância obtidos.

4. Linhas customizáveis
 Algumas linhas podem ser customizadas no script para que seja possível a configuração de parâmetros. A seguir, são descritas as funções de cada uma:

- Linha 78 - configure o centro (em graus decimais) da visualização inicial do mapa e a sua escala.

- Linha 104 - permite a adição e configuração da imagem utilizada para a classificação.

- Linhas com o termo "scale" - o parâmetro "scale" define a escala de um determinado resultado.
- Linhas com o termo "print" - é possível habilitar ou não informações a serem mostradas no Console do GEE
- Itens a1, a2, b1 e b2 - permitem alternar entre os algoritmos classificadores. a1 e a2 sempre estarão habilitados enquanto b1 e b2 estarão desabilitados. E vice-versa. Utilize barras para desabilitar.
- Linha 164 - permite definir o percentual das amostras que serão utilizadas para a classificação. Se 0.7, 70% das amostras serão utilizadas na classificação e 30% na verificação da precisão.
- Linhas com os termos "geometry" ou "region" - é possível definir uma região específica para a obtenção de dados da análise ou desabilitar a linha para que o parâmetro padrão seja utilizado.
- A variável clip está vinculada à imagem (mosaico) a ser utilizada na classificação. Portanto, certifique-se em relação ao conteúdo desta variável. Também é possível alterá-la.

```
*/
```

```
// -----  
// Customização do mapa de fundo  
// -----
```

```
// Configurar a imagem de satélite do Google como  
padrão e criar novo mapa de fundo.
```

```
var styles = {  
  'Soft': [  
    {  
      featureType: 'all',  
      stylers: [  
        { saturation: -80 }  
      ]  
    },  
    {  
      featureType: 'road.arterial',  
      elementType: 'geometry',
```

```

        stylers: [
            { hue: '#00ffee' },
            { saturation: 50 }
        ]
    }, {
        featureType: 'poi.business',
        elementType: 'labels',
        stylers: [
            { visibility: 'off' }
        ]
    }
]
};

Map.setOptions('satellite', styles);

//Centralizar a visualização inicial em um ponto e
zoom específicos:
Map.setCenter(-51.3,-27.5,7); // Visão inicial do
mapa

// -----
// Parâmetros para a visualização da composição
colorida e título do mapa
// -----

// Adicionar a composição com configurações pré-
definidas:
Map.addLayer(clip,{bands:['red_B4','green_B3','blue
_B2'], min:0.03, max:0.20495},'Mosaico', false)

// Adicionar uma barra de título:
Map.add(ui.Label(
    'Classificação Sentinel 2 - SVM e RF',
    {fontWeight: 'bold', fontSize: '24px'}));

// -----
// Classificação
// -----

// Juntar todas as amostras de treinamento:

```



```

var sample =
ini.merge(hidrografia).merge(med).merge(ava).merge(
silvicultura).merge(nao_class);
//print('Detalhes das amostras: ', sample);

// Seleção das bandas a serem utilizadas na
classificação:
var bandas_class = ['blue_B2', 'green_B3',
'red_B4','red1_B5','red2_B6','red4_B8A','h2o_B9',
'cirrus_B10','swirl_B11', 'swir2_B12'];

// Buscar o mosaico recortado, contemplando as
bandas escolhidas para classificação
(bandas_class):
var mosaico = clip.select(bandas_class);

//Treinar o classificador:
var treinamento = mosaico.sampleRegions({
collection: sample,
properties: ['class'],
scale: 30
});

// -----
// Defina aqui o classificador a ser utilizado.
// Para utilizar o classificador SVM, mantenha
habilitados os itens a1 e a2.
// Para utilizar o RF, mantenha habilitados os
itens b1 e b2.
// -----

//a1. Definir como classificador o SVM, escolhendo
os parâmetros "gamma" e "cost":
//var classificacao = ee.Classifier.svm({
//  kernelType: 'RBF',
//  gamma: 2.0,
//  cost: 200
//})

//a2. Definir o classificador para aferição dos
dados treinados (SVM):
//var classificadorTreinado = ee.Classifier.svm({

```

```

//     kernelType: 'RBF',
//     gamma: 2.0,
//     cost: 200
//})

//b2. Definir como classificador para a aferição
dos dados treinados (RF):
var classificacao = ee.Classifier.randomForest(100)

//b1. Definir como classificador o RF, escolhendo o
parâmetro de número de árvores:
var classificadorTreinado =
ee.Classifier.randomForest(100)

// -----
// Treinamento do classificador escolhido
// -----

// Treinar o classificador escolhido, usando as
amostras de treinamento:
var fullClassifier = classificacao.train({
    features: treinamento,
    classProperty: 'class',
    inputProperties: bandas_class
});

//Classificação da imagen:
var classificacao_final =
mosaico.classify(fullClassifier);

// -----
// Verificação do desempenho do classificador
// -----

//Teste do classificador:
var randomizacao =
treinamento.randomColumn('random');

// Segregar 70% para treinar a classificação e 30%
para testar a acurácia do classificador.
var divisao = 0.7;

```

```

var fracaoClassificacao =
  randomizacao.filter(ee.Filter.lt('random',
  divisao));
var fracaoTestar =
  randomizacao.filter(ee.Filter.gte('random',
  divisao));

// Treinar o classificador escolhido, usando 30%
das amostras:
var fullTrained = classificadorTreinado.train({
  features: fracaoClassificacao,
  classProperty: 'class',
  inputProperties: bandas_class
});

// Classificar o verificador de desempenho:
var testar = fracaoTestar.classify(fullTrained);

// -----
// Parâmetros de precisão - Obtenção dos
Coeficientes de Concordância
// -----

// Mostrar os coeficientes de concordância no
console.
var confusionMatrix = testar.errorMatrix('class',
'classification');
print('Matriz de Erro da Validação:',
confusionMatrix);
print('Precisão global:',
confusionMatrix.accuracy());
print('Coeficiente Kappa:',
confusionMatrix.kappa());
print('Precisão do utilizador:',
confusionMatrix.consumersAccuracy());
print('Precisão do produtor:',
confusionMatrix.producersAccuracy());

// Exportar uma tabela com as informações da Matriz
de Erro:
var table = ee.FeatureCollection([
  ee.Feature(null, {

```

```

        'Matriz_de_Confusao':
confusionMatrix.array(),
        'Precisao_Global':
confusionMatrix.accuracy(),
        'Coeficiente_Kappa':
confusionMatrix.kappa(),
        'Precisao_do_utilizador':
confusionMatrix.consumersAccuracy(),
        'Precisão_do_produtores':
confusionMatrix.producersAccuracy()
    })
}
Export.table(table, 'Exportar coeficientes de
concordância', {fileFormat: 'JSON'});

```

```

// -----
// Inserir a legenda no mapa
// -----

```

```

// Posição:
var legend = ui.Panel({
  style: {
    position: 'bottom-left',
    padding: '20px 30px'
  }
});

```

```

// Criar título:
var legendTitle = ui.Label({
  value: 'Legenda',
  style: {
    fontWeight: 'bold',
    fontSize: '18px',
    margin: '0 0 4px 0',
    padding: '0'
  }
});

```

```

// Adicionar o título ao painel:
legend.add(legendTitle);

```

```

// Criar e estilizar a linha 1 da legenda:

```

```

var makeRow = function(color, name) {

// Criar a caixa colorida:
var colorBox = ui.Label({
  style: {
    backgroundColor: '#' + color,
    // Use padding to give the box height
and width.
    padding: '8px',
    margin: '0 0 4px 0'
  }
});

// Criar a descrição da classe:
var description = ui.Label({
  value: name,
  style: {margin: '0 0 4px 6px'}
});

// Resultar no painel:
return ui.Panel({
  widgets: [colorBox, description],
  layout:
ui.Panel.Layout.Flow('horizontal')
});

};

// Paleta de cores:
var palette =['98ff00', 'b9b312', 'ff1010',
'12c281', 'e6e6e6', '0c1eff'];

// Nomes da legenda:
var names =
['Inicial', 'Médio', 'Avançado', 'Silvicultura', 'Outra
s Classes', 'Hidrografia'];

// Adicionar as cores e os nomes:
for (var i = 0; i < 6; i++) {
  legend.add(makeRow(palette[i], names[i]));
}

Map.add(legend);

```

```

// -----
// Camadas complementares
// -----

//Map.addLayer(amostras, {}, 'Amostras', false);
//Map.addLayer(medio.draw({color: '#FFFF00',
strokeWidth: 6}), {}, 'Médio', false);
//Map.addLayer(inicial.draw({color: '#00BFFF',
strokeWidth: 6}), {}, 'Inicial', false);
//Map.addLayer(iffsc.draw({color: 'FF0000',
strokeWidth: 6}), {}, 'IFFSC', false);
Map.addLayer(fom.draw({color: 'FF0000',
strokeWidth: 1}), {}, 'FOM', false);

// -----
// Adição da camada classificada no mapa
// -----

// Parâmetros de visualização da classificação:
Map.addLayer(classificacao_final, {min: 1, max: 6,
palette:palette}, 'Classificação');

// -----
// Estatísticas da imagem classificada
// -----

// Informações, em percentual, das áreas
classificadas em uma determinada região
(certifique-se
// sobre a escala e a geometry):

var qtidade = classificacao_final.reduceRegion({
reducer:ee.Reducer.frequencyHistogram(),
geometry:area_personalizada,
//#CONFIGURE A ÁREA A SER ANALISADA.
scale:100 //#CONFIGURE O TAMANHO DOS
PIXELS (EM METROS) A SEREM ANALISADOS.
});
var dict =

```

```

ee.Dictionary(qtdade.get('classification'));
var soma =
ee.Array(dict.values()).reduce(ee.Reducer.sum(), [0]
).get([0]);
var new_dict = dict.map(function(k,v) {
  return ee.Number(v).divide(soma).multiply(100);
});
print('Classes (%)', new_dict, 'Considerere:', ' 0
= Estágio Inicial,', ' 1 = Estágio Médio,', ' 2
= Estágio Avançado', ' 3 = Silvicultura', ' 4 =
Outras Classes', ' 5 = Hidrografia');

// Gráficos:

//Configuração do gráfico "Contagem de Pixels por
Classe":
var opcoes = {
title: 'Contagem de Pixels por Classe',
  hAxis: {title: 'Classes'},
  vAxis: {title: 'Número de Pixels'},
  lineWidth: 1,
  pointSize: 4,
  //fontSize: 20, //#CONFIGURE O TAMANHO DA FONTE A
SER EXIBIDA NO GRÁFICO.
  series: {
    0: {color: '98ff00'}, // Inicial
    1: {color: 'b9b312'}, // Médio
    2: {color: 'ff1010'}, // Avançado
    3: {color: '12c281'}, // Silvicultura
    4: {color: 'e6e6e6'}, // Outras Classes
    5: {color: '0cleff'}, // Hidrografia
  }
};

// Construção do gráfico com a contagem de pixels:
var graficoPixel = ui.Chart.image.byClass({
  image: ee.Image(1).addBands(classificacao_final),
  classBand: 'classification',
  region: area_personalizada, //#CONFIGURE A ÁREA A
SER ANALISADA
  scale: 20, //#CONFIGURE O TAMANHO DOS PIXELS (EM
METROS) A SEREM ANALISADOS.
  reducer: ee.Reducer.count()

```

```

})
    .setSeriesNames(names)
    .setOptions(opcoes);

//Configuração do gráfico "Somatório de Áreas por
Classe":
var opcoes2 = {
title: 'Somatório de Áreas por Classe',
  hAxis: {title: 'Classes'},
  vAxis: {title: 'Área (hectares)'},
  lineWidth: 1,
  pointSize: 4,
  //fontSize: 20, //CONFIGURE O TAMANHO DA FONTE A
SER EXIBIDA NO GRÁFICO.
  series: {
    0: {color: '98ff00'}, // Inicial
    1: {color: 'b9b312'}, // Médio
    2: {color: 'ff1010'}, // Avançado
    3: {color: '12c281'}, // Silvicultura
    4: {color: 'e6e6e6'}, // Outras Classes
    5: {color: '0c1eff'}, // Hidrografia
  }
};

//Construção do gráfico com a área e hectares. Para
obter em metros, suprimir o trecho "divide(10000)":
var graficoArea = ui.Chart.image.byClass({
  image:
ee.Image.pixelArea().divide(10000).addBands(classif
icacao_final),
  classBand: 'classification',
  region: area_personalizada, //CONFIGURE A ÁREA A
SER ANALISADA
  scale: 20, //CONFIGURE O TAMANHO DOS PIXELS (EM
METROS) A SEREM ANALISADOS.
  reducer: ee.Reducer.sum()
})
    .setSeriesNames(names)
    .setOptions(opcoes2);

// Adicionar os gráficos ao Console:
print(graficoPixel);
print(graficoArea);

```



```
// -----  
//  Exportação da imagem classificada  
//  -----  
  
Export.image.toAsset({  
    image: classificacao_final,  
    description: 'imagem_classificada',  
    assetId: 'classificada',  
    scale: 10, //#CONFIGURE O TAMANHO DOS PIXELS  
    (EM METROS) A SEREM ANALISADOS.  
    maxPixels: 1e13,  
    //region: fom //#CONFIGURE A ÁREA A SER  
    EXPORTADA. QUANDO DESABILITADA, SERÁ EXPORTADA A  
    ÁREA VISÍVEL NO MAPA  
});
```

APÊNDICE D – Script Mensuração da Classificação

Apêndice D – Script com a rotina elaborada para a apresentação dos dados mensurados em uma imagem classificada. Este código está disponível a partir do repositório do GEE: http://bit.ly/codigos_gce para clonagem e listagem de alterações (logs).

```
/* INFORMAÇÕES GERAIS SOBRE O SCRIPT
```

1. Todas as linhas que iniciam com `//`, são utilizadas para comentários e informações relacionadas ao código. Elas sempre aparecerão na cor verde. Em alguns casos, podem representar uma linha desabilitada.

2. As linhas comentadas com o título no formato
`// -----`
`// Texto`
`// -----`

indicam uma seção/tópico específico do código e representa a função ou descrição do script.

3. Ao executar o código, o painel "Console" do GEE apresentará todas as informações requisitadas pela função "print".

4. Linhas customizáveis

Algumas linhas podem ser customizadas no script para que seja possível a configuração de parâmetros. A seguir, são descritas as funções de cada uma:

- Linhas com o termo "scale" - o parâmetro "scale" define a escala de um determinado resultado.
- Linhas com o termo "print" - é possível habilitar ou não informações a serem mostradas no Console do GEE
- Linhas com os termos "geometry" ou "region" - é possível definir uma região específica para a

```

    obtenção de dados da análise ou desabilitar a
    linha para que o parâmetro padrão seja utilizado.
    */

// -----
// Criar painel lateral
// -----

var names =
['Inicial','Médio','Avançado','Banhado','Silvicultu
ra','Outras Classes','Hidrografia'];
var panel = ui.Panel();
panel.style().set('width', '400px');

var intro = ui.Panel([
  ui.Label({
    value: 'Estatísticas da Classificação',
    style: {fontSize: '20px', fontWeight: 'bold'}
  }),
  ui.Label('Posicione o cursor sobre as colunas
para visualizar os valores.')
]);
panel.add(intro);

// -----
// Estatísticas da imagem classificada
// -----

// Informações, em percentual, das áreas
classificadas em uma determinada região:

var frequency = classificacao_final.reduceRegion({
  reducer: ee.Reducer.frequencyHistogram(),
  //geometry: area_personalizada, //CONFIGURE A
ÁREA A SER ANALISADA.
  scale: 10, //CONFIGURE O TAMANHO DOS PIXELS (EM
METROS) A SEREM ANALISADOS.
  maxPixels: 1e13,
});
var dict =
ee.Dictionary(frequency.get('classification'));
var sum =

```

```

ee.Array(dict.values()).reduce(ee.Reducer.sum(), [0]
).get([0]);
var new_dict = dict.map(function(k,v) {
  return ee.Number(v).divide(sum).multiply(100);
});
print('Classes (%)', new_dict, 'Considera:', ' 1
= Estágio Inicial,', ' 2 = Estágio Médio,', ' 3
= Estágio Avançado', ' 4 = Banhado', ' 5 =
Silvicultura', ' 6 = Outras Classes', ' 7 =
Hidrografia');

//Configuração do gráfico "Contagem de Pixels por
Classe":
var options = {
title: 'Contagem de Pixels por Classe',
  hAxis: {title: 'Classes'},
  vAxis: {title: 'Número de Pixels'},
  lineWidth: 1,
  pointSize: 4,
  //fontSize: 20, //CONFIGURE O TAMANHO DA FONTE A
SER EXIBIDA NO GRÁFICO.
  series: {
    0: {color: '98ff00'}, // Inicial
    1: {color: 'b9b312'}, // Médio
    2: {color: 'ff1010'}, // Avançado
    3: {color: 'ff3af4'}, // Banhado
    4: {color: '12c281'}, // Silvicultura
    5: {color: 'e6e6e6'}, // Outras Classes
    6: {color: '0c1eff'}, // Hidrografia
  }
};

//Criação do gráfico "Contagem de Pixels por
Classe":
var pixelChart = ui.Chart.image.byClass({
  image: ee.Image(1).addBands(classificacao_final),
  classBand: 'classification',
  region: fom, //CONFIGURE A ÁREA A SER ANALISADA
  scale: 10, //CONFIGURE O TAMANHO DOS PIXELS (EM
METROS) A SEREM ANALISADOS.
  reducer: ee.Reducer.count()
})
.setSeriesNames(names)

```

```

        .setOptions(options);
        panel.widgets().set(1, pixelChart);

//Configuração do gráfico de "Somatório de Áreas
por Classe".
    var options2 = {
title: 'Somatório de Áreas por Classe',
    hAxis: {title: 'Classes'},
    vAxis: {title: 'Área (hectares)'},
    lineWidth: 1,
    pointSize: 4,
    //fontSize: 20, //#CONFIGURE O TAMANHO DA FONTE A
SER EXIBIDA NO GRÁFICO.
    series: {
        0: {color: '98ff00'}, // Inicial
        1: {color: 'b9b312'}, // Médio
        2: {color: 'ff1010'}, // Avançado
        3: {color: 'ff3af4'}, // Banhado
        4: {color: '12c281'}, // Silvicultura
        5: {color: 'e6e6e6'}, // Outras Classes
        6: {color: '0c1eff'}, // Hidrografia
    }
};

//Criação do gráfico de "Somatório de Áreas por
Classe":
var areaChart = ui.Chart.image.byClass({
    image:
ee.Image.pixelArea().divide(10000).addBands(classif
icacao_final),
    classBand: 'classification',
    region: fom, //#CONFIGURE A ÁREA A SER ANALISADA
    scale: 10, //#CONFIGURE O TAMANHO DOS PIXELS (EM
METROS) A SEREM ANALISADOS.
    reducer: ee.Reducer.sum()
})
    .setSeriesNames(names)
    .setOptions(options2);
    panel.widgets().set(2, areaChart);

Map.style().set('cursor', 'crosshair');

ui.root.insert(0, panel);

```

```

// -----
// Inserir a legenda no mapa
// -----

// Posição:
var legend = ui.Panel({
  style: {
    position: 'bottom-left',
    padding: '20px 30px'
  }
});

// Criar título:
var legendTitle = ui.Label({
  value: 'Legenda',
  style: {
    fontWeight: 'bold',
    fontSize: '18px',
    margin: '0 0 4px 0',
    padding: '0'
  }
});

// Adicionar o título ao painel:
legend.add(legendTitle);

// Criar e estilizar a linha 1 da legenda:
var makeRow = function(color, name) {

// Criar a caixa colorida:
var colorBox = ui.Label({
  style: {
    backgroundColor: '#' + color,
    // Use padding to give the box height
and width.
    padding: '8px',
    margin: '0 0 4px 0'
  }
});

// Criar a descrição da classe:
var description = ui.Label({

```

```

        value: name,
        style: {margin: '0 0 4px 6px'}
    });

// Resultar no painel:
    return ui.Panel({
        widgets: [colorBox, description],
        layout:
ui.Panel.Layout.Flow('horizontal')
    });
};

// Paleta de cores:
    var palette =['98ff00', 'b9b312', 'ff1010',
'12c281', 'e6e6e6', '0c1eff'];

// Nomes da legenda:
    var names =
['Inicial', 'Médio', 'Avançado', 'Silvicultura', 'Outra
s Classes', 'Hidrografia'];

// Adicionar as cores e os nomes:
    for (var i = 0; i < 6; i++) {
        legend.add(makeRow(palette[i], names[i]));
    }

    Map.add(legend);

// -----
// Adição uma barra de título ao mapa
// -----

Map.add(ui.Label(
    'Classificação Sentinel 2', {fontWeight:
'bold', fontSize: '24px'}));

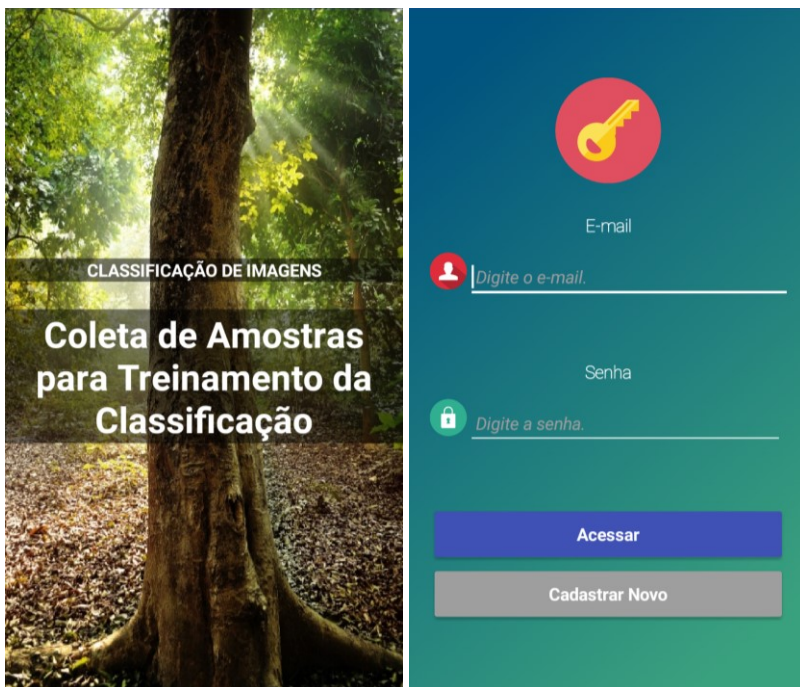
// -----
// Adição da imagem classificada ao mapa
// -----

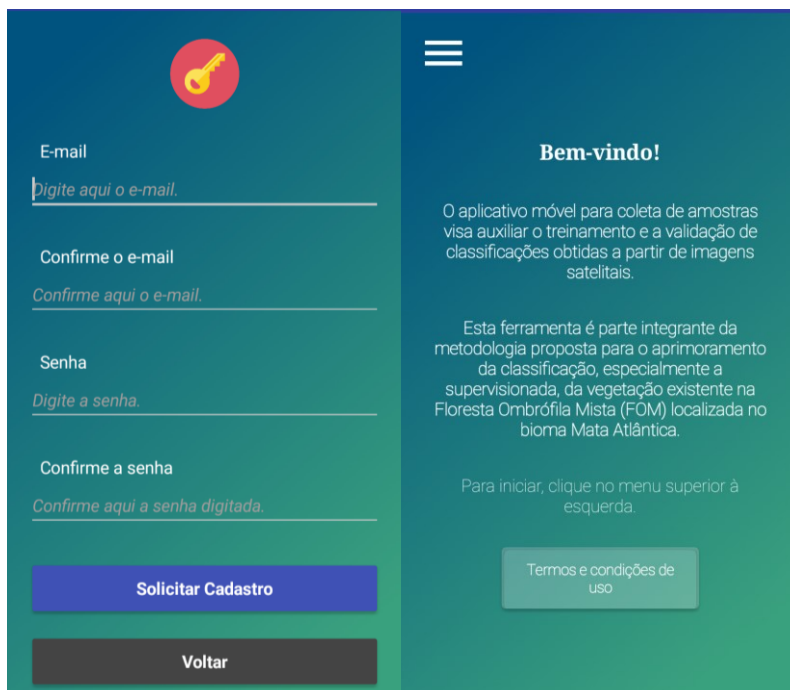
//Visão inicial do mapa:
Map.setCenter(-51.3,-27.5,7); //geral

```


```
// Parâmetros de visualização da classificação:  
Map.addLayer(classificacao_final, {min: 1, max: 7,  
palette:['98ff00', 'b9b312', 'ff1010', 'ff3af4',  
'12c281', 'e6e6e6', '0c1eff']}, 'Classificação');
```


APÊNDICE E – Telas do aplicativo Completo





The image shows a registration form on the left and a welcome message on the right, both on a dark blue background with a green gradient. The registration form includes fields for E-mail, confirm E-mail, Senha, and confirm Senha, with a 'Solicitar Cadastro' button and a 'Voltar' button. The welcome message includes a heading 'Bem-vindo!', a paragraph about the mobile application, a paragraph about the methodology, and a paragraph about starting the process, with a 'Termos e condições de uso' button.



E-mail
digite aqui o e-mail.


Confirme o e-mail
Confirme aqui o e-mail.

Senha
digite a senha.

Confirme a senha
Confirme aqui a senha digitada.

Solicitar Cadastro

Voltar




Bem-vindo!

O aplicativo móvel para coleta de amostras visa auxiliar o treinamento e a validação de classificações obtidas a partir de imagens satelitais.

Esta ferramenta é parte integrante da metodologia proposta para o aprimoramento da classificação, especialmente a supervisionada, da vegetação existente na Floresta Ombrófila Mista (FOM) localizada no bioma Mata Atlântica.

Para iniciar, clique no menu superior à esquerda.

Termos e condições de uso



Nova coleta

Consultar classificação

Legislação

Estimativa de altura

Sobre

Sair

Precisão do GNSS: **37 metros.**

Insira as informações no formulário a seguir:

1. Nome ou descrição do local.

Amostra Teste 1

2. Tipo de uso/cobertura do solo.

Inicial

3. Observações.


Informações adicionais.

4. Localização.



4. Localização:

Latitude: [redacted]
Longitude: [redacted]
Endereço: Av. [redacted]
Tel [redacted]


Altitude aproximada: **119 metros.**




Registro atual:

Salvar na lista  Cancelar 



Gerenciar registros gravados:

Enviar lista para o banco de dados 

Apagar registro selecionado na lista 

Lista de amostras coletadas:

Amostra Teste 1



Voltar

Resolução CONAMA n° 04, de 04 de maio de 1994

O CONSELHO NACIONAL DO MEIO AMBIENTE - CONAMA, no uso das atribuições que lhe são conferidas pela Lei no. 6.938, de 31 de agosto de 1981, alterada pela Lei no. 8.028, de 12 de abril de 1990, regulamentadas pelo Decreto no. 99.274, de 06 de junho de 1990, e Lei no. 8.746, de 09 de dezembro de 1993, considerando o disposto na Lei no. 8.490, de 19 de novembro de 1992, e tendo em vista o disposto em seu Regimento Interno, e

Considerando a necessidade de se definir vegetação primária e secundária nos estágios inicial, médio e avançado de regeneração da Mata Atlântica em cumprimento ao disposto no artigo 6o. do Decreto 750, de 10 de fevereiro de 1993, na Resolução/CONAMA/n°. 10, de 01 de outubro de 1993, e a fim de orientar os procedimentos de licenciamento de atividades florestais no Estado de Santa Catarina, resolve:

Art. 1º **Vegetação primária** é aquela de máxima expressão local, com grande diversidade biológica, sendo os efeitos das ações antrópicas mínimos, a ponto de não afetar significativamente suas características originais de estrutura e de espécies, onde são observadas **área basal média superior a 25 00 metros quadrados por hectare; DAP médio**

Estimativa de altura ?

Localização atual:  

Precisão: 37 metros

Ativar voz Preencher itens 3 e 4 autom.

1. Salvar a localização da árvore:



2. Ângulo e distância atuais:

Ângulo: 23 ° / Distância: 26

3. Digite ou capture a distância da árvore.

Distância da árvore: X

Capturar distância

4. Digite ou capture o ângulo.

Ângulo para o topo: X




3. Digite ou capture a distância da árvore.

Distância da árvore: X

Capturar distância


4. Digite ou capture o ângulo.

Ângulo para o topo: X



Distância utilizada para o cálculo: 10 metros.

A altura estimada da árvore é de 4 metros.



Voltar

Informações

1. Termos e condições gerais de uso do aplicativo

Qualquer pessoa, física ou jurídica, que pretenda utilizar o presente aplicativo declara estar ciente quanto aos seguintes termos:

- O usuário possui total responsabilidade pelo seu uso e informações apresentadas;
- É vedada a reprodução do conteúdo sem o consentimento ou citação do autor;
- O aplicativo faz parte de uma proposta metodológica para procedimentos de classificação de imagens e possui apenas caráter experimental, visando o uso científico.
- Este aplicativo apresenta-se como um protótipo e se encontra em contínuo desenvolvimento, podendo conter erros. Portanto, eventuais prejuízos, travamentos, defeitos e/ou problemas relacionados ao uso do aplicativo, eximem o autor de quaisquer responsabilidades.

- O autor não garante, declara ou assegura que o uso deste aplicativo seja ininterrupto e o usuário concorda estar ciente que o programa possa ficar indisponível por períodos indefinidos;

- O autor não assegura que este aplicativo esteja livre de vulnerabilidades quanto à segurança, incluindo ataques por vírus ou quaisquer outros tipos de invasão. Portanto, isenta-se de qualquer responsabilidade em relação a estes aspectos.

2. Dúvidas, erros ou aprimoramentos

Dúvidas sobre o aplicativo ou relato de erros, enviar e-mail para diegohemk@gmail.com.

3. A ferramenta de apoio "Estimativa de altura"

Baseada no cálculo tradicional para a medida de altura das árvores, a ferramenta permite uma rápida estimativa de objetos com base no cálculo trigonométrico dos catetos oposto ($H+h$) em razão do adjacente (D), multiplicado pela tangente do ângulo ($\hat{\alpha}$) de um triângulo retângulo. É importante ressaltar que o método não contabiliza a altura do observador. Portanto, é necessário que seja considerada,

Dúvidas sobre o aplicativo ou relato de erros, enviar e-mail para diegohemk@gmail.com.

3. A ferramenta de apoio "Estimativa de altura"

Baseada no cálculo tradicional para a medida de altura das árvores, a ferramenta permite uma rápida estimativa de objetos com base no cálculo trigonométrico dos catetos oposto ($H+h$) em razão do adjacente (D), multiplicado pela tangente do ângulo ($\hat{\alpha}$) de um triângulo retângulo. É importante ressaltar que o método não contabiliza a altura do observador. Portanto, é necessário que seja considerada, além do resultado obtido pelo aplicativo, a medida "h" indicada na figura a seguir. Esta funcionalidade permite somente uma estimativa e não há como determinar a margem de erro, considerando que não foram realizadas análises estatísticas quanto à sua acurácia.

