

UFRRJ
INSTITUTO DE TECNOLOGIA
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL

DISSERTAÇÃO

**Biometria e índices de vegetação por sensoriamento remoto em área de
pastagem no município de Cachoeiras de Macacu, RJ**

Mariane dos Santos Pessanha

2020



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO INSTITUTO
DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

**BIOMETRIA E ÍNDICES DE VEGETAÇÃO POR SENSORIAMENTO
REMOTO EM ÁREA DE PASTAGEM NO MUNICÍPIO DE CACHOEIRAS
DE MACACU, RJ**

MARIANE DOS SANTOS PESSANHA

Sob a Orientação do Professor
Gustavo Bastos Lyra
e Coorientação do Professor
Evaldo de Paiva Lima

Dissertação submetida como requisito parcial para obtenção do grau de **Mestra em Engenharia Agrícola e Ambiental**, no Curso de Pós- Graduação em Engenharia Agrícola e Ambiental, Área de Concentração em Meio Ambiente.

Seropédica - RJ
Novembro de 2020

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

P475b Pessanha , Mariane dos Santos , 1993-
Biometria e índices de vegetação por sensoriamento
remoto em área de pastagem no município de Cachoeiras
de Macacu, RJ / Mariane dos Santos Pessanha . -
Seropédica, 2020.
62 f.

Orientador: Gustavo Bastos Lyra.
Coorientador: Evaldo de Paiva Lima.
Dissertação(Mestrado). -- Universidade Federal
Rural do Rio de Janeiro, Pós-Graduação em Engenharia
Agrícola e Ambiental , 2020.

1. Geociências. 2. Geoprocessamento. 3. Imagem
orbital. 4. Meteorologia. I. Lyra, Gustavo Bastos ,
1975-, orient. II. Lima, Evaldo de Paiva , 1978-
coorient. III Universidade Federal Rural do Rio de
Janeiro. Pós-Graduação em Engenharia Agrícola e
Ambiental . IV. Título.

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

MARIANE DOS SANTOS PESSANHA

Dissertação submetida como requisito parcial para obtenção do grau de Mestra em Engenharia Agrícola e Ambiental, no Programa de Pós-graduação em Engenharia Agrícola e Ambiental, área de Concentração em Meio Ambiente.

DISSERTAÇÃO APROVADA EM 06/11/2020

Gustavo Bastos Lyra, D.Sc., DCA/IF/UFRRJ
(Orientador)

Marcel Carvalho Abreu, D.Sc., DCA/IF/UFRRJ

Ricardo Guimarães Andrade, D.Sc., EMBRAPA



Emitido em 06/11/2020

HOMOLOGAÇÃO DE DISSERTAÇÃO DE MESTRADO Nº 90/2020 - IT (12.28.01.27)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 27/07/2021 13:53)

GUSTAVO BASTOS LYRA
PROFESSOR DO MAGISTERIO SUPERIOR
DeptCAmb (12.28.01.00.00.00.00.29)
Matrícula: 1574025

(Assinado digitalmente em 27/07/2021 18:42)

MARCEL CARVALHO ABREU
PROFESSOR DO MAGISTERIO SUPERIOR
DeptCAmb (12.28.01.00.00.00.00.29)
Matrícula: 3040039

(Assinado digitalmente em 28/07/2021 11:34)

RICARDO GUIMARÃES ANDRADE
ASSINANTE EXTERNO
CPF: 027.659.606-40

Para verificar a autenticidade deste documento entre em <https://sipac.ufrj.br/documentos/> informando seu número: **90**, ano: **2020**, tipo: **HOMOLOGAÇÃO DE DISSERTAÇÃO DE MESTRADO**, data de emissão: **26/07/2021** e o código de verificação: **e0d1462d24**

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico
Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

DEDICATÓRIA

*A Deus.
Ao padrinho Tadeu (in memoriam), grande amigo e incentivador.*

Dedico.

AGRADECIMENTOS

A Deus por me guiar e iluminar em todos os momentos da vida.

Agradeço minha mãe Aline, e minha irmã, Sarah, por todo apoio durante minha trajetória acadêmica. Obrigada por me ensinar sobre amor e coragem.

Agradeço minha avó Ana, mulher de fé, por todas as orações e carinho.

Agradeço minha tia Arlinda, minha madrinha Flávia, meu tio Everton, minha prima Ana Célia e meu afilhado Hugo. Obrigada pelo apoio e por acreditarem nos meus sonhos.

Ao meu orientador, Gustavo Bastos Lyra, por toda confiança depositada quando solicitei a orientação. Grande incentivador e guia, obrigada por acreditar e me motivar nos momentos mais difíceis.

Ao meu coorientador, Evaldo de Paiva Lima, sempre disposto a ajudar e compartilhar conhecimentos.

Ao professor Marcel Carvalho Abreu, pelo apoio incondicional durante a construção do trabalho.

As amigas, Aolibama e Carina, por dividirem momentos em sala de aula, experiências e sorrisos.

As amigas do Colégio Agrícola, Ana e Juliana, por dividirem dificuldades e conquistas da vida.

Aos amigos do Laboratório de Modelagem Ambiental e Atmosférica, Danilo, Janaína, Fabiana, Suelen, Isabela e Wellerson, por toda ajuda nos trabalhos de campo e análise de dados. Vocês foram essenciais nessa caminhada. Obrigada por compartilharem emoções, além de experiências acadêmicas.

Aos amigos da Rural, Ana Marinho, Ana Carolina, Bruno, Gabriela, Halina, Jéssica, Letícia, Manuela, Marcondes, Mirelle, Rayna, Samir e Tuane por todos os momentos vividos. Carrego vocês no meu coração.

Aos amigos do IBGE toda minha gratidão. Obrigada especialmente a Wanessa, Rodrigo, Theo, Rafael, Andressa, Lizandra e Felipe pelo convívio mais próximo e por compartilharem experiências.

Aos professores participantes da banca examinadora, por aceitarem o convite para contribuir neste trabalho.

Ao Laboratório de Pesquisas e Estudos em Reflorestamentos (LAPER), coordenado pelo Prof. Paulo Sérgio dos Santos Leles, por ceder equipamentos para análises. Obrigada em especial para Juçara Garcia Ribeiro, sempre disponível para ajudar.

À Universidade Federal Rural do Rio de Janeiro, minha segunda casa, lugar de aprendizado. Obrigada por tudo, entre lágrimas e sorrisos, derrotas e conquistas, essas experiências foram essenciais para o meu crescimento.

Ao Programa de Pós Graduação em Engenharia Agrícola e Ambiental pela oportunidade de crescimento acadêmico.

À Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) pelo auxílio financeiro por meio do Edital FAPERJ Nº 22/2016 – Apoio Emergencial para os Programas e Cursos de Pós-graduação Stricto Sensu do Estado do Rio de Janeiro – 2016 concedido ao Programa de Pós Graduação em Engenharia Agrícola e Ambiental – UFRRJ.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Aos professores que passaram pela minha vida, obrigada por acreditarem no poder transformador da educação

A todos que de alguma forma e em algum momento cruzaram meu caminho e participaram dessa etapa.

RESUMO

PESSANHA, Mariane dos Santos. **Biometria e índices de vegetação por sensoriamento remoto em área de pastagem no município de Cachoeiras de Macacu, RJ.** 2020. 63p. Dissertação (Mestrado em Engenharia Agrícola e Ambiental). Instituto de Tecnologia, Departamento de Engenharia, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2020.

A produção agrícola e pecuária é influenciada por diferentes fatores climáticos e pela demanda internacional. Atualmente a pecuária tem importante papel na atividade econômica do País e, em decorrência dessa influência surge a necessidade de repensar as etapas de manejo a partir da aplicação de novas técnicas e ferramentas tecnológicas no gerenciamento dessas áreas. O presente trabalho apresenta uma avaliação das características biométricas e o processamento de imagens orbitais para obtenção dos índices de vegetação de uma área de pastagem comercial localizada no município de Cachoeiras de Macacu, RJ. Para a caracterização biométrica foram considerados métodos destrutivos e não-destrutivos em superfície, assim como o método baseado em imagens orbitais dos satélites Landsat-8 (L8) e Sentinel-2 (S2). Nas campanhas foi determinado o índice de área foliar (IAF), com a utilização de um ceptômetro e a altura para duas áreas, definidas como: i) externa (30 ha) com pastoreio de 160 animais a cada 15 dias, e ii) interna (25 m²), cercada dentro da área externa e sem pastoreio. No método destrutivo adotado em três campanhas, a vegetação da área externa foi coletada ao nível do solo e levada para laboratório. As imagens orbitais foram selecionadas, considerando a menor interferência de nuvens, pré-processadas e manipuladas algebricamente com ferramentas de geoprocessamento. As variáveis meteorológicas para caracterização das condições ambientais do local foram obtidas por uma estação micrometeorológica instalada na área e a precipitação foi medida por uma estação meteorológica localizada próxima da área de estudo. O IAF apresentou média de 2,10 m².m⁻², com valor mínimo de 0,68 m².m⁻², e valor máximo de 5,00 m².m⁻², enquanto na área interna a média foi de 2,72 m².m⁻², com mínimo de 1,31 m².m⁻²; e máximo de 5,31 m².m⁻². A altura da vegetação na área externa apresentou média de 29,19 cm, com valor máximo de 75 cm e mínimo de 8 cm, para a área interna foi encontrada média de 48,41 cm, com valor máximo de 90 cm e mínimo de 12 cm. Para imagens do Landsat-8, o NDVI (*Normalized Difference Vegetation Index*) variou entre 0,61 e 0,83; SAVI (*Soil-Adjusted Vegetation Index*) entre 0,32 e 0,68; e IAF com valores entre 0,52 e 4,56, para Sentinel-2 a variação do NDVI foi entre 0,58 e 0,79, SAVI entre 0,29 e 0,61 e IAF entre 0,42 a 2,17. Os valores de IAF estimado pelo índice SAVI com o IAF observado (ceptômetro) apresentou precisão, com coeficiente de concordância de Willmott (d) de 0,87 (Sentinel-2) e 0,86 (Landsat-8) para L=0,25. O estudo demonstrou que os resultados apresentam comportamento sazonal, que indicou períodos com maior disponibilidade de água e energia solar no ambiente favorecem o crescimento da vegetação. O monitoramento se torna importante ferramenta para auxiliar no conhecimento da dinâmica sazonal e, fornece informações para projetos e manejo de áreas de pastagem.

Palavras-chave: geoprocessamento, imagens orbitais, dinâmica sazonal

ABSTRACT

PESSANHA, Mariane dos Santos. **Biometry and vegetation indexes by remote sensing in a pasture area in the municipality of Cachoeiras de Macacu, RJ** 2020. 63p Dissertation (Master Agricultural and Environmental Engineering). Institute of Technology, Engineering Department, Federal Rural University of Rio de Janeiro, Seropédica, RJ, 2020.

Agricultural and livestock production is influenced by different climatic factors and international demand. Livestock currently plays an important role in the country's economic activity and, as a result of this influence, there is a need to rethink the management stages based on the application of new techniques and technological tools in the management of these areas. The present work presents an evaluation of the biometric characteristics and the processing of orbital images to obtain the vegetation indices of a commercial pasture area located in the municipality of Cachoeiras de Macacu, RJ. For the biometric characterization, destructive and non-destructive methods on the surface were considered, as well as the method based on orbital images from the Landsat-8 (L8) and Sentinel-2 (S2) satellites. The leaf area index (LAI) was determined in the campaigns, using a ceptometer and the height for two areas, defined as: i) outdoor (30 ha) with 160 animals grazing every 15 days, and ii) indoor (25 m²), fenced inside the outdoor area and without grazing. In the destructive method adopted in three campaigns, the vegetation in the external area was collected at ground level and taken to the laboratory. The orbital images were selected, considering the lowest cloud interference, pre-processed and algebraically manipulated with geoprocessing tools. The meteorological variables for characterization of the environmental conditions of the place were obtained by a micrometeorological station installed in the area and the precipitation was measured by a meteorological station located close to the study area. The IAF presented an average of 2.10 m².m⁻², with a minimum value of 0.68 m².m⁻², and a maximum value of 5.00 m².m⁻², while in the internal area the average was 2.72 m².m⁻², with a minimum of 1.31 m².m⁻²; and a maximum of 5.31 m².m⁻². The height of the vegetation in the external area averaged 29.19 cm, with a maximum value of 75 cm and a minimum of 8 cm, for the internal area it was found an average of 48.41 cm, with a maximum value of 90 cm and a minimum of 12 cm. For Landsat-8 images, the NDVI (Normalized Difference Vegetation Index) ranged between 0.61 and 0.83; SAVI (Soil-Adjusted Vegetation Index) between 0.32 and 0.68; and IAF with values between 0.52 and 4.56, for Sentinel-2 the NDVI variation was between 0.58 and 0.79, SAVI between 0.29 and 0.61 and IAF between 0.42 and 2.17. The IAF values estimated by the SAVI index with the observed IAF (ceptometer) showed accuracy, with a Willmott coefficient of agreement (d) of 0.87 (Sentinel-2) and 0.86 (Landsat-8) for L=0.25. The study showed that the results show seasonal behavior, which indicated periods with greater availability of water and solar energy in the environment favor the growth of vegetation. Monitoring becomes an important tool to help understand seasonal dynamics and provide information for projects and management of pasture areas.

Key words: geoprocessing, orbital images, seasonal dynamics

SUMÁRIO

DEDICATÓRIA	i
AGRADECIMENTOS	ii
RESUMO.....	iv
ABSTRACT	v
LISTA DE FIGURAS.....	xi
LISTA DE TABELAS	xiii
LISTA DE SIGLAS E ABREVIATURAS	xiv
1. INTRODUÇÃO	15
2. OBJETIVOS.....	17
2.1. Geral	17
2.2. Específicos	17
3. REVISÃO DE LITERATURA	18
3.1. Pastagem	18
3.2. Sensoriamento Remoto	19
3.2.1. Sensores	19
3.2.2. Características dos sensores	20
3.2.3. Missão Landsat.....	23
3.2.4. Missão Sentinel.....	23
3.3. Índices de Vegetação	25
4. MATERIAL E MÉTODOS.....	28
4.1. Caracterização da Área de Estudo	28
4.2. Dados meteorológicos e micrometeorológicos	31
4.3. Biometria.....	32
4.3.1. Ceptômetro	32
4.3.2. Método destrutivo	35

4.3.3. Sensoriamento Remoto	37
4.3.4. Análise estatística	41
5. RESULTADOS E DISCUSSÃO	43
5.1. Condições meteorológicas.....	43
5.2. Biometria.....	48
5.3. Sensoriamento Remoto	50
5.3.1. Índices de vegetação	50
5.3.2. Índice de Área Foliar	52
6. CONCLUSÕES	54
7. REFERÊNCIAS BIBLIOGRÁFICAS	55

LISTA DE FIGURAS

Figura 1. Descrição da trajetória da radiação eletromagnética e seu componentes radiométricos.....	20
Figura 2. Imagem digital (a) com área em zoom de grupo de pixels em valores de cinza (b) e correspondentes valores digitais (c).....	21
Figura 3. Da esquerda para a direita, imagens dos satélites, Landsat com resolução espacial de 30m, Spot com 10 m e Ikonos com 1 m, de uma porção do lago Paranoá de Brasília.....	22
Figura 4. Fluxograma metodológico.....	28
Figura 5. Localização geográfica da área experimental.....	29
Figura 6. Coleta de amostras indeformadas de solo na área experimental para realização das análises físico-hídricas do solo.....	29
Figura 7. Estação micrometeorológica com a localização dos instrumentos.....	31
Figura 8. Coleta de altura da vegetação, DFFF e estimativas do IAF na área experimental.....	33
Figura 9. Caracterização da área experimental.....	34
Figura 10. Área experimental com presença de animais de raça predominantemente nelore (<i>Bos taurus indicus</i>).....	35
Figura 11. Esquema da coleta com ceptômetro da amostra pelo método destrutivo.....	35
Figura 12. Subamostras coletas em 10/12/2019. A: Folha verde; B: Caule; C:Parte seca.....	36
Figura 13. Variação temporal da temperatura do ar.....	45
Figura 14. Variação temporal da umidade relativa do ar.....	45
Figura 15. Variação temporal da radiação solar no topo da atmosfera (R_n) e radiação solar global (R_g).....	46
Figura 16. Variação temporal da Transmissividade.....	46
Figura 17. Variação temporal da Precipitação e Evapotranspiração (ETo).....	47
Figura 18. Variação temporal da umidade do solo (m^3/m^3) para 10 e 30 cm de profundidade e valor médio.....	47
Figura 19. Variação dos dados de altura (cm) da área externa para as campanhas avaliadas no estudo (a); Variação dos dados de altura (cm) da área interna para as campanhas avaliadas no estudo (b).....	48
Figura 20. Correlação da variável IAF (Folha verde) e IAF (Destrutivo).....	49

Figura 21. Variação dos dados da variável IAF corrigido (m^2m^{-2}) para: (a) área externa e
(b) área interna para as campanhas. 50

LISTA DE TABELAS

Tabela 1. Resolução temporal dos satélites Landsat-8 e Sentinel-2A/B..	22
Tabela 2. Características espectrais e espaciais do sensor MSI/Sentinel-2A.	24
Tabela 3. Características espectrais e espaciais do sensor MSI/Sentinel-2B	25
Tabela 4. Análise granulométrica.	30
Tabela 5. Análise química.	30
Tabela 6. Análise química.	30
Tabela 7. Descrição dos instrumentos da estação micrometeorológica.	32
Tabela 8. Descrição da campanha	34
Tabela 9. Imagens OLI/Landsat-8 e MSI/Sentinel-2 livres de nuvens na área de estudo.	38
Tabela 10. Características temporal e espectral do Landsat-8 OLI e Sentinel-2 MSI.....	38
Tabela 11. Características espaciais e espectrais do Landsat-8 OLI e Sentinel-2 MSI..	39
Tabela 12. Data da passagem do satélite associada com a campanha de campo.	41
Tabela 13. Temperatura do ar média, média das máximas e das mínimas.....	44
Tabela 14. Total mensal da precipitação, número de dias com chuva e frequência.....	44
Tabela 15. Variação temporal dos Índices de Vegetação do satélite Landsat-8.....	51
Tabela 16. Variação temporal dos Índices de Vegetação do satélite Sentinel-2A/B.	52
Tabela 17. Coeficiente de determinação (r^2), Índice de concordância de Willmott (d) e Raiz do Quadrado Médio do Erro (RQME)..	55

LISTA DE SIGLAS E ABREVIATURAS

ESA	<i>European Space Agency</i>
GEE's	Gases de Efeito Estufa
GMES	<i>Global Monitoring for Environment and Security</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
NASA	<i>National Aeronautic and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
OLI	<i>Operational Land Imager</i>
REM	Radiação eletromagnética
SAVI	<i>Soil-Adjusted Vegetation Index</i>
USGS	<i>United State Geological Survey</i>

1. INTRODUÇÃO

A produção agrícola e pecuária da América Latina e Caribe se desenvolve cada vez mais influenciada por fatores climáticos e pela demanda internacional por alimentos, energia e biocombustíveis. A Organização das Nações Unidas para a Alimentação e a Agricultura (FAO - *Food and Agriculture Organization of the United Nations*) projeta que a pecuária seja a única fonte de subsistência para, pelo menos, 20 milhões de famílias e, que se apresente como a principal fonte de renda para cerca de 200 milhões de famílias de pequenos produtores na Ásia, África e América Latina (FAO, 2019).

As pastagens representam a mais importante fonte de alimento para produção animal do planeta (BELLA et al., 2004; FAO, 2003). Na pecuária apenas 3% dos rebanhos são caracterizados por sistemas intensivos e altamente produtivos, sendo menos de 40% de pastejo em áreas que suportam taxas de lotação superiores a 0,5 unidade animal por hectare (CEZAR et al., 2005; ESCADA et al., 2005; MERRY e SOARES-FILHO, 2017). O Brasil possui extensas áreas de pastagem, e a pecuária apresenta importante papel na atividade econômica do País. De acordo com os dados do Censo Agropecuário 2017, realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), a atividade econômica pecuária predominou em 47% dos estabelecimentos que declararam valor de produção e estes representam 34% do valor total da produção da agropecuária. O País possui 159,5 milhões de hectares de áreas de pastagem e rebanho bovino de 172,7 milhões de cabeças (IBGE, 2019).

Segundo o Painel Intergovernamental sobre Mudanças Climáticas (PIMC), a pecuária é responsável por cerca de 40% das emissões de Gases de Efeito Estufa (GEE's) provenientes da agricultura (FAO, 2019). A expansão da pecuária está vinculada aos fatores econômicos, ambientais, legais e sociais e, esses influenciam em que medida e com que velocidade a intensificação da atividade ocorre, visto que a avaliação e a definição de estratégias são cruciais para a conservação de florestas e redução de emissões (LATAWIEC et al., 2014).

A produtividade e a qualidade das pastagens estão diretamente relacionadas ao processo de gestão e às condições climáticas locais. As informações de monitoramento de pastagens, previsão de taxas de crescimento e indicadores de qualidade auxiliam no manejo eficiente das pastagens e, assim, permitem evitar o excesso de pastoreio (PULLANAGARI et al., 2011). Propor indicadores de qualidade das pastagens, quando ponderados pelos fatores associados às características do local, permite ao analista tomar decisões quanto ao manejo da pastagem, identificação da necessidade de reforma e, ou renovação/recuperação da pastagem, e propor estratégias de pastejo, tais como, taxa de lotação e tempo de pastejo (OLIVEIRA, 2005).

O uso de informações espectrais por meio de técnicas e ferramentas de sensoriamento remoto na pecuária torna-se uma alternativa interessante diante dos fatores limitantes, visto que viabiliza a detecção de alterações na vegetação (RIZZI, 2004). Propor métodos para avaliar as pastagens tropicais no Brasil e repensar a pecuária envolve formas de gerenciamento de sistemas de produção animal a pasto, tendo em vista a análise da intensidade de pastejo adequada às necessidades dos animais em distintas épocas do ano (LACA, 2008). As técnicas de sensoriamento remoto, quando aplicadas ao estudo da vegetação são fundamentais, visto que, inúmeras informações podem ser extraídas a partir da análise de bandas espectrais (BATISTELLA et al., 2011). Destaca-se a viabilidade da aplicação dessas técnicas para identificar, quantificar e monitorar a produtividade das pastagens (BOLFE et al., 2011). O monitoramento automático do crescimento da pastagem por meio de imagens orbitais, que conciliam precisão adequada e resolução espaço-temporal, permite uma série de possibilidades para um gerenciamento mais eficiente das pastagens e uma agricultura mais lucrativa.

A facilidade na aplicação de processos computacionais faz com que métodos baseados em índices de vegetação (IVs) sejam aplicados na análise e determinação de variáveis biofísicas da vegetação. A utilização de imagens orbitais tem sido considerada uma das principais fontes para monitoramento da vegetação e apresenta vantagens quando comparada com campanhas de campo para mapeamento de cultura (VALENCIA, 2020). O estudo apresentado por Valencia (2020) indicou que índices de vegetação obtidos após o processamento das imagens Landsat-8 (LC8) e Sentinel-2 (S2) permitem identificar a sazonalidade do pastejo. Nos trabalhos de Frampton et al. (2013), Martinez (2017) e Escolà et al. (2017) são apresentados a utilização de imagens S2 para estimativa de variáveis biofísicas da vegetação por meio dos cálculos de diferentes índices de vegetação.

2. OBJETIVOS

2.1. Geral

Avaliar a aplicação de índices de vegetação obtidos por sensoriamento remoto e medidas *in situ*, a fim de caracterizar e quantificar a variabilidade espaço-temporal da altura e índice de área foliar de uma pastagem no município de Cachoeiras de Macacu, RJ.

2.2. Específicos

- Analisar a variabilidade sazonal da biometria (índice de área foliar e altura);
- Avaliar a variabilidade dos índices de vegetação (NDVI, SAVI) com base em produtos Landsat-8 e Sentinel-2;
- Validar os diferentes valores de L para SAVI obtidos de imagens Landsat-8 e Sentinel-2 para estimar o índice de área foliar.

3. REVISÃO DE LITERATURA

3.1. Pastagem

As pastagens no Brasil são formadas por gramíneas forrageiras que, em sua maioria, pertencem aos gêneros *Brachiaria*, *Panicum* e *Andropogon* (RIBEIRO et al., 2016). Em áreas de pastagem plantada se destacam no País a *Brachiaria decumbens* e a *Brachiaria brizantha* (RODRIGUES, 2010). As braquiárias se apresentam como uma das principais fontes de nutrientes aos animais (SILVA e FERRARI, 2012) e este tipo de forrageira se disseminou no Brasil, dentre outros motivos, devido à boa produção de forragem e à germinação de sementes (RIBEIRO et al., 2016). De acordo com Crispim e Branco (2002), *Brachiaria brizantha* e *Brachiaria decumbens* apresentam ciclo perene e se desenvolvem de maneiras distintas. A *Brachiaria brizantha* caracterizada por crescimento na forma de touceira, apresenta grande porte e necessita de solo que tenha fertilidade de média a alta, sendo durante a estação das chuvas a melhor época de plantio, entretanto, é pouco resistente a áreas úmidas. No percentual de matéria seca apresenta 10% de proteína bruta. A *Brachiaria decumbens*, cresce na forma decumbente. A estação chuvosa é a melhor época para plantio e também possui baixa resistência a áreas úmidas. Exige solo de fertilidade baixa a média e possui de 7 a 9% de proteína bruta na matéria seca.

No Censo Agropecuário de 2017, as pastagens foram classificadas em três categorias: Pastagem natural, Pastagem plantada em boas condições de uso e Pastagem plantada em más condições de uso. A utilização da terra para pastagem é representada por 63% de pastagem plantada em boas condições de uso, 30% por pastagem natural e 7% por pastagem plantada em más condições de uso (IBGE, 2019).

Segundo Dias-Filho (2005), a degradação de pastagens é identificada em todas as regiões do Brasil, contribuindo para que o uso efetivo das áreas de pastagens no País esteja abaixo da real capacidade de produção. Essa situação se justifica pela ausência da aplicação de insumos e tecnologia no manejo destas áreas, um cenário característico em diferentes áreas de pastagens no Brasil. Um indicativo do processo de degradação agrícola é a presença de plantas invasoras, comum em regiões onde o período seco não é tão rigoroso (DIAS-FILHO, 2011). De acordo com Neto et al. (2006), existe a perda de um quilo de pastagem para cada quilo de matéria verde de planta invasora produzida. Esses autores destacam as diferentes vantagens competitivas que as plantas invasoras levam em relação às pastagens, tais como, a germinação não uniforme, rápido crescimento, facilidade de adaptação às mais diversas condições de clima e solo e a elevada capacidade de reprodução vegetativa.

3.2. Sensoriamento Remoto

O Sensoriamento Remoto (SR) é a tecnologia que possibilita a aquisição e medição de informações de alguma propriedade do objeto ou fenômeno por um dispositivo de registro sem que haja o contato físico entre eles (NOVO, 2008). Isso acontece a partir da detecção e registro da energia eletromagnética emitida e, ou refletida pelo alvo. O SR refere-se à utilização de um conjunto de sensores e equipamentos para aquisição, processamento e análise da energia eletromagnética refletida ou emitida pelos alvos (JANSSEN, 2001).

As vantagens do uso de satélites e imagens de plataformas aéreas foram descobertas desde os primeiros estudos usando esses dados no começo da década de 1970. As diferentes aplicações dos sensores remotos estão relacionadas com os tipos de plataformas usadas pelo sensor na aquisição de dados. As plataformas servem como suporte para o transporte do sensor e são classificadas como terrestres, aéreas ou espaciais. Cada uma das plataformas apresenta vantagens e desvantagens em determinada área, sendo as resoluções espaciais (tamanho do pixel imageado), espectrais (faixas do espectro cobertas) e temporais (tempo de revisita do sensor), conforme DI MAIO (2018).

3.2.1. Sensores

Os sensores podem ser ativos ou passivos, tendo como princípio básico a transferência de dados do objeto para o sensor por meio da medida da radiação eletromagnética (REM). Quando a REM incide sobre a superfície de um material, parte dela será refletida por esta superfície, parte será absorvida e parte pode ser transmitida, caso a matéria possua alguma transparência, e isso se justifica pelo princípio da conservação da energia (Figura 1). A energia incidente, em intensidade, é sempre igual a soma da reflectância, absorvância e transparência (NOVO, 2008). As informações podem ser coletadas por sensores instalados a bordo de satélites, o que caracteriza o sensoriamento remoto orbital que, por meio deste procedimento, gera imagens com base na resposta espectral dos materiais que recobrem a região imageada (LILLESAND e KIEFER, 1993).




Figura 1: Descrição da trajetória da radiação eletromagnética e seus componentes radiométricos. Fonte: Meneses e Almeida (2012).

3.2.2. Características dos sensores

Os sensores registram as intensidades do espectro eletromagnético e com essas medidas pode-se obter imagens nas regiões do visível e no intervalo do infravermelho. Essa intensidade de cada intervalo de radiação eletromagnética refletida é determinada pelo comprimento de onda e sua frequência. As imagens de sensoriamento remoto apresentam uma estrutura constituída por um arranjo de elementos sob a forma de matriz (Figura 2), de dimensão vertical “y” (colunas) e horizontal “x” (linhas), com cada elemento possuindo um atributo z (nível de cinza). A célula da matriz (“x”, “y” e z) é denominada pixel, derivado do inglês *picture element*. O nível de cinza de um pixel, (ou DN, de *digital number*) corresponde sempre a média da intensidade da energia refletida ou emitida pelos diferentes materiais presentes nesse pixel (MENESES e ALMEIDA, 2012). As imagens coletadas por sensores remotos possuem características necessárias para a compreensão dos fundamentos do processamento digital, e isso as difere de outras imagens digitais, sendo elas: a estrutura e a resolução (NOVO, 2008). O sistema de SR apresenta quatro resoluções: espacial, radiométrica, temporal e espectral, e essas permitem diferenciar os produtos ou imagens geradas pelos diferentes sensores a bordo de satélites.




Figura 2: Imagem digital (a) com área em *zoom* de grupo de pixels em valores de cinza (b) e correspondentes valores digitais (c). Fonte: Meneses e Almeida (2012).

A resolução espacial está relacionada ao tamanho do pixel e é um importante parâmetro do sensor por determinar o tamanho do menor objeto que pode ser identificado em uma imagem, sendo expressa em metros (resolução terrestre) ou em radianos (resolução do sensor), conforme Meneses e Almeida (2012). Cada sistema sensor apresenta uma capacidade de definição do tamanho do pixel (Figura 3), que representa a menor parcela imageada. Portanto, quando um sistema possui uma resolução de 10 metros, significa que objetos distanciados entre si menos que 10 metros, em geral, não serão distinguidos pelo sistema. Assim, quanto menor a dimensão do pixel, maior é a resolução espacial da imagem, ou seja, maior o seu poder de distinguir objetos mais próximos.

A sensibilidade do sistema em detectar níveis de intensidade de radiação é medida pela resolução radiométrica, sendo a capacidade de um determinado sensor em distinguir diferentes níveis de intensidade do sinal de retorno. De forma que, quanto maior a resolução radiométrica maior será a quantidade de níveis de brilho que o sensor poderá distinguir (MENESES e ALMEIDA, 2012).



Figura 3. Da esquerda para a direita, imagens dos satélites, Landsat com resolução espacial de 30m, Spot com 10 m e Ikonos com 1 m, de uma porção do lago Paranoá em Brasília, DF. Fonte: Meneses e Almeida (2012).

A resolução espectral se refere ao número ou largura das bandas espectrais que o sensor apresenta e, uma maior resolução espectral está associada ao maior número de bandas e estreita largura de faixas de imageamento (CHUVIECO e SALAS, 1996). A resolução temporal (Tabela 1) é o intervalo de tempo que o satélite volta a visitar uma mesma área, sendo essa periodicidade relacionada às características orbitais do satélite como altura, velocidade e inclinação e o ângulo total de abertura do sensor.

Tabela 1: Resolução temporal dos satélites Landsat-8 e Sentinel-2A/B.

Plataforma Satélite	Resolução temporal (dias)
Landsat-8	16
Sentinel-2A/B	5

Fonte: Adaptado de Valencia (2020).

A coleta sistemática de imagens pelos sensores remotos permite a observação de fenômenos terrestres e comportamento de alvos a partir de séries temporais de dados (HUETE et al., 2012). O monitoramento e detecção de evoluções temporal e espacial da superfície terrestre por meio do uso de sensoriamento remoto consiste em interpretar a resposta espectral de cada objeto e no reconhecimento de padrões (LIU, 2006).

3.2.3. Missão Landsat

A missão Landsat é um marco no uso de satélites destinados a estudos dos recursos naturais no nosso planeta, tendo como objetivo principal a aquisição de dados espaciais e temporais da superfície da terra, de forma global, contínua e repetitiva (FEITOSA, 2005). O programa Landsat, sob responsabilidade da NASA (*National Aeronautic and Space Administration*), é composto de uma série de oito satélites, mas atualmente só possui um em operação (Landsat 8).

O satélite mais recente da missão, Landsat 8, foi lançado no dia 11 de fevereiro de 2013 pela NASA na base aérea de Vandenberg no estado da Califórnia (EUA), operando a uma altitude de 705 km, numa órbita heliosíncrona com inclinação de 98,2° (ligeiramente retrógrada), semelhante às órbitas das séries Landsat 5 e 7. A sua passagem na linha do equador ocorre às 10:00 horas, com diferença de 15 minutos para mais ou para menos (EUA, 2013).

Com cobertura praticamente total do globo terrestre, com exceção para latitudes polares, possui uma resolução temporal de 16 dias e cenas de aproximadamente 170 x 183 km. O sistema de mapeamento do Landsat-8 dispõe de dois instrumentos de observação terrestre: *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS). O primeiro fornece nove bandas espectrais, e o segundo, duas bandas de pixel de 100 metros, processadas e disponibilizadas em versões de 30 metros, coincidindo com as outras bandas do satélite Landsat-8 (EUA, 2013).

3.2.4. Missão Sentinel

A missão Sentinel, iniciada em 2014, foi desenvolvida pela *European Space Agency* (ESA) em conjunto com a *Global Monitoring for Environment and Security* (GMES), é composta atualmente por seis sub-missões, cada uma com objetivos diferentes de monitoramento. Entre elas destacam-se as seguintes: Sentinel-1, com o monitoramento da superfície terrestre e oceânica; Sentinel-2, com o monitoramento da vegetação, do solo e da costa; Sentinel-3, com a captura da topografia oceânica, o monitoramento dos oceanos, medições da temperatura na superfície, detecção da cor dos Oceanos e da Terra; Sentinel-4, com o monitoramento da composição atmosférica; Sentinel-5, com o monitoramento da qualidade do ar; Sentinel-5P, com o monitoramento e medição de componentes atmosféricas em maior resolução espacial auxiliando assim a Sentinel-5. O GMES é uma iniciativa conjunta da União Europeia (UE) e da ESA cujo objetivo é prover dados precisos e acessíveis de satélite para gerenciamento ambiental, identificação e mitigação dos efeitos das mudanças climáticas.

A missão Sentinel-2 (Tabela 2) é constituída de 2 satélites (A e B), com órbita sol-síncrona e altitude média de 800 km e que, juntos, têm a capacidade de revisita de 5 dias no equador, e de 2 a 3 dias nas latitudes médias (EUROPEAN SPACE AGENCY, 2012). Para obter uma menor cobertura de nuvens, garantir uma boa iluminação solar e uma similaridade com os dados da série Landsat e SPOT, os satélites da missão Sentinel-2 cruzam o equador às 10:30 a.m. do horário local (DRUSCH et al., 2012).

Ambos os satélites da missão Sentinel-2 (2A e 2B) contam com o sensor Multi Spectral Instrument (MSI) com 13 bandas espectrais, de elevada qualidade geométrica e radiométrica, voltadas para o monitoramento terrestre (DRUSCH et al., 2012), cujas características são apresentadas nas Tabelas 2 e 3.

Tabela 2: Características espectrais e espaciais do sensor MSI/Sentinel-2A

Banda	Centro da banda (nm)	Largura (nm)	Resolução (m)
1	443,9	27	60
2	496,6	98	10
3	560,0	45	10
4	664,5	38	10
5	703,9	19	20
6	740,2	18	20
7	782,5	28	20
8A	864,8	33	20
8	835,1	145	10
9	945,0	26	60
10	1373,5	75	60
11	1613,7	143	20
12	2202,4	242	20

Fonte: DRUSCH et al. (2012).

Tabela 3: Características espectrais e espaciais do sensor MSI/Sentinel-2B

Banda	Centro da banda nm	Largura nm	Resolução m
1	442,3	45	60
2	492,1	98	10
3	559,0	46	10
4	665,0	39	10
5	703,8	20	20
6	739,1	18	20
7	779,7	28	20
8A	864,0	32	20
8	833,0	133	10
9	943,2	27	60
10	1376,9	76	60
11	1610,4	141	20
12	2185,7	238	20

Fonte: DRUSCH et al. (2012).

As bandas do Sentinel-2 cobrem as regiões espectrais do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). As bandas com resolução espacial de 10 metros (2, 3, 4 e 8), foram definidas para manter a compatibilidade com os produtos SPOT, enquanto que as bandas de 20 metros de resolução espacial foram concebidas para observar principalmente as características da vegetação (borda vermelha da vegetação e a banda de absorção da lignina). As bandas de resolução espacial de 60 metros são destinadas para correção atmosférica (EUROPEAN SPACE AGENCY, 2012).

3.3. Índices de Vegetação

Nas aplicações de sensoriamento remoto, diferentes pesquisadores desenvolveram os índices de vegetação para monitorar e quantificar as condições e distribuições espaciais de diferentes tipos de vegetação.

Os dados espectrais oriundos de satélites ópticos servem como base para o cálculo de índices de vegetação para biomas de pastagens com uso de imagens que apresentam resolução espacial maior que 100 metros (ATZBERGER et al., 2015; DARVISHZADEH et al., 2011; DARVISHZADEH et al., 2008; PASOLLI et al., 2015) e com imagens (10-100m) (DUSSEUX et al., 2014; FRIEDL et al., 1994; LI et al., 2016; WYLIE et al., 2002). O monitoramento da dinâmica por imagens ópticas é geralmente dificultado pela contaminação por nuvens e alta cobertura de vegetação durante as estações de cultivo (DUSSEUX et al., 2014; ZHANG et al., 2018).

Segundo Jensen (2011), desde 1960 diversos parâmetros biofísicos da vegetação são estudados, modelados e aplicados por meio do uso de diferentes técnicas de sensoriamento remoto como os índices de vegetação. Os padrões não são diretamente visualizados por meio do processo de imageamento, mas sim de forma indireta por meio da manipulação das medidas dos diferentes níveis de reflectância dentro dos comprimentos de ondas eletromagnéticas das faixas espectrais e permite distinguir a vegetação com base no seu registro fotossintético, por meio de técnicas aplicadas aos produtos dos sensores multiespectrais e hiperespectrais, e assim expressar a composição, abundância e distribuição da vegetação no meio físico (CAMPBELL e WYNNE, 2011; SANTANA e GALVÍNIO, 2013).

Os índices espectrais associados ao estudo da vegetação são importantes instrumentos, pois permite a separação dos alvos, o monitoramento das condições e saúde das plantas, auxiliando como ferramenta para análise, identificação de composição, padrão de cobertura e limitações biofísicas (JENSEN, 2011). O comportamento antagônico da vegetação nas regiões do vermelho e do infravermelho próximo está relacionado à forte absorção pelos pigmentos foliares e ao espalhamento múltiplo da radiação nas diferentes camadas de folhas (PONZONI e SHIMABUKURO, 2009; FORMAGGIO e SANCHES, 2017).

Para Campbell e Wynne (2011), os índices de vegetação calculados com base em valores digitais de brilho, proporcionam a medição da biomassa ou do vigor vegetativo. Os cálculos desses índices são elaborados a partir de combinações de vários valores espectrais que somados, divididos ou multiplicados tornam-se um valor único, indicando a quantidade ou o vigor vegetativo para determinado *pixel*.

Os índices de vegetação podem ser obtidos tanto de dados coletados por satélites como por equipamentos próximos e, foram determinados a partir da necessidade de ressaltar o comportamento espectral da vegetação em relação ao solo e a outros alvos da superfície terrestre. O *Normalized Difference Vegetation Index* (NDVI) foi desenvolvido por Rouse et al. (1974) com o objetivo de mensurar quantitativamente as características da vegetação. Jensen (2011), destaca a vantagem do índice NDVI por permitir o monitoramento de variações sazonais e anuais no desenvolvimento das atividades da vegetação, promover a redução de ruídos presentes em múltiplas bandas de imagens de diferentes datas de aquisição, oriundos de atenuação atmosférica, presença de sombreamento de nuvens, variações na iluminação solar e topografia. Diferentes estudos baseados no uso de dados NDVI de Sensoriamento Remoto relacionam os valores desse índice de vegetação e a degradação de pastagens (TURMA et al., 2014; WANG et al., 2016; WIESMAIR et al., 2016).

Huete (1988) identifica problemas quanto ao uso do NDVI como a saturação em alvos com elevado índice de área foliar e com a ocorrência de *background* do solo e umidade, tornando limitada a amplitude da análise em áreas com dosséis vegetais densos e regiões com solo muito exposto, sendo assim, propõe o índice SAVI (*Soil-Adjusted Vegetation Index*) para diminuir a influência da resposta espectral do solo. O índice de área foliar (IAF) proposto por Allen et al. (2002) pode ser definido pela razão entre a área foliar do dossel por unidade de área projetada no solo ($m^2 m^{-2}$), é um componente determinante do microclima, tanto abaixo do dossel quanto acima e pode ser obtido por diversos métodos (GOWER et al., 1999), tanto por medidas diretas (fotografia hemisférica), como por estimativas (sensoriamento remoto), neste, indicando a biomassa de cada pixel da imagem (ALLEN et al., 2002).

4. MATERIAL E MÉTODOS

A metodologia envolveu duas etapas, uma realizada com dados coletados em campo e a outra executada com processamento de imagens orbitais. As campanhas em campo coletaram informações sobre altura e índice de para o processamento das imagens orbitais. Os procedimentos metodológicos deste trabalho encontram-se no fluxograma (Figura 4). A primeira etapa constituiu a seleção, processamento e análise das imagens orbitais, enquanto na segunda foram coletadas amostras em campo pelo método não-destrutivo e destrutivo, scanneamento e análise estatística.

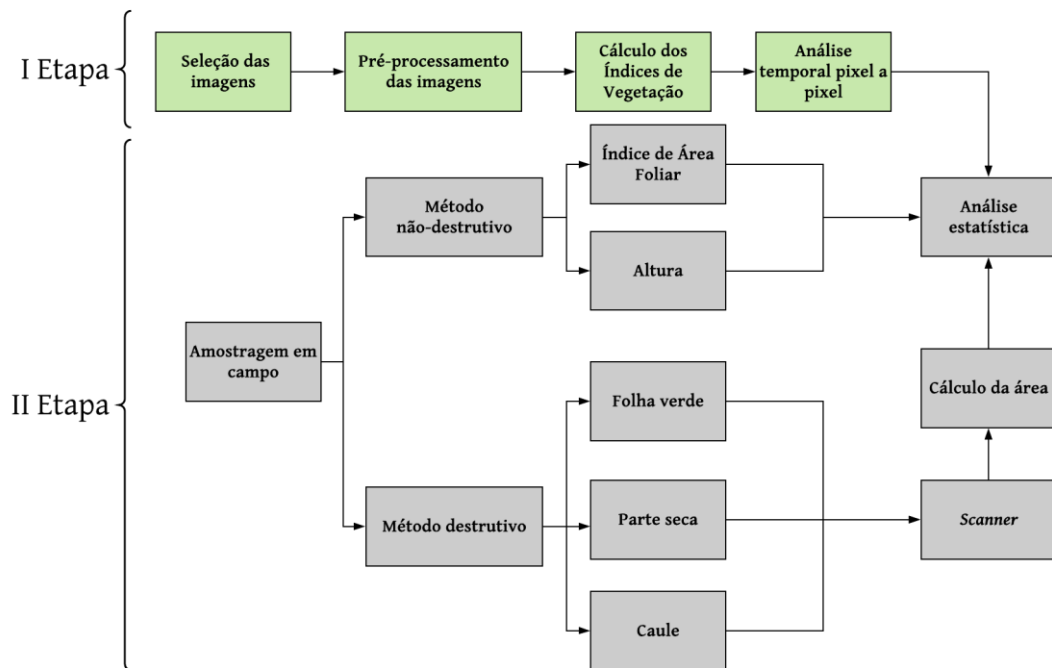


Figura 4: Fluxograma metodológico. Fonte: O autor (2020).

4.1. Caracterização da Área de Estudo

O estudo foi realizado em uma área de pastagem (22° 27' 49" S; 42° 45' 56" W, 21 m) localizada no município de Cachoeiras de Macacu (Figura 5) e inserida na Bacia da Baía de Guanabara e Sub-Bacia do Guapimirim-Macacu, no estado do Rio de Janeiro. O clima da região, segundo a classificação de Köppen (1948) é Aw – megatérmico tropical úmido, com estação seca no inverno (ALVARES et al., 2013).

O solo da área foi classificado como Gleissolo Melânico Tb Distrófico típico, vegetação com predominância de *Brachiaria* (*Urochloa decumbens* e *Urochloa purpurascens*) e área de 30 hectares, que é ocupada a cada 15 dias, em média, por 160 animais de raça predominantemente nelore (*Bos taurus indicus*).




Figura 5: Localização geográfica da área experimental. Fonte: O autor (2020).

Foram identificadas diferentes espécies de vegetação na área experimental, entre elas: *Urena Lobata* L., *Solanum lycocarpum* A.St.-Hil., *Hydrocotyle leucocephala* Cham. & Schldtl., *Sida* sp., *Emilia fosbergii* Nilcoson., *Asclepias curassavica* L., com predominância de *Urochloa Purpurascens* e *Urochloa decumbens*.

As coletas das amostras de solo foram realizadas em três pontos ao acaso ao redor da estação micrometeorológica. Em cada ponto, três amostras indeformadas a profundidades diferentes – 10, 30 e 60 cm foram coletadas (Figura 6), e enviadas para análise no Laboratório de Solos e Qualidade de Água, na Escola Superior de Agricultura “Luiz de Queiroz” – ESALQ, Universidade de São Paulo - USP.



Figura 6: Coleta de amostras indeformadas de solo na área experimental para realização das análises físico-hídricas do solo. Fonte: Martins (2019).

Na caracterização do solo foram analisadas as propriedades de granulometria (Tabela 4) e química (Tabelas 5 e 6) por horizonte.

Tabela 4: Análise granulométrica

Horizonte	Argila	Silte (dag/kg)	Areia	Classe textural
A	26	37	37	Franco
Bg	17	31	52	Franco-arenosa
B/C	27	28	45	Franco
Cg	8	19	73	Areia-franca

Fonte: O autor (2020).

Tabela 5: Análise química

Horizonte	pH H ₂ O	P	K (mg/dm ³)	Na	Ca ²⁺	Mg ²⁺	Al ³⁺ (cmol _c /dm ³)	H+Al
A	5,2	32,8	160	15	1,4	0,7	0,4	9,9
Bg	6,0	10,8	13	40	1,3	0,3	0,1	3,6
B/C	6,1	81,0	11	38	1,0	0,3	0,1	7,9
Cg	6,1	83,7	14	30	0,5	0,2	0,4	3,63

Fonte: O autor (2020).

Tabela 6: Análise química

Horizonte	SB	t (mg/dm ³)	T	V	m (%)	ISNa	MO (dag/kg)
A	2,6	3,0	12,5	20,6	13,5	2,2	6,99
Bg	1,9	2,0	5,5	33,9	5,1	8,87	0,94
B/C	1,5	1,6	9,4	15,8	6,3	10,39	0,81
Cg	0,8	1,3	4,5	19,5	31,3	10,19	0,54

Fonte: O autor (2020).

4.2. Dados meteorológicos e micrometeorológicos

Uma estação micrometeorológica de 4,0 m de altura foi instalada na área de estudo, como descrito por Martins (2019), para servir de base aos instrumentos meteorológicos (Figura 7). O local de instalação da estação foi cercado para evitar a entrada de aninas (por exemplo, gado) e possíveis avarias nos instrumentos de medidas micrometeorológicas. A área de estudo possuía uma área interna (cercado da estação) e uma área externa (área de estudo com acesso do gado) e possuía aproximadamente 300 m de bordadura na direção predominante do vento.

As medições do saldo de radiação foram obtidas por um saldo radiômetro (Modelo LP-NET-14, Delta Ohm, Itália), instalado a 1,80 m acima do solo (orientado para Norte) e aproximadamente a 1,50 - 1,55 m acima da vegetação (Tabela 7). Os dados de temperatura e umidade relativa do ar foram obtidos por três termohigrômetros (DB-TH1-SDI, dualBASE, EUA), sendo estes instalados a 1,15; 1,58 e 2,33 m acima do dossel da vegetação. A velocidade do vento foi obtida por quatro anemômetros sônicos (GILL-1405, Gill Instruments, Reino Unido), instalados a 1,23; 1,68; 2,34 e 3,00 m de altura. As medições do fluxo de calor no solo foram realizadas por duas placas de fluxo de calor no solo (HFP01, Hulkseflux Termal Sensors), a aproximadamente 0,05 m de profundidade. O sistema ainda contava com três reflectômetros de conteúdo de água, instalados a 0,10; 0,30 e 0,60 m de profundidade. As médias das coletas foram armazenadas a cada 10 minutos, com auxílio de um sistema automático de aquisição de dados (*datalogger* CR3000, Campbell Scientific Inc, EUA).




Figura 7: Estação micrometeorológica com a localização dos instrumentos. Fonte: O autor (2020).

Tabela 7: Descrição dos instrumentos da estação micrometeorológica

ID	Instrumento	Modelo	Quantidade	Dados
1	Placa solar		1	Alimentação (energia)
2	Anemômetros sônico 2D	GILL-1405, Gill Instruments, Reino Unido	4	Velocidade do vento
3	Sistema Automático de Aquisição de Dados	CR3000, Campbell Scientific Inc, EUA	1	Armazenamento de energia
4	Termohigrômetros	DB-TH1-SDI, dualBASE, EUA	3	Temperatura e umidade relativa do ar
5	Saldo Radiômetro	Modelo LP-NET-14, Delta Ohm, Itália	1	Saldo de radiação
6	Placas de fluxo de calor no solo	HFP01, Hulkseflux Termal Sensors	2	Fluxo de calor no solo
7	Reflectômetros de conteúdo de água	modelo CS616 Water. Content Reflectometers, Campbell Scientific, Inc.	3	Reflectômetros de conteúdo de água.

Fonte: O autor (2020).

4.3. Biometria

4.3.1. Ceptômetro

Foram realizadas campanhas com medidas de densidade de fluxos de fótons fotossintéticos (DFFF) acima e abaixo do dossel e estimativas do índice de área foliar (IAF), por método não destrutivo, com o uso de um ceptômetro (AccuPAR LP-80, Decagon Devices, EUA). A altura da vegetação (h) (intensidade do pastejo) foi obtida por método não destrutivo com auxílio de uma trena graduada em cm.

O ceptômetro é composto por um sensor quantum externo para a realização de medidas de DFFF acima do dossel (DFFFa), e uma sonda de 86,5 x 2,0 cm com 80 sensores quantum espaçados em 1,0 cm cada (amplitude de 0 - 2500 $\mu\text{mol m}^{-2} \text{s}^{-1}$ e resolução de 1 $\mu\text{mol m}^{-2} \text{s}^{-1}$) para as medidas da densidade de fluxos de fótons fotossintéticos fotossintéticos abaixo do dossel (DFFFin) (DECAGON DEVICES, 2015). Nas medições (Figura 8) a régua foi mantida na posição vertical, a sonda do ceptômetro posicionada abaixo do dossel próximo a superfície e o sensor externo nivelado acima do dossel.




Figura 8: Coleta de altura da vegetação, DFFF e estimativas do IAF na área experimental. Fonte: Martins (2019).

As campanhas foram feitas em intervalos entre 30 e 60 dias, durante um período de 13 meses. As campanhas de coleta foram caracterizadas pela presença ou não presença de gado na área de estudo, devido ao sistema de rotação adotado pela fazenda na área experimental. O sistema de rotação adotado considerava a área experimental desse trabalho e outras áreas de pastagem (piquetes), de forma, que o rodízio do gado na área experimental era de 15/15 dias (pastejo/descanso) (Figura 10).

A Tabela 8 mostra as datas das campanhas, as datas de rotação do pasto, se havia ou não a presença de gado na área experimental e os métodos utilizados para obtenção do IAF. As medidas de altura, densidade de fluxos e estimativa de IAF foram realizadas em pontos ao acaso na área experimental (interna e externa), considerando uma média de 20 pontos fora da área cercada, porém, próximos à estação, conforme esquema (Figura 9).

Tabela 8: Descrição da campanha

Campanhas	Rotação do pasto		Gado no pasto	Método
	Entrada	Saída		
25/07/2018	30/06/2018	15/07/2018	Ausência	Não destrutivo
04/09/2018	29/08/2018	13/09/2018	Presença	Não destrutivo
19/10/2018	28/09/2018	13/10/2018	Ausência	Não destrutivo
22/11/2018	29/10/2018	13/11/2018	Ausência	Não destrutivo
19/12/2018	29/11/2018	14/12/2018	Ausência	Não destrutivo
23/01/2019	30/12/2018	14/01/2019	Ausência	Não destrutivo
19/03/2019	01/03/2019	16/03/2019	Ausência	Não destrutivo
08/05/2019	02/05/2019	17/05/2019	Presença	Não destrutivo
18/06/2019	02/06/2019	17/06/2019	Ausência	Não destrutivo
09/07/2019	02/07/2019	17/07/2019	Presença	Não destrutivo
22/08/2019	01/08/2019	16/08/2019	Ausência	Destrutivo e Não destrutivo
02/10/2019	01/10/2019	16/10/2019	Presença	Destrutivo e Não destrutivo
10/12/2019	01/12/2019	16/12/2019	Presença	Destrutivo e Não destrutivo

Fonte: O autor (2020).

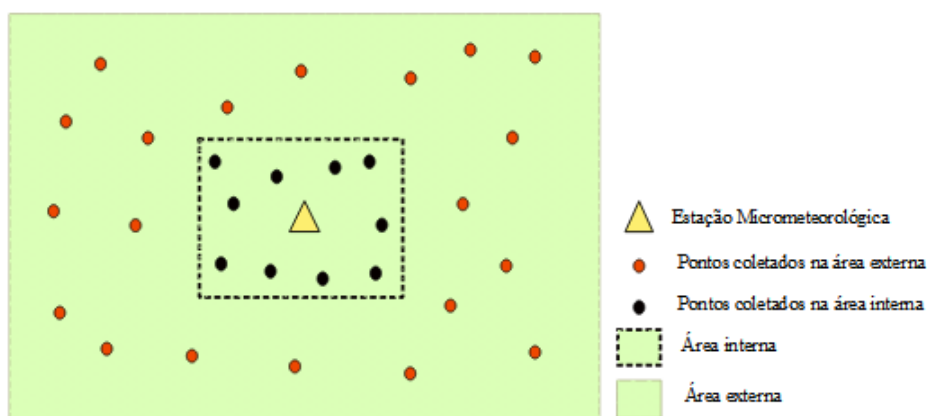


Figura 9: Caracterização da área experimental. Fonte: O autor (2020).



Figura 10: Área experimental com presença de animais de raça predominantemente nelore (*Bos taurus indicus*). Fonte: O autor (2020).

4.3.2. Método destrutivo

Nas campanhas dos dias 22/08/19, 02/10/19 e 10/12/19 (Tabela 8), o IAF foi também determinado por método destrutivo, com base em amostras da vegetação obtidas em áreas coincidentes com as de medidas do ceptômetro. Para avaliação do IAF pelo método destrutivo foi coletada a vegetação acima da superfície de uma área com dimensões de 0,20 x 0,20 m (Figura 11). Nas três campanhas foram avaliadas 23 amostras de vegetação. A vegetação foi cortada ao nível do solo e levada para laboratório no menor espaço de tempo possível.

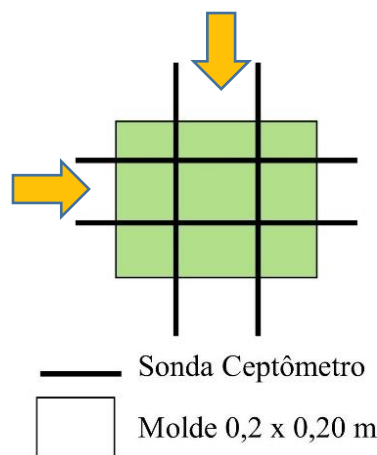


Figura 11: Esquema da coleta com ceptômetro da amostra pelo método destrutivo. Fonte: O autor (2020).

Em laboratório, as amostras foram fracionadas manualmente nos seguintes compartimentos: folha verde, parte seca e caule (Figura 12). Após essa etapa as subamostras foram pesadas na balança de precisão para determinação da massa fresca e, em seguida digitalizadas pelo método do *scanner*. No método do *scanner* as subamostras foram dispostas sobre o *scanner* (modelo HP Deskjet F4280, Hewlett-Packard, EUA), conectado a um computador *Desktop*, junto com uma régua para serem digitalizadas. Para que as imagens fossem calibradas de acordo com a distância, em centímetros, a régua era digitalizada com as subamostras. As imagens foram escaneadas numa resolução de 200 ppp em preto e branco, salvas em .jpg e processadas pelo programa Image J (SCHINDELIN, 2012; PINHEIRO et al., 2020).



Figura 12: Subamostras coletas em 10/12/2019. A: Folha verde; B: Caule; C: Parte seca.
Fonte: O autor (2020).

Na primeira etapa do método, as imagens de cada partição (folha verde, parte seca e caule) foram importadas no programa ImageJ por meio do comando (*File > Open*). Para a calibração, utilizou-se a ferramenta *straight*, definindo a medida de 1 cm, com a utilização da imagem da régua. Com o *zoom* máximo, para melhor visualização dos pixels, por meio do comando (*Analyze > Set Scale*) a equivalência do pixel da imagem ao centímetro selecionado foi realizada (*Know distance: 1,00; Unit of length: cm*) foi realizada. Após este procedimento algumas funções foram executadas para a melhoria da qualidade da imagem (*Image > Type: 8bits; Process > Binary > Make binary*) para que assim a análise da imagem fosse processada (*Analyze > Analyze Particles > Size(cm²):1,00 > Circularity:1,00*). Com a função *wand* a área foliar foi obtida apenas clicando sobre a região foliar. Após o escaneamento das subamostras, essas foram colocadas em estufa por 24 horas à 65°C de temperatura e, após esse período, pesadas para obtenção de massa seca de cada compartimento (folhas verdes + caule + parte seca) e total, além do percentual.

4.3.3. Sensoriamento Remoto

O fluxograma metodológico da etapa de processamento das imagens orbitais é apresentado na Figura 13. Na primeira etapa as imagens foram selecionadas considerando a área experimental e a nebulosidade; na segunda ocorreu o pré-processamento das imagens a partir dos dados do satélite; na terceira calculou-se os índices de vegetação por manipulações algébricas; na quinta foi realizada a análise temporal considerando o valor encontrado no pixel e na última etapa a análise estatística dos dados.




Figura 13: Fluxograma metodológico. Fonte: O autor (2020).

As imagens Landsat 8/OLI e Sentinel 2A/B (Tabelas 9 e 10) foram adquiridas do sítio do Serviço Geológico dos Estados Unidos (*United State Geological Survey – USGS*), que estavam disponíveis em <https://www.earthexplorer.usgs.gov/>. Para a seleção das imagens no período de julho/2018 até dezembro/2019 considerou-se as que apresentavam menor interferência de nebulosidade e os procedimentos de pré e pós-processamento das imagens foram realizados no QGIS 2.14.13 (QGIS Development Team, 2015) com o complemento *Semi-Automatic Classification Plugin* (SCP), conforme Congedo (2016).

As cenas do Landsat-8 (Órbita/Ponto - 217/75) obtidas da *Collection 1 Level-1* com correção radiométrica, geométrica e atmosférica no sistema de projeção cartográfica UTM/WGS84. As cenas do Sentinel-2 também adquiridas na plataforma do USGS foram fornecidas como produto *Top-Of-Atmosphere* Nível-1C (L1C), com correção radiométrica e geométrica no sistema de projeção cartográfica UTM/WGS84.

No SCP, as cenas do Landsat-8 para cada data de aquisição foram importadas e passaram pela etapa de correção atmosférica pelo método *Dark Object Subtraction* (DOS) e transformações em nível de reflectância *Top-Of-Atmosphere* (TOA) e *Bottom-Of-Atmosphere* (BOA), conforme Congedo (2016).

Tabela 9: Imagens OLI/Landsat-8 e MSI/Sentinel-2 livres de nuvens na área de estudo.

Satélite	Cena	Data de aquisição
Sentinel-2	T23KQR	28/07/2018
		10/03/2019
		15/03/2019
		30/03/2019
		19/04/2019
		14/05/2019
		18/06/2019
		23/07/2019
		02/08/2019
		12/08/2019
		27/08/2019
		11/09/2019
		16/09/2019
		15/12/2019
		Landsat-8
01/09/2018		
03/10/2018		
06/12/2018		
22/12/2018		
07/01/2019		
23/01/2019		
08/02/2019		
24/02/2019		
16/06/2019		
02/07/2019		
19/08/2019		
20/09/2019		
23/11/2019		
25/12/2019		

Fonte: O autor (2020).

Tabela 10: Características temporal e espectral do Landsat-8 OLI e Sentinel-2 MSI

Características	Landsat-8	Sentinel-2
Número de Bandas	8 (OLI) 2 (TIRS)	13 (MSI)
Resolução Radiométrica	16 bits	12 bits
Resolução Temporal	16 dias	5 dias
Banda do Azul (B)	B2 (0,45-0,51 um) 30m	B2 (0,46-0,52 um) 10m
Banda do Verde (G)	B3 (0,53-0,59 um) 30m	B3 (0,54-0,58 um) 10m
Banda do Vermelho (RR)	B4 (0,64-0,67 um) 30m	B4 (0,65-0,68 um) 10m
Banda Infravermelho próximo (NIR)	B5 (0,85-0,88 um) 30m	B8 (0,78-0,90 um) 10m

Fonte: ESA (2017).

As imagens Sentinel-2 adquiridas em nível de reflectância TOA passaram pelo processo de correção DOS e transformação em nível de reflectância BOA. Para realizar essa série de cálculos são necessários parâmetros, sendo eles: radiância mínima e máxima, irradiância no topo da atmosfera e ganho do sensor, parâmetros que variam para cada banda espectral. Além disso, são necessários outros parâmetros que dependem da data da imagem, como a distância Terra-Sol e o ângulo de elevação solar. A conversão dos números digitais das imagens para valores de parâmetros físicos como a radiância e a reflectância tem como objetivo permitir a caracterização espectral de objetos, elaboração de cálculos que incluem dados de imagens de diferentes sensores ou de diferentes bandas espectrais (PONZONI et al., 2015).

A correção pelo método *Dark Object Subtraction* (DOS) é realizada a partir da estimativa da interferência atmosférica em cada banda espectral. O método DOS, também denominado Correção Atmosférica pelo Pixel Escuro foi proposto por Chaves (1988), sendo um método de fácil aplicação baseado somente na imagem e que parte do princípio de que, em toda e qualquer cena e em qualquer banda espectral existem pixels, que deveriam assumir o valor zero. Dessa forma, esses pixels não poderiam refletir radiação ou absorvê-la totalmente, logo, o valor excedente deveria ser explicado pela interferência aditiva do espalhamento atmosférico. Com um procedimento simples, os valores de ND (*Digital Number*) são subtraídos de todos os NDs da cena, considerando a interferência atmosférica como algo uniforme (LIU, 2015).

Após a realização das etapas de pré-processamento, as bandas de reflectância do infravermelho próximo e do vermelho foram utilizadas para o cálculo dos índices de vegetação (Tabela 11). Os índices foram calculados para as 15 cenas do satélite Landsat-8 e para as 14 cenas do Sentinel-2 no *software* QGIS com a ferramenta modelador gráfico. Para cada satélite foi criado um *workflow* indicando as bandas de entrada.

Tabela 11: Característica espacial e espectral do Landsat-8 OLI e Sentinel-2 MSI

Satélite	Resolução espacial	Banda	Nome da banda	Comprimento de onda central (nm)
Sentinel-2	10 m	B04	Red (Vermelho)	665
		B08	NIR (Infravermelho Próximo)	842
Landsat-8	30 m	B04	Red (Vermelho)	654
		B05	NIR (Infravermelho Próximo)	864

Fonte: ESA (2017).

Na primeira etapa, o Índice de Vegetação da Diferença Normalizada (NDVI - *Normalized Difference Vegetation Index*) foi calculado, sendo a razão entre a diferença das reflectividades das bandas no infravermelho próximo (ρ_{iv}) e no vermelho (ρ_v) do visível e pela soma dessas mesmas reflectividades apresentado na Equação 1 (ROUSE et al., 1974).

$$NDVI = \frac{\rho_{iv} - \rho_v}{\rho_{iv} + \rho_v} \quad (1)$$

Para determinação do Índice de Vegetação Ajustado ao Solo (SAVI - *Soil-adjusted vegetation index*) aplicou-se a Equação 2, que considera os efeitos do solo exposto nas imagens analisadas e, busca minimizar a influência da resposta espectral do solo, mediante a inclusão de um fator de ajuste (L), que é variável com o grau de fechamento do dossel e permite melhora na interpretação das variáveis da vegetação. A constante L varia entre 0 e 1, de acordo com a densidade da vegetação, sendo o valor 1 adotado para áreas com pouca cobertura vegetal, enquanto áreas com cobertura intermediária é representada por L = 0,5, áreas muito densas, geralmente adota-se a constante L = 0,25, quando o L é igual a 0, o SAVI é idêntico ao NDVI (HUETE 1988; Qi et al. 1994; MENESES, 2011). No presente estudo adotou-se L = 0,25, L = 0,50 e L = 1.

$$SAVI = \frac{(1 + L)(\rho_{iv} - \rho_v)}{(\rho_{iv} + \rho_v)} \quad (2)$$

Em seguida, foi calculada a relação entre a área foliar de toda vegetação e a unidade de área de solo ocupada por essa vegetação, denominada de índice de área foliar (m^2 folhas/ m^2 solo), tendo por base o SAVI estimado na etapa anterior para L = 0,25, L = 0,50 e L = 1, e empregando a equação empírica sugerida por Allen et al. (2002):

$$IAF = \frac{\ln\left(\frac{0,69 - SAVI}{0,59}\right)}{0,91} \quad (3)$$

Após o cálculo dos índices de vegetação as imagens orbitais foram selecionadas considerando a proximidade entre a data de passagem e a campanha de campo (Tabela 12), que resultou em seis imagens do satélite Sentinel-2 e oito imagens do satélite Landsat-8.

Em seguida foram elaborados gráficos correlacionando os dados de IAF obtidos em campo com ceptômetro e os gerados no processamento das imagens. Na análise foram considerados os diferentes valores de L (0,25, 0,50 e 1,00).

Tabela 12: Data da passagem do satélite associada com a campanha de campo

	Data da imagem	Campanhas
Sentinel-2	15/03/2019	19/03/2019
	18/06/2019	18/06/2019
	23/07/2019	09/07/2019
	27/08/2019	22/08/2019
	16/09/2019	02/10/2019
	15/12/2019	10/12/2019
Landsat-8	01/09/2018	04/09/2018
	03/10/2018	19/10/2018
	06/12/2018	22/11/2018
	24/02/2019	19/03/2019
	16/06/2019	18/06/2019
	02/07/2019	09/07/2019
	19/08/2019	22/08/2019
	20/09/2019	02/10/2019

Fonte: O autor (2020).

4.3.4. Análise estatística

Nas avaliações considerou-se a regressão linear simples ($Y = a + b X$) entre os dados observados (X) e estimados (Y), o coeficiente de determinação (r^2), coeficiente de concordância de Willmott (d) e a Raiz do Quadrado Médio do Erro (RQME).

O coeficiente de determinação (r^2) apresentado na Equação 4 indica a precisão das estimativas, é dado pela seguinte razão:

$$r^2 = \left(\frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{(\sum(X_i - \bar{X})^2 \sum(Y_i - \bar{Y})^2)}} \right)^2 \quad (4)$$

em que, \bar{X}_i e \bar{Y} são a média dos valores observados e estimados, respectivamente. O índice subscrito i , representa, a i -ésima observação.

Para avaliar a exatidão das estimativas foi considerado o coeficiente de concordância de Willmott (WILLMOTT, 1981):

$$d = 1 - \frac{\sum(X_i - Y_i)^2}{\sum(|X_i - O| + |Y_i - O|)^2} \quad (5)$$

A Raiz do Quadrado Médio do Erro (RQME) absoluta e relativa (em relação à média) foi estimada pela Equação 6, onde N é o número de observações.

$$RQME = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}} \quad (6)$$

5. RESULTADOS E DISCUSSÃO

5.1. Condições meteorológicas

O comportamento temporal das variáveis meteorológicas mensuradas durante o período de 01/07/2018 até 01/07/2019 na área experimental é descrito nas Tabelas 13 e 14. A variável temperatura do ar (Figura 13) apresentou média anual de 24,0 °C, e média mensal entre 20,5°C (julho) a 29,0°C (fevereiro) no ano de 2019 e de 21,5°C (julho) a 27,0°C (novembro) no ano de 2018. Comparando o valor médio da temperatura do ar em julho de 2018, com o observado para o mesmo mês em 2019, identificou-se diferença de 1,0°C. A taxa fotossintética máxima apresentada por gramíneas forrageiras do tipo C4 está em entre 30 e 35 °C e a temperatura base inferior (temperatura abaixo da qual não há crescimento) varia entre 12 e 17 °C (CORRÊA e SANTOS, 2006).

Dezembro de 2018 se destacou ao longo do período analisado com maior totais de chuvas (339,3 mm), enquanto julho de 2019 apresentou o menor total (21,6 mm), conforme se observa na Tabela 14. Ao longo dos meses considerados, o valor da chuva total mensal foi menor do que os de evapotranspiração de referência (ET_o) em setembro de 2018 e em junho, julho e setembro de 2019, o que indicou que a área em estudo apresentou deficiência hídrica nesses meses. Pesquisas pioneiras de irrigação de pastagens associada à adubação evidenciam acentuada estacionalidade de produção, mesmo na ausência de déficit hídrico (GHELFI FILHO, 1972), em consequência do menor fotoperíodo e temperatura do ar no inverno (CORRÊA e SANTOS, 2006).

Verificou-se maior disponibilidade de radiação solar entre os meses de setembro de 2018 e abril de 2019, que resultou em maiores valores de ET_o nesses meses, sendo esse resultado explicado pela relação direta entre a disponibilidade da radiação solar e a transferência de água na forma de vapor da superfície para a atmosfera.

Tabela 13: Temperatura do ar média, média das máximas e das mínimas.

Ano	Mês	Rg (MJ.m ⁻² .d ⁻¹),	Temperatura do ar		
			Mínima (°C)	Máxima (°C)	Média (°C)
2018	Julho	14,15	10,9	32,2	21,5
	Agosto	12,25	11,8	32,6	22,2
	Setembro	15,81	11,3	35,7	23,5
	Outubro	13,07	13,2	37,2	25,2
	Novembro	15,64	17,3	36,7	27,0
	Dezembro	19,37	12,3	38,0	25,2
2019	Janeiro	24,71	19,3	38,4	28,8
	Fevereiro	17,54	19,1	39,0	29,0
	Março	16,75	17,1	37,0	27,1
	Abril	16,84	16,3	37,3	26,8
	Maió	13,34	13,3	33,8	23,5
	Junho	12,88	12,1	33,6	22,8
	Julho	13,49	7,7	33,3	20,5

Tabela 14: Total mensal da precipitação, número de dias com chuva e frequência.

Ano	Mês	Precipitação				
		ETo (mm)	Total (mm)	Dias	Freq.	P – ETo
2018	Julho	81,3	85,1	19	4	3,8
	Agosto	79,4	105,9	17	6	26,6
	Setembro	107,8	88,4	10	9	-19,4
	Outubro	100,9	244,6	22	11	143,7
	Novembro	118,8	324,6	16	20	205,8
	Dezembro	151,4	339,3	25	14	187,9
2019	Janeiro	172,6	209,4	12	17	36,9
	Fevereiro	111,5	197,9	20	10	86,5
	Março	111,3	154,4	23	7	43,1
	Abril	100,2	301,9	20	15	201,7
	Maió	77,0	182,4	16	11	105,4
	Junho	66,7	54,6	20	3	-12,1
	Julho	68,9	21,6	19	1	-47,3

A umidade relativa do ar (Figura 14) apresentou média do período julho 2018 a julho 2019 de 78,5%. O menor valor médio foi de 63,3% observado em julho (16/07/2018) e o maior em abril (07/04/2019) com valor de 97,6%.




Figura 13: Variação temporal da temperatura do ar.

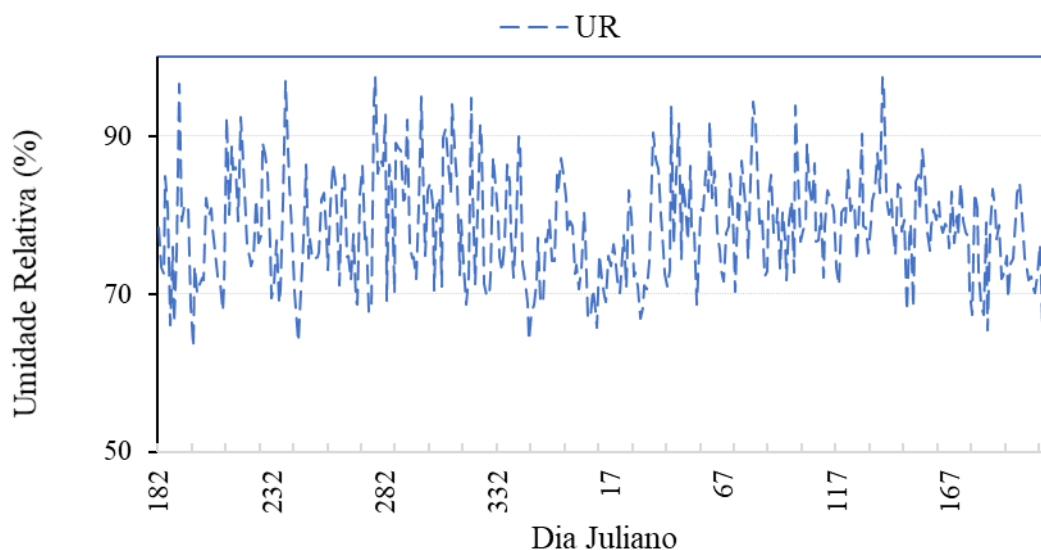


Figura 14: Variação temporal da umidade relativa do ar.

A radiação solar global (R_g) apresentou média do período julho 2018 a julho 2019 de $15,82 \text{ MJ m}^{-2} \text{ d}^{-1}$, valor mínimo de $1,65 \text{ MJ m}^{-2} \text{ d}^{-1}$ em julho (2018) e máximo de $30,18 \text{ MJ m}^{-2} \text{ d}^{-1}$ em dezembro (2019) (Figura 16). A transmissividade variou de 0,07 (mínimo) a 0,72 (máximo) no mês de julho de 2018, a média do período entre julho 2018 a julho 2019 foi de 0,49 (Figura 17).

A variação temporal da radiação solar no topo da atmosfera (R_n) (Figura 15) apresentou média do período julho 2018 a julho 2019 de $33,05 \text{ MJ m}^{-2} \text{ d}^{-1}$, valor máximo de $42,62 \text{ MJ m}^{-2} \text{ d}^{-1}$ em 2018 (entre 20 e 26/12), e registrou mínimo de $22,91 \text{ MJ m}^{-2} \text{ d}^{-1}$ em 2019 (entre 21 e 23/06).

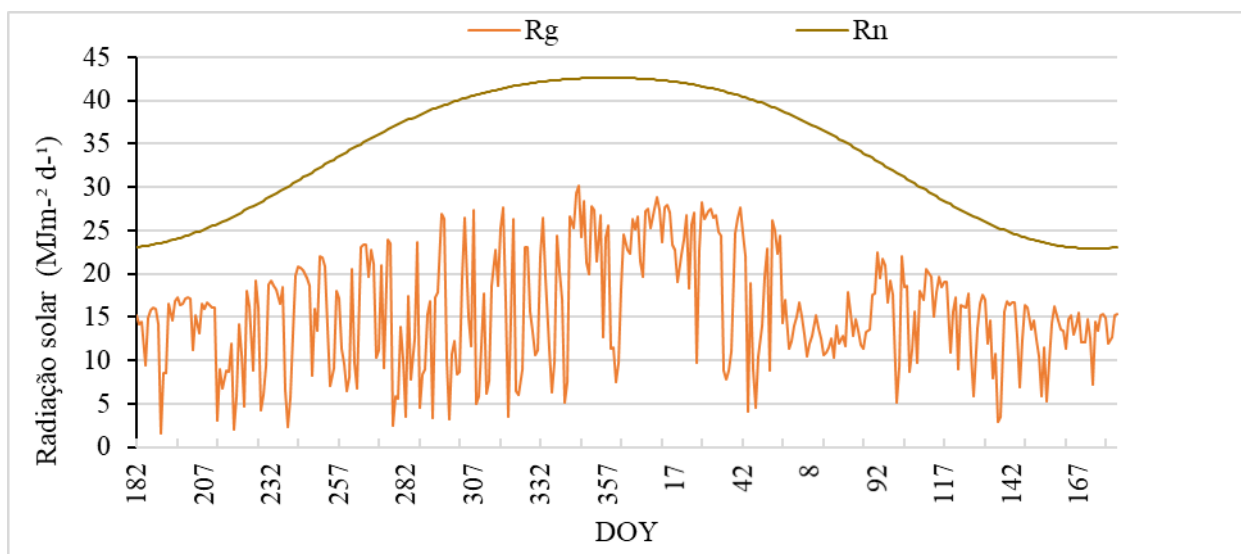


Figura 15. Variação temporal da radiação solar no topo da atmosfera (Rn) e radiação solar global (Rg).

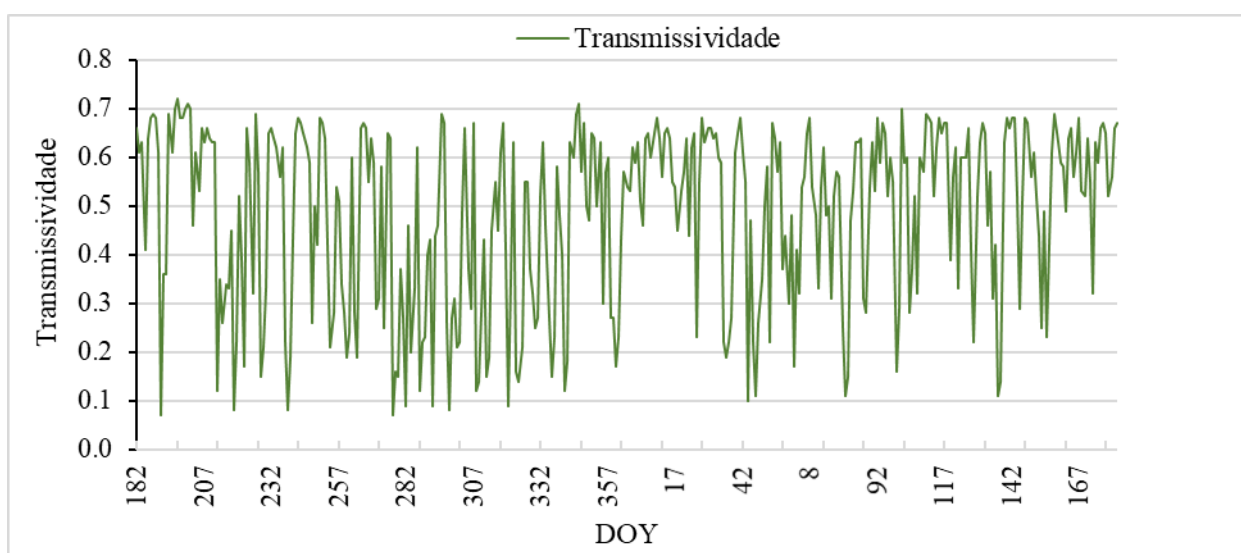


Figura 16: Variação temporal da transmissividade.

Na Figura 18 os dados de ET_o apresentaram tendência de aumento nos meses da primavera e do verão em decorrência de maiores valores de radiação solar global e temperatura do ar. Observou-se aumento de ET_o a partir de outubro (2018) até janeiro (2019), acompanhando do aumento do total das chuvas nos meses de outubro, novembro e dezembro de 2018.

Martins (2019) identificou tendência de aumento nos valores de ET_o nos meses da primavera e do verão (dezembro) para uma área de pastagem e relacionou com a disponibilidade

de água no ambiente e de energia solar, visto que essas estações apresentam maior oferta de radiação solar, umidade relativa do ar mais elevada e taxas pluviométricas também mais elevadas. A umidade do solo (Figura 18) apresentou comportamento similar para as três profundidade analisadas, variando conforme a disponibilidade hídrica do local.




Figura 17. Variação temporal da precipitação e evapotranspiração (ETo).

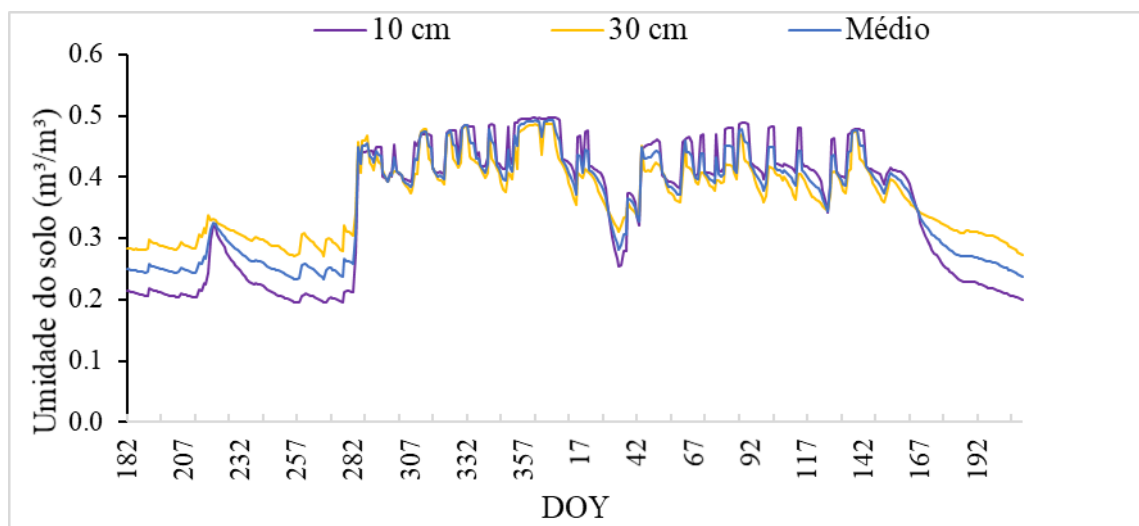


Figura 18. Variação temporal da umidade do solo (m^3/m^3) para 10 e 30 cm de profundidade e valor médio.

5.2. Biometria

O comportamento temporal da variável altura para a área externa mensurada durante 13 campanhas em campo no período de 25/07/2018 até 10/12/2019 na área experimental é apresentado na Figura 19. Para a área interna o período considerado foi de 25/07/2018 até 22/08/2019.

A altura da área externa apresentou média de 29,19 ($\pm 11,37$) cm, com valor máximo de 75 cm em dezembro (19/12/2018) e mínimo de 8 cm em agosto (22/08/2019). Na área interna a média foi de 48,41 ($\pm 20,27$) cm, com valor máximo de 90 cm em novembro (22/11/2018) e mínimo de 12 cm (25/07/2018). Pode-se observar que a variação da altura acompanhou a sazonalidade da região, apresentando menores valores no período seco (abril a setembro) e maiores valores no período chuvoso (outubro a março). Na área interna também foi possível identificar sazonalidade e maiores valores para a altura, sendo esse aumento justificado pela ausência de interferência do gado. Observou-se que a campanha do dia 19/12/2018 na área interna apresentou descontinuidade do comportamento sazonal esperado, e isso ocorre devido a necessidade de roçado da área, visando preservar o funcionamento dos sensores da estação micrometeorológica.




Figura 19: Variação dos dados de altura (cm) da área externa para as campanhas avaliadas no estudo (a); Variação dos dados de altura (cm) da área interna para as campanhas avaliadas no estudo (b).

Os valores de Índice de Área Foliar (IAF) da área externa obtidos com ceptômetro foram corrigidos (Figura 20) considerando o dados de IAF obtidos pelo método destrutivo (padrão).

Para isso, um coeficiente de correção foi determinado pela relação entre o IAF (Folha verde) e IAF (Destrutivo), sendo o último a soma do IAF das partições (Folha verde, Caule e Parte seca).

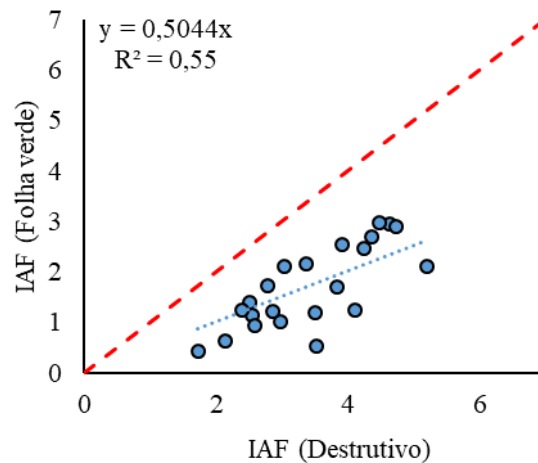


Figura 20: Correlação entre IAF (Folha verde) e IAF (Destrutivo).

Na Figura 21 foi possível identificar que o comportamento da IAF acompanhou a sazonalidade climática da região, apresentando menores valores no período seco e maiores valores no período chuvoso. O IAF da área externa coletada com ceptômetro e corrigida com o fator de correção definido (0,5044) apresentou média de $2,10 (\pm 0,77) \text{ m}^2.\text{m}^{-2}$, com valor mínimo de $0,68 \text{ m}^2.\text{m}^{-2}$ na campanha do dia 10/12/2019 e valor máximo de $5,00 \text{ m}^2.\text{m}^{-2}$ em 22/11/2018. O IAF da área interna apresentou média de $2,72 (\pm 0,89) \text{ m}^2.\text{m}^{-2}$, com valor máximo de $5,31 \text{ m}^2.\text{m}^{-2}$ (19/12/2018) e mínimo de $1,31 \text{ m}^2.\text{m}^{-2}$ (19/03/2019) (Figura 22).




Figura 21: Variação dos dados de IAF corrigido (m^2m^{-2}): (a) área externa e (b) área interna para as campanhas.

5.3. Sensoriamento Remoto

5.3.1. Índices de vegetação

Os índices de vegetação considerados para a construção da série temporal anual da pastagem apresentaram pequena amplitude de variação. Para o período entre 15/07/2018 e 25/12/2019 o NDVI (Tabela 15) obtido a partir das imagens Landsat-8 apresentou valor mínimo de 0,61 em agosto de 2019 e máximo de 0,83 em dezembro do mesmo ano, com amplitude de 0,22 e média 0,75 (0,06). Enquanto os valores de SAVI variaram de 0,32 até 0,54, com média de 0,46 (0,067), quando considerado $L = 1$, para $L = 0,5$ variou de 0,38 até 0,61 com média de 0,52 (0,068) e quando adotou-se $L = 0,25$ os valores ficaram entre 0,45 e 0,68 com média de 0,60 (0,07).

Tabela 15: Variação temporal dos Índices de Vegetação obtidos a partir de dados do satélite Landsat-8

Data de aquisição	LANDSAT-8						
	NDVI	SAVI			IAF		
		1,0	0,5	0,25	1,0	0,5	0,25
15/07/2018	0,64	0,36	0,43	0,49	0,65	0,88	0,88
01/09/2018	0,77	0,49	0,56	0,63	1,19	1,64	2,44
03/10/2018	0,78	0,51	0,57	0,64	1,29	1,8	2,8
06/12/2018	0,73	0,41	0,48	0,55	0,82	1,13	1,61
22/12/2018	0,82	0,54	0,61	0,68	1,48	2,15	4,26
07/01/2019	0,81	0,51	0,58	0,66	1,31	1,87	3,15
23/01/2019	0,8	0,54	0,6	0,67	1,48	2,11	3,74
08/02/2019	0,78	0,47	0,54	0,62	1,08	1,51	2,3
24/02/2019	0,71	0,42	0,49	0,56	0,88	1,19	1,67
16/06/2019	0,72	0,43	0,49	0,57	0,88	1,21	1,71
02/07/2019	0,68	0,41	0,47	0,54	0,8	1,08	1,48
19/08/2019	0,61	0,32	0,38	0,45	0,52	0,72	0,99
20/09/2019	0,75	0,41	0,48	0,56	0,82	1,15	1,7
23/11/2019	0,77	0,52	0,58	0,64	1,37	1,87	2,81
25/12/2019	0,83	0,53	0,61	0,68	1,45	2,14	4,56

Para o período entre 28/07/2018 e 15/12/2019 o NDVI (Tabela 16) obtido a partir das imagens Sentinel-2 apresentou valor mínimo de 0,58 em julho de 2019 e máximo de 0,79 em março e maio do mesmo ano, com amplitude de 0,21 média 0,69 (0,06). Enquanto que, os valores de SAVI variou entre 0,29 e 0,45 e média de 0,37 (0,04), quando considerado L=1 , para L=0,5 variou entre 0,35 e 0,53; com média de 0,44 (0,05)e quando adotou-se L=0,25 os valores ficaram entre 0,42 e 0,61; com média de 0,51 (0,05).

Para Silva et al. (2015), mesmo apresentando variação temporal anual a amplitude de variação em áreas de pastagem é pequena, encontrando diferença de 0,17 entre o valor máximo de dezembro (0,66) e o menor em julho (0,49) no trabalho desenvolvido na região Sudoeste do estado do Paraná, em clima Subtropical Úmido (Cfa). Santos et al. (2014) obtiveram valores máximo e mínimo: 0,74 e 0,44, respectivamente, de NDVI para pastagem por meio do sensor MODIS na região Amazônica, com amplitude na ordem de 0,3. Vicente et al. (2012) apresentaram média de 0,53 para o valor de NDVI após analisar séries temporais compostas por 252 imagens do satélite SPOT. O baixo valor de amplitude para o NDVI encontrado por diferentes autores coincide com os valores 0,21 e 0,22 de amplitude encontrados nessa pesquisa.

Tabela 16: Variação temporal dos Índices de Vegetação obtidos a partir de dados do satélite Sentinel-2A/B.

Data de aquisição	SENTINEL-2A/B						
	NDVI	SAVI			IAF		
		1,0	0,5	0,25	1,0	0,5	0,25
28/07/2018	0,65	0,36	0,42	0,49	0,63	0,87	1,28
10/03/2019	0,65	0,32	0,39	0,46	0,53	0,74	1,06
15/03/2019	0,68	0,35	0,42	0,5	0,62	0,86	1,23
30/03/2019	0,79	0,45	0,53	0,61	0,99	1,41	2,17
19/04/2019	0,76	0,42	0,49	0,57	0,84	1,19	1,75
14/05/2019	0,79	0,45	0,52	0,61	0,97	1,45	1,39
18/06/2019	0,72	0,39	0,46	0,54	0,75	1,04	1,50
23/07/2019	0,58	0,35	0,41	0,48	0,6	0,82	1,13
02/08/2019	0,66	0,35	0,42	0,49	0,62	0,85	1,18
12/08/2019	0,65	0,35	0,41	0,48	0,6	0,82	1,14
27/08/2019	0,74	0,40	0,47	0,54	0,76	1,06	1,53
11/09/2019	0,66	0,34	0,4	0,48	0,56	0,79	1,11
16/09/2019	0,72	0,38	0,45	0,53	0,72	1,00	1,45
15/12/2019	0,62	0,29	0,35	0,42	0,42	0,60	0,87

5.3.2. Índice de Área Foliar

Para o período entre 15/07/2018 e 25/12/2019, o IAF obtido a partir das imagens Landsat-8 apresentou valor mínimo de 0,52 em agosto de 2019 e máximo de 1,48 em dezembro (2018) e janeiro (2019), com amplitude de 0,96 e média 1,07 (0,31), quando considerado $L = 1$. Para $L = 0,5$, o IAF variou entre 0,72 em agosto (2019) e 2,15 registrado em dezembro (2018), com média de 1,50 (0,46) e, quando adotou-se $L=0,25$ os valores ficaram entre 0,88 em julho (2018) e 4,56 em dezembro (2019), com média de 2,41 (1,10).

Para o período entre 28/07/2018 e 15/12/2019 o IAF obtido a partir das imagens Sentinel-2 apresentou valor mínimo de 0,42 em dezembro (2019) e máximo de 0,99 em março (2019), com amplitude de 0,57 e média 0,69 (0,16) quando considerado $L = 1$, para $L = 0,5$ variou entre 0,60 em dezembro (2019) e 1,45 registrado em maio (2019), com média de 0,96 (0,24) e; quando adotou-se $L = 0,25$ os valores ficaram entre 0,87 em dezembro (2019) e 2,17 em março (2019), com média de 1,34 (0,32).

Quando se comparou os valores de IAF estimado pelo índice SAVI com o IAF observado (ceptômetro) observou-se precisão das estimativas, com coeficiente de concordância de Willmott (d) de 0,87 (Sentinel-2) e 0,86 (Landsat-8) para $L=0,25$. Para os demais valores de L , a concordância diminuiu com o aumento de L .

O coeficiente de determinação (r^2) foi de 0,12 ($L= 0,25$) para Landsat-8, enquanto para Sentinel-2 o valor foi de 0,64 ($L=0,25$), explicando 64% da variância da variável dependente. A Raiz do Quadrado Médio do Erro (RQME) foi de 0,58 ($L= 0,25$) para Landsat-8, enquanto para Sentinel-2 o valor foi de 0,66 ($L=0,25$).

Tabela 17: Coeficiente de determinação (r^2), Índice de concordância de Willmott (d) e Raiz do Quadrado Médio do Erro (RQME).

	IAF					
	Landsat-8			Sentinel-2		
	1	0,50	0,25	1	0,50	0,25
RQME	1,12	0,82	0,58	1,25	1,02	0,66
R²	0,18	0,17	0,12	0,43	0,43	0,64
d	0,28	0,72	0,86	0,54	0,70	0,87

A caracterização da variação anual das condições meteorológicas e o comportamento do crescimento da vegetação tornam-se fundamental para nortear práticas de manejo, auxiliar no desenvolvimento de modelos para projeção e com isso prever rendimento e efetuar diagnósticos relativos ao desenvolvimento da vegetação. A diferença entre os resultados encontrados para os IVs (S2) considerando os IVs (L8) pode ser decorrente da data de aquisição das imagens por se tratar de diferentes plataformas, incidência de chuva, nebulosidade e influência da resolução espacial. Recomenda-se para estudos posteriores a caracterização desse comportamento temporal por um maior número de imagens, de forma a comparar comportamentos de sazonalidade em diferentes épocas e anos.

O estudo demonstrou que os resultados apresentados com o processamento das imagens LC8 e S2 podem capturar e auxiliar no monitoramento da dinâmica sazonal por meio dos índices, identificar variação no crescimento vegetativo em período seco e chuvoso. Os índices quando associados aos dados de campo fornecem informações importantes sobre o crescimento e vigor da vegetação e a integração das imagens de diferentes satélites pode viabilizar a caracterização ao longo do tempo e suprimir limitações como nebulosidade e longo período de revisita apresentado pela plataforma. Os dados do processamento das imagens orbitais com os obtidos em campo resultaram no valor de $L= 0,25$ como indicado para a condição da área experimental do estudo.

Vale ressaltar que os resultados desse trabalho direcionam para as vantagens que a aplicação de ferramentas digitais, sensores e equipamentos, podem auxiliar na tomada de decisões e com isso oferecer ganhos na produtividade, redução do impacto ambiental e otimização no uso de insumos em geral.

6. CONCLUSÕES

Diante do exposto, este trabalho avaliou a aplicação de índices de vegetação obtidos por sensoriamento remoto e medidas *in situ*, a fim de caracterizar e quantificar a variabilidade espacial e temporal de uma pastagem no município de Cachoeiras de Macacu, RJ. O estudo indica a variabilidade da pastagem em decorrência de fatores climáticos e do pastoreio. Para uma escala local, os índices de vegetação NDVI e SAVI obtidos dos produtos Landsat-8 e Sentinel-2 apresentam capacidade para monitorar o comportamento sazonal da pastagem, sendo o índice $L = 0,25$ indicado para a condição da área experimental do estudo.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ALLEN, R. G.; TASUMI, M.; TREZZA, R.; WATERS, R.; BASTIAANSSEN, W. Surface Energy Balance Algorithms for Land (SEBAL). **Advanced Training and users Manual**, Kimberly, Idaho, v.1, 97p. 2002.

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

ATZBERGER, Clement *et al.* Comparative analysis of different retrieval methods for mapping grassland leaf area index using airborne imaging spectroscopy. **International Journal of Applied Earth Observation and Geoinformation**, v. 43, p. 19-31, 2015.

BADIA, N. et al. Using Sentinel-2 images to implement Precision Agriculture techniques in large arable fields: First results of a case study. **Advances in Animal Biosciences**, v. 8, n. 2, p. 377-382, 2017.

BATISTELLA, M.; ANDRADE, R.G.; BOLFE, É.L.; VICTORIA, D.C.; SILVA, G.B.S. Geotecnologias e gestão territorial da bovinocultura no Brasil. **Revista Brasileira de Zootecnia**, v. 40, supl. especial, p. 251-260, 2011.

BELLA, D.; FAIVRE, R.; RUGET, F.; SEGUIN, B.; GUÉRIF, M.; COMBAL, B.; WEISS, M.; REBELLA, C.; DI BELLA, D. Remote sensing capabilities to estimate pasture production in France. **International Journal of Remote Sensing**, v. 25, n. 23, p. 5359–5372, 2004.

CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. 5. ed. Nova York: Guilford Press, 2011.

CEZAR, I. M.; QUEIROZ, H. P. de; THIAGO, L. R. L. de S.; GARAGORRY, F. L.; COSTA, F. P. **Sistemas de produção de gado de corte no Brasil: uma descrição com ênfase no regime alimentar e no abate**. Campo Grande: Embrapa Gado de Corte, 2005.

Chavez Jr., P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459-479, 1988.

CONGEDO, Luca. Semi-automatic classification plugin documentation. **Release**, v. 4, n. 0.1, p. 29, 2016.

CORRÊA, L. de A.; SANTOS, P. M. Irrigação de pastagens formadas por gramíneas forrageiras tropicais. **Embrapa Pecuária Sudeste-Circular Técnica (INFOTECA-E)**, São Carlos, 2006.

CRISPIM, Sandra Mara Araújo; DOMINGOS BRANCO, O. Aspectos gerais das braquiárias e suas características na sub-região da Nhecolândia, Pantanal, MS. **Embrapa Pantanal-Boletim de Pesquisa e Desenvolvimento (INFOTECA-E)**, Corumbá: Embrapa Pantanal, 2002.

CHUVIECO, Emilio; SALAS, Javier. Mapping the spatial distribution of forest fire danger using GIS. **International Journal of Geographical Information Science**, v. 10, n. 3, p. 333-345, 1996.

DARVISHZADEH, Roshanak *et al.* Estimation of vegetation LAI from hyperspectral

reflectance data: Effects of soil type and plant architecture. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, n. 3, p. 358-373, 2008.

DARVISHZADEH, Roshanak *et al.* Mapping grassland leaf area index with airborne hyperspectral imagery: A comparison study of statistical approaches and inversion of radiative transfer models. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 6, p. 894-906, 2011.

DECAGON DEVICES. Accupar LP80. Disponível em: <<http://www.decagon.com.br/dossel/luz/accupar/>>. Acesso em: fev. 2019.

DIAS-FILHO, Moacyr Bernardino. **Degradação de pastagens: processos, causas e estratégias de recuperação**. 4ª ed. Belém: MBDF, 2011.

DIAS-FILHO, Moacyr Bernardino. Degradação de pastagens. Brasil, p. 62, 2005.

DI MAIO, A. FRIEDRICH, T. MORAES, E. PEREIRA, G. MOREIRA, M. SAUSEN, T. FLORENZANO, T. Sensoriamento Remoto. Brasil, 2018. Disponível em: http://www.cdcc.usp.br/cda/oba/aeb/sensoriamento_remoto_alta_resolucao_2008.pdf. Acesso em 28 abr. 2020.

DRUSCH, M.; BELLO, U. del; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. **Remote Sensing Of Environment**, v. 120, p. 25-36, 2012. <http://dx.doi.org/10.1016/j.rse.2011.11.026>.

DUSSEUX, Pauline; CORPETTI, Thomas; HUBERT-MOY, Laurence; CORGNE, Samuel. Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring. **Remote Sensing**, v. 6, n. 7, p. 6163-6182, 2014. <http://dx.doi.org/10.3390/rs6076163>.

ESCADA, Maria Isabel Sobral; VIEIRA, Ima Célia G.; KAMPEL, Silvana A.; ARAËJO, Roberto; VEIGA, Jonas Bastos da; AGUIAR, Ana Paula Dutra; VEIGA, Iran; OLIVEIRA, Myriam; PEREIRA, Jorge Luís Gavina; CARNEIRO FILHO, Arnaldo. Processos de ocupação nas novas fronteiras da Amazônia: o interflúvio do xingu/ iriri. **Estudos Avançados**, v. 19, n. 54, p. 9-23, 2005. <http://dx.doi.org/10.1590/s0103-40142005000200002>.

ESCOLÀ, A.; BADIA, N.; ARNÓ, J.; MARTÍNEZ-CASASNOVAS, J.A. Using Sentinel-2 images to implement Precision Agriculture techniques in large arable fields: first results of a case study. **Advances In Animal Biosciences**, v. 8, n. 2, p. 377-382, 2017. <http://dx.doi.org/10.1017/s2040470017000784>.

European Space Agency (ESA). Global monitoring for environment and security (GMES). Disponível em: <http://www.esa.int/About_Us/Ministerial99_Council_2012/Global_Monitoring_for_Environment_and_Security_GMES>. Acesso em: 9 fev. 2019.

ESA. European Space Agency. Multispectral instrument (MSI) overview. Disponível em: <<https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>>. Acesso em: 7 mar. 2018.

FEITOSA, João Roberto Pinto. Uso de técnica de sensoriamento remoto e imagens Landsat-TM e NOAA-AVHRR na estimativa de balanço de energia à superfície. 2005. 183f. Tese (Doutorado em Recursos Naturais), Programa de Pós-graduação em Recursos Naturais, Centro de Tecnologias e Recursos Naturais, Universidade Federal de Campina Grande, Paraíba, 2005.

FOOD AND AGRICULTURE ORGANIZATION (FAO). World agriculture: towards 2015/2030 - Prospects by Major Sector. Roma, 2003. World agriculture: Statistics. Roma, 2013. Disponível em: <<http://www.fao.org/statistics/en/>>. Acesso em: 18 jun. 2019.

FORMAGGIO, Antonio Roberto; SANCHES, Ieda Del'Arco. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017.

FRAMPTON, William James; DASH, Jadunandan; WATMOUGH, Gary; MILTON, Edward James. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal Of Photogrammetry And Remote Sensing**, v. 82, p. 83-92, 2013. <http://dx.doi.org/10.1016/j.isprsjprs.2013.04.007>.

FRIEDL, M. A.; SCHIMEL, D. S.; MICHAELSEN, J.; DAVIS, F. W.; WALKER, H. Estimating grassland biomass and leaf area index using ground and satellite data. **International Journal Of Remote Sensing**, v. 15, n. 7, p. 1401-1420, 1994. <http://dx.doi.org/10.1080/01431169408954174>.

GHELFI FILHO, Hugo. **Efeito da irrigação sobre a produtividade do capim elefante (pennisetum purpureum schum.) Variedade napier**. 1972. 77 f. Tese (Doutorado) - Escola Superior de Agricultura Luiz de Queiros, Universidade de São Paulo, Piracicaba, 1972.

GOWER, Stith T.; KUCHARIK, Chris J.; NORMAN, John M. Direct and Indirect Estimation of Leaf Area Index, fAPAR, and Net Primary Production of Terrestrial Ecosystems. **Remote Sensing Of Environment**, v. 70, n. 1, p. 29-51, 1999. [http://dx.doi.org/10.1016/s0034-4257\(99\)00056-5](http://dx.doi.org/10.1016/s0034-4257(99)00056-5).

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing Of Environment**, v. 25, n. 3, p. 295-309, 1988. [http://dx.doi.org/10.1016/0034-4257\(88\)90106-x](http://dx.doi.org/10.1016/0034-4257(88)90106-x).

IBGE. Instituto Brasileiro de Geografia e Estatística. Censo Agropecuário 2017. Rio de Janeiro, 2017. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_definitivos.pdf>. Acesso em: 20 abr. 2019.

Janssen, L.L.F. Introduction to remote sensing. In: Janssen, L.L.F., Huurnemann (Eds). Principles of remote sensing. 2.ed. Enschede: ITC. 2001. p.41-53.

LACA, E.A. Pastoreo de precisión. In: **Bioma Campos: innovando para mantener su sustentabilidad y competitividad**. Montevideo: Tradinco, 2008, v.1, p.29-40.

LATAWIEC, A.e.; STRASSBURG, B.B.N.; VALENTIM, J.F.; RAMOS, F.; ALVES-PINTO, H.N. Intensification of cattle ranching production systems: socioeconomic and environmental synergies and risks in Brazil. **Animal**, v. 8, n. 8, p. 1255-1263, 2014. <http://dx.doi.org/10.1017/s1751731114001566>.

LILLESAND, Thomas; KIEFER, Ralph W.; CHIPMAN, Jonathan. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 1993.

LIU, William Tse Horng. **Aplicações de sensoriamento remoto**. São Paulo: Oficina de Textos, 2015.

LIU, William Tse Horng. **Aplicações de sensoriamento remoto**. São Paulo: Oficina de Textos, 2006. Disponível em: <https://books.google.com.br/books?id=YNEtCQAAQBAJ&printsec=frontcover&hl=ptBR#v=onepage&q&f=false>. Acesso em 12.07.2019.

MARTÍNEZ, Luis Joel Martínez. Relationship between crop nutritional status, spectral measurements and Sentinel 2 images. **Agronomía Colombiana**, v. 35, n. 2, p. 205-215, 2017. <http://dx.doi.org/10.15446/agron.colomb.v35n2.62875>.

MARTINS, S. C. F. **Evapotranspiração real pelo método do balanço de energia - Razão de Bowen em área de pastagem na região metropolitana do Rio de Janeiro**. Dissertação (Mestrado em Engenharia Agrícola e Ambiental) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2019.

MENESES, Paulo Roberto; ALMEIDA, Tati de. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: Conselho Nacional de Desenvolvimento Científico e Tecnológico, 2012.

MERRY, Frank; SOARES-FILHO, Britaldo. Will intensification of beef production deliver conservation outcomes in the Brazilian Amazon? **Elementa: Science of the Anthropocene**, v. 5, p. 24, 2017. <http://dx.doi.org/10.1525/elementa.224>.

NETO, A. L.; SVICERO, E. F.; BARROS, J. C. B. V. Manejo de plantas daninhas em pastagens. In: PIRES, WAGNER (Org.). **Manual de pastagens: formação, manejo e recuperação**. 1. ed. Viçosa: Editora Aprenda Fácil, 2006. p. 302.

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. São Paulo: Editora Blucher, 2008.

Organização das Nações Unidas para Alimentação e Agricultura. FAO, 2020. Pecuária sustentável e mudanças climáticas na América Latina e no Caribe. Disponível em: <http://www.fao.org/americas/prioridades/ganaderia-sostenible/pt/>. Acesso em: 25 jul. 2020.

PASOLLI, Edoardo; YANG, Hsiuhan Lexie; CRAWFORD, Melba M. Active-metric learning for classification of remotely sensed hyperspectral images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 4, p. 1925-1939, 2015.

PINHEIRO, Fernanda da Silva; LYRA, Gustavo Bastos; ABREU, Marcel Carvalho; ARTHUR JUNIOR, José Carlos; SILVA, Leonardo Duarte Batista da; LYRA, Guilherme Bastos; SANTOS, Ednaldo Oliveira dos. Área foliar de mudas de urucum (*Bixa orellana* L.) estimada por diferentes métodos: uma análise comparativa. **Ciência Florestal**, v. 30, n. 3, p. 885-897, 2020. <http://dx.doi.org/10.5902/1980509840896>.

PONZONI, F. J.; SHIMABUKURU, Y.E. Sensoriamento remoto no estudo da vegetação. São José dos Campos: A. Silva Vieira, 2009. 127 p.

PONZONI, Flávio Jorge; SHIMABUKURO, Yosio Edemir; KUPLICH, Tatiana Mora. **Sensoriamento remoto da vegetação**. São Paulo: Oficina de Textos, 2015.

PULLANAGARI, R.R.; YULE, I.; KING, W.; DALLEY, D.; DYNES, R. The use of optical sensors to estimate pasture quality. **International Journal On Smart Sensing And Intelligent Systems**, v. 4, n. 1, p. 125-137, 2011. <http://dx.doi.org/10.21307/ijssis-2017-430>.

QGIS. Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation Project. 2015. Disponível em: <http://qgis.osgeo.org>. Acesso em: 23 set. 2015.

QI, J.; CHEHBOUNI, A.; HUETE, A.R.; KERR, Y.H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing Of Environment**, v. 48, n. 2, p. 119-126, 1994. [http://dx.doi.org/10.1016/0034-4257\(94\)90134-1](http://dx.doi.org/10.1016/0034-4257(94)90134-1).

RIBEIRO, T. B. et al. Características forrageiras de algumas gramíneas do gênero *Brachiaria*-Revisão de literatura. **Nutritime Revista Eletrônica**, v. 13, n. 4, p. 4773-4780, 2016.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. 2004. 212 f. Tese (Doutorado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais, São José dos Campos (SP), 2004.

RODRIGUES, Elisângela Ronconi. **Controle biológico de *Brachiaria decumbens* Stapf em área de reserva legal em processo de recuperação, na região do Pontal do Paranapanema, São Paulo, Brasil**. 2010. 77 f. Tese (Doutorado) - Universidade Estadual Paulista, Instituto de Biociências de Rio Claro, 2010.

ROUSE, John Wilson et al. Monitoring vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351, n. 1974, p. 309, 1974.

SCHINDELIN, Johannes; ARGANDA-CARRERAS, Ignacio; FRISE, Erwin; KAYNIG, Verena; LONGAIR, Mark; PIETZSCH, Tobias; PREIBISCH, Stephan; RUEDEN, Curtis; SAALFELD, Stephan; SCHMID, Benjamin. Fiji: an open-source platform for biological-image analysis. **Nature Methods**, v. 9, n. 7, p. 676-682, 2012. <http://dx.doi.org/10.1038/nmeth.2019>.

SILVA, Samuel; FERRARI, Jéferson Luiz. Descrição Botânica, Distribuição Geográfica e Potencialidades de Uso da *Brachiaria brizantha* (Hochst. ex. A. Rich) Stapf. **Enciclopédia Biosfera**, Goiânia, v. 8, n. 14, 2012.

VALENCIA, Lady Victoria Angulo. **Comportamento espectral das culturas de milho, arroz e soja, usando imagens dos satélites Sentinel-2, Cbers-4 e Landsat-8**. 2020. 116 f. Dissertação (Mestrado em Ciências e Aplicações Geoespaciais) - Universidade Presbiteriana Mackenzie, São Paulo, 2020.

VICENTE, Luiz Eduardo; GOMES, Daniel; VICTORIA, Daniel de Castro; GARÇON, Edlene Aparecida Monteiro; BOLFE, Édson Luis; ANDRADE, Ricardo Guimarães; SILVA, Gustavo Bayma Siqueira da. Séries temporais de NDVI do sensor SPOT Vegetation e algoritmo SAM aplicados ao mapeamento de cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1337-1345, 2012. <http://dx.doi.org/10.1590/s0100-204x2012000900019>.

WILLMOTT, Cort J. On the validation of models. **Physical geography**, v. 2, n. 2, p. 184-194, 1981. <http://dx.doi.org/10.1080/02723646.1981.10642213>.

ZHANG, Xin; WU, Bingfang; PONCE-CAMPOS, Guillermo; ZHANG, Miao; CHANG, Sheng; TIAN, Fuyou. Mapping up-to-Date Paddy Rice Extent at 10 M Resolution in China through the Integration of Optical and Synthetic Aperture Radar Images. **Remote Sensing**, v. 10, n. 8, p. 1200, 2018. <http://dx.doi.org/10.3390/rs10081200>.