

ERLI PINTO DOS SANTOS

**MONITORAMENTO DA COBERTURA VEGETAL EM BACIAS
HIDROGRÁFICAS INSERIDAS NO BIOMA MATA ATLÂNTICA COM BASE
EM INTEGRAÇÃO DE IMAGENS ÓPTICAS E DE RADAR**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

Orientador: Demetrius David da Silva

Coorientadora: Cibele Hummel do Amaral

**VIÇOSA – MINAS GERAIS
2020**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

Santos, Erli Pinto dos, 1995-
S237m Monitoramento da cobertura vegetal em bacias
2020 hidrográficas inseridas no bioma Mata Atlântica com base em
integração de imagens ópticas e de radar / Erli Pinto dos Santos.
– Viçosa, MG, 2020.
93 f. : il. (algumas color.) ; 29 cm.

Inclui apêndices.

Orientador: Demetrius David da Silva.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Sensoriamento remoto - Mata Atlântica. 2. Radar de
abertura sintética. 3. Imagens ópticas. 4. Aprendizado do
computador. 5. Vegetação - Monitoramento - Índices.
6. Nuvens. I. Universidade Federal de Viçosa. Departamento de
Engenharia Agrícola. Programa de Pós-Graduação em
Engenharia Agrícola. II. Título.

CDD 22. ed. 621.3678


ERLI PINTO DOS SANTOS

**MONITORAMENTO DA COBERTURA VEGETAL EM BACIAS
HIDROGRÁFICAS INSERIDAS NO BIOMA MATA ATLÂNTICA COM BASE
EM INTEGRAÇÃO DE IMAGENS ÓPTICAS E DE RADAR**

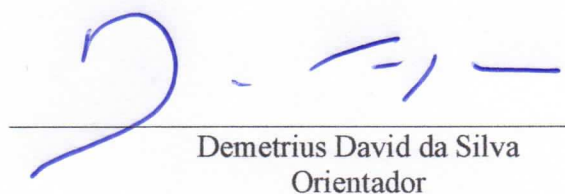
Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Magister Scientiae*.

APROVADA: 20 de julho de 2020.

Assentimento:



Erli Pinto dos Santos
Autor



Demetrius David da Silva
Orientador

Aos meus avós, Carlos Alberto (*in memoriam*), Joaquim José (*in memoriam*), Maria de Lourdes (*in memoriam*) e vó Lili, **dedico**.

AGRADECIMENTOS

Essa é, quiçá, a etapa mais difícil de um trabalho. Não de agradecer, mas a quem agradecer, pois, tantas foram as personalidades que concorreram direta e indiretamente para a realização deste sonho que, busco não ser injusto ao nomeá-las. Agradeço então, primeiramente, à inteligência suprema que conheci através da Doutrina Espírita, obrigado Pai. É como disse o poeta Altay Veloso: quando você quer, acredita naquilo, empreende tua jornada que aqueles que somam contigo surgirão, eles estarão à postos.

Os primeiros à postos, que nos receberam (a mim e ao meu irmão) e dedicam suas vidas a nós, foram meus pais: Roberval e Marli. A eles toda a gratidão pela recepção, dedicação, amor e sapiência com que nos ensinaram, ensinam e ensinarão. Obrigado por se doarem, por certo já vivenciam o conceito de *vida plena*. Em vocês agradeço a todos os familiares pela torcida, e ao meu irmão Ieslli pelo companheirismo.

Agradeço sempre àqueles familiares que desde a graduação e até os dias atuais, fizeram-se presentes abençoando o caminho, em especial a tia Belinha! Na Princesa do Sertão ganhei, além de tudo, um núcleo familiar que se expande para além dos laços genealógicos, a estes, Jaime, Ane, Rose, D. Vera, Maria Clarinha e ao meu amigo Jarielson, cuja palavra que melhor define o laço é irmandade, minha gratidão por sempre serem presentes mesmo na distância.

A jornada trilhada aqui em Viçosa me revelou grandes amigos, e com eles experiências inesquecíveis. A turma do CRRH fica aqui representada (pois ela se estende para além destes) pelo Robson que me recebeu e me apresentou a UFVida, a Ana, Rafael Dias parceiro de pesquisa, o gordin (Micael), Caliman, Isabela, Cris, Cambraia, Janna, Julia, ao Cogu (Arthur), Guilherme, o Robert e por fim (mas não menos importante) a Bianca, caloura no mestrado e fomentadora de ideias. A vocês – e aos demais – o meu muito obrigado pela paciência e amizade!

Não poderia deixar de agradecer a tranquila companhia dos contemporâneos na Fenda do Biquini, a república mais silenciosa de Viçosa! Em especial para o amigo que esta república me presenteou, aquele que têm cópia autenticada da gargalhada do Bira!

Agradeço ao professor Silvio Bueno (*in memoriam*) pela iniciativa de escolher nos orientar, mas que por um infortuno não tive a oportunidade de conhecer. Esse agradecimento estende-se ao professor Demetrius, que naquele momento abraçou a nossa causa e nos adotou como seus orientados, e coordenou esse trabalho até aqui. Agradeço por extensão a professora Cibele, por guiar em bases sólidas este trabalho de pesquisa. E falando de orientadores, preciso agradecer aqui também a orientação e amizade de Taíse e Rosângela, duas grandes incentivadoras que deram base, oportunidade e atenção para este que vos escreve. Sem todos vocês esse trabalho não sairia!

Por fim, a todos que contribuíram direta ou indiretamente nesta jornada até a realização deste trabalho, meu sincero muito obrigado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

“Não basta investigar fenômenos, aderir verbalmente, melhorar a estatística, doutrinar consciências alheias, fazer proselitismo e conquistar favores da opinião, por mais respeitável que seja, no plano físico. É indispensável cogitar do conhecimento de nossos infinitos potenciais, aplicando-os, por nossa vez, nos serviços do bem.”

(Emmanuel, 1943; extraído de Nosso Lar, Chico Xavier e André Luiz)

“Tudo que toma forma vive antes na consciência.”

(Haroldo Dutra Dias)

RESUMO GERAL

SANTOS, Erli Pinto dos, M.Sc., Universidade Federal de Viçosa, julho de 2020. **Monitoramento da cobertura vegetal em bacias hidrográficas inseridas no bioma mata atlântica com base em integração de imagens ópticas e de radar.** Orientador: Demetrius David da Silva. Coorientadora: Cibele Hummel do Amaral.

Um entrave na aplicação de métodos e técnicas de sensoriamento remoto orbital com sensores ópticos para monitoramento espacialmente contínuo de diversas atividades é a influência das condições atmosféricas na qualidade das imagens e na frequência de observação da superfície. Esse é um problema recorrente em regiões tropicais como o território do Brasil, principalmente no período chuvoso, de modo que a observação da vegetação para atividades como agricultura, manejo florestal e meio ambiente é afetada. Dada a natureza das micro-ondas, nas técnicas de sensoriamento remoto por radar, como os radares de abertura sintética, as partículas atmosféricas não influenciam nesse tipo de imageamento, permitindo monitoramento contínuo e frequente da superfície em observação. Desse modo, o objetivo deste estudo foi propor uma metodologia capaz de possibilitar o monitoramento da cobertura vegetal em bacias hidrográficas com base em integração de imagens ópticas e de radar que permita o monitoramento frequente e sem lacunas oriundas de nuvens, usando como área de estudo a bacia hidrográfica do rio Doce. A área de estudo foi escolhida por apresentar duas propriedades que interferem no imageamento do sensor de banda-C empregado: as variações do relevo e a vegetação densa do bioma predominante na bacia do rio Doce, a Mata Atlântica. Para monitorar quantitativamente a presença da vegetação foi proposto um índice de dupla polarização (DPSVIm) com dados Sentinel-1, e sua avaliação levou em conta a sazonalidade dos regimes de chuva e do relevo ao longo da bacia. O índice proposto foi confrontado com índices de vegetação (NDVI e EVI) calculados com imagens do sensor OLI/Landsat 8 ao longo de uma série mensal de quatro anos hidrológicos, tendo apresentado melhores ajustes no semestre seco de cada ano, evidenciando a sensibilidade dos dados de radar à umidade da superfície. Com base na relação complementar entre o DPSVIm e os índices ópticos foi proposto o monitoramento contínuo e frequente da vegetação através da predição dos índices ópticos por sistemas de aprendizado de máquina. Nesse sentido, o *Random Forest* foi o algoritmo que melhor acertou na predição do NDVI e EVI em diferentes escalas, generalizando bem para pontos amostrais não conhecidos. A proposta de integração de imagens de radar com imagens ópticas para monitorar vegetação

mostrou-se promissora mesmo com as influências do relevo e umidade nas imagens SAR-C, carecendo, em trabalhos futuros, do estudo dos efeitos da umidade da superfície no índice DPSVIm para melhorar a sensibilidade deste em quantificar a vegetação no período chuvoso bem como o teste com dados de outras missões de radar, avaliando ainda os resultados com medidas alométricas da vegetação.

Palavras-chave: Radar de abertura sintética. Índice de vegetação por radar. Aprendizado de máquina. Cobertura de nuvens. Mata Atlântica.

ABSTRACT

SANTOS, Erli Pinto dos, M.Sc., Universidade Federal de Viçosa, July, 2020. **Vegetation cover monitoring in watersheds inserted in Atlantic Rain Forest biome based on integration of optical and radar imagery.** Adviser: Demetrius David da Silva. Co-adviser: Cibele Hummel do Amaral.

An obstacle in the application of orbital remote sensing methods and techniques with optical sensors for spatially continuous monitoring of various activities is the influence of atmospheric conditions on image quality and surface observation frequency. This is a recurrent problem in tropical regions such as Brazil, especially in the rainy season, so that the observation of vegetation for activities such as agriculture, forest management and the environment is affected. In function of the nature of microwaves, in radar remote sensing techniques, such as synthetic aperture radars, atmospheric particles do not influence this type of imaging, allowing continuous and frequent monitoring of the surface under observation. Thus, the objective of this study was to propose a methodology capable of enabling the monitoring of vegetation cover in watersheds based on integration of optical and radar images that allows frequent monitoring and without cloud gaps, using as a study area the Doce river watershed. The study area was chosen because it presented two properties that interfere in the imaging of the C-band sensor used: the topography's behavior and the dense vegetation of the predominant biome in the Doce watershed, the Atlantic Forest. To quantitatively monitor the presence of vegetation, a modified dual polarization SAR vegetation index (DPSVIm) was proposed with Sentinel-1 data, and its evaluation took into account the seasonality of rainfall regimes and the topography along the watershed. The proposed index was compared with vegetation indices (NDVI and EVI) calculated with images captured by the OLI/Landsat 8 sensor over a monthly series of four hydrological years, having presented better adjustments in the dry semester of each year, evidencing the sensitivity of radar data to surface moisture. Based on the complementary relationship between the DPSVIm and the optical indices, continuous and frequent monitoring of vegetation was proposed through the prediction of optical indices by machine learning systems. In this sense, Random Forest was the algorithm that generated the most accurate predictions of NDVI and EVI in different scales, generalizing well to unknown sampling points. The proposal for the integration of radar images with optical images to monitor vegetation was promising even with the influences of topography and surface moisture on SAR-C images, lacking, in future studies, the study

of the effects of surface moisture on the DPSVIm index to improve its sensitivity in quantifying vegetation in the rainy season as well as testing with data from other radar missions, also evaluating the results with allometric measurements of the vegetation.

Keywords: Synthetic aperture radar. Radar vegetation index. Machine learning. Cloud cover. Atlantic Rain Forest.

LISTA DE ILUSTRAÇÕES

Figura 2.1.1. Localização da bacia hidrográfica do rio Doce sobre modelo digital de declividade, com destaque para as sub-bacias adotadas no estudo.....	21
Figura 2.1.2. Mapa de uso e cobertura do solo ao longo da bacia do rio Doce, destacando diferentes fitofisionomias existentes no ano de 2018.	22
Figura 2.1.3. Distribuição da classificação climática de Köppen sobre a bacia do rio Doce e sub-bacias de interesse.	23
Figura 2.1.4. Pré e pós processamento de dados Sentinel-1 compondo a base de dados do estudo na plataforma GEE.	26
Figura 2.1.5. Comportamento do DPSVI em função dos índices IDPDD, VDDPI e da banda VH.	27
Figura 2.1.6. Processamento de dados ópticos da plataforma Landsat 8, tendo como produtos de saída as bandas de NDVI e EVI.	29
Figura 2.1.7. Processo de amostragem dos índices de vegetação DPSVIm, EVI e NDVI no GEE.	30
Figura 2.1.8. Correlações entre NDVI vs. DPSVI e NDVI vs. DPSVIm para a bacia 779926.....	32
Figura 2.1.9. Diagrama de dispersão exibindo o comportamento do DPSVIm em função de DPSVI atribuindo as amostras a classe de uso e cobertura do solo (MAPBIOMAS, 2019).	33
Figura 2.1.10. Série temporal dos coeficientes de correlação mensais e significância da correlação para a bacias do rio Doce e sub-bacias 786232, 78623, 779926 e 77992.	34
Figura 2.1.11. Índice de concordância de Willmott (d) representando o erro relativo médio, ou concordância, entre as variáveis aleatórias DPSVIm vs. EVI e DPSVIm vs. NDVI ao longo da série temporal.	36
Figura 2.1.12. Séries temporais do RMSE e MBE para a bacia do rio Doce e sub-bacias 779926 e 786232.	37
Figura 2.1.13. Distribuição da declividade (GD: grau decimal) do terreno na bacia do rio Doce e sub-bacias em análise.....	40
Figura 2.1.14. Correlação (r), concordância (d) e acurácia (RMSE) entre NDVI e DPSVIm obtido antes e após RTF (σ_0 e γ_0 , respectivamente) para a sub-bacia 78623.	41
Figura 2.2.1. Localização da bacia hidrográfica do rio Doce, exibindo modelo digital de declividade, com destaque para as sub-bacias adotadas no estudo.....	52
Figura 2.2.2. Mapa de uso e cobertura do solo ao longo da bacia do rio Doce, destacando diferentes fitofisionomias existentes no ano de 2018.	53
Figura 2.2.3. Esquema de processamento dos dados orbitais no GEE para gerar base de dados do estudo.	56
Figura 2.2.4. Esquema de separação das amostras, seleção de variáveis, treinamento dos modelos e avaliação da performance.	59
Figura 2.2.5. Ranking de importância das covariáveis de cada modelo na predição do NDVI na: a) bacia do rio Doce; b) sub-bacia 77992 e c) sub-bacia 78623.	61
Figura 2.2.6. Resultados da validação cruzada <i>k-Fold</i> repetida, para os diferentes conjuntos de treinamento.	63

Figura 2.2.7. Métricas estatísticas da validação *holdout* e comportamento dos modelos na predição do NDVI para: a) bacia do rio Doce; b) sub-bacia 77992 e c) sub-bacia 78623.

..... 65

Figura 2.2.8. Métricas estatísticas da validação *holdout* e comportamento dos modelos na predição do EVI para: a) bacia do rio Doce; b) sub-bacia 77992 e c) sub-bacia 78623. 66

SUMÁRIO

1. INTRODUÇÃO GERAL.....	13
1.1. Referências	16
2. ARTIGOS CIENTÍFICOS.....	18
2.1 Artigo 1 – Monitoramento de vegetação em regiões tropicais com índice de dupla polarização SAR-C: influências sazonais e espaciais	18
2.1.1. Introdução	18
2.1.2. Metodologia	19
2.1.2.1. Área de estudo.....	20
2.1.2.2. Dados orbitais.....	23
2.1.3. Resultados e discussão.....	31
2.1.4. Conclusões	42
2.1.5. Referências.....	42
2.2. Artigo 2 – Monitoramento contínuo da vegetação em bacias hidrográficas com base em integração de imagens ópticas e de radar	49
2.2.1. Introdução	49
2.2.2. Metodologia	50
2.2.2.1. Área de estudo.....	50
2.2.2.2. Dados orbitais.....	54
2.2.2.3. Algoritmos de regressão e processo de modelagem	57
2.2.2.4. Avaliação dos modelos	59
2.2.3. Resultados e discussão.....	60
2.2.3.1. Seleção e importância das covariáveis.....	60
2.2.3.2. Ajuste dos hiperparâmetros via validação cruzada <i>k-Fold</i>	62
2.2.3.3. Estratégia de validação <i>holdout</i>	64
2.2.4. Conclusões	68
2.2.5. Referências.....	68
3. CONCLUSÕES GERAIS.....	75
4. APÊNDICE A – Código-fonte para cômputo do DPSVIm para monitoramento de vegetação.....	76
5. APÊNDICE B – Código-fonte para geração das covariáveis de radar e variáveis dependentes ópticas.....	85

1. INTRODUÇÃO GERAL

Métodos e técnicas de sensoriamento remoto têm o potencial de fornecer informações da superfície da Terra em larga escala, com alta resolução espacial e temporal, permitindo o monitoramento de diferentes atividades. Essas informações desempenham um papel vital na avaliação e estudo da dinâmica da cobertura vegetal, impactando atividades como agricultura, florestas e meio ambiente (PERIASAMY, 2018). Para isso foram desenvolvidos diferentes métodos, baseados em dados coletados por sensores ópticos, para avaliação das condições da vegetação, como os índices espectrais de vegetação.

Índices de vegetação calculados a partir de dados de sensores remotos que operam no espectro óptico são amplamente usados para estimar atributos biofísicos da vegetação, como biomassa fotossinteticamente ativa, índice de área foliar e atividade fotossintética (DUBE; MUTANGA, 2015; LEHMANN *et al.*, 2012; MOREIRA *et al.*, 2016). Estes índices usam relações de bandas do espectro azul, vermelho e infravermelho próximo para inferir sobre parâmetros biofísicos, tais como o NDVI (*Normalized Difference Vegetation Index*), o SAVI (*Soil Adjusted Vegetation Index*) e o EVI (*Enhanced Vegetation Index*) (HUETE *et al.*, 2002; HUETE, 1988; JUSTICE *et al.*, 1998; ROUSE *et al.*, 1973). Entretanto, estes produtos oriundos de sensores ópticos são altamente influenciados pelas condições atmosféricas, especialmente pela cobertura de nuvens que são opacas à radiação eletromagnética nessas regiões do espectro.

A cobertura de nuvens, para o sensoriamento remoto óptico, é um problema recorrente em regiões tropicais como o território do Brasil (ASNER, 2001; SANO *et al.*, 2007), porquê impede que instrumentos ópticos obtenham dados da superfície da Terra. Mas enquanto isso, a vegetação tem um processo dinâmico e mudanças expressivas na biomassa muitas vezes ocorrem em curtos intervalos de tempo (WHITCRAFT *et al.*, 2015; WISEMAN *et al.*, 2014). Por isso as técnicas de imageamento por micro-ondas são importantes alternativas, principalmente usando sensores ativos como os radares de abertura sintética (*Synthetic Aperture Radar – SAR*) (REIGBER *et al.*, 2020), pois estes independem da iluminação solar e penetram em áreas cobertas por nuvens, neblina e chuva, permitindo fluxos de dados livres de lacunas para mapeamento da vegetação (SZIGARSKI *et al.*, 2018; WOODHOUSE, 2006).

As razões fundamentais para a aplicação de sensores de micro-ondas é que estes usam a região do espectro de micro-ondas, onde as interações com os alvos são afetadas

por diferentes parâmetros físicos comparativamente aos sistemas ópticos (WOODHOUSE, 2006). Enquanto a quantidade de energia refletida por uma folha verde no espectro vermelho é dada em função da quantidade de clorofila, num determinado comprimento de micro-ondas a energia refletida é proporcional ao tamanho, forma e conteúdo de água da folha (WOODHOUSE, 2006), governando os mecanismos de reflexão, nesse caso de retroespalhamento, da energia emitida pelo sensor.

O mecanismo de retroespalhamento de uma superfície depende das propriedades físicas e elétricas desta e das características operacionais do sensor (LIU *et al.*, 2019; WOODHOUSE, 2006). Como características operacionais do sensor tem-se o comprimento e a polarização da onda, além do ângulo de incidência. Já as propriedades dielétricas, a orientação (incluindo topografia) e a rugosidade da superfície, são parâmetros dos alvos. Esses parâmetros dos alvos condicionam o sinal retroespalhado para os sensores SAR, e na prática um parâmetro é com frequência minimizado para a extração de outro parâmetro importante (RAO *et al.*, 2013). Um parâmetro do sensor que é importante na avaliação da cobertura vegetal, seja sua biomassa acima do solo (AGB), o conteúdo de água da vegetação (VWC) ou outras propriedades, é a polarização (MCNAIRN; SHANG, 2016) e foi baseado no conceito de polarização que índices de vegetação como o RVI (*Radar Vegetation Index*) foram propostos (KIM; VAN ZYL, 2000, 2009; SZIGARSKI *et al.*, 2018).

Quando o sinal de polarização vertical é emitido (como as bandas VV e VH do Sentinel-1) este tende a mudar o estado de polarização parcialmente ou totalmente quando interage com um anteparo, isso porquê o ângulo de orientação muda em função de vários fatores (PERIASAMY, 2018). E essa energia emitida quando interage com a superfície vegetada tende a sofrer alteração no estado de polarização, fenômeno conhecido como despolarização. De acordo com Woodhouse (2006), a vegetação tende a ser tanto emissor quanto dispersor despolarizante, de modo que as contribuições verticais e horizontais tendem a ser progressivamente similares na proporção em que o sinal retroespalhado da vegetação aumenta. Ou seja, a alta densidade de plantas retorna altos valores em polarização cruzada (VH ou HV) (PATEL *et al.*, 2006).

Abordagens de quantificação da vegetação, como o RVI, são frequentes com sensores de banda L (SAR-L), e como alternativa adequada para o RVI foi proposto por Periasamy (2018) o modelo DPSVI (*Dual Polarimetric SAR Vegetation Index*) para representar a vegetação como um modelo de espalhamento físico baseado no grau de despolarização do sinal (PERIASAMY; SENTHIL; SHANMUGAM, 2019). O DPSVI,

desenvolvido para imagens do sensor de banda C (SAR-C) da missão Sentinel-1 aproveita, ainda, a alta resolução espacial e temporal (6 dias de revisita com dois satélites) da missão Sentinel-1, permitindo monitoramento espacialmente contínuo e frequente da superfície. Entretanto, o DPSVI foi desenvolvido para regiões na Índia de vegetação esparsa e culturas agrícolas (PERIASAMY, 2018), sendo desconhecida a sua eficiência em regiões de biomassa vegetal densa, como a Mata Atlântica do Brasil.

É importante deixar evidente que, como já discutido, os índices ópticos são estreitamente relacionados aos parâmetros biofísicos da vegetação fotossinteticamente ativa, já os dados de radares à toda a AGB (dependendo da frequência da banda) e conteúdo de água, portanto, medem a radiação proveniente da vegetação sob diferentes espectros. Dada a empregabilidade dos índices ópticos em estudos e na tomada de decisão nas atividades supracitadas, abordagens de uso dos radares em integração aos dados ópticos têm surgido mais recentemente, como abordado por Sivasankar *et al.* (2018) e Filgueiras *et al.* (2019), por sistemas de aprendizado de máquina.

Sistemas de aprendizado de máquina tem sido amplamente empregado nas últimas décadas por efeito do poder de prever ou classificar (dependendo do problema em questão) com acurácia e da capacidade de aprendizado com novas informações (GÉRON, 2017). O problema de predição abrange o desenvolvimento de uma ferramenta matemática (ou modelo) capaz de gerar predições acuradas (KUHN; JOHNSON, 2013), e assim a integração de dados de radar e ópticos na avaliação da vegetação tem sido empregada por predição de índices de vegetação por covariáveis originárias dos radares (FILGUEIRAS *et al.*, 2019; SIVASANKAR *et al.*, 2018).

Considerando possibilidades de integração de dados ópticos e de radar, e ainda as potencialidades das imagens SAR-C da missão Sentinel-1 em quantificar a vegetação sem influências de condições atmosféricas e suas limitações quanto às características ambientais da bacia hidrográfica do rio Doce, a dissertação, apresentada na forma de artigos, buscou investigar o uso dessas imagens para propor um sistema de monitoramento contínuo da vegetação no bioma Mata Atlântica. Os artigos desenvolvidos visam analisar i) o monitoramento de vegetação em regiões tropicais com índice de dupla polarização SAR-C avaliando influências sazonais e espaciais, e ii) o monitoramento contínuo da vegetação em bacias hidrográficas com base em integração de imagens ópticas e de radar por algoritmos de aprendizado de máquina.

1.1. Referências

ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 15 dez. 2001.

DUBE, T.; MUTANGA, O. Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 101, p. 36–46, 1 mar. 2015.

FILGUEIRAS, R. *et al.* Crop NDVI Monitoring Based on Sentinel 1. **Remote Sensing**, v. 11, n. 12, p. 1441, 2019.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. 2. ed. Sebastopol: O'Reilly Media, Inc., 2017.

HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 1 nov. 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1 ago. 1988.

JUSTICE, C. O. *et al.* The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KIM, Y.; VAN ZYL, J. **On the relationship between polarimetric parameters**. IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment. Proceedings (Cat. No.00CH37120). **Anais...IEEE**, 2000Disponível em: <<http://ieeexplore.ieee.org/document/858099/>>. Acesso em: 6 maio. 2020

KIM, Y.; VAN ZYL, J. J. A time-series approach to estimate soil moisture using polarimetric radar data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 8, p. 2519–2527, ago. 2009.

KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. New York, NY: Springer New York, 2013.

LEHMANN, E. A. *et al.* Forest cover trends from time series Landsat data for the Australian continent. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, n. 1, p. 453–462, 1 abr. 2012.

LIU, C. AN *et al.* **Research advances of SAR remote sensing for agriculture applications: A review****Journal of Integrative Agriculture**Chinese Academy of Agricultural Sciences, , 1 mar. 2019.

MCNAIRN, H.; SHANG, J. A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. In: **Remote Sensing and Digital Image Processing**. [s.l.] Springer

International Publishing, 2016. v. 20p. 317–340.

MOREIRA, E. P. *et al.* Efeito topográfico sobre índices de vegetação obtidos com dados Landsat TM: É necessário correção topográfica? **Boletim de Ciências Geodésicas**, v. 22, n. 1, p. 95–107, 1 jan. 2016.

PATEL, P. *et al.* Comparative evaluation of the sensitivity of multi-polarized multi-frequency SAR backscatter to plant density. **International Journal of Remote Sensing**, v. 27, n. 2, p. 293–305, 2006.

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. **Remote Sensing of Environment**, v. 217, n. September, p. 537–549, 2018.

PERIASAMY, S.; SENTHIL, D.; SHANMUGAM, R. S. A soil texture categorization mapping from empirical and semi-empirical modelling of target parameters of synthetic aperture radar. **Geocarto International**, p. 1–18, 10 jun. 2019.

RAO, S. S. *et al.* Modified Dubois Model for Estimating Soil Moisture with Dual Polarized SAR Data. **Journal of the Indian Society of Remote Sensing**, v. 41, n. 4, p. 865–872, 19 dez. 2013.

REIGBER, A. *et al.* The High-Resolution Digital-Beamforming Airborne SAR System DBFSAR. **Remote Sensing**, v. 12, n. 11, p. 1710, 27 maio 2020.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

SANO, E. E. *et al.* Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v. 28, n. 12, p. 2739–2752, 29 jun. 2007.

SIVASANKAR, T. *et al.* Advances in radar remote sensing of agricultural crops: A review. **International Journal on Advanced Science, Engineering and Information Technology**, v. 8, n. 4, p. 1126–1137, 2018.

SZIGARSKI, C. *et al.* Analysis of the Radar Vegetation Index and Potential Improvements. **Remote Sensing**, v. 10, n. 11, p. 1776, 2018.

WHITCRAFT, A. K. *et al.* Cloud cover throughout the agricultural growing season: Impacts on passive optical earth observations. **Remote Sensing of Environment**, v. 156, p. 438–447, 1 jan. 2015.

WISEMAN, G. *et al.* RADARSAT-2 Polarimetric SAR response to crop biomass for agricultural production monitoring. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 11, p. 4461–4471, 1 nov. 2014.

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**. Boca Raton: CRC Press, 2006.

2. ARTIGOS CIENTÍFICOS

2.1 Artigo 1 – Monitoramento de vegetação em regiões tropicais com índice de dupla polarização SAR-C: influências sazonais e espaciais

2.1.1. Introdução

Índices espectrais de vegetação têm sido utilizados em diversos estudos hidrológicos com objetivos distintos, como para a compreensão dos padrões de precipitação e sua relação com a cobertura vegetal (WANG; RICH; PRICE, 2003; WANG *et al.*, 2010) e dos efeitos da dinâmica vegetal nos regimes hidrológicos em bacias hidrográficas (LIU *et al.*, 2016). O uso não se restringe à hidrologia, sendo também amplamente empregados para estimar atributos biofísicos da vegetação, como biomassa, índice de área foliar e atividade fotossintética (DUBE; MUTANGA, 2015; LEHMANN *et al.*, 2012; MOREIRA *et al.*, 2016). Ademais, índices de vegetação como fonte de informação sobre crescimento e condições da vegetação em nível sinóptico são fundamentais na tomada de decisão em campos como agricultura, silvicultura, meio ambiente e áreas afins (PERIASAMY, 2018).

Diversos índices espectrais, como o NDVI (Normalized Difference Vegetation Index) e o EVI (Enhanced Vegetation Index) (HUETE *et al.*, 2002; ROUSE *et al.*, 1973) tem sua aplicabilidade demonstrada para representar a vegetação por muitos trabalhos nas últimas décadas (COLWELL, 1974; DUBE; MUTANGA, 2015; GITELSON, 2004; HUETE, 1988). Entretanto, índices oriundos de sensores óticos são altamente influenciados pelas condições atmosféricas, especialmente pela cobertura de nuvens em regiões tropicais (ASNER, 2001; SANO *et al.*, 2007) e sua opacidade à radiação eletromagnética nos espectros visível e infravermelho, problema este que não afeta o sensoriamento feito por radares de abertura sintética (SAR).

Os sensores SAR não dependem de iluminação solar e penetram em áreas cobertas por nuvens, neblina e chuva, permitindo fluxos de dados livres de lacunas, podendo ser empregados no mapeamento da vegetação (SZIGARSKI *et al.*, 2018; WOODHOUSE, 2006). Por isso, ao passo que índices espectrais de vegetação foram desenvolvidos, índices de micro-ondas também emergiram (CHANG; SHOSHANY; OH, 2018; CHOUDHURY *et al.*, 1987; KIM; VAN ZYL, 2009; PERIASAMY, 2018). Todas estas abordagens são baseadas em polarimetria e em mecanismos de espalhamento volumétrico

da vegetação (CHANG; SHOSHANY; OH, 2018; FRISON *et al.*, 2018; PERIASAMY, 2018; WOODHOUSE, 2006). Embora existam métodos mais complexos que podem ser desenvolvidos com sistemas polarimétricos aéreos ou de medições interferométricas polarimétricas (SAATCHI, 2019), métodos como o RVI (Radar Vegetation Index) são bem fundamentados na literatura (ARII; VAN ZYL; KIM, 2010; KIM; VAN ZYL, 2000; SZIGARSKI *et al.*, 2018).

O RVI foi desenvolvido para sensores de banda L (KIM; VAN ZYL, 2000) e todas as modificações feitas também para sensores SAR-L (CHARBONNEAU; TRUDEL; FERNANDES, 2005; SZIGARSKI *et al.*, 2018). Mas só recentemente índices polarimétricos surgiram para sensores SAR de banda C de dupla polarização vertical (VV e VH), aproveitando dados da missão Copernicus Sentinel-1 da ESA. Um exemplo é a abordagem de Nasirzadehdizaji *et al.* (2019) para RVI (de Charbonneau *et al.* (2005)). Hird *et al.* (2017) desenvolveram o índice Pol (Normalized Polarization), para mapeamento de zonas úmidas com dados Sentinel-1. Razão de bandas também empregada por Filgueiras (2019) para modelagem de NDVI sobre lavouras. Além destes, um desenvolvimento recente é o DPSVI (Dual Polarimetric SAR Vegetation Index) por Periasamy (2018): um índice de dupla polarização VV e VH, bandas de maior distribuição global das missões Sentinel-1 A e B, baseado no efeito de despolarização do sinal de micro-ondas. Estas abordagens foram desenvolvidas e testadas em culturas agrícolas ou classes específicas de vegetação.

O DPSVI foi desenvolvido para regiões de vegetação esparsa e clima semiárido, e sua aplicabilidade a regiões de biomassa densa é desconhecida, mas prevista por Periasamy (2018) como sendo de baixa sensibilidade. Partindo desse pressuposto, os objetivos desta pesquisa são: a) propor modificações no DPSVI (Dual Polarimetric SAR Vegetation Index) para representação de vegetação densa usando dados do sensor SAR-C Sentinel-1, tendo como espaço amostral a bacia hidrográfica do rio Doce, Brasil; e b) identificar efeitos da sazonalidade do regime de chuvas, bem como dos aspectos topográficos da bacia, sobre as imagens SAR, e como estes parâmetros interferem no desempenho do índice.

2.1.2. Metodologia

2.1.2.1. Área de estudo

O espaço amostral escolhido foi a bacia hidrográfica do rio Doce, situada na região Sudeste do Brasil e inserida nos Estados de Minas Gerais e Espírito Santo. Abrange uma área de drenagem de, aproximadamente, 86555 km² (AGÊNCIA NACIONAL DE ÁGUAS, 2017). O rio Doce tem sua foz no Oceano Atlântico, fazendo com que a bacia apresente altitude mínima de 0 m (nível do mar), atingindo máxima de 2606m de acordo com modelo digital de elevação NASADEM (NASA JPL, 2020). Além da bacia do rio Doce, quatro sub-bacias foram escolhidas para avaliar o índice DPSVI em maiores escalas, representadas pelos códigos: 77992, 78623, 7799262 e 786232. Sub-bacias codificadas de acordo com a metodologia proposta por Pfafstetter (1989) adotada oficialmente no Brasil pela Agência Nacional de Águas (BRASIL, 2003).

Uma descrição das características planialtimétricas da bacia e suas sub-bacias é dada pela Tabela 2.1.1, e a Figura 2.1.1 traz localização da bacia e sub-bacias com modelo digital de declividade representando variações e classes no relevo de acordo com Santos *et al.* (2018).

Tabela 2.1.1. Características físicas da bacia do rio Doce e sub-bacias em estudo.

Bacia/Sub-bacia	Área aproximada (km ²)	Altitude (m)			
		Máxima	Média	Mínima	Desvio-padrão
Rio Doce	86 555.00	2606	519.32	0	307.50
77992	3996.46	560	62.88	0	62.62
779926	347.54	114	48.91	0	23.24
78623	1043.12	1272	760.06	360	112.60
786232	127.49	1114	755.41	565	113.46

Fonte dos dados altimétricos: Modelo Digital de Elevação NASADEM (NASA JPL, 2020).

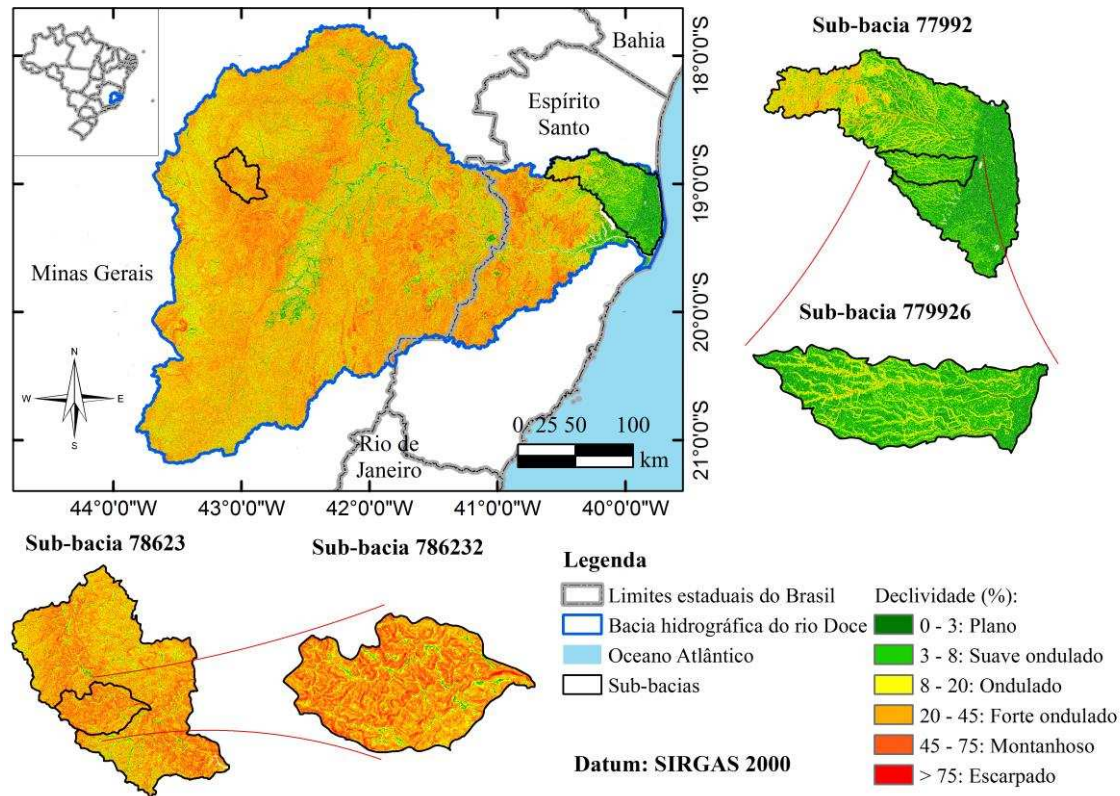


Figura 2.1.1. Localização da bacia hidrográfica do rio Doce sobre modelo digital de declividade, com destaque para as sub-bacias adotadas no estudo.

Fonte dos dados: limites estaduais do Brasil (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2020), bacias hidrográficas (AGÊNCIA NACIONAL DE ÁGUAS, 2017) e modelo digital de declividade (FARR *et al.*, 2007; GOOGLE EARTH ENGINE, 2020a).

Fonte: Autor.

A bacia do rio Doce tem 98% de sua área inserida no bioma Mata Atlântica e outros 2% no bioma Cerrado (ECOPLAN-LUME, 2010), mas apresenta uma diversidade de classes de uso e cobertura do solo como mostra a Figura 2.1.2, com dados da coleção 4.1 da iniciativa MapBiomas (2019) de mapeamento da cobertura dos biomas do Brasil. Esta destaca apenas classes vegetais de uso e cobertura como formação florestal, florestas plantadas, agricultura e pastagem e outras, que são objeto do estudo. Além disso há seis zonas climáticas ao longo da bacia variando de zonas tropicais à subtropicais úmidas, de acordo com a espacialização da classificação climática de Köppen efetuada por Alvares *et al.* (2013), ilustrada no mapa da Figura 2.1.3. Essa diversidade de zonas climáticas reflete nas temperaturas médias anuais que, conforme Pires *et al.* (2017), variam de 18 a 25 °C. Nas sub-bacias de altitude, o clima é subtropical úmido com inverno seco e verão

quente (Cwa) e com verão temperado (Cwb), já nas sub-bacias mais planas o clima é tropical com monções (Am) e com inverno seco (Aw).

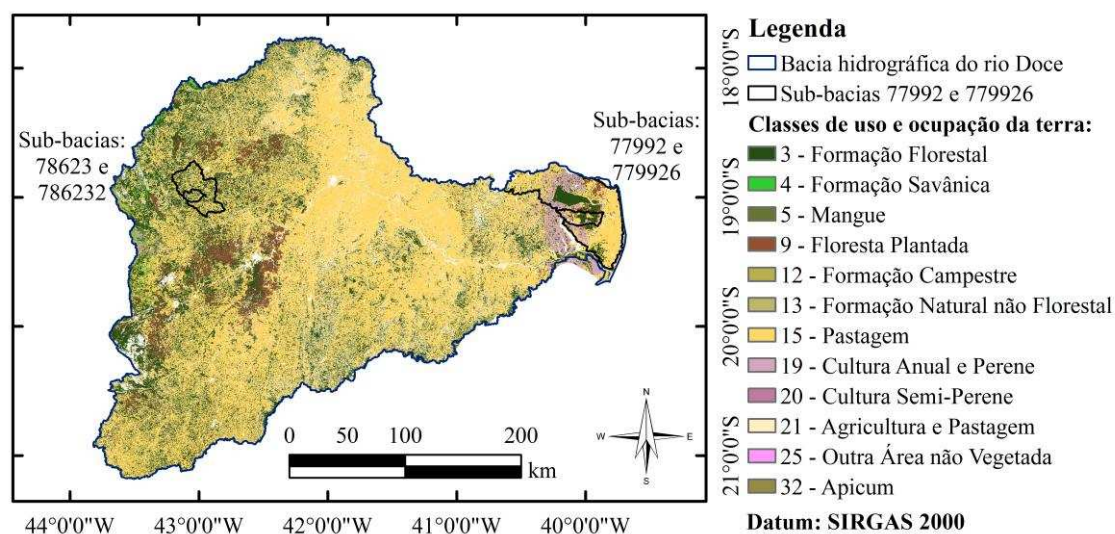


Figura 2.1.2. Mapa de uso e cobertura do solo ao longo da bacia do rio Doce, destacando diferentes fitofisionomias existentes no ano de 2018.

Fonte dos dados: MapBiomas (2019).

Fonte: Autor.

Para avaliar a influência do regime de chuvas no desempenho do índice DPSVI o ano hidrológico na bacia do rio Doce foi definido, e toda a análise é baseada nele. O ano hidrológico foi obtido a partir da análise das séries históricas de dados consistidos de todas as estações pluviométricas e fluviométricas localizadas ao longo da bacia e com dados disponíveis no portal Hidroweb (<http://www.snirh.gov.br/hidroweb/publico/apresentacao.jsf>) da Agência Nacional de Águas (ANA), tendo sido definido o semestre chuvoso como sendo de outubro a março e o semestre seco de abril a setembro, com o ano hidrológico iniciando em outubro de cada ano. Assim, a análise compreende quatro anos hidrológicos: 2015/2016 a 2018/2019.

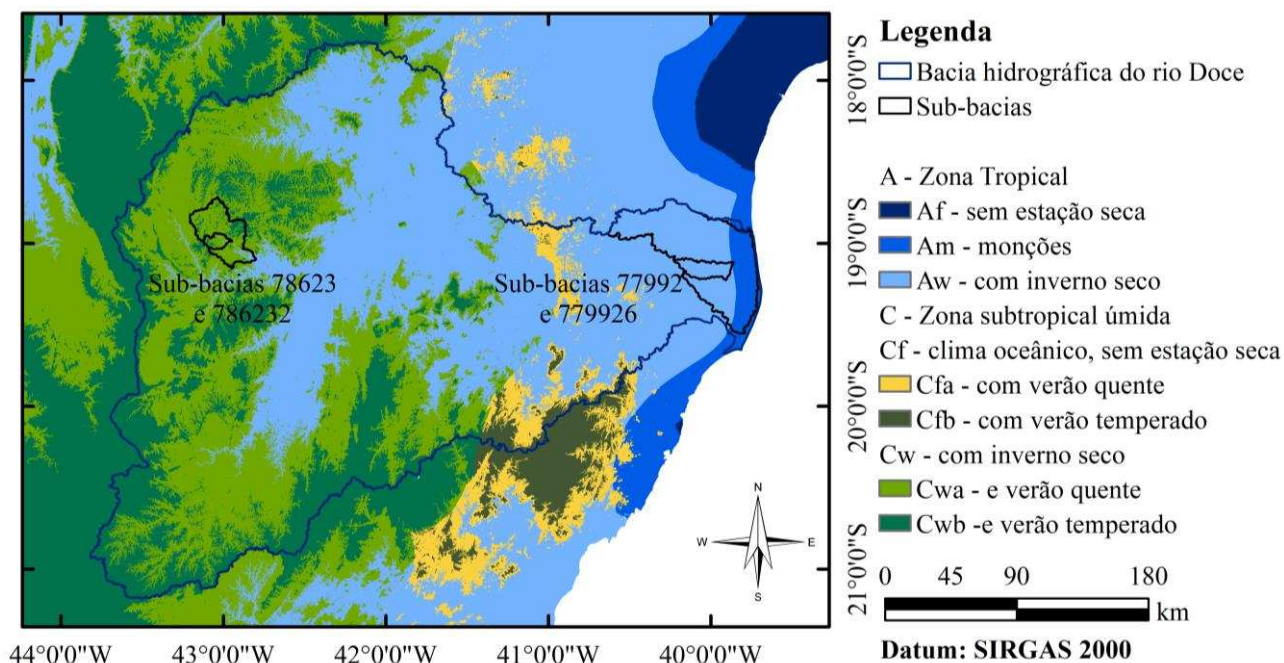


Figura 2.1.3. Distribuição da classificação climática de Köppen sobre a bacia do rio Doce e sub-bacias de interesse.

Fonte dos dados: Alvares *et al.* (2013).

Fonte: Autor.

2.1.2.2. Dados orbitais

Todo o processamento de imagens orbitais sobre a área de estudo foi realizado na plataforma Google Earth Engine (GEE) JavaScript (<https://earthengine.google.com/platform/>) (GORELICK *et al.*, 2017), salvo exceções explicitadas na sequência. No GEE foram processadas imagens SAR-C Sentinel-1 e Landsat 8 OLI (*Operational Land Imager*). Como a análise neste estudo foi realizada em quatro anos hidrológicos, as imagens Sentinel-1 e Landsat 8 foram pareadas mensalmente gerando 48 mosaicos mensais: as últimas imagens do mês (para ambos, Sentinel-1 e Landsat 8) que cobrem toda a área de estudo, são selecionadas e mosaicadas.

Para calcular o índice DPSVI foram usadas imagens Sentinel-1 pré-processadas no GEE. Foram empregadas imagens do modo de aquisição IW (*Interferometric Wide Swath Mode*), que escaneiam a superfície em três subfaixas (IW1, IW2 e IW3) com ângulos de incidência de 32.9, 28.3 e 43.1° e resolução azimutal de 22.4, 22.5 e 22.6m respectivamente (EUROPEAN SPACE AGENCY, 2019). Essas imagens são produtos *Ground Range Detected* (GRD) (EUROPEAN SPACE AGENCY, 2020a) disponíveis na coleção “COPERNICUS/S1_GRD_FLOAT” do GEE e já são pré-processados (GOOGLE EARTH ENGINE, 2020b) com as bandas VV e VH calibradas para σ^0 , cujo

tamanho do pixel passa para 10m. Filipponi (2019) descreve em detalhes o pré-processamento dos produtos GRD Sentinel-1.

Com propósito de analisar a sensibilidade do DPSVI para representar a vegetação, este foi comparado com NDVI e EVI calculados com dados do sensor ótico Landsat 8 OLI. O sensor OLI gera imagens com resolução espacial de 30 m (com exceção da banda pancromática, que é de 15 m) com cenas de órbitas sobrepostas com dimensões 170 x 183km, aproximadamente. O sensor coleta bandas no espectro visível, infravermelho próximo e de ondas curtas, totalizando nove bandas espectrais. Suas cenas foram também processadas no GEE e obtidas a partir coleção de imagens "LANDSAT/LC08/C01/T1_SR" (GOOGLE EARTH ENGINE, 2020c).

As cenas da coleção "LANDSAT/LC08/C01/T1_SR" são ortoretificadas e as imagens são em reflectância da superfície, corrigidas atmosféricamente pelo algoritmo **LaSCR** (UNITED STATES GEOLOGICAL SURVEY, 2019; VERMOTE *et al.*, 2016). Das nove bandas Landsat 8/OLI, três foram usadas no estudo: NIR (infravermelho próximo), vermelho e azul (bandas 5, 4, e 2 respectivamente), para cômputo dos índices NDVI e EVI. As cenas Landsat 8 passaram por eliminação de nuvens (e sombras de nuvens) usando atributos de qualidade de pixel (banda **pixel_qa**) gerados a partir do algoritmo **CFMask** (FOGA *et al.*, 2017; GOOGLE EARTH ENGINE, 2020c).

Processamento de imagens Sentinel-1

Para avaliar a influência do relevo sobre as imagens SAR, e por consequência no desempenho do DPSVI, foi necessário aplicar correção de terreno. Entretanto, a técnica não foi possível de ser aplicada no GEE, pois atualmente as imagens Sentinel-1 estão calibradas apenas para σ^0 (GOOGLE EARTH ENGINE, 2020b), de modo que para estudar esse efeitos topográficos algumas imagens foram obtidas do portal *Alaska Satellite Facility* (ASF, <https://asf.alaska.edu/>) e foram processadas usando o pacote **Sentinel-1 Toolbox** no software **SNAP** versão 7.0 (EUROPEAN SPACE AGENCY, 2020b). Foram calibradas para γ^0_{VV} e γ^0_{VH} (unidade de potência linear) pelo algoritmo RTF (*Radiometric Terrain Flattening*) proposto por Small (2011). Essa etapa foi aplicada na bacia 78623 e as imagens processadas (Tabela 2.1.2) foram inseridas no GEE: (https://code.earthengine.google.com/?asset=users/erlisantos/S1_GRD_FLOAT_TF).

Tabela 2.1.2. Data de aquisição de imagens Sentinel-1 para aplicação de RTF

Ano hidrológico	Semestre	Data da imagem
2015/16	Chuvoso	2015-10-23
	Seco	2016-04-20
2016/17	Chuvoso	2016-10-23
	Seco	2017-04-09
2017/18	Chuvoso	2017-10-30
	Seco	2018-04-28
2018/19	Chuvoso	2018-10-25
	Seco	2019-04-23

Mesmo após calibração e remoção de ruídos (de borda e térmico), a distribuição dos dados Sentinel-1 em unidade de potência exibe um comportamento propenso a outliers, devido a problemas de calibração que ocorrem em várias aquisições, de acordo com Frison *et al.* (2018). Esse comportamento é atenuado quando os dados estão em escala logarítmica (dB) mas isso resulta em números negativos, inviabilizando o cálculo do DPSVI. Portanto, com base no histograma de bandas σ^0 e γ^0 , foram encontrados outliers, definindo como limiar os percentis 95 e 99%, respectivamente, os quais foram mascarados. Feito isso, o efeito *speckle* foi atenuado com filtro de mediana com um kernel 5 x 5 pixels. A Figura 2.1.4 exibe o fluxograma adotado para o processamento dos dados Sentinel-1, onde os produtos finais são bandas σ^0_{VV} , σ^0_{VH} , γ^0_{VV} e γ^0_{VH} .

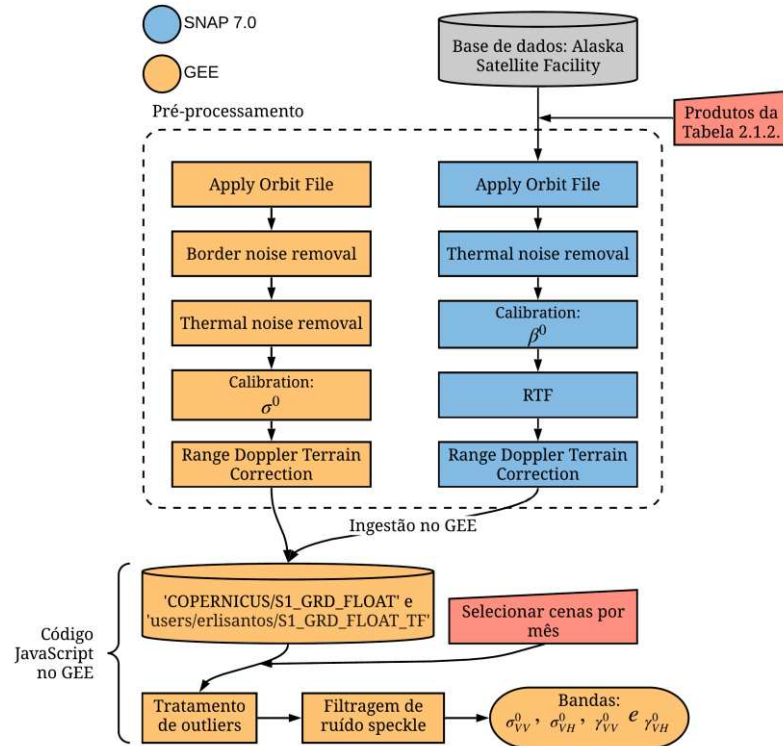


Figura 2.1.4. Pré e pós processamento de dados Sentinel-1 compondo a base de dados do estudo na plataforma GEE.

Fonte: Autor.

Índice DPSVI

O DPSVI é um produto de dois outros índices: o IDPDD (*Inverse Dual-Pol Diagonal Distance*) e o VDDPI (*Vertical Dual De-Polarization Index*), equações 1 e 2, respectivamente (PERIASAMY, 2018). O IDPDD distingue pixels de água e/ou vegetação de pixels de solo descoberto, e com a inclusão do VDDPI, o índice estratifica o tipo de alvo presente no pixel (Figura 2.1.5). O produto de IDPDD, VDDPI e a banda VH resulta no DPSVI (equação 4), cuja interpretação pode ser visualizada na Figura 2.1.5 onde o índice encontra-se matematicamente normalizado, onde valor resultante aumenta com o incremento da quantidade de biomassa acima do solo (AGB).

$$IDPDD = \frac{(\sigma^0_{VV(máx)} - \sigma^0_{VV}) + \sigma^0_{VV}}{\sqrt{2}} \quad (1)$$

$$VDDPI = \frac{\sigma^0_{VV} + \sigma^0_{VH}}{\sigma^0_{VV}} \quad (2)$$

$$VDDPI = 1 + \frac{\sigma^0_{VH}}{\sigma^0_{VV}} \quad (3)$$

$$DPSVI = \frac{(\sigma_{VV(máx)}^0 - \sigma_{VV}^0) + \sigma_{VV}^0}{\sqrt{2}} \cdot \frac{\sigma_{VV}^0 + \sigma_{VH}^0}{\sigma_{VV}^0} \cdot \sigma_{VH}^0 \quad (4)$$




Figura 2.1.5. Comportamento do DPSVI em função dos índices IDPDD, VDDPI e da banda VH.

Fonte: adaptado de Periasamy (2018).

O comportamento do IDPDD tende a saturar em regiões de biomassa densa (PERIASAMY, 2018). Partindo desse pressuposto modificações foram necessárias no modelo por dois motivos: simplificar cálculos para implementar o modelo em computação em nuvem e melhorar o desempenho do índice em regiões de biomassa densa. Assim, o IDPDD foi substituído pelo DPDD (Dual Polarization Diagonal Distance) também proposto por Periasamy (2018) que visa ser mais sensível à vegetação densa.

O VDDPI pode ser matematicamente descrito pelas equações 2 e 3: a equação 3 apresenta a soma da razão de σ_{VH}^0 por σ_{VV}^0 (empregado por Vreugdenhil *et al.* (2018)) com a unidade, podendo ser simplificado pela exclusão da unidade. Invertendo o numerador (σ_{VH}^0) e denominador (σ_{VV}^0), têm-se a taxa cruzada (CR, equação 6). O CR tem um comportamento exponencial em função de VDDPI, melhor estratificando pixels de vegetação, além de já ter sido testado por Frison *et al.* (2018) em áreas de floresta decídua. Portanto, o DPSVI modificado (DPSVIm) foi proposto como produto de DPDD, CR e σ_{VH}^0 para quantificar a vegetação na área de estudo (equação 7). DPSVI e DPSVIm são não-normalizados, mas para sua avaliação com índices óticos passaram por normalização matemática.

$$DPDD = \frac{\sigma^0_{VV} + \sigma^0_{VH}}{\sqrt{2}} \quad (5)$$

$$CR = \frac{\sigma^0_{VV}}{\sigma^0_{VH}} \quad (6)$$

$$DPSVIm = \frac{\sigma^0_{VV}^2 + \sigma^0_{VV} \cdot \sigma^0_{VH}}{\sqrt{2}} \quad (7)$$

Índices óticos de vegetação a partir das imagens Landsat 8

O NDVI, desenvolvido por Rouse *et al.* (1973), não tem um comportamento linear e tende a saturar em áreas de vegetação com altas quantidades de biomassa (GITELSON, 2004; HUETE *et al.*, 2002; JIANG *et al.*, 2008). Por essa razão, além do NDVI foi lançado mão do EVI, que foi desenvolvido para otimizar o sinal da vegetação melhorando a sensibilidade em regiões de alta biomassa, reduzindo a influência de sinal do solo e da atmosfera sobre a resposta do dossel (JIANG *et al.*, 2008; JUSTICE *et al.*, 1998). O EVI foi calculado de acordo com a equação de Justice *et al.* (1998) e Huete *et al.* (2002), mas para compatibilizar amplitude de valores de NDVI e DPSVIm, o parâmetro G foi alterado de 2.5 para 1.5. Além disso passou-se, por uma análise preliminar das imagens, identificou-se os limites de $NDVI \geq 0.3$ e $EVI \geq 0.15$ para áreas de vegetação, mascarando as imagens com esse critério a fim de perfazer análise apenas em áreas vegetadas.

Um modelo digital de declividade com resolução espacial de 30m oriundo dos dados SRTM (Shuttle Radar Topography Mission) (FARR *et al.*, 2007; FARR; KOBRIK, 2000) foi incorporada ao processamento das imagens Landsat 8 para restringir a amostragem em áreas com declividade maior que 10°: todas as amostras foram tomadas em áreas com relevo ondulado, suave ondulado e plano, que representa aproximadamente um terço da área da bacia. O propósito foi de evitar amostrar pixels que aparecem com efeitos de layover e radar shadow (WOODHOUSE, 2006) nas imagens Sentinel-1 sem procedimento de RTF. O fluxograma da Figura 2.1.6 exhibe o processamento das imagens Landsat 8 e SRTM no GEE.

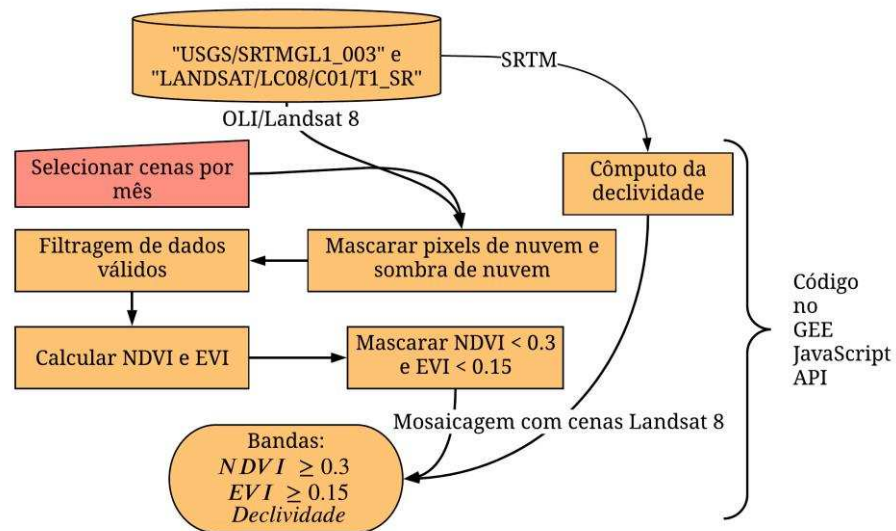


Figura 2.1.6. Processamento de dados ópticos da plataforma Landsat 8, tendo como produtos de saída as bandas de NDVI e EVI.

Fonte: Autor.

Amostragem e avaliação de resultados

O fluxograma da Figura 2.1.7 resulta do processamento ilustrado na Figura 2.1.4 e na Figura 2.1.6, e exibe o processo de amostragem aleatória em pixels com dados válidos (*no-null*) no GEE. As amostras foram empregadas para avaliar o desempenho do DPSVI e DPSVIm com os índices NDVI e EVI. A comparação dos índices de radar em função dos índices óticos foi realizada por métricas estatísticas de correlação e acurácia em um total de **103 638** amostras através do tempo e espaço, de diferentes classes de vegetação. As amostras mensais de DPSVIm vs. NDVI e DPSVIm vs. EVI foram submetidas ao teste de correlação de Spearman, em função da não-normalidade das distribuições (DE WINTER; GOSLING; POTTER, 2016).

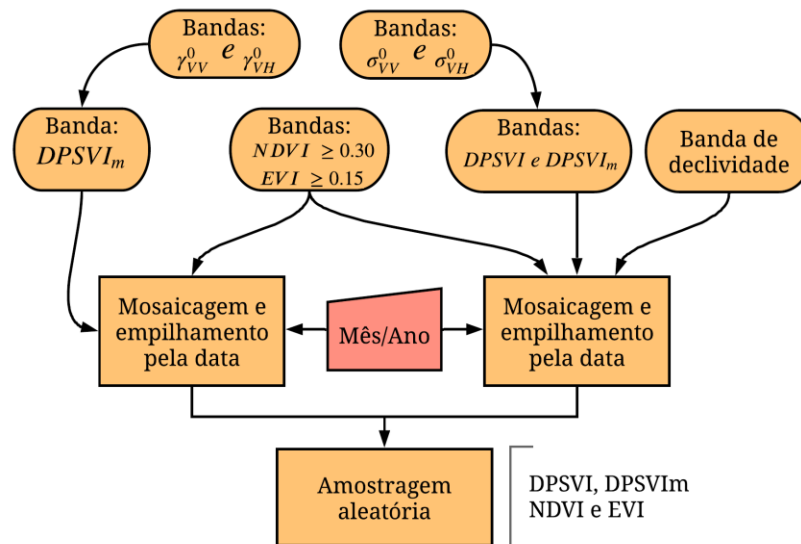


Figura 2.1.7. Processo de amostragem dos índices de vegetação DPSVIm, EVI e NDVI no GEE.

Fonte: Autor.

Todas as análises de correlação, concordância e acurácia foram executadas entre DPSVIm vs. NDVI e DPSVIm vs. EVI. Assim, como medida de acurácia adotou-se o Índice de Concordância de Willmot (d), conforme proposto por Willmott (1981). Para avaliar o viés e os erros do DPSVIm foram computados as métricas estatísticas RMSE e MBE (Root Mean Square Error e Mean Bias Error, respectivamente). Toda a avaliação foi realizada usando **linguagem R** (R CORE TEAM, 2019): medidas de acurácia obtidas com funções do pacote **hydroGOF** (ZAMBRANO-BIGIARINI, 2017) e a manipulação e visualização de dados realizada com recursos do ecossistema de pacotes **tidyverse** (WICKHAM *et al.*, 2019).

É importante deixar evidente que índices oriundos de sensores radares são diferentes daqueles provenientes de sensores óticos. Enquanto a quantidade de energia refletida por uma folha verde no espectro vermelho é dada em função da quantidade de clorofila, num determinado comprimento de micro-ondas a energia refletida é proporcional ao tamanho, forma e conteúdo de água da folha (WOODHOUSE, 2006). A comparação entre DPSVIm e os índices óticos aqui apresentadas foi uma maneira preliminar de avaliar o desempenho do índice como alternativa para a região em estudo, como aplicado também por Periasamy (2018), Chang, Shoshany e Oh (2018) e Kim e van Zyl (2009), sendo que a maneira mais verossímil de avaliar a acurácia desses índices é a partir de medidas alométricas da vegetação.

2.1.3. Resultados e discussão

Conceitualmente a origem dos índices de vegetação SAR e dos índices óticos é diferente, portanto, eles medem coisas diferentes. Índices óticos têm sido correlacionados na literatura com diversos parâmetros vegetativos como área foliar verde, biomassa verde, percentual de cobertura verde, produtividade e atividade fotossintética (APARICIO *et al.*, 2000; HUETE, 1988; JIANG *et al.*, 2006; ZHOU *et al.*, 2001), mas são baseados nos processos de fluxo de radiação de folhas isoladas e de um dossel, caracterizando componentes bioquímicos como pigmentos, mantendo uma relação com a quantidade de biomassa verde do dossel (HUETE, 1989). Já as tentativas de quantificar a cobertura vegetal a partir de observações com micro-ondas (CHANG; SHOSHANY; OH, 2018; CHOUDHURY *et al.*, 1987; KIM; VAN ZYL, 2009; PERIASAMY, 2018) são fundamentadas na relação entre o anteparo (a vegetação) e a radiação de micro-ondas incidente, de maneira que esta (pela frequência da região de micro-ondas) tende a relacionar-se com o tamanho, orientação e conteúdo de água (propriedades dielétricas) dos objetos.

Em função do exposto, avaliar uma abordagem de quantificação da cobertura vegetal por dados SAR, comparando-a com outra proveniente de sensores óticos não é suficiente, até mesmo porquê, índices óticos como variáveis aleatórias têm suas fontes de erros e incerteza. Entretanto, em primeira instância, essa comparação é válida para indicar o potencial e aplicabilidade de uma abordagem com dados desta natureza, como realizado por Chang, Shoshany e Oh (2018), Periasamy (2018) e Frison *et al.* (2018), embora Kim e Van Zyl (2000) e Periasamy (2018) tenham também validado o RVI e o DPSVI, respectivamente, com dados de AGB.

2.1.3.1. DPSVI versus DPSVIm

Para explorar os efeitos das mudanças propostas no modelo DPSVI, a Figura 2.1.8 exibe o coeficiente de correlação obtido entre NDVI vs. DPSVI e NDVI vs. DPSVIm para a sub-bacia 779926, que é representativa do comportamento observado em todas as outras áreas, e mostrando que a correlação entre NDVI e DPSVIm é superior em todos os casos comparativamente ao NDVI vs. DPSVI. Atribui-se esse melhor desempenho ao comportamento do DPSVIm em função do DPSVI, apresentado pela Figura 2.1.9 para duas cenas distintas do Sentinel-1, onde o DPSVIm tem maior amplitude que o DPSVI

com um comportamento exponencial e, sendo assim, apresenta maior capacidade de estratificar pixels de vegetação.

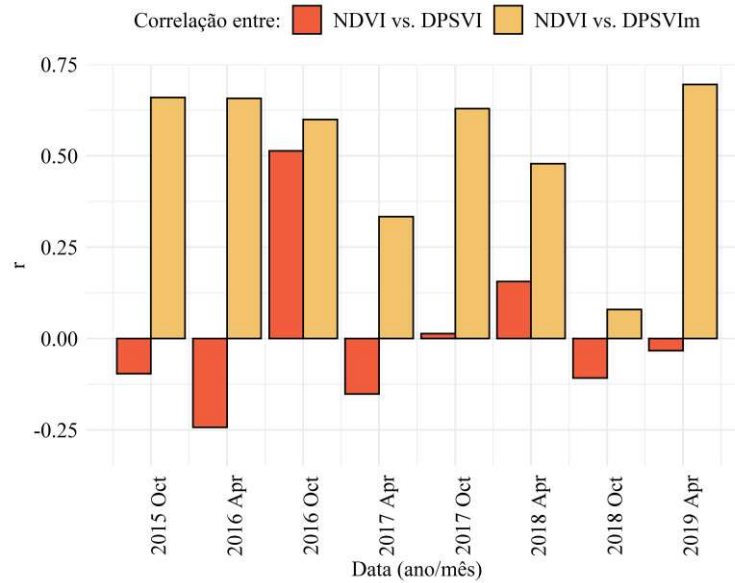


Figura 2.1.8. Correlações entre NDVI vs. DPSVI e NDVI vs. DPSVIm para a bacia 779926.

Fonte: Autor.

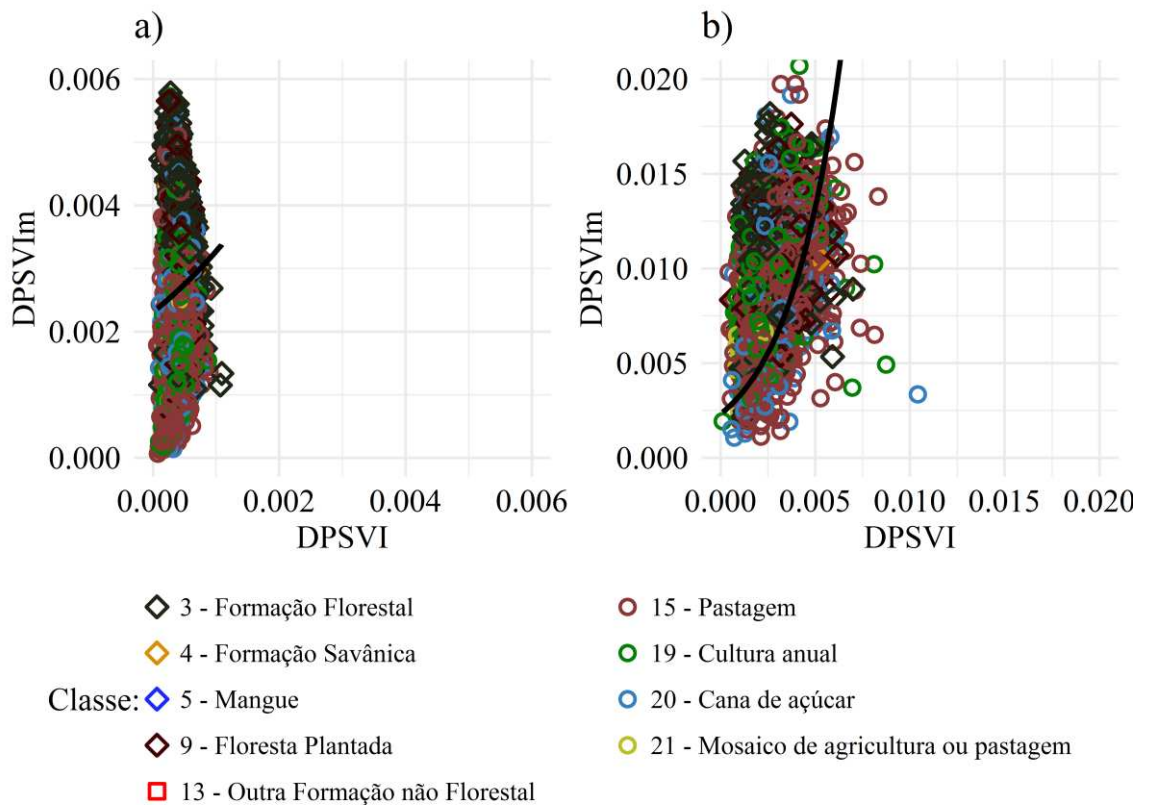


Figura 2.1.9. Diagrama de dispersão exibindo o comportamento do DPSVIm em função de DPSVI atribuindo as amostras a classe de uso e cobertura do solo (MAPBIOMAS, 2019).

Obs.: Cenas usadas:

a) S1B_IW_GRDH_1SDV_20161018T081204_20161018T081233_002558_004526_49C8;

b) S1B_IW_GRDH_1SDV_20180411T081208_20180411T081237_010433_013024_7CCD.

Fonte: Autor.

2.1.3.2. Influências sazonais e espaciais

A avaliação do DPSVIm em função dos índices espectrais de vegetação NDVI e EVI foi inicialmente realizada por meio de uma série temporal de correlação e significância da correlação, exibida pela Figura 2.1.10. Considerando a bacia do rio Doce, a Figura 2.1.10 mostra o comportamento do DPSVIm variável ao longo do ano hidrológico. A correlação entre DPSVIm com os índices óticos varia de valores próximos a zero, como nos meses de janeiro/2016, maio e novembro/2017 e fevereiro/2019, que não apresentam correlação significativa (ao intervalo de confiança $\alpha = 0.05$); chegando a valores de $r \cong 0.6$, indicando correlação significativamente positiva.

Na série temporal estes picos de correlação positiva ocorrem com frequência no período seco de cada ano hidrológico, comportamento válido para todas as bacias em análise no estudo. Este comportamento era esperado em decorrência da sensibilidade de dados SAR em função da umidade da superfície. Apesar de a sensibilidade dos dados SAR em função da precipitação não serem objeto de investigação deste estudo, é notório que a variação das chuvas ao longo do ano hidrológico introduz incertezas no modelo DPSVIm, resultando em menores correlações no período chuvoso.

Além dos efeitos do conteúdo de água da superfície promovendo uma variabilidade temporal do desempenho do DPSVIm, a variabilidade do tipo de cobertura influencia na significância da variável resposta em relação aos índices espectrais. À medida em que a escala de análise aumenta, ou seja, à medida em que a área diminui a correlação das variáveis melhora. Os maiores valores de correlação encontrados na Figura 2.1.10 dizem respeito à sub bacia 779926, que chegam a atingir $r \cong 0,75$ permanecendo mais constantes ao longo dos anos.

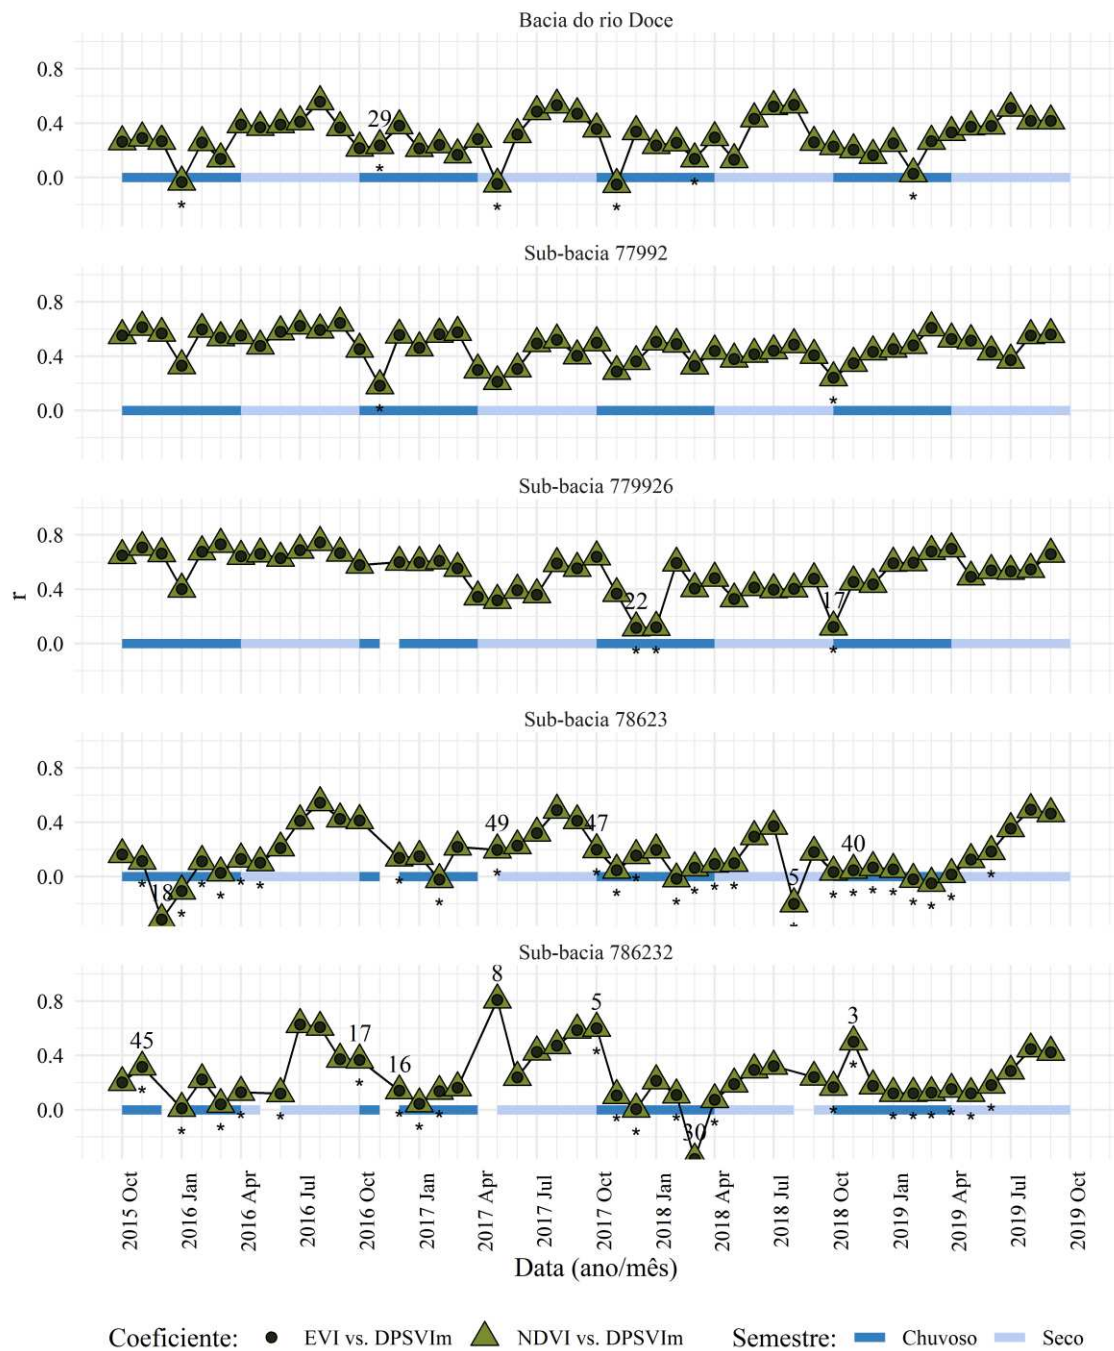


Figura 2.1.10. Série temporal dos coeficientes de correlação mensais e significância da correlação para a bacias do rio Doce e sub-bacias 786232, 78623, 779926 e 77992.

Obs.: * correlação não significante ($\alpha = 0,05$), o número sobreposto indica o número de amostras disponíveis.

Fonte: Autor.

O coeficiente de correlação e sua significância não são suficientes na avaliação do DPSVIm, isso porquê são baseados na significância estatística das amostras e não no que representa de fato o índice. Então, para avaliar a acurácia do modelo DPSVIm em função

dos índices espectrais, foi adotado o Índice de concordância de Willmott (d), conforme apresentado na Figura 2.1.11. Embora tenha sido desenvolvido para comparar variáveis preditas por um modelo (P) baseado em variáveis observadas (O) (WILLMOTT, 1981, 1982), e neste estudo todas as variáveis serem aleatórias, d representa o erro relativo médio entre DPSVIm e NDVI ou EVI e a capacidade do DPSVIm em descrever a vegetação, tal como empregado por Venancio *et al.* (2020) na avaliação do desempenho de índices óticos.

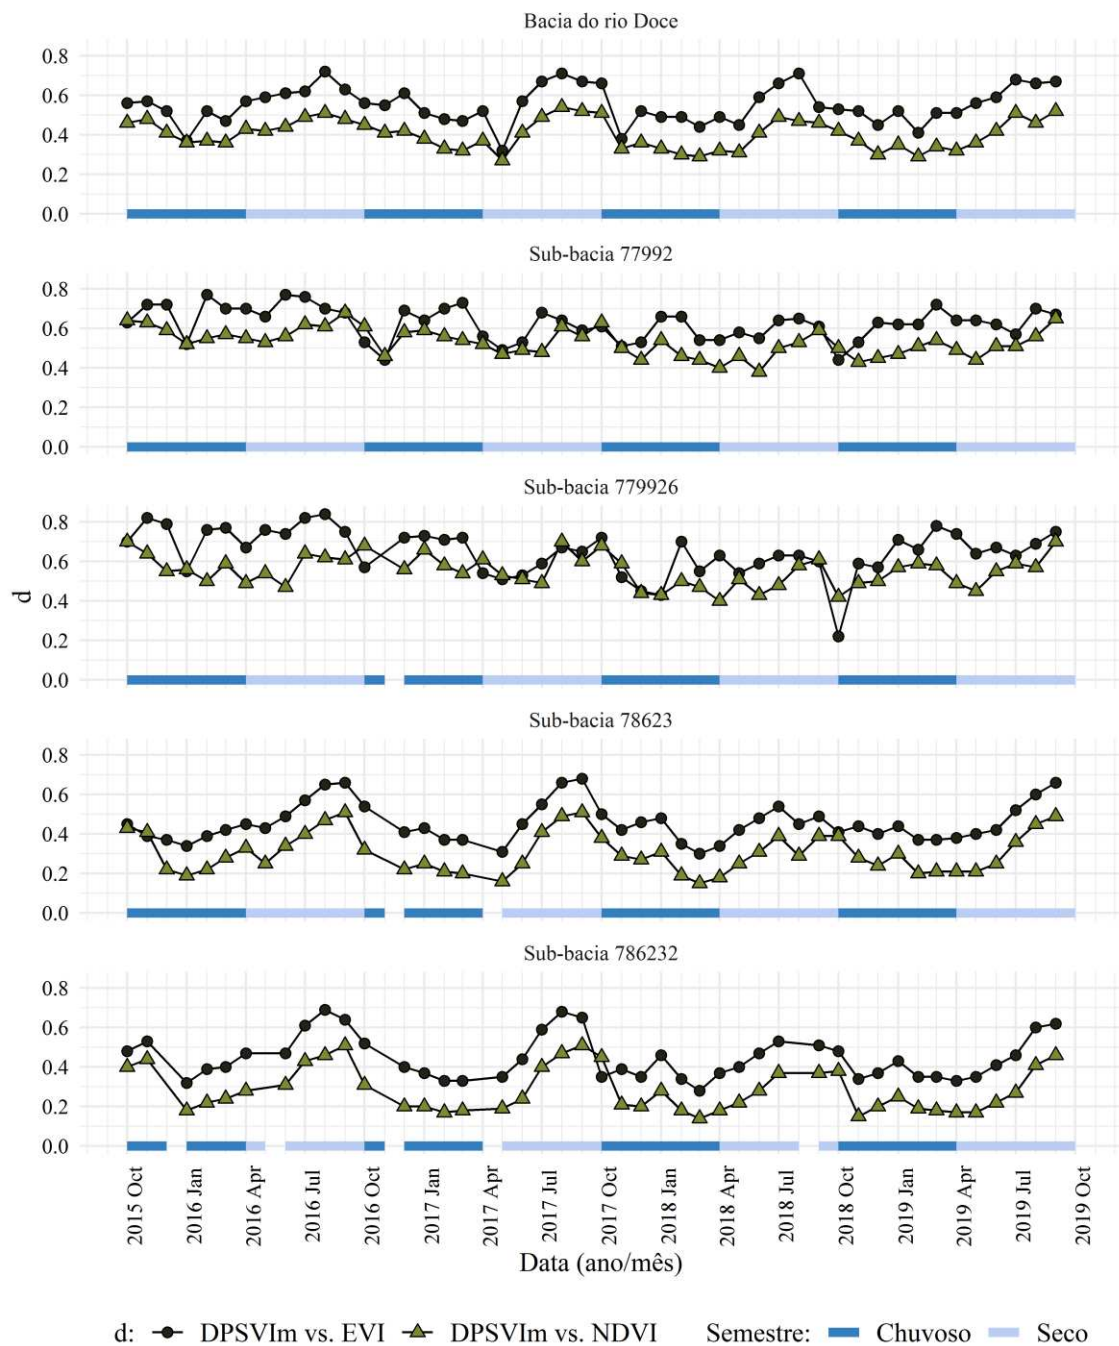


Figura 2.1.11. Índice de concordância de Willmott (d) representando o erro relativo médio, ou concordância, entre as variáveis aleatórias DPSVIm vs. EVI e DPSVIm vs. NDVI ao longo da série temporal.

Fonte: Autor.

Apesar da pequena diferença dos coeficientes de correlação entre EVI e NDVI vs. DPSVIm (Figura 2.1.10), numa observação nas séries de d (Figura 2.1.11) é notório que as concordâncias são maiores quando EVI representa o dado observado e DPSVIm o simulado. Essa constatação é válida para todas as bacias em análise, indicando que os erros associados ao EVI são relativamente menores que quando DPSVIm é associado ao NDVI.

A visualização da série temporal de d deixa evidente, ainda, a relação sazonal do índice DPSVIm em função dos índices espectrais. A concordância entre os índices tende a aumentar no final do período seco, demonstrando a susceptibilidade (atenuação ou dispersão) dos pulsos de radar à interferência da precipitação e, por conseguinte, da umidade do anteparo com que interage. Essa relação não ocorre, entretanto, com tanta notoriedade para as sub-bacias localizadas no baixo Doce (77992 e 779926). Nestas, o índice tende a permanecer mais constante através do tempo.

Em complemento ao Índice de Concordância de Willmott, a Figura 2.1.12 exhibe as métricas estatísticas de erro para a bacia do rio Doce e sub-bacias 779926 e 786232. O RMSE e MBE acrescentam uma informação ao que já foi exibido: o viés do DPSVIm em função do EVI e NDVI. Além disso, ambas as medidas denotam melhor acurácia de uma variável alternativa, nesse caso um índice alternativo, quanto mais próximo de zero for.

É perceptível na Figura 2.1.12, para a distribuição temporal da sub-bacia 779926, que RMSE tende a permanecer com valores da ordem de 0,2 e MBE da ordem de -0,2, demonstrando os menores erros comparativamente às demais áreas. Na bacia do rio Doce a sazonalidade é melhor observada entre as medidas de erro e o tempo. O DPSVIm tende a ficar mais acurado no fim do período seco, e menos acurado no fim do período chuvoso, em comparação a ambos os índices óticos. Além disso, em todas as bacias o RMSE e MBE tendem a mostrar maior acurácia do DPSVIm em comparação ao EVI. Os maiores valores de erro estão associados à sub-bacia 786232, conforme também apresentado na Figura 2.1.10 em que boa parte das correlações não foram significativas.




Figura 2.1.12. Séries temporais do RMSE e MBE para a bacia do rio Doce e sub-bacias 779926 e 786232.

Fonte: Autor.

Verifica-se, pela interpretação das métricas estatísticas de acurácia (Figura 2.1.11 e Figura 2.1.12), que o DPSVIm tem melhor ajuste aos dados do EVI do que NDVI. Essa constatação torna potencial a aplicação do índice DPSVIm para quantificar e mapear a cobertura vegetal em áreas densas, uma vez que o EVI tende a representar melhor a cobertura vegetal densa, como a Mata Atlântica (HUETE *et al.*, 2002; JIANG *et al.*, 2008; JUSTICE *et al.*, 1998). A Figura 2.1.9 deixa evidente a capacidade do DPSVIm de estratificar a cobertura vegetal pela quantidade de biomassa na superfície, onde formações florestais e florestas plantadas assumem maiores valores, reduzindo à medida que se aproxima de classes como culturas anuais e pastagens.

Esse ajuste aos índices óticos mostrou-se sensível à sazonalidade do regime de chuvas, pois no semestre chuvoso o desempenho do DPSVIm caiu em todos os anos hidrológicos. Isso se dá porquê na estação chuvosa aumenta também a umidade do solo, que afeta significativamente (dependendo da densidade da cobertura vegetal) o retroespalhamento nas bandas HH e VV (co-polarização) e em menor grau para bandas de polarização cruzada (VH) (SAATCHI, 2019). Ainda de acordo com Saatchi (2019), a água interceptada pelo dossel provinda da precipitação ou no início da manhã devido ao orvalho, gera gotículas de água nas folhas que provocam dispersão e atenuação do sinal SAR, especialmente para banda C. Veloso *et al.* (2017), que estudaram monitoramento de culturas agrícolas, demonstraram como a precipitação influencia nos coeficientes de retroespalhamento, principalmente da banda VV oriunda do Sentinel-1. Kasischke *et al.* (2003) estudaram os efeitos de padrões hidrológicos sazonais em pântanos no sul da Flórida no retroespalhamento medido pelo sensor SAR ERS-2 (também de banda C) e concluíram que as variações na biomassa tiveram um impacto relativamente pequeno nas variações na retrodispersão associadas às mudanças na umidade do solo e no nível da água.

A sazonalidade do regime de chuvas é menor nas sub-bacias 77992 e 779926, que se encontram na porção mais baixa da bacia do rio Doce. E embora seja consenso, através dos dados obtidos neste estudo e em relatórios como ECOPLAN-LUME (2010), que o período chuvoso seja de outubro a março de cada ano hidrológico, na porção do baixo Doce o total precipitado no período chuvoso é menor que nas áreas de maior altitude (onde localizam-se as sub-bacias 78623 e 786232), isso de acordo com normais climatológicas de 1961 a 1990 (ECOPLAN-LUME, 2010; IGAM, 2008). A caracterização climática dessa região é Aw, enquanto que nas sub-bacias de altitude o clima predominante é Cwa e Cwb. Essa combinação de inverno seco e menor precipitação no período chuvoso pode ser levada em conta como uma das razões para a constância nos valores de r e d observados nas sub-bacias 77992 e 779926 ao longo do tempo.

2.1.3.3. Influências do relevo

Com diminuição do espaço amostral e da declividade deste o desempenho do DPSVIm melhorou. Isso pode ser observado nas sub-bacias 77992 e 779926, em detrimento da bacia do rio Doce. Essa restrição no tamanho da área tende a reduzir a variabilidade dos dados e ocasiona nos maiores coeficientes de correlação registrados, com exceção dos meses de dezembro/2017, janeiro e outubro de 2018, onde o número de

amostras é insuficiente para inferir em qualquer decisão. Tal fenômeno pode ser explicado pelo conceito de continuidade espacial, em que a continuidade (ou dependência) tende a ser maior com a proximidade (ISAACS; SRIVASTAVA, 1989), que remete ainda ao postulado de Tobler (1970) de que coisas mais próximas são mais relacionadas. Entretanto o mesmo não acontece com as sub-bacias 78623 e 786232, onde os resultados são provavelmente influenciados pelo fator topográfico.

Considerando que o espaço amostral nas sub-bacias 78623 e 786232 é ainda menor que nas bacias 77992 e 779926, mas a magnitude dos erros são as maiores (Figura 2.1.12), o ajuste insuficiente do DPSVIm nestas sub-bacias tem um outro fator de origem: a topografia e orientação do terreno. Nessas sub-bacias o relevo é predominantemente forte ondulado, diferente das sub-bacias do baixo Doce, como mostra a Figura 2.1.1 e o diagrama na Figura 2.1.13.

As variações no relevo provocam distorções radiométricas na amplitude do sinal retroespalhado para o sensor SAR. Esse é um problema recorrente na literatura, principalmente no que diz respeito ao mapeamento de biomassa florestal, como demonstrado por Luckman *et al.* (1998), Sun *et al.*, (2002), Soja *et al.* (2010) e Atwood *et al.* (2014). O impacto da topografia no sinal retroespalhado pode dominar variações normais no sinal de uma floresta (Atwood *et al.*, 2014). Por isso, o melhor desempenho do DPSVIm nas sub-bacias 77992 e 779926 não é apenas atribuído ao tamanho da área, mas também à menor variação na declividade do terreno (Figura 2.1.13).




Figura 2.1.13. Distribuição da declividade (GD: grau decimal) do terreno na bacia do rio Doce e sub-bacias em análise.

Fonte: Autor.

A abordagem mais usual na literatura para perfazer atenuação dos efeitos da topografia para dados Sentinel-1 é a metodologia proposta por Small (2011): o algoritmo de RTF. Entretanto, como já exposto, devido aos artefatos nas encostas de montanhas esse algoritmo ainda não foi implementado no GEE. Devido a isso, algumas alternativas, como a proposta por Hoekman e Reiche (2015), foram implementadas por Slagter *et al.* (2020) no GEE. Essa abordagem leva em consideração o ângulo de incidência local (LAI). Entretanto, normalizações que levam em conta apenas o ângulo de incidência local tendem a apresentar performance pobre como aponta Small (2011). Por isso as imagens que cobrem as sub-bacias 78623 e 786232 foram processadas por RTF.

A Figura 2.1.14 confronta as medidas de correlação, concordância e acurácia do DPSVIm em função do EVI para a sub-bacia 78623, antes e após o processamento RTF, referente às imagens que constam na Tabela 2.1.2. É importante destacar que com o procedimento as amostras usadas para gerar a Figura 2.1.14 não foram filtrados pela declividade $< 10^\circ$, pois, os efeitos topográficos dos pixels projetados em elipsoide (σ^0) foram atenuados (γ^0). A técnica foi aplicada apenas a essa sub-bacia por ser uma das que apresenta maior amplitude de declividade. Em todos os casos a correlação entre EVI e DPSVIm aumentou, melhorando o ajuste dos dados, bem como as correlações positivas passaram a ser significantes ($p - value < 0.05$ em um intervalo de confiança $\alpha = 0.05$). Embora a correlação tenha melhorado significativamente, d e RMSE tenderam a permanecer próximos.




Figura 2.1.14. Correlação (r), concordância (d) e acurácia (RMSE) entre NDVI e DPSVIm obtido antes e após RTF (σ^0 e γ^0 , respectivamente) para a sub-bacia 78623.

Fonte: Autor.

Por se tratar de um índice baseado no retroespalhamento da banda C há limitações inerentes à essa frequência para estudos de vegetação, pois o sinal retroespalhado para sensores SAR-C tende a saturar com o aumento de AGB. Essa saturação é entendida como a perda da sensibilidade do retroespalhamento referente à vegetação a partir de determinada quantidade de AGB (JOSHI *et al.*, 2017): pesquisas mostram que em média o retroespalhamento na banda C saturam em regiões abaixo do limite de 50 Mg ha⁻¹ (DOBSON *et al.*, 1992; IMHOFF, 2019; SARKER *et al.*, 2013). Essa pode também ser uma fonte de incerteza e limitação de índices polarimétricos derivados dos dados do sensor SAR Sentinel-1, carecendo de campanhas de campo para colocar à prova nestas áreas de biomassa densa o índice DPSVIm.

Além disso, uma fonte de incerteza no modelo, melhor observada através do tempo pela sazonalidade do regime pluviométrico, é a umidade da superfície. Sugere-se que em trabalhos futuros a relação entre o DPSVIm e variáveis que denotem a umidade da superfície, como umidade do solo e conteúdo de água da vegetação (VWC), sejam mensuradas, como feito por Szigarski *et al.* (2018) que propuseram melhorias no RVI através da mensuração dessas variáveis ambientais, as quais podem ser inseridas no modelo através do conceito de propriedade dielétrica (ϵ) dos alvos, proposto inclusive por Periasamy (2018).

2.1.4. Conclusões

As modificações propostas no DPSVI tornaram o índice mais sensível ao detalhamento da vegetação no bioma Mata Atlântica e reduziram a demanda computacional para processamento das análises.

O DPSVI modificado apresentou desempenho adequado para representar a cobertura vegetal na bacia do rio Doce, principalmente em áreas cujas propriedades topográficas e dielétricas são naturalmente menos influentes.

Em todas as áreas amostradas houve maior concordância do DPSVIm ao EVI, em detrimento do NDVI, independente da classe de relevo predominante, mostrando aplicabilidade no mapeamento de biomassa densa.

A topografia como parâmetro da superfície detectada é uma fonte de incertezas em modelos derivados de observações SAR, mas a atenuação do efeito por técnicas como RTF são uma alternativa para minimizar os efeitos deste parâmetro.

A sazonalidade do regime de chuvas é um fator ambiental que influencia nas medições de radar, afetando o DPSVIm em todas as escalas de estudo e indicando que a inclusão das propriedades dielétricas deve ser considerada em trabalhos futuros, com objetivo de atenuar essa incerteza temporal.

2.1.5. Referências

AGÊNCIA NACIONAL DE ÁGUAS. **Dados Abertos da Agência Nacional de Águas**. Disponível em: <<http://dadosabertos.ana.gov.br/>>. Acesso em: 21 jun. 2020.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

APARICIO, N. *et al.* Spectral Vegetation Indices as Nondestructive Tools for Determining Durum Wheat Yield. **Agronomy Journal**, v. 92, n. 1, p. 83–91, 1 jan. 2000.

ARII, M.; VAN ZYL, J. J.; KIM, Y. A general characterization for polarimetric scattering from vegetation canopies. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 9, p. 3349–3357, set. 2010.

ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 15 dez. 2001.

ATWOOD, D. K. *et al.* Impact of Topographic Correction on Estimation of Aboveground Boreal Biomass Using Multi-temporal, L-Band Backscatter. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 8, p. 3262–3273, ago. 2014.

BRASIL. **Conselho Nacional de Recursos Hídricos: Resolução nº 30, de dezembro de 2002** Brasil, 2003. Disponível em: <<https://pesquisa.in.gov.br/imprensa/jsp/visualiza/index.jsp?data=19/03/2003&jornal=1000&pagina=32&totalArquivos=36>>

CHANG, J. G.; SHOSHANY, M.; OH, Y. Polarimetric Radar Vegetation Index for Biomass Estimation in Desert Fringe Ecosystems. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 12, p. 7102–7108, 1 dez. 2018.

CHARBONNEAU, F.; TRUDEL, M.; FERNANDES, R. **Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping**. Proceedings of the 2005 Advanced Synthetic Aperture Radar (ASAR). **Anais...St-Hubert: 2005**

CHOUDHURY, B. J. *et al.* Monitoring vegetation using nimbus-7 scanning multichannel microwave radiometer's data. **International Journal of Remote Sensing**, v. 8, n. 3, p. 533–538, 1987.

COLWELL, J. E. Vegetation canopy reflectance. **Remote Sensing of Environment**, v. 3, n. 3, p. 175–183, 1 jan. 1974.

DE WINTER, J. C. F.; GOSLING, S. D.; POTTER, J. Comparing the pearson and spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data. **Psychological Methods**, v. 21, n. 3, p. 273–290, 1 set. 2016.

DOBSON, M. C. *et al.* Dependence of Radar Backscatter on Coniferous Forest Biomass. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 412–415, 1992.

DUBE, T.; MUTANGA, O. Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 101, p. 36–46, 1 mar. 2015.

ECOPLAN-LUME. **Plano integrado de recursos hídricos na bacia hidrográfica do**

rio Doce e planos de ações para as unidades de planejamento e gestão de recursos hídricos no âmbito da bacia do rio Doce. [s.l.: s.n.].

EUROPEAN SPACE AGENCY, E. **Terms of the Copernicus Data Hub portals and Data supply conditions.** Disponível em: <<https://scihub.copernicus.eu/twiki/do/view/SciHubWebPortal/TermsConditions>>. Acesso em: 23 abr. 2020a.

EUROPEAN SPACE AGENCY, E. **Sentinel-1 Toolbox.** Disponível em: <<https://sentinel.esa.int/web/sentinel/toolboxes/sentinel-1>>. Acesso em: 23 abr. 2020b.

FARR, T. G. *et al.* The Shuttle Radar Topography Mission. **Reviews of Geophysics**, v. 45, n. 2, p. RG2004, 19 maio 2007.

FARR, T. G.; KOBRICK, M. Shuttle radar topography mission produces a wealth of data. **Eos, Transactions American Geophysical Union**, v. 81, n. 48, p. 583, 2000.

FILGUEIRAS, R. *et al.* Crop NDVI Monitoring Based on Sentinel 1. **Remote Sensing**, v. 11, n. 12, p. 1441, 2019.

FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, v. 18, n. 1, p. 11, 4 jun. 2019.

FOGA, S. *et al.* Cloud detection algorithm comparison and validation for operational Landsat data products. **Remote Sensing of Environment**, v. 194, p. 379–390, jun. 2017.

FRISON, P.-L. *et al.* Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology. **Remote Sensing**, v. 10, n. 12, p. 2049, 17 dez. 2018.

GITELSON, A. A. Wide Dynamic Range Vegetation Index for Remote Quantification of Biophysical Characteristics of Vegetation. **Journal of Plant Physiology**, v. 161, n. 2, p. 165–173, 1 jan. 2004.

GOOGLE EARTH ENGINE. **SRTM Digital Elevation Data 30m.** Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/USGS_SRTMGL1_003>. Acesso em: 21 jun. 2020a.

GOOGLE EARTH ENGINE. **Sentinel-1 Algorithms | Google Earth Engine | Google Developers.** Disponível em: <<https://developers.google.com/earth-engine/sentinel1>>. Acesso em: 23 abr. 2020b.

GOOGLE EARTH ENGINE. **USGS Landsat 8 Surface Reflectance Tier 1 | Earth Engine Data Catalog.** Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C01_T1_SR#description>. Acesso em: 24 abr. 2020c.

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

HIRD, J. *et al.* Google Earth Engine, Open-Access Satellite Data, and Machine Learning

in Support of Large-Area Probabilistic Wetland Mapping. **Remote Sensing**, v. 9, n. 12, p. 1315, 14 dez. 2017.

HOEKMAN, D. H.; REICHE, J. Multi-model radiometric slope correction of SAR images of complex terrain using a two-stage semi-empirical approach. **Remote Sensing of Environment**, v. 156, p. 1–10, 1 jan. 2015.

HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 1 nov. 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1 ago. 1988.

HUETE, A. R. Soil influences in remotely sensed vegetation-canopy spectra. In: ASRAR, G. (Ed.). . **Theory and Applications of Optical Remote Sensing**. New York, NY: Wiley, 1989. p. 107–141.

IGAM, I. M. DE G. DAS Á. **Banco de Dados Hidrogeológicos do Instituto Mineiro de Gestão das Águas no Estado de Minas Gerais**. Belo Horizonte: [s.n.]. Disponível em: <<http://www.igam.mg.gov.br/>>.

IMHOFF, M. L. Radar backscatter and biomass saturation: ramifications for global biomass inventory. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 511–518, 28 jun. 2019.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Geociências**. Disponível em: <<https://www.ibge.gov.br/geociencias/todos-os-produtos-geociencias.html>>. Acesso em: 21 jun. 2020.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. [s.l.] Oxford University Press, 1989.

JIANG, Z. *et al.* Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. **Remote Sensing of Environment**, v. 101, n. 3, p. 366–378, 15 abr. 2006.

JIANG, Z. *et al.* Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 15 out. 2008.

JOSHI, N. *et al.* Understanding “saturation” of radar signals over forests. **Scientific Reports**, v. 7, n. 1, p. 1–11, 1 dez. 2017.

JUSTICE, C. O. *et al.* The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KASISCHKE, E. S. *et al.* Effects of seasonal hydrologic patterns in south Florida wetlands on radar backscatter measured from ERS-2 SAR imagery. **Remote Sensing of Environment**, v. 88, n. 4, p. 423–441, 30 dez. 2003.

KIM, Y.; VAN ZYL, J. **On the relationship between polarimetric parameters.** IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment. Proceedings (Cat. No.00CH37120). **Anais...IEEE**, 2000Disponível em: <<http://ieeexplore.ieee.org/document/858099/>>. Acesso em: 6 maio. 2020

KIM, Y.; VAN ZYL, J. J. A time-series approach to estimate soil moisture using polarimetric radar data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 8, p. 2519–2527, ago. 2009.

LEHMANN, E. A. *et al.* Forest cover trends from time series Landsat data for the Australian continent. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, n. 1, p. 453–462, 1 abr. 2012.

LIU, X. *et al.* Lake evaporation in a hyper-arid environment, northwest of China-measurement and estimation. **Water (Switzerland)**, v. 8, n. 11, p. 1–21, 2016.

LUCKMAN, A. *et al.* Tropical forest biomass density estimation using JERS-1 SAR: Seasonal variation, confidence limits, and application to image mosaics. **Remote Sensing of Environment**, v. 63, n. 2, p. 126–139, 1 fev. 1998.

MAPBIOMAS. **Coleção 4.1 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil.** Disponível em: <<https://mapbiomas.org/>>. Acesso em: 28 abr. 2020.

MOREIRA, E. P. *et al.* Efeito topográfico sobre índices de vegetação obtidos com dados Landsat TM: É necessário correção topográfica? **Boletim de Ciências Geodesicas**, v. 22, n. 1, p. 95–107, 1 jan. 2016.

NASA JPL. **NASADEM Merged DEM Global 1 arc second V001 [Data set]. NASA EOSDIS Land Processes DAAC.** Disponível em: <https://doi.org/10.5067/MEaSURES/NASADEM/NASADEM_HGT.001>. Acesso em: 10 set. 2020.

NASIRZADEHDIZAJI, R. *et al.* Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. **Applied Sciences**, v. 9, n. 4, p. 655, 15 fev. 2019.

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. **Remote Sensing of Environment**, v. 217, n. September, p. 537–549, 2018.

PFAFSTETTER, O. **Classificação de bacias hidrográficas.** Rio de Janeiro: [s.n.].

PIRES, A. P. F. *et al.* Forest restoration can increase the Rio Doce watershed resilience. **Perspectives in Ecology and Conservation**, v. 15, n. 3, p. 187–193, 1 jul. 2017.

R CORE TEAM, R. **R: A Language and Environment for Statistical Computing**ViennaR Foundation for Statistical Computing, , 2019. Disponível em: <<https://www.r-project.org/>>

ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

SAATCHI, S. SAR Methods for Mapping and Monitoring Forest Biomass. In: FLORES-ANDERSON, A. I. *et al.* (Eds.). . **The Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation**. Huntsville: NASA, 2019.

SANO, E. E. *et al.* Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v. 28, n. 12, p. 2739–2752, 29 jun. 2007.

SANTOS, H. G. DOS *et al.* **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília: Embrapa, 2018.

SARKER, M. L. R. *et al.* Forest biomass estimation using texture measurements of high-resolution dual-polarization C-band SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 6, p. 3371–3384, 2013.

SLAGTER, B. *et al.* Mapping wetland characteristics using temporally dense Sentinel-1 and Sentinel-2 data: A case study in the St. Lucia wetlands, South Africa. **International Journal of Applied Earth Observation and Geoinformation**, v. 86, p. 102009, 1 abr. 2020.

SMALL, D. Flattening Gamma: Radiometric Terrain Correction for SAR Imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 8, p. 3081–3093, 2011.

SOJA, M. J.; SANDBERG, G.; ULANDER, L. M. H. **Topographic correction for biomass retrieval from P-band SAR Data in Boreal Forests**. International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...2010**

SUN, G.; RANSON, K. J.; KHARUK, V. I. Radiometric slope correction for forest biomass estimation from SAR data in the Western Sayani Mountains, Siberia. **Remote Sensing of Environment**, v. 79, n. 2–3, p. 279–287, 1 fev. 2002.

SZIGARSKI, C. *et al.* Analysis of the Radar Vegetation Index and Potential Improvements. **Remote Sensing**, v. 10, n. 11, p. 1776, 2018.

TOBLER, W. R. A Computer Movie Simulating Urban Growth in the Detroit Region. **Economic Geography**, v. 46, p. 234, jun. 1970.

UNITED STATES GEOLOGICAL SURVEY, U. **Landsat 8 Surface Reflectance Code (LaSRC) product guide**. [s.l: s.n.].

VELOSO, A. *et al.* Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote Sensing of Environment**, v. 199, p. 415–426, 15 set. 2017.

VENANCIO, L. P. *et al.* Potential of using spectral vegetation indices for corn green

biomass estimation based on their relationship with the photosynthetic vegetation sub-pixel fraction. **Agricultural Water Management**, v. 236, p. 106155, 30 jun. 2020.

VERMOTE, E. *et al.* Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, 1 nov. 2016.

WANG, J.; RICH, P. M.; PRICE, K. P. Temporal responses of NDVI to precipitation and temperature in the central Great Plains, USA. **International Journal of Remote Sensing**, v. 24, n. 11, p. 2345–2364, 10 jun. 2003.

WANG, T. *et al.* Temporal and spatial patterns of NDVI and their relationship to precipitation in the Loess Plateau of China. **International Journal of Remote Sensing**, v. 31, n. 7, p. 1943–1958, 23 abr. 2010.

WICKHAM, H. *et al.* Welcome to the Tidyverse. **Journal of Open Source Software**, v. 4, n. 43, p. 1686, 21 nov. 2019.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v. 2, n. 2, p. 184–194, 1981.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin - American Meteorological Society**, v. 63, n. 11, p. 1309–1313, 1982.

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**. Boca Raton: CRC Press, 2006.

ZAMBRANO-BIGIARINI, M. **hydroGOF: Goodness-of-Fit Functions for Comparison of Simulated and Observed Hydrological Time Series**, 2017. Disponível em: <<https://cran.r-project.org/package=hydroGOF>>

ZHOU, L. *et al.* Variations in northern vegetation activity inferred from satellite data of vegetation index during 1981 to 1999. **Journal of Geophysical Research: Atmospheres**, v. 106, n. D17, p. 20069–20083, 16 set. 2001.

2.2. Artigo 2 – Monitoramento contínuo da vegetação em bacias hidrográficas com base em integração de imagens ópticas e de radar

2.2.1. Introdução

O mapeamento de grandes áreas utilizando sensoriamento remoto óptico é desafiador em decorrência do expressivo volume de dados de satélite para fins de aquisição e processamento, além da presença de falhas na continuidade espacial em decorrência da cobertura de nuvens (CARRASCO *et al.*, 2019). Entretanto, a ocorrência de nuvens (e suas sombras) em imagens ópticas não é um desafio apenas para grandes áreas, como demonstraram Roy e Yan (2020) ao desenvolverem um sistema de monitoramento de cultivos em escala local por modelagem temporal de índices de vegetação oriundos da missão Landsat. Portanto, a presença de nuvens é um desafio em diferentes escalas de observação e no monitoramento de diferentes atividades, como o monitoramento da dinâmica da cobertura vegetal.

A dinâmica da cobertura vegetal tem sido estudada pelo uso de índices espectrais de vegetação. Estes não apenas embasam, em nível sinóptico, a tomada de decisão em diferentes segmentos como agricultura, floresta e ambiente (PERIASAMY, 2018) como também em diversos estudos hidrológicos com objetivos distintos (LIU *et al.*, 2016; WANG; RICH; PRICE, 2003; WANG *et al.*, 2010). São também usados na climatologia, onde a classificação e mapeamento da vegetação é uma tarefa imprescindível, pois a vegetação fornece base para todos os seres vivos e desempenha papel essencial no armazenamento de carbono na superfície, afetando as mudanças climáticas globais e influenciando o CO₂ terrestre (XIAO *et al.*, 2004; XIE; SHA; YU, 2008).

Os índices ópticos de vegetação são calculados por técnicas aplicadas às medidas tomadas por sensores ópticos, como o NDVI (*Normalized Difference Vegetation Index*) e o SAVI (*Soil Adjusted Vegetation Index*) que são baseados na reflectância do vermelho e infravermelho próximo (APARICIO *et al.*, 2000; ASNER, 2001; HUETE, 1988; ROUSE *et al.*, 1973; WANG *et al.*, 2010) e o EVI (*Enhanced Vegetation Index*) que inclui também a reflectância no espectro azul (HUETE *et al.*, 2002; JUSTICE *et al.*, 1998). Para isso, vários sensores têm sido usados, como demonstrado por Xie (2008), que revisou os sensores ópticos usados com essa finalidade, incluindo as missões Landsat (TM e ETM+), SPOT, MODIS, ASTER (e outros) e, mais recentemente, uma nova era em termos de alta resolução espacial e temporal com a constelação Sentinel-2 A e B (IMMITZER; VUOLO;

ATZBERGER, 2016; WANG *et al.*, 2017), todos estes sujeitos às condições atmosféricas do momento de aquisição de dados da superfície.

As nuvens são um grande obstáculo ao sensoriamento remoto óptico de regiões tropicais úmidas (ASNER, 2001). Nesse sentido, alguns esforços surgiram para contornar este problema. Roy e Yan (2020) aplicaram modelos não-lineares harmônicos sobre dados Landsat para modelagem de NDVI em lavouras, assim como Pouliot e Latifovic (2018). Por outro lado, além de modelos harmônicos, a fusão de dados multisensores também emergiu envolvendo a integração de dados de radares de abertura sintética (SAR), pois os sistemas SAR são bem estabelecidos e podem fornecer imagens de alta resolução independente de condições climáticas (REIGBER *et al.*, 2020).

Existem robustos índices de vegetação SAR, como RVI (*Radar Vegetation Index*) e PRVI (*Polarimetric Radar Vegetation Index*), e os mais recentes Pol (*Normalized Polarization*) e DPSVI (*Dual Polarimetric SAR Vegetation Index*) (CHANG; SHOSHANY; OH, 2018; HIRD *et al.*, 2017; KIM; VAN ZYL, 2000; PERIASAMY, 2018), mas estes apresentam limitações por características dos sensores. Assim, trabalhos tem focado em fusionar dados ópticos com dados SAR, como Carrasco *et al.* (2019) que empregaram a agregação temporal de imagens Landsat 8, Sentinel-2 e Sentinel-1 e Filgueiras *et al.* (2019a) que executaram a modelagem do NDVI com covariáveis de radar em áreas agrícolas irrigadas.

O Artigo 1 demonstrou que a aplicação do DPSVIm (DPSVI modificado) apresentou potencial de representar vegetação densa, quando confrontado aos índices NDVI e EVI, principalmente em regiões planas. Dada essa relação complementar, o objetivo deste trabalho é: a) predizer valores de NDVI e EVI oriundos de imagens OLI/Landsat 8 em diferentes escalas espaciais por meio de sistemas de aprendizado de máquina usando covariáveis provenientes do sensor SAR-C dos satélites Sentinel-1 A e B; e b) avaliar a importância das covariáveis de radar, principalmente o DPSVIm na predição dos índices ópticos bem como avaliar o desempenho dos algoritmos de predição empregados.

2.2.2. Metodologia

2.2.2.1. Área de estudo

O espaço amostral escolhido foi a bacia hidrográfica do rio Doce, situada na região Sudeste do Brasil e inserida nos Estados de Minas Gerais e Espírito Santo. Abrange uma

área de drenagem de, aproximadamente, 86555 km² (AGÊNCIA NACIONAL DE ÁGUAS, 2017). O rio Doce tem sua foz no Oceano Atlântico, fazendo com que a bacia apresente altitude mínima de 0 m (nível do mar), atingindo máxima de 2606m de acordo com modelo digital de elevação NASADEM (NASA JPL, 2020). Além desta, duas sub-bacias foram escolhidas para avaliar os modelos em diferentes escalas e situações de relevo, representadas pelos códigos: 77992 e 78623, codificadas de acordo com a metodologia proposta por Pfafstetter (1989) adotada oficialmente no Brasil pela Agência Nacional de Águas (BRASIL, 2003).

Uma descrição das características planialtimétricas da bacia e suas sub-bacias é dada pela Tabela 2.2.1. Características físicas da bacia do rio Doce e sub-bacias em estudo., e a Figura 2.2.1 traz localização da bacia e sub-bacias com modelo digital de declividade representando variações e classes no relevo de acordo com Santos *et al.* (2018).

Tabela 2.2.1. Características físicas da bacia do rio Doce e sub-bacias em estudo.

Bacia/Sub-bacia	Área aproximada (km²)	Altitude (m)			
		Máxima	Média	Mínima	Desvio-padrão
Rio Doce	86 555.00	2606	519.32	0	307.50
77992	3996.46	560	62.88	0	62.62
78623	1043.12	1272	760.06	360	112.60

Fonte dos dados altimétricos: Modelo Digital de Elevação NASADEM (NASA JPL, 2020).

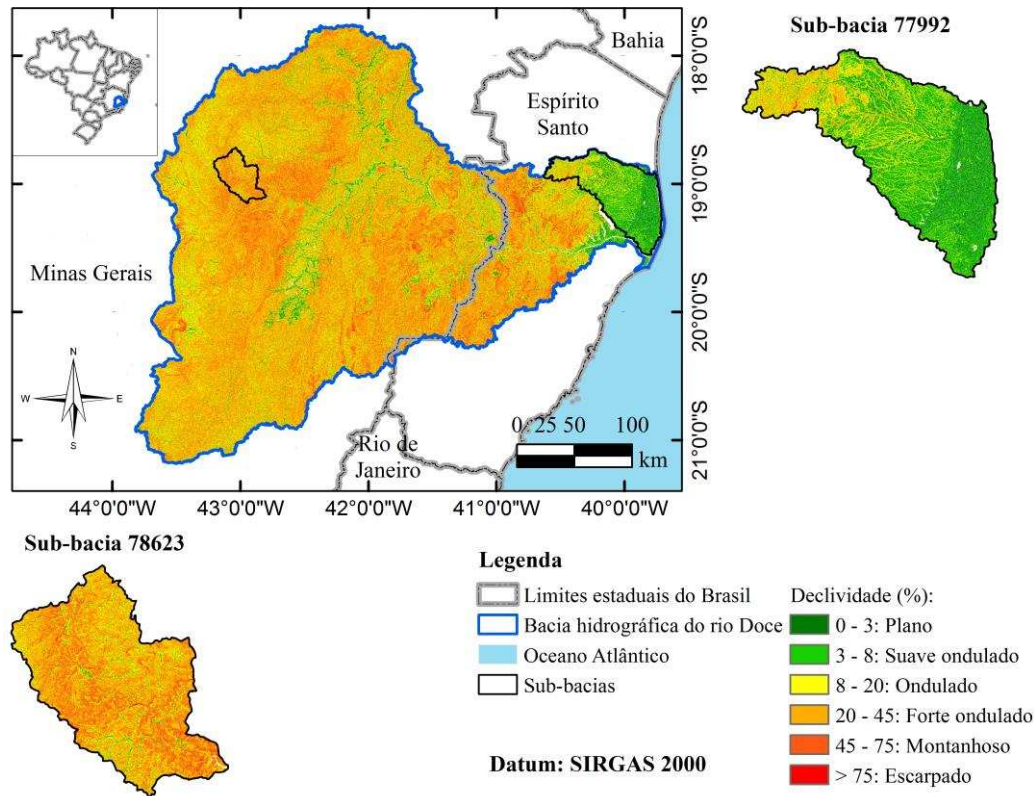
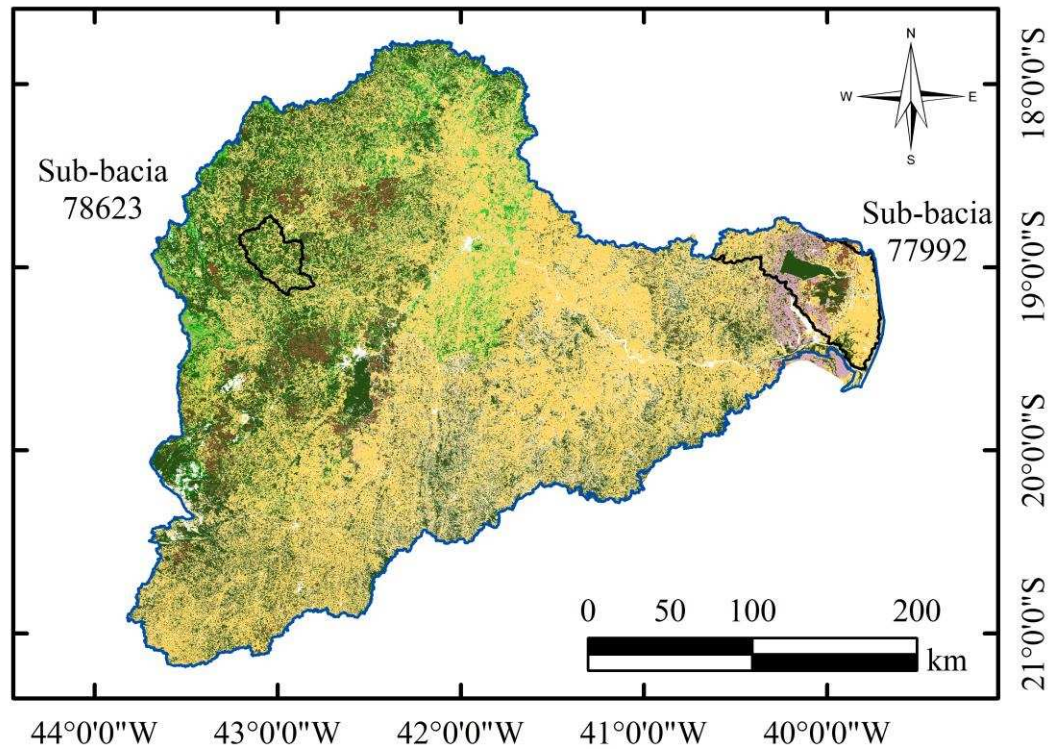


Figura 2.2.1. Localização da bacia hidrográfica do rio Doce, exibindo modelo digital de declividade, com destaque para as sub-bacias adotadas no estudo.

Fonte dos dados: limites estaduais do Brasil (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2020), bacias hidrográficas (AGÊNCIA NACIONAL DE ÁGUAS, 2017) e declividade (FARR *et al.*, 2007; GOOGLE EARTH ENGINE, 2020a).

Fonte: Autor.

A bacia do rio Doce tem 98% de sua área inserida no bioma Mata Atlântica e outros 2% no bioma Cerrado (ECOPLAN-LUME, 2010), mas apresenta uma diversidade de classes de uso e cobertura do solo como mostra a Figura 2.2.2, com dados da coleção 5.0 da iniciativa MapBiomas (2020; SOUZA *et al.*, 2020) de mapeamento da cobertura dos biomas do Brasil. A Figura 2.2.2 destaca apenas classes vegetais de uso e cobertura como formação florestal, florestas plantadas, agricultura e pastagem e outras, que são objeto do estudo. Conforme Pires *et al.* (2017), apresenta um clima quente, com temperaturas médias anuais variando de 18 a 25 °C.



Legenda














	Bacia hidrográfica do rio Doce		13 - Outra Formação Natural não Florestal
Classes de uso e ocupação da terra:			
Value			15 - Pastagem
	3 - Formação Florestal		18 - Agricultura
	4 - Formação Savânica		19 - Cultura Anual e Perene
	5 - Mangue		20 - Cultura Semi-Perene
	9 - Floresta Plantada		21 - Mosaico de Agricultura e Pastagem
	12 - Formação Campestre		32 - Apicum
Datum: SIRGAS 2000			

Figura 2.2.2. Mapa de uso e cobertura do solo ao longo da bacia do rio Doce, destacando diferentes fitofisionomias existentes no ano de 2018.

Fonte dos dados: MapBiomias (2020).

O estudo foi executado com uma base de dados composta de amostras coletadas no tempo em quatro anos hidrológicos: 2015/2016 a 2018/2019. Este foi definido a partir da análise das séries históricas de dados consistidos de todas as estações pluviométricas e fluviométricas localizadas ao longo da bacia do rio Doce – e com dados disponíveis no portal Hidroweb (<http://www.snirh.gov.br/hidroweb/publico/apresentacao.jsf>) da ANA – tendo sido definido como semestre chuvoso o período de outubro a março e semestre seco de abril a setembro, com o ano hidrológico iniciando em outubro e findando em setembro do ano subsequente.

2.2.2.2. Dados orbitais

O pré e pos-processamento das imagens dos sensores orbitais sobre a área de estudo foi completamente realizado via computação em nuvem na plataforma *Google Earth Engine* (GEE) JavaScript (<https://earthengine.google.com/platform/>) (GORELICK *et al.*, 2017). No GEE foram processadas imagens SAR-C Sentinel-1 e Landsat 8 OLI (*Operational Land Imager*), bem como um modelo digital de elevação (DEM) SRTM (*Shuttle Radar Topography Mission*). O GEE foi projetado para não haver problema de compatibilidade entre diferentes bases, estando todas sob mesmo datum: WGS 1984.

Sentinel-1

As covariáveis de radar, incluindo índices de vegetação apresentados na Tabela 2.2.2, foram computadas usando imagens Sentinel-1. Tais imagens foram produtos *Ground Range Detected* (GRD) (EUROPEAN SPACE AGENCY, 2020) disponíveis na coleção “COPERNICUS/S1_GRD_FLOAT” do GEE e já pré-processados (GOOGLE EARTH ENGINE, 2020b) com as bandas VV e VH calibradas para σ^0 . Filipponi (2019) descreve em detalhes o pré-processamento dos produtos GRD Sentinel-1. Foi necessária a remoção de pixels com comportamento de outliers nas bandas σ^0_{VV} e σ^0_{VH} (em unidade de potência linear). Isso porque a distribuição dessas bandas apresentou comportamento propenso a outliers, originados segundo Frison *et al.* (2018) por problemas de calibração. Assim, baseando-se no histograma das bandas, outliers foram removidos definindo como limiar o percentil 95%, sendo então mascarados, conforme recomendado por Nielsen *et al.* (2017). Essa operação foi seguida da atenuação de ruído *speckle* por filtro de mediana com kernel de 5 x 5 pixels.

Tabela 2.2.2. Índices de vegetação gerados com dados Sentinel-1 e suas respectivas fontes

Índice de vegetação	Equação	Fonte
DPSVIm	$DPSVIm = \frac{\sigma_{VV}^0 + \sigma_{VV}^0 \cdot \sigma_{VH}^0}{\sqrt{2}}$	(SANTOS, 2020)
CR	$CR = \frac{\sigma_{VV}^0}{\sigma_{VH}^0}$	(FRISON <i>et al.</i> , 2018)
Pol	$Pol = \frac{\sigma_{VH}^0 - \sigma_{VV}^0}{\sigma_{VH}^0 + \sigma_{VV}^0}$	(HIRD <i>et al.</i> , 2017)
RVIm	$RVIm = \frac{4 \sigma_{VH}^0}{\sigma_{VH}^0 + \sigma_{VV}^0}$	(NASIRZADEHDIZAJI <i>et al.</i> , 2019)

Na Tabela 2.2.2 σ_{VH}^0 e σ_{VV}^0 são os coeficientes de retroespalhamento das bandas VH e VV, respectivamente. Os índices Pol e RVIm foram calculados com σ^0 em decibel (dB), obtido por transformação através da equação 1.

$$\sigma^0 (dB) = 10 \cdot \log_{10} \sigma^0 \quad (1)$$

Landsat 8

As variáveis dependentes, NDVI e EVI, foram provenientes das bandas 2, 4 e 5 do sensor óptico OLI/Landsat 8. As cenas OLI/Landsat 8 foram processadas no GEE obtidas da coleção "LANDSAT/LC08/C01/T1_SR" (GOOGLE EARTH ENGINE, 2020c). Estes produtos têm resolução espacial de 30m, são ortoretificados e seus valores são de reflectância da superfície, cuja correção atmosférica foi executada pelo algoritmo **LaSCR** (UNITED STATES GEOLOGICAL SURVEY, 2019; VERMOTE *et al.*, 2016). No processamento das imagens pixels inválidos (UNITED STATES GEOLOGICAL SURVEY, 2019) foram filtrados e os índices calculados.

O NDVI, desenvolvido por Rouse *et al.* (1973), não tem um comportamento linear e tende a saturar em áreas de vegetação densa com altas quantidades de biomassa (GITELSON, 2004; HUETE *et al.*, 2002; JIANG *et al.*, 2008). Por essa razão, além do NDVI foi lançado mão do EVI, que foi desenvolvido para otimizar o sinal da vegetação melhorando a sensibilidade em regiões de vegetação densa (JIANG *et al.*, 2008; JUSTICE *et al.*, 1998). O EVI foi calculado de acordo com as equações de Justice *et al.* (1998) e

Huete *et al.* (2002), mas para compatibilizar amplitude de valores de NDVI o parâmetro G foi alterado de 2.5 para 1.5.

SRTM

Um modelo digital de declividade com resolução espacial de 30m oriundo dos dados SRTM (*Shuttle Radar Topography Mission*) (FARR *et al.*, 2007; FARR; KOBICK, 2000) foi incorporada ao processamento das imagens Landsat 8 para restringir a amostragem em áreas com declividade maior que 10°: todas as amostras foram tomadas em áreas com relevo ondulado, suave ondulado e plano, que representa aproximadamente um terço da área da bacia. O propósito foi de evitar amostrar pixels que aparecem com efeitos de *layover* e *radar shadow* (WOODHOUSE, 2006) nas imagens Sentinel-1 sem procedimento de RTF. Assim, a amostragem foi aleatória no espaço e realizada mês a mês, montando uma base de dados para cada uma das três bacias em estudo, totalizando 48 imagens para cada. Todo o processamento está ilustrado na Figura 2.2.3.

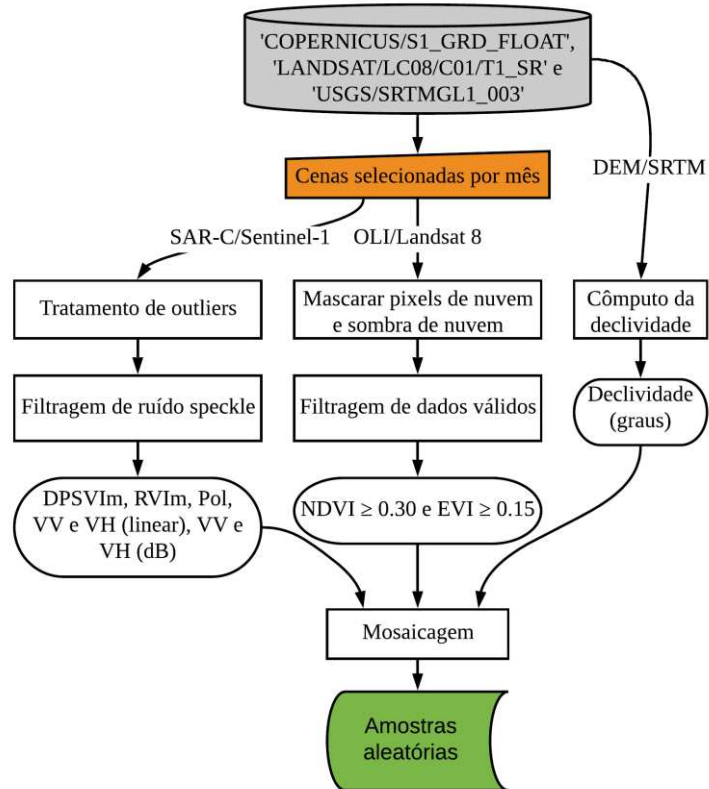


Figura 2.2.3. Esquema de processamento dos dados orbitais no GEE para gerar base de dados do estudo.

Fonte: Autor.

2.2.2.3. Algoritmos de regressão e processo de modelagem

Algoritmos de regressão

Três algoritmos de regressão foram empregados para prever as variáveis dependentes (NDVI e EVI): regressão linear múltipla (MLR), *Multivariate Adaptive Splines Regression* (MARS) e *Random Forest* (RF). Esses métodos foram selecionados para envolver no processo de predição diferentes modelos baseados em: a) regressão linear; b) não-linear; e c) árvore de regressão (KUNN; JOHNSON, 2013). Uma descrição detalhada dos modelos supracitados pode ser consultada em Boehmke e Greenwell (2019) e Kuhn e Johnson (2013).

Ajuste dos modelos

Doze covariáveis foram usadas para alimentar cada modelo, sendo: **DPSVIm**, **Pol**, **RVIm**, **Sigma0_VV** e **Sigma0_VH** (σ^0_{VV} e σ^0_{VH} em unidade de potência), **Sigma0_VV_dB** e **Sigma0_VH_dB** (σ^0_{VV} e σ^0_{VH} em dB), **CR_VVbyVH** (CR), **Lat_GD** e **Long_GD** (latitude e longitude, em grau decimal), além de **slope** (declividade, em graus) e o **Mes** (mês da amostra). Com isso foi empregada a técnica de RFE (*Recursive Feature Elimination*) para selecionar aquelas mais afetas a cada modelo, visando melhorar o desempenho das predições e fornecer preditores mais rápidos, com melhor relação custo-benefício (GUYON; DE, 2003; KUNN; JOHNSON, 2013). A etapa antecedente ao RFE foi a eliminação de covariáveis altamente relacionadas ($r > 0.95$), de modo a evitar colinearidade nos preditores. Tanto a aplicação do RFE quanto o ajuste dos modelos foram possíveis com funções do pacote **caret** (KUNN, 2020) implementado na linguagem **R** (R CORE TEAM, 2019).

Três bases de dados iniciais (uma para cada bacia) contemplando quatro anos hidrológicos foram usadas para separar dados de treinamento e validação na proporção de 70 e 30%, respectivamente, usando o pacote **rsample** (KUNN; CHOW; WICKHAM, 2020). O número pontos amostrados no tempo e espaço para a bacia do rio Doce e sub-bacias 77992 e 78623 está disponível na Tabela 2.2.3, nela o número de amostras na sub-bacia 77992 é superior à bacia por se tratar de uma área menor que demanda menos memória para o GEE processar, mas na sub-bacia 78623 há mais restrições com declividade e cobertura de nuvens. Com dados de treinamento o RFE foi aplicado para os modelos e com as covariáveis selecionadas cada modelo seguiu para treinamento. A estratégia de ajuste e seleção dos modelos escolhida foi validação cruzada k-Fold repetida

(k-Fold CV) e foram definidas 10-Folds com 10 repetições, ou seja, cada modelo foi ajustado 100 vezes (incluindo o RFE).

Tabela 2.2.3. Número de pontos amostrados, no tempo e espaço, por bacia em estudo.

Bacia/sub-bacia	Pontos amostrados
Doce	15 802
77992	40 092
78623	11 258

Escolhido o modelo de melhor ajuste via k-Fold CV cada modelo foi submetido a estratégia de validação *holdout* com 30% de dados selecionados para validação. Uma segunda estratégia de validação *holdout* consistiu em avaliar o desempenho de cada modelo com pixels coletados, também aleatoriamente no GEE, com uma outra semente de randomização, mas mesmo intervalo de tempo. Todo o processo de ajuste dos modelos está esquematizado na Figura 2.2.4.

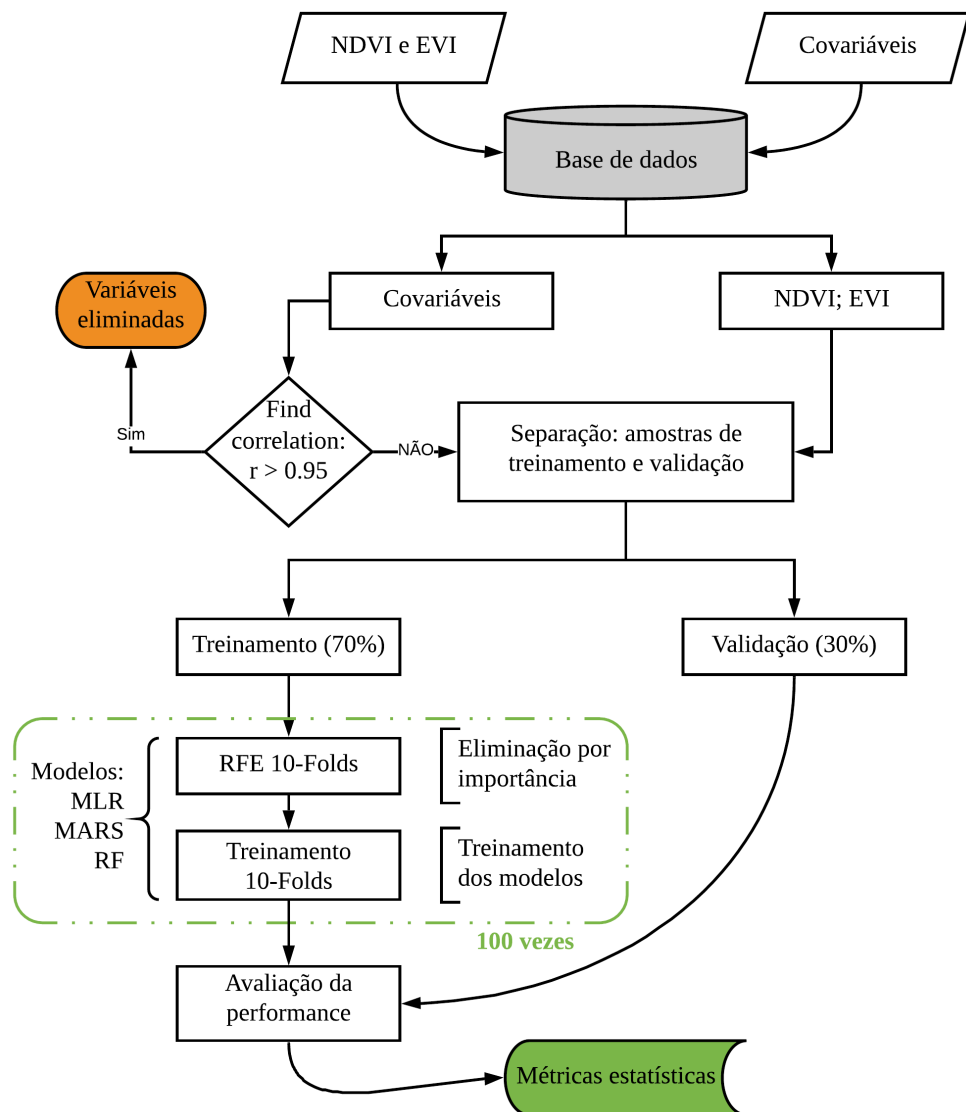


Figura 2.2.4. Esquema de separação das amostras, seleção de variáveis, treinamento dos modelos e avaliação da performance.

Fonte: Autor.

2.2.2.4. Avaliação dos modelos

O desempenho dos modelos no treinamento por validação *k*-Fold *random CV* foi realizado usando as métricas: coeficiente de determinação (r^2), raiz quadrada do erro médio (RMSE) e erro médio absoluto (MAE). Com os modelos ajustados o grau de importância das variáveis para o modelo foi avaliado por ranking usando o pacote **vip** (GREENWELL; BOEHMKE; GRAY, 2020). O desempenho dos modelos escolhidos na validação *holdout* foi realizado incluindo as métricas: coeficiente de correlação (r), índice de concordância de Willmott (d) e erro de viés médio (MBE) (WILLMOTT, 1982; WILLMOTT; ROBESON; MATSUURA, 2012; WILLMOTT; MATSUURA, 2005)

calculadas usando o pacote **hydroGOF** (ZAMBRANO-BIGIARINI, 2017). O ecossistema de pacotes **tidyverse** foi fundamental para organização e visualização de dados (WICKHAM *et al.*, 2019).

2.2.3. Resultados e discussão

2.2.3.1. Seleção e importância das covariáveis

Para cada algoritmo treinado com cada conjunto de dados (bacia do rio doce, sub-bacia 77992 e sub-bacia 78623) o algoritmo de RFE selecionou as variáveis mais importantes, as quais estão apresentadas na Tabela 2.2.4.

Observa-se na Tabela 2.2.4 que as variáveis preditoras do EVI foram ligeiramente diferentes daquelas selecionadas para prever o NDVI. Aqui é importante destacar que o RVIm apresentou correlação igual a 1 com o índice Pol, mostrando-se não normalizado em comparação ao Pol e sendo, portanto, eliminado.

Tabela 2.2.4. Covariáveis selecionadas pelo RFE para alimentar os modelos na predição do NDVI e EVI.

Modelo	Covariáveis selecionadas
MLR	$NDVI = f(\sigma^0_{VV}, \sigma^0_{VH}, Pol, DPSVIm, \sigma^0_{VH} (dB))$
	$EVI = f(\sigma^0_{VH}, \sigma^0_{VV}, Pol, DPSVIm, \sigma^0_{VH} (dB))$
MARS	$NDVI = f(\sigma^0_{VH}, Mes, DPSVIm, Long, \sigma^0_{VV})$
	$EVI = f(\sigma^0_{VV}, Mes, DPSVIm, Long, Lat)$
RF	$NDVI = f(Mes, Long, Lat, DPSVIm)$
	$EVI = f(Mes, Long, Lat, DPSVIm)$

Com as variáveis selecionadas os modelos foram treinados, e para avaliar o grau de importância das covariáveis apresenta-se na Figura 2.2.5 os rankings de importância das covariáveis em cada modelo, considerando o NDVI como variável dependente em três situações: a) bacia do rio Doce, b) sub-bacia 77992 e c) sub-bacia 78623. De maneira geral, o DPSVIm foi a covariável derivada do Sentinel-1 mais importante para os modelos, com exceção do MARS na bacia do rio Doce e do MLR e MARS na sub-bacia 78623. Isso dá ênfase para a importância do DPSVI modificado para estimar o NDVI. O

comportamento da importância das covariáveis na predição do EVI foi semelhante ao NDVI.

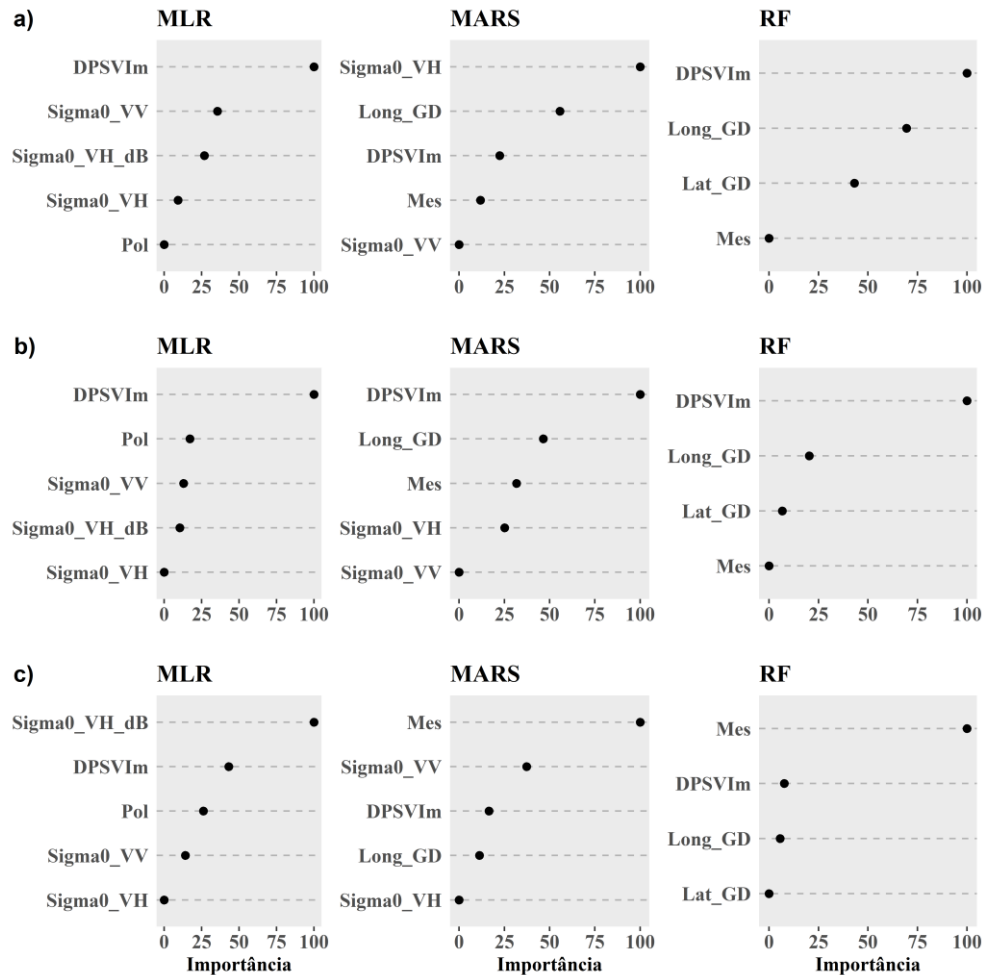


Figura 2.2.5. Ranking de importância das covariáveis de cada modelo na predição do NDVI na: a) bacia do rio Doce; b) sub-bacia 77992 e c) sub-bacia 78623.

Fonte: Autor.

Para modelos de regressão linear a importância das covariáveis no treinamento é frequentemente mensurada pelo valor absoluto da estatística t (BOEHMKE; GREENWELL, 2019). Já para modelos mais complexos, como o MARS e outros modelos baseados em árvore (como RF), monitora-se o desempenho que ocorre no modelo ao adicionar cada preditor (KUHN; JOHNSON, 2013), método conhecido como permutação (GRÖMPING, 2009; STROBL *et al.*, 2008). Com o método de permutação obteve-se a importância das variáveis para os modelos, onde o DPSVIm, aprimorado com base no índice DPSVI (PERIASAMY, 2018) para representar a vegetação na área de estudo, foi o índice de vegetação de maior importância para os modelos em detrimento

dos demais índices SAR-C Sentinel-1 (Tabela 2.2.2). Na sub-bacia 77992 foi a variável de maior importância em todos os modelos ajustados (Figura 2.2.5a). Não foi, entretanto, a variável mais importante em todos os modelos treinados, ficando atrás do Mês e da posição (a longitude principalmente) dos pontos amostrados.

2.2.3.2. Ajuste dos hiperparâmetros via validação cruzada *k-Fold*

A Figura 2.2.6 exibe os resultados da validação cruzada *k-Fold* aplicada no conjunto de treinamento de cada bacia para ajustar os modelos. A validação cruzada no treinamento é amplamente empregada para avaliar a variabilidade dos ajustes, e é importante para demonstrar o grau de robustez da modelagem. Ao se analisar os resultados de RMSE, MAE e r^2 constata-se que os melhores desempenhos são do RF para todas as bacias, como esperado, e as piores performances (com maiores erros) observadas nos modelos lineares (MLR), estando os modelos MARS com desempenho intermediário. Além disso, nota-se que o desempenho dos modelos foi melhor e mais acurado nas estimativas do NDVI, em detrimento do EVI.




Figura 2.2.6. Resultados da validação cruzada *k-Fold* repetida, para os diferentes conjuntos de treinamento.

Fonte: Autor.

O ajuste dos modelos MLR, MARS e RF com as covariáveis selecionadas gerou estatísticas de validação cruzada *k-Fold* muito semelhantes em cada uma das três áreas estudadas, fato importante para demonstrar o grau de robustez da modelagem, pois a validação cruzada é um dos métodos mais empregados para ajuste de modelos (ARLOT; CELISSE, 2010). Os resultados semelhantes, obtidos com a validação cruzada, demonstram baixa variabilidade na predição das variáveis dependentes nos conjuntos de treinamento. Com baixa variância na validação cruzada, o risco de sobreajuste na predição de dados não conhecidos foi atenuado, fato também observado na validação *holdout* (Figura 2.2.7), visto que as estimativas de RMSE e MAE foram semelhantes em

ambas as validações, indicando capacidade de generalização dos modelos (ARLOT; CELISSE, 2010; FILGUEIRAS *et al.*, 2019a).

2.2.3.3. Estratégia de validação *holdout*

A validação cruzada *k-Fold* repetida foi empregada para seleção do modelo de melhor ajuste baseado nos diferentes algoritmos. De posse do modelo de melhor ajuste para RF, MARS e MLR e, em função do conjunto de dados ser suficientemente grande, a validação de espera foi empregada. Os resultados da validação *holdout* são exibidos nas Figura 2.2.7 e 2.2.7, para estimativa de NDVI e EVI, respectivamente. Nota-se que as estimativas de RMSE e MAE são semelhantes às aquelas obtidas com a validação cruzada *k-Fold*, para todos os conjuntos de treinamento (bacia do rio Doce e sub-bacias 77992 e 78623).

Em ambas as figuras (Figura 2.2.7 e Figura 2.2.8) a equação de ajuste entre os dados preditos e observados de NDVI ou EVI é semelhante à reta 1:1 em todos os modelos ajustados, deixando claro que os algoritmos empregados foram eficientes em reduzir o viés de sub ou superestimação da variável dependente. Embora na maioria dos casos o valor de MBE mostre-se negativo (indicando subestimação da variável observada), esses resultados são muito próximos de zero.

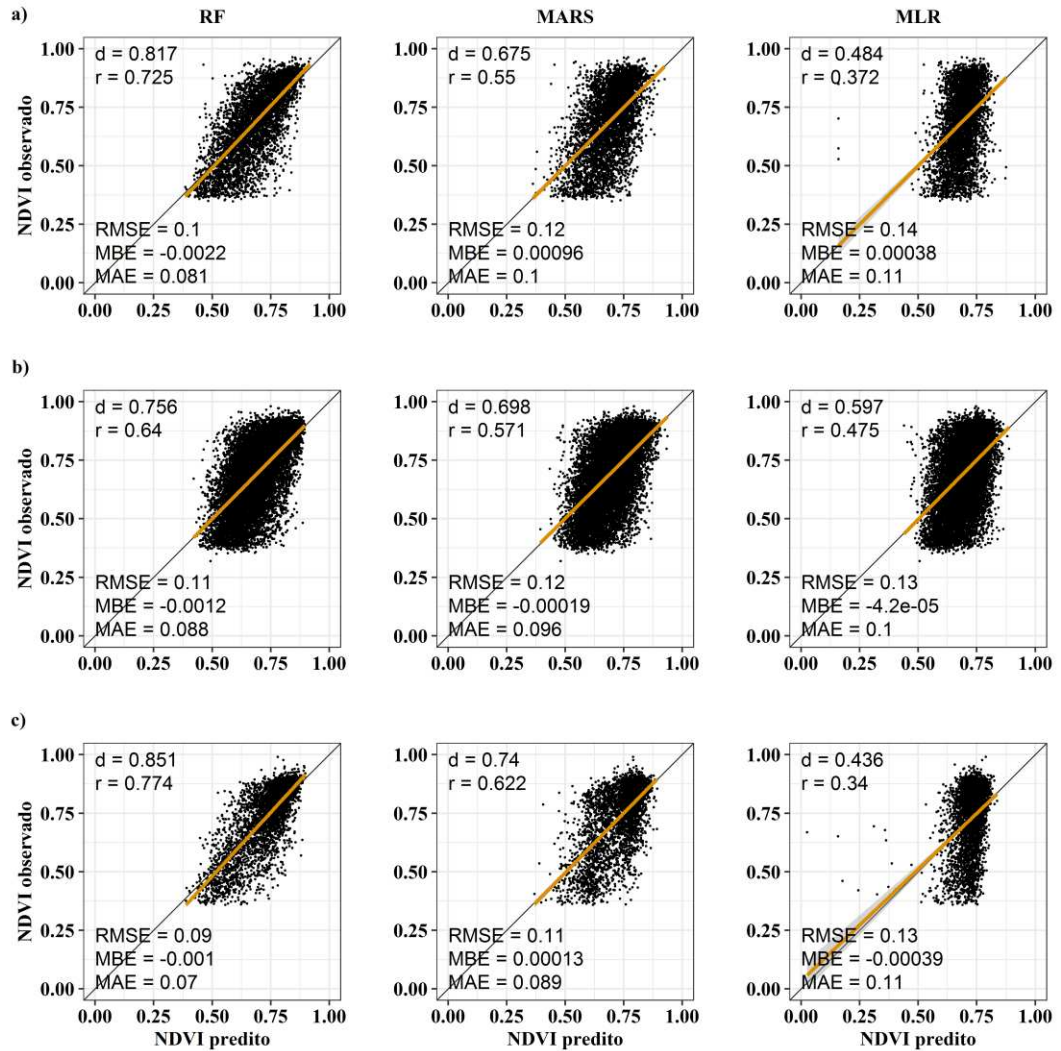


Figura 2.2.7. Métricas estatísticas da validação *holdout* e comportamento dos modelos na predição do NDVI para: a) bacia do rio Doce; b) sub-bacia 77992 e c) sub-bacia 78623. Fonte: Autor.

As estimativas do EVI não foram tão eficientes quanto do NDVI, como pode ser observado na Figura 2.2.8. Isso está também evidenciado no grau de correlação entre os valores preditos e observados do NDVI e EVI, pois o coeficiente de correlação de Pearson indica menor agrupamento das estimativas e observações de EVI em todas as bacias.




Figura 2.2.8. Métricas estatísticas da validação *holdout* e comportamento dos modelos na predição do EVI para: a) bacia do rio Doce; b) sub-bacia 77992 e c) sub-bacia 78623.

Fonte: Autor.

A avaliação dos modelos ajustados usando as métricas d e r na validação *holdout* partiram do pressuposto explorado por Willmott (1981) de que o coeficiente de determinação acrescenta pouca informação. O principal problema é que as magnitudes de r e r^2 não estão consistentemente relacionadas à precisão da previsão de um modelo (WILLMOTT, 1982; WILLMOTT; ROBESON; MATSUURA, 2012). Nesse sentido, principalmente os modelos baseados em RF geraram os melhores índices de concordância (tanto para NDVI quanto para EVI) em detrimento dos demais modelos.

O desempenho do algoritmo RF foi melhor em todas as situações comparado com MARS e MLR, principalmente na bacia do rio Doce e sub-bacia 78623 (área mais declivosa). O RF é um método de aprendizado de máquina cujo desempenho das

predições é originado na redução da correlação entre os preditores por inserção de aleatoriedade no processo de construção de uma árvore (BREIMAN, 2001; JAMES *et al.*, 2013; KUHN; JOHNSON, 2013). Na sub-bacia 77992, cujas variações no relevo são menores (Figura 2.2.1), houve o menor desempenho do RF em decorrência do fato de que nesta as variáveis derivadas do sensor SAR-C estão mais correlacionadas (Capítulo 1). Já nas demais, a disposição do terreno é capaz de gerar uma aleatoriedade nas covariáveis de radar (por efeitos de *shadow* e *layover*) (HOEKMAN; REICHE, 2015; LUCKMAN *et al.*, 1998; SOJA; SANDBERG; ULANDER, 2010; WOODHOUSE, 2006), o que explica o melhor desempenho do RF.

O Artigo 1 explorou as influências espaciais das áreas de estudo, onde as áreas mais planas apresentaram melhores ajustes entre o índice DPSVIm e os índices NDVI e EVI. Analogamente, na Figura 2.2.7 e Figura 2.2.8 é possível também observar, no modelo baseado em regressão linear, que o melhor desempenho pode ser atribuído à sub-bacia 77992, com superfície mais plana conforme mostrado na Figura 2.2.1.

Em uma abordagem semelhante à deste estudo, Filgueiras *et al.* (2019a) lançaram mão de variáveis derivadas do sensor SAR-C Sentinel-1 para predizer o NDVI de culturas agrícolas irrigadas. Os autores tiveram como variável importante o índice NRPB (*Normalized Ratio Procedure between Bands*) derivado da metodologia Filgueiras *et al.* (2019b) – representado aqui pelo índice Pol – e tiveram também melhores desempenhos com RF. Na predição de NDVI > 0.25 (apenas pixels vegetados) o desempenho do RF apresentou r^2 da ordem de 0.95 (validação *holdout*), muito superior aos encontrados neste trabalho (Figura 2.2.7). Entretanto, a área de abrangência do estudo foi restrita aos perímetros irrigados, áreas muito menores. No presente estudo comprovou-se, também, que o desempenho da modelagem do NDVI melhorou em áreas menores, reforçando a aplicabilidade dos dados SAR-C em regiões mais homogêneas.

Além das influências espaciais, cuja proximidade reflete no relacionamento do alvo do estudo (ISAACS; SRIVASTAVA, 1989; TOBLER, 1970), demonstradas no Artigo 1, há também influências sazonais a serem consideradas. Sivasankar *et al.* (2018) e Filgueiras (2019a) propuseram fusão de dados SAR com dados ópticos para monitorar culturas agrícolas, considerando períodos específicos de desenvolvimento das lavouras. Na situação em que este estudo foi desenvolvido há influências sazonais a serem consideradas na modelagem, pois o conteúdo de água na superfície influencia no sinal retroespalhado para os radares (PERIASAMY, 2018; SZIGARSKI *et al.*, 2018). O regime

de chuvas (semestre chuvoso e semestre seco) influenciam no ajuste de produtos de sensores SAR-C, como demonstrado no Artigo 1.

Os modelos gerados refletem também as incertezas trazidas pelos sensores em análise, pois, cada sensor tem uma razão sinal/ruído diferente (JORGE *et al.*, 2017; XU *et al.*, 2019). Desse modo trabalhos futuros podem aproveitar dados de missões SAR diferentes, como as missões de monitoramento ambiental com alta resolução espacial: SAOCOM (*Satélite Argentino de Observación Con Microondas*) que conta com sensor SAR-L já operacional no satélite 1, e que alcançará também alta resolução temporal (8 dias de revisita) com o lançamento do satélite 1B (GIUDICI; GUARNIERI; GONZALEZ, 2017); e a missão NISAR (NASA-ISRO SAR) dotada de sensores de banda-L e -S, que tem previsão de lançamento para o ano de 2020 (NATIONAL AERONAUTICS AND SPACE ADMINISTRATION, 2018; ROSEN *et al.*, 2017). Além destes, a abordagem poderá ser testada também com outros sensores ópticos, como os da missão Sentinel-2.

2.2.4. Conclusões

A predição dos índices espectrais de vegetação NDVI e EVI a partir de covariáveis derivadas do sensor SAR-C Sentinel-1 produziu bons ajustes, principalmente para o NDVI.

O melhor desempenho na predição do NDVI e EVI foi observado no algoritmo *Random Forest*.

O DPSVIm foi uma variável chave em todos os modelos, caracterizando-se como uma variável importante na predição dos índices ópticos de vegetação.

Os resultados obtidos mostram que a integração de variáveis de radar a índices de vegetação ópticos possibilitam um monitoramento livre de lacunas (nuvens e sombra de nuvens) em diferentes escalas, mesmo considerando condições adversas às medições SAR como as influências topográficas.

2.2.5. Referências

AGÊNCIA NACIONAL DE ÁGUAS. **Dados Abertos da Agência Nacional de Águas**. Disponível em: <<http://dadosabertos.ana.gov.br/>>. Acesso em: 21 jun. 2020.

APARICIO, N. *et al.* Spectral Vegetation Indices as Nondestructive Tools for

Determining Durum Wheat Yield. **Agronomy Journal**, v. 92, n. 1, p. 83–91, 1 jan. 2000.

ARLOT, S.; CELISSE, A. A survey of cross-validation procedures for model selection. **Statistics Surveys**, v. 4, p. 40–79, 2010.

ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 15 dez. 2001.

BOEHMKE, B.; GREENWELL, B. **Hands-On Machine Learning with R**. [s.l.] Chapman and Hall/CRC, 2019.

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

CARRASCO, L. *et al.* Evaluating Combinations of Temporally Aggregated Sentinel-1, Sentinel-2 and Landsat 8 for Land Cover Mapping with Google Earth Engine. **Remote Sensing**, v. 11, n. 3, p. 288, 1 fev. 2019.

CHANG, J. G.; SHOSHANY, M.; OH, Y. Polarimetric Radar Vegetation Index for Biomass Estimation in Desert Fringe Ecosystems. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 12, p. 7102–7108, 1 dez. 2018.

EUROPEAN SPACE AGENCY, E. **Terms of the Copernicus Data Hub portals and Data supply conditions**. Disponível em: <<https://scihub.copernicus.eu/twiki/do/view/SciHubWebPortal/TermsConditions>>. Acesso em: 23 abr. 2020.

FARR, T. G. *et al.* The Shuttle Radar Topography Mission. **Reviews of Geophysics**, v. 45, n. 2, p. RG2004, 19 maio 2007.

FARR, T. G.; KOBRICK, M. Shuttle radar topography mission produces a wealth of data. **Eos, Transactions American Geophysical Union**, v. 81, n. 48, p. 583, 2000.

FILGUEIRAS, R. *et al.* Crop NDVI Monitoring Based on Sentinel 1. **Remote Sensing**, v. 11, n. 12, p. 1441, 2019a.

FILGUEIRAS, R. *et al.* New approach to determining the surface temperature without thermal band of satellites. **European Journal of Agronomy**, v. 106, p. 12–22, maio 2019b.

FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, v. 18, n. 1, p. 11, 4 jun. 2019.

FRISON, P.-L. *et al.* Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology. **Remote Sensing**, v. 10, n. 12, p. 2049, 17 dez. 2018.

GAO, J. *et al.* Estimation of Alpine Grassland Forage Nitrogen Coupled with Hyperspectral Characteristics during Different Growth Periods on the Tibetan Plateau. **Remote Sensing**, v. 11, n. 18, p. 2085, 6 set. 2019.

GITELSON, A. A. Wide Dynamic Range Vegetation Index for Remote Quantification of

Biophysical Characteristics of Vegetation. **Journal of Plant Physiology**, v. 161, n. 2, p. 165–173, 1 jan. 2004.

GIUDICI, D.; GUARNIERI, A. M.; GONZALEZ, J. C. Pre-Flight SAOCOM-1A SAR Performance Assessment by Outdoor Campaign. **Remote Sensing**, v. 9, n. 7, p. 729, 14 jul. 2017.

GOOGLE EARTH ENGINE. **SRTM Digital Elevation Data 30m**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/USGS_SRTMGL1_003>. Acesso em: 21 jun. 2020a.

GOOGLE EARTH ENGINE. **Sentinel-1 Algorithms | Google Earth Engine | Google Developers**. Disponível em: <<https://developers.google.com/earth-engine/sentinel1>>. Acesso em: 23 abr. 2020b.

GOOGLE EARTH ENGINE. **USGS Landsat 8 Surface Reflectance Tier 1 | Earth Engine Data Catalog**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C01_T1_SR#description>. Acesso em: 24 abr. 2020c.

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

GREENWELL, B.; BOEHMKE, B.; GRAY, B. **vip: Variable Importance Plots**, 2020. Disponível em: <<https://cran.r-project.org/package=vip>>

GRÖMPING, U. Variable Importance Assessment in Regression: Linear Regression versus Random Forest. **The American Statistician**, v. 63, n. 4, p. 308–319, nov. 2009.

GUYON, I.; DE, A. M. **An Introduction to Variable and Feature Selection** André Elisseeff **Journal of Machine Learning Research**. [s.l.: s.n.].

HIRD, J. *et al.* Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. **Remote Sensing**, v. 9, n. 12, p. 1315, 14 dez. 2017.

HOEKMAN, D. H.; REICHE, J. Multi-model radiometric slope correction of SAR images of complex terrain using a two-stage semi-empirical approach. **Remote Sensing of Environment**, v. 156, p. 1–10, 1 jan. 2015.

HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 1 nov. 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1 ago. 1988.

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

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Geociências**. Disponível em: <<https://www.ibge.gov.br/geociencias/todos-os-produtos-geociencias.html>>. Acesso em: 21 jun. 2020.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied Geostatistics**. New York: Oxford University Press, 1989.

JAMES, G. *et al.* **An Introduction to Statistical Learning**. New York, NY: Springer New York, 2013. v. 103

JIANG, Z. *et al.* Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 15 out. 2008.

JORGE, D. S. F. *et al.* SNR (Signal-To-Noise Ratio) Impact on Water Constituent Retrieval from Simulated Images of Optically Complex Amazon Lakes. **Remote Sensing**, v. 9, n. 7, p. 644, 22 jun. 2017.

JUSTICE, C. O. *et al.* The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KIM, Y.; VAN ZYL, J. **On the relationship between polarimetric parameters**. IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment. Proceedings (Cat. No.00CH37120). **Anais...IEEE**, 2000. Disponível em: <<http://ieeexplore.ieee.org/document/858099/>>. Acesso em: 6 maio. 2020

KUHN, M. **caret: Classification and Regression Training**, 2020. Disponível em: <<https://cran.r-project.org/package=caret>>

KUHN, M.; CHOW, F.; WICKHAM, H. **rsample: General Resampling Infrastructure**, 2020. Disponível em: <<https://cran.r-project.org/package=rsample>>

KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. New York, NY: Springer New York, 2013.

LIU, X. *et al.* Lake evaporation in a hyper-arid environment, northwest of China—measurement and estimation. **Water (Switzerland)**, v. 8, n. 11, p. 1–21, 2016.

LUCKMAN, A. *et al.* Tropical forest biomass density estimation using JERS-1 SAR: Seasonal variation, confidence limits, and application to image mosaics. **Remote Sensing of Environment**, v. 63, n. 2, p. 126–139, 1 fev. 1998.

MAPBIOMAS. **Coleção 5.0 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil**. Disponível em: <<https://mapbiomas.org/>>. Acesso em: 22 out. 2020.

MEYER, H. *et al.* Improving performance of spatio-temporal machine learning models using forward feature selection and target-oriented validation. **Environmental Modelling and Software**, v. 101, p. 1–9, 1 mar. 2018.

NASA JPL. **NASADEM Merged DEM Global 1 arc second V001 [Data set]. NASA EOSDIS Land Processes DAAC.** Disponível em: <https://doi.org/10.5067/MEaSURES/NASADEM/NASADEM_HGT.001>. Acesso em: 10 set. 2020.

NASIRZADEHDIZAJI, R. *et al.* Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. **Applied Sciences**, v. 9, n. 4, p. 655, 15 fev. 2019.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **NASA-ISRO SAR (NISAR) Mission Science Users' Handbook.** [s.l.: s.n.]. Disponível em: <https://nisar.jpl.nasa.gov/files/nisar/NISAR_Science_Users_Handbook.pdf>. Acesso em: 7 jul. 2020.

NIELSEN, A. A. *et al.* **Change detection in a series of Sentinel-1 SAR data.** 2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2017. **Anais...**Institute of Electrical and Electronics Engineers Inc., 12 set. 2017

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. **Remote Sensing of Environment**, v. 217, n. September, p. 537–549, 2018.

POULIOT, D.; LATIFOVIC, R. Reconstruction of Landsat time series in the presence of irregular and sparse observations: Development and assessment in north-eastern Alberta, Canada. **Remote Sensing of Environment**, v. 204, p. 979–996, 1 jan. 2018.

R CORE TEAM, R. **R: A Language and Environment for Statistical Computing**ViennaR Foundation for Statistical Computing, , 2019. Disponível em: <<https://www.r-project.org/>>

REIGBER, A. *et al.* The High-Resolution Digital-Beamforming Airborne SAR System DBFSAR. **Remote Sensing**, v. 12, n. 11, p. 1710, 27 maio 2020.

ROSEN, P. *et al.* **The NASA-ISRO SAR (NISAR) mission dual-band radar instrument preliminary design.** International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...**Institute of Electrical and Electronics Engineers Inc., 1 dez. 2017

ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

ROY, D. P.; YAN, L. Robust Landsat-based crop time series modelling. **Remote Sensing of Environment**, v. 238, p. 110810, 1 mar. 2020.

SANTOS, H. G. DOS *et al.* **Sistema Brasileiro de Classificação de Solos.** 5. ed. Brasília: Embrapa, 2018.

SIVASANKAR, T. *et al.* Advances in radar remote sensing of agricultural crops: A

review. **International Journal on Advanced Science, Engineering and Information Technology**, v. 8, n. 4, p. 1126–1137, 2018.

SOJA, M. J.; SANDBERG, G.; ULANDER, L. M. H. **Topographic correction for biomass retrieval from P-band SAR Data in Boreal Forests**. International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...**2010

SOUZA, C. M. *et al.* Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. **Remote Sensing**, v. 12, n. 17, p. 2735, 1 set. 2020.

STROBL, C. *et al.* Conditional variable importance for random forests. **BMC Bioinformatics**, v. 9, n. 1, p. 307, 11 dez. 2008.

SZIGARSKI, C. *et al.* Analysis of the Radar Vegetation Index and Potential Improvements. **Remote Sensing**, v. 10, n. 11, p. 1776, 2018.

TOBLER, W. R. A Computer Movie Simulating Urban Growth in the Detroit Region. **Economic Geography**, v. 46, p. 234, jun. 1970.

UNITED STATES GEOLOGICAL SURVEY, U. **Landsat 8 Surface Reflectance Code (LaSRC) product guide**. [s.l.: s.n.].

VERMOTE, E. *et al.* Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, 1 nov. 2016.

WANG, J.; RICH, P. M.; PRICE, K. P. Temporal responses of NDVI to precipitation and temperature in the central Great Plains, USA. **International Journal of Remote Sensing**, v. 24, n. 11, p. 2345–2364, 10 jun. 2003.

WANG, Q. *et al.* Fusion of Landsat 8 OLI and Sentinel-2 MSI Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 7, p. 3885–3899, 1 jul. 2017.

WANG, T. *et al.* Temporal and spatial patterns of NDVI and their relationship to precipitation in the Loess Plateau of China. **International Journal of Remote Sensing**, v. 31, n. 7, p. 1943–1958, 23 abr. 2010.

WICKHAM, H. *et al.* Welcome to the Tidyverse. **Journal of Open Source Software**, v. 4, n. 43, p. 1686, 21 nov. 2019.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v. 2, n. 2, p. 184–194, 1981.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin - American Meteorological Society**, v. 63, n. 11, p. 1309–1313, 1982.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, v. 32, n. 13, p. 2088–2094, 15 nov. 2012.

WILLMOTT, C.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate Research**, v. 30, p. 79–82, 2005.

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**. Boca Raton: CRC Press, 2006.

XIAO, X. *et al.* Modeling gross primary production of temperate deciduous broadleaf forest using satellite images and climate data. **Remote Sensing of Environment**, v. 91, n. 2, p. 256–270, 30 maio 2004.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, v. 1, n. 1, p. 9–23, 1 mar. 2008.

XU, M. *et al.* Thin cloud removal from optical remote sensing images using the noise-adjusted principal components transform. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 149, p. 215–225, 1 mar. 2019.

ZAMBRANO-BIGIARINI, M. **hydroGOF: Goodness-of-Fit Functions for Comparison of Simulated and Observed Hydrological Time Series**, 2017. Disponível em: <<https://cran.r-project.org/package=hydroGOF>>

3. CONCLUSÕES GERAIS

Com a realização do estudo, pôde-se concluir que:

As modificações propostas no DPSVI (*Dual Polarimetric SAR Vegetation Index*) mostraram-se promissoras para quantificação da cobertura vegetal densa, principalmente considerando os resultados obtidos no semestre seco.

No semestre chuvoso o desempenho do DPSVIm foi comprometido em razão da influência que a umidade da superfície exerce nas medições SAR. Sugere-se que em trabalhos futuros as propriedades dielétricas da superfície sejam estudadas na busca de atenuar esses efeitos.

O DPSVI modificado teve melhor desempenho em áreas menos declivosas, sendo que para áreas mais declivosas a técnica de RTF atenuou os efeitos topográficos.

A predição dos índices NDVI e EVI por algoritmos de aprendizado de máquina produziu bons ajustes, principalmente no *Random Forest*, se mostrando uma alternativa para monitoramento contínuo da vegetação por integração de imagens ópticas e de radar.

Para trabalhos futuros sugere-se novos testes do desempenho do DPSVIm com imagens de outros sensores SAR, de bandas-L e -C, confrontando com medidas alométricas da vegetação para investigar a relação entre o índice e uma verdade de campo.

4. APÊNDICE A – Código-fonte para cômputo do DPSVIm para monitoramento de vegetação

O material a seguir é um código-fonte (linguagem JavaScript) implementado na plataforma Google Earth Engine JavaScript API (<https://earthengine.google.com/>). Este código está afeto ao primeiro artigo, cujo objetivo é propor um índice de vegetação SAR usando dados do sensor SAR-C dos satélites Sentinel-1 A e B. O código está subdividido em quatro partes: 1) STUDY AREA POLYGONS, onde os arquivos vetoriais das áreas de estudo são importados para o processamento das imagens; 2) LANDSAT 8 DATA PROCESSING, onde ocorre todo o processamento (mascarar nuvem e sombra de nuvem, eliminação de pixels anômalos, etc) das imagens Landsat 8 (reflectância da superfície) para gerar os índices de vegetação EVI e NDVI, além disso, nesta parte há a agregação de uma imagem de declividade proveniente do DEM/SRTM; 3) SENTINEL-1 DATA PROCESSING, processamento dos dados de radar Sentinel-1 (filtragem de outliers, filtragem de *speckle*, etc) onde os índices DPSVI e DPSVIm são calculados; por fim a parte 4) onde todas as imagens (Sentinel-1, Landsat 8 e SRTM) são combinadas (pela data) para serem amostrados pixels dos índices de vegetação.

Link para acesso ao código no Google Earth Engine:

<https://code.earthengine.google.com/b1846be7c65d2d04832f60920c854c16?noload=true>

```
//Code: Sentinel-1 and Landsat 8 Vegetation Indices
//Inputs/Arguments: Polygons of study areas; date (month) of analysis
//Author: Erli Pinto dos Santos
//  Agronomy Engineer
//  PhD student in Agricultural Engineering
//  Universidade Federal de Viçosa (Viçosa, Minas Gerais, Brazil)
//  E-mail: erlispinto@outlook.com or erli.santos@ufv.br
//Last update: September 13, 2020

/* ANALYSIS MONTH: */
// The input vars 'start' and 'finish' controls the imagery acquisition.
// The date must initiate in the first day of month (start) in analysis
// and finish at the second day of the subsequent month (finish),
// totalizing 30 days. The exception is to February month, that the subsequent
// date must finish in March 4th, to complete 30 days.
var start = ee.Date('2015-10-01');
var finish = ee.Date('2015-11-02');

/** STUDY AREA POLYGONS: */
```

```

// The geometry roi is especially needs to when apply the algorithm over entire Doce
river Watershed,
// to avoid select excess imagery
var roi = ee.FeatureCollection('users/erlisantos/Poligono_buffer_BH_RioDoce'
    //'users/erlisantos/Poligono_BH_77992'
    //'users/erlisantos/Poligono_BH_78623'
    //'users/erlisantos/Poligono_BH_779926'
    //'users/erlisantos/Poligono_BH_786232'
    ).geometry();
// Note that from roi to aoi only the first geometry changes (to
'users/erlisantos/Poligono_BH_UPH_RioDoce'):
var aoi = ee.FeatureCollection('users/erlisantos/Poligono_BH_UPH_RioDoce'
    //'users/erlisantos/Poligono_BH_77992'
    //'users/erlisantos/Poligono_BH_78623'
    //'users/erlisantos/Poligono_BH_779926'
    //'users/erlisantos/Poligono_BH_786232'
    ).geometry();

/** LANDSAT 8 DATA PROCESSING: */
// The goal of this algorithm is take Landsat 8 Surface Reflectance scenes over the
AOI's and compute
// both NDVI and EVI spectral indices for all area and free of cloud cover and cloud
shadown. Thus,
// the output of this code is a table with pixel samples (NDVI) collected trough the
selected AOI.
// Note that all pixels with NDVI < 0.3 are masked, because this algorithm is designed
to vegetation analysis.
// Enjoy it!

/** SRTM IMAGE IN THE SCRIPT */
// Is known that the topographical features of an area infer in the backscattering
behavior of radar data
// collected by SAR (Synthetic Aperture Radar) sensors. To study the topographical
influences about
// Sentinel-1 SAR data, we include SRTM information in this script, with the goal
avoid samples radar
// pixels under effect of shadow or layover mechanims.

/** LOAD THE SRTM IMAGE: */
var srtm = ee.Image('USGS/SRTMGL1_003')
    .clip(aoi);

/** APPLY AN ALGORITHM TO COMPUTE TERRAIN SLOPE: */
var slope = ee.Terrain.slope(srtm);

/** MASK SLOPE IMAGE OMMITING SLOPE PIXELS > 10°: */
var Slope10 = slope.select('slope').lte(10);
var slopeNew = slope.updateMask(Slope10);

/** FUNCTION TO ADD SLOPE BAND TO EACH LANDSAT 8 SCENE: */

```

```

function Combine(image){
  return image.addBands(slopeNew.select('slope'));
}

/** FUNCTION TO MASK INVALID BANDS VALUES */
// This function will mask values out of valid range to the band B2, B4 and B5
necessary to this approach
// according to Valid Range, noticed in Landsat 8 Surface Reflectance Code (LaSRC),
// section Surface Reflectance Specifications. Available for consultation here:
// https://www.usgs.gov/media/files/land-surface-reflectance-code-lasrc-product-
guide
function maskInvalid(image){
  var validPixels = image.gte(0.0);
  return image.updateMask(validPixels);
}

/** FUNCTION TO MASK CLOUDS BASED ON THE pixel_qa BAND OF
LANDSAT 8 SR DATA */
function maskL8sr(image) {
  // Bits 3 and 5 are cloud shadow and cloud, respectively.
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);
  // Get the pixel QA band.
  var qa = image.select('pixel_qa');
  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  return image.updateMask(mask);
}

/** FUNCTION TO COMPUTE NDVI AND EVI */
function VI(image){
  var NDVI = image.expression(
    '(B5 - B4) / (B5 + B4)', {
      'B5': image.select('B5'),
      'B4': image.select('B4')
    });
  var EVI = image.expression(
    '(G * (B5 - B4))/(L+B5+(B4*C1)+(B2*C2))', {
      'B5': image.select('B5'),
      'B4': image.select('B4'),
      'B2': image.select('B2'),
      'L': ee.Number(1.0),
      'G': ee.Number(1.5),
      'C1': ee.Number(6.0),
      'C2': ee.Number(7.5)
    });
  return image.addBands([NDVI.rename("NDVI"), EVI.rename("EVI")]);
}

```

```

/** FUNCTIONS TO MASK NDVI < 0.3 and EVI < 0.15 (Non vegetated areas): */
function maskNDVI(image){
  var NDVIlessThan = image.select('NDVI').gte(0.3);
  return image.updateMask(NDVIlessThan);
}
function maskEVI(image){
  var EVIlessThan = image.select('EVI').gte(0.15);
  return image.updateMask(EVIlessThan);
}

/** FUNCTION TO SUBSET ALL IMAGES FROM A COLLECTION: */
function subset(image) {
  return image.clip(aoi);
}

/** CREATING THE VARIABLE AS COLLECTION TO STORE THE FILTERED
AND PROCESSED SCENES: */
// Defining the range period:
var landsat8 = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
  .filterBounds(aoi)
  .filterDate(start, finish)
  .map(maskInvalid)
  .map(maskL8sr)
  .map(VI)
  .map(subset)
  .map(maskNDVI)
  .map(maskEVI)
  .map(Combine);
//print(landsat8, 'Landsat 8 Surface Reflectance without clouds');

/** MOSAICKING LANDSAT 8 SCENES BY DATE (ONE MOSAIC BY MONTH)
*/
// Difference in days between start and finish
var diff = finish.difference(start, 'month');
//print(diff, "Difference of months");

// Make a list of all dates
var range = ee.List.sequence(0, diff.subtract(1)).map(function(day){return
start.advance(day,'month')});
//print(range, "List of all months");

// Funtion for iteraton over the range of dates
var day_mosaics = function(date, newlist) {
  // Cast
  date = ee.Date(date);
  newlist = ee.List(newlist);

  // Filter collection between date and the next day
  var filtered = landsat8.filterDate(date, date.advance(1,'month'));

```

```

// get date as YEARMONTHDAY. For example, for January 8th 2010
// would be: 20100108
var date_formatted = ee.Number.parse(date.format('YYYYMMdd'));

// Make the mosaic
var image = ee.Image(filtered.mosaic()).set('Mosaic', date_formatted);

// Add the mosaic to a list only if the collection has images
return ee.List(ee.Algorithms.If(filtered.size(), newList.add(image), newList));
};

// Iterate over the range to make a new list, and then cast the list to an imagecollection
var newcoll8 = ee.ImageCollection(ee.List(range.iterate(day_mosaics, ee.List([]))));
//print(newcoll8, "Collection with Landsat 8 mosaic images");

/** SENTINEL-1 DATA PROCESSING: */
// The goal of this algorithm is process SAR images from Sentinel-1. The code does:

// 1) Creates a function to apply an speckle filter: in this case by Focal Median method;

// 2) Creates a function that will, based on band histogram (from VV and VH FLOAT
bands),
// remove an "heavy-tail" from their histograms: this part of distribution that is
understood as
// outliers;

// 3) Applying all functions above, the code creates a variable containing a image
// collection for each band. The result are the bands Sigma0_VV and Sigma0_VH;

// 5) Creates and apply functions to compute all the SAR vegetation indices of interest:
// DPSVI original (Periasamy, 2018) and DPSVI modified;

// 6) Finally, the code create mosaics for the area, combining images from the data
period
// selected;

/** Function to apply speckle noise removal filter by Focal Median: */
// The window (the kernel) used to apply the filter is in pixel number, that is odd
number
function MedianVV(image){
  return image.addBands(image.focal_median({radius: 5,
      kernelType: 'square',
      units: 'pixels'}))
      .rename(['Sigma0_VV']));
}
function MedianVH(image){
  return image.addBands(image.focal_median({radius: 5,
      kernelType: 'square',
      units: 'pixels'}))
      .rename(['Sigma0_VH']));
}

```

```

}

/** Function to mask outliers in VV band based on histogram analysis */
function maskVV(image){
  var quantil90 = image.reduceRegion({reducer:
    ee.Reducer.percentile({percentiles: ee.List([95]),
      outputNames: ee.List(['p95'])}),
    scale: 10,
    bestEffort: true});
  var Outliers = image.select('VV').lte(ee.Number(quantil90.get('VV')));
  return image.updateMask(Outliers);}
function maskVH(image){
  var quantil90 = image.reduceRegion({reducer:
    ee.Reducer.percentile({percentiles: ee.List([95]),
      outputNames: ee.List(['p95'])}),
    scale: 10,
    bestEffort: true});
  var Outliers = image.select('VH').lte(ee.Number(quantil90.get('VH')));
  return image.updateMask(Outliers);}

/** Vars that will receive and pre-process the Sentinel-1 SAR choiced images: */
var sentinel1VV = ee.ImageCollection('COPERNICUS/S1_GRD_FLOAT')
  .filter(ee.Filter.eq('instrumentMode', 'IW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  // .filter(ee.Filter.eq('relativeOrbitNumber_start', 82)) //Filter necessary to
basin 779926
  .filter(ee.Filter.eq('resolution_meters', 10))
  .filterBounds(aoi) //roi: Necessary to Doce River Basin, to avoid select
excess images
  .filterDate(start, finish)
  .select('VV')
  .map(maskVV)
  .map(MedianVV)
  .select('Sigma0_VV');

// VH band
var sentinel1VH = ee.ImageCollection('COPERNICUS/S1_GRD_FLOAT')
  .filter(ee.Filter.eq('instrumentMode', 'IW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  // .filter(ee.Filter.eq('relativeOrbitNumber_start', 82)) //Filter necessary to
basin 779926
  .filter(ee.Filter.eq('resolution_meters', 10))
  .filterBounds(aoi) //roi: Necessary to Doce River Basin, to avoid select
excess images
  .filterDate(start, finish)
  .select('VH')
  .map(maskVH)
  .map(MedianVH)
  .select('Sigma0_VH');

```

```

/** Combining both image collections (Sigma0_VV and Sigma0_VH): */
var sentinel1 = sentinel1VV.combine(sentinel1VH);
//print(sentinel1, "Sentinel-1 filtered images");

/** Computing vegetation index over each image in collection: */
// The outputs of this function are:
// The original Dual Polarization SAR Vegetation Index (DPSVI; Perisamy, 2018);
// and the modified DPSVI (proposed here):
function indices(image){
  var max = image.reduceRegion({reducer: ee.Reducer.max(), scale: 10,
                                geometry: aoi, bestEffort: true});
  var DPSVIoriginal = image.expression(
    '((VVmax - VV)+VH)/1.414213562 * ((VV+VH)/VV) * VH', {
      'VH': image.select('Sigma0_VH'),
      'VV': image.select('Sigma0_VV'),
      'VVmax': ee.Number(max.get('Sigma0_VV'))
    });
  var DPSVIm = image.expression(
    '(VV*VV+VV*VH)/1.414213562',{
      'VH': image.select('Sigma0_VH'),
      'VV': image.select('Sigma0_VV')
    });
  return image.addBands([DPSVIm.rename("DPSVIm"),
                        DPSVIoriginal.rename("DPSVIo")]);}

// The follow function apply the DPSVI normalization procedure:
function DPSVINorm(image){
  var max = image.reduceRegion({reducer: ee.Reducer.max(),
                                scale: 10,
                                geometry: aoi,
                                bestEffort: true});
  var min = image.reduceRegion({reducer: ee.Reducer.min(),
                                scale: 10,
                                geometry: aoi,
                                bestEffort: true});
  var DPSVI = image.expression(
    '(DPSVI - DPSVImin) / (DPSVImax - DPSVImin)',{
      'DPSVI': image.select('DPSVIm'),
      'DPSVImax': ee.Number(max.get('DPSVIm')),
      'DPSVImin': ee.Number(min.get('DPSVIm'))
    });
  return image.addBands(DPSVI.rename('DPSVI'));
}

// Now the functions of this section are applied over Image Collection:
var S1 = sentinel1.map(indices);
var S1new = S1.map(DPSVINorm)
  .select(['Sigma0_VV', 'Sigma0_VH', 'DPSVIo', 'DPSVI'])
  .map(subset);

```

```

//print(S1new, "Pos processing images S1");

/** Mosaicking Sentinel-1 scenes by date */
// Difference in days between start and finish
var diff = finish.difference(start, 'month');
//print(diff, "Difference of months");

// Make a list of all dates
var range = ee.List.sequence(0, diff.subtract(1)).map(function(day){return
start.advance(day,'month')});
print(range, "List of all months");

// Funtion for iteraton over the range of dates
var day_mosaics = function(date, newlist) {
  // Cast
  date = ee.Date(date);
  newlist = ee.List(newlist);

  // Filter collection between date and the next day
  var filtered = S1new.filterDate(date, date.advance(1,'month'));

  // get date as YEARMONTHDAY. For example, for January 8th 2010
  // would be: 20100108
  var date_formatted = ee.Number.parse(date.format('YYYYMMdd'));

  // Make the mosaic
  var image = ee.Image(filtered.mosaic()).set('Mosaic', date_formatted);

  // Add the mosaic to a list only if the collection has images
  return ee.List(ee.Algorithms.If(filtered.size(), newlist.add(image), newlist));
};

// Iterate over the range to make a new list, and then cast the list to an imagecollection
var newcols1 = ee.ImageCollection(ee.List(range.iterate(day_mosaics, ee.List([]))));
//print(newcols1, "Collection with Sentinel-1 mosaic images");

/** COMBINING LANDSAT 8 AND SENTINEL-1 MOSAICS IN ONE IMAGE
COLLECTION: */
var images = newcoll8.select(['NDVI','EVI','slope'])
    .combine(newcols1);
//print(images, "Image collection containing L8 and S1 data");

/** VISUALIZING ON THE MAP THE AOI AND SCENES PROCESSED: */
Map.centerObject(aoi);
//Map.addLayer(aoi);
//var NDVIvisParams = {min: 1, max: 33};
//Map.addLayer(images.first(), {bands: ['EVI'], visParams: NDVIvisParams}, "EVI");
//Map.addLayer(images.first(), {bands: ['DPSVI'], visParams: NDVIvisParams},
"DPSVI");

```

```

/** GETTING RANDOMLY SAMPLES: */
// Sample mosaic images
//var listOfImages = images.toList(images.size());
//print(listOfImages, "Lista de imagens selecionadas e processadas.");

//var image = ee.Image(listOfImages.get(0));
var image = images.first();
//print(image, "Product in analysis");

var sample = image.sample({region: aoi,
                          scale: 30,
                          tileSize: 16,
                          numPixels: 3000 //Note that numPixels is the approximated number of
samples to collect
});
//print(sample, "Amostras coletadas");

// Export sample tables obtained from Sentinel-1 and Landsat-8 mosaics at same
position:
Export.table.toDrive({collection: sample,
                     folder: 'Chapter1_Indices_baciaDoce',
                     description: 'DPSVI-NDVI-EVI_2015-10'});

// Visualize the behavior of spectral and microwave indices:
var chart = ui.Chart.feature.byFeature(sample, 'NDVI', ['DPSVI'])
    .setChartType('ScatterChart')
    .setOptions({pointSize: 2,
                 pointColor: 'red',
                 title: "Bacia Doce",
                 titleY: 'DPSVI (dl)',
                 titleX: 'NDVI (dl)',
                 trendlines: {0: {
                               type: 'linear',
                               color: 'green',
                               showR2: true,
                               visibleInLegend: true }}});

print(chart);
var chart1 = ui.Chart.feature.byFeature(sample, 'NDVI', ['DPSVIo'])
    .setChartType('ScatterChart')
    .setOptions({pointSize: 2,
                 pointColor: 'red',
                 title: "Bacia Doce",
                 titleY: 'DPSVI',
                 titleX: 'NDVI (dl)',
                 trendlines: {0: {
                               type: 'linear',
                               color: 'green',
                               showR2: true,
                               visibleInLegend: true }}});

//print(chart1);

```

```

/** ANALYSING THE IMAGE USING A BAND SCATTERPLOT */
//var result = image.reduceRegion({reducer: ee.Reducer.toList(),
//                                geometry: aoi,
//                                bestEffort: true,
//                                scale: 1000});
// Convert the band data to plot on the y-axis to arrays.
//var yValues = ee.Array(result.get('DPSVI'));
// The band data to plot on the x-axis is a List.
//var xValues = result.get('EVI');
// Make a band correlation chart.
//var chart2 = ui.Chart.array.values(yValues, 0, xValues)
//                .setOptions({title: '2015-10-01',
//                              hAxis: {'title': 'EVI (dl)'},
//                              vAxis: {'title': 'DPSVI (dl)'},
//                              pointSize: 3});
//Print the chart.
//print(chart2, "Band scatter plot");

```

5. APÊNDICE B – Código-fonte para geração das covariáveis de radar e variáveis dependentes ópticas

O material a seguir é um código fonte em JavaScript implementado na plataforma Google Earth Engine JavaScript API (<https://earthengine.google.com/>). Esse código está afeto ao segundo artigo da dissertação, e o objetivo é gerar as covariáveis provenientes do SAR-C Sentinel-1 e variáveis dependentes provenientes do Landsat 8. O código está subdividido em quatro partes: 1) STUDY AREA POLYGONS, onde os arquivos vetoriais das áreas de estudo são importados para o processamento das imagens; 2) LANDSAT 8 DATA PROCESSING, onde ocorre todo o processamento (mascarar nuvem e sombra de nuvem, eliminação de pixels anômalos, etc) das imagens Landsat 8 (reflectância da superfície) para gerar as variáveis dependentes: índices de vegetação EVI e NDVI, além disso, nesta parte há a agregação de uma imagem de declividade proveniente do DEM/SRTM; 3) SENTINEL-1 DATA PROCESSING, processamento dos dados de radar Sentinel-1 (filtragem de outliers, filtragem de *speckle*, etc) onde os índices: DPSVIm, RVIm, Pol e CR são calculados; por fim a parte 4) onde todas as imagens (Sentinel-1, Landsat 8 e SRTM) são combinadas (pela data) para serem amostrados pixels.

Link para acesso ao código no Google Earth Engine:
<https://code.earthengine.google.com/41aff12ff0d4248d1768cec3162d7eb1?noload=true>

```

//Code: Sentinel-1 and Landsat 8 derived variables.
//The Sentinel-1 generates the covariables to modelling
//the Landsat 8 dependent variables, both: NDVI and EVI.

//Inputs/Arguments: Polygons of study areas; date (month) of analysis
//Author: Erli Pinto dos Santos
//   Agronomy Engineer
//   Master's student in Agricultural Engineering
//   Universidade Federal de Viçosa (Viçosa, Minas Gerais, Brazil)
//   E-mail: erlisanto@outlook.com or erli.santos@ufv.br
//Last update: June 21, 2020

/** STUDY AREA POLYGONS */
// The geometry roi is especially needs to when apply the algorithm over entire Doce
river Watershed,
// to avoid select excess imagery
var roi = ee.FeatureCollection('users/erlisantos/Poligono_buffer_BH_RioDoce'
                              //'users/erlisantos/Poligono_BH_77992'
                              //'users/erlisantos/Poligono_BH_78623'
                              ).geometry();
// Note that from roi to aoi only the first geometry changes (to
'users/erlisantos/Poligono_BH_UPH_RioDoce'):
var aoi = ee.FeatureCollection('users/erlisantos/Poligono_BH_UPH_RioDoce'
                              //'users/erlisantos/Poligono_BH_77992'
                              //'users/erlisantos/Poligono_BH_78623'
                              ).geometry();

/** LANDSAT 8 DATA PROCESSING */
// The goal of this algorithm is take Landsat 8 Surface Reflectance scenes over the
AOI's and compute
// both NDVI and EVI spectral indices for all area and free of cloud cover and cloud
shadown. Thus,
// the output of this code is a table with pixel samples (NDVI) collected trough the
selected AOI.
// Note that all pixels with NDVI < 0.3 are masked, because this algorithm is designed
to vegetation analysis.
// Enjoy it!

/** SRTM IMAGE IN THE SCRIPT */
// It known that the topographical behavior of an area infer in the backscattering
behavior of radar data
// collected by SAR (Synthetic Aperture Radar) sensors. To study the topographical
influences about Sentinel-1
// SAR data, we include SRTM information in this script, with the goal of obtain
terrain slope and/or
// terrain aspect.

/** LOAD THE SRTM IMAGE: */
var srtm = ee.Image('USGS/SRTMGL1_003')
            .clip(aoi);

```

```

/** APPLY AN ALGORITHM TO COMPUTE TERRAIN SLOPE: */
var slope = ee.Terrain.slope(srtm);

/** MASK SLOPE IMAGE OMMITING SLOPE PIXELS > 10°: */
var Slope10 = slope.select('slope').lte(10);
var slopeNew = slope.updateMask(Slope10);

/** FUNCTION TO ADD SLOPE BAND TO EACH LANDSAT 8 SCENE: */
function Combine(image){
  return image.addBands(slopeNew.select('slope'));
}

/** FUNCTION TO MASK CLOUDS BASED ON THE pixel_qa BAND OF
LANDSAT 8 SR DATA */
function maskL8sr(image) {
  // Bits 3 and 5 are cloud shadow and cloud, respectively.
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);
  // Get the pixel QA band.
  var qa = image.select('pixel_qa');
  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  return image.updateMask(mask);
}

/** FUNCTION TO COMPUTE NDVI USING B5 AND B4 BANDS OF LANDSAT
8 SR DATA*/
function VI(image){
  var NDVI = image.expression(
    '(B5 - B4) / (B5 + B4)', {
      'B5': image.select('B5'),
      'B4': image.select('B4')
    });
  var EVI = image.expression(
    '(G * (B5 - B4))/(L+B5+(B4*C1)+(B2*C2))', {
      'B5': image.select('B5'),
      'B4': image.select('B4'),
      'B2': image.select('B2'),
      'L': ee.Number(1.0),
      'G': ee.Number(1.5),
      'C1': ee.Number(6.0),
      'C2': ee.Number(7.5)
    });
  return image.addBands([NDVI.rename("NDVI"), EVI.rename("EVI")]);
}

/** FUNCTIONS TO MASK NDVI < 0.3 and EVI < 0.15 (Non vegetated areas): */
function maskNDVI(image){

```

```

    var NDVILessThan = image.select('NDVI').gte(0.3);
    return image.updateMask(NDVILessThan);
  }
  function maskEVI(image){
    var EVILessThan = image.select('EVI').gte(0.15);
    return image.updateMask(EVILessThan);
  }

  /** FUNCTION TO SUBSET ALL IMAGES FROM A COLLECTION: */
  function subset(image) {
    return image.clip(aoi);
  }

  /** CREATING THE VARIABLE AS COLLECTION TO STORE THE FILTERED
  AND PROCESSED SCENES: */
  // Defining the range period:
  var start = ee.Date('2015-10-01');
  var finish = ee.Date('2015-11-02');

  var landsat8 = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
    .filterBounds(aoi)
    .filterDate(start, finish)
    .map(maskL8sr)
    .map(VI)
    .map(subset)
    .map(maskNDVI)
    .map(maskEVI)
    .map(Combine);
  //print(landsat8, 'Landsat 8 Surface Reflectance without clouds');

  /** MOSAICKING LANDSAT 8 SCENES BY DATE (ONE MOSAIC BY MONTH)
  */
  // Difference in days between start and finish
  var diff = finish.difference(start, 'month');
  //print(diff, "Difference of months");

  // Make a list of all dates
  var range = ee.List.sequence(0, diff.subtract(1)).map(function(day){return
  start.advance(day,'month')});
  //print(range, "List of all months");

  // Funtion for iteraton over the range of dates
  var day_mosaics = function(date, newlist) {
    // Cast
    date = ee.Date(date);
    newlist = ee.List(newlist);

    // Filter collection between date and the next day
    var filtered = landsat8.filterDate(date, date.advance(1,'month'));

```

```

// get date as YEARMONTHDAY. For example, for January 8th 2010
// would be: 20100108
var date_formatted = ee.Date(date);

// Make the mosaic
var image = ee.Image(filtered.mosaic()).set('system:time_start', date_formatted);

// Add the mosaic to a list only if the collection has images
return ee.List(ee.Algorithms.If(filtered.size(), newList.add(image), newList));
};

// Iterate over the range to make a new list, and then cast the list to an imagecollection
var newcoll8 = ee.ImageCollection(ee.List(range.iterate(day_mosaics, ee.List([]))));
//print(newcoll8, "Collection with Landsat 8 mosaic images");

/** SENTINEL-1 DATA PROCESSING */
// The goal of this algorithm is process SAR images from Sentinel-1. The code does:

// 1) Creates a function to apply an speckle filter: in this case by Focal Median method;

// 2) Creates a function that will, based on band histogram (from VV and VH FLOAT
bands),
// remove an "heavy-tail" from their histograms: this part of distribution that is
understood as
// outliers;

// 3) Applying all functions above, the code creates a variable containing a image
// collection for each band. The result are the bands Sigma0_VV and Sigma0_VH;

// 5) Creates and apply functions to compute all the SAR vegetation indices of interest:
// DPSVI modified, RVI modified and Pol (both based on Sigma0 in dB);

// 6) Finally, the code create mosaics for the area, combining images from the data
period
// selected;

/** Function to apply speckle noise removal filter by Focal Median: */
// The window (the kernel) used to apply the filter is in pixel number, that is odd
number
function MedianVV(image){
  return image.addBands(image.focal_median({radius: 5,
                                          kernelType: 'square',
                                          units: 'pixels'}))
    .rename(['Sigma0_VV']));
}
function MedianVH(image){
  return image.addBands(image.focal_median({radius: 5,
                                          kernelType: 'square',
                                          units: 'pixels'}))
    .rename(['Sigma0_VH']));}

```

```

/** Function to mask outliers in VV band based on histogram analysis */
function maskVV(image){
  var quantil90 = image.reduceRegion({reducer:
    ee.Reducer.percentile({percentiles: ee.List([95]),
      outputNames: ee.List(['p95'])}),
    scale: 10,
    bestEffort: true });
  var Outliers = image.select('VV').lte(ee.Number(quantil90.get('VV')));
  return image.updateMask(Outliers);}
function maskVH(image){
  var quantil90 = image.reduceRegion({reducer:
    ee.Reducer.percentile({percentiles: ee.List([95]),
      outputNames: ee.List(['p95'])}),
    scale: 10,
    bestEffort: true });
  var Outliers = image.select('VH').lte(ee.Number(quantil90.get('VH')));
  return image.updateMask(Outliers);}

/** Vars that will receive and pre-process the Sentinel-1 SAR choiced images: */
var sentinel1VV = ee.ImageCollection('COPERNICUS/S1_GRD_FLOAT')
  .filter(ee.Filter.eq('instrumentMode', 'IW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  // .filter(ee.Filter.eq('relativeOrbitNumber_start', 82)) //Necessary to basin
779926
  .filter(ee.Filter.eq('resolution_meters', 10))
  .filterBounds(aoi) //roi: Necessary to Doce River Basin, to avoid select
excess images
  .filterDate(start, finish)
  .select('VV')
  .map(maskVV)
  .map(MedianVV)
  .select('Sigma0_VV');

// VH band
var sentinel1VH = ee.ImageCollection('COPERNICUS/S1_GRD_FLOAT')
  .filter(ee.Filter.eq('instrumentMode', 'IW'))
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
  // .filter(ee.Filter.eq('relativeOrbitNumber_start', 82)) //Necessary to basin
779926
  .filter(ee.Filter.eq('resolution_meters', 10))
  .filterBounds(aoi) //roi: Necessary to Doce River Basin, to avoid select
excess images
  .filterDate(start, finish)
  .select('VH')
  .map(maskVH)
  .map(MedianVH)
  .select('Sigma0_VH');

/** Combining both image collections (Sigma0_VV and Sigma0_VH): */
var sentinel1 = sentinel1VV.combine(sentinel1VH);

```

```

//print(sentinel1, "Sentinel-1 filtered images");

/** Computing vegetation index over each image in collection: */
// The outputs of this function are:
// The modified Dual Polarization SAR Vegetation Index (DPSVIm);
// the Radar Vegetation Index modified (RVIm); and
// the Normalized Index (Pol):
function indices(image){
  var Pol = image.expression(
    '(VH - VV)/(VH + VV)', {
      'VH': image.select('Sigma0_VH').log10().multiply(10.0),
      'VV': image.select('Sigma0_VV').log10().multiply(10.0)
    });
  var RVIm = image.expression(
    '(4 * VH)/(VV + VH)', {
      'VH': image.select('Sigma0_VH').log10().multiply(10.0),
      'VV': image.select('Sigma0_VV').log10().multiply(10.0)
    });
  var DPSVIm = image.expression(
    '(VV*VV+VV*VH)/1.414213562',{
      'VH': image.select('Sigma0_VH'),
      'VV': image.select('Sigma0_VV')});

  return image.addBands([DPSVIm.rename("DPSVIm"),
    Pol.rename("Pol"),
    RVIm.rename("RVIm")]);}

// The follow function apply the DPSVI normalization procedure:
function DPSVINorm(image){
  var max = image.reduceRegion({reducer: ee.Reducer.max(),
    scale: 10,
    geometry: aoi,
    bestEffort: true});
  var min = image.reduceRegion({reducer: ee.Reducer.min(),
    scale: 10,
    geometry: aoi,
    bestEffort: true});
  var DPSVI = image.expression(
    '(DPSVI - DPSVImin)/(DPSVImax - DPSVImin)',{
      'DPSVI': image.select('DPSVIm'),
      'DPSVImax': ee.Number(max.get('DPSVIm')),
      'DPSVImin': ee.Number(min.get('DPSVIm'))
    });
  return image.addBands(DPSVI.rename('DPSVI'));
}

// Now the functions of this section are applied over Image Collection:
var S1 = sentinel1.map(indices);
var S1new = S1.map(DPSVINorm)
  .select(['Sigma0_VV', 'Sigma0_VH', 'DPSVI', 'RVIm', 'Pol'])

```

```

        .map(subset);
    //print(S1new, "Pos processing images S1");

    /** Mosaicking Sentinel-1 scenes by date */
    // Difference in days between start and finish
    var diff = finish.difference(start, 'month');
    //print(diff, "Difference of months");

    // Make a list of all dates
    var range = ee.List.sequence(0, diff.subtract(1)).map(function(day){return
start.advance(day, 'month')});
    print(range, "List of all months");

    // Funtion for iteraton over the range of dates
    var day_mosaics = function(date, newlist) {
    // Cast
    date = ee.Date(date);
    newlist = ee.List(newlist);

    // Filter collection between date and the next day
    var filtered = S1new.filterDate(date, date.advance(1, 'month'));

    // get date as YEARMONTHDAY. For example, for January 8th 2010
    // would be: 20100108
    var date_formatted = ee.Date(date);

    // Make the mosaic
    var image = ee.Image(filtered.mosaic()).set('system:time_start', date_formatted);

    // Add the mosaic to a list only if the collection has images
    return ee.List(ee.Algorithms.If(filtered.size(), newlist.add(image), newlist));};

    // Iterate over the range to make a new list, and then cast the list to an imagecollection
    var newcols1 = ee.ImageCollection(ee.List(range.iterate(day_mosaics, ee.List([]))));
    //print(newcols1, "Collection with Sentinel-1 mosaic images");

    /** COMBINING LANDSAT 8 AND SENTINEL-1 MOSAICS IN ONE IMAGE
    COLLECTION */
    var images = newcoll8.select(['NDVI', 'EVI', 'slope'])
        .combine(newcols1);
    //print(images, "Image collection containing L8 and S1 data");

    /** VISUALIZING ON THE MAP THE AOI AND SCENES PROCESSED: */
    Map.centerObject(aoi);
    //Map.addLayer(aoi);
    //var NDVIvisParams = {min: 0, max: 1};
    //Map.addLayer(images.first(), {bands: ['NDVI'], visParams: NDVIvisParams},
    "NDVI");
    //Map.addLayer(images.first(), {bands: ['DPSVI'], visParams: NDVIvisParams},
    "DPSVI");

```

```

/** GETTING SAMPLES: */
// Sample mosaic images
var image = images.first();
//print(image, "Produto em análise");

var sample = image.sample({region: aoi,
                          scale: 30,
                          tileScale: 16,
                          geometries: true,
                          seed: 317, //This randomization seed is useful to obtain another
pixels in sampling
                          numPixels: 2000 //Note that numPixels is the approximated number of
samples to collect
});
//print(sample, "Amostras coletadas");

// Export sample tables obtained from Sentinel-1 and Landsat-8 mosaics at same
position:
Export.table.toDrive({collection: sample,
                    folder: 'Chapter2_Indices_bacia_77992',
                    description: "Sample_2015-10-01"});

var chart = ui.Chart.feature.byFeature(sample, 'NDVI', ['DPSVI'])
    .setChartType('ScatterChart')
    .setOptions({pointSize: 2,
                pointColor: 'red',
                title: "Bacia 77992",
                titleY: 'DPSVI (dl)',
                titleX: 'NDVI (dl)',
                trendlines: {0: {
                    type: 'linear',
                    color: 'green',
                    showR2: true,
                    visibleInLegend: true }}}});

print(chart);
var chart1 = ui.Chart.feature.byFeature(sample, 'NDVI', ['Pol'])
    .setChartType('ScatterChart')
    .setOptions({pointSize: 2,
                pointColor: 'red',
                title: "Bacia UPH Rio Doce",
                titleY: 'Pol (dB)',
                titleX: 'NDVI (dl)',
                trendlines: {0: {
                    type: 'linear',
                    color: 'green',
                    showR2: true,
                    visibleInLegend: true }}}});

//print(chart1);

```