

JULIANO MARQUES PINTO

**USO DO SATÉLITE SENTINEL NA CORRELAÇÃO DE PARÂMETROS FÍSICOS-  
HÍDRICOS DO SOLO EM ÁREA CAFEIEIRA**

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia, *Campus* Monte Carmelo, como parte das exigências para obtenção do título de “Mestre”.

Orientador

Prof. Dr. Eusímio Fraga Felisbino Junior  
Coorientador

Prof. Dr. George Deroco Martins  
Coorientador

Prof. Dr. Osvaldo Rettore Neto

MONTE CARMELO  
MINAS GERAIS – BRASIL 2021

JULIANO MARQUES PINTO

**USO DO SATÉLITE SENTINEL NA CORRELAÇÃO DE PARÂMETROS FÍSICOS-  
HÍDRICOS DO SOLO EM ÁREA CAFEIRA**

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia, *Campus* Monte Carmelo, como parte das exigências para obtenção do título de “Mestre”.

APROVADA em 12 de agosto de 2021.

Banca examinadora

Prof. Dr. Eusímio Fraga Felisbino Junior – Universidade Federal de Uberlândia

Prof. Dr. Osvaldo Rettore Neto – Universidade Federal de Uberlândia

Prof. Dr. Jéfferson de Oliveira Costa – Universidade de São Paulo

Prof. Dr. Eusímio Fraga Felisbino  
Junior Ciências Agrárias – ICIAG

MONTE CARMELO  
MINAS GERAIS – BRASIL 2021



## UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Agricultura e  
Informações Geoespaciais

Rodovia LMG 746, Km 01, s/nº, Bloco 1AMC, Sala 1A202, Monte Carmelo-  
MG, CEP 38.500-000 Telefone: (34) 3810-1033 - ppgaig@iciag.ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	12/08/2021	Hora de início:	13:30	Hora de encerramento:	16:10
Matrícula do Discente:	31922AIG007				
Nome do Discente:	Juliano Marques Pinto				
Título do Trabalho:	Uso do satélite sentinel na modelagem de parâmetros físicos-hídricos do solo em área cafeeira				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Sistemas integrados de produção vegetal				

Reuniu-se na sala virtual Google Meet - <https://meet.google.com/rvv-wxhj-odf> a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. Jéfferson de Oliveira Costa (USP), Dr. Osvaldo Rettore Neto (UFU), Dr. Eusímio Felisbino Fraga Junior (UFU) – orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. Eusímio Felisbino Fraga Junior, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor (a) presidente concedeu a palavra, pela ordem sucessivamente, aos (às) examinadores (as), que passaram a arguir o (a) candidato (a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o (a) candidato (a):

## Aprovado

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Eusímio Felisbino Fraga Junior, Professor(a) do Magistério Superior**, em 12/08/2021, às 18:04, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Jéfferson de Oliveira Costa, Usuário Externo**, em 12/08/2021, às 18:04, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do

[Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Oswaldo Reçore Neto, Professor (a) do Magistério Superior**, em 13/08/2021, às 13:04, conforme horário oficial de Brasília, com fundamento no art. 6º,

§ 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site

[https://www.sei.ufu.br/sei/controlador\\_externo.php?](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2971273** e o código CRC **E9BA1ACE**.

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU com dados informados pelo (a) próprio (a) autor (a).

P659 Pinto, Juliano Marques, 1995-  
2021 USO DO SATÉLITE SENTINEL NA CORRELAÇÃO DE PARÂMETROS FÍSICOS-HÍDRICOS DO SOLO EM ÁREA CAFEIRA [recurso eletrônico] / Juliano Marques Pinto. - 2021.

Orientador: Eusímio Felisbino Fraga Junior.

Coorientador: George Deroco Martins.

Coorientador: Osvaldo Rettore Neto. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Agricultura e Informações Geoespaciais.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2021.385>

Inclui bibliografia.

1. Agronomia. I. Fraga Junior, Eusímio Felisbino , 1986-, (Orient.). II. Martins, George Deroco, 1987-, (Coorient.). III. Rettore Neto, Osvaldo , 1975-, (Coorient.). IV. Universidade Federal de Uberlândia.

Pós-graduação em Agricultura e Informações Geoespaciais.

V. Título.

CDU: 631

## **DEDICATÓRIA**

A Deus, meu protetor

Aos meus queridos pais Donizete Marques e Maria Lucia Pinto, ao meu irmão Donizete Marques Junior e minha namorada Marlyane Davi, por todo carinho e apoio nesta jornada.

## AGRADECIMENTOS

A realização deste trabalho contou com a colaboração direta e indireta de diversas pessoas, a quem manifesto meus sinceros agradecimentos:

Em primeiro lugar a Deus, pela minha vida e por minha família, por iluminar esta trajetória, abrindo caminhos e concedendo a oportunidade de conviver com pessoas especiais que me ensinaram muito nesse período de aprendizado.

Ao meu orientador Prof<sup>º</sup>. Dr. Eusímio F. Fraga Junior, pela transferência de conhecimentos acadêmicos, pela paciência e pelos momentos de incentivo, dedicação, sugestões e críticas construtivas que me fez eu passar por reflexões positivas nesta jornada da vida.

Ao meu co-orientador Prof. Dr. George Deroco Martins pelo auxílio na metodologia e desenvolvimento de grande parte da pesquisa recomendações que foram essenciais para que pudesse desenvolver e finalizar este trabalho, ao seu apoio na trajetória final da minha pós-graduação, bem como a dedicação e disponibilização de seu tempo.

Ao meu co-orientador Dr. Osvaldo Rettore Neto pelo seu auxílio nos diversos trabalhos realizados no período do mestrado, sugestões e críticas construtivas para a vida profissional.

A Fazenda Lajinha por ser parceira no trabalho, disponibilizando a área e para o Engenheiro Agrônomo Miguel Domingues Dias Junior pela coleta de amostras e disponibilizar dados de relevância que foram necessários no desenvolvimento da pesquisa.

Ao Centro de Inteligência de Cultivos Irrigados (CinCi), e aos colaboradores: Daniel Martins, Sarah Rios, Lucas Svirkas e demais colaboradores pelo apoio, auxílio e discussões sobre o tema da pesquisa.

Aos meus amigos Glécia do Carmo, Bruno Póvoa, Fernando Vasconcelos Pereira, Renato Aurélio Severino de Menezes Freitas e a todos os amigos não citados da 1º turma de Pós-Graduação em Agricultura e Informações Geoespaciais, pelos momentos de auxílio, reflexões e discussões sobre o tema da dissertação.

Ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais e a Universidade Federal de Uberlândia pelo auxílio financeiro, disponibilização do espaço físico e oportunidade de capacitação.

## **BIOGRAFIA**

Juliano Marques Pinto nasceu em Monte Carmelo, Minas Gerais, Brasil, 1995. Graduado em Engenharia Agrônoma pela Universidade Federal de Uberlândia – *Campus* Monte Carmelo (UFU), Minas Gerais, Brasil em 2017. Seus interesses de pesquisa incluem o desenvolvimento de técnicas de sensoriamento remoto em ambientes de cultivos irrigados.

## SUMÁRIO

1. INTRODUÇÃO .....	8
2. MATERIAL E MÉTODOS .....	9
2.1. Área de Estudo .....	9
2.2. Amostragem .....	10
2.3. Aquisição de Imagens .....	11
2.4. Processamento de Imagens e Dados.....	13
2.5. Cálculos dos Índices de Vegetação .....	14
2.6. Mineração e Método de Avaliação dos Dados .....	15
2.7. Regressão.....	15
2.8. Validação dos Modelos .....	16
3. RESULTADOS E DISCUSSÃO .....	19
4. CONCLUSÕES.....	27
5. PRÓXIMOS PASSOS.....	27
6. REFERÊNCIAS BIBLIOGRÁFICAS .....	28

## USO DO SATÉLITE SENTINEL NA CORRELAÇÃO DE PARÂMETROS FÍSICOS-HÍDRICOS DO SOLO EM ÁREA CAFEIEIRA

**RESUMO** - A agricultura utiliza-se de várias técnicas para aumentar a produtividade das lavouras. O uso da irrigação é uma técnica que permite o aumento e garantia da produtividade das culturas. O uso de conjunto de técnicas de sensoriamento remoto pode melhorar o manejo de água em diferentes escalas espaciais e temporais permitindo o monitoramento de grandes áreas irrigadas. Nesse contexto, o objetivo deste trabalho é aplicar índices espectrais derivados do Sentinel 2 em três imagens de datas diferentes (24/06/2017, 29/06/2018 e 09/07/2019), usufruindo dos algoritmos *Otimização Sequencial Mínima* (SMOreg) e Regressão Linear Simples (RLS), para constituir dentro das ciências agrárias modelos de predição capazes de representar os parâmetros físicos-hídricos capacidade de água disponível as plantas (CAD), umidades de capacidade de campo (CC) e ponto de murcha permanente (PMP) de forma rápida e com precisão. Para tanto, foram georreferenciados 21 pontos em uma área de lavoura cafeeira de 4,1ha. A cada ponto foi coletada uma amostra indeformada de solo na camada de 0 a 0,2 m de profundidade. Os modelos foram gerados através do software *Waikato Environment for Knowledge Analysis* (WEKA). Em todos os modelos gerados, nas três datas, os modelos não paramétricos sobressaíram com a Raiz Quadrada do Erro Médio (RMSE) menor em relação aos paramétricos. Houve predominância de uso do Índice de Diferença de Umidade Normalizado (NDMI) para estimar CC, uso do Índice de Estresse de Umidade de Razão Simples (MSI) para estimar PMP e uso predominante de NDMI e MSI nos modelos de CAD. Analisando o índice de confiança (c), os modelos gerados nas três datas, para estimar CAD foram os únicos satisfatórios, sendo que tanto para CAD, quanto para CC e PMP foram utilizadas bandas do Infravermelho próximo (NIR) e Infravermelho de ondas curtas (SWIR).

**Palavras-chave:** capacidade de água disponível, Modelos, SMOreg.

## USE OF SENTINEL SATELLITE IN THE CORRELATION OF PHYSICAL-HYDRIC SOIL PARAMETERS IN COFFEE AREA

**ABSTRACT** - Agriculture uses several techniques to increase crop productivity. The use of irrigation is a technique that allows the increase and guarantee of crop productivity. The use of a set of remote sensing techniques can improve water management at different spatial and temporal scales, allowing the monitoring of large irrigated areas. In this context, the objective of this work is to apply spectral indices derived from Sentinel 2 on three images of different dates (06/24/2017, 06/29/2018 and 07/09/2019), taking advantage of the Minimum Sequential Optimization (SMOreg) algorithms and Simple Linear Regression (RLS), to constitute, within the agricultural sciences, prediction models capable of representing the physical-water parameters available water capacity of plants (CAD), field capacity humidity (CC) and permanent wilting point (PMP) quickly and accurately. For this purpose, 21 points were georeferenced in a 4.1 ha coffee plantation area. At each point, an undisturbed soil sample was collected in the 0 to 0.2 m layer. The models were generated using the Waikato Environment for Knowledge Analysis (WEKA) software. In all models generated, on the three dates, the non-parametric models stood out with the Square Root Mean Error (RMSE) smaller than the parametric models. There was a predominance of use of the Normalized Moisture Difference Index (NDMI) to estimate WC, use of the Single Ratio Moisture Stress Index (MSI) to estimate PMP and predominant use of NDMI and MSI in CAD models. Analyzing the confidence index (c), the models generated on the three dates to estimate CAD were the only satisfactory ones, and for both CAD, CC and PMP, Near Infrared (NIR) and shortwave infrared bands were used (SWIR).

**Keywords:** available water capacity, Model, SMOreg

## 1. INTRODUÇÃO

A irrigação é uma técnica adotada na busca pelo aumento da produtividade das culturas dentro das fronteiras agrícolas já abertas, evitando supressão de vegetação nativa e aumentando a duração do período anual de plantios e a produção agrícola. O uso de conjunto de técnicas de sensoriamento remoto pode melhorar o manejo de água em diferentes escalas espaciais e temporais permitindo o monitoramento de grandes áreas irrigadas (SILVA et al., 2019).

Estudos com a aplicação de sensoriamento remoto (SR) vem tendo destaque na agricultura. Dentre eles o trabalho realizado por Senay et al. (2016) demonstrou que uso do SR e de dados agrometeorológicos são uma alternativa viável para o gerenciamento de recursos hídricos, auxiliando no planejamento agrícola e na eficiência do manejo da irrigação, a um custo relativamente baixo. As imagens contêm informações além de detecção do balanço de energia na superfície, mas também, quando corrigidas, podem captar fatores de estresses hídricos na vegetação, inerentes, principalmente, à evapotranspiração (MUSSI et al., 2020).

As características estruturais do solo são informações de grande valia no campo da agricultura irrigada, retratam sua constituição e nas condições sob as quais ele foi formado, destacando aquelas relacionadas à parâmetros físico-hídricos, drenagem e capacidade de armazenamento de água (PEREIRA et al., 2019).

A capacidade de água disponível (CAD) no solo é um parâmetro resultante de informações obtidas nas curvas de retenção de água (CRAs) do solo e que representa o seu conteúdo que pode ser efetivamente usufruído pela planta. Este está compreendido entre os limites de capacidade de campo (CC) e o ponto de murcha permanente (PMP), considerando a profundidade efetiva do sistema radicular (SOUZA; PEREIRA, 2019). O método mais utilizado para compor as CRAs é por câmara de Richards, apesar de preciso, esse método depende de análises laboratoriais onerosas, podendo se tornar uma tarefa trabalhosa e de elevado custo.

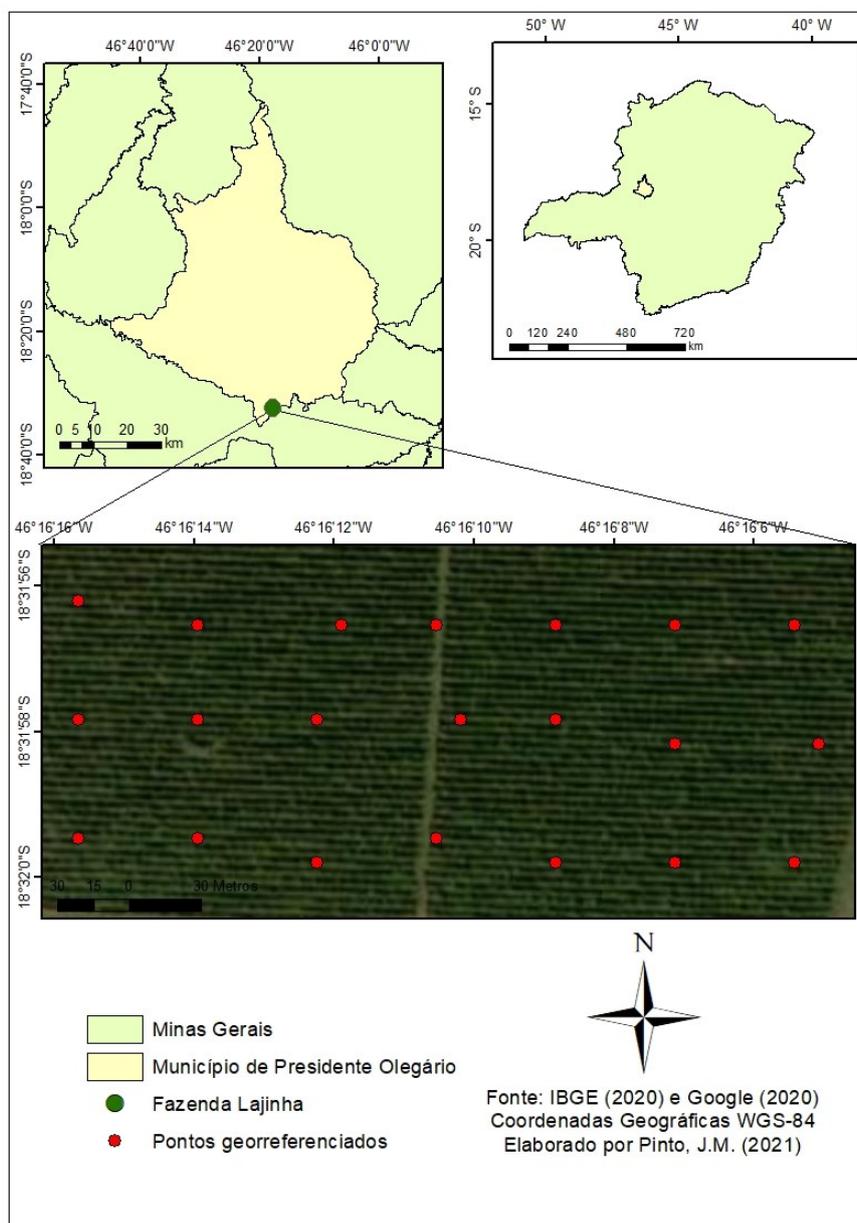
A hipótese a ser verificada no presente estudo é de que o uso de índices espectrais derivados do Sentinel 2 facilitam a estimativa de parâmetros físico-hídricos do solo quando utilizados em modelos de predição.

O objetivo deste trabalho foi aplicar índices espectrais derivados do Sentinel 2, usufruindo de algoritmos de aprendizagem de máquinas, com uso do algoritmo *Otimização Sequencial Mínima* (SMOreg) e Regressão Linear Simples (RLS), para constituir dentro das ciências agrárias modelos de predição capazes de representar os parâmetros físicos-hídricos capacidade de água disponível (CAD), umidades de capacidade de campo (CC) e ponto de murcha permanente (PMP) de forma rápida e com precisão.

## 2. MATERIAL E MÉTODOS

### 2.1. Área de Estudo

A área de pesquisa está situada na Fazenda Lajinha, no município de Presidente Olegário, MG, Brasil (latitude 18° 31' 56" Sul, longitude, 46° 16' 05" Oeste, com altitude média de 1022 m). A área de estudo contém 4,1 ha, conforme a Figura 1. A cada ponto foi coletada uma amostra indeformada de solo na camada de 0 a 0,2 m de profundidade. O local caracteriza-se por clima Aw segundo classificação de Koppen por ter clima tropical com verão chuvoso e inverno seco.



## FIGURA 1. Mapa de localização da Fazenda Lajinha

A cultura implementada na área é a *Coffea arabica* L., variedade Catuaí – 144. A lavoura foi implementada no ano de 2005, com espaçamento de 4 m entre linhas de cultivo e 0,5 m entre plantas. No ano de 2017, a produção da lavoura obteve média de 51,94 sacas por ha. Após a colheita foi realizado dois tipos de poda na lavoura (esqueletamento e decote). Tendo assim, no ano de 2018, safra “zero”, com apenas 3 sacas por ha e, no ano de 2019, uma média de 73,71 sacas por ha.

A lavoura também conta com a tecnologia de irrigação por gotejamento, com tubo gotejador Hydropec de vazão  $3,5 \text{ L h}^{-1}$  espaçados a 0,85 m entre emissores e utiliza manejo de irrigação via climático com auxílio de estação meteorológica.

O presente estudo foi dividido em três partes, a primeira descreve a coleta de amostras e parâmetros agronômicos, a segunda parte demonstra a aquisição e processamento de imagens utilizadas no estudo e a parte final apresenta a análise estatística e avaliação dos modelos.

### 2.2. Amostragem

Com o intuito de estimar parâmetros físico-hídricos do solo as amostras foram encaminhadas a um laboratório certificado conforme descrito no Manual de Métodos de Análise de Solo (TEIXEIRA et al., 2017), As amostras foram encaminhadas para o laboratório de Física do Solo da Escola Superior de Agricultura Luiz de Queiroz em Piracicaba para serem realizadas as análises de parâmetros do solo: determinação de granulometria, densidade aparente pelo método do anel volumétrico e determinação de dos parâmetros físico-hídricos do solo conforme o fluxograma da Figura 2.

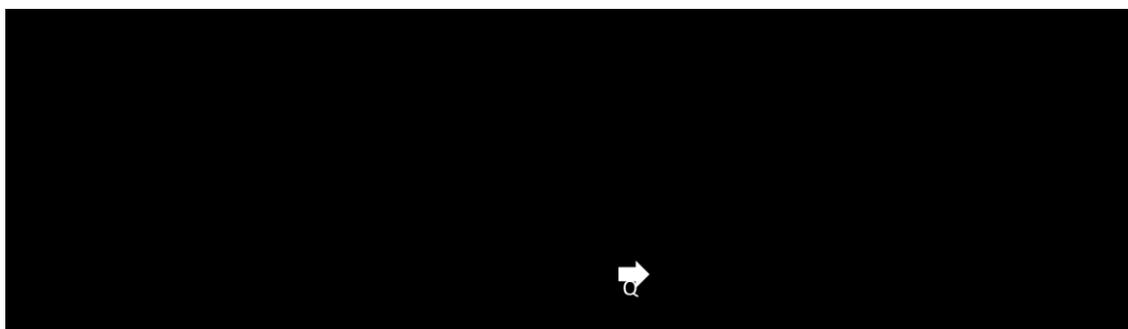


FIGURA 2. Fluxograma de amostragem de solo e análises realizadas em laboratório.

O entendimento dos parâmetros físico-hídricos contribui no planejamento de manejo da cultura, manejo irrigação e da fertirrigação, pois pode ser observado valores fixos de capacidade de valor de umidade de CC e valor de umidade de PMP em relação ao potencial matricial do solo. Para melhor compreensão os valores atribuídos a CC e PMP foram fixados aos respectivos valores de potencial matricial do solo (100 e 15200 cmca).

Para se obter resultado de todas as análises citadas, o laboratório começou os testes no dia 15 de julho de 2017 e terminou no dia 15 de setembro de 2017, totalizando 60 dias.

Para maior eficiência do monitoramento da irrigação via solo é vital conhecer sua função de reservatório de água, armazenando uma quantidade máxima de água, representada em milímetros. Na literatura o termo utilizado é no solo CAD do solo. O valor deste parâmetro está relacionado diretamente com a granulometria e densidade aparente do solo. Podendo assim variar conforme o tipo de solo. Com isto foi utilizada a Equação 1, para determinação da CAD das amostras em estudo com o auxílio dos parâmetros gerados nas CRAs.

$$CAD = \left( \frac{CC - PMP}{100} \right) * Z \quad (1)$$

Em que: “CAD” - capacidade de água disponível no solo, “CC” representa em porcentagem de umidade do solo em base volume, na capacidade de campo; “PMP” representa a porcentagem de umidade do solo base volume, no ponto de murcha permanente e “Z” a profundidade efetiva da raiz (mm).

Com isto, foi tabelado os valores de granulometria, densidade aparente e os parâmetros físicos-hídricos CAD, CC e PMP das 21 amostras, para melhor análise dos dados, conforme Tabela 4. Sendo assim, foram realizados estatística descritiva médias e desvio padrão (DP) de cada amostra para os parâmetros analisados: granulometria, densidade aparente e dos parâmetros CAD, CC e PMP, das 21 amostras enviadas para laboratório.

### **2.3. Aquisição de Imagens**

A segunda parte da pesquisa foi direcionada a aquisição de imagens, dentre vários satélites em órbita, o Sentinel-2A é um satélite com sensor multiespectral de resolução espacial média produzido pela Agência Espacial Europeia (ESA) contendo 13 bandas espectrais e 3 tipos diferentes de resolução, conforme a Tabela 1.

**TABELA 1.** Valores de comprimento de onda central e resolução para cada banda do satélite Sentinel 2.

Bandas Sentinel 2 A	Comprimento de onda central (nm)	Resolução (m)
B1 (Costal Aerossol)	442,7	60
B2 (Azul)	492,4	10
B3 (Verde)	559,8	10
B4 (Vermelho)	664,6	10
B5 (Red Edge 1)	704,1	20
B6 (Red Edge 2)	740,5	20
B7 (Red Edge 3)	782,8	20
B8 (Inf. Próximo)	832,8	10
B8A (Red Edge 4)	864,7	20
B9 (Vapor D'agua)	945,1	60
B10 (Cirrus)	1373,5	60
B11 (SWIR 1)	1613,7	20
B12 (SWIR 2)	2202,4	20

Este satélite caracteriza-se por abranger uma larga faixa imageada de 290 km, com resolução temporal de cinco dias e o tamanho da cena disponibilizada é de 100 por 100 km (DRUSCH et al., 2012; SOTHE et al., 2017). As imagens deste sensor são disponibilizadas ao público no banco de dados da ESA, as quais já estão processadas ao nível 1C, ou seja, já são corrigidas radiométrica e geometricamente (DRUSCH et al., 2012)

Para seleção das imagens na fase de *download* foram utilizados dois critérios. O primeiro foi a necessidade de coletar as imagens no período de estiagem de chuvas e o segundo a necessidade de quantidade mínima possível de cobertura de nuvens na imagem. O primeiro requisito é importante pois assegura que o solo não tenha interferência de acréscimo de umidade por pluviosidade, situação em que a estimativa dos parâmetros CAD, CC e PMP seriam afetadas, por isso, sendo aferido com a observação dos dados de chuva obtidos pela estação meteorológica da fazenda, identificando períodos com ausência de chuvas para que a estimativa dos parâmetros físico-hídricos do solo não tivesse interferência de acréscimo de umidade no solo por pluviosidade. Já o segundo foi observado diretamente na plataforma *Earth Explorer* desenvolvido pelo *United States Geological Survey* (USGS), o qual é realizado o *download* pelo site (<https://earthexplorer.usgs.gov>). Com os devidos critérios analisados, foram coletados

dados em formato GeoTIFF nas respectivas datas 24/06/2017 com ausência de chuva de trinta e quatro dias, 29/06/2018 com ausência de 41 dias de chuva e 09/07/2019 com ausência de 31 dias sem chuva.

## 2.4. Processamento de Imagens e Dados

Esta etapa da pesquisa foi dividida em processamento de imagens e processamento de dados, detalhando o passo a passo de cada processo, conforme fluxograma da Figura 3.

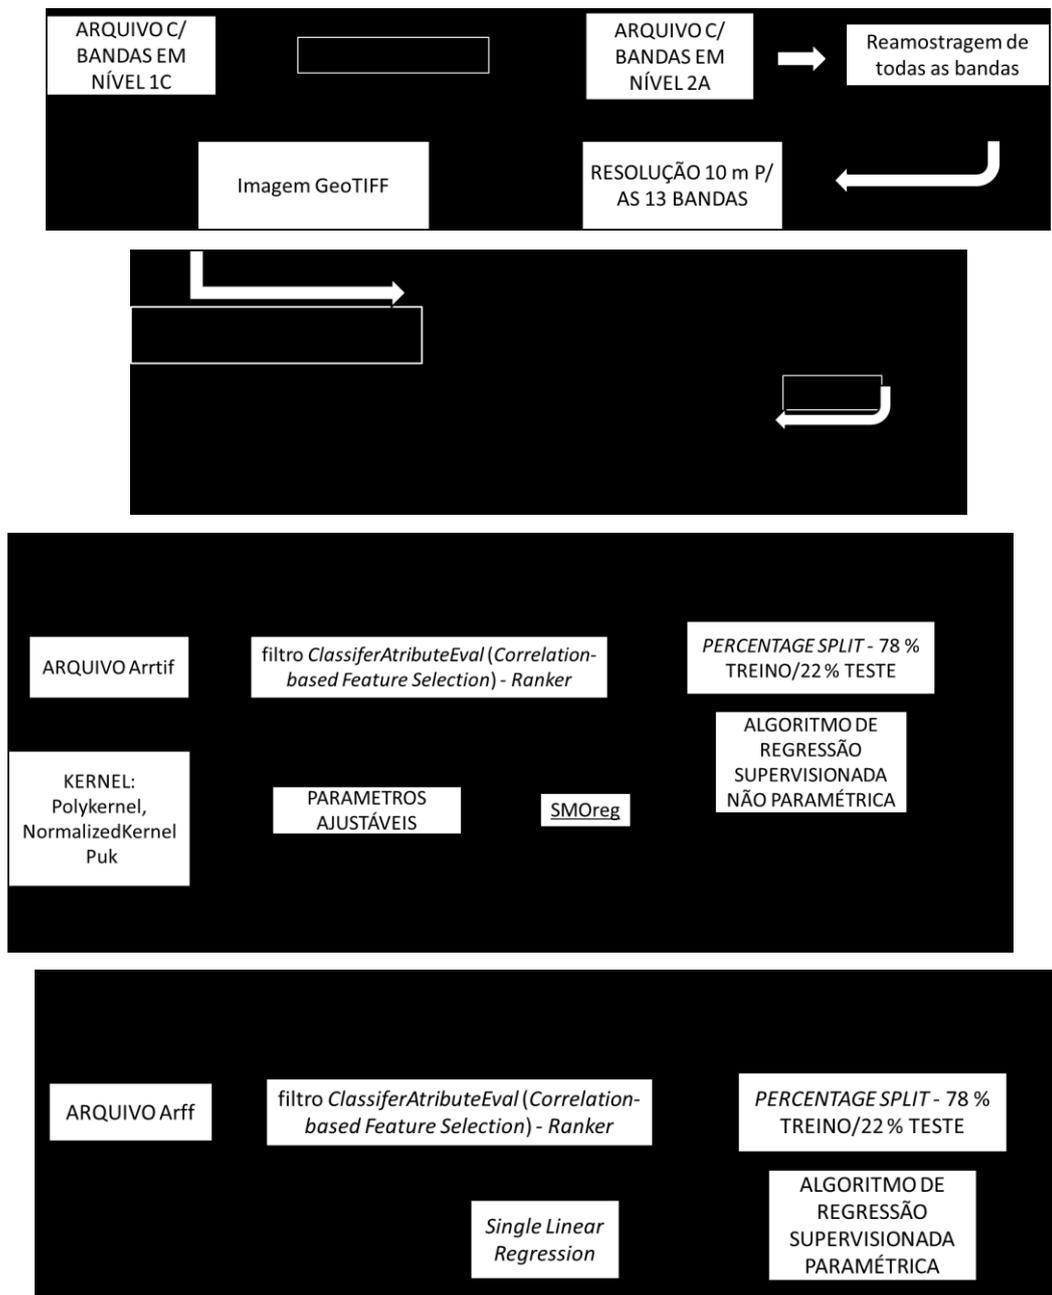


FIGURA 3. Fluxograma de processamento dos dados e modelagem

Para transformação dos valores de refletância no topo da atmosfera em valores de refletância da superfície foi realizada a correção atmosférica. Com isso, as imagens passam de nível 1C para nível 2A. Para essa correção foi utilizado o algoritmo *Sentinel 2A Atmospheric Correction* (Sen2Cor) disponibilizado no *software* SNAP (*Sentinel Application Correction Platform*).

Para a geração de valores de reflectância da superfície o algoritmo utiliza as bandas de aerossol (443 nm), de absorção de vapor d'água atmosférico (945 nm) e de nuvens cirros (1375 nm) em funções de transferência radiativa, oriundas de *lookuptables* (LUT) e geradas a partir da biblioteca *LibRadtran*, que calculam a radiação solar na atmosfera (EMDE et al., 2016).

Com uso do *software* ENVI 5.1, procedeu a extração dos valores de reflectância das treze bandas que o sensor MSI fornece em cada um dos 21 pontos georreferenciados, com a intenção de realizar a modelagem de estimativa da CAD, CC e PMP.

## **2.5. Cálculos dos Índices de Vegetação**

O sensoriamento remoto a partir de imagens orbitais, permite o monitoramento espaço-temporal dos recursos naturais de maneira eficiente e sistemática, vindo a proporcionar apoio técnico nas áreas de agricultura, previsões meteorológicas e hidrológicas.

Desse modo, diversos índices têm se apresentado mais recorrentes à literatura, como os índices de vegetação e do albedo superficial. Dentre eles, Jiao et al. (2016) relataram que o NDVI é um índice que tem a funcionalidade de acompanhamento do desenvolvimento vegetativo, principalmente estresse vegetativo e avaliação da produção da cultura, e podem estar relacionados ao estresse hídrico a nível regional, continental e até mundial. Os autores Almeida; Simões; Ferraz (2019) utilizaram os índices NDVI e SAVI para avaliar a degradação de pastagens. Segundo Zhang et. al (2017) utilizaram os índices MSI e NDMI na tentativa de detectar estresse hídrico na lavoura de trigo e constaram que o NDMI é um ótimo preditor, podendo auxiliar no manejo da irrigação.

Com isso, recorrendo ao uso das bandas fornecidas pelo sensor, foram escolhidos índices espectrais derivados do satélite Sentinel 2, os quais utilizam as bandas do sensor MSI para geração de modelos matemáticos, que em sua funcionalidade tem maior facilidade de caracterizar os parâmetros relacionados a umidade do solo, especificamente os parâmetros físicos-hídricos (CAD, CC e PMP), pela refletância do solo e da planta. Os índices podem ser observados na Tabela 2.

**TABELA 2.** Índices espectrais derivados do Sentinel 2 relacionados aos parâmetros de interesse neste trabalho.

Índice de Vegetação	Equação (nm)	Referência
NDVI	$\frac{R842 - R665}{R842 + R665}$	Rouse et al.(1973)
NDWI	$\frac{R. 560 - R842}{R560 + R842}$	McFeeters (1996)
NDMI	$\frac{R842 - R1610}{R842 + R1610}$	Hardisky; Klemas; Smart (1983)
SAVI	$\frac{R842 - R665}{R842 + R665 + L} * 1 + L$	Huete (1988)
ATSAVI	$\frac{R0.842 - a * R0.665 - b}{a * R842 + R665 - a * b + X * (1 + a^2)}$	He et al. (2006)
MSI	$\frac{R1600}{R800}$	Hunt e Rock(1989)

*Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Água por Diferença Normalizada (NDWI), Índice de Diferença Normalizada de Umidade (NDMI), Índice de Vegetação Ajustado ao Solo (SAVI), parâmetro L (fator de ajuste na fórmula do SAVI), Índice de Vegetação Ajustado e Transformado ao Solo VI (ATSAVI), parâmetros a, b e X são parâmetros de ajuste na fórmula do ATSAVI, Índice de Estresse de Umidade de Razão Simples (MSI).*

## 2.6. Mineração e Método de Avaliação dos Dados

Na modelagem de estimativa dos parâmetros físico-hídricos do solo, fez-se uso do *software* WEKA versão 3.9.4. Conforme apresentado no fluxograma 2, inicialmente fez-se a mineração de dados e em seguida utilizou a opção de aprendizagem de máquina supervisionada, a qual objetivou-se prever o valor de uma função para qualquer entrada válida de atributos, utilizando certo número de exemplos, assim chamados de treinamentos. A função de saída é denominada como valor de espaço contínuo.

## 2.7. Regressão

Com o carregamento do arquivo Arff com valor de CAD, os atributos escolhidos da imagem de 24/06/2017, o algoritmo de *Otimização Sequencial Mínima* (SMOreg) foi selecionado como ferramenta de análise, por demonstrar valor de RMSE menor entre todos os algoritmos testados. Este algoritmo qualifica-se como um codificador do classificador *Support*

*Vector Machine* (SVM). A vantagem deste algoritmo é que ele tem a capacidade de diminuir a quantidade de operações aritméticas, assim diminuindo o tempo de processamento das SVM.

A constante  $C$  e o tipo do kernel são parâmetros ajustáveis dentro SVM que podem ser ajustados para melhorar o desempenho dos modelos. A constante  $C$ , é um parâmetro utilizado para destacar maior ou menor importância das variáveis de folga (valores ou pontos que estão entre a linha de divisão e a linha de vetor), sendo assim, podendo diminuir ou aumentar a quantidade das variáveis de folga. O seu ajuste está no intervalo de 0 a 1, porém em todos os modelos a melhor performance foi com a escolha de  $C$  igual a 1. O termo  $C$  tem como objetivo a regularização que impõe um peso a minimização dos erros no conjunto de treinamento, isso em relação à minimização da complexidade do modelo (GEVERT, 2010). Outro parâmetro que tem a ajuda na precisão do modelo é o Kernel, o qual tem a finalidade de projetar os vetores de características de entrada em um espaço de características de alta dimensão para classificação de problemas que se encontram em espaços não linearmente separáveis, ou seja, ajustar o hiperplano. Foram testados três tipos de Kernel, o Polykernel (kernel polinomial de grau 1), NormalizedKernel (kernel polinomial de grau 2) e o Puk que abrange características de vários tipos de kernels (polinomial, função de base radial, sogmóide, etc.). Com isso fora escolhido para cada modelo aquele que melhor desempenhou em relação ao RMSE.

Com a escolha do algoritmo não paramétrico, foram realizados os modelos para CAD, CC e PMP com a utilização de imagens do satélite Sentinel 2 nas três datas selecionadas representando os anos 2017, 2018 e 2019. Após realizado a mineração com o filtro *ClassifierAttributeEval*, foi observado os índices mais relacionados com CAD, CC e PMP. Com isso, foram feitos testes combinando os índices que obtiveram mais destaque na mineração de dados com o intuito de encontrar índices que conseguissem representar os parâmetros, com menor valor de RMSE.

Para efeitos comparativos, o fluxograma 4 demonstra como foram realizados modelos paramétricos com o algoritmo RLS com os mesmos arquivos utilizados anteriormente utilizando apenas o índice espectral, tendo como requisito menor valor de RMSE possível. Totalizando dezoito modelos, sendo seis modelos por ano, cada ano contendo um modelo paramétrico e um não paramétrico para os parâmetros CAD, CC e PMP.

## **2.8. Validação dos Modelos**

Com o intuito de analisar a precisão dos modelos gerados foram utilizados os dados estimados de cada modelo, especificamente os escolhidos no subconjunto de treinamento pelo

método de avaliação *Percentage Split*, avaliando a qualidade dos mesmos baseando em indicadores estatísticos: coeficiente de correlação de linear de Pearson - r, Equação (2), indicando o grau de dispersão dos dados obtidos em relação à média, ou seja, o erro aleatório, Raiz Quadrada do Erro Médio - RMSE, Equação (3), índice de concordância Willmott- d, Equação (4), o qual demonstra o afastamento dos valores estimados em relação aos observados (exatidão) e o índice de confiança - c, Equação (5).

$$r = \frac{\sum_{i=1}^n (P_i - \bar{P}) \cdot (O_i - \bar{O})}{\sqrt{[\sum_{i=1}^n (P_i - \bar{P})^2] \cdot [\sum_{i=1}^n (O_i - \bar{O})^2]}} \quad (2)$$

$$\text{RMSE \%} = \sqrt{\sum_{i=1}^N (P_i - O_i)^2 / n} \cdot \frac{100 \times n}{\sum_{i=1}^n O_i} \quad (3)$$

$$d = 1 - \frac{\sum_{i=1}^n (P_i - \bar{O}_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}|) + (|O_i - \bar{O}|)^2} \quad (4)$$

$$c = r * d \quad (5)$$

Em que, “O” representa os dados observados em laboratório, “ $\bar{O}$ ” a média dos dados observados, “P” os dados previstos pelos modelos supervisionados, “ $\bar{P}$ ” a média dos dados previstos.

Na validação dos modelos, foi utilizado o RMSE, expressando a magnitude do erro produzido pelo modelo, então quanto mais próximo de zero melhor é o modelo (JANSSEN; HEUBERGER, 1995).

Neste trabalho foi utilizado o índice de confiança “c”, proposto por Camargo e Sentelhas (1997), que reúne os índices de precisão “r” e de exatidão “d” dos modelos para indicar o desempenho dos modelos, o seu valor pode variar de 0 a 1. Tendo a possibilidade de ser classificado em sete classes, conforme a Tabela 3:

**TABELA 3.** Classificação dos valores de índice de confiança “c” proposto por Camargo e Sentelhas (1997).

Índice “c”	Classificação
$<0,4$	Péssimo
$0,41 < c < 0,50$	Mal
$0,51 < c < 0,60$	Sofrível
$0,60 < c < 0,65$	Mediano
$0,66 < c < 0,75$	Bom
$0,76 < c < 0,85$	Muito bom
$> 0,85$	Ótimo

Se tratando do coeficiente de correlação linear de Pearson, segundo Dancey e Reidy (2006) é possível classificar o grau de correlação entre duas variáveis por meio deste em três classes, sendo que  $0,10 < r < 0,30$  é considerado como correlação fraca,  $0,40 < r < 0,60$  correlação moderada e  $0,70 < r < 1,00$  correlação forte. O índice de concordância designado pela letra “d” Willmott et al. (1985) como dito, demonstra a exatidão, o intervalo do índice é de 0, para não concordância, a 1, para concordância perfeita.

Ademais, a fim de se verificar possíveis diferenças significativas entre os valores observadas e preditos com a combinação de melhor desempenho, após a verificação de normalização dos dados, foi realizado o teste t de Student, admitindo um nível de significância de 5% ( $p < 0,05$ ).

Os melhores modelos foram selecionados com bases nos maiores valores dos parâmetros de avaliação, considerando a seguinte escala de importância: RMSE > “c” > Teste t de Student.

### 3. RESULTADOS E DISCUSSÃO

Após a observação dos valores de granulometria, densidade, CAD, CC e PMP das 21 amostras destacadas na Tabela 4, foram calculados médias e desvio padrão para cada um dos parâmetros citados. A classe granulométrica da área é classificada como argilosa (REINERT; REICHERT, 2006), tendo 51,90 % de argila e 7,51 % de DP entre as amostras, silte com 13,74 % e 2,94 % de DP e areia com 34,36 % e tendo um DP entre as amostras de 6,82 %. Sua densidade aparente média dos pontos foi de 0,99 g cm<sup>-3</sup> com DP de 0,04 g cm<sup>-3</sup>. Já o valor médio com os respectivos DPs das 21 amostras dos parâmetros CAD, CC e PMP com base em suas CRAs 20,82 mm e 2,29 mm, 44,26 % e 2,20%; 33,85 % e 2,06 %.

**TABELA 4.** Valores de granulometria, densidade aparente e dos parâmetros físicos CAD, CC e PMP das amostras.

Amostra	Argila (%)	Silte (%)	Areia (%)	Densidade (g.cm <sup>-3</sup> )	CAD (mm)	CC (%)	PMP (%)
1	54,72	9,84	35,44	1,04	20,23	44,52	34,41
2	55,39	6,51	38,11	0,97	20,31	42,86	32,71
3	64,05	11,17	24,77	0,92	17,10	43,93	35,38
4	70,72	13,84	15,44	0,97	19,80	43,26	33,36
5	50,72	12,51	36,77	0,97	20,58	43,87	33,58
6	60,05	9,84	30,11	1,03	24,57	48,02	35,73
7	54,72	12,51	32,77	0,99	23,78	45,20	33,31
8	53,39	13,84	32,77	1,12	16,83	48,17	39,76
9	40,05	16,51	43,44	0,87	18,31	41,14	31,99
10	52,05	11,17	36,77	0,97	23,67	44,03	32,19
11	49,39	15,17	35,44	0,97	21,27	44,37	33,74
12	42,72	13,84	43,44	1,06	24,82	47,30	34,89
13	52,05	13,84	34,11	0,99	21,41	44,05	33,34
14	52,05	12,51	35,44	1,04	21,64	44,92	34,10
15	60,05	19,17	20,77	0,90	20,08	41,10	31,06
16	53,39	13,84	32,77	0,96	17,26	39,46	30,83
17	46,72	15,17	38,11	1,06	20,78	46,49	36,10
18	49,39	16,51	34,11	1,00	22,55	43,72	32,45
19	42,72	16,51	40,77	0,96	20,22	44,28	34,17
20	42,72	17,84	39,44	0,99	19,84	46,01	36,09

21      42,72      16,51      40,77      0,94      22,14      42,66      31,59

Na Tabela 5, pode ser observado os valores dos índices espectrais provindos do Sentinel 2 no caso do NDMI, o qual está correlacionado com o estresse hídrico da planta. As imagens 24/06/2017 e 09/07/2019 demonstram, segundo classificação proposta por Guidotti et. al (2019), que a lavoura estava com a cobertura do dossel alto e nestes dois anos a lavoura estava em produção, justificando sua necessidade de demanda hídrica maior quando comparada com a imagem de 2018, em que a lavoura estava com dossel médio, ainda em recuperação de galhos e folhas por conta do manejo de poda, representando um ano de safra zero, situação de menor exigência hídrica, já que sustentava poucos frutos na planta. Segundo Zhang et. al (2017), em sua pesquisa, o NDMI obteve alta correlação com a umidade do solo em laboratório com  $R^2$  de 0,86, tendo facilidade de demonstrar o estresse hídrico da planta.

Di Raimo (2020) observou alta correlação das bandas do VIS na estimativa da granulometria do solo, em que a VIS conseguiu diferenciar em níveis de textura do solo arenoso de estudo, impactando nos parâmetros físico-hídricos do solo.

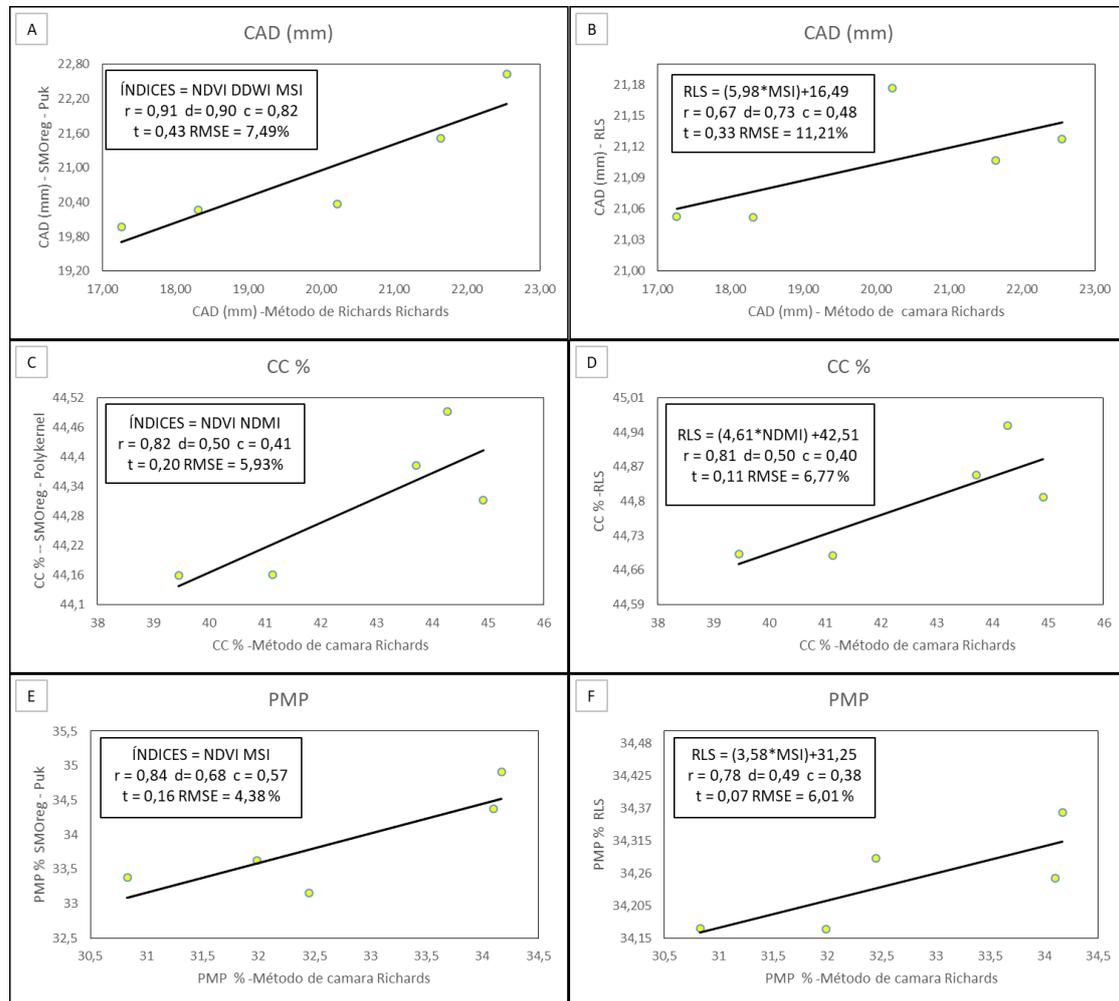
**TABELA 5.** Valores médios dos índices calculados dos 21 pontos georreferenciados.

DATA	NDVI	NDWI	NDMI	SAVI	GSAVI	ATSAVI	MSI
26/06/2017	0,81	-0,81	0,26	0,81	1,20	0,81	0,59
29/06/2018	0,89	-0,85	0,38	0,89	1,26	0,89	0,45
09/07/2019	0,67	-0,75	-0,02	0,67	1,11	0,65	1,06

O desempenho dos modelos gerados para a imagem de 24/06/2017 pode ser observado na Figura 4. Os modelos de RLS obtiveram nos três parâmetros avaliados (CAD, CC e PMP), valores de índice de confiança “c” menores quando comparados com os modelos realizados com SVM.

O modelo não paramétrico construído para a CAD, foi o único que obteve índice “c” classificado como um modelo muito bom segundo classificação proposta por Camargo e Sentelhas (1997). Pode ser observado que nos três modelos de regressão foram utilizados índices espectrais que utilizam de bandas SWIR, o índice MSI se destaca nos modelos dos parâmetros CAD e PMP. Utilizando essa classificação pode-se observar que os restantes dos modelos não foram satisfatórios, sendo que o modelo realizado com regressão para a CAD e o modelo com *support Vector Machine* para a PMP obtiveram valores que são classificados como

maus modelos. Já os modelos de CC obtiveram desempenho ainda menores, sendo classificados como péssimos. Isso justifica-se pelo fato de a exatidão dos modelos insatisfatórios estarem com valores baixos, mesmo com os valores elevados do coeficiente de Pearson “r”.



**FIGURA 4.** Desempenho de predição através de gráficos. Figura (A) Modelo de predição de CAD com algoritmo SMOreg; Figura (B) Modelo de predição de CAD com algoritmo RLS; Figura (C) Modelo de predição de CC com algoritmo SMOreg; Figura (D) Modelo de predição de CC com algoritmo RLS; Figura (E) Modelo de predição de PMP com algoritmo SMOreg; Figura (F) Modelo de predição de PMP com algoritmo RLS, com imagem Sentinel 24/06/2017.

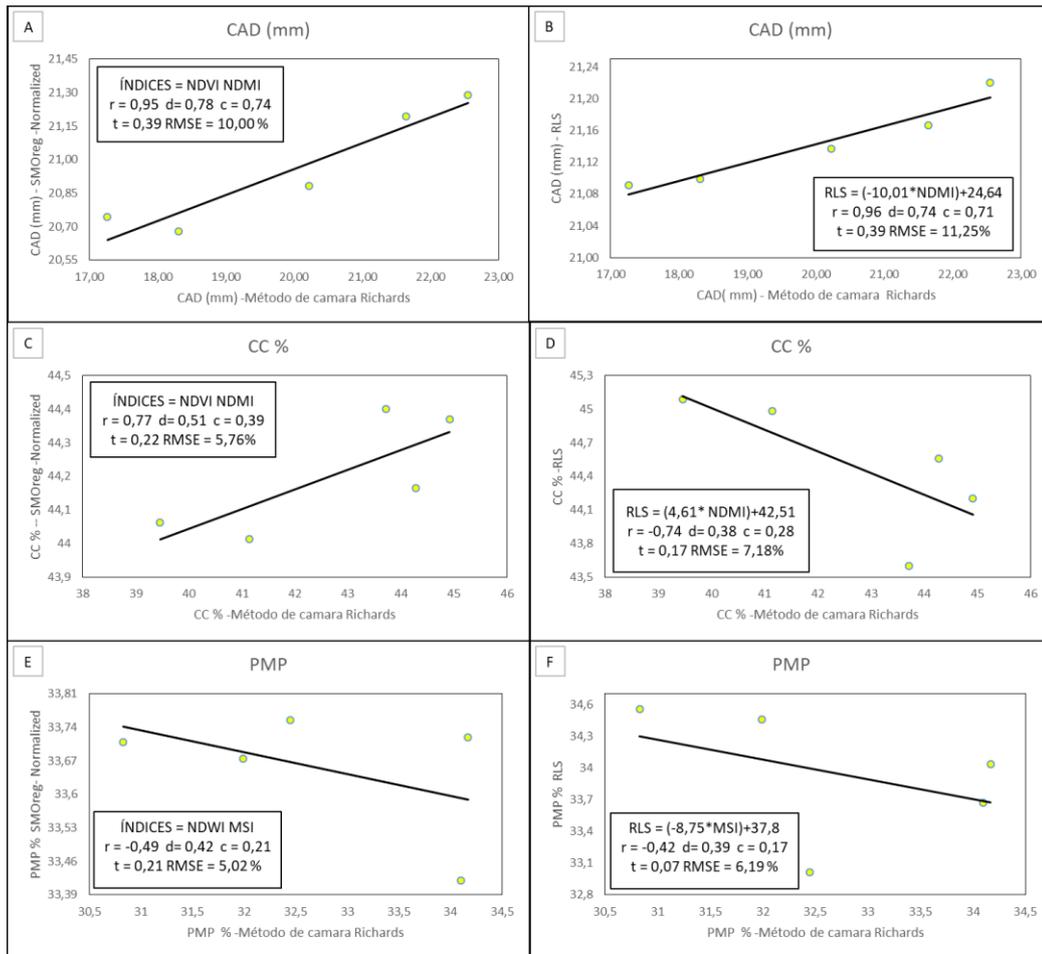
Ainda na Figura 4, pode ser observado que o valor de “r” em todos os casos com o algoritmo SMOreg foram superiores em relação aos modelos com RLS. Com isso, pode ser observado segundo a classificação de Dancey e Reidy (2006) que o valor “r” em todos os casos obtiveram correlações fortes entre os valores observados e estimados, exceto o modelo para a CAD com regressão, o qual classifica-se como moderado. Os valores de RMSE para os modelos

com o algoritmo SVM foram menores quando observado a percentagem de RMSE dos modelos não paramétricos e paramétricos. Desse modo, os modelos com SVM estimadores de CAD, CC e PMP tendem a ter precisão assertiva dos dados de 92,51 %, 94,07 % e 95,62 % dos dados respectivamente; já os modelos com regressão tendem a ter uma assertividade de 88,79 %, 93,23 % e 93,99 %.

O modelo de CAD não paramétrico utiliza do índice NDWI juntamente com o MSI e o NDVI, obtendo um RMSE de 7,49 % e índice de confiança de 0,90, demonstrando ser o modelo mais preciso e exato. Segundo Oliveira et al. (2010) em seu estudo, NDWI descreve com facilidade as mudanças de quantidade de umidade da região da Bacia Hidrográfica do Rio Moxotó-PE, sendo que a imagem do dia 20/04/1992 com maior valor de 0,5.

Analisado a Figura 5, a qual corresponde ao desempenho dos modelos gerados com o uso da imagem do dia 29/06/2018, foi observado que o cenário do coeficiente “r” modificou-se, e, segundo a classificação de Dancey e Reidy (2006), foi demonstrado que apenas os dois modelos para a CAD e os modelos com o SMOreg para CC obtiveram altos valores de correlação. Já os dois modelos gerados para estimar PMP demonstraram correlações moderadas.

Analisando o coeficiente “c” de cada item da Figura 5, os modelos estimadores de CAD conseguem ser classificados como bons modelos segundo a classificação de Camargo e Sentelhas (1997). E, nesta imagem, os modelos para os parâmetros CC e PMP ficaram enquadrados na classe de desempenho péssimo, segundo a mesma classificação. Isso pode ser explicado pelo fato que os valores do coeficiente “r” e os valores de Willmott “d” foram baixos para essas duas variáveis. Quando comparados os modelos da imagem 29/06/2018 para CC e PMP com os modelos gerados na imagem de 2017, é possível observar uma diminuição dos coeficientes citados, demonstrando uma perda de exatidão e precisão dos modelos na imagem de 2018.

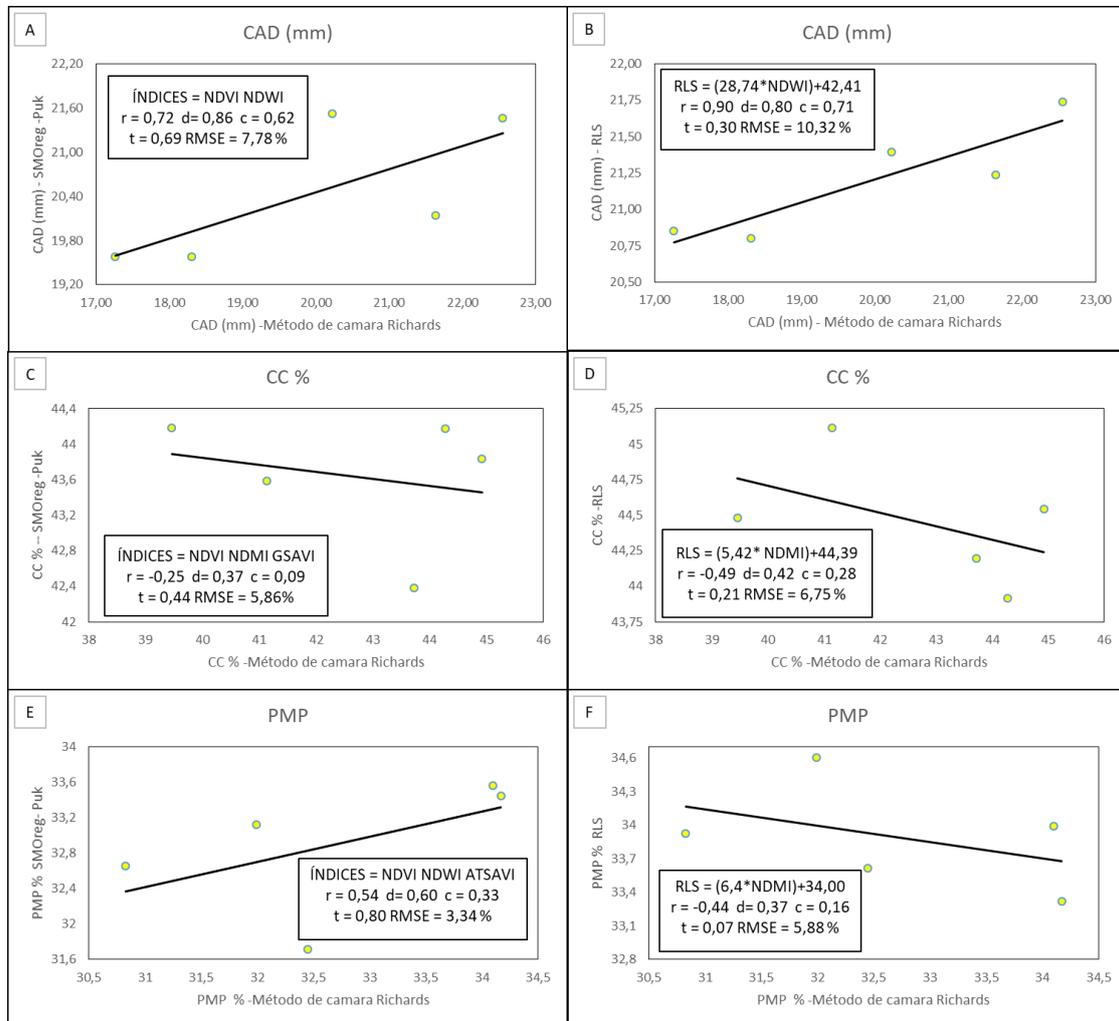


**FIGURA 5.** Desempenho de predição através de gráficos. Figura (A) Modelo de predição de CAD com algoritmo SMOreg; Figura (B) Modelo de predição de CAD com algoritmo RLS; Figura (C) Modelo de predição de CC com algoritmo SMOreg; Figura (D) Modelo de predição de CC com algoritmo RLS; Figura (E) Modelo de predição de PMP com algoritmo SMOreg; Figura (F) Modelo de predição de PMP com algoritmo RLS, com imagem Sentinel 29/06/2018.

Quando analisados os gráficos da Figura 5, foi possível verificar que os modelos com o algoritmo SMOreg obtiveram desempenho melhores quando comparados os modelos que utilizaram RLS nos três parâmetros (CAD, CC e PMP), quando observado o coeficiente “d”, coeficiente “c” e os valores RMSE. Porém, analisando os valores de RMSE, o modelo com maior valor é o de estimativa de CAD por RLS, com a possibilidade de precisão assertiva dos dados de 88,75%. Todos os outros modelos para o restante dos parâmetros conseguem precisão ainda maiores.

Na Figura 6, demonstra-se por gráficos o desempenho dos modelos para os parâmetros com dados da imagem de 2019. Pode ser observado que os dois modelos de estimativa da CAD

novamente se destacam no índice de confiança, sendo classificados como modelos medianos. Já os outros modelos para os parâmetros CC e PMP com os valores de “r” (precisão) e “d” (exatidão) menores, consequentemente obtiveram valores baixos no índice de confiança, assim sendo classificados como péssimos modelos.



**FIGURA 6.** Desempenho de predição através de gráficos. Figura (A) Modelo de predição de CAD com algoritmo SMOreg; Figura (B) Modelo de predição de CAD com algoritmo RLS; Figura (C) Modelo de predição de CC com algoritmo SMOreg; Figura (D) Modelo de predição de CC com algoritmo RLS; Figura (E) Modelo de predição de PMP com algoritmo SMOreg; Figura (F) Modelo de predição de PMP com algoritmo RLS, com imagem Sentinel 09/07/2019.

Utilizando da classificação de Dancy e Reidy (2006) é observado na Figura 6 que apenas os modelos de CAD conseguiram correlações de grau forte entre os valores observados e estimados para o coeficiente “r”. Já os modelos para o PMP obtiveram valor de “r” moderados e negativos. Toda via, os modelos de CC obtiveram valores de “r” negativos, sendo que o

modelo não paramétrico foi classificado como baixa correlação e o modelo de RLS demonstrou correlação moderada.

Entretanto, nos gráficos gerados para demonstrar o desempenho dos modelos gerados da Figura 6 pode ser observado que os modelos não paramétricos conseguiram valores de RMSE mais baixos do que os modelos realizados com RLS. Com tudo, pode ser observado nas Figuras 4, 5 e 6 que sempre os modelos de CAD obtiveram valores de RMSE maiores do que os outros dois parâmetros.

Segundo o teste de t Student, todos os modelos realizados para as três variáveis não apresentaram diferença significativa entre as medianas das amostras. Sendo assim, não houveram evidências suficientes para concluir que há diferença significativa entre as amostras, indicando um desempenho satisfatório tanto dos modelos não paramétricos quanto os modelos paramétricos.

Analisando os gráficos gerados pelos modelos percebe-se que os modelos de RLS gerados tiveram maiores desempenhos com o índice de vegetação NDMI e MSI. Pode ser observado que nas três datas os modelos de CAD utilizaram índices diferentes. Já os modelos para CC, em todas as imagens o melhor desempenho foi com o NDMI. Já para PMP, os modelos nos anos de 2017 e 2018 foram realizados com o índice MSI, diferente da imagem de 2019, em que o melhor desempenho de modelo com regressão foi com o que utilizou o índice NDMI.

A Agencia Nacional de Águas (ANA) realizou juntamente com a Universidade Federal do Paraná (UFPR) um estudo de estimativa de CAD por pedotransfêrencia (PTF), assim pode ser observado que o município de Presidente Olegário, o qual está localizado a área de estudo deste trabalho está representado com valor de CAD de 11,2 mm (ANA, 2021). Comparando o valor estimado por PTF, com os modelos por SR, os modelos gerados conseguem estimar com menor variação de erro, obtendo valores mais próximos com os valores de laboratório.

Raimo (2020) demonstra em seu trabalho que de maneira geral, duas regiões com maiores valores de correlação entre refletância e atributos físico-hídricos (CC e PMP) podem ser destacadas nos espectros nas bandas que compreendem parte das regiões Vis e NIR, entre 500 e 850 nm, onde obteve correlação de 0,25 a 0,50 entre de água em solos arenosos e valores de refletância. As bandas dessa região são relacionadas com a coloração do solo e de avermelhamento, deste modo os valores de refletância nesses comprimentos de onda relacionam-se também com a argila, qualitativamente e quantitativamente, e com os teores de matéria orgânica (POPPIEL et al., 2018).

O segundo comprimento de onda está entorno de 1400 nm; a 2500 nm, compreendendo parte da banda do infravermelho de ondas curtas (SWIR), sendo que as correlações começaram

com -0,35 com 1400 nm e chegando a -0,85 no comprimento de onda de 2500 nm. Demonstrando sensibilidade a minerais de argila presentes no solo especificamente, os argilominerais caulinita e gibbsita, que apresentam grande influência na retenção de água dos solos (DEMATTE et al., 2017)

Pode ser observado, nos três anos de avaliação, o uso diversas vezes do índice NDVI em modelos não paramétricos e no estudo elaborado por Raimo (2020) na tentativa de estimar parâmetros físico-hídricos em solos arenosos, com uso de bandas do visível (VIS) e bandas e ondas médias (MIR), relatou que as bandas do VIS são boas predictoras em modelos de previsão de CC e PMP.

Em todos os modelos de previsão para CC houve o uso do índice NDMI, ou seja, tendo influência da banda NIR e SWIR, conseguindo valores de RMSE baixos, porém seu índice “c” em todos os modelos foram insatisfatórios, por seu valor de exatidão não ser próximo a 1. Com uma correlação de 0,98 entre NDMI e o índice de umidade, porém por dificuldade de interpretação, o NDMI obteve baixo desempenho no estudo realizado por (SANTOS, 2005). A banda NIR tem facilidade interpretação visual da água, devido à forte absorção da água que é fortemente refletida pela vegetação terrestre e pelo solo seco.

O modelo com maior RMSE foi o da CAD de 2018, com uso de regressão linear simples, com RMSE de 11,25 %, sendo que todos os outros modelos gerados para os parâmetros em estudo obtiveram RMSE menor. Com tudo, a junção de dois ou mais índices espectrais provindos do Sentinel 2 tende a proporcionar um melhor desempenho nos modelos com o algoritmo não paramétrico SMOreg para prever os parâmetros de CC, PMP e CAD do que com modelos de regressão linear simples com apenas um índice espectral.

#### **4. CONCLUSÕES**

O uso de índices espectrais provindos do Sentinel 2 conseguem auxiliar na geração indireta de informações dos parâmetros físico-hídricos do solo. Por meio de softwares de aprendizado de máquinas, os índices conseguem descrever as características dos parâmetros CAD, CC e PMP. Com tudo, entre todos os modelos estimadores, os modelos para CAD obtiveram maior desempenho. Sendo que o índice utilizado em todos os modelos teve influência das bandas NIR e SWIR.

#### **5. PRÓXIMOS PASSOS**

O índice de confiança “c” demonstrou que os apenas os modelos para CAD obtiveram valores altos de precisão e exatidão, já os modelos de CC e PMP obtiveram valores mais baixos, necessitando de aprimoramento dos modelos. Sendo assim, há a necessidade de aumentar a quantidade de amostras coletadas na área, estimar variáveis como granulometria do solo com índices espectrais e testar os modelos confiáveis em áreas com vegetação e sem vegetação.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- AGENCIA NACIONAL DE ÁGUAS (ANA). Capacidade de água disponível (cad/awc) para solos brasileiros. v. 0, p. 1–5, 2021.
- ALMEIDA, M. B. F. DE; SIMÕES, M.; FERRAZ, R. P. D. Avaliação Dos Níveis De Degradação De Pastagens Por Sensoriamento Remoto: Um Subsídio Para O Plano De Agricultura De Baixa Emissão De Carbono. **Xix Simpósio Brasileira De Sensoriamento Remoto**, p. 3252–3255, 2019.
- CAMARGO, A. P. DE; SENTELHAS, P. C. **Performance evaluation of different potential evapotranspiration estimating methods in the State of São Paulo, Brazil** *Revista Brasileira de Agrometeorologia*, 1997. Disponível em: <[http://www.leb.esalq.usp.br/agmfacil/artigos/artigos\\_sentelhas\\_1997/1997\\_RB\\_Agro\\_5\(1\)\\_89-97\\_ETPM%E9todosSP.pdf](http://www.leb.esalq.usp.br/agmfacil/artigos/artigos_sentelhas_1997/1997_RB_Agro_5(1)_89-97_ETPM%E9todosSP.pdf)>
- DANCEY, C. RISTIN. P.; REIDY, J. **Estatística sem matemática: para psicologia usando SPSS para Windows**. 3. ed. Porto Alegre: Artmed, 2006.
- DEMATTÊ, J. A. M. et al. Genesis and properties of wetland soils by VIS-NIR-SWIR as a technique for environmental monitoring. **Journal of Environmental Management**, v. 197, p. 50–62, 2017. DOI : 10.1016/j.jenvman.2017.03.014
- DRUSCH, M. et al. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012. DOI: 10.1016/j.rse.2011.11.026
- EMDE, C. et al. The libRadtran software package for radiative transfer calculations (version 2.0.1). **Geoscientific Model Development**, v. 9, n. 5, p. 1647–1672, 2016. DOI: 10.5194/gmd-9-1647-2016
- GEVERT, V. G. Modelos de Regressão Logística, Redes Neurais e Support Vector Machine (SVM's) na Análise de Crédito a Pessoas Jurídicas. **RECEN - Revista Ciências Exatas e Naturais**, v. 12, n. 2, p. 269–293, 2010.
- GUIDOTTI, D. et al. Water management: Agriculus tools integration. **Global IoT Summit, GIoTS 2019 - Proceedings**, p. 1–5, 2019. DOI: 10.1109/GIOTS.2019.8766408
- HARDISKY, M. A.; KLEMAS, V.; SMART, R. M. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. **Photogrammetric Engineering & Remote Sensing**, v. 49, n. 1, p. 77–83, 1983.
- HE, Y.; GUO, X.; WILMSHURST, J. Studying mixed grassland ecosystems I: Suitable hyperspectral vegetation indices. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 98–

107, 2006. DOI: 10.5589/m06-009

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, n. 1, p. 225–309, 1988.

HUNT, E. R.; ROCK, B. N. Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. **Remote Sensing of Environment**, v. 30, n. 1, p. 43–54, 1989. DOI: 10.1016/0034-4257(89)90046-1

JANSSEN, P. H. M.; HEUBERGER, P. S. C. Calibration of process-oriented models. **Ecological Modelling**, v. 83, n. 1–2, p. 55–66, 1995. DOI: 10.1016/0304-3800(95)00084-9

JIAO, W. et al. Evaluating an enhanced vegetation condition index (VCI) based on VIUPD for drought monitoring in the continental United States. **Remote Sensing**, v. 8, n. 3, p. 1–21, 2016. DOI: 10.3390/rs8030224

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425–1432, 1996. DOI: 10.1080/01431169608948714

MUSSI, R. F. et al. Evapotranspiração da cana-de-açúcar estimada pelo algoritmo safer. **Brazilian Journal Of Irrigation And Drainage**, v. 25, p. 263–278, 2020. DOI : <http://dx.doi.org/10.15809/irriga.2020v25n>

OLIVEIRA, T. H. et al. Índice de umidade (NDWI) e análise espaço-temporal do albedo da superfície da bacia hidrográfica do rio Moxotó-PE. **Revista Brasileira de Geografia Física**, v. 2, n. 3, p. 55, 2010. DOI : 10.26848/rbgf.v3i2.232669

PEREIRA, M. G. et al. Formação e caracterização do solo. In: ATENA (Ed.). . **Formação, Classificação e Cartografi a dos Solos**. 1. ed. Ponta Grossa: Atena, 2019. p. 1–20. DOI: 10.29327/523696.1-1

POPPIEL, R. R. et al. Surface spectroscopy of oxisols, entisols and inceptisol and relationships with selected soil properties. **Revista Brasileira de Ciencia do Solo**, v. 42, p. 1–26, 2018. DOI: 10.1590/18069657rbc20160519

RAIMO, UIS A. D. L. DI. Caracterização e modelagem de solos arenosos e seus atributos químicos, físicos e físico-hídricos por sensoriamento remoto. n. July 2020, 2020. DOI: 10.13140/RG.2.2.17985.68967

REINERT, D. J.; REICHERT, J. M. **Propriedades físicas do solo**. Santa Maria: Departamento de Solos, UFSM, 2006.

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.

SANTOS, R. O uso de processamento digital de imagens do sensor advanced spaceborne

thermal emission and reflection radiometer (aster) na identificação de horizontes coesos em solos dos tabuleiros costeiros da bahia. **Journal of Chemical Information and Modeling**, v. 53, n. 9, p. 246, 2005.

SENAY, G. B. et al. Evaluating Landsat 8 evapotranspiration for water use mapping in the Colorado River Basin. **Remote Sensing of Environment**, v. 185, p. 171–185, 2016. DOI: 10.1016/j.rse.2015.12.043

SILVA, C. D. O. F. et al. Sensoriamento Remoto Orbital Para Manejo Da Irrigação: Uma Revisão Sistêmica. **Cybrarians Journal**, n. 37, p. 1–10, 2019. DOI: 10.13140/RG.2.2.19266.12487

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 data to map sucessional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, 2017. DOI: 10.3390/rs9080838

SOUZA, J. M. DE; PEREIRA, L. R. Capacidade de água disponível no solo em diferentes usos e amostras de solo. **Water Resources and Irrigation Management**, v. 7, n. January 2018, p. 6, 2019. DOI: 2316-6886

TEIXEIRA, P. C. et al. **Manual De Métodos De Análise De Solo**. 3. ed. Brasília: Embrapa, 2017.

WILLMOTT, C. J. et al. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v. 90, n. C5, p. 8995–9005, 1985. DOI: 10.1029/jc090ic05p08995

ZHANG, C. et al. Retrieving leaf and canopy water content of winter wheat using vegetation water indices. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 1, p. 112–126, 2017. DOI: 10.1109/JSTARS.2017.2773625