

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

VINÍCIUS LORINI DA COSTA

**DETECÇÃO DE ESTÁGIOS SUCESSIONAIS POR SENSORIAMENTO REMOTO
EM FRAGMENTOS FLORESTAIS DE ALTOS DE CANGUÇU - RS**

PORTO ALEGRE

2021

VINÍCIUS LORINI DA COSTA

**DETECÇÃO DE ESTÁGIOS SUCESSIONAIS POR SENSORIAMENTO REMOTO
EM FRAGMENTOS FLORESTAIS DE ALTOS DE CANGUÇU - RS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de mestre em Sensoriamento Remoto e Geoprocessamento.

Orientador: Prof. Dr. Marcos Wellausen Dias de Freitas

PORTO ALEGRE

2021

VINÍCIUS LORINI DA COSTA

**DETECÇÃO DE ESTÁGIOS SUCESSIONAIS POR SENSORIAMENTO REMOTO
EM FRAGMENTOS FLORESTAIS DE ALTOS DE CANGUÇU - RS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de mestre em Sensoriamento Remoto e Geoprocessamento.

Data de aprovação: 29 de setembro de 2021.

Banca Examinadora:

Prof. Dr. Cláudio Wilson Mendes Júnior (PPGSR/UFRGS)

Profa. Dra. Tatiana Mora Kuplich (PPGSR/INPE)

Prof. Dr. Veraldo Liesenberg (UDESC - Membro externo)

CIP - Catalogação na Publicação

da Costa, Vinicius Lorini
Detecção de estágios sucessionais por
sensoriamento remoto em fragmentos florestais de Altos
de Canguçu - RS / Vinicius Lorini da Costa. -- 2021.
63 f.
Orientador: Marcos Wellausen Dias de Freitas.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,
BR-RS, 2021.

1. Classificação Supervisionada. 2. Computação em
Nuvem. 3. Aprendizagem de Máquina. 4. Sucessão
Florestal. 5. Floresta Estacional Semidecídua. I. de
Freitas, Marcos Wellausen Dias, orient. II. Título.

Dedico este trabalho à minha Mãe e ao meu Pai por estimularem meus estudos e por todos os momentos de apoio e encorajamento que proporcionaram.

AGRADECIMENTOS

Ao corpo do CEPSRM e do Programa de Pós-Graduação em Sensoriamento Remoto pela manutenção do PPG.

Ao CNPq pela bolsa de pesquisa.

À Professora Dra. Eliana Lima da Fonseca pelo primeiro ano de orientação e pelos ensinamentos.

Ao Professor Dr. Marcos Wellausen Dias de Freitas pela sequência na orientação deste trabalho, pela autonomia concedida e pelas sugestões e ensinamentos.

À sociedade de Canguçu e Piratini pela cordialidade e pelas autorizações para coleta de dados.

À Mariana Diedrich e família pelo companheirismo e pelo apoio.

RESUMO

As florestas secundárias estão em constante aumento à medida que as florestas primárias são degradadas e as áreas produtivas são abandonadas. O mapeamento dos estágios de sucessão das florestas secundárias é importante para apoiar a previsão de impactos, o monitoramento e a conservação ambiental, permitindo avaliar quantitativa e qualitativamente os remanescentes florestais bem como sua distribuição espacial. Neste estudo objetivou-se avaliar o potencial de classificação de estágios sucessionais da Floresta Estacional Semidecídua em uma região da Serra do Sudeste do Rio Grande do Sul a partir de diferentes fontes de dados de sensoriamento remoto e suas sinergias. Foram utilizados dados ópticos Sentinel-2 de reflectância de superfície, dados SAR Sentinel-1 e texturas GLCM (*Grey Level Co-Occurrence Matrix*) derivadas e dados geomorfométricos SRTM, os quais compuseram diferentes grupos que serviram como dados de entrada para os classificadores de aprendizagem de máquina *Support Vector Machine* (SVM), *Classification and Regression Tree* (CART) e *Random Forest* (RF). Os procedimentos foram realizados na plataforma *Google Earth Engine*. O RF apresentou as maiores exatidões globais (93 a 97%), independente do conjunto de dados utilizados como entrada, com o índice kappa variando de 0,89 (dados ópticos e SAR) a 0,95 (dados ópticos, SAR e geomorfométricos). O CART apresentou valores idênticos de exatidão global (92,5%) exceto para o conjunto de dados acrescido das camadas de textura SAR, que apresentou exatidão ligeiramente mais baixa (91,7%); o índice kappa variou de 0,89 a 0,91. O pior desempenho foi o da classificação de dados ópticos por SVM, resultando em 59% de exatidão e 0,37 de índice kappa, todavia, a sinergia de dados ópticos, SAR e geomorfométricos classificados por SVM atingiu 75% de exatidão. A inclusão de camadas de texturas GLCM promoveu aumento da confusão entre as classes para todos os classificadores. Os melhores resultados foram obtidos pela sinergia de dados ópticos, SAR e geomorfométricos classificados por RF, com exatidão global de 97% e índice kappa de 0,95.

Palavras-chave: Classificação supervisionada. Computação em nuvem. Floresta secundária.

ABSTRACT

Secondary forests are constantly increasing as primary forests are degraded and productive areas are abandoned. The mapping of successional stages of the secondary forests is important to support the prediction of impacts, monitoring and environmental conservation, allowing the quantitative and qualitative assessment of forest remnants as well as their spatial distribution. The aim of this study was to evaluate the potential for classification of successional stages of the Semideciduous Seasonal Forest in a region of Serra do Sudeste in Rio Grande do Sul, using different sources of remote sensing data and their synergies. Sentinel-2 optical surface reflectance data, SAR Sentinel-1 data and GLCM (Grey Level Co-Occurrence Matrix) derived textures and SRTM geomorphometric data were used, which composed different groups that served as input data for the learning classifiers Support Vector Machine (SVM), Classification and Regression Tree (CART) and Random Forest (RF). The procedures were performed on the Google Earth Engine platform. The RF had the highest global accuracies (93 to 97%), regardless of the data set used as input, with the kappa index ranging from 0.89 (optical and SAR data) to 0.95 (optical, SAR and geomorphometric data). CART had identical global accuracy values (92.5%) except for the dataset SAR-GLCM texture layers, which had slightly lower accuracy (91.7%); the kappa index ranged from 0.89 to 0.91. The optical data (S2) classification by SVM had the worst performance, resulting in 59% accuracy and 0.37 kappa index, however, the synergy of optical, SAR and geomorphometric data classified by SVM reached 75% accuracy. The inclusion of SAR-GLCM texture layers increased confusion between classes for all classifiers. The best results were obtained by the synergy of optical, SAR and geomorphometric data classified by RF, with global accuracy of 97% and kappa index of 0.95.

Keywords: Supervised classification. Cloud computing. Secondary forest.

LISTA DE ILUSTRAÇÕES

Figura 1: Comparação entre as revisões de 2007 e de 2020 das Áreas Prioritárias para Biodiversidade no Bioma Pampa.	14
Figura 2: Curva padrão de resposta espectral da vegetação em faixa do espectro eletromagnético.....	19
Figura 3: Representação dos principais tipos de retroespalhamento observados em ambientes florestais.	20
Figura 4: Penetração no dossel e interação com diferentes porções florestais para as bandas C, L e P. Percebe-se maior transparência do dossel florestal para a banda P em relação à banda L, apesar da total penetração destas no dossel.	20
Figura 5: Localização da área de estudo.	33
Figura 6: Dados médios de precipitação (mm) e de temperatura (°C) mensais adquiridos pela estação meteorológica Canguçu (A811) para o período de 2009-2019.	34
Figura 7: Mapa hipsométrico da área de estudo.	35
Figura 8: Regiões fitoecológicas regionais propostas pelo IBGE (2006).....	36
Figura 9: Representação do mosaico campo-floresta com presença de Araucaria em Altos de Canguçu/RS.	37
Figura 10: Fluxograma de procedimentos metodológicos adotado	38
Figura 11: Composições sazonais medianas obtidas para o ano de 2019. Verão (A), Outono (B), Inverno (C), Primavera (D).....	39
Figura 12: Unidades Amostrais foram demarcadas com trenas de 20 e 50 metros no interior dos remanescentes, divididas em subunidades de 10x10m. (B): Foi realizada a marcação dos vértices das Unidades Amostrais com GPS Garmin eTrex10.....	42
Figura 13: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT.	47
Figura 14: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_DEM	48
Figura 15: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_SAR	49

Figura 16: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_DEM_SAR50

Figura 17: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_DEM_SAR_GLCM51

LISTA DE QUADROS

Quadro 1: Demonstrativo de polígonos e área por categoria de importância Biológica entre as revisões de 2007 e de 2020 das Áreas Prioritárias para Biodiversidade no Bioma Pampa.....	14
Quadro 2: Descrição da resolução espacial e espectral do sensor MSI.	26
Quadro 3: Imagens Sentinel-2 nível 2A utilizadas para agregação temporal.....	40
Quadro 4: Imagens Sentinel-1 nível 2A utilizadas para agregação temporal.....	40
Quadro 5: Número de amostras por classe para treinamento e validação.....	41
Quadro 6: Agrupamentos de dados utilizados para comparação de desempenho de classificação.....	43
Quadro 7: Valores de exatidão global e índice Kappa atingidos por cada classificador para cada agrupamento de dados utilizado.....	45
Quadro 8: Mapa de Calor de área absoluta e relativa estimada para cada classe para a área de estudo por classificador por conjunto de dados. AC: Agricultura; CA: Campo; SC: Silvicultura; AG: Água; FM: Floresta em Estágio Médio; FA: Floresta em Estágio Avançado. Áreas em km ²	46

LISTA DE ABREVIATURAS E SIGLAS

ALOS - AW3D	<i>Advanced Land Observing Satellite - ALOS World 3D</i>
ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
AVHRR	<i>Advanced Very High-Resolution Radiometer</i>
CONAMA	Conselho Nacional do Meio Ambiente
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ESA	<i>European Space Agency</i>
GPS	<i>Global Positioning System</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
MDE	Modelo Digital de Elevação
MDT	Modelo Digital de Terreno
NOAA	<i>National Oceanic and Atmospheric Administration</i>
OLI	<i>Operational Land Imager</i>
SPOT - HVR	<i>Satellite pour l'Observation de la Terre - High Resolution Visible</i>
SRTM	<i>Shuttle Radar Topography Mission</i>
USGS	<i>United States Geological Survey</i>
WGS84	<i>World Geodetic System 1984</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivos	15
1.1.1	<i>Objetivos específicos</i>	15
2	REFERENCIAL TEÓRICO	16
2.1	Fitogeografia do Rio Grande do Sul	16
2.2	Comportamento Espectral da Vegetação	18
2.3	Sensoriamento Remoto de Florestas	21
2.4	Deteccão de estágios sucessionais da vegetação florestal	22
2.5	Missão Sentinel-1	25
2.6	Missão Sentinel-2	25
2.7	Influência da geomorfologia sobre a vegetação	26
2.8	Processamento de imagens	28
2.9	Classificação de imagens	30
3	METODOLOGIA	33
3.1	Área de Estudo	33
3.1.1	<i>Clima</i>	33
3.1.2	<i>Geologia, Geomorfologia e Solos</i>	35
3.1.3	<i>Vegetação</i>	36
3.2	Dados de Sensoriamento Remoto	37
3.2.1	<i>Modelo Digital de Terreno</i>	37
3.2.2	<i>Dados Ópticos</i>	37
3.2.3	<i>Dados Radar</i>	37
3.3	Procedimentos metodológicos	38
3.3.1	<i>Processamento do Modelo Digital de Elevação</i>	38
3.3.2	<i>Processamento dos Dados Ópticos</i>	39
3.3.3	<i>Processamento dos Dados Radar</i>	40
3.3.4	<i>Classificação de Estágios Sucessionais</i>	41
3.3.4.1	<u>Levantamento de Campo</u>	41
3.3.4.2	<u>Classificação por aprendizagem de máquina</u>	42
3.3.4.3	<u>Validação</u>	43
4	RESULTADOS E DISCUSSÕES	44
4.1	Classificação da sucessão florestal	44
4.2	Discussões	52
5	CONCLUSÕES	54
	FINANCIAMENTO	55
	REFERÊNCIAS	56

1 INTRODUÇÃO

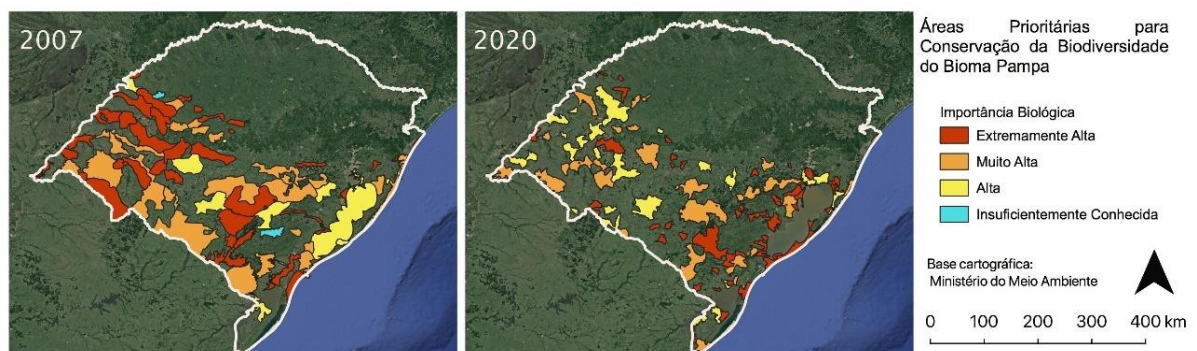
As florestas abrigam grande parte da biodiversidade dos ecossistemas terrestres e têm um papel fundamental no ciclo do carbono. Aprimorar as técnicas de monitoramento das florestas é uma importante questão de pesquisa, relevante para a implementação de acordos relacionados às mudanças climáticas, para a conservação da biodiversidade, para a definição de esquemas sustentáveis para extração de madeira e planejamento de impactos ambientais. A compreensão dos mecanismos ecológicos também pode se beneficiar de um melhor monitoramento da floresta, como no caso da dinâmica da distribuição de espécies arbóreas em diferentes ecossistemas, estruturas comunitárias e distribuições espaciais de características funcionais (LAURIN *et al.*, 2016).

As florestas secundárias tornaram-se um elemento comum da paisagem e sua extensão está em constante aumento à medida que as florestas primárias continuam sendo degradadas e as áreas produtivas são abandonadas, tornando-se áreas em regeneração. Estas florestas variam em idade, composição florística e taxas de crescimento, dependendo de fatores que incluem histórico de perturbações e características edáfico-climáticas (AGUILAR, 2005). A vegetação florestal secundária é comumente agrupada em três estágios de sucessão: estágio inicial, estágio intermediário e estágio avançado (LU, 2003). Cada um deles possui características particulares em relação à composição de espécies, estrutura da vegetação e região de ocorrência. O mapeamento destes estágios é uma tarefa fundamental para apoiar estudos com aplicações múltiplas, além de iniciativas de manejo, monitoramento e conservação ambiental, permitindo avaliar quantitativa e qualitativamente os remanescentes florestais bem como sua distribuição espacial (SOTHE *et al.*, 2017). Desde 1993, as florestas primárias e secundárias em estágio médio e avançado de regeneração do Bioma Mata Atlântica e de seus ecossistemas associados vêm recebendo regramentos legais quanto ao uso e conservação e quanto aos parâmetros para caracterização e enquadramento destes estágios devido ao estado de degradação do bioma (BRASIL, 1993; 1994; 2006).

As Áreas Prioritárias para a Conservação da Biodiversidade foram instituídas com o objetivo de formular e implementar políticas públicas, programas e projetos voltados à conservação e uso sustentável da biodiversidade, à pesquisa e inventários

de biodiversidade, à recuperação de áreas degradadas e de espécies ameaçadas de extinção e valorização econômica da biodiversidade (BRASIL, 2004). O resultado foi um mapa de áreas às quais foram atribuídos níveis de importância biológica: extremamente alta, muito alta, alta e insuficientemente conhecidos, mas de provável importância biológica. A área denominada Altos do Canguçu, localizada no sudoeste do RS em um ecossistema predominantemente florestal, integrava a lista de áreas prioritárias para a biodiversidade no mapeamento de 2007 sob enquadramento de importância biológica insuficientemente conhecida e foi desconsiderada na revisão de 2020, gerando uma lacuna regional neste âmbito, como observado na Figura 1, bem como uma redução significativa nas áreas com foco a receber ações de conservação da biodiversidade, como observado no Quadro 1.

Figura 1: Comparação entre as revisões de 2007 e de 2020 das Áreas Prioritárias para Biodiversidade no Bioma Pampa.



Fonte: o Autor

Quadro 1: Demonstrativo de polígonos e área por categoria de importância Biológica entre as revisões de 2007 e de 2020 das Áreas Prioritárias para Biodiversidade no Bioma Pampa.

Categoria de Importância Biológica	2007		2020	
	Polígonos	Área (km ²)	Polígonos	Área (km ²)
Extremamente Alta	41	34.282,95	45	13.604,48
Muito Alta	28	36.274,28	24	20.310,13
Alta	17	16.581,67	41	14.267,52
Insuficientemente Conhecida	2	933,46	0	0
Total	88	88.072,36	110,00	48.182,13

Fonte: o Autor.

De acordo com MARGULES & PRESSEY (2000), a realização de metas de conservação requer estratégias para o manejo da paisagem como um todo, incluindo áreas de produção e de proteção. Muitas espécies e tipos de vegetação agora existem apenas em remanescentes de habitats, que são alterados e cercados por usos

intensivos da terra. Desta forma, as reservas, por si só, não são adequadas para a conservação da natureza, mas são o ponto sobre o qual as estratégias são construídas, visto que as principais funções das reservas são representar a biodiversidade de cada região e separar esta biodiversidade de processos que ameacem a sua persistência, sendo necessário reexaminar as metas de conservação à medida que o conhecimento se acumula.

1.1 Objetivos

Mapear os estágios sucessionais da Floresta Estacional Semidecídua na Serra do Sudeste do Rio Grande do Sul, a partir de dados de sensoriamento remoto, utilizando técnicas de aprendizagem de máquina, na plataforma *Google Earth Engine*.

1.1.1 *Objetivos específicos*

- Avaliar a potencialidade de dados Sentinel-1, Sentinel-2 e SRTM e suas sinergias para uso na classificação de estágios sucessionais da Floresta Estacional Semidecídua na Serra do Sudeste do Rio Grande do Sul;
- Analisar o desempenho dos algoritmos *Support Vector Machine*, *Classification and Regression Tree* e *Random Forest* para classificação de estágios sucessionais da Floresta Estacional Semidecídua na Serra do Sudeste do Rio Grande do Sul utilizando diferentes conjuntos de dados de sensoriamento remoto;
- Gerar mapeamentos dos diferentes estágios sucessionais da Floresta Estacional Semidecídua na Serra do Sudeste do Rio Grande do Sul e avaliar a qualidade dos mapeamentos gerados.

2 REFERENCIAL TEÓRICO

2.1 Fitogeografia do Rio Grande do Sul

As diferentes espécies vegetais estão distribuídas sobre a Terra de acordo com suas exigências climáticas e edáficas. Espécies muito antigas tiveram mais oportunidades que espécies mais recentes para distribuir seu habitat, bem como espécies que apresentam mecanismos de dispersão mais eficientes, como estruturas de adesão animal, frutos ou sementes com período de dormência tiveram sua distribuição afetada por tais mecanismos; desta forma, o estudo fitogeográfico das comunidades vegetais busca associar o padrão de distribuição das principais espécies em uma determinada região a eventos climáticos, faunísticos, pedológicos, entre outros (CABRERA, 1971). RIZZINI (1992) define a *flora* como as espécies que compõe qualquer vegetação em um determinado lugar, abstendo-se da taxonomia e priorizando a distribuição, o que chama de Fitogeografia ou *Florística*.

As condições climáticas e edáficas são importantes para o surgimento de determinada formação vegetal. Aspectos como a quantidade e distribuição anual das chuvas, o teor de umidade atmosférica, incidência da radiação solar, ocorrência de ventos e a variação anual da temperatura configuram o clima; os principais fatores edáficos são a composição físico-química do solo, a profundidade do solo, a ciclagem de nutrientes e o relevo (RIZZINI, 1992; BLUM, 2011).

A vegetação no Rio Grande do Sul apresenta duas fisionomias marcantes, os campos e as matas. LINDMAN (1974) afirma que o Rio Grande do Sul está numa zona de transição entre a mata virgem brasileira e os pampas argentinos. Os campos são formações edáfico-climáticas remanescentes do período Glacial, época em que o clima seco e frio era impróprio para formar matas de galeria. A transição do período Glacial Tardio para o Holoceno (aproximadamente 10.500 anos) evidencia uma mudança de clima frio e seco para clima quente e seco, ainda assim não sendo aparentes as matas. O desenvolvimento das florestas há aproximadamente 5.200 anos indica a mudança para clima úmido; já a expansão destas florestas sobre os campos ocorreu há aproximadamente 1.550 anos, conforme estudos realizados por BEHLING *et al.* (2005, 2007) ao realizarem a datação de radiocarbono no Rio Grande do Sul.

O desenvolvimento das florestas no sul do Brasil a partir de remanescentes do Brasil-central ocorreu por duas rotas de migração, uma litorânea e outra pelo interior do continente, respectivamente o corredor leste Atlântico, recoberto pela Floresta Ombrófila Densa (Mata Atlântica *sensu strictu*) e o oeste continental, com predomínio da Floresta Estacional das bacias do rio Paraná e do rio Uruguai. Estes contingentes vegetacionais migratórios têm sua expansão limitada pelo Planalto Sul Brasileiro, o qual forma uma encosta voltada para o oceano Atlântico, de Torres a Osório, com altitudes de até 1400 metros, e uma encosta meridional, que se estende de Osório a São Francisco de Assis apresentando lenta diminuição da altitude no sentido Oeste. A sobreposição dos dois contingentes florísticos é dificultada devido as menores temperaturas nas regiões mais elevadas, ocorrendo a mistura na composição da vegetação na região da Depressão Central (JARENKOW & WAECHTER, 2001; BUDKE *et al.*, 2004; SCIPIONI, 2013). Compondo a flora Sul Riograndense existe, ainda, o contingente migratório Andino ou Austral-antártico, que engloba *Araucaria*, *Drymis*, *Podocarpus*, *Fucsia*, dentre outros gêneros botânicos, todos ocorrentes na Mata de Araucária (Floresta Ombrófila Mista) do planalto meridional, os quais têm sua origem nos Andes Meridionais (Chile) (RAMBO, 1951; 1956).

A Serra do Sudeste ou Escudo Rio-Grandense é um complexo granítico que se estende do Uruguai à Porto Alegre, não ultrapassando altitudes de 600 metros. Suas formações vegetais são basicamente campos manejados e florestas contínuas quando nas encostas do relevo, formando matas de galeria. CORDEIRO & HASENACK (2009), ao mapearem a cobertura vegetal do Rio Grande do Sul, sugerem oito regiões fitogeográficas e classificam a vegetação da Serra do Sudeste do Rio Grande do Sul como Estepe e Floresta Estacional Semidecídua, sendo o mosaico campo-floresta a fisionomia mais representativa. O termo Estepe tem sido utilizado para designar formações vegetais campestres (herbáceas), como a Estepe Russa, as pradarias (Prairies) Norte-Americanos e os Pampas Sul-Americanos. No Brasil o termo é utilizado para salientar as diferenças ecológicas para com as regiões de Savana (Cerrados) e de Savana-Estépica (Caatinga, Chaco, Espinilho). O domínio da Estepe no Brasil abrange o Planalto Meridional (Planalto das Araucárias), a região sul do Planalto Sul-Rio-Grandense, o Planalto da Campanha Gaúcha e a Depressão Central Gaúcha. As florestas do Escudo Rio-Grandense são estacionais em função das estações climáticas bem definidas. Nas regiões tropicais o período é definido pela

seca, já nas subtropicais não há período de seca, todavia o frio determina repouso fisiológico e parte da vegetação (de 20% a 50%) perde as folhas (IBGE, 2012). JURINITZ & JARENKOW (2003) ao conduzirem estudos fitossociológicos na Serra do Sudeste afirmam que as espécies componentes do estrato arbóreo são originárias dos contingentes Atlântico e Estacional.

No Rio Grande do Sul, a Floresta Estacional Semidecídua é encontrada em dois blocos: um, ao sul, na encosta oriental da Serra do Sudeste do Rio Grande do Sul, correspondendo à 76%; e outro, à nordeste de Porto Alegre, no entorno dos terços iniciais do Rio dos Sinos que corresponde à 24% do total. A paisagem da Floresta Estacional Semidecídua foi severamente transformada em um mosaico agrícola, restando apenas 20% de cobertura florestal. Os remanescentes de maior representatividade são encontrados nas matas ciliares do Rio Camaquã e do Rio Piratini, que agregam 30% dos remanescentes florestais do bloco sul (CORDEIRO & HASENACK, 2009).


2.2 Comportamento Espectral da Vegetação

A relação entre a energia solar incidente na superfície e a composição espectral da energia refletida fornece muitas informações sobre a natureza da vegetação, sendo moderada pela quantidade de biomassa, quantidade de umidade e arranjo estrutural (HUETE & GLENN, 2011). A Figura 2 apresenta a resposta espectral de uma folha hipotética sob a radiação solar.

A radiação fotossinteticamente ativa (PAR – *Photosynthetically Active Radiation*) é a radiação solar recebida na faixa espectral de 0,4 a 0,7 μm . A fração da radiação fotossinteticamente ativa absorvida (FAPAR) é a porção da radiação nesta faixa espectral absorvida pela vegetação; uma porcentagem é transmitida através das folhas e outra parte é refletida. A clorofila absorve fortemente nas regiões do azul e do vermelho do espectro e é evidente um pico na reflectância aos 0,55 μm , comprimentos de onda na faixa do verde, razão da cor verde da vegetação (HUETE & GLENN, 2011). A resposta espectral na região do Infravermelho Próximo (NIR – *Near Infrared*), entre 0,7 e 1,3 μm é sensível à morfologia foliar e propriedades estruturais da folha, particularmente à camada do mesófilo na qual a reflectância e a transmitância NIR aumentam de acordo com o número de camadas celulares e espaços intercelulares e atuam como mecanismo de resfriamento foliar (FONSECA,

2007). Na região do infravermelho de 1,3 μm a 2,6 μm são observadas regiões do espectro onde há absorção da radiação pelo conteúdo de água nas folhas (HUETE & GLENN, 2011).

Figura 2: Curva padrão de resposta espectral da vegetação em faixa do espectro eletromagnético.




Fonte: adaptado de HUETE & GLENN, 2011.

A resposta da vegetação aos sinais de Radar (*Radio detection and ranging*) fornece informações sobre o alvo com base nos parâmetros amplitude, polarização e fase da energia retroespalhada que retorna ao sensor. No ambiente florestal observam-se o retroespalhamento de duplo-queque, o qual resulta da interação entre o pulso de radiação, troncos e solo, então retornando ao sensor; e o retroespalhamento volumétrico, no qual a radiação interage com o volume do dossel, sendo rebatida múltiplas vezes enquanto propaga-se, como observado na Figura 3 (MEYER *et al.*, 2019).

A penetração de micro-ondas na floresta depende principalmente do comprimento de onda da radiação. A frequência, o ângulo de incidência e a polarização são os parâmetros do sistema e a constante dielétrica, a temperatura e a orientação e rugosidade da superfície são os parâmetros alvo. O grau de despolarização e a quantidade de energia retroespalhada no sensor são normalmente controlados pela topografia local, presença de vegetação, construções e ocorrência de corpos d'água (PERIASAMY, 2018).

Figura 3: Representação dos principais tipos de retroespalhamento observados em ambientes florestais.



Fonte: MEYER, 2019.

Na banda "C" a radiação penetra cerca de um metro, interage com o volume do dossel e fornece informações sobre a biomassa foliar, saturando em torno de 60 a 70 toneladas por hectare (FOODY & CURRAN, 1994). Esta banda é menos propícia que outras bandas do espectro das micro-ondas, como as bandas "L" e "P", pois o retroespalhamento deste comprimento de onda relativamente pequeno satura em locais com densidade de biomassa de 30-50 t/ha (HANSEN *et al.* 2020). A banda "L" satura com aproximadamente 100 t/ha (JOSHI *et al.* 2016) e a banda "P" apresenta saturação na faixa de 150-200 t/ha (HANSEN *et al.* 2020) devido ao comprimento de onda maior e à interação com troncos e galhos mais expressivos. O retroespalhamento volumétrico é a principal fonte de radiação de polarização cruzada (HV ou VH), pois a energia é rebatida diversas vezes antes de retornar ao sensor, como demonstrado na Figura 4.

Figura 4: Penetração no dossel e interação com diferentes porções florestais para as bandas C, L e P. Percebe-se maior transparência do dossel florestal para a banda P em relação à banda L, apesar da total penetração destas no dossel.



Fonte: SAATCHI, 2019.

2.3 Sensoriamento Remoto de Florestas

O sensoriamento remoto fornece medições consistentes da condição e possibilita a detecção de mudanças bruscas e de tendências de mudanças ao longo do tempo na cobertura vegetal. A vegetação é um dos mais importantes componentes dos ecossistemas e conhecimentos sobre os padrões de distribuição das comunidades vegetais e alterações dos ciclos fenológicos são importantes informações sobre as características climáticas, edáficas e fisiografias de uma área (JENSEN, 2011). As florestas armazenam grandes quantidades de carbono, são habitats naturais de quase dois terços de todas as espécies da Terra, são vitais como recursos econômicos de produtos madeireiros e fornecem subsistência para milhões de pessoas nos países em desenvolvimento (HUETE, 2012).

A detecção e caracterização de alterações na vegetação permitem o monitoramento da dinâmica da paisagem em grandes áreas, inclusive aquelas de difícil acesso. A detecção de mudanças em longo prazo pode fornecer informações sobre os estressores e os fatores determinantes da mudança, potencialmente permitindo estratégias de gerenciamento direcionadas à causa (KENNEDY *et al.*, 2009). Métodos de sensoriamento remoto florestal foram utilizados por HANSEN *et al.* (2013) para mapear as mudanças na cobertura florestal mundial, constatando a perda de 2,3 milhões de quilômetros quadrados de área florestal e o ganho de apenas 0,8 milhões de quilômetros quadrados entre 2000 e 2012.

Dados de sensoriamento remoto florestal são utilizados pela Organização das Nações Unidas (ONU) para avaliar os países em desenvolvimento por seus resultados no combate ao desmatamento, à degradação florestal e pelo incremento da área coberta por florestas e recompensá-los financeiramente com base no programa REDD+ (*Reducing emissions from deforestation and forest degradation and the role of conservation, sustainable management of forests and enhancement of forest carbon stocks in developing countries*) da UNFCCC (*United Nations Framework Convention on Climate Change*) (UN, 2016).

Técnicas de sensoriamento remoto florestal também são utilizadas pelo INPE no sistema operacional mais avançado de monitoramento florestal, que integra o monitoramento de desmatamento em tempo quase real (DETER e DETER-B), o monitoramento do desmatamento anual (PRODES), monitoramento da degradação

florestal (DEGRAD) e o mapeamento do uso da terra após o desmatamento em florestas primárias (TerraClass) na Amazônia (RASMUSSEN & JEPSEN 2018).

Dados de sensoriamento remoto também são utilizados pelo MapBiomas, uma iniciativa que desenvolve mapas anuais de cobertura da terra para todos os biomas brasileiros utilizando computação em nuvem, a fim de compreender os processos dinâmicos de uso e ocupação da terra bem como diminuir incertezas nas estimativas de emissões de gases de efeito estufa (MAPBIOMAS, 2021).

Procedimentos de sensoriamento remoto são utilizados pelo governo dos Estados Unidos desde 1990 no programa de Monitoramento da Saúde Florestal, um programa concebido para determinar o estado, as mudanças e tendências nos indicadores das condições florestais anualmente (FHM, 2021). A União Europeia desenvolveu uma cooperação intergovernamental para desenvolver estratégias comuns para todos os países signatários de como proteger e realizar o manejo sustentável de suas florestas designada *Forest Europe* (FOREST EUROPE, 2021), que também utiliza recursos de sensoriamento remoto para gerar resultados. O governo da China executa o Programa Nacional de Monitoramento das Funções Ecológicas Florestais, que integra dados de inventários florestais nacionais e dados de sensoriamento remoto para gerar relatórios similares aos dos Estados Unidos e União Europeia, relativos ao monitoramento da qualidade dos ambientes florestais (YANG, 2015).

Pesquisas em sensoriamento remoto da vegetação florestal têm sido desenvolvidas visando mapear a distribuição de espécies (CHIANG, 2019; XIE *et al.* 2021), a biomassa acima do solo (PERIASAMY, 2018; LAURIN *et al.* 2018, CHEN *et al.* 2019, LIU *et al.* 2019, FORKUOR *et al.* 2020) o tipo de vegetação (WOOD *et al.* 2012, LAURIN *et al.* 2013, 2016; ERINJERY, 2018; ZHANG *et al.* 2019; PRATICÒ *et al.* 2021), a sucessão de florestas secundárias (LU *et al.* 2003, ESPIRITO-SANTO, 2005; LU *et al.* 2014, SOTHE *et al.* 2017, CHRAIBI *et al.* 2021, REYES-PALOMEQUE *et al.* 2021), dentre outros.

2.4 Detecção de estágios sucessionais da vegetação florestal

As florestas secundárias são ambientes alterados e estão em fase de regeneração. A sucessão florestal descreve as mudanças em uma comunidade com o passar do tempo; representa o gradiente desde as espécies pioneiras que crescem

rapidamente ao detectar uma abertura no dossel e promovem o ambiente ideal para o desenvolvimento de espécies de crescimento mais lento. Dentre os parâmetros para diferenciação dos estágios sucessionais florestais estão: idade (ou tempo de regeneração), altura média, área basal média, fisionomia e métodos de sensoriamento remoto (LU *et al.* 2003). Para as florestas do Rio Grande do Sul, a Resolução nº 33 de 1994 do Conselho Nacional do Meio Ambiente (CONAMA) é o instrumento legal que define os estágios sucessionais da vegetação secundária da Mata Atlântica e dos ecossistemas associados, que incluem, dentre outras tipologias, a Floresta Estacional Semidecídua.

Geralmente, as florestas com cinco anos ou menos são consideradas em estágio inicial, com vegetação entre seis e 15 anos em estágio intermediário e com mais de 15 anos em estágio avançado de sucessão. Todavia, LU *et al.* (2003), ao classificarem os estágios sucessionais florestais na bacia amazônica brasileira, afirmam não haver linearidade entre a idade e os parâmetros dendrométricos dos remanescentes devido à variação dos fatores edáfico-climáticos. PONZONI (2004) correlacionaram dados biofísicos coletados manualmente em campo e dados radiométricos do sensor Landsat-5/TM para avaliar o potencial e as limitações do uso de dados radiométricos para caracterização da vegetação florestal secundária em Altamira (PA) e não encontraram diferenças estatisticamente significantes entre os estágios, mas concluíram que a posição relativa das curvas espectrais de cada estágio está relacionada ao aumento dos níveis de sombra, sendo os valores de reflectância menores no estágio avançado. AGUILAR (2005) ao descrever o desenvolvimento espectral de florestas em regeneração avaliando dados Landsat-5/TM do Parque Nacional Celaque, em Honduras, observou que no estágio avançado de sucessão houve o aumento dos componentes de sombra devido à diversidade e complexidade da estrutura do dossel, resultando na assinatura mais escura dentre os estágios de regeneração.

FOODY & CURRAN (1994) ao avaliarem o estágio de regeneração de florestas tropicais em Gana utilizando imagens NOAA AVHRR, Landsat-MSS, SPOT-HVR, além de dados de Radar, afirmam que a sucessão florestal é caracterizada por incrementos na biomassa foliar, na biomassa lenhosa e na rugosidade do dossel, sendo a rugosidade máxima atingida com a formação de um dossel terciário maduro e que geralmente estágios mais avançados são de difícil diferenciação a partir de

dados de sensoriamento remoto óptico. Ainda, afirmam que imagens SAR banda C quando adquiridas em diferentes polarizações apresentam potencial de diferenciação de biomassa foliar e rugosidade do dossel.

O mapeamento dos estágios sucessionais da floresta por meio de imagens de sensoriamento remoto óptico apresenta desafios no processo de classificação pois os espectros de reflectância das classes envolvidas são muito semelhantes (VIEIRA *et al.*, 2003). A seleção de variáveis apropriadas e a utilização de algoritmos refinados são os dois principais pontos para melhorar o desempenho da classificação da vegetação (SOTHE *et al.*, 2017). VIEIRA *et al.* (2003) objetivou distinguir florestas de 3 a 70 anos relacionando os sinais espectrais destas coberturas da terra à atributos de comunidades vegetais como composição de espécies, distribuição de altura e diâmetro dos indivíduos e índice de área foliar. A combinação de informações de várias bandas Landsat-7/ETM+ permitiu o agrupamento das florestas secundárias em três estágios sucessivos: inicial (3 e 6 anos), intermediário (10 e 20 anos), avançado (40 e 70 anos) e concluiu que a classificação de florestas secundárias por seu estágio sucessional em vez da idade pode produzir correlações mais amplamente aplicáveis com propriedades espectrais.

SOTHE *et al.* (2017) ao avaliarem o estágio sucessional florestal no Parque Nacional de São Joaquim/SC utilizaram imagens Landsat-8/OLI bandas 2, 3, 4, 5, 6, 7 e 8 bem como imagens Sentinel-2 bandas 2, 3, 4, 5, 6, 7, 8, 8A, 11 e 12 obtiveram resultados de exatidão do usuário e do produtor acima de 80% em todos os experimentos. REYES-PALOMEQUE *et al.* (2021) utilizaram dados SPOT-5 de 10m de resolução espacial e dados biofísicos da vegetação florestal para classificar os fragmentos florestais secundários em categorias de idade (tempo de regeneração), cita a média e desvio padrão das bandas RED, GREEN e NIR como dados entrada mais importantes para o classificador *Random Forest*, obtendo exatidão superior a 88%.

CHRAIBI *et al.* (2021) analisaram a sucessão florestal secundária de agroflorestas de cacau em Trinidad e Tobago utilizando dados Sentinel-2 e índices de diversidade de espécies e destacam que mapas de uso e cobertura da terra produzidos a partir de dados de sensoriamento remoto e dados de campo podem aprofundar o conhecimento sobre padrões de biodiversidade e processos ecológicos tanto a nível local quanto de paisagem.

2.5 Missão Sentinel-1

A missão Sentinel-1 foi lançada em 2014 e é composta por dois satélites (S1A e S1B) distantes 180° entre si em órbita quase polar e heliossíncrona a 693 km de altitude com capacidade de mapear todo o planeta a cada 6 dias. A constelação apresenta taxa de revisita entre um e três dias dependendo da latitude. As unidades contam com o *Synthetic-Aperture Radar* (SAR), um sensor ativo de visada lateral com ângulo de incidência entre $29,1^\circ$ e $46,0^\circ$ que opera na banda $\sim C \sim$ com frequência de 5,405 GHz e suporta operação em polarização simples (bandas 'VV' e 'HH') e em dupla polarização (bandas 'VV+VH' e 'HH+HV'), transmitindo e recebendo radiação de micro-ondas em duas polarizações, e isso fornece mais informações sobre a rugosidade da superfície e o arranjo geométrico dos componentes do terreno. O modo *Interferometric Wide Swath* (IW) é o padrão para aquisição de dados terrestres e imageia uma faixa de 250 km com uma resolução espacial de 5 x 20 metros.

A aquisição resulta em dados do nível 0, 1 ou 2, sendo os de nível 1 projetados para o maior número de usuários. Os dados nível 1 podem ser processados em produtos SLC (*Single Look Complex*), os quais consistem em dados SAR georreferenciados usando dados de órbita e atitude do satélite e fornecidos em geometria de alcance inclinado (*Slant Range*) ou produtos GRD (*Ground Range Detected*) que consistem em dados SAR que foram detectados, multi-visualizados e projetados para o alcance do solo usando o modelo elipsóide da Terra WGS84 (ESA, 2019).

2.6 Missão Sentinel-2

A missão Sentinel-2 foi lançada em 2015 e é composta por dois satélites (S2A e S2B) distantes 180° entre si em órbita polar e heliossíncrona a 786 km de altitude. A constelação apresenta taxa de revisita entre dois e cinco dias dependendo da latitude e limites de cobertura terrestre entre $84^\circ N$ e $56^\circ S$. As unidades contam com o *MultiSpectral Instrument* (MSI), um sensor passivo que coleta a energia solar refletida pela Terra com um campo de visada de 290 km de largura que atua por sistema de varredura eletrônica (*pushbroom*). O MSI tem resolução espectral de 13 bandas, a resolução espacial varia de 10 a 60 metros dependendo da banda e a resolução radiométrica é de 12 *bits*, resultando em 4096 níveis de brilho (ESA, 2019). O

detalhamento das resoluções espacial e espectral das bandas do sensor MSI é apresentado no Quadro 2.

Quadro 2: Descrição da resolução espacial e espectral do sensor MSI.

Banda	Resolução espacial (m)	Comp. de onda		Descrição
		S2A	S2B	
1	60	443.9nm	442.3nm	<i>Aerosols</i>
2	10	496.6nm	492.1nm	<i>Blue</i>
3	10	560nm	559nm	<i>Green</i>
4	10	664.5nm	665nm	<i>Red</i>
5	20	703.9nm	703.8nm	<i>Red Edge 1</i>
6	20	740.2nm	739.1nm	<i>Red Edge 2</i>
7	20	782.5nm	779.7nm	<i>Red Edge 3</i>
8	10	835.1nm	833nm	<i>NIR</i>
8A	20	864.8nm	864nm	<i>Red Edge 4</i>
9	60	945nm	943.2nm	<i>Water vapor</i>
10	60	1373.5nm	1376.9nm	<i>Cirrus</i>
11	20	1613.7nm	1610.4nm	<i>SWIR 1</i>
12	20	2202.4nm	2185.7nm	<i>SWIR 2</i>

Fonte: adaptado de *ESA Sentinel Online* (2019).

Os produtos nível 1C e 2A são disponibilizados aos usuários. O produto 1C fornece refletância ortorretificada de topo da atmosfera, já o produto 2A inclui correção atmosférica sobre o produto 1C e fornece a reflectância da superfície terrestre, ambos na projeção UTM, datum WGS84. Ainda, a banda QA60 que contém informações sobre a presença de nuvens (ESA, 2019). As bandas 5, 6 e 7 (*Red Edge*) são especialmente promissoras por sua capacidade de detectar diferenças finas nos pigmentos de clorofila; maior teor de clorofila pode indicar maior densidade do dossel ou estrutura complexa da comunidade ou maior teor de nitrogênio no tecido da planta (LAURIN *et al.* 2016).

2.7 Influência da geomorfologia sobre a vegetação

As orientações de encostas conferem diferentes perfis de insolação, de exposição a ventos e umidade. No hemisfério Sul, encostas voltadas para o Norte são mais quentes e secas devido à maior insolação, enquanto encostas voltadas para o

Sul são mais frescas e úmidas. As encostas voltadas para o Norte recebem os primeiros e os últimos raios de sol do dia, ao passo que a encosta sul apresenta uma deposição de orvalho durante um período mais longo como consequência de um maior período de sombreamento (OLIVEIRA *et al.*, 1995). Já a declividade das encostas condiciona a ocorrência de solos rasos e a presença frequente de afloramentos rochosos (KURTZ *et al.*, 2009).

Os Modelos Digitais de Elevação (MDE) globais possuem diversas aplicações e tornaram-se essenciais para pesquisas ambientais. A missão SRTM foi uma cooperação entre as agências espaciais Norte-Americana, Alemã e Italiana lançada em fevereiro de 2000 a bordo do ônibus espacial *Endeavour* com o objetivo de mapear a topografia terrestre entre 60°N e 56°S utilizando interferometria de radares de abertura sintética (SAR) bandas C e X (FARR *et al.*, 2009). GROHMANN (2018) considera os dados SRTM como os mais utilizados e de maior sucesso até hoje apesar de limitações como vazios ocasionados por sombra de radar e ausência de cobertura em grandes latitudes e menciona os modelos ASTER GDEM e ALOS AW3D, os quais são baseados em processamento fotogramétrico de imagens ópticas e podem apresentar artefatos e vazios ocasionados por nuvens.

THEOBALD *et al.* (2015) desenvolveram o conjunto de dados *SRTM Landforms*, que classifica as formas de relevo a partir do MDE SRTM com base na orientação solar e na posição da encosta, critérios com grande estabilidade temporal, com objetivo de calcular o poder explanatório das variáveis fisiográficas sobre os indicadores de biodiversidade. As posições das encostas foram definidas como picos/cumes, encostas superiores, encostas inferiores e fundos de vale. Quanto à insolação, utilizaram uma estimativa de radiação incidente e carga de calor, que combina a declividade, a orientação e a latitude para prever efeitos ecológicos da radiação direta potencial, e definiram as diferentes porções da paisagem como *quente*, *neutra* e *fria*. De acordo com os autores, a carga de calor tem relação com a evapotranspiração, que afeta a distribuição da vegetação.

LIU *et al.* (2019) afirmam que a elevação, a declividade e a orientação do terreno são parâmetros biogeográficos importantes e controlam a distribuição e o crescimento vegetal. Ainda, que os parâmetros topográficos aumentam a separabilidade das classes e contribuem com uma melhora de mais de 10% na exatidão global de classificação de tipos florestais.

CHIANG & VALDEZ (2019) conduziram experimentos de classificação de diferentes espécies florestais na Mongólia utilizando dados ópticos Landsat 8 e variáveis topográficas como elevação, declividade, orientação e índice topográfico de umidade (TWI) extraídas do modelo digital ASTER GDEM e, apesar dos dados topográficos por si só não fornecerem informações suficientes para a classificação de espécies, estes apresentaram maior importância que os dados espectrais. A utilização conjunta de dados topográficos e espectrais com o classificador *Maximum Entropy Text Classifier* resultou em uma exatidão de 81% enquanto apenas com dados ópticos de 71%.

XIE *et al.* (2021) utilizaram dados SRTM como parte do conjunto de dados para analisar a distribuição regional de espécies florestais afirmam que a declividade e a orientação do terreno são fortemente ligadas à distribuição da vegetação, bem como amplamente utilizadas em pesquisas florestais. Os autores extraíram as camadas de declividade e orientação do MDE SRTM e reclassificaram os valores de variáveis contínuas para variáveis categóricas e afirmam que os dados geomorfológicos podem auxiliar na classificação de tipos florestais pois a ocorrência de determinadas espécies é restrita à locais de maior altitude ou de maior declividade, por exemplo.

2.8 Processamento de imagens

O processamento de imagens de sensoriamento remoto consiste na operação matemática sobre dados matriciais realizadas por algoritmos específicos. Correções de distorções geométricas, atmosféricas e de posicionamento compõe a fase de pré-processamento, e a fase de processamento engloba operações aritméticas, filtros de textura, classificação, entre outras (MENESES, 2012).

A detecção de nuvens e de sombras de nuvens é um problema de processamento de imagens ópticas, especialmente nuvens semitransparentes, quando a reflectância observada contém uma mistura de sinais de superfície terrestre e nuvens. A detecção das sobras de nuvens é complexa devido à baixa reflectância e confusão com *pixels* de água, de áreas queimadas ou de sombreamento topográfico, o que demonstra a importância de máscaras confiáveis, as quais podem ser obtidas somente automaticamente (BAETENS *et al.*, 2019). Os dados Sentinel-2 nível 1C contém máscara de nuvens com indicador de tipo de nuvem, sejam nuvens densas ou *cirrus*, e o percentual de *pixels* com nuvens. A máscara de nuvens permite a

identificação de *pixels* sem nuvens, processamento que é realizado com resolução espacial de 60m para todas as bandas. As nuvens densas apresentam alta reflectância na região espectral azul (B2). Para evitar confusão entre neve e nuvens, a reflectância no Infravermelho de ondas curtas (SWIR, B11 e B12) é utilizada, pois as nuvens apresentam maior reflectância nesta região espectral. Já as nuvens *cirrus* são finas e o método de identificação é baseado na banda 10 (B10, 1375nm) exclusiva para detecção de *cirrus*, nuvens de altitude aproximada de 6-7km (MULLER-WILM, 2019).

O *Google Earth Engine* (GEE) é uma plataforma de computação em nuvem onde estão armazenados *petabytes* de conjuntos de dados prontos para análise (GORELICK *et al.*, 2016), dentre eles dados SRTM (*Shuttle Radar Topography Mission*), dados SRTM *Landforms*, dados das missões Sentinel-1-2, dados da série Landsat, dados climatológicos, algoritmos de classificação como *Random Forests*, *Classification and Regression Tree* e *Support Vector Machine*, além de outras funções embutidas na plataforma para operação de dados matriciais e vetoriais.

A agregação temporal é uma técnica de processamento de imagens definida pelo uso de métricas (média, mediana, variância, entre outras) aplicadas a medidas tais como reflectância ou NDVI em um período determinado com o objetivo de preencher espaços vazios gerados por procedimentos automatizados de mascaramento de nuvens. Devido ao alto poder computacional o GEE pode processar centenas de imagens rapidamente gerando uma única imagem, reduzindo significativamente o volume final de dados (CARRASCO *et al.*, 2019). STROMANN *et al.* (2020) aplicam redutores de média e desvio padrão à empilhamentos de imagens Sentinel-1 e afirmam que o ruído *speckle* é reduzido enquanto ainda captura as variações temporais das diferentes classes de uso e ocupação do solo.

HARALICK *et al.* (1973) apresentam a Matriz de Co-ocorrência de Níveis de Cinza (GLCM), uma técnica de processamento para extração de características de textura da imagem. De acordo com os autores a textura contém informações sobre o arranjo estrutural de superfícies e nas imagens digitais corresponde à distribuição espacial dos níveis de cinza. Os índices de GLCM são calculados com base na contagem da frequência com que pares de pixels com níveis de cinza específicos em uma determinada relação espacial ocorrem na matriz e a inclusão de uma camada de

textura normalmente aumenta a exatidão do processo de classificação, não importando o método de decisão utilizado.

De acordo com HALL-BAYER (2017) as texturas GLCM apresentam sucesso no aumento das exatidões de classificação e são extensivamente utilizadas em estudos florestais, onde as texturas são formadas por diferentes padrões de sombreamento devido às diferenças estruturais das árvores. As texturas GLCM *Contrast* e *Entropy* estão associadas ao grau de variação da tonalidade de cinza, as quais apresentam correlação com a biomassa florestal uma vez que o retroespalhamento aumenta em um dossel acidentado e diminui em dosséis mais jovens, nos quais o dossel está normalmente disposto em apenas uma camada (KUPLICH *et al.*, 2005).

2.9 Classificação de imagens

Os algoritmos de aprendizagem de máquina tornaram-se parte integrante dos estudos de sensoriamento remoto nos últimos anos por possibilitarem a realização de classificações de uso e cobertura do solo (WHITE, 2018). A classificação digital de imagens proporciona a automatização da extração de informações das imagens diminuindo a influência da subjetividade da interpretação humana. O resultado final da classificação é uma imagem digital de pixels classificados por cores que representam as classes alvo, chamada de mapa temático (MENESES, 2012).

A aplicação de algoritmos de classificação no sensoriamento remoto frequentemente é baseada em classificadores por *pixel*. Essas técnicas são baseadas na atribuição de *pixels* à uma classe com base nas suas características espectrais. Os métodos de classificação são ditos não supervisionados quando os *pixels* são agrupados por sua similaridade espectral em um número de classes estipulado pelo classificador, chamadas *clusters*; ou supervisionados, quando os *pixels* são atribuídos a um conjunto de classes predefinidas e caracterizadas espectralmente pelo usuário. Na classificação supervisionada a qualidade da classificação depende dos dados rotulados como de treinamento, pois estes dados devem ser representantes estatísticos da superfície para que o classificador tenha um desempenho satisfatório (WHITE, 2018). A aquisição de dados de treinamento é um componente dispendioso em um programa de mapeamento e existe o desejo de reduzir o volume destes dados particularmente em ações de recursos limitados como as relacionadas à conservação da biodiversidade, pois os recursos financeiros necessários para o levantamento

destes dados *in situ* aumenta à medida que aumenta o volume de dados. A classificação binária pode requerer um número menor de amostras de treinamento, reduzindo erros mesmo quando há sobreposição espectral de classes (FOODY, 2007).

Os algoritmos de classificação supervisionada não-paramétricos embutidos no GEE, *Support Vector Machine* (SVM), *Classification and Regression Tree* (CART) e *Random Forest* (RF), têm sido amplamente utilizados em diferentes estudos (TASSI & VIZZARI, 2020; SULOVA & ARSANJANI, 2021; PRATICÒ *et al.*, 2021). Segundo a revisão publicada por TAMIMINIA *et al.* (2021), estes são os algoritmos de classificação não-paramétrica mais utilizados em estudos no GEE.

Os SVM são baseados na teoria de aprendizagem estatística e têm o objetivo de determinar a localização dos limites de decisão que produzem a separação ideal de classes. Assim, o limite de decisão selecionado será aquele que deixa a maior margem entre as duas classes, onde a margem é definida como a soma das distâncias dos pontos mais próximos das duas classes ao hiperplano. Se as duas classes não são linearmente separáveis, o SVM tenta encontrar o hiperplano que maximize a margem e, ao mesmo tempo, minimize uma quantidade proporcional ao número de erros de classificação (PAUL & MATHER, 2005). O CART é um classificador de decisão binária de árvore única. Um atributo divide os dados em subconjuntos em cada nó da árvore com base no ganho de informação normalizado, resultando no atributo de definição da divisão. O atributo com o maior valor de ganho de informação normalizado é escolhido para tomar a decisão final (PRATICÒ *et al.*, 2021). O RF está entre os mais populares pois é um meio de melhorar a precisão das árvores de classificação e regressão através da combinação de um grande número de subconjuntos aleatórios de árvores, onde cada árvore contribui com um voto e a classificação final é determinada pela maioria dos votos, levando em consideração todas as árvores (SOTHE *et al.* 2017; XIE *et al.* 2021).

CONGALTON & GREEN (2009) consideram que a avaliação da exatidão do processo de classificação de imagens encontra-se na era da matriz de erro, que é uma matriz quadrada que expressa os rótulos de amostras designadas a uma classe em uma classificação relativa aos rótulos de amostras designados a uma determinada classe em outra classificação. Estas matrizes são representações muito eficientes de exatidão de mapas pois as exatidões individuais de cada classe são descritas pelos

erros de inclusão (erros de comissão) e erros de exclusão (erros de omissão) presentes no mapa. Um erro de comissão ocorre quando uma área é incluída na classe incorreta, já um erro de omissão ocorre quando uma área é excluída da classe à qual pertence. Todo erro em um mapa é uma omissão da categoria correta e uma comissão a uma categoria incorreta. A exatidão global é dada pelo quociente entre a soma da diagonal principal (amostras classificadas corretamente) pelo número total de amostras na matriz de erro. As exatidões do usuário e do produtor estão relacionadas aos erros de comissão e de omissão, respectivamente,

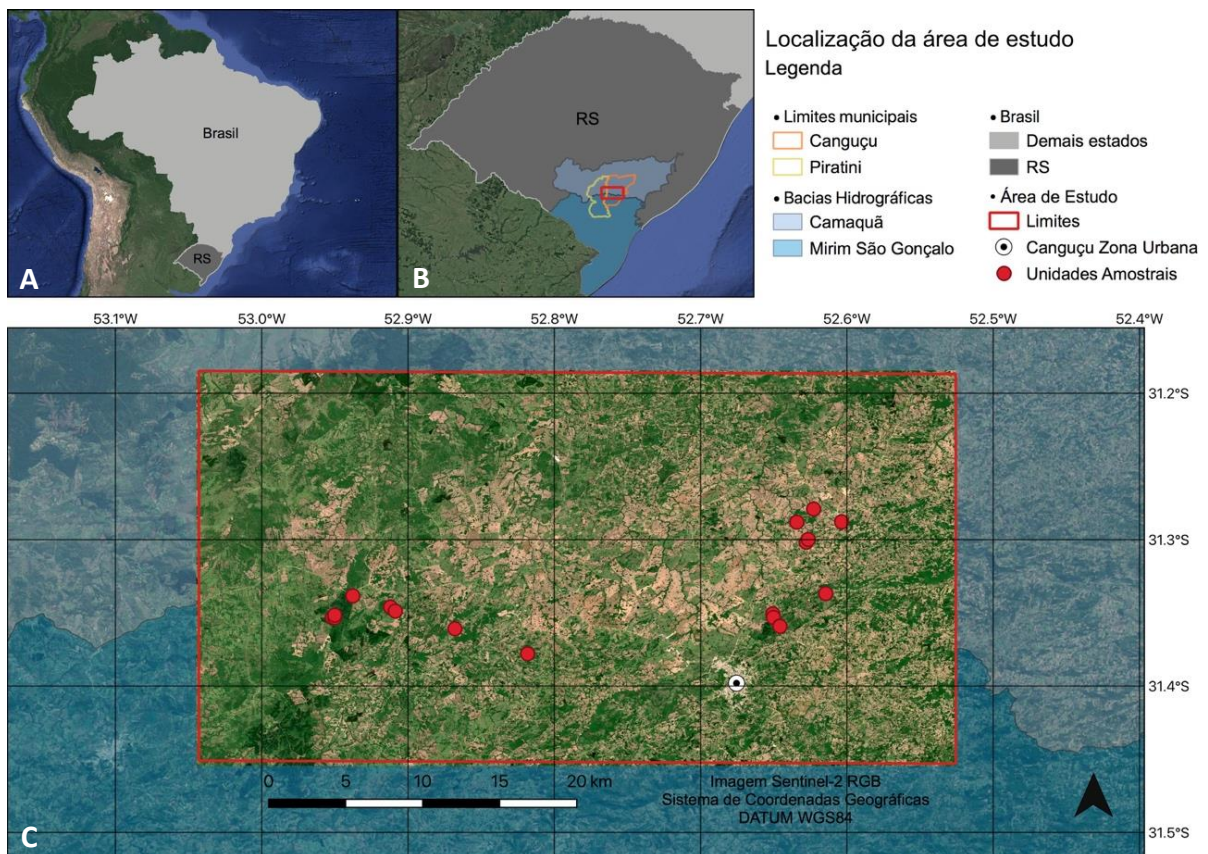
O coeficiente Kappa é utilizado em sensoriamento remoto como um avanço em relação à exatidão global, pois corrige a proporção de casos corretamente classificados pela proporção esperada de casos corretamente classificados por acaso. Apesar de amplamente aceito e utilizado, PONTIUS & MILLONES (2011) e FOODY (2020) fazem uma revisão dedicada a evidenciar a inadequação deste índice para avaliação de exatidão de classificação e reiteram o uso das exatidões global, do usuário e do produtor como medidas indicadas para tal.

3 METODOLOGIA

3.1 Área de Estudo

A área de estudo foi definida como o retângulo envolvente da área prioritária para conservação da biodiversidade considerada na revisão de 2007 denominada Altos de Canguçu. É formada por porções dos municípios de Canguçu e Piratini, abrange aproximadamente 1450 km² e está dividida entre as bacias hidrográficas do Camaquã e do Piratini-São Gonçalo-Mangueira. Sua localização é dada na **Figura 3**.

Figura 5: Localização da área de estudo. A) Localização do Rio Grande do Sul no Brasil. B) Localização de Canguçu, Piratini e das bacias hidrográficas do Camaquã e do Mirim-São Gonçalo no RS. C)




Fonte: o Autor.

3.1.1 Clima

O Rio Grande do Sul apresenta, de acordo com a classificação de Köppen-Geiger, clima subtropical úmido, oceânico, sem estação seca, com verão quente (Cfa) ou verão temperado (Cfb). O clima Cfa compreende a maior parte da área do Estado, já o clima Cfb está relacionado aos locais de maior altitude ou onde a temperatura média do mês mais quente não exceda 22°C (ALVARES *et al.*, 2013). Foram

analisados os dados históricos mensais de temperatura e de precipitação para o período de 2009 a 2019, coletados pela estação meteorológica de Canguçu (latitude -31.40333, longitude -52.700833, altitude: 446,81m) e processados e disponibilizados pelo Instituto Nacional de Meteorologia. A temperatura média mais baixa foi de 11,25 °C, em julho, e a mais alta 21,76 °C em janeiro, como observado na Figura 4.

Figura 6: Dados médios de precipitação (mm) e de temperatura (°C) mensais adquiridos pela estação meteorológica Canguçu (A811) para o período de 2009-2019.



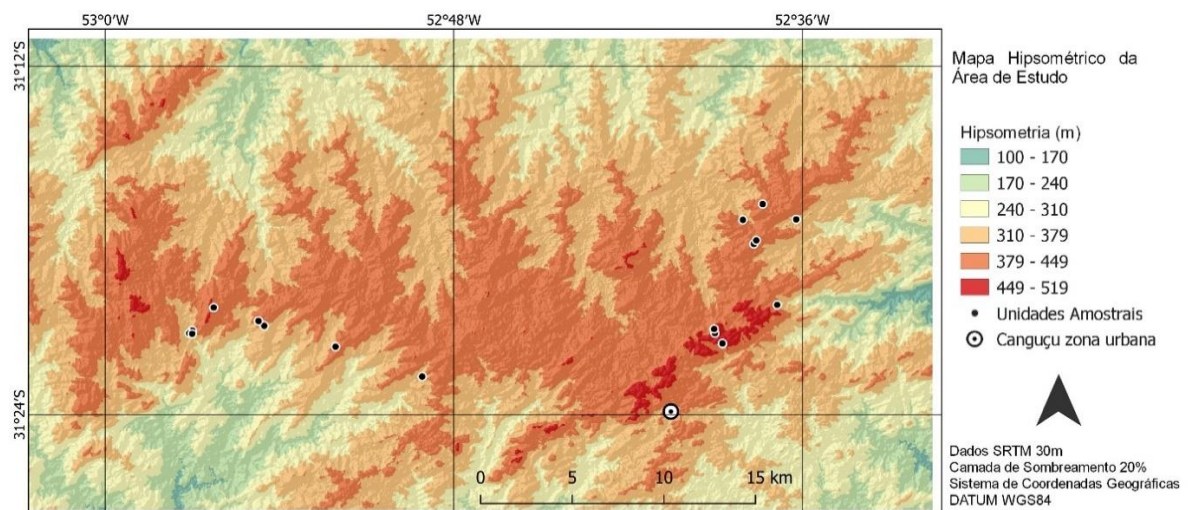
Fonte: o Autor.

CAPORAL & BOLDRINI (2007), ao realizarem estudos da vegetação campestre em Canguçu adotaram clima Cfb para a região e mencionam frequentes períodos de estiagem entre dezembro e março, redução nas chuvas em junho e julho e ocorrência de geadas de abril a outubro. ALVARES *et al.* (2013) ao realizarem o mapeamento da classificação climática de Köppen-Geiger para o Brasil indicam a maior ocorrência do clima Cfb no Rio Grande do Sul no Planalto das Araucárias; já a região da área de estudo apresenta clima Cfa com ilhas de clima Cfb. WREGGE *et al.* (2016, 2017) simularam a ocorrência futura de *Araucaria angustifolia* utilizando duas Trajetórias Representativas de Concentrações de gases de efeito estufa até o ano de 2100 propostas pelo IPCC (*Intergovernmental Panel on Climate Change*): RCP 4.5 (menos pessimista) e RCP 8.5 (mais pessimista) e em ambas as simulações as áreas de nicho fundamental para espécie na Serra do Sudeste do Rio Grande do Sul desaparecem totalmente a partir do ano 2041 devido às mudanças climáticas. FRITZSONS *et al.* (2018) considera esta espécie como um indicador do clima Cfb.

3.1.2 Geologia, Geomorfologia e Solos

A área localiza-se no Planalto Sul-Rio-Grandense, formação granítica que corresponde ao segmento sul da Província da Mantiqueira, sobre o Cinturão Dom Feliciano. Os Cinturões Móveis Neoproterozóicos são formados por áreas de planaltos, serras e depressões em terrenos dobrados e falhados, cuja evolução está ligada ao desenvolvimento de tais falhas; neste caso a mais expressiva é a Zona de Cisalhamento Transcorrente Dorsal de Canguçu, que apresenta mais de 250km. O relevo apresenta morros, serras baixas, planaltos esparsos e predominantemente as coxilhas, que são morros amplos com vertentes suaves. As altitudes variam entre 100 a 519 metros, podendo ocorrer desnivelamentos de 200 metros (DANTAS, 2010; WILDNER & LOPES, 2010). Conforme a classificação proposta pela EMBRAPA (1979), a declividade do relevo da região varia entre Plano, Suave Ondulado, Ondulado e Forte Ondulado. Conforme o mapa pedológico 1:5000000 (IBGE, 2006) proposto pelo IBGE são encontrados na área os Argissolos Vermelho-Amarelos Distrófico, caracterizados por boa drenagem e baixa fertilidade natural, geralmente profundos; os Neossolos Litólicos Eutróficos, que apresentam horizonte A ou O sobre horizonte C constituído majoritariamente por cascalhos e matacões, pouca profundidade e sujeitos à degradação por arenização; e os Planossolos Hidromórficos Eutróficos, que são solos mal drenados encontrados em áreas de várzea, de textura mais arenosa (KÄMPF & STRECK, 2010).

Figura 7: Mapa hipsométrico da área de estudo.

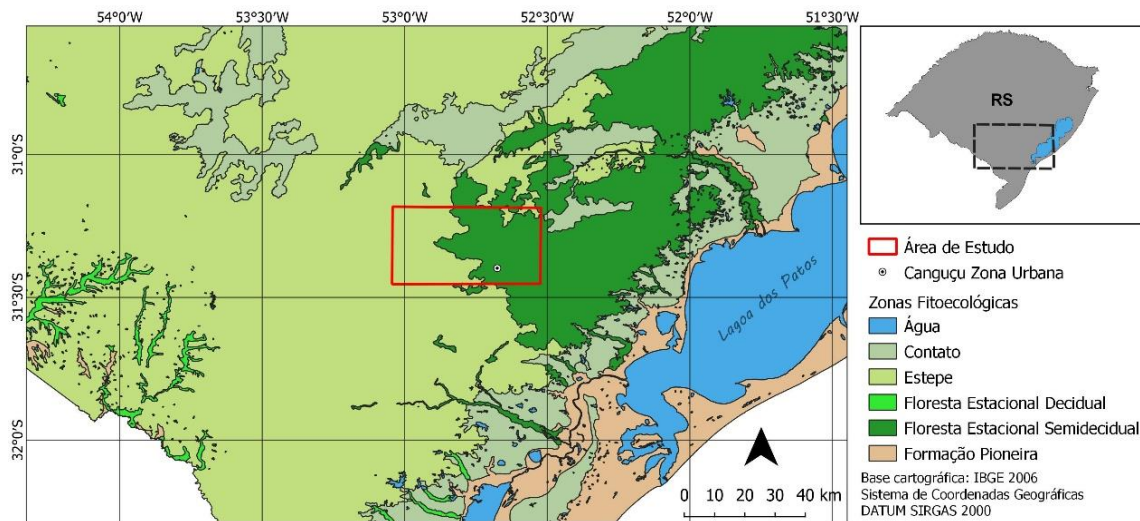


Fonte: o autor.

3.1.3 Vegetação

A área de estudo está localizada no bioma Pampa e o mapeamento das regiões fitoecológicas realizado pelo IBGE (2006) propõe a classificação das formações vegetais da área de estudo como Estepe e Floresta Estacional Semidecídua (IBGE, 2006), configurando um ambiente de transição, apresentado na Figura 6.

Figura 8: Regiões fitoecológicas propostas pelo IBGE (2006).



Fonte: o autor.

O mosaico campo-floresta é a fisionomia dominante da paisagem, alterada por uso antrópico rural, como apontado por CORDEIRO & HASENACK (2009). Os remanescentes florestais são frequentemente encontrados em encostas e nas margens de cursos hídricos e como abordado por CARLUCCI *et al.* (2011), há ocorrência de *Araucaria angustifolia* em núcleos, os quais são pequenos, porém fitogeograficamente importantes devido à latitude, como representado na Figura 7. A floresta com Araucária apresenta tendência natural de expansão sobre o campo, movimento obstruído pelas ações de fogo e pastoreio (BEHLING *et al.* 2009).

Os estudos de caracterização da vegetação na Serra do Sudeste são escassos. JURINITZ & JARENKOW (2003) estudaram um remanescente de Floresta Estacional Semidecídua primária em Camaquã/RS, que é a referência mais citada em estudos do componente arbóreo na Serra do Sudeste.

Na área de estudo as principais espécies que compõem os fragmentos da floresta secundária são *Ocotea pulchella* (canela-lageana), *Blepharocalyx salicifolius* (murta), *Sebastiania commersoniana* (branquilha), *Casearia decandra* (guaçatunga), *Myrcianthes gigantea* (araçá-do-mato), *Cupania vernalis* (camboatá-vermelho),

Zanthoxylum rhoifolium (mamica-de-cadela), *Vitex megapotamica* (tarumã), *Nectandra megapotamica* (canela-preta) e *Allophylus edulis* (chal-chal).

Figura 9: Representação do mosaico campo-floresta com presença de *Araucaria* em Altos de Canguçu/RS.



Fonte: o Autor.

3.2 Dados de sensoriamento remoto

3.2.1 Modelo Digital de Elevação

Foi utilizado o produto SRTM versão 3.0 (*SRTM Plus*) disponível no GEE (USGS/SRTMGL1_003) em resolução de 1 arcseg (aproximadamente 30m). O objetivo desta versão foi o preenchimento de espaços vazios utilizando dados ASTER GDEM2 e Modelos Digitais de Elevação do USGS (USGS, 2021).

3.2.2 Dados Ópticos

Foi utilizada a coleção de imagens Sentinel-2 nível 2A disponível no GEE ('COPERNICUS/S2_SR') que fornece ortoimagens com valores de reflectância da superfície terrestre (*Bottom of Atmosphere*) corrigidas atmosféricamente (ESA, 2011).

3.2.3 Dados Radar

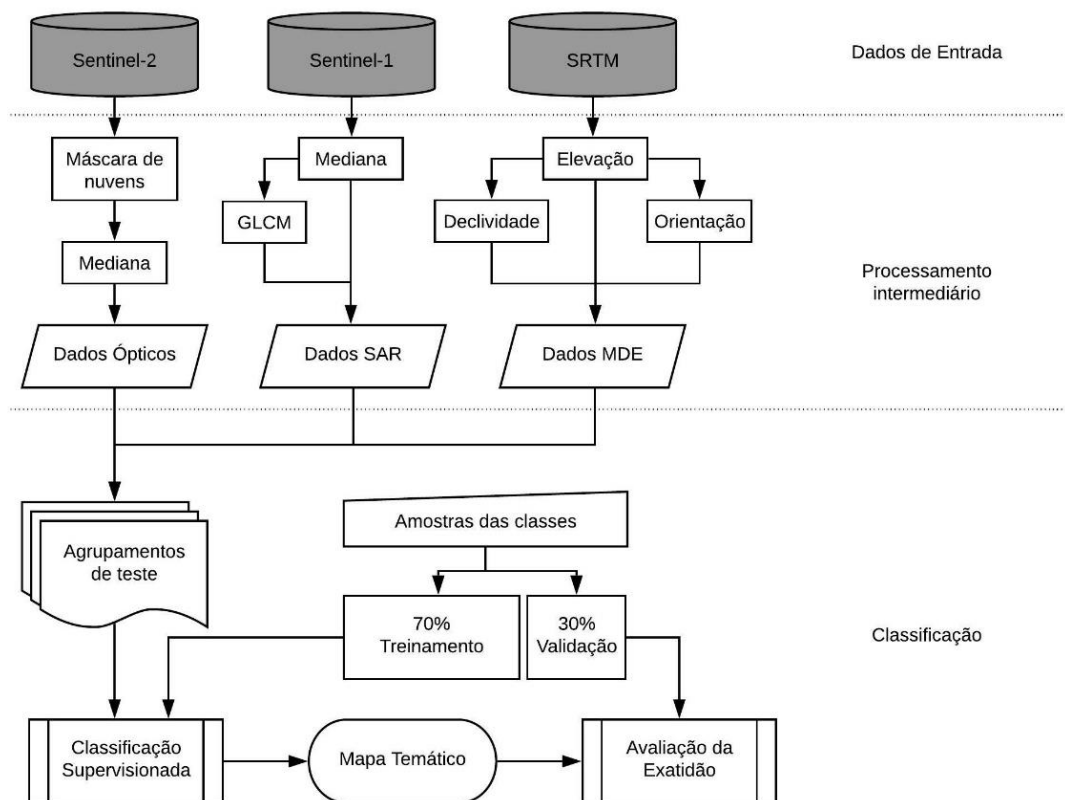
Foram utilizados dados da coleção de imagens Sentinel-1 nível GRD (*Ground Range Detected*) disponível no GEE ('COPERNICUS/S1_GRD') que fornece imagens

pré-processadas para remoção do ruído termal, calibração radiométrica e correção do terreno utilizando os dados SRTM de 30 metros ou ASTER DEM para áreas onde o SRTM não está disponível. As imagens GRD então são processadas para coeficiente de retroespalhamento (σ°) em decibéis (dB) por escala logarítmica (ESA, 2015).

3.3 Procedimentos metodológicos

Os procedimentos metodológicos incluíram a seleção e processamento de dados de sensoriamento remoto, a compilação de diferentes agrupamentos de dados para testes e a formação de subconjuntos das amostras para procedimentos de classificação e validação, os quais são apresentados em forma de fluxograma na Figura 8 e detalhados nos subitens seguintes.

Figura 10: Fluxograma de procedimentos metodológicos adotado.



Fonte: o Autor.


3.3.1 Processamento do Modelo Digital de Elevação

Foram geradas, a partir do Modelo Digital de Elevação, uma camada de declividade do terreno e uma camada de orientação das vertentes do terreno para a região de interesse utilizando funções de terreno embutidas no GEE (XIE *et al*, 2021).

3.3.2 Processamento dos dados ópticos

Foram processadas agregações temporais medianas para cada estação do ano de 2019 a fim de escolher a melhor composição óptica quanto à presença de nuvens, quanto à interpretação da imagem pelo usuário e quanto à separabilidade das classes. As agregações temporais medianas sazonais obtidas a partir dos dados Sentinel-2 estão representadas na Figura 9 como composições RGB. Foi selecionada a composição temporal de primavera por apresentar maior contraste entre as áreas agrícolas e as áreas de campo e por resultarem em uma composição livre de nuvens. Para isso foram selecionadas as imagens da região de interesse obtidas entre 9 de setembro e 22 de dezembro de 2019 que apresentassem cobertura de nuvens inferior a 10%. Sete imagens preencheram os critérios de seleção, as quais foram agregadas utilizando agregação temporal mediana (CARRASCO *et al.*, 2019). Para análise foram selecionadas as bandas B2, B3, B4, B5, B6, B7, B8, B8A, B11 e B12 com resoluções espaciais de 10 e 20m dependendo da banda. Um procedimento automático de mascaramento de nuvens foi aplicado utilizando a banda QA60. O Quadro 3 apresenta as imagens utilizadas para a composição da agregação temporal e o identificador (ID) de cada imagem no GEE.

Figura 11: Composições sazonais medianas obtidas para o ano de 2019. Verão (A), Outono (B), Inverno (C), Primavera (D).



Fonte: o Autor.

Quadro 3: Imagens Sentinel-2 nível 2A utilizadas para agregação temporal.

Imagem	ID
1	20190930T133229_20190930T133239_T22JCL
2	20191010T133229_20191010T133952_T22JCL
3	20191119T133219_20191119T133222_T22JCL
4	20191129T133219_20191129T133219_T22JCL
5	20191204T133221_20191204T133222_T22JCL
6	20191209T133219_20191209T133942_T22JCL
7	20191219T133219_20191219T133219_T22JCL

Fonte: o autor.

3.3.3 Processamento dos dados de Radar

Foram filtradas as imagens da região de interesse obtidas entre 9 de setembro e 22 de dezembro de 2019 (primavera) adquiridas no modo IW (*Interferometric Wide Swath*), na órbita relativa de número 24 e com resolução espacial de 10m. As imagens disponíveis são de banda dupla de polarização cruzada (VV+VH) em decibéis. Sete imagens preencheram os critérios de filtro, as quais foram agregadas utilizando agregação temporal mediana (CARRASCO *et al.*, 2019) para as duas bandas, ambas utilizadas para análise. O Quadro 4 apresenta as imagens utilizadas para a composição da agregação temporal e o identificador (ID) de cada imagem no GEE. A partir das medianas das bandas SAR foram calculadas três métricas baseadas na Matriz de Co-ocorrência de Níveis de Cinza propostas por HARALICK *et al.* (1973) utilizando uma matriz deslizante de 3x3 pixels. As métricas calculadas foram *Contrast*, que mede o contraste local da imagem, *Inverse Difference Moment (IDM)*, que mede a homogeneidade dos níveis de cinza e *Entropy*, que mede a aleatoriedade da distribuição dos níveis de cinza (TASSI & VIZZARI, 2020).

Quadro 4: Imagens Sentinel-1 nível 2A utilizadas para agregação temporal.

Imagem	ID
1	S1B_IW_GRDH_1SDV_20190929T084858_20190929T084923_018250_0225D6_C7AB
2	S1B_IW_GRDH_1SDV_20191011T084858_20191011T084923_018425_022B53_BE6D

3	S1B_IW_GRDH_1SDV_20191023T084858_20191023T084923_018600_0230AF_0841
4	S1B_IW_GRDH_1SDV_20191104T084858_20191104T084923_018775_023639_AEBC
5	S1B_IW_GRDH_1SDV_20191116T084858_20191116T084923_018950_023BEF_97B9
6	S1B_IW_GRDH_1SDV_20191128T084857_20191128T084922_019125_024183_8228
7	S1B_IW_GRDH_1SDV_20191210T084857_20191210T084922_019300_024710_4948

Fonte: o autor.

3.3.4 Classificação de estágios sucessionais

3.3.4.1 Levantamento de campo

Foi realizada etapa de campo para coleta de dados entre março e abril de 2020, os quais deram origem a camadas vetoriais para treinamento dos classificadores e validação das classificações. Foram coletados pontos das classes Campo, Agricultura, Silvicultura, Lâmina d'água, Floresta em Estágio Médio e Floresta em Estágio Avançado de regeneração. As amostras foram cadastradas manualmente como geometrias de pontos diretamente no GEE e seus quantitativos são apresentados no Quadro 5.

Quadro 5: Número de amostras por classe para treinamento e validação.


Classes	Número de Amostras
Lâmina d'água	47
Agricultura	57
Campo	44
Silvicultura	48
Floresta Secundária em Estágio Médio	108
Floresta Secundária em Estágio Avançado	87

Fonte: o autor.

Para determinação dos estágios sucessionais da floresta secundária foi realizado levantamento vegetal em 18 unidades amostrais (UA) de 1000m² (50x20m), método representado na Figura 10(A), instaladas aleatoriamente nos fragmentos

florestais, nas quais todos os indivíduos com circunferência à altura do peito (CAP) \geq 15,7 cm foram identificados quanto à espécie, tiveram o CAP medido com trena metálica e altura total estimada com vara graduada de quatro metros. Os vértices das UA foram demarcados com GPS, representado na Figura 10(B), e os estágios sucessionais da vegetação secundária classificados conforme a Resolução CONAMA 33/94, que define a vegetação primária e os estágios sucessionais da vegetação secundária para o Rio Grande do Sul.

Figura 12: Unidades Amostrais foram demarcadas com trenas de 20 e 50 metros no interior dos remanescentes, divididas em subunidades de 10x10m. (B): Foi realizada a marcação dos vértices das Unidades Amostrais com GPS Garmin eTrex10.



Fonte: o autor.

3.3.4.2 Classificação por aprendizagem de máquina

Foram utilizados os classificadores *Random Forest* (RF), *Classification and Regression Tree* (CART) e *Support Vector Machine* (SVM), todos implementados no GEE. O RF é o único dos classificadores que requer a definição do parâmetro ‘*numberOfTrees*’, que indica ao classificador o número de árvores de decisão a serem criadas. ERINJERY *et al.* (2018) utilizaram 10 e 100 árvores, TASSI & VIZZARI (2020) utilizaram 50 árvores, XIE *et al.* (2021) otimizaram o parâmetro implementando uma curva de aprendizagem que variou de 1 a 100 árvores e obtiveram um valor ótimo de 71 árvores; já para este estudo foram utilizadas 50 árvores. Os classificadores CART e SVM não requerem definições de parâmetros e foram utilizados em configuração padrão. Para o treinamento dos classificadores foi criado um subconjunto de dados de 70% das amostras das classes, as quais foram selecionadas aleatoriamente pelo GEE.

A fim de verificar o desempenho dos conjuntos de dados de sensoriamento remoto e suas sinergias para o aumento da exatidão da classificação, foram formados diferentes grupos de testes, conforme apresentado no Quadro 6.

Quadro 6: Agrupamentos de dados utilizados para comparação de desempenho de classificação.

Conjunto de dados de entrada	Descrição
OPT	Mediana MSI Sentinel-2 com 10 camadas (B2, B3, B4, B5, B6, B7, B8, B8A, B11 e B12)
OPT_DEM	OPT + Elevação, Declividade e Orientação do terreno
OPT_SAR	OPT + Mediana SAR Sentinel-1 com camadas VV e VH
OPT_DEM_SAR	Todos os descritos acima
OPT_DEM_SAR_GLCM	OPT_DEM_SAR + Métricas de textura GLCM <i>Contrast</i> , <i>IDM</i> e <i>Entropy</i> das camadas medianas de VV e VH

Fonte: o autor.

3.3.4.3 Validação

A avaliação da exatidão de classificação no sensoriamento remoto é importante pois informa a capacidade do classificador utilizado de identificar os alvos desejados em uma determinada imagem (XIE *et al.* 2021). O conjunto de amostras foi dividido em treinamento e validação aplicando a função *randomColumn()* do GEE, que adiciona uma coluna ao conjunto de dados com valores contínuos que variam entre 0 e 1 e divide o conjunto utilizando a proporção desejada. As amostras foram divididas em uma proporção de 70/30 para treinamento e validação, respectivamente. A avaliação de exatidão foi aplicada ao subconjunto de dados de validação, que avaliou a exatidão com base na matriz de confusão e a partir desta foram derivados a exatidão global e o índice Kappa (SULOVA & ARSANJANI, 2021).

4 RESULTADOS E DISCUSSÕES

4.1 Classificação de sucessão florestal

Foram realizadas 15 classificações de cobertura do solo na área de estudo utilizando três classificadores de aprendizagem de máquina (RF, CART e SVM) e cinco conjuntos de dados que incluíram dados ópticos, geomorfométricos, SAR e texturas derivadas a fim de avaliar o seu potencial individual e sinérgico para classificação de estágios de sucessão da vegetação florestal nativa. O Quadro 7 apresenta os resultados de exatidão global e índice kappa obtidos por cada classificador para cada um dos grupos. As Figuras 11 a 15 apresentam uma composição RGB da área de estudo para referência e as previsões de distribuição das classes de floresta por cada classificador acompanhada de sua matriz de confusão, organizadas por agrupamento de dados para fins de comparação.

O algoritmo *Random Forest* apresentou as maiores exatidões globais (93 a 97%), independente do conjunto de dados utilizados como entrada, com o índice kappa variando de 0,89 (dados ópticos e SAR) a 0,95 (dados ópticos, SAR e geomorfométricos). O CART atingiu valores muito próximos aos do RF, apresentando valores idênticos de exatidão global (92,5%) exceto para o conjunto de dados acrescido das camadas de textura SAR, que apresentou exatidão ligeiramente mais baixa (91,7%); o índice kappa variou de 0,89 a 0,91. O pior desempenho foi o da classificação de dados ópticos por SVM, resultando em 59% de exatidão e 0,37 de índice kappa, todavia, a sinergia de dados ópticos, SAR e geomorfométricos classificados por SVM atingiu 75% de exatidão, representando um aumento de 16,6% na exatidão e de 0,25 no índice kappa (0,62), sendo este o classificador que apresentou as variações mais significativas devido à inclusão de outras camadas de dados.

Em relação aos quantitativos absolutos e relativos estimados de área por classes de sucessão florestal, expressos no Quadro 8, os fragmentos florestais em estágio avançado apresentaram uma área relativa de 8,7 a 13,7% pelo RF, de 7 a 7,7% pelo CART e de 27,4 a 61,7% pelo SVM, observando-se semelhança entre as áreas relativas classificadas em estágio avançado por RF e CART e uma discordância total com o SVM, que superestimou esta classe. Já os fragmentos florestais em estágio médio apresentaram uma área relativa de 11,5 a 19,5% pelo RF, de 23 a 23,6% pelo

CART e de 0 a 11,6% pelo SVM. Considerando a sobreposição espectral destas classes e a confusão observada nas matrizes de erro das Figuras 11 a 15, a análise do somatório das áreas relativas classificadas como floresta (em ambos os estágios) variou entre 25,2 e 28,3% pelo RF, 30,6 e 30,7% pelo CART e 37,1 a 61,7% pelo SVM, indicando que o SVM superestimou as áreas destas classes.

Quadro 7: Valores de exatidão global e índice Kappa atingidos por cada classificador para cada agrupamento de dados utilizado.

Conjunto de Dados de entrada	SVM		RF		CART	
	Exat.	Kapp.	Exat.	Kapp.	Exat.	Kapp.
OPT	0,586	0,37	0,950	0,92	0,925	0,91
OPT_DEM	0,719	0,55	0,942	0,91	0,925	0,89
OPT_SAR	0,694	0,56	0,933	0,89	0,925	0,91
OPT_DEM_SAR	0,752	0,62	0,966	0,95	0,925	0,91
OPT_DEM_SAR_GLCM	0,719	0,52	0,950	0,92	0,917	0,89

Fonte: o autor.

Quanto aos quantitativos relativos de área estimada para as outras classes de uso da terra (Quadro 8), o CART apresentou as proporções de 16,3; 24,6 e 28,3% para Agricultura, Campo e Silvicultura, respectivamente, sem apresentar variações independentemente do conjunto de dados de entrada, sendo notada uma superestimativa para a classe de Silvicultura, todavia não é observada confusão entre a silvicultura e as classes de mata nativa. Já o SVM classificou de 20,5 a 33,4% como agricultura, de 11,3 a 20,8% como campo e de 0,6 a 16% como silvicultura. O RF variou entre 24,4% para agricultura, 28,3 e 31,6% para campo e 14,8 a 17% para silvicultura. Por fim, percebe-se grande estabilidade nos quantitativos estimados para a classe água por todos os classificadores variando entre 0,05% (CART), 0,18% (RF) e 0,22% (SVM), refletindo a pequena proporção desta classe na área de estudo.

Quadro 8: Mapa de Calor (em verde os valores mais baixos, em vermelho os mais altos por classe) de área absoluta e relativa estimada para cada classe para a área de estudo por classificador por conjunto de dados. AC: Agricultura; CA: Campo; SC: Silvicultura; AG: Água; FM: Floresta em Estágio Médio; FA: Floresta em Estágio Avançado. Áreas em km².

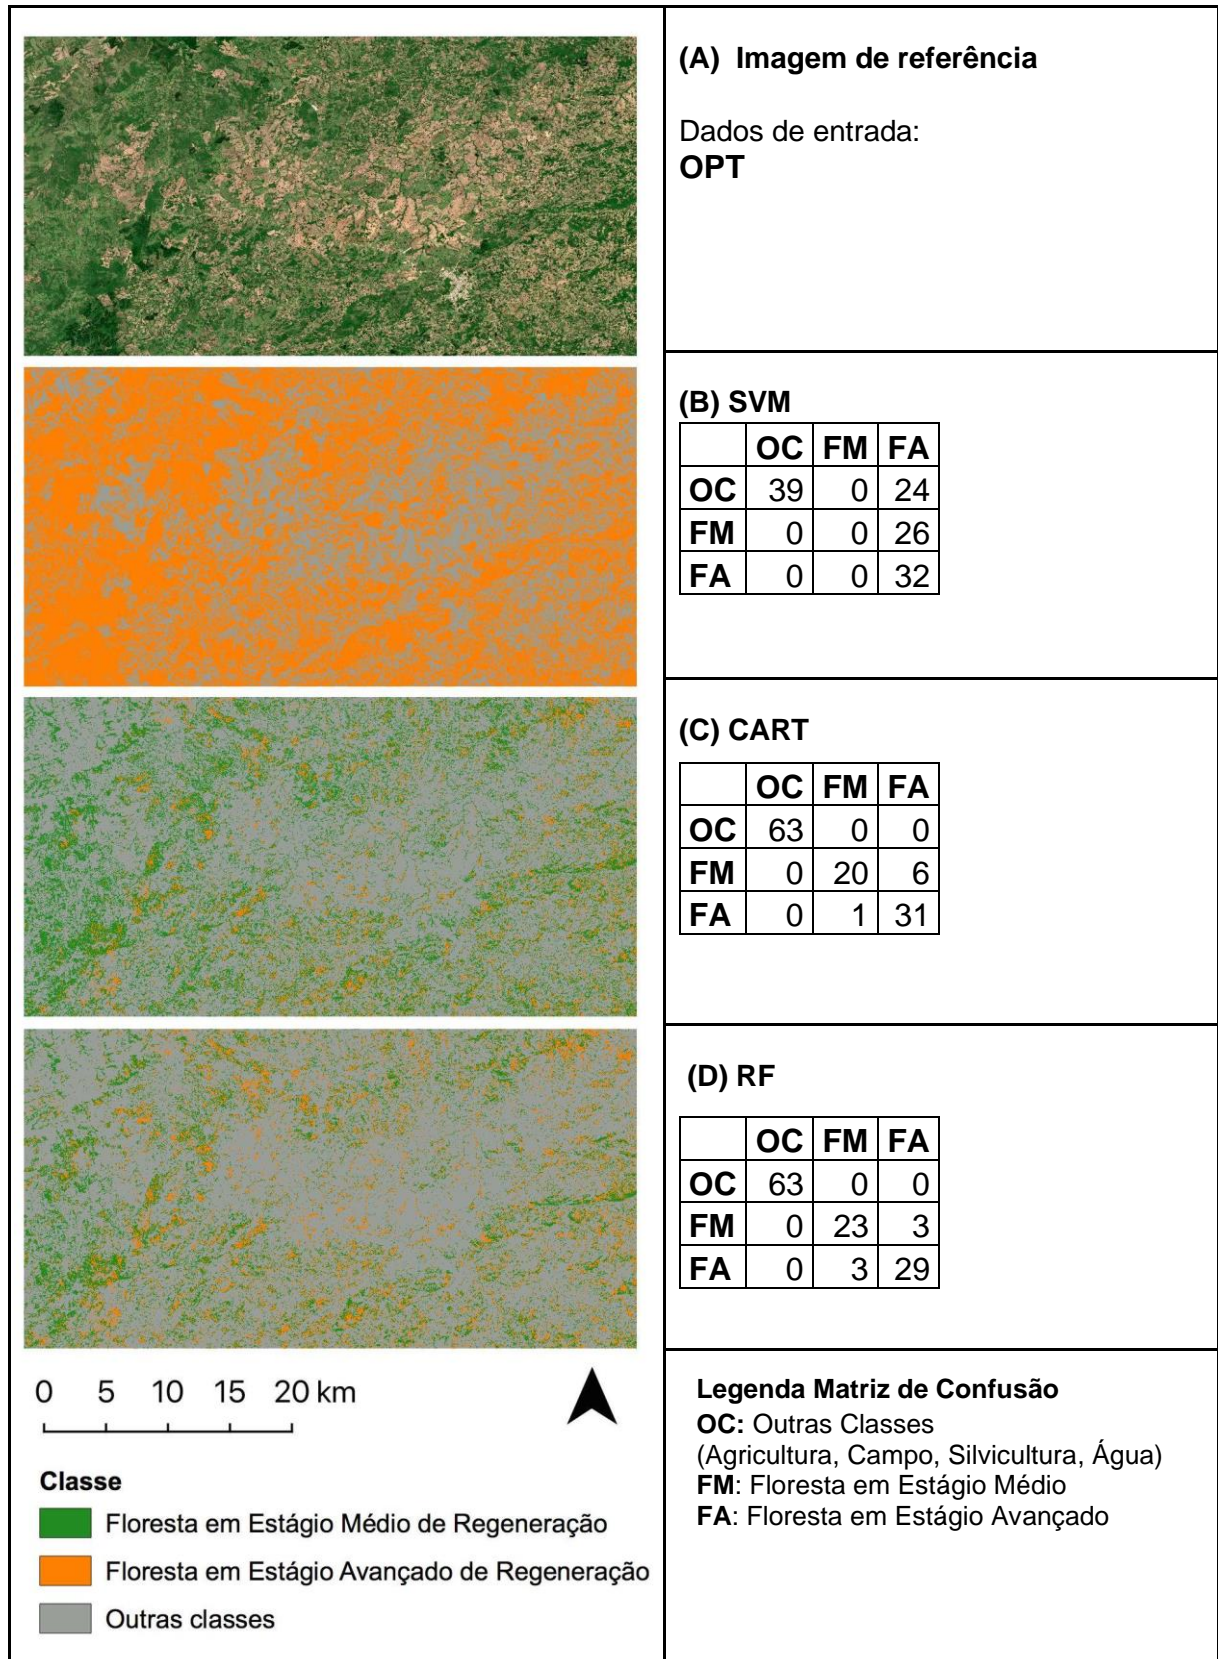
		AC		CA		SC		AG		FM		FA	
		Área	%	Área	%	Área	%	Área	%	Área	%	Área	%
OPT	SVM	388,4	26,3	166,3	11,3	8,2	0,6	2,8	0,19	0,0	0	912,5	61,7
O.DEM		419,2	28,4	265,1	17,9	54,9	3,7	3,2	0,22	176,1	11,9	559,3	37,8
O.SAR		303,4	20,5	307,9	20,8	237,1	16,0	2,6	0,18	51,5	3,5	575,7	38,9
ODS		493,9	33,4	268,7	18,2	164,2	11,1	2,4	0,16	144,0	9,7	404,7	27,4
ODSGLCM		419,3	28,4	265,1	17,9	54,2	3,7	3,2	0,22	176,1	11,9	559,2	37,8
OPT	CART	241,6	16,3	363,5	24,6	419,0	28,3	0,8	0,05	345,5	23,4	107,8	7,3
O.DEM		241,6	16,3	363,5	24,6	418,9	28,3	0,8	0,05	348,4	23,6	104,9	7,1
O.SAR		241,6	16,3	363,5	24,6	419,0	28,3	0,8	0,05	345,5	23,4	107,8	7,3
ODS		241,6	16,3	363,5	24,6	418,9	28,3	0,8	0,05	339,8	23,0	113,4	7,7
ODSGLCM		241,6	16,3	363,5	24,6	418,9	28,3	0,8	0,05	348,4	23,6	104,2	7,0
OPT	RF	412,8	27,9	444,8	30,1	237,2	16,0	2,4	0,16	223,5	15,1	157,6	10,7
O.DEM		407,5	27,6	425,1	28,8	246,5	16,7	2,6	0,18	201,1	13,6	195,0	13,2
O.SAR		402,2	27,2	418,4	28,3	251,8	17,0	2,2	0,15	274,2	18,5	129,5	8,8
ODS		360,4	24,4	445,6	30,1	251,8	17,0	2,5	0,17	288,4	19,5	129,2	8,7
ODSGLCM		417,6	28,3	467,1	31,6	218,3	14,8	2,7	0,18	170,3	11,5	201,9	13,7

Fonte: o autor.

Para todos os conjuntos de dados utilizados, os classificadores CART e RF não apresentaram confusão entre os pixels de floresta nativa e os pixels de outras classes, o que foi apresentado apenas pelo SVM em configuração predefinida (Figuras 11 a 15).

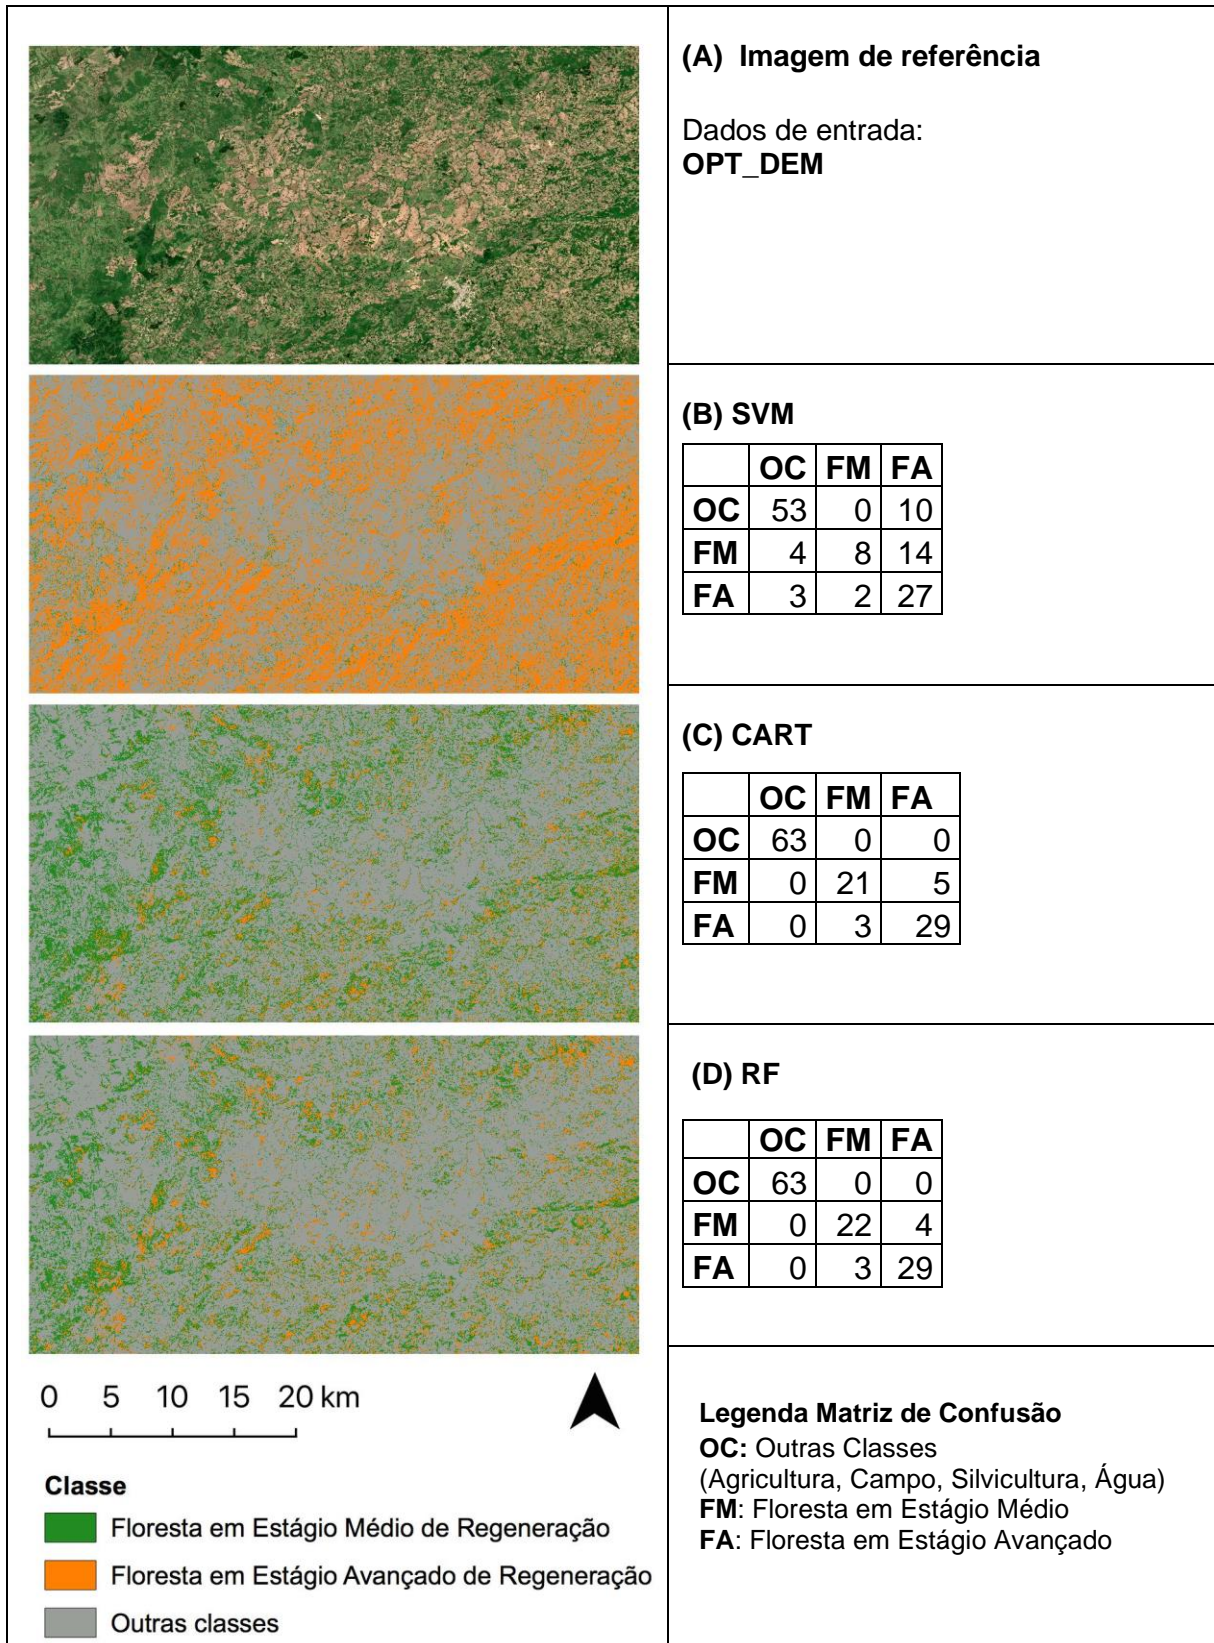
O conjunto de dados que obteve os melhores resultados de exatidão e índice kappa foi o de dados ópticos, SAR e geomorfométricos, apontando que esta sinergia tem potencial para classes que apresentam sobreposição espectral. As camadas de textura GLCM *Contrast*, *IDM* e *Entropy* das camadas medianas de VV e VH calculadas a partir de uma janela deslizante de 3x3 pixels não incorporaram os efeitos esperados de aumento nas exatidões.

Figura 13: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT.



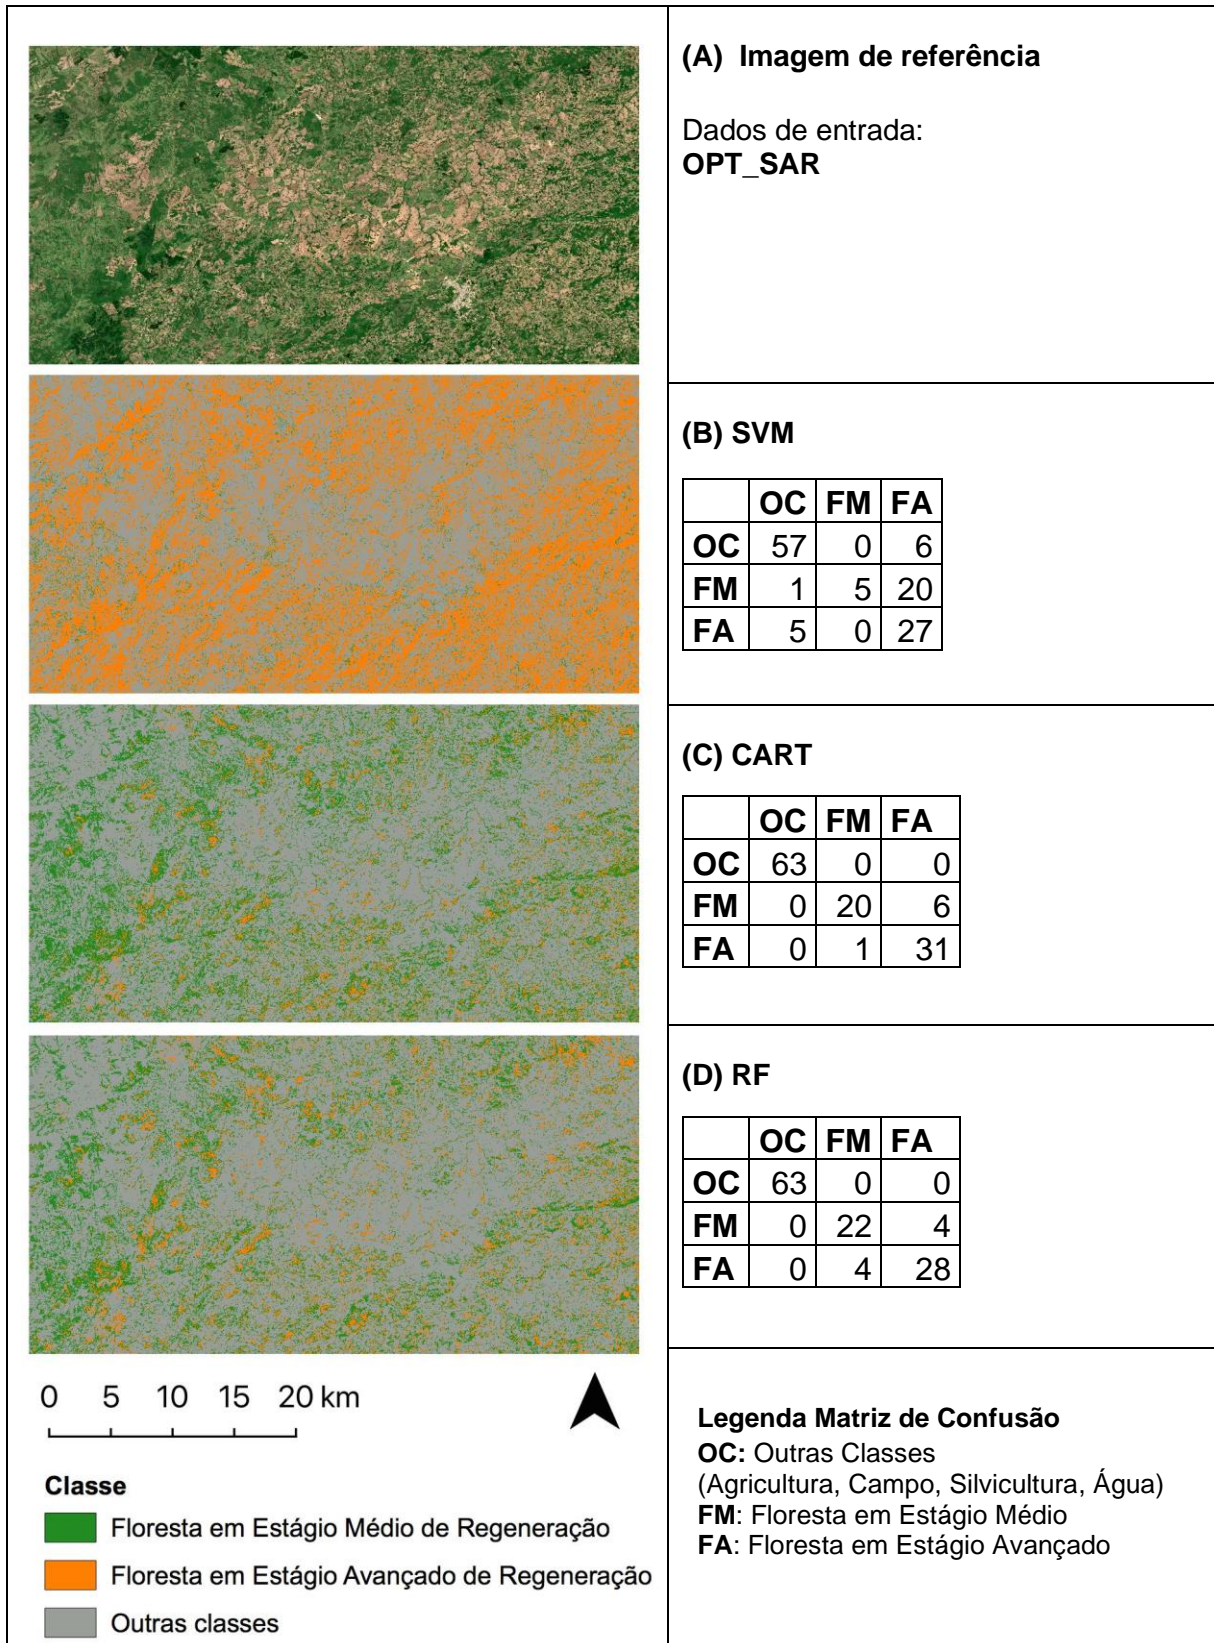
Fonte: o autor

Figura 14: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_DEM



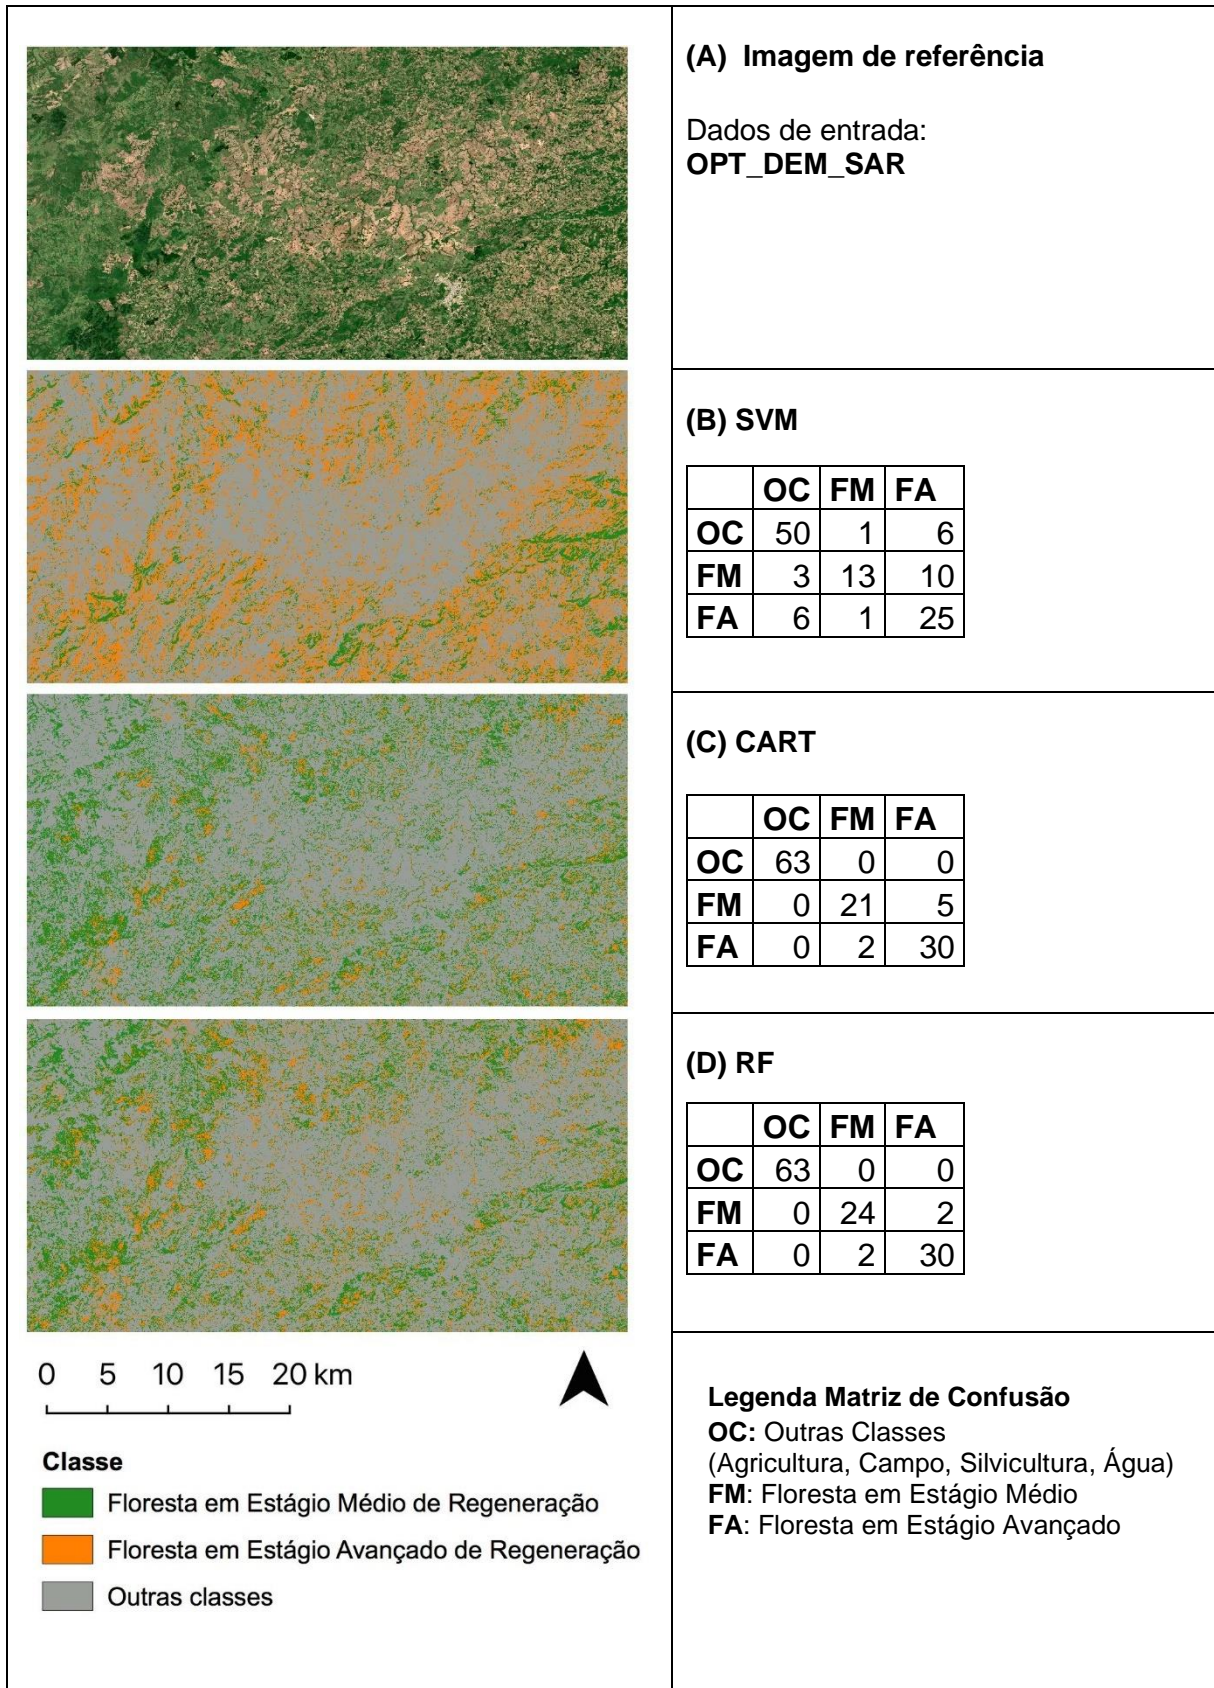
Fonte: o autor.

Figura 15: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_SAR



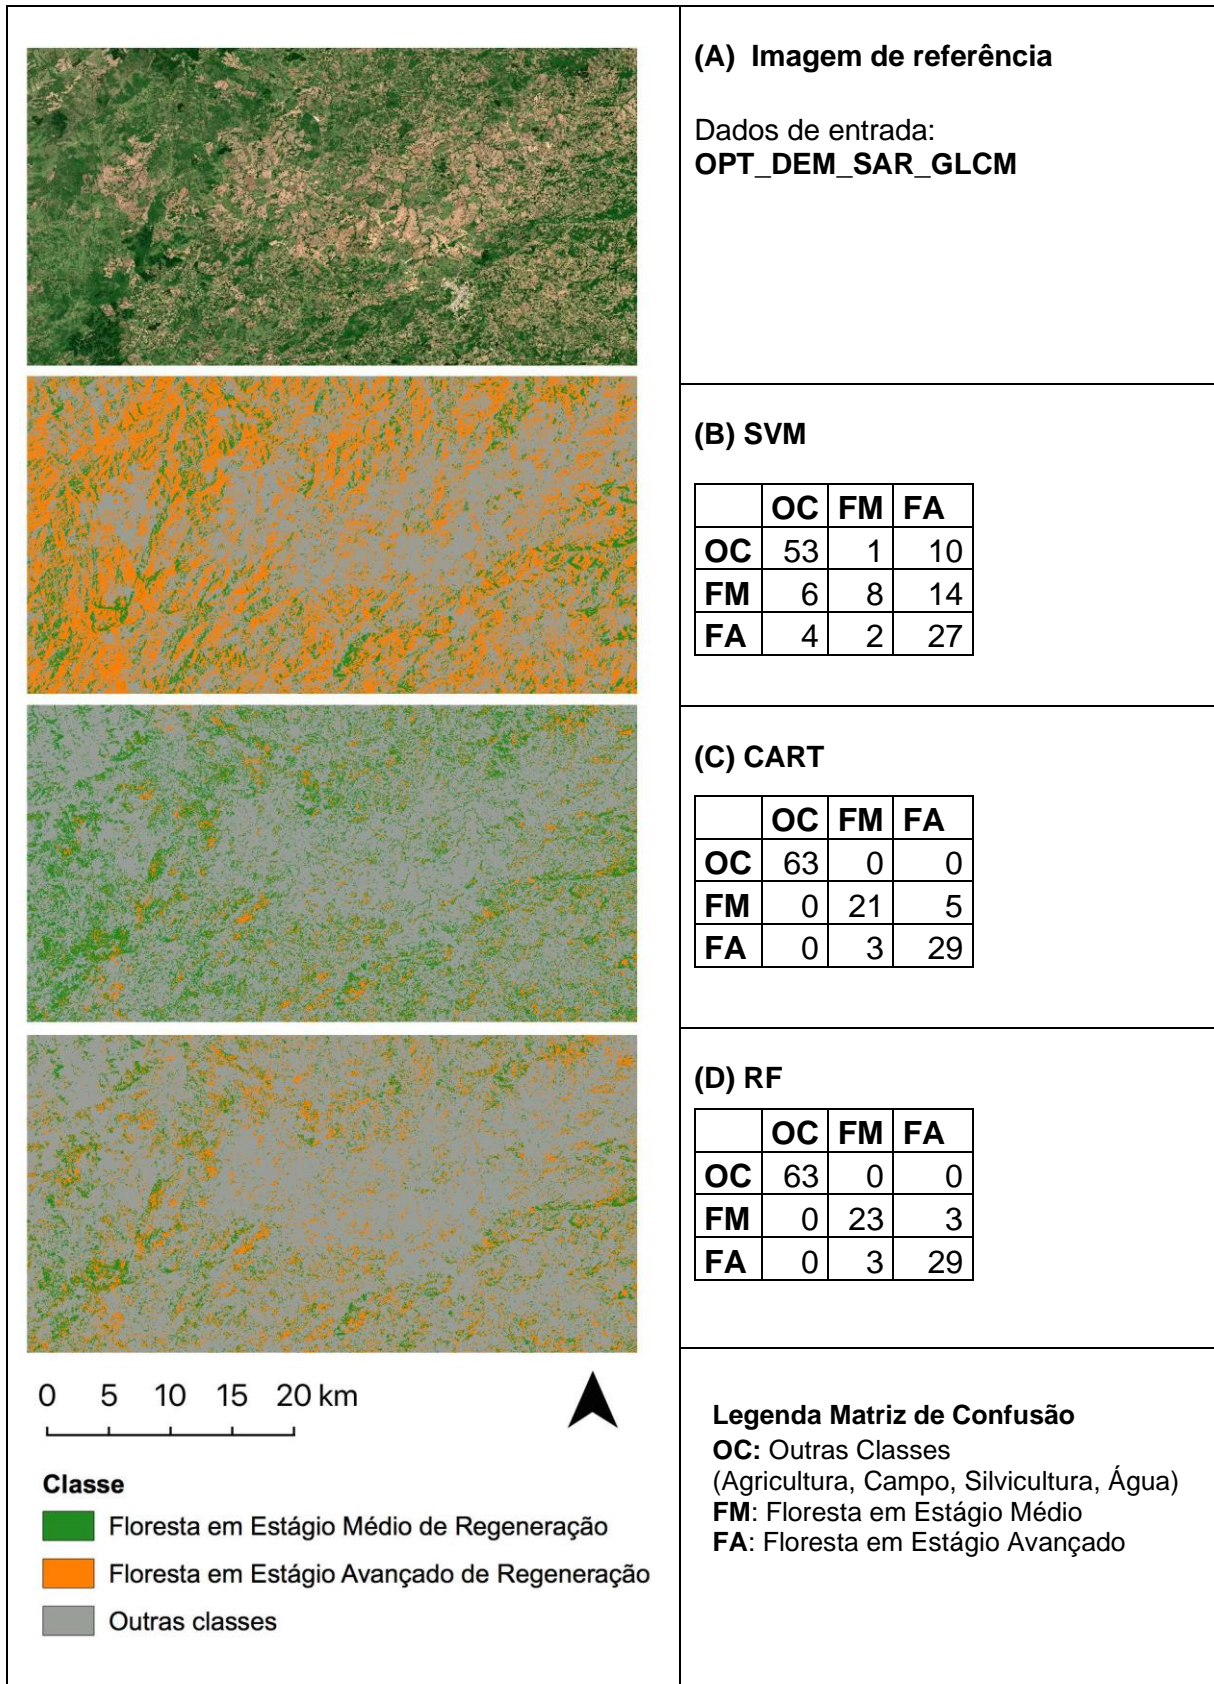
Fonte: o autor.

Figura 16: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_DEM_SAR



Fonte: o autor.

Figura 17: Classificações de estágios sucessionais por SVM, CART e RF e as respectivas matrizes de confusão para os dados de entrada OPT_DEM_SAR_GLCM



Fonte: o autor.

4.2 Discussões

A diferenciação florestal por sensoriamento remoto é considerada por LAURIN *et al.* (2013) como uma tarefa difícil devido à suavidade na transição entre os diferentes estágios sucessionais e a sobreposição espectral destas classes.

Autores reportam que a utilização de diferentes tipos de dados de sensoriamento remoto (ópticos, SAR, índices, modelos de terreno) tendem a melhorar o desempenho dos algoritmos, seja para classificação ou regressão. Ao mapear a distribuição de biomassa acima do solo FORKUOR *et al.* (2020) obtiveram exatidão de 90% realizando regressão por *Random Forest*, correlacionando variáveis biofísicas da vegetação com séries temporais óticas e índices derivados fusionados à dados de radar, totalizando 138 variáveis preditoras, reportando que os dados ópticos superam os dados de radar quando utilizados separadamente, todavia a complementariedade dos dois tipos de dados aumentara a exatidão de seus experimentos em relação à apenas um conjunto de dados. As camadas de dados ópticos também são consideradas por CHEN *et al.* (2019) como as mais fundamentais, e destacam a maior importância de camadas derivadas do MDE SRTM em relação às camadas SAR Sentinel-1, corroborando diversos dados obtidos neste estudo, como as grandes exatidões e concordâncias obtidas por RF e CART apenas com os dados ópticos Sentinel-2 bem como a melhora no desempenho SVM pela adição de camadas DEM e SAR.

Em relação ao algoritmo SVM, é mais sensível à qualidade dos dados de treinamento e o baixo desempenho de classificação atingido por este método neste estudo pode estar relacionado à heterogeneidade das amostras ou à presença de *outliers*, como indicado por PRATICÒ *et al.* (2021). SOTHE *et al.* (2017) obtiveram exatidão global superior a 98% utilizando SVM para classificação de estágios sucessionais em Santa Catarina adotando como dados de entrada todas as bandas Sentinel-2, indicando que a configuração de parâmetros do classificador como o tipo do *kernel*, bem como configurações de parâmetros do próprio *kernel* promovem o aumento do desempenho de classificação. Outro fator para o desempenho mais baixo do SVM nesta pesquisa está relacionado ao número de amostras de treinamento, pois STROMANN *et al.* (2020) o utilizaram com configuração predefinida para classificação de uso e cobertura da terra no GEE e geraram uma curva de aprendizagem do

classificador, a qual revelou que classificações com menos de 100 amostras resultaram em exatidões entre 60 e 70% e um aumento gradual da exatidão até aproximadamente 90% com 2000 amostras, indicando que o aumento do número de amostras de treinamento também é um fator de otimização fundamental para este classificador.

Em relação ao desempenho dos algoritmos de classificação em estudos florestais, PRATICÒ *et al.* (2021) utilizaram RF, SVM e CART para classificar os tipos florestais em uma região do Mediterrâneo, obtendo exatidões globais de 88%, 83% e 80%, respectivamente, utilizando índices espectrais e composições óticas sazonais.

De modo comparativo a outros estudos com os mesmos classificadores RF, CART e SVM no GEE, este trabalho apresentou desempenho semelhante ao de SHAHARUM *et al.* (2020) que mapearam cultivares de óleo de palma em regiões da península da Malásia atingindo exatidões globais de 86,5%, 80,08% e 93.16%, respectivamente. Apesar da exatidão global mais alta do SVM, os autores destacam que esse classificou amostras de óleo de palma como “outros tipos de vegetação” para uma das regiões analisadas e consideraram que os algoritmos baseados em árvores de decisão (RF e CART) foram mais eficientes, sendo que o RF teve melhor desempenho de maneira geral, como neste trabalho.

Neste estudo não se observou o proposto por HARALICK *et al.* (1973) e HALL-BAYER (2017), e a inclusão de camadas de textura ocasionou maior confusão nas classificações dos três algoritmos, resultando em exatidões globais mais baixas, e isto pode estar relacionado ao tamanho da janela utilizada para o cálculo destas métricas, visto que CHEN *et al.* (2019) reportam que ao utilizarem uma janela de 11x11 atingiram melhores valores de correlação.

5 CONCLUSÕES

Neste estudo foram avaliados os potenciais de diferentes conjuntos de dados de sensoriamento remoto e de algoritmos de aprendizagem de máquina para classificar estágios de sucessão de floresta secundária na Serra do Sudeste do Rio Grande do Sul através da plataforma de computação em nuvem *Google Earth Engine*.

Os dados disponibilizados pela missão Sentinel-2 são, por si só, capazes de fornecer informações para distinguir as classes propostas neste estudo com alto desempenho pelos classificadores CART e RF. Os dados da missão Sentinel-1 bem como os dados do MDE SRTM não promoveram aumento nas exatidões globais dos classificadores CART e RF, todavia seu uso sinérgico demonstrou potencial ligeiramente maior para classificação por RF. Mesmo com apenas 270 elementos de treinamento para todas as classes, sendo as classes de estágio sucessional médio e avançado com 75 e 60 amostras, respectivamente, os classificadores *Random Forest* e CART obtiveram desempenho de exatidão global superior a 90%. Estes algoritmos têm alto poder de classificação mesmo quando as classes alvo apresentam sobreposição espectral, quando o número de amostras de treinamento é limitado e, ainda, são de simples utilização, não requerendo a configuração de parâmetros avançados, o que os torna relevantes para classificação de estágios de regeneração da vegetação natural. Com os resultados obtidos neste trabalho, conclui-se que a sinergia entre dados ópticos, de radar e geomorfométricos apresentou maior potencialidade para a classificação dos estágios de sucessão médio e avançado da Floresta Estacional Semidecídua na Serra do Sudeste do Rio Grande do Sul quando submetidos ao classificador *Random Forest*.

O alastramento do coronavírus impediu a sequência na coleta de dados de treinamento e validação. Dados SAR banda L livre não foram utilizados por não haver livre acesso ou disponibilidade no GEE. Como perspectivas futuras, o cruzamento de dados NISAR e GEDI em plataformas de computação em nuvem para estimativas de biomassa acima do solo é a área de maior interesse.

FINANCIAMENTO

O presente trabalho foi realizado com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil, processo número 132457/2019-9, modalidade Mestrado – GM, com vigência de 01/03/2019 a 30/04/2021.

REFERÊNCIAS

- AGUILAR, Alexis. Remote Sensing of Forest Regeneration in Highland Tropical Forests. **Giscience & Remote Sensing**, volume 42, p. 66-79, 2005.
- ALVARES, C.A.; José Luiz Stape, Paulo Cesar Sentelhas, José Leonardo de Moraes Gonçalves e Gerd Sparovek. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, volume 22, p. 711 – 728, 2013.
- BAETENS, Louis, Camille Desjardins e Olivier Hagolle. Validation of Copernicus Sentinel-2 Cloud Masks Obtained from MAJA, Sen2Cor, and FMask Processors Using Reference Cloud Masks Generated with a Supervised Active Learning Procedure. **Remote Sensing**, volume 11, 2019.
- BEHLING, H. , Pillar, V. D., Müller, S. C. And Overbeck, G. E., Late-Holocene fire history in a forest-grassland mosaic in southern Brasil: Implications for conservation. **Applied Vegetation Science**, volume 10, p. 81-90, 2007.
- BEHLING, H. *et al.* Dinâmica dos campos no sul do Brasil durante o Quaternário Tardio, em: Pillar, V. De P.; Müller, S. C.; Castilhos, Z. M. De S.; Jacques, A. V. Á. (Org.). **Campos sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, p. 285-299, 2009.
- BEHLING, H., Pillar, V.P. And Bauermann, S.G. Late Quaternary grassland (Campos), gallery forest, fire and climate dynamics, studied by pollen, charcoal and multivariate analysis of the São Francisco de Assis core in western Rio Grande do Sul (southern Brazil). **Review of Palaeobotany and Palynology**, volume 133, p. 235-248, 2005.
- BLUM, Christopher Thomas; Roderjan, Carlos Vellozo; Galvão, Franklin. O clima e sua influência na distribuição da floresta ombrófila densa na serra da prata, morretes, paraná. **Floresta**, v. 41, p. 589-598, 2011.
- BRASIL. Decreto nº 5.092 de 21 de maio de 2004. Define regras para identificação de áreas prioritárias para a conservação, utilização sustentável e repartição dos benefícios da biodiversidade, no âmbito das atribuições do ministério do meio ambiente. **Diário Oficial da União**, Página 2, 24/05/2004.
- BRASIL. Decreto nº 750, de 10 de Fevereiro de 1993. Dispõe sobre o corte, a exploração e a supressão de vegetação primária ou nos estágios avançado e médio de regeneração da Mata Atlântica, e dá outras providências. **Diário Oficial da União** - Seção 1, Página 1801, 11/2/1993.
- 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. **Diário Oficial da União** - Seção 1, Página 1, 26/12/2006.
- BRASIL. Resolução CONAMA nº 33, de 7 de dezembro de 1994. Define estágios sucessionais das formações vegetais que ocorrem na região da Mata Atlântica do Estado do Rio Grande do Sul, visando viabilizar critérios, normas e procedimentos

para o manejo, utilização racional e conservação da vegetação natural. **Diário Oficial da União** 248, Seção 1, pg. 21352-21353, de 30 de dezembro de 1994.

BUDKE, Jean Carlos, Giehl, Eduardo Luis Hettwer, Athayde, Eduardo Anversa, Eisinger, Sônia Maria, & Záchia, Renato Aquino. Florística e fitossociologia do componente arbóreo de uma floresta ribeirinha, arroio Passo das Tropas, Santa Maria, RS, Brasil. **Acta Botanica Brasilica**, volume 18(3), p. 581-589, 2004.

CABRERA, A. L.. **Fitogeografía de la República Argentina**. Boletín de la Sociedad Argentina de Botánica, volume 14, p.1-42, 1971.

CAPORAL, F.J.M. & BOLDRINI, I.I. Florística e fitossociologia de um campo manejado na Serra do Sudeste, Rio Grande do Sul. **Revista Brasileira de Biociências**, volume 5, p. 37 – 44, 2007.

CARLUCCI, M. B. *et al.* Conservação da Floresta com Araucária no Extremo Sul do Brasil. **Natureza & Conservação**, volume 9, p. 111 – 114, 2011.

CARRASCO, Luis; Aneurin W. O’Neil, R. Daniel Morton e Clare S. Rowland. Evaluating Combinations of Temporally Aggregated Sentinel-1, Sentinel-2 and Landsat 8 for Land Cover Mapping with Google Earth Engine. **Remote Sensing**, volume 11, 288, 2019.

CHEN, Lin *et al.* Optimal Combination of Predictors and Algorithms for Forest Above-Ground Biomass Mapping from Sentinel and SRTM Data. **Remote Sensing**, volume 11, 414, 2019.

CHIANG, Shou-Hao & VALDEZ, Miguel. Tree Species Classification by Integrating Satellite Imagery and Topographic Variables Using Maximum Entropy Method in a Mongolian Forest. **Forests**, volume 10, 2019.

CHRAIBI, Eric *et al.* A Remote Sensing Approach to Understanding Patterns of Secondary Succession in Tropical Forest. **Remote Sensing**, volume 13, 2148, 2021.

CONGALTON, R.G. & GREEN, K. **Assessing the accuracy of remotely sensed data: Practices and principles**. 2a Edição. Ed. CRC Press, Boca Ratón, FL.

CORDEIRO, J. L. P.; HASENACK, H. Cobertura vegetal atual do Rio Grande do Sul. Em: Pillar, V. De P.; Müller, S. C.; Castilhos, Z. M. De S.; Jacques, A. V. Á. (Org.). **Campos sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, p. 285-299, 2009.

DANTAS, M.E.; VIERO. A.C e da SILVA, D.R.A. Origem das Paisagens, em: **Geodiversidade do estado do Rio Grande do Sul** / Organização Ana Cláudia Viero e Diogo Rodrigues Andrade da Silva. Porto Alegre: CPRM, 2010.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Serviço Nacional de Levantamento e Conservação de Solos (Rio de Janeiro, RJ). **Súmula da X Reunião Técnica de Levantamento de Solos**. Rio de Janeiro. 83p, 1979.

ERINJERY, Joseph J & Singh, Mewa & Kent, Rafi. Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multispectral Sentinel-2 and SAR Sentinel-1 satellite imagery. **Remote Sensing of Environment**, volume 216, p. 345-354, 2018.

ESA – EUROPEAN SPACE AGENCY (2011) **Sentinel-2 MSI – Level 2A Products Algorithm Theoretical Basis Document**. Disponível em: https://earth.esa.int/c/document_library/get_file?folderId=349490&name=DLFE-4518.pdf

ESA – EUROPEAN SPACE AGENCY (2015) – **Sentinel-1 Data Products**. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1/data-products>

ESA (EUROPEAN SPACE AGENCY) Sentinel Online. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/missions>

ESPÍRITO-SANTO, F. D. B., Y. E. Shimabukuro e T. M. Kuplich. Mapping forest successional stages following deforestation in Brazilian Amazonia using multi-temporal Landsat images. **International Journal of Remote Sensing**, volume 26, p. 635 – 642, 2005.

FARR, Tom G., *et al.* The Shuttle Radar Topography Mission. **Reviews of Geophysics**, volume 45, RG2004, 2007.

FHM (FOREST HEALTH MONITORING), 2021. Disponível em: <https://www.fs.fed.us/foresthealth/protecting-forest/forest-health-monitoring/>

FONSECA, Eliana Lima Da, Formaggio, Antônio Roberto, & Ponzoni, Flavio Jorge. Estimativa da disponibilidade de forragem do bioma Campos Sulinos a partir de dados radiométricos orbitais: parametrização do submodelo espectral. **Ciência Rural**, volume 37(6), p. 1668-1674, 2007.

FOODY, G. M; D. S. Boyd e C. Sanchez-Hernandez. Mapping a specific class with an ensemble of classifiers. **International Journal of Remote Sensing**, volume 28, p. 1733 – 1746, 2007.

FOODY, G., & CURRAN, P. Estimation of Tropical Forest Extent and Regenerative Stage Using Remotely Sensed Data. **Journal of Biogeography**, volume 21(3), p. 223-244, 1994.

FOODY, G.M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. **Remote Sensing of Environment**, volume 239, 111630, 2020.

FOREST EUROPE, 2021. Disponível em: <https://foresteurope.org/wp-content/uploads/2016/08/Pilot-study-Fragmentation.pdf>

FORKUOR, Gerald *et al.* Above-ground biomass mapping in West African dryland forest using Sentinel-1 and 2 datasets - A case study. **Remote Sensing of Environment**, volume 236, 111496, 2020.

FRITZONS, E.; Wrege, M.S.; Mantovani, L.E. A Distribuição Natural Do Pinheiro-Do-Paraná No Estado Do Rio Grande Do Sul, Brasil: A Influência De Fatores Climáticos. **Revista Brasileira de Climatologia**, volume 22, p. 117 – 132, 2018.

GORELICK, Noel, Matt Hancher, Mike Dixon, Simon Ilyushchenko, David Thau, Rebecca Moore. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, volume 202, p. 18-27, 2017.

GROHMANN, Carlos H. Evaluation of TanDEM-X DEMs on selected Brazilian sites: Comparison with SRTM, ASTER GDEM and ALOS AW3D30. **Remote Sensing of Environment**, volume 212, p.121 – 133, 2018.

HALL-BAYER, Mryka. Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. **International Journal of Remote Sensing**, 38:5, p. 1312 – 1338, 2017.

HANSEN, J.N., Edward T. A. Mitchard and Stuart King. Assessing Forest/Non-Forest Separability Using Sentinel-1 C-Band Synthetic Aperture Radar. **Remote Sensing**, volume 12, 1899, 2020.

HANSEN, M.C. et al.. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, volume 342, p. 850-853, 2013.

HARALICK, R.M., Shanmugam, K. and Dinstein, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, volume SMC-3, n.6, p.610-621, 1973.

HUETE, A. R., Vegetation Indices, Remote Sensing and Forest Monitoring. **Geography Compass**, volume 6, p. 513-532, 2012.

HUETE, A.R. & GLENN, E.P. Remote Sensing of Ecosystem Structure and Function. Em: WENG, Qihao (Ed.) (2011). **Advances in Environmental Remote Sensing: Sensors, Algorithms and Applications**. CRC Press.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2006). Mapa Pedológico 5000 mil. Disponível em: https://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/vetores/brasil_5000_mil/

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (2006). Mapa de Regiões Fitoecológicas. <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual técnico da vegetação brasileira**: sistema fitogeográfico, inventário das formações florestais e campestres, técnicas e manejo de coleções botânicas, procedimentos para mapeamentos. Rio de Janeiro: IBGE- Diretoria de Geociências, 271p, 2012.

JARENKOW, J.A. & Waechter, J.L. Composição, estrutura e relações florísticas do componente arbóreo de uma floresta estacional no Rio Grande do Sul, Brasil. **Revista Brasileira de Botânica**, volume 24, p. 263-272, 2001.

JENSEN, J. R. (2009). **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: PARENTESE EDITORA. 672 p.

JOSHI, Neha; Edward T. A. Mitchard, Matthew Brolly, Johannes Schumacher, Alfredo Fernández-Landa, Vivian Kvist Johannsen, Miguel Marchamalo & Rasmus Fensholt. **Scientific Reports**, volume 7, 3505, 2017.

JURINITZ, C.F. & JARENKOW, J.A. Estrutura do componente arbóreo de uma floresta estacional na Serra do Sudeste, Rio Grande do Sul, Brasil. **Revista Brasileira de Botânica**, volume 26, n. 4, p. 475-487, 2003.

KÄMPF, Nestor & STRECK, Edegar V. Solos, em: **Geodiversidade do estado do Rio Grande do Sul** / Organização Ana Cláudia Viero e Diogo Rodrigues Andrade da Silva. Porto Alegre: CPRM, 2010.

KENNEDY, R.E., P.A. Townsend, J.E. Gross, W.B. Cohen, P. Bolstad, Y.Q. Wang, P. Adams. Remote Sensing change detection tools for natural resource managers: understanding concepts and tradeoffs in the design of landscape monitoring projects. **Remote Sensing of Environment**, volume 113, p. 1382 – 1396, 2009.

KUPLICH, T.M.; P. J. Curran, P.M. Atkinson. Relating SAR image texture to the biomass of regenerating tropical forests. **International Journal of Remote Sensing**, volume 26, p. 4829 – 4854, 2005.

KURTZ, Bruno Coutinho, Sá, Cyl Farney Catarino De, & Silva, Daniele Oliveira Da. Fitossociologia do componente arbustivo-arbóreo de florestas semidecíduas costeiras da região de Emerenças, Área de Proteção Ambiental do Pau Brasil, Armação dos Búzios, Rio de Janeiro, Brasil. **Rodriguésia**, volume 60(1), p. 129-146, 2009.

LAURIN, Gaia Vaglio *et al.* Above-ground biomass prediction by Sentinel-1 multitemporal data in central Italy with integration of ALOS2 and Sentinel-2 data. **Journal of Applied Remote Sensing**, volume 12, p. 016008-1 - 016008-18, 2018.

LAURIN, Gaia Vaglio, Nicola Puletti, William Hawthorne, Veraldo Liesenberg, Piermaria Corona, Dario Papale, Qi Chen, Riccardo Valentini. Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. **Remote Sensing of Environment**, Volume 176, p. 163-176, 2016.

LAURIN, Gaia Vaglio, Veraldo Liesenberg, Qi Chen, Leila Guerriero, Fabio Del Frate, Antonio Bartolini, David Coomes, Beccy Wilebore, Jeremy Lindsell, Riccardo Valentini. Optical and SAR sensor synergies for forest and land cover mapping in a tropical site in West Africa. **International Journal of Applied Earth Observation and Geoinformation**, volume 21, p. 7 – 16, 2013.

LINDMAN, C.A.M. & Ferry, M.G. **A vegetação do Rio Grande do Sul**. São Paulo, EDUSP/Livraria Itatiaia Editora, Belo Horizonte, 1974.

LIU, Yanan *et al.* Estimation of the forest stand mean height and aboveground biomass in Northeast China using SAR Sentinel-1B, multispectral Sentinel-2A, and

DEM imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, volume 151, p. 277 – 289, 2019.

LU, Dengsheng *et al.* A comparative analysis of approaches for successional vegetation classification in the Brazilian Amazon. **GIScience & Remote Sensing**, volume 51, p. 695 – 709, 2014.

LU, Dengsheng. *et al.* Classification of successional forest stages in the Brazilian Amazon basin. **Forest Ecology and Management**, volume 181, p. 301–302, 2003.

MAPBIOMAS, 2021. Disponível em: <https://mapbiomas.org/o-projeto>

MARGULES, C.R. & R.L. Pressey. Systematic conservation planning. **Nature**, volume 405p. 243–253, 2000, .

MENESES, Paulo Roberto; ALMEIDA, Tati De. (ORGS). **Introdução ao Processamento de imagens de sensoriamento remoto**. Brasília: UNB, 2012.

MEYER, Franz em: Flores-Anderson, A. I., Herndon, K. E., Thapa, R. B., and Cherrington, E. (2019). **The SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation**, 1st Edn. Huntsville, AL: NASA Marshall Space Flight Center.

MUELLER-WILM, U.; Devignot, O.; Pessiot, L. S2 MPC - Sen2Cor Configuration and User Manual. ESA Report, Ref. S2-PDGS-MPCL2A-SUM-V2.8 Issue 2. 2019. Disponível em: <http://step.esa.int/thirdparties/sen2cor/2.8.0/docs/S2-PDGS-MPC-L2A-SUMV2.8.pdf>

OLIVEIRA, R.R.; Zaú, A.S.; Lima, D.F.; Silva, M.B.R.; Vianna, M.C.; Sodré, D.O. & Sampaio, P.D. 1995. Significado ecológico da orientação de encostas no maciço da Tijuca, Rio de Janeiro. **Oecologia Brasiliensis**, volume 1, pp. 523-541, 1995.

PAL, M. & MATHER, P.M. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, volume 26, p. 1007 – 1011, 2005.

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. **Remote sensing of environment**, volume 217, p. 537-549, 2018.

PONTIUS, R.G. & MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, volume 32, p. 4407 – 4429, 2011.

PONZONI, F.J. e Ana Carolina Pinto Rezende. Caracterização espectral de estágios sucessionais de vegetação secundária arbórea em altamira (PA), através de dados orbitais. **Árvore**, volume 28, p. 535 – 545, 2004.

PRATICÒ, Salvatore *et al.* Machine Learning Classification of Mediterranean Forest Habitats in Google Earth Engine Based on Seasonal Sentinel-2 Time-Series and Input Image Composition Optimisation. **Remote Sensing**, volume 13, 586, 2021.

RAMBO, Balduino. A imigração da selva higrófila no Rio Grande do Sul. **Anais Botânicos do Herbário Barbosa Rodrigues**, volume 3(3), p. 55-91, 1951.

RAMBO, Balduino.. **A fisionomia do Rio Grande do Sul**. 2ed. Selbach, Porto Alegre, 1956.

RASMUSSEN, LAURA & JEPSEN, MARTIN. Monitoring systems to improve forest conditions. **Current Opinion in Environmental Sustainability**, volume 32, p. 29 – 37, 2018.

REYES-PALOMEQUE, Gabriela *et al.* Mapping forest age and characterizing vegetation structure and species composition in tropical dry forests. **Ecological Indicators**, volume 120, 106955, 2021.

RIZZINI, C.T. **Tratado de fitogeografia do Brasil**: aspectos ecológicos, sociológicos e florísticos. 2 ed. Rio de Janeiro, Âmbito Cultural, 1992.

SAATCHI, Sassan em: Flores-Anderson, A. I., Herndon, K. E., Thapa, R. B., and Cherrington, E. (2019). **The SAR Handbook**: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation, 1st Edn. Huntsville, AL: NASA Marshall Space Flight Center.

SCIPIONI, Marcelo & Galvão, Franklin & Longhi, Solon. Composição florística e estratégias de dispersão e regeneração de grupos florísticos em florestas estacionais decíduais no rio grande do sul. **Floresta**, 43, 2013.

SHAHARUM, Nur Shafira Nisa *et al.* Oil palm mapping over Peninsular Malaysia using Google Earth Engine and machine learning algorithms. **Remote Sensing Applications: Society and Environment**, volume 17, 100287, 2020.

SOTHE, Camile & Almeida, Cláudia & Liesenberg, Veraldo & Schimalski, Marcos. Evaluating Sentinel-2 and Landsat-8 Data to Map Successional Forest Stages in a Subtropical Forest in Southern Brazil. **Remote Sensing**, Volume 9, 838, 2017.

STROMANN, Oliver *et al.* Dimensionality Reduction and Feature Selection for Object-Based Land Cover Classification based on Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine. **Remote Sensing**, volume 12, 76, 2020.

SULOVA, Andrea & ARSANJANI, J.J. Exploratory Analysis of Driving Force of Wildfires in Australia: An Application of Machine Learning within Google Earth Engine. **Remote Sensing**, 13(10), 2021.

TAMIMINIA, Haifa; Bahram Salehia, Masoud Mahdianpari, Lindi Quackenbush, Sarina Adeli, Brian Brisco. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, volume 164, p. 152 – 170, 2020.

TASSI, Andrea & VIZZARI, Marco. Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms. **Remote Sensing**, volume 12, 3776, 2020.

THEOBALD, David M., Dylan Harrison-Atlas, William B. Monahan, Christine M. Albano. Ecologically-Relevant Maps of Landforms and Physiographic Diversity for Climate Adaptation Planning. **PLoS ONE**, 10(12), 2015.

UN (UNITED NATIONS), (2016). **Towards a common understanding of REDD+ under the UNFCCC**: A UN-REDD Programme document to foster a common approach of REDD+ implementation. Technical Resource Series 3. United Nations. Disponível em: https://www.unclearn.org/wp-content/uploads/library/redd_under_the_unfccc_hq.6_713128_1.pdf

USGS – UNITED STATES GEOLOGICAL SERVICE (2021). **Shuttle Radar Topography Mission (SRTM)**, Disponível em: https://lpdaac.usgs.gov/documents/13/SRTM_Quick_Guide.pdf

VIEIRA, I. C. G. et al. Classifying successional forests using Landsat spectral properties and ecological characteristics in eastern Amazonia. **Remote Sensing of Environment**, volume 87, p. 470–481, 2003.

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

WILDNER, W. & LOPES, R. C. Evolução Geológica: do paleoproterozóico ao recente, em: **Geodiversidade do estado do Rio Grande do Sul** / Organização Ana Cláudia Viero e Diogo Rodrigues Andrade da Silva. Porto Alegre: CPRM, 2010.

WOOD, E.M *et al.* Image texture as a remotely sensed measure of vegetation structure. **Remote Sensing of Environment**, volume 121, p. 516 – 526, 2012.

WREGG, M.S. *et al.* Predicting Current and Future Geographical Distribution of Araucaria in Brazil for Fundamental Niche Modeling. **Environment and Ecology Research**, volume 4, p. 269 – 279, 2016.

WREGG. M.S. *et al.* Distribuição natural e habitat da araucária frente às mudanças climáticas globais. **Pesquisa Florestal Brasileira**, volume 37, p. 331 – 346, 2017.

XIE, Bo *et al.* Analysis of Regional Distribution of Tree Species Using Multi-Seasonal Sentinel-1&2 Imagery within Google Earth Engine. **Forests**, volume 12, 2021.

YANG, J., Guanghui Dai and Shurong Wang. China's National Monitoring Program on Ecological Functions of Forests: An Analysis of the Protocol and Initial Results. **Forests**, volume 6, p. 809 – 826, 2015.

ZHANG, Wenmin *et al.* From woody cover to woody canopies: How Sentinel-1 and Sentinel-2 data advance the mapping of woody plants in savannas. **Remote Sensing of Environment**. volume 234, 11465, 2019.