

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

FACULDADE DE AGRONOMIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

GERMANA MARQUES DE SANTO

**Estimativa de Massa de Forragem em diferentes fitosionomias dos Campos Sulinos
do Brasil através de imagens de satélite**

Porto Alegre

Abril de 2023

GERMANA MARQUES DE SANTO

**Avaliação da Massa de Forragem de Campo Nativo através de imagens de satélite
ao longo do ano em diferentes regiões do estado do Rio Grande do Sul, Brasil**

Dissertação apresentada como requisito para obtenção do Grau de Mestre em Zootecnia, no Programa de Pós-Graduação em Zootecnia, da Universidade Federal do Rio Grande do Sul.

Orientador: César Henrique Espírito Candal Poli

Coorientador: Carolina Bremm

Porto Alegre

Abril de 2023

CIP - Catalogação na Publicação

de Santo, Germana Marques
Estimativa de Massa de Forragem em diferentes
fitosionomias dos Campos Sulinos do Brasil através de
imagens de satélite / Germana Marques de Santo. --
2023.

74 f.

Orientador: César Henrique Espírito Candal Poli.

Coorientadora: Carolina Bremm.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Faculdade de Agronomia, Programa de
Pós-Graduação em Zootecnia, Porto Alegre, BR-RS, 2023.

1. Campos Sulinos. 2. Sensoriamento Remoto. 3.
Zootecnia. 4. Produção Vegetal. I. Espírito Candal
Poli, César Henrique, orient. II. Bremm, Carolina,
coorient. III. Título.

GERMANA MARQUES DE SANTO
Bióloga

DISSERTAÇÃO

Submetida como parte dos requisitos
para obtenção do Grau de

MESTRE EM ZOOTECNIA

Programa de Pós-Graduação em Zootecnia
Faculdade de Agronomia
Universidade Federal do Rio Grande do Sul
Porto Alegre (RS), Brasil

Aprovada em: 11.04.2023
Pela Banca Examinadora

Homologado em: 07/06/2023
Por

DocuSigned by:
Carolina Bremm
8CE25AB046324B1...
CAROLINA BREMM
PPG Zootecnia/UFRGS
Coorientadora

Sergio Luiz Vieira
Assinado de forma digital por
Sergio Luiz Vieira
Dados: 2023.06.21 19:32:02 -03'00'

Sergio Luiz Vieira
Coordenador do Programa de
Pós-Graduação em Zootecnia

DocuSigned by:
Denise Fontana
B705DC6CE09449B...
Denise Cybis Fontana
UFRGS

DocuSigned by:
Christian Bredemeier
ECDA4416160D459...
Christian Bredemeier
UFRGS

DocuSigned by:
Carlos Nabinger
FF7F4BB3046A4A2...
Carlos Nabinger
UFRGS

Documento assinado digitalmente
gov.br CARLOS ALBERTO BISSANI
Data: 22/06/2023 15:06:50-0300
Verifique em <https://validar.iti.gov.br>

CARLOS ALBERTO BISSANI
Diretor da Faculdade de Agronomia

AGRADECIMENTOS

Aos meus pais, Miguelina e Pedro, por todo o suporte e a base que me deram durante toda a minha trajetória de vida, por oportunizarem minha dedicação exclusiva aos estudos e por me apoiarem nas minhas decisões. Aos meus irmãos, Pedro e Thais, pelo apoio e pelo carinho dedicados a mim. Aos meus sobrinhos, João Bernardo, Ana Laura e Olívia, por serem minha alegria diária. Ao meu namorado e colega de profissão, Alexandre, pelo amor e pelo incentivo a sempre buscar novos desafios e me tornar uma pessoa melhor.

Aos meus amigos de infância, Gabriel e Felipe Albrecht Fitarelli, por todos os verões na praia, brincadeiras, histórias, jogatinas, maratonas, sorvetes e risadas que tivemos durante todos esses anos.

À Marta e ao Luís Carlos pelo apoio e por me acompanharem durante toda, literalmente, a minha trajetória estudantil.

Aos meus amigos de Colégio de Aplicação, Alexandra Kleinicke, Amanda Andrade, Ana Danielle Cavalheiro, Bruna da Silva, Ilon Oliveira, Lucas Greff e Luísa Saraiva por todos esses anos de amizade, por tantos momentos maravilhosos compartilhados e por fazerem parte da minha vida. E, principalmente, por mais tempo que ficamos sem se ver, a amizade continua.

À minha amiga e melhor presente da Biologia, Camila Armani, por compartilhar comigo o amor pela leitura, por filmes, seriados e Harry Potter, além de tantos momentos incríveis que estivemos juntas. Aos meus amigos da Biologia, que apesar da distância e da correria do dia a dia, tive e tenho o prazer de conviver e de poder chamar de amigos.

Ao meu orientador, César Poli, e a todo grupo CEPOV, por toda a orientação e pelo convívio. Muito obrigada a Lívia Irigoyen por estar comigo durante todo o experimento e por participar dele. À professora Carolina Bremm pela coorientação e pela ajuda na elaboração do trabalho.

À Capes pelo financiamento da minha bolsa-salário, viabilizando a minha permanência nesses dois anos de mestrado.

RESUMO

Os Campos Sulinos são as pastagens naturais da região Sul do Brasil e que apresentam alta diversidade vegetal e animal. São os campos dos biomas Pampa e Mata Atlântica. O Sensoriamento Remoto (SR) vem sendo utilizado em diversos estudos e os resultados são capazes de descrever o estado de conservação e produtividade da vegetação. Ainda é necessário averiguar sobre quais as melhores práticas e métodos a serem utilizados na caracterização e estimativa de massa de forragem nos ambientes campestres para compreender e aferir a massa de forragem através do Sensoriamento Remoto. O objetivo desse trabalho é correlacionar a massa de forragem de campo nativo de diferentes fitofisionomias do Rio Grande do Sul com índices de vegetação obtidos a partir de imagens do satélite Sentinel-2. Esse estudo foi realizado em nove locais que compreendem propriedades privadas e públicas no Rio Grande do Sul (Aceguá, Alegrete, Eldorado do Sul, Encruzilhada do Sul, Jaquirana, Lavras do Sul, São Francisco de Paula, Tavares e Vacaria). As amostras foram coletadas em dois a três piquetes de 70 x 70 m com diferentes massas de forragem em que se mediu a altura de forragem com as ferramentas *falling plate* e *sward stick* e se mediu a massa de forragem de forma direta através do corte da massa de forragem total contida em nove quadrados de 0,25m² por sítio de pesquisa. Para coleta das imagens, foi utilizado os dados do satélite SENTINEL-2 e gerados os valores de índices de vegetação (IVs). Foi realizado, posteriormente, a correlação entre os IVs com a altura e a massa de forragem coletada a campo. Os IVs utilizados são: NDVI, EVI, EVIB5, SAVI, Msavi2, NDWI, GLI, NDRE e PSRI. As análises estáticas realizadas foram análises de variâncias e Random Forest. Houve interação entre altura x ferramenta de medida x estação do ano ($p < 0,05$), gerando-se equações de regressão linear para cálculo da massa de forragem com base na altura do pasto medida com *falling plate* e com *sward stick* para as diferentes estações do ano. Na matriz de correlação, o EVIB5 foi o índice que mais se correlacionou com a altura do pasto. Para massa de forragem, massa verde, massa de material morto e massa de lâminas não houve um índice com maior correlação. Com a análise Random Forest, foram gerados diferentes modelos os que apresentaram maior R^2 foram os modelos para Massa de Forragem ($R^2 = 82,19$) e Massa Verde ($R^2 = 78,01$) Esses resultados dos Modelos de Regressão foram os mais promissores desse estudo.

Palavras chaves: Campos Sulinos; Índices de Vegetação; Sentinel-2; Estações do ano;

ABSTRACT

The Campos Sulinos are the natural pastures of the southern region of Brazil that have a high plant and animal diversity. These are the native grasslands of the Pampa and Atlantic Forest biomes. Remote Sensing (SR) has been used in several studies and the results are able to describe the state of conservation and productivity of the vegetation. It is still necessary to find out which are the best practices and methods to be used in the characterization and estimation of forage mass in rural environments to understand and measure the forage mass through Remote Sensing. The objective of this work is to correlate the forage mass of native grassland from different phytophysiognomies of Rio Grande do Sul with vegetation index obtained from Sentinel-2 satellite images. This study was carried out in nine sites comprising private and public properties (Aceguá, Alegrete, Eldorado do Sul, Encruzilhada do Sul, Jaquirana, Lavras do Sul, São Francisco de Paula, Tavares and Vacaria). Samples were collected from two to three 70 x 70 m paddocks in which the forage height was measured with the falling plate and sward stick tools, and the forage mass was measured directly by cutting the total forage mass contained in nine squares of 0.25m² per research site. Data from the SENTINEL-2 satellite was used to collect the images, and the values of vegetation indexes (VIs) were generated. The correlation between VIs with height and forage mass was subsequently performed. The VIs used are: NDVI, EVI, EVIB5, SAVI, Msavi2, NDWI, GLI, NDRE and PSRI. Analysis of variance and random forest analysis were performed. There was an interaction between sward height x measuring tool x season ($p < 0.05$), generating linear regression equations to calculate forage mass based on pasture height measured with sward stick and falling plate for the different seasons of the year. In the correlation matrix, EVIB5 was the index that most correlated with pasture height. For forage mass, green mass, dead material mass and blade mass there was no index with higher correlation. With the Random Forest analysis, different models were generated, those that presented the highest R² were the models for Forage Mass (R² = 82.19) and Green Mass (R² = 78.01). These results from the Regression Models were the most promising in this study.

Keywords: Southern Grasslands; Vegetation Indexes; Sentinel-2; Seasons;

LISTA DE FIGURAS

Figura 1. Localização dos sítios de pesquisa onde foram realizadas as coletas de campo e as diferentes fitofisionomias dos Campos Sulinos localizados nos biomas Pampa e Mata Atlântica no RS	36
Figura 2. Índices de vegetação e suas respectivas fórmulas.....	40
Figura 3. Gráfico de dispersão da Massa de Forragem – MF seca (kg/ha) do campo nativo relacionada as medições de alturas com falling plate (cm) e sward-stick (cm) por estação do ano.....	43
Figura 4. Plot entre ALT, MF, ML, MV e MMM e Índices de Vegetação	44
Figura 5. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa de Forragem. (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Forragem (B)	47
Figura 6. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa Verde (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa Verde (B).	49
Figura 7. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa de Material Morto (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Material Morto (B).	51
Figura 8. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa de Lâminas (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Lâminas (B).	53

LISTA DE TABELAS

Tabela 1. Bandas do satélite Sentinel-2 e suas respectivas descrições.....	39
Tabela 2 - Equações de regressão linear para estimativa de massa de forragem (kg MS/ha) dos Campos Sulinos através do falling plate e sward-stick.....	42
Tabela 3. Clusters com as respectivas MF, MV e MMM.....	45
Tabela 4. Valores de contribuição das classes e dos IVs no modelo para Massa de Forragem.....	46
Tabela 5. Valores de contribuição das classes e dos IV's no modelo para Massa Verde	48
Tabela 6. Valores de contribuição das classes e dos IVs no modelo para Massa de Material Morto.....	50
Tabela 7. Valores de contribuição das classes e dos IVs no modelo para Massa de Lâminas	52

LISTA DE ABREVIATURAS

ALT Altura

ANN Rede Neural Artificial

CE Comissão Europeia

Cfa Clima Subtropical Úmido

Cfb Clima temperado Úmido

EEA/UFRGS Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul

ESA Agência Espacial Europeia

EVI Enhanced Vegetation Index

EVIB5 Enhanced Vegetation Index B5

IAF Índice de Área Foliar

IV Índice de Vegetação

GLI Green leaf index

MF Massa de Forragem

ML Massa de Lâminas

MMM Massa de Material Morto

MS Matéria Seca

MV Massa Verde

MSI Instrumento Multiespectral

MSAVI2 Modified Soil Adjusted Vegetation Index 2

NBDI Índice de profundidade de banda normalizado

NDRE Normalized Difference Red Edge

NDVI Normalized Difference Vegetation Index

NDWI Normalized Difference Water Index

OF Oferta de Forragem

PELD Pesquisa Ecológica de Longa Duração

PR Paraná

PSRI Plant senescence reflectance index

RFAA Radiação Fotossinteticamente Absorvida

RS Rio Grande do Sul

SAVI Soil-Adjusted Vegetation Index

SC Santa Catarina

SR Sensoriamento Remoto

TA Taxa de acúmulo

TSAVI SAVI Transformado

WDVI Índice de Vegetação por Diferença Ponderada

SÚMARIO

1. INTRODUÇÃO.....	13
2. HIPÓTESES.....	16
3.OBJETIVOS.....	16
3.1 Objetivos Gerais.....	16
3.2 Objetivos Específicos.....	16
4. REVISÃO BIBLIOGRÁFICA.....	17
4.1 Campos Sulinos.....	17
4.2 Produção de ruminantes nas pastagens nativas do Rio Grande do Sul.....	20
4.3 Produção de massa de forragem.....	21
4.4 Sensoriamento Remoto.....	23
4.5 Random Forest.....	32
5. MATERIAL E MÉTODOS.....	34
5.1 Época e locais.....	34
5.2 Tratamento e manejo experimental.....	36
5.3 Massa e altura de forragem.....	38
5.4 Coleta e processamento da imagem.....	39
5.5 Análise estatística.....	41
6. RESULTADOS.....	42
6.1 Equações de Regressão.....	42
6.2 Matriz de Correlação.....	43
6.3 Análise de Agrupamento.....	44
6.4 Random Forest para Massa de Forragem.....	45
6.5 Random Forest para Massa Verde.....	47
6.6 Random Forest para Massa de Material Morto.....	49
6.7 Random Forest para Massa de Lâminas.....	51
7. DISCUSSÃO.....	54
7.1 Equações de Regressão.....	54
7.2 Matriz de Correlação.....	56
7.3 Random Forest para Massa de Forragem (MF), Massa Verde (MV), Massa de Material Morto (MMM) e Massa de Lâminas (ML).....	57
8. CONCLUSÃO.....	61
9. REFERÊNCIAS BIBLIOGRÁFICAS.....	62

1. INTRODUÇÃO

Os Campos Sulinos são as pastagens naturais da região Sul do Brasil e que apresentam alta diversidade vegetal e animal (Boldrini, 2009; Pillar *et al.*, 2009), e constituem a base alimentar para a pecuária na região, contribuindo para o diferencial econômico e ecológico da atividade no país (Nabinger, 2006; Nabinger e Carvalho, 2009). São os campos dos biomas Pampa e Mata Atlântica (Pillar *et al.*, 2009). Esses campos, quando bem manejados, além de proverem forragens para a produção de produtos de origem animal, fornecem serviços ecossistêmicos como, por exemplo, a conservação dos recursos hídricos e a mitigação da emissão de gases do efeito estufa oriundos de outras atividades econômicas (Sarmiento, Macedo e Ramborger, 2020).

A pecuária nos Campos Sulinos é uma atividade desenvolvida principalmente em pastagem nativa, de maneira extensiva e com baixos índices produtivos. Dessa forma, apesar da importância dessas pastagens para a manutenção do equilíbrio ecológico, há um aumento na eliminação e na transformação dessas pastagens pelo excesso de carga animal e expansão de outras atividades agrícolas, como o cultivo de grãos, pastagens cultivadas e silvicultura (Nabinger, 2006; Nabinger; Carvalho, 2009). Esta situação pode ser reduzida, ou até mesmo revertida, desde que haja alternativas econômicas para assegurar a permanência da pecuária em pastagens nativas (Nabinger, 2006).

Apesar de os campos sulinos terem a sua importância reconhecida para a manutenção do equilíbrio ecológico, tem se observado uma crescente pressão econômica pela transformação ou até mesmo eliminação destes campos, tanto via conversão para outras atividades agrícolas como via utilização de excessivas cargas animais (Nabinger *et al.*, 2009). Menezes, Silveira e Overbeck (2021a) destacam que a maioria das áreas remanescentes dos Campos Sulinos está sob manejo pastoril. A pecuária em campo nativo é uma possibilidade de aliar a produção animal com a conservação da biodiversidade, mantendo importantes serviços ecossistêmicos fornecidos pelos campos, além da cultura gaúcha.

O Sensoriamento Remoto (SR) vem sendo utilizado em diversos estudos e os resultados são capazes de descrever o estado de conservação e produtividade da vegetação, além de ser possível identificar a ocorrência de perturbações condicionadas por alterações climáticas. A partir do uso de imagens de satélite é possível conhecer,

avaliar e monitorar continuamente os processos dinâmicos da vegetação (Moreira, 2018).

A avaliação e quantificação de massa de forragem por sensoriamento remoto (SR) ainda precisa ser aprimorada, sendo necessário que se realizem mais pesquisas para melhor compreender e identificar os métodos mais adequados para minimização das falhas, pois o desempenho dos dados de sensoriamento remoto e métodos de estimativa da massa de forragem são altamente dependentes da imagem, dos tipos de dados coletados, tipo e estado da cobertura vegetal, condições e métodos geográficos e ambientais usados (Kumar *et al.*, 2015). Igualmente é necessário averiguar quais as melhores práticas e métodos a serem utilizados na caracterização e medição *in loco* da massa de forragem nos ambientes campestres para compreender e aferir a massa de forragem estimada através do SR (Jia *et al.*, 2016).

Imagens e dados obtidos por SR são ferramentas importantes na caracterização de ambientes naturais ou manejados, pois cobrem extensas áreas e tornam possíveis os mapeamentos de larga escala. Dependendo da consistência e estabilidade da variável estudada, possibilitam a extrapolação das relações obtidas em regiões específicas (Kuplich *et al.*, 2016).

O estudo de ecossistemas campestres com dados de SR já apresenta alguns resultados que demonstram a possibilidade de monitoramento da produtividade de forragem, já que a métricas fenológicas dos campos exhibe padrões característicos registráveis (Hill *et al.*, 2004). Entretanto, mesmo já havendo usos comprovados dos dados de SR para ecossistemas campestres, ainda é necessário conhecimento sobre o comportamento espectral e espacial das tipologias campestres com suas diversas características funcionais. Com o auxílio do SR, podem ser gerados diversos dados como, por exemplo, mapas de cobertura da terra para áreas com diferentes usos e mapas específicos com a apresentação de variáveis representativas do funcionamento dos ecossistemas em estudo, como a massa de forragem (Guerini Filho, *et al.*, 2018).

Estudos com campo nativo vem sendo realizados no Uruguai e que demonstram o uso do SR. No estudo realizado por Ceroni, Achkar e Gazzano (2013) em campo nativo uruguaio, utilizou-se dados de NDVI (*Normalized Difference Vegetation Index*) obtidos a partir de SR nas diferentes estações do ano (outono, inverno, primavera e verão). Observou-se que, para a série temporal analisada, houve a existência de uma

tendência significativa de queda do NDVI, que pode ser explicado por uma mudança na cobertura do solo, aumento da variabilidade climática, evidenciado pela recorrência de eventos extremos, como seca e inundações. Observou-se, também, que a primavera é a estação com maior média de NDVI, enquanto que o inverno é a estação com menor média. As diferenças entre as estações do ano são o resultado da variabilidade intra-anual da quantidade de radiação solar disponível e precipitação. Os valores intermediários de NDVI (entre 0,66 e 0,75) ocupam as áreas onde predomina a pecuária extensiva.

2. HIPÓTESES

Existe relação entre massa de forragem do campo nativo e os índices de vegetação obtidos por sensor remoto orbital nas diferentes fitofisionomias do Rio Grande do Sul ao longo das estações do ano.

É possível estimar a massa de forragem dos campos sulinos através da medida da altura do pasto usando *falling plate* e *sward stick*.

3. OBJETIVOS

3.1 Objetivo Geral:

Correlacionar a massa de forragem de campo nativo de diferentes fitofisionomias do Rio Grande do Sul com índices de vegetação obtidos a partir de imagens do satélite Sentinel-2.

Estimar a massa de forragem dos campos sulinos através da medida da altura do pasto usando *falling plate* e *sward stick*.

3.2 Objetivos Específicos:

Identificar entre os Índices de Vegetação gerados qual possui maior potencial para estimar a massa de forragem.

Indicar qual a ferramenta que melhor estima a massa de forragem a partir da altura da pastagem, se é o *falling plate* ou *sward stick*.

4. REVISÃO BIBLIOGRÁFICA

4.1 Campos Sulinos

Campos Sulinos é um termo usado para denominar as regiões campestres nos estados da região Sul do Brasil: Rio Grande do Sul (RS), Santa Catarina (SC) e Paraná (PR). Os Campos Sulinos são ecossistemas naturais que integram os campos do sul do Brasil, tanto do bioma Pampa, quanto no bioma Mata Atlântica, onde ocorrem em mosaicos com florestas de Araucária (Menezes, Silveira e Overbeck, 2021b). Possuem alta diversidade de espécies vegetais e animais, possuindo tanto função ecológica quanto econômica, por serem a principal fonte forrageira para a pecuária do RS (Carvalho *et al.*, 2006; Pillar *et al.*, 2012). Segundo Andrade *et. al* (2023), existem 12503 espécies na região, sendo a biodiversidade distribuída entre plantas, fungos, bactérias e animais.

Os Campos Sulinos estão presentes em dois biomas brasileiros, o Pampa e a Mata Atlântica. O bioma Pampa estende-se pela metade sul do RS, com uma área de aproximadamente de 17,6 milhões de ha, ocupando até o início do presente século 63% do território gaúcho e 2,1% do território nacional (IBGE, 2004). O bioma Pampa também se estende por todo o Uruguai e parte da Argentina, sendo um dos principais ecossistemas campestres de clima temperado da América do Sul (Chomenko; Benck, 2016).

Segundo a classificação de Köppen, o bioma Pampa possui o clima do tipo Cfa. A temperatura média anual varia entre 13,4°C e 25,6°C com precipitação média de 1600 mm por ano (INMET, 2020). As condições edafo-climáticas possibilitam a presença de várias formações vegetacionais nesse bioma, aumentando a biodiversidade e contribuindo para a complexidade e heterogeneidade forrageira das áreas de campos. Essa complexidade forrageira se deve pela presença de espécies forrageiras de clima tropical e subtropical, com ciclo fotossintético C4, e a presença de espécies de clima temperado, com ciclo fotossintético C3, além de diversas espécies de outras famílias botânicas (Boldrini, 1997, 2006), totalizando mais de 3600 espécies vegetais vasculares (Andrade *et al.*, 2023).

O bioma Mata Atlântica inclui áreas de campos no planalto sul-brasileiro distribuídos desde o norte do RS até o PR, formando mosaicos com as florestas (Overbeck *et al.*, 2009, 2015). Segundo o Ministério do Meio Ambiente, os campos

desse bioma são denominados de “Campos de Altitude”, e são conhecidos no RS como Campos de Cima da Serra, região da qual fazem parte (Fortes, 1959).

Segundo a classificação de Köppen, os Campos de Altitude possuem clima do tipo Cfb. A temperatura média anual varia entre 10,6°C e 21,5°C com precipitação média anual de 1800 mm (INMET, 2020). Apesar de haver condições climáticas para o desenvolvimento de espécies hibernais, há a predominância de espécies estivais. Isso ocorre, provavelmente, devido ao uso do fogo no início do desenvolvimento das espécies hibernais, com interesse no rebrote da vegetação para ser usada durante a primavera e verão para o consumo animal. Dessa forma, dificulta-se o florescimento e a frutificação das espécies hibernais (Boldrini, 2009). Assim, é típico da região a alta porcentagem de solo descoberto associada à dominância de espécies cespitosas eretas e de ciclo estival (Boldrini, 1997).

Apesar das diferenças na composição botânica entre os campos dos dois biomas, há um grande número de espécies vegetais que ocorrem em ambos os biomas (Overbeck *et al.*, 2015). Os Campos Sulinos possuem pastagens naturais com grande diversidade de espécies das famílias Poaceae, as gramíneas, e Fabaceae, as leguminosas. As gramíneas apresentam um alto valor forrageiro e são predominantes nas pastagens nativas do RS (Boldrini; Overbeck; Trevisan, 2015).

A dinâmica dos campos naturais possui relação direta com os aspectos edafoclimáticos das regiões, como vegetação, recursos hídricos e relevo. Segundo o Serviço Estadual de Geografia, aprovada pelo Conselho Nacional de Geografia em 1956, a divisão regional do Rio Grande do Sul é composta por 11 regiões fisiográficas, sendo elas: Litoral, Depressão Central, Missões, Campanha, Serra do Sudeste, Encosta do Sudeste, Alto Uruguai, Campos de Cima da Serra, Planalto Médio, Encosta Inferior do Nordeste, Encosta Superior do Nordeste (Pacheco, 1956). Cerca de 46,9% do RS ainda mantém sua vegetação nativa, constituída por 27,33% de campo e 19,59% de floresta (MAPBiomas, 2021). As áreas remanescentes de campo nativo encontram-se majoritariamente na região da Campanha, com áreas menos expressivas na Serra do Sudeste, Depressão Central, Campos de Cima da Serra, Litoral e Missões.

A cobertura vegetal influenciada pelas condições ambientais produz a matéria seca (MS) diariamente. A massa de MS produzida pela pastagem ao longo da estação de crescimento é o resultado da ação integrada entre altitude, tipo de solo, posição

topográfica, condições climáticas da região e flora (Maraschin, 2012), além das condições de manejo, representadas basicamente pela carga animal. Os solos influenciam a vegetação natural. Os solos rasos possuem menor capacidade de armazenamento de água, proporcionando estresse hídrico para as plantas, principalmente no verão. Contudo, quando há impedimento da drenagem do solo pelo excesso de água, as plantas também passam por estresse (Overbeck *et al.*, 2015). As condições climáticas sazonais estão relacionadas com a variação estacional da produção de forragem. O RS apresenta marcante variação climática ao longo do ano, sendo a presença de geadas comum no inverno e as altas temperaturas são frequentes no verão (Jochims *et al.*, 2017).

Sabe-se que a variabilidade climática afeta o crescimento da vegetação ao longo das estações do ano (Fontana *et al.*, 2018) e que as respostas ao clima variam conforme o genótipo da planta forrageira (Barioni *et al.*, 2006). As pastagens nativas do RS são formadas principalmente por espécies C4, que diminuem a sua capacidade de manter a produção de forragem no período de inverno (Moojen; Maraschin, 2002). Os efeitos da estação do ano indicam que o verão e a primavera são as estações em que ocorre aumento da massa de forragem, devido ao clima predominantemente favorável (Thurow *et al.*, 2009). O aumento da massa de forragem ocorrido no verão e primavera tende a diminuir no outono e inverno (Tiecher *et al.*, 2013), já que as variações de temperatura em função das estações do ano influenciam na produtividade das pastagens nativas do RS (Maraschin, 2012). No inverno, é comum ocorrer taxas de acúmulo negativas, explicado principalmente pela senescência foliar acarretada pelas baixas temperaturas (Carvalho *et al.*, 2006).

À medida que a planta cresce, acumula material senescente em sua base, havendo redução na taxa de acúmulo de MS. É na primavera em que normalmente ocorrem as maiores taxas de acúmulo de MS (Maraschin, 2001). O aumento das taxas de crescimento do pasto na primavera acarreta na aumento da altura do estrato inferior (plantas com crescimento prostrado ou rasteiro e com altura inferior a 15 cm), gerando maiores alturas da pastagem no verão. No outono e inverno, a altura do estrato inferior tende a diminuir devido à redução ou paralisação do crescimento das plantas e do pastejo preferencial dos animais neste estrato (Thurow *et al.*, 2009). No estudo de Neves *et al.* (2009) encontrou-se correlação positiva entre altura do pasto e a massa de forragem no estrato inferior, que aparentemente apresenta menor heterogeneidade

estrutural. Em ambientes muito heterogêneos como as pastagens nativas, pode-se obter de baixo grau de correlação entre essas variáveis.

A produção de MS das pastagens nativas é também afetada pela intensidade de pastejo, isto é, pela carga animal imposta ao campo (Maraschin, 2001; Moojen e Maraschin, 2002; Thurow et al., 2009, entre outros), que afeta a área foliar residual. Níveis de oferta de forragem adequados permitem que as pastagens mantenham mais folhas, mesmo após o pastejo, resultando em mais fotossíntese, maior absorção de carbono e maior crescimento das plantas (Nabinger, 2006). Quando há o aumento da intensidade de pastejo ocorre a redução da captação de energia solar em função diminuição do índice de área foliar (Carvalho; Batello, 2009), refletindo em menor taxa de acúmulo da forragem.

Menezes, Silveira e Overbeck (2021a) destacam que os campos sulinos foram historicamente utilizados para o pastoreio de animais domésticos, sem supressão da vegetação nativa, o que, sob determinadas condições, é reconhecido como uso sustentável nesse ambiente. De acordo Kuplich *et al.* (2016), além de representar a base forrageira para rebanhos que são um dos pilares da economia e cultura da região, os campos nativos asseguram serviços ecossistêmicos insubstituíveis, como a proteção dos recursos hídricos, solos, a manutenção da fauna e flora. Entretanto, de acordo com Nabinger *et al.* (2009), grande parte dos campos do Sul do Brasil apresenta-se em acentuado processo de degradação, devido à expansão da fronteira agrícola, em conjunto com excesso de carga animal além de capacidade de suporte destes ecossistemas. De acordo com Pillar *et al.*, (2009) corroborado por Baggio *et al.*, (2021) o manejo adequado, além tornar o uso pecuário altamente produtivo contribui para a manutenção da biodiversidade e dos processos ecossistêmicos nos campos sulinos.

4.2 Produção de ruminantes nas pastagens nativas do Rio Grande do Sul

A produção pecuária, de acordo com Nabinger e Carvalho (2009) é uma das principais atividades econômicas no sul do Brasil e tendo como base forrageira as pastagens nativas. O Rio Grande do Sul detém uma parcela significativa da produção pecuária nacional. A população de ruminantes está inserida principalmente na metade sul do estado e nos Campos de Cima da Serra, com maior concentração na região da Campanha e Serra da Sudeste.

Nabinger *et al.* (2006) destacam que em vista da tradição pecuarista do estado do Rio Grande do Sul, espera-se uma maior eficiência produtiva e econômica desta atividade. Porém, de acordo com Poli *et al.* (2009) a produção em grande parte das propriedades rurais no estado tem baixos índices produtivos, muitas vezes subestimando o campo natural como fonte de nutrientes. Os autores ainda destacam a baixa produtividade forrageira, devido a problemas associados à desfolha excessiva, causado por cargas animal muito elevadas, sendo esse um dos principais motivos pelos baixos resultados produtivos. Carvalho *et al.* (2001) destacam que além dos aspectos relacionados a quantidade de pasto ofertado, a forma com que a forragem é apresentada aos animais (estrutura do pasto representada pela altura, massa de forragem e distribuição e frequência dos diferentes tipos funcionais) também tem relevância. Então para melhorar o desempenho dos rebanhos nos campos sulinos é importantíssimo fazer o ajuste de carga corretamente, condicionando a estrutura do pasto, pois assim será possível o aumento da produção forrageira e também a disponibilidade de forragem.

De acordo com Nabinger (1996) a produtividade secundária, ou seja, o produto animal em relação à área e tempo é limitada pela disponibilidade de produção primária (vegetal). É possível estabelecer uma faixa de oferta de forragem que otimize o ganho médio diário dos animais e o ganho de peso vivo por área, promovendo a eficiência produtiva e a sustentabilidade do ecossistema (Carvalho *et al.*, 2006).

O pastejo é considerado uma fonte de distúrbio e alteração da vegetação campestre, sendo tão importante quanto o solo e clima. Conforme a intensidade de pastejo é alterada, as plantas que compõem a vegetação e o hábito de crescimento também são alteradas. Com baixas intensidades de pastejo, predominam plantas altas e eretas, enquanto que com o aumento do pastejo predominam plantas baixas e prostadas ou espécies com resposta intermediária, que são as plantas eretas de estatura mediana (Boldrini, 1993).

4.3 Produção de massa de forragem

De acordo com Maraschin (2009) a massa de forragem produzida pela pastagem ao longo das estações do ano é o produto da relação entre altitude, tipo de solo, condições climáticas da região e da flora. A vegetação das pastagens nativas pode ser considerada o produto das características físicas e químicas do solo, da posição

topográfica e das condições climáticas (Garagorry *et al.*, 2008). Assim a produção de forragem nos campos sulinos ocorre de forma sazonal, diretamente influenciada por variações edafoclimáticas.

Barioni *et al.*, (2006) destacam que as respostas ao padrão climático dependem do genótipo da espécie forrageira. De acordo com Moojen e Maraschin (2002) os campos sulinos são formados principalmente por espécies de ciclo metabólico C4, que reduzem a capacidade de manter a produção de forragem no período de inverno. Durante a primavera acontece o desenvolvimento das gramíneas hibernais, com metabolismo fotossintético C3, quando a temperatura aumenta, as gramíneas C4 começam a emitir suas inflorescências, juntamente com um grande número de outras espécies que também florescem (Boldrini, Overbeck e Trevisan, 2015). Thurow *et al.*, (2009) ressaltam que os efeitos da estação do ano indicam que o verão e a primavera são as estações que mais possibilitam o aumento da massa de forragem. Durante o inverno, o campo apresenta uma redução em suas características produtivas e qualitativas (Moojen e Maraschin, 2002), criando um desafio para a produtividade animal (Jochim *et al.*, 2013).

De acordo com Maraschin (2009) o crescimento diário da massa de forragem é denominado de taxa de acúmulo (TA). Para Pallarés *et al.* (2005) nas pastagens nativas a taxa de acúmulo e a produção de matéria seca estão associadas principalmente à composição botânica e estrutural da vegetação e, em parte, pelas características do solo, temperatura, regime hídrico, topografia, estação do ano e manejo de pastejo. Para Webby e Bywater (2007) as taxas de crescimento das pastagens dependem da temperatura e da precipitação que, em muitas áreas, variam consideravelmente entre estações e entre anos.

Os campos sulinos por se situarem em regiões com variações climáticas ao longo do ano apresentam diferenças na taxa de acúmulo em cada estação ano (Maraschin, 2009). Carvalho *et al.* (2006) destacam que durante o inverno é comum encontrar taxas de acúmulos negativas, principalmente devido à senescência foliar provocada pelas baixas temperaturas e geadas nas primeiras horas do amanhecer. Já durante a primavera, normalmente ocorrem as maiores taxas de acúmulo de forragem (Maraschin, 2001). Para Webby e Bywater (2007), os perfis de alimentação com base nas taxas médias de crescimento de pastagem fornecem apenas um guia básico para a oferta de alimentos ao longo de um ano e, para o manejo prático, a carga animal precisa

ser ajustada em resposta às mudanças nas condições sazonais para combinar a oferta e a demanda dos animais.

A estimativa e o monitoramento da produção de massa de forragem é uma forma de gerenciamento sobre o manejo do pastejo (Cunha, 2002). Para estimativa da massa de forragem e da estrutura da vegetação campestre podem ser utilizadas diversas metodologias, como a avaliação direta com o uso de amostragens destrutivas (corte e pesagem) e avaliações indiretas como o uso de sward stick (régua graduada), medidores que avaliam através da resistência à pressão exercida pela massa de forragem (disco calibrado, falling plate), sensores hiperespectrais e imagens de satélites provenientes de sensores ativos e passivos (Wachendorf *et al.*, 2017). Contudo, ainda são poucas as ferramentas que juntem elevada acurácia e baixo custo. Para os Campos Sulinos, a estimativa da massa de forragem é essencial para a produção vegetal e animal, auxiliando na tomada de decisões referentes ao manejo das pastagens nativas. Entretanto, estimar de forma objetiva é algo complexo, principalmente devido a heterogeneidade das pastagens, a variabilidade climática ao longo do ano e os métodos de estimativa empregados.

4.4 Sensoriamento Remoto

Sensoriamento remoto (SR) se refere à obtenção de dados à distância sobre a superfície terrestre. Estes dados são adquiridos através de sensores, que são alocados a bordo de aeronaves ou de satélites de sensoriamento remoto. A avaliação e quantificação de massa de forragem por SR ainda necessita ser bastante trabalhada para compreender e identificar os melhores métodos a serem utilizados, minimizando as falhas e incertezas (Kumar *et al.*, 2015). Ainda não há consenso sobre quais práticas e métodos mais adequados na caracterização e estimativa de massa de forragem nos ambientes campestres, considerando a utilização de dados observado a campo é fundamental para entender e aferir a massa de forragem a partir do SR (Jia *et al.*, 2016).

As imagens de SR podem cobrir extensas áreas na superfície terrestre dependendo da plataforma e tornam possíveis mapeamentos de grande escala. Além disso, é possível extrapolar as relações obtidas em regiões específicas, dependendo da consistência e estabilidade da variável estudada. Dessa forma, as imagens e dados obtidos por SR são importantes ferramentas para o estudo de ambientes naturais ou

manejados (Kuplich *et al.*, 2016). A caracterização e estimativa da massa de forragem dos campos é fundamental para a avaliação das práticas de manejo mais adequadas para aquele ambiente. Assim, desenvolver ferramentas que possibilitem auxiliar no mapeamento, monitoramento e conservação das áreas campestres é essencial para utilização sustentável dos recursos naturais, minimizando impactos negativos da utilização inadequada dos campos (Guerini Filho, 2018).

O SR tem sido utilizado desde a década de 1960 na extração e monitoramento de parâmetros biofísicos da vegetação principalmente por meio de índices de vegetação (Jensen, 2009). O estudo de ecossistemas campestres com dados de SR já conta com alguns anos de estudos, que apresentam a possibilidade de monitoramento da massa de forragem, já que a dinâmica dos campos apresenta padrões característicos registráveis. Na Austrália, há a utilização do NDVI no monitoramento da produtividade dos campos, que serve como subsídio para produtores da região (Hill *et al.*, 2004). O Uruguai vem utilizando dados de NDVI para monitoramento mensal da vegetação, com geração de mapas com a evolução da vegetação há mais de duas décadas (INIA, 2022).

Dados de SR apresentam uso operacional e estudos têm analisado as tendências dos índices de vegetação, principalmente o NDVI, para monitoramento nas mudanças no uso e da cobertura do solo (Leeuwen *et al.*, 2006). Segundo o estudo realizado por Wagner *et al.*, 2013, os índices EVI e NDVI proporcionaram detectar variações temporais na vegetação de diferentes formações campestres do Bioma Pampa no RS e no Uruguai, assim como possibilitou observar alterações na cobertura vegetal das formações campestres no Bioma Pampa.

Apesar do uso operacional de dados de SR em ecossistemas campestres, ainda falta conhecimento sobre o comportamento espectral e espacial das tipologias campestres com suas diversas características funcionais. Os padrões de resposta espectrais dependem das características das comunidades vegetais, sendo assim possível identificar diferenças nos padrões de refletância em função do manejo pastoril (Guerini Filho, 2018). O uso de satélites e imagens orbitais são importantes ferramentas na avaliação e detecção de mudanças associadas a perturbações naturais ou antrópicas, com a capacidade de fornecer informações temporalmente contínuas e em diferentes escalas (Zhang *et al.*, 2003).

Métodos de sensoriamento remoto para estimativa de produção de massa de forragem podem ser agrupado em três estratégias: desenvolvimento de modelos de regressão de estimativa baseados em diferentes índices de vegetação gerados a partir de imagens de satélites, uso de diferentes algoritmos de *machine learning* e uso combinado de parâmetros da vegetação gerados por sensoriamento remoto e modelos de simulação biofísica (Gao, 2006).

Os índices de vegetação (IVs) são medidas radiométricas adimensionais e que indicam a abundância relativa e a atividade da vegetação verde, o que inclui o índice de área foliar (IAF), porcentagem de cobertura verde, teor de clorofila, massa de forragem verde e radiação fotossinteticamente absorvida (RFAA) (Jensen, 2009). Os IV's são combinações matemáticas da resposta espectral de diferentes bandas do espectro eletromagnético, sendo que os principais índices utilizam os valores da reflectância em duas faixas de comprimento de onda, o vermelho e o infravermelho próximo. Esses índices também sintetizam os dados a serem analisados, permitindo a avaliação de diferenças nas condições de crescimento a partir da relação entre o índice e as variáveis da vegetação, como, por exemplo, as características estruturais e fisiológicas da mesma, além da densidade da vegetação (Fonseca, 2004; Pan *et al.*, 2015; Prabhakara; Dean Hively; McCarty, 2015). Por exemplo, quanto maior for a densidade da cobertura vegetal em uma determinada área, menor será a reflectância no vermelho visível, em razão da maior presença de pigmentos fotossintetizantes para a absorção da radiação solar e maior será a reflectância no infravermelho próximo, devido ao efeito do espalhamento múltiplo (Ponzoni *et al.*, 2012; Jensen, 2009).

Os IVs são comumente usados como variáveis preditivas para qualificar e quantificar a massa de forragem de pastagens e da vegetação em geral. Este trabalho examinará diferentes IVs, sendo dois deles (NDVI e EVI) amplamente conhecidos por suas correlações com a massa de forragem (Hmimina *et al.* 2013; González-Dugo e Mateos 2008; Xu *et al.* 2014). Serão testadas variações nos índices normalmente usados, com a inclusão da região da banda vermelha do espectro eletromagnético (EVI-B5 e NDRE). O uso da região da banda vermelha vem se intensificando desde o lançamento dos satélites Sentinel, como alguns estudos abordaram a relação entre a refletância da banda vermelha com clorofila e outros nutrientes presentes na estrutura celular da planta e tem sido usada como um meio para estimar o teor foliar de clorofila ou nitrogênio de plantas (Frampton *et al.* 2013; Ju *et al.* 2010; Skidmore & Cho, 2009).

Considerando a presença de massa de forragem senescente nas áreas de estudo, o índice PSRI (Plant senescence reflectance index) será incluído, pois é usado nas estimativas e monitoramento de vegetação fotossinteticamente ativa e também senescente (Sims e Gamon, 2002).

O NDVI (Normalized Difference Vegetation Index – Índice De Vegetação Por Diferença Normalizada, em português) é um índice adimensional que descreve a diferença entre o visível e refletância infravermelha próxima da cobertura vegetal e pode ser usado para estimar a densidade de verde em uma área de terra (Weier e Hering, 2000). Os valores de NDVI variam de - 1 a 1 e, em geral, seus valores são negativos para corpos d'água, próximos a zero para rochas, areias ou superfícies de concreto e positivo para a vegetação, incluindo culturas, arbustos, gramíneas e florestas (Jones e Vaughan, 2010). Dessa forma, maiores valores de NDVI significam maior vigor da vegetação. Esse IV tem sido utilizado como ferramenta para monitoramento da vegetação, principalmente em estudos de construção de perfis temporais, sazonais e fenológicos, pico de verde e período de crescimento, estudos climáticos e de mudanças agrícolas e florestais (Ponzoni; Shimabukuro; Kuplich, 2012).

Além disso, o NDVI também vem sendo usado para a determinação de índices de massa de forragem. Esse índice constitui-se como um bom indicador da presença e condição da vegetação e é utilizado devido a sua sensibilidade a condição da vegetação foliar verde, relacionando-se com a quantidade de clorofila e à radiação fotossinteticamente ativa absorvida pela planta. Pode ser usado em estudos envolvendo fotossíntese, estoques de carbono, balanço hídrico e outros processos afins (Lillesand *et al.*, 2007).

Segundo os resultados de Guerini Filho (2020) a utilização de dados oriundos da imagem de satélite apresenta a capacidade para avaliação e monitoramento de campos nativos, corroborando com os resultados de outros autores que pesquisam sobre a relação da massa de forragem com dados de diferentes satélites. Em relação a análise temporal dos dados espectrais, Fonseca (2000) avaliou a evolução temporal do NDVI durante o período de crescimento do *Paspalum notatum* com diferentes níveis de adubação nitrogenada, a partir de medições obtidas com espectrorradiômetro portátil. Foi observado nesse estudo que o aumento ou diminuição de massa de forragem alteram os valores de NDVI, que tendem a aumentar com o incremento de massa de forragem,

podendo este índice ser utilizado para estimar índice de área foliar, matéria seca verde e radiação fotossinteticamente ativa absorvida.

O EVI (Enhanced Vegetation Index – Índice de Vegetação Melhorado, em português) foi desenvolvido para otimização da resposta da vegetação verde, melhorando a sensibilidade para as variações estruturais e arquitetônicas do dossel da vegetação, diminuindo as influências atmosféricas e do solo (Huete *et al.*, 2002), possuindo um fator de ajuste para solos e dois coeficientes para correção da banda vermelha quanto ao espalhamento atmosférico por aerossóis. O EVI melhora a sensibilidade para áreas com alta massa de forragem e permite um melhor desempenho no monitoramento da vegetação devido a diminuição do sinal proveniente da superfície abaixo do dossel e através da redução da influência atmosférica. O valor de EVI varia de -1 a 1 e para vegetação saudável, os valores ficam entre 0,2 e 0,8.

O NDVI e o EVI possuem potencial em estudos que analisam e monitoram os tipos e as mudanças da cobertura vegetal. Enquanto o NDVI é sensível à clorofila, o EVI é sensível as variações da estrutura e arquitetura do dossel (Huete *et al.* 2002). Isso ocorre, pois o NDVI se baseia na quantidade de luz vermelha visível absorvida e a luz infravermelha refletida. Em uma planta considerada saudável, a clorofila absorve a luz vermelha visível, enquanto o dossel reflete o infravermelho. A atividade fotossintética elevada, normalmente associada à vegetação densa, terá menor reflectância na banda vermelha e maior reflectância no infravermelho.

O EVIB5 (Enhanced Vegetation Index B5 – Índice de Vegetação Melhorado B5, em português) é uma adaptação do EVI, utilizando-se dos mesmos princípios. Entretanto, substitui a banda NIR, que corresponde a faixa espectral do infravermelho próximo, por bandas na faixa do Red-Edge, que corresponde a faixa da borda do vermelho, e aparentemente tem melhores relações com o Índice de Área foliar utilizando imagens do satélite Sentinel 2 (Perez, 2018).

O SAVI (Soil-Adjusted Vegetation Index - Índice de Vegetação Ajustado ao Solo, em português) é o índice de vegetação que considera os efeitos do solo exposto nas imagens analisadas, ajustando o NDVI quando a superfície não está completamente coberta pela vegetação. Para minimizar a influência da reflectância do solo no NDVI, incorporou-se o fator L, que promove um ajuste de acordo com a cobertura do solo, minimizando os efeitos da cor do solo, dos efeitos da variabilidade, do tipo e densidade

da vegetação nos resultados do índice. Dependendo das características do solo e do tipo de cobertura, este índice pode variar de 0 (vegetação densa) a 1 (vegetação mais rala). (Huete, 1988; Meneses e Almeida, 2012).

O MSAVI2 (Modified Soil Adjusted Vegetation Index 2 - Índice de Vegetação Ajustado do Solo Modificado 2, em português) é um índice que busca lidar com as limitações do NDVI quando aplicado em áreas com alto grau de exposição da superfície do solo. O índice de vegetação original, o SAVI, requer a especificação da correção do solo, o fator L, que varia de 0 para cobertura vegetal alta, a 1 para vegetação muito baixa. O L é tomado como 0,5 para cobertura vegetal intermediária. O MSAVI definiu o valor de L incorporando o Índice de Vegetação por Diferença Ponderada (WDVI) e, por fim, foi modificado para MSAVI2 para reduzir a complexidade dos seus cálculos (Marshall, 2005).

O NDWI (Normalized Difference Water Index - Índice de diferença normalizada da água, em português), é um índice de vegetação que está diretamente relacionado com a quantidade de água presente na cobertura vegetal. Permite monitorar mudanças na massa de forragem e avaliar o estresse hídrico da vegetação, sendo pouco sensível aos efeitos da atmosfera. Esse IV requer o uso de uma banda situada na região do comprimento de onda do NIR e de uma banda situada no comprimento de onda do infravermelho de ondas curtas (SWIR) (Szabó *et al.* 2016). O valor de NDWI varia entre -1 e 1, definindo-se 0 como limiar, ou seja, o tipo de cobertura é a água se NDWI for maior que 0 e é não água se NDWI for menor que 0 (Brubascher e Guasselli, 2013).

O GLI (Green leaf index – Índice de folha verde, em português) é um índice de vegetação elaborado para determinar a intensidade de degradação da vegetação. É formado pela diferença normalizada das reflectâncias das faixas espectrais do azul, verde e vermelho. Apresenta bons resultados na avaliação da vegetação, sendo utilizado na indicação da degradação vegetal, tendo boas correlações com alterações na clorofila foliar (Hunt-Jr *et al.*, 2011; Ballesteros *et al.*, 2018).

O NDRE (Normalized Difference Red Edge Index – Índice da diferença normalizada na borda vermelha, em português) é um índice que possibilita avaliar o teor de clorofila, o teor de nitrogênio e a demanda de fertilizantes das plantas. Utiliza a banda espectral do NIR, que é sensível às mudanças nas propriedades da vegetação (Jorge *et al.*, 2019).

O PSRI (Plant senescence reflectance index – Índice de reflectância de senescência da planta, em português) é um índice de vegetação proposto para determinar o estágio de senescência foliar, pois é sensível ao acúmulo de folhas (Merzlyak *et al.* 1999). Dentro de um ano, o PSRI apresenta uma curva de sino invertida com NDVI. Ou seja, o valor de PSRI diminui com o aparecimento de folhas verdes na primavera, atinge o valor de vale no meio do verão e aumenta com a senescência foliar no outono.

O valor do PSRI aumenta durante a senescência foliar devido ao aumento na proporção de carotenóides em relação às clorofilas. Estudos mostraram que PSRI tem sensibilidade semelhante à dinâmica da vegetação com NDVI na primavera, mas maior sensibilidade que o NDVI no outono (Rautiainen *et al.* 2011; Cole *et al.* 2014). Assim, o PSRI deve ser explorado para fins de rastreamento da estrutura do mesófilo em folhas, sendo utilizado na identificação da estação de crescimento da vegetação, enriquecendo os métodos de identificação de métricas fenológicas no Sensoriamento Remoto (Ren *et al.*, 2016). Os valores de PSRI variam de -1 a 1, com valores para vegetação verde variando entre -0,1 e 0,2 (Zagajewski *et al.*, 2017).

O uso de séries temporais de índices de vegetação possibilita determinar o início e fim da estação de crescimento, taxa de crescimento e senescência, pico máximo de desenvolvimento e duração do ciclo que definem o padrão de desenvolvimento da vegetação (Reed *et al.*, 2003). Os IV são indicadores de atividade fotossintética e vigor da vegetação, usado no monitoramento do estado da vegetação e detecção de mudanças na vegetação (Hill 2013; Brantley, Zinnert e Young 2011).

Os IV podem ser utilizados no monitoramento das variações e do crescimento da vegetação ao longo de um determinado período e utilizados para estabelecer uma relação entre as variáveis meteorológicas e a sua influência sobre a vegetação. A métrica fenológica é definida como o padrão sazonal de variação da vegetação e é observável a partir de imagens de sensoriamento remoto com alta resolução temporal, capazes de cobrir extensas áreas sob diferentes ecossistemas (Tan *et al.*, 2011).

A caracterização de padrões fenológicos em séries temporais com a utilização dos índices de vegetação possibilita a identificação e quantificação dos efeitos das variações dos elementos climáticos e ambientais nestes ciclos. Os índices NDVI e EVI são bastante usados nos estudos com diferentes tipos de vegetação, pois permitem a

construção de perfis sazonais e temporais da vegetação, pico de verde e períodos de senescência determinando o padrão fenológico de diferentes tipologias vegetais (Moreira, 2018). Os índices de vegetação reduzem a variabilidade gerada por fatores externos à vegetação, servindo como indicadores do crescimento e vigor da vegetação, mostrando-se adequados para o monitoramento de mudanças fenológicas tanto nas formações vegetais naturais quanto em áreas agrícolas (Fontana; Almeida; Jacóbsen, 2007; Rizzi; Rudorff, 2007; Kuplich; Moreira; Fontana, 2013).

A análise fenológica da vegetação é realizada por meio de séries temporais dos IVs e métricas fenológicas, possibilitando identificar o padrão de desenvolvimento da vegetação e determinando o período de crescimento, comprimento da estação, amplitude sazonal, além de outros parâmetros. As métricas fenológicas são obtidas através de dados de reflectância da superfície e de IVs que permitem identificar parâmetros fenológicos gerais como taxa de crescimento e senescência, pico máximo de desenvolvimento e duração do ciclo (Reed; White; Brown, 2003; Tiedemann, 2011). A obtenção contínua de dados de sensoriamento remoto orbital constitui séries temporais que fornecem informações sobre a reflectância e alterações sobre a vegetação em resposta as mudanças ocorridas na superfície terrestre, seja por influência antrópica, devido a métricas fenológicas natural da vegetação ou pela variabilidade climática (Moreira, 2018).

Os IVs são uma fonte de dados para monitoramento da dinâmica e variabilidade dos campos nativos. Existem trabalhos que analisam a vegetação dos campos nativos com IVs em diferentes escalas e com objetivos diversos. No estudo realizado por Fontana *et al.* (2007), avaliou-se os perfis temporais como indicadores da dinâmica temporal da vegetação em regiões de campos no RS, através de imagens de NDVI/AVHRR/NOAA. Os resultados demonstraram que os menores valores de NDVI observados foram nos meses de outono e inverno, sendo que o mês de julho é o que apresenta os menores valores de NDVI, pois coincide com o mês mais frio do ano na média. Esses menores valores de NDVI são atribuídos às mudanças na vegetação devido às baixas temperaturas que ocorrem no inverno no RS, associada a baixa disponibilidade de radiação solar global. Em contrapartida, no período de primavera verão foram encontrados os máximos valores de NDVI, quando também foram observadas as maiores diferenças entre as regiões estudadas, o que foi atribuído principalmente a variação na precipitação pluvial.

Em outro estudo realizado por Fontana *et al.* (2018), relacionou-se a dinâmica do NDVI com as condições meteorológicas e à dinâmica anual de acúmulo de massa de forragem em pastagens naturais utilizando imagens do sensor MODIS. Esse estudo mostrou que o inverno é a estação com a menor taxa de acúmulo de forragem e menores valores de NDVI, devido a diminuição da radiação solar e temperatura do ar. Já no verão, o fator que limita o crescimento das pastagens é a pluviosidade. No estudo de Junges *et al.* (2016), utilizou-se de NDVI e EVI para discriminar padrões de intensidades de pastejo uma área experimental na Depressão Central do RS. O EVI foi eficiente para diferenciar a intensidade moderada de pastejo da baixa e alta intensidades de pastejo durante qualquer estação do ano. Já o NDVI foi mais adequado para diferenciar as intensidades de pastejo na primavera e inverno.

No estudo de Ogliari (2020), a série temporal dos índices NDVI e EVI mostrou variações tanto ao longo do ano quanto entre os anos avaliados. Essas variações refletem as variações na massa de forragem e métricas fenológicas das pastagens naturais. As variações da massa de forragem são devidas as diferenças nas condições meteorológicas e podem ser em função das diferenças nas práticas de manejo, como a intensidade de pastejo empregada na área. Já a métricas fenológicas varia em função das diferentes espécies que compõem a pastagem nativa, principalmente espécies C4. Os índices apresentaram maiores valores nos períodos de outono e primavera e menores no inverno. Os maiores valores dos IVs ocorrem devido ao rebrote das espécies vegetais que compõem o dossel no período de primavera e pelo pleno desenvolvimento delas no período de outono. Quando há aumento da temperatura na primavera e no verão, as gramíneas com metabolismo fotossintético C4 iniciam o período de florescimento (Boldrini *et al.*, 2015). O menor crescimento das plantas no inverno pode ser explicado devido à baixa quantidade de radiação solar global, baixas temperaturas e ocorrência de geadas (Fontana *et al.*, 2018).

Nesse mesmo estudo de Ogliari (2020), verificou-se a diferenciação dos níveis de oferta de forragem (OF) ao longo do ano. De modo geral, verificou-se que o tratamento com 4% de OF apresentou maiores valores para os índices de vegetação NDVI e EVI e, conforme aumentava-se a OF, diminuíam-se os valores dos IVs. Isto pode ser explicado devido às diferenças da estrutura da vegetação, causadas pelas diferentes ofertas de forragem (Melizara *et al.*, 2012). No tratamento com 4% de OF, o dossel apresenta baixa quantidade de vegetação senescente e, à medida que se aumenta a oferta

de forragem, há incremento de material senescente na pastagem (Moojen, 2002). Por causa disso, a vegetação no tratamento 4% de OF apresenta-se de modo geral com maior verdor em relação aos demais tratamentos. Como os IVs estimam o teor de massa de forragem verde (Ponzoni *et al.*, 2012), o tratamento 4% de OF apresenta os valores dos IVs superiores. Já o tratamento 16% de OF, apresentou os menores valores dos IVs devido a maior quantidade de material vegetal senescente (Pinto *et al.*, 2017).

4.5 Random Forest

O *machine learning* é um método de análise de dados com o objetivo de automatizar a construção de modelos analíticos. Modelos baseados em árvores são um método de *machine learning* supervisionado, normalmente utilizados em análises e previsão de dados exploratórios devido ao seu design não paramétrico. Em vez de ajustar um modelo aos dados, esses modelos particionam os dados em grupos cada vez mais homogêneos com base em valores que minimizam uma função de perda (como Soma dos Erros Quadrados (SSE) para regressão ou Índice de Gini para classificação) (James *et al.*, 2021).

Os dois pacotes mais comuns para gerar modelos baseados em árvore no software R são *rpart* (Therneau e Atkinson, 2019) e *random forest* (Liaw e Wiener, 2002). O pacote *rpart* cria uma regressão ou árvore de classificação baseada em divisões binárias que maximizam a homogeneidade e minimizam a impureza. A saída é uma única árvore de decisão que pode ser ainda mais “podada” usando a estatística de erro de validação cruzada para reduzir o ajuste excessivo. O pacote *random forest* é semelhante ao *rpart*, mas é duplo aleatório, pois cada nó é dividido usando um subconjunto aleatório de preditores e observações em cada nó e esse processo é repetido centenas de vezes, conforme especificado pelo usuário. Ao contrário do *rpart*, o *random forest* não produz uma árvore de decisão gráfica, pois as previsões são calculadas em centenas ou milhares de árvores. Em vez disso, o *random forest* produz um gráfico de importância variável e um resumo estatístico tabular.

Da mesma forma que *rpart*, *random forest* permite que todos os tipos de dados sejam usados como variáveis independentes, independentemente de o modelo ser uma árvore de classificação ou regressão. Ao contrário de *rpart*, o algoritmo *random forest* não lida diretamente com valores ausentes com divisões substitutas. Existe uma função

que usa uma matriz de proximidade do random forest para preencher os valores ausentes com a média ponderada das observações não ausentes (ponderadas pelas proximidades) para preditores contínuos ou a categoria com a maior proximidade média para preditores categóricos. Assim como rpart, random forest tem a mesma função de modelo básico: $(y \sim x)$. Em uma análise de árvore de regressão, random forest usa %IncMSE para classificar a importância da variável. %IncMSE é o aumento médio nos resíduos quadrados do conjunto de teste quando as variáveis são permutadas aleatoriamente (pouca importância = pouca mudança no modelo quando a variável é removida ou adicionada).

5. MATERIAL E MÉTODOS

5.1 Época e locais

As observações desta pesquisa foram realizadas em nove sítios localizados em diferentes regiões fisiográficas nos Campos Sulinos do estado do Rio Grande do Sul, Brasil, no período de outubro de 2021 a agosto de 2022. Os sítios de pesquisa compreenderam propriedades privadas e instituições públicas de reserva ecológica e pesquisa. A coleta de dados a campo da massa de forragem e das alturas do pasto com sward stick e falling plate foi realizada em dois meses consecutivos, escolhidos por serem representativos com as características de cada estação, sendo outubro e novembro, representando a primavera; janeiro e fevereiro, representando o verão; abril e maio, representando o outono; julho e agosto, representando o inverno.

As coletas a campo de massa de forragem e altura do pasto foram realizadas nos seguintes períodos: entre os dias 4 e 12 de outubro de 2021; entre 11 e 20 de novembro de 2021; entre 3 e 11 de janeiro de 2022; entre 1 e 9 de fevereiro de 2022; entre 5 e 13 de abril de 2022; entre 2 e 10 de maio de 2022; entre 5 e 13 de julho de 2022; e entre 3 e 10 de agosto de 2022.

No bioma Pampa, foram estabelecidos seis sítios de pesquisa nos municípios de Aceguá, Alegrete, Eldorado do Sul, Encruzilhada do Sul, Lavras do Sul e Tavares. Segundo a classificação de Köppen, o clima dessas regiões do bioma Pampa é classificado como clima subtropical úmido (Cfa).

Na região do Litoral, a pesquisa foi desenvolvida em uma propriedade privada situada no município de Tavares. A altitude é de 3 m com coordenadas geográficas 31°23'38.0"S e 51°9'22.3"W. A área é de campo nativo pastejado com bovinos e bubalinos. Na região denominada Depressão Central, a pesquisa foi realizada na Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul (EEA/UFRGS), em Eldorado do Sul. A altitude é de 46 m com coordenadas geográficas de 30°06'09.4"S e 51°40'56.0"W. É uma área experimental com campo nativo em que há pastejo de bovinos. Na região da Serra do Sudeste, a coleta de dados foi realizada na Fazenda Alto das Figueiras situada no município de Encruzilhada do Sul. A altitude é de 200 m com coordenadas geográficas 30°23'28.1"S e 52°28'02.3"W. O campo nativo é pastejado com bovinos e ovinos.

Na região da Campanha, a pesquisa foi desenvolvida em três propriedades particulares situadas nos municípios de Aceguá (Fazenda Cinco Salsos), Lavras do Sul (Fazenda São Crispim) e Alegrete (Estância do Carvão). A altitude e as coordenadas geográficas são respectivamente: 167 m, 31°38'55.0"S e 54°09'26.0"W; 330 m, 30°41'55.0"S e 53°58'12.0"W; 185 m, 30°04'09.0"S e 55°59'28.0"W. Em Aceguá, o campo nativo é pastejado com bovinos, enquanto em Lavras do Sul é pastejado com bovinos, ovinos e equinos, e em Alegrete é pastejado com bovinos e ovinos.

Nos Campos de Altitude, bioma Mata Atlântica, foram estabelecidos três sítios de pesquisa nos municípios de Jaquirana, São Francisco de Paula e Vacaria. O clima dessas regiões é classificado como clima temperado úmido (Cfb), segundo a classificação de Köppen. Na região denominada Campos de Cima da Serra, a coleta de dados foi realizada no Parque Estadual das Tainhas situado no município de Jaquirana, na Estação Ecológica Aratinga em São Francisco de Paula, e na Fazenda Capão Alto em Vacaria. A altitude e as coordenadas geográficas são respectivamente: 815 m, 29°05'43.0"S e 50°22'02.0"W; 900 m, 29°23'35.0"S e 50°14'26.0"W; 970 m, 28°11'08.19"S e 51°01'56.40"W. Nas três áreas, o campo nativo é pastejado com bovinos.

Uma observação a ser feita é que o Parque Estadual de Tainhas e a Estação Ecológica Aratinga possuem limitações devido ao seu manejo diferenciado dos outros sítios de pesquisa onde foram realizadas as coletas a campo. Esse manejo possui uma densidade de carga animal baixa, com poucos animais em uma área ampla de pastejo, além de poucos funcionários para executar os ajustes necessários. A carga de animais era mais baixa devido ao plano de manejo do parque estadual e da Estação Ecológica, por isso não são áreas representativas do manejo executado tradicionalmente nos campos nativos do RS.

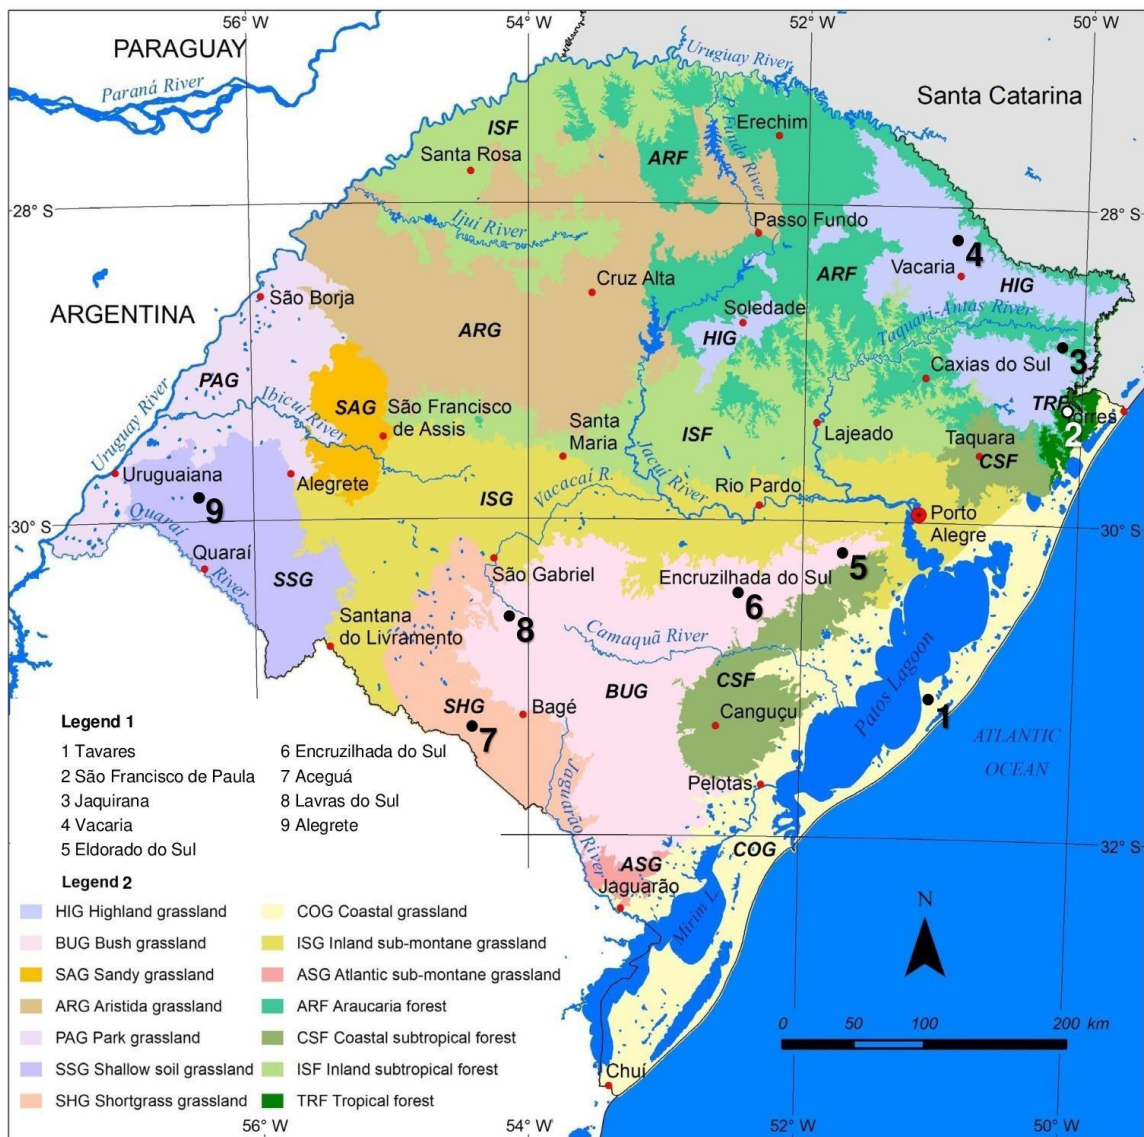


Figura 1. Localização dos sítios de pesquisa onde foram realizadas as coletas de campo (Legenda 1) e as diferentes fitofisionomias dos Campos Sulinos localizados nos biomas Pampa e Mata Atlântica no RS (Legenda 2). Adaptado de Hasenack *et. al*, 2023.

5.2 Tratamentos e manejo experimental

Nos sítios de pesquisa de Tavares, Aceguá, Lavras do Sul, Alegrete, São Francisco de Paula, Jaquirana e Vacaria foram utilizadas áreas de campo nativo de um experimento de Pesquisa Ecológica de Longa Duração (PELD Campos Sulinos) que vem sendo desenvolvido desde 2010. Nesses sítios, foram utilizados em cada um deles dois piquetes de 0,5 ha (70 x 70 m) das áreas do PELD. Nessas áreas, as áreas de coletas foram em dois piquetes representando dois tratamentos de controle de pastejo: o

conservativo, que é um área cercada, com controle de acesso dos animais, o qual é determinado com base no cálculo de graus dias; e o convencional, em que o acesso dos animais e o pastejo são contínuos, é referente ao manejo tradicional dos campos (Dias, 2016).

As espécies presentes na região do Litoral são: *Axonopus affinis*, *Paspalum dilatatum*, *Stylosanthes leiocarpa*, *Desmodium incanum* e *Onira unguiculata*. Espécies presentes na região da região dos Campos de Cima da Serra são: *Baccharis trimera*, *Andropogon lateralis*, *Macroptilium prostratum* e espécies do gênero *Eryngium*. Na região da Depressão Central, espécies presentes na região são: *Paspalum notatum*, *Axonopus affinis*, *Andropogon lateralis*. Na região da Serra do Sudeste, as espécies que podem ser citadas são: *Aristida jubata*, *Andropogon ternatus*, *Lathyrus pubescens*, *Rhynchosia diversifolia*. Nos campos da região da Campanha, pode-se citar espécies como: *Paspalum notatum*, *Axonopus affinis*, *Baccharis coridifolia*, *Andropogon lateralis*, *Coelorachis selloana*, *Paspalum dilatatum*, *Stipa setigera*, *Piptochaetium stipoides* (Boldrini, 2009).

Em relação ao manejo pastoril conservativo, o controle do acesso do animal ao piquete experimental foi feito através do protocolo em soma térmica acumulada de graus-dia. O intervalo de descanso da área corresponde à soma térmica de 750° graus-dia, permitindo o alongamento foliar da pastagem e o acúmulo de matéria vegetal morta (Barbieri *et al.* 2014). Atingindo-se a soma térmica determinada, é permitida a introdução dos animais dentro da parcela, com carga animal ajustada para haver uma oferta de forragem de 4,5 % do peso vivo. Os animais possuem acesso ao piquete para pastejar por um período de 24 horas.

No sítio de pesquisa de Eldorado do Sul, utilizou-se três piquetes de uma área de campo nativo de um experimento de longa duração que vem sendo conduzido desde 1986 na EEA/UFRGS. Os piquetes escolhidos para coletas foram com 4% Oferta (Baixa Massa de forragem), 8-12% Oferta (Média Massa de forragem) e 16% Oferta (Alta Massa de forragem). No sítio de pesquisa de Encruzilhada do Sul foram utilizados dois piquetes de campo nativo submetidos ao manejo típico praticado pelo produtor, normalmente sob pastejo contínuo com bovinos e ovinos. Um dos piquetes possui média e alta massa de forragem, e outro piquete possui baixa massa de forragem. Utilizou-se em cada sítio de pesquisa dois piquetes de 0,5 ha (70 x 70 m).

5.3 Massa e altura da forragem

O *falling plate* (ou disco medidor) é composto por uma placa de acrílico quadrada (podendo ser quadrado ou redondo de metal) com um peso conhecido, que desliza ao longo de um eixo central graduado, onde é realizada a medida de altura do pasto. Essa metodologia avalia a massa de forragem considerando sua altura e a densidade em função da pressão exercida pela placa sobre o pasto. O *sward stick* é constituído por uma haste metálica graduada e possibilita que as alturas da vegetação sejam realizadas através de um pequeno e transparente marcador móvel de plástico, o qual percorre a haste metálica. A base da haste é posicionada sobre o solo e o marcador móvel deve ser deslizado até o primeiro toque na folha da planta, onde é realizada a leitura da escala graduada (Cauduro *et. al.*, 2006).

Mediu-se a altura da pastagem de cada piquete em 25 pontos através de caminhamento aleatório utilizando um bastão graduado em centímetros (*sward stick* - Barthram, 1985). Depois, fazia-se a média desses pontos para alocação das gaiolas de exclusão de pastejo para obtenção da massa de forragem do piquete. A medida da massa de forragem foi feita de forma direta, através do corte da massa de forragem total, contida em nove quadrados de 0,25m² por sítio de pesquisa. Após o corte, as amostras de forragem foram acondicionadas em estufa de circulação de ar forçado a 60°C por no mínimo 72 horas, sendo pesadas posteriormente. Com isso, foi possível estimar a massa seca de forragem por hectare.

Anteriormente aos cortes para a determinação da massa de forragem foram realizadas mensurações da altura do pasto com *sward stick* (Barthram, 1985) na área onde a pastagem seria cortada. Obteve-se cinco pontos dentro do quadrado de 0,25m² e calculada a média destes pontos.

Também foi realizada a medida da altura do pasto e da altura de dentro do quadrado com *falling plate* (Ed Rayburn e Lozier, 2003). O *falling plate* é uma placa descendente utilizada para estimar a massa de forragem através da altura comprimida pelo prato. Dessa forma, conseguiu-se verificar a melhor metodologia para estimar a massa de forragem.

5.4 Coleta e processamento da imagem

A série de satélites SENTINEL começou a ser lançada em 2014, e se desenvolveu a partir de um projeto da Agência Espacial Europeia (ESA) e pela Comissão Europeia (CE). A missão é composta por pares de satélites especializados, indicados a diferentes temas de interesse. O par de satélites SENTINEL-2 foi direcionado ao monitoramento da vegetação, solos e áreas costeiras, sendo dotado com sensor óptico de alta resolução espacial (Guerini Filho *et al.*, 2020).

Dessa forma, foi utilizado os dados do satélite SENTINEL-2 para coleta de imagens, geração dos valores de índices de vegetação (IV's) e posterior correlação entre os IV's com a massa de forragem coletada a campo. O SENTINEL-2 é composto por dois satélites com órbita sincronizada com o sol e 13 bandas espectrais, com resolução espacial variável (10, 20 ou 60 m, dependendo da banda) e resolução temporal de 5 dias com os dois satélites operacionais. Dependendo das características da área de estudo, podem ser escolhidas diferentes bandas como, por exemplo, as bandas B2, B3, B4, B5 e B8 do MSI (Instrumento Multiespectral). Na Tabela 1, são indicadas as resoluções das bandas, além de outras informações.

Tabela 1. Bandas do satélite Sentinel-2 e suas respectivas descrições.

Nome	Descrição	Resolução	Comprimento de onda	Escala
B2	Azul	10 metros	496.6nm (S2A) / 492.1nm (S2B)	0,0001
B3	Verde	10 metros	560nm (S2A) / 559nm (S2B)	0,0001
B4	Verde	10 metros	664.5nm (S2A) / 665nm (S2B)	0,0001
B5	Red Edge	20 metros	703.9nm (S2A) / 703.8nm (S2B)	0,0001
B8	NIR	10 metros	835.1nm (S2A) / 833nm (S2B)	0,0001

Para atenuar os possíveis efeitos dos componentes ativos da atmosfera na superfície refletância, a imagem foi submetida ao processo de correção atmosférica com o modelo 6S (segunda simulação de um sinal de satélite no espectro solar), desenvolvido por Vermote *et al.* (1997). O produto utilizado foi surface reflectance.

Obteve-se as imagens do satélite e dos IVs nas datas mais próximas das coletas, isto é, cinco dias antes ou após a data da coleta a campo. A área de amostragem foi de dois piquetes de 0,5 ha (70 x 70 m) em cada sítio de pesquisa previamente georrefenciadas e a janela foi sobre o ponto da coleta, ou seja, a área dos dois piquetes. O ambiente de coleta e processamento das imagens foi o Google Earth Engine, que é

uma plataforma de análise geoespacial baseada em nuvem que permite aos usuários visualizar e analisar imagens de satélite de nosso planeta. É utilizado para pesquisas de sensoriamento remoto, previsão de surtos de doenças, gerenciamento de recursos naturais, entre outros.

Foi utilizado três filtros no Google Earth Engine para seleção das imagens do SENTINEL-2: por data (foi informado para a plataforma o período de interesse para o cálculo dos índices); por recobrimento de nuvens (assumiu-se um nível máximo de recobrimento por nuvens nos pixels que compõem a imagem, além do qual elas não entraram no cálculo); por polígono de interesse (foi delimitada a área de interesse, por meio de coordenadas geográficas). Após a seleção das imagens, as linhas de código seguiram com a aplicação de fórmulas para o cálculo efetivo dos índices de vegetação. Essas fórmulas são geralmente operações simples entre as bandas que compõem as imagens.

Os IVs utilizados no presente estudo foram o NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), EVIB5 (Enhanced Vegetation Index B5), SAVI (Soil-Adjusted Vegetation Index), Msavi2 (Modified Soil Adjusted Vegetation Index 2), NDWI (Normalized Difference Water Index), GLI (Green leaf index), NDRE (Normalized Difference Red Edge Index) e o PSRI (Plant senescence reflectance index). Os IVs foram obtidos pelas seguintes fórmulas:

Figura 2. Índices de vegetação e suas respectivas fórmulas.

Índice de Vegetação	Fórmula
(1) NDVI	$(\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho})$
(2) EVI	$2,5 * (\text{IVP} - \text{Vermelho}) / (\text{L} + \text{IVP} + \text{C1vermelho} - \text{C2azul})$
	$2,5 * ((\text{NIR} - \text{Vermelho}) / (1 + \text{NIR} + 6 * \text{Vermelho} - 7,5 * \text{Azul}))$
(3) EVIB5	$2,5 * (\text{Red Edge} - \text{Vermelho}) / (1 + \text{Red Edge} + 6 * \text{Vermelho} - 7,5 * \text{Azul})$
(4) SAVI	$((\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho} + \text{L})) * (1 + \text{L})$
	$((\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho} + 0,5)) * (1,5)$
(5) Msavi2	$(2 * \text{NIR} + 1 - \sqrt{(2 * \text{NIR} + 1)^2 - 8 * (\text{NIR} - \text{RED})}) / 2$
(6) NDWI	$(\text{Verde} - \text{NIR}) / (\text{Verde} + \text{NIR})$
(7) GLI	$((\text{Verde} - \text{Vermelho}) + (\text{Verde} - \text{Azul}) / (2 * \text{Verde}) + \text{Vermelho} + \text{Azul})$
(8) NDRE	$(\text{Red Edge} - \text{Vermelho}) / (\text{Red Edge} + \text{Vermelho})$
(9) PSRI	$((\text{Vermelho} - \text{Azul}) / (\text{Red Edge}))$

Observação 1.: No EVI, a primeira fórmula é a inicial, onde L = ajuste de solo; C1 e C2 = coeficientes de ajuste para efeito de aerossóis da atmosfera; azul é a reflectância da região espectral do azul, vermelho é a reflectância da região espectral do vermelho e

IVP é a reflectância da região espectral do infravermelho próximo. Os valores dos coeficientes são $L = 1$, $C1 = 6$, $C2 = 7,5$ e o fator de ganho $G = 2,5$ (JUSTICE et al., 1998). Na segunda fórmula, os coeficientes com seus respectivos valores já estão inseridos.

Observação 2: No SAVI a primeira fórmula é a inicial, sendo L uma constante que melhora a discriminação de classes com densidades altas de vegetação - quanto maior o valor do L melhor a discriminação, embora haja diminuição da sensibilidade. Os valores médios ($L = 0,5$) são preferidos quando as classes vegetadas são as de interesse na imagem. Na segunda fórmula, os coeficientes com seus respectivos valores já estão inseridos.

5.5 Análise estatística

Avaliou-se através de análises de variância correlação entre ferramentas de avaliação da massa de forragem (*sward stick* ou *falling plate*), município, estação do ano e bioma. Foi realizado uma análise de agrupamento (clusters) com propósito de classificar os valores dos piquetes em um número adequado grupos homogêneos, relacionando-os através de similaridades. Nessa análise, foi realizada o teste de Bonferroni e o teste de Kruskal-Wallis. Para gerar modelos para Massa de Forragem, (valores gerados a partir da média da altura do pasto com o *sward stick*), Massa Verde, Massa de Material Morto e Massa de Lâminas (determinados a partir da separação botânica do pasto realizada de uma amostra do pasto), utilizou-se o Random Forest na análise e previsão de dados devido ao seu design não paramétrico. Para realizar as análises foi utilizado o Software R Studio. O conjunto de dados de treino e validação foram determinados aleatoriamente pelo *Random Forest*. O número de árvores de decisão utilizado foi 500 e o R^2 foi utilizado na mensuração da qualidade do modelo.

6. RESULTADOS

6.1 Equações de Regressão:

Realizada a análise de variância, viu-se que houve a interação entre altura x ferramenta de avaliação x estação do ano ($p < 0,05$). A partir de então gerou-se equações de regressão linear para cálculo da massa de forragem com base na altura do pasto medida com *falling plate* e com *sward stick*. As equações são apresentadas na Tabela 2, juntamente com os coeficientes de determinação, onde y é massa de forragem em kg de MS/ha, e x é a altura do pasto em cm.

Tabela 2 - Equações de regressão linear para estimativa de massa de forragem (kg MS/ha) dos Campos Sulinos através do falling plate e sward-stick.

Descrição	Equação	R ²	n
Sward stick (outono)	$y = 256,25 x$	0,84	162
Sward stick (inverno)	$y = 172,98 x$	0,90	81
Sward stick (primavera/verão)	$y = 129,99 x$	0,85	322
Falling Plate (outono)	$y = 356,48 x$	0,84	160
Falling Plate (inverno)	$y = 260,95 x$	0,90	81
Falling Plate (primavera/verão)	$y = 156,24 x$	0,82	241

A Figura 3 apresenta um gráfico de dispersão da massa de forragem seca relacionando as medições das alturas do *falling plate* e do *sward stick*. em cada estação do ano. Os gráficos de dispersão são úteis na visualização da relação entre variáveis quantitativas e na detecção de padrões e tendências entre as variáveis.

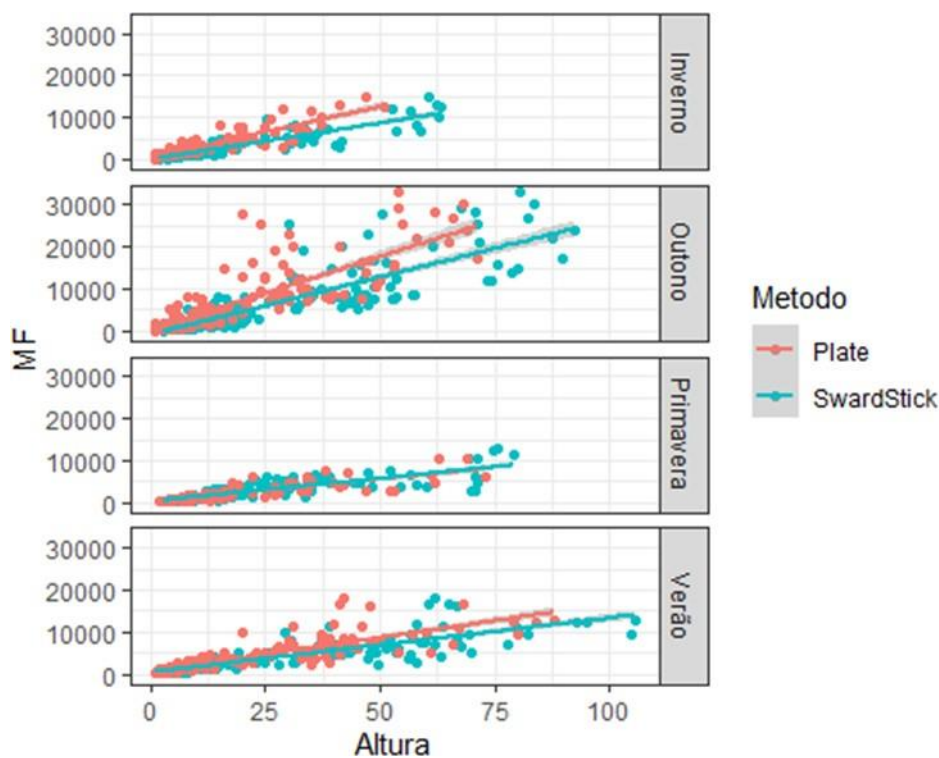


Figura 3. Gráfico de dispersão da Massa de Forragem – MF seca (kg/ha) do campo nativo relacionada as medições de alturas com falling plate (cm) e sward-stick (cm) por estação do ano.

6.2 Matriz de Correlação:

Gerou-se uma matriz de correlação entre os IVs e diferentes variáveis do pasto. Essas variáveis foram: Altura do Pasto (ALT), obtida a partir da medição com o sward stick, Massa de Forragem (MF), estimada a partir da ALT obtida com o sward stick, Massa de Lâminas (ML), Massa Verde (MV) e Massa de Material Morto (MMM), sendo esses três foram obtidos a partir da separação botânica de uma amostra da pastagem.

Na Figura 3, é apresentado a matriz de correlação entre as variáveis. Essa matriz foi utilizada para exploração inicial dos dados. De maneira geral, as correlações entre ALT, MF, ML, MV e MMM com os IVs foram negativas, com algumas sendo significativas ($P < 0,05$).

Destaca-se a correlação entre ALT, medida a partir do *sward stick*, com o EVIB5. Para MF, calculada a partir da altura do *sward stick*, houve correlação negativa

semelhante com o GLI, NDRE, PSRI, SAVI, MSAVI2 e NDVI e correlação positiva com NDWI. Para ML, a correlação que mais se destaca é com o PSRI e com o EVI. Já para MV, houve correlações negativas com o GLI, NDRE, PSRI, SAVI, MSAVI2 e NDVI, além de uma correlação positiva com NDWI. Para MMM, houve correlações positivas com GLI, NDRE, SAVI, MSAVI2 e NDVI e correlação negativa com o NDWI.

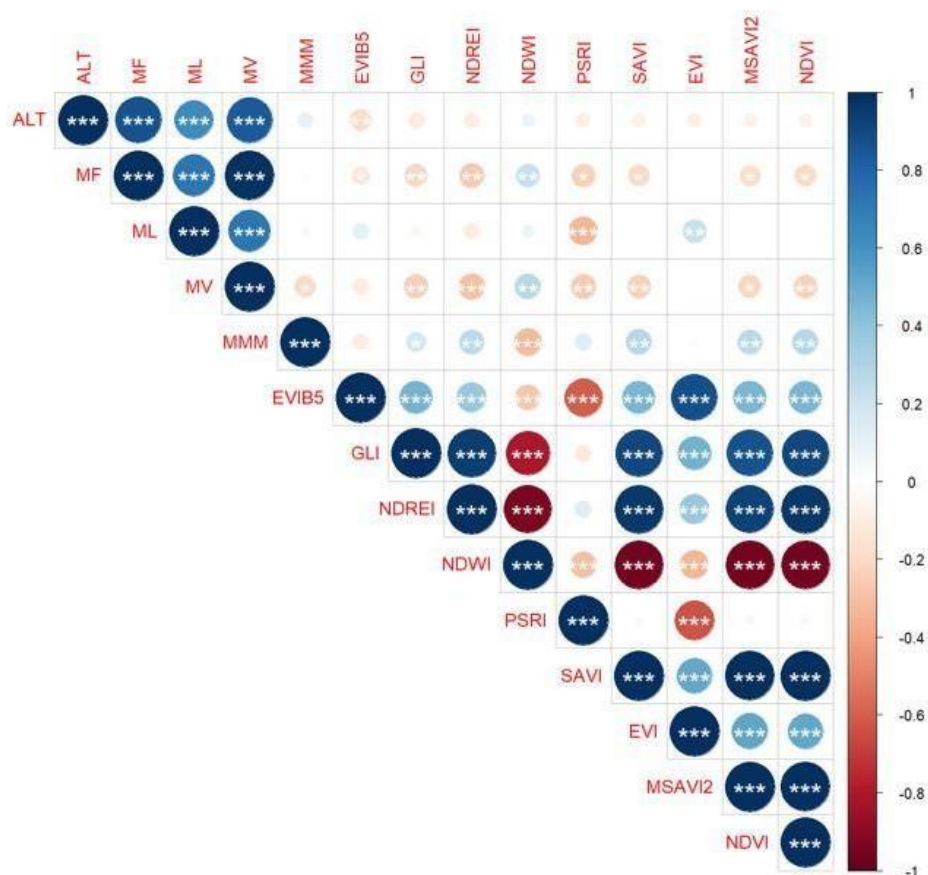


Figura 4. Plot entre ALT, MF, ML, MV e MMM e Índices de Vegetação: NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), EVIB5 (Enhanced Vegetation Index B5), SAVI (Soil-Adjusted Vegetation Index), Msavi2 (Modified Soil Adjusted Vegetation Index 2), NDWI (Normalized Difference Water Index), GLI (Green leaf index), NDRE (Normalized Difference Red Edge Index) e o PSRI (Plant senescence reflectance index).

6.3 Análise de agrupamento

Foi realizado uma análise de agrupamento (clusters) com propósito de classificar os valores de Massa de Forragem (MF), Massa Verde (MV) e Massa de Material Morto

(MMM) dos piquetes em um número adequado grupos homogêneos, relacionando-os através de similaridades. De acordo com a análise, o melhor número de clusters gerados foi 3. Os dados são apresentados na Tabela 3.

Tabela 3. Clusters com as respectivas MF, MV e MMM.

	MF	MV	MMM
Cluster	Média	Média	Média
1	2486,44 b	2265,69 c	215,34 a
2	7919,79 a	7831,58 b	213,41 a
3	17478,30 a	17478,30 a	00,00 a

Tratamentos com a mesma letra na coluna não apresentam diferença significativa.

Esse agrupamento foi realizado com o objetivo de homogeneizar os dados do piquete e os clusters foram utilizados na análise de Random Forest.

6.4 Random Forest para Massa de Forragem

No algoritmo *random forest*, são gerados dois modelos, sendo que o primeiro deles é o treinamento com 70% dos dados e o segundo é o modelo de validação com 30% dos dados, sendo os dados escolhidos aleatoriamente pelo algoritmo. Foram analisados os dados de Massa de Forragem em função dos IVs (EVIB5, GLI, NDRE, NDWI, PSRI, SAVI, EVI, MSAVI2, NDVI) e das variáveis de Região, Cluster e Estação. Assim, obteve-se que 67,91% do conjunto de treinamento explica a variância da Massa de Forragem.

Então, há a classificação de valores de contribuição de cada índice de vegetação e de cada classe dentro do modelo. Os valores são apresentados na Tabela 4.

Tabela 4. Valores de contribuição das classes e dos IVs no modelo para Massa de Forragem.

	%IncMSE
Cluster	31,281165
Estação	12,316352
Região	7,214295
NDRE	6,769155
NDVI	5,391623
NDWI	5,293236
msavi2	5,122404
SAVI	4,785049
EVIB5	4,682691
GLI	4,636212
EVI	4,292695
PSRI	2,562861

Legenda: %IncMSE (Aumento médio dos resíduos dos quadrados quando as variáveis são permutadas aleatoriamente), NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), EVIB5 (Enhanced Vegetation Index B5), SAVI (Soil-Adjusted Vegetation Index), Msavi2 (Modified Soil Adjusted Vegetation Index 2), NDWI (Normalized Difference Water Index), GLI (Green leaf index), NDRE (Normalized Difference Red Edge Index) e o PSRI (Plant senescence reflectance index).

Para esse modelo de treinamento gerado para Massa de Forragem seca, o cluster, a estação do ano e a região são os fatores que mais explicam a Massa de Forragem. Entre os índices de vegetação, destacam-se o NDRE, o NDVI, NDWI e o MSAVI2.

Na Figura 5A, observa-se a relação entre os valores observados e os valores preditos para modelo de treinamento para massa de forragem. Na Figura 5B, observa-se a relação entre os valores observados e os valores preditos para o modelo de validação da massa de forragem.

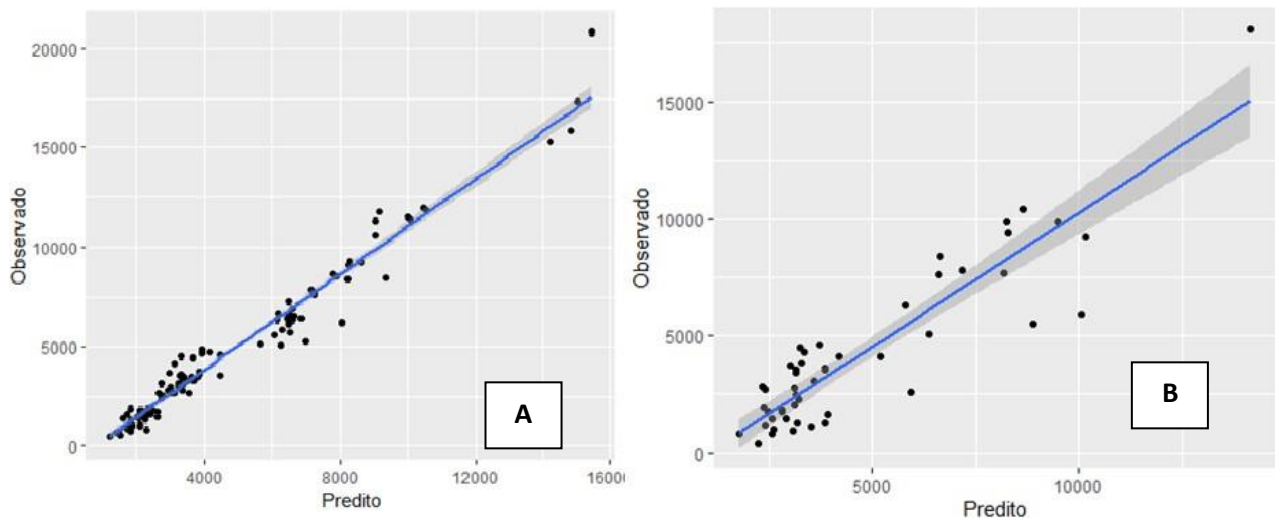


Figura 5. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa de Forragem. (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Forragem (B).

Então, foi gerado um modelo de regressão entre o observado e o predito, sendo ele: $y = 1147x - 1,190e+03$, onde y é a massa de forragem e o x é o valor estimado da variável resposta. Esse modelo de regressão possui $R^2 = 82,19\%$.

6.5 Random Forest para Massa Verde

No algoritmo *random forest*, foram analisados os dados de Massa Verde em função dos IVs (EVIB5, GLI, NDRE, NDWI, PSRI, SAVI, EVI, MSAVI2, NDVI) e das variáveis de Região, Cluster e Estação. Assim, obteve-se que 66,87% do conjunto de treinamento explica a variância da Massa Verde.

Então, há a classificação de valores de contribuição de cada índice de vegetação e de cada classe dentro do modelo. Os valores são apresentados na Tabela 5.

Tabela 5. Valores de contribuição das classes e dos IV's no modelo para Massa Verde.

	% IncMSE
Cluster	27,844359
Estação	9,786791
NDRE	8,754273
NDWI	7,275202
msavi2	6,198370
Região	5,971480
GLI	5,966025
NDVI	4,900477
SAVI	4,806974
PSRI	4,690947
EVI	3,684475
EVIB5	2,945505

Legenda: %IncMSE (Aumento médio dos resíduos dos quadrados quando as variáveis são permutadas aleatoriamente), NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), EVIB5 (Enhanced Vegetation Index B5), SAVI (Soil-Adjusted Vegetation Index), Msavi2 (Modified Soil Adjusted Vegetation Index 2), NDWI (Normalized Difference Water Index), GLI (Green leaf index), NDRE (Normalized Difference Red Edge Index) e o PSRI (Plant senescence reflectance index).

Para esse modelo de treinamento gerado, o cluster e a estação do ano são os fatores que mais explicam a Massa Verde. Entre os índices de vegetação, destacam-se o NDRE, o NDWI e o MSAVI2.

Na Figura 6A, observa-se a relação entre os valores observados e os valores preditos para modelo de treinamento para massa de forragem. Na Figura 6B, observa-se a relação entre os valores observados e os valores preditos para o modelo de validação da Massa Verde.




Figura 6. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa Verde (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa Verde (B).

Então, foi gerado um modelo de regressão entre o observado e o predito, sendo ele: $y = 1139x - 1,165e+03$, onde y é a massa de forragem e o x é o valor estimado da variável resposta. Esse modelo de regressão possui $R^2 = 78,01\%$.

6.6 Random Forest para Massa de Material Morto

No algoritmo *random forest*, foram analisados os dados de Massa de Material Morto em função dos IVs (EVIB5, GLI, NDRE, NDWI, PSRI, SAVI, EVI, MSAVI2, NDVI) e das variáveis de Região, Cluster e Estação. Assim, obteve-se que 10,33% do conjunto de treinamento explica a variância da Massa de Forragem.

Então, há a classificação de valores de contribuição de cada índice de vegetação e de cada classe dentro do modelo. Os valores são apresentados na Tabela 6.

Tabela 6. Valores de contribuição das classes e dos IVs no modelo para Massa de Material Morto.

	%IncMSE
NDRE	6,8896595
Estação	6,8769682
SAVI	6,6371347
NDWI	6,1481395
msavi2	5,8689507
GLI	5,4077935
NDVI	5,2262863
EVIB5	2,5221431
EVI	2,4007889
Cluster	2,1736858
Região	1,0049488
PSRI	-0,2590271

Legenda: %IncMSE (Aumento médio dos resíduos dos quadrados quando as variáveis são permutadas aleatoriamente), NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), EVIB5 (Enhanced Vegetation Index B5), SAVI (Soil-Adjusted Vegetation Index), Msavi2 (Modified Soil Adjusted Vegetation Index 2), NDWI (Normalized Difference Water Index), GLI (Green leaf index), NDRE (Normalized Difference Red Edge Index) e o PSRI (Plant senescence reflectance index).

Para esse modelo de treinamento gerado, a estação do ano é o fator que mais explica a Massa de Material Morto. Entre os índices de vegetação, destacam-se o NDRE, o SAVI e o NDWI.

Na Figura 7A, observa-se a relação entre os valores observados e os valores preditos para modelo de treinamento para massa de forragem. Na Figura 7B, observa-se a relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Material Morto.

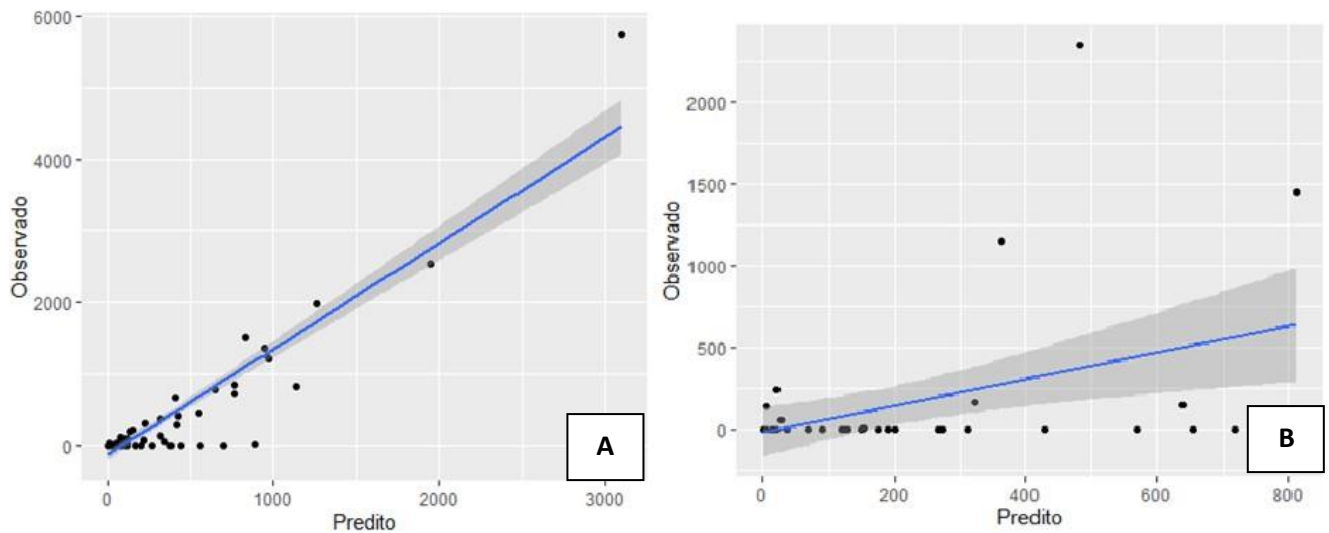


Figura 7. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa de Material Morto (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Material Morto (B).

Então, foi gerado um modelo de regressão entre o observado e o predito, sendo ele: $y = 0,8019x - 13,93$, onde y é a massa de forragem e o x é o valor estimado da variável resposta. Esse modelo de regressão possui $R^2 = 18,54\%$.

6.7 Random Forest para Massa de Lâminas

No algoritmo *random forest*, foram analisados os dados de Massa de Lâminas em função dos IVs (EVIB5, GLI, NDRE, NDWI, PSRI, SAVI, EVI, MSAVI2, NDVI) e das variáveis de Região, Cluster e Estação. Assim, obteve-se que 43,07% do conjunto de treinamento explica a variância da Massa de Lâminas.

Então, há a classificação de valores de contribuição de cada índice de vegetação e de cada classe dentro do modelo. Os valores são apresentados na Tabela 7.

Tabela 7. Valores de contribuição das classes e dos IVs no modelo para Massa de Lâminas.

	%IncMSE
Cluster	21,122421
Região	7,793063
EVI	6,227579
PSRI	5,412984
NDRE	5,161216
msavi2	4,908529
NDWI	4,900855
NDVI	4,789332
Estação	4,482206
GLI	4,402027
SAVI	3,566467
EVIB5	2,510164

Legenda: %IncMSE (Aumento médio dos resíduos dos quadrados quando as variáveis são permutadas aleatoriamente), NDVI (Normalized Difference Vegetation Index), EVI (Enhanced Vegetation Index), EVIB5 (Enhanced Vegetation Index B5), SAVI (Soil-Adjusted Vegetation Index), Msavi2 (Modified Soil Adjusted Vegetation Index 2), NDWI (Normalized Difference Water Index), GLI (Green leaf index), NDRE (Normalized Difference Red Edge Index) e o PSRI (Plant senescence reflectance index).

Para esse modelo de treinamento gerado, o cluster e a região são os fatores que mais explicam a Massa de Lâminas. Entre os índices de vegetação, destacam-se o EVI, PSRI e o NDRE.

Na Figura 8A, observa-se a relação entre os valores observados e os valores preditos para modelo de treinamento para massa de forragem. Na Figura 8B, observa-se a relação entre os valores observados e os valores preditos para o modelo de validação da Massa Verde.

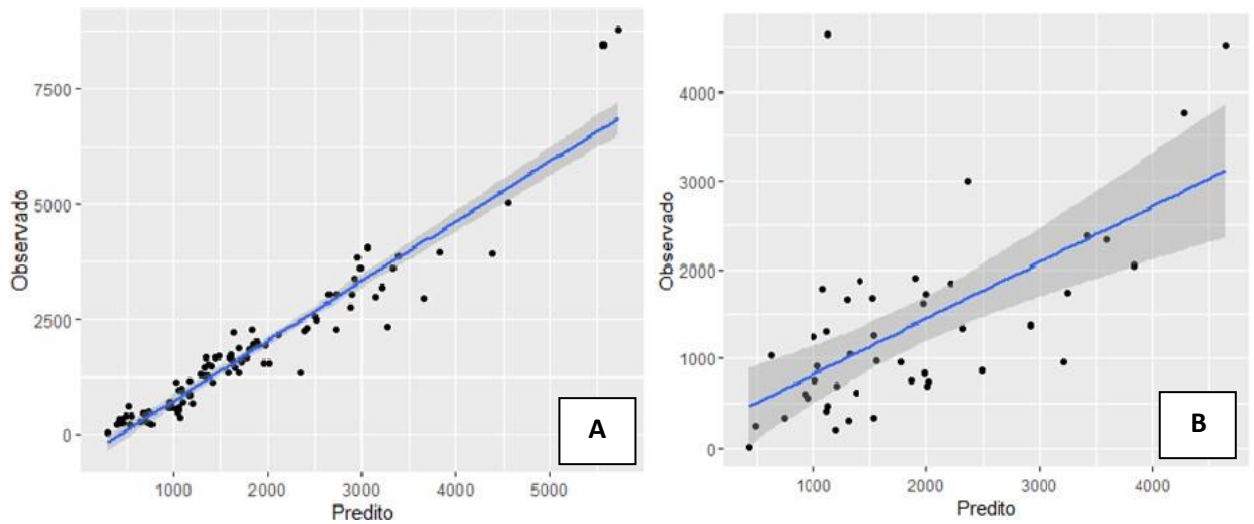


Figura 8. Relação entre os valores observados e os valores preditos para modelo de treinamento para Massa de Lâminas (A) e Relação entre os valores observados e os valores preditos para o modelo de validação da Massa de Lâminas (B).

Então, foi gerado um modelo de regressão entre o observado e o predito, sendo ele: $y = 0,63x + 191,73$, onde y é a massa de forragem e o x é o valor estimado da variável resposta. Esse modelo de regressão possui $R^2 = 37,17\%$.

7. DISCUSSÃO

7.1 Equações de Regressão

Uma das principais dificuldades encontradas no manejo de pastagens é o controle da altura do pasto, que sendo manejado de forma adequada, traz benefícios para a pastagem, podendo refletir em maiores índices produtivos e econômico ao se aproveitar de maneira mais adequada a massa de forragem. O controle da altura e da massa de forragem demandam tempo e conhecimento na tomada de decisão, por isso é necessário adotar ferramentas que facilitem esse processo. Dessa forma, é interessante o desenvolvimento de equações de regressão que possam ser utilizadas na estimativa da massa de forragem com base na altura do pasto, visando facilitar o uso da pastagem de forma mais adequada, sendo possível identificar a capacidade de suporte dos pastos (Fávaro *et al.*, 2020; Righi *et al.*, 2022).

As equações encontradas para o *falling plate* apresentaram um coeficiente de determinação (R^2) muito semelhantes aos R^2 encontrados para a equação do *sward stick* (Tabela 1). Quando comparados os instrumentos *falling plate* e o *sward stick*, nota-se que ambos os instrumentos apresentaram boa precisão na descrição da massa de forragem, independentemente da estação em que foram utilizados. Esse fato demonstra que as duas ferramentas parecem ser confiáveis para estimativa da massa de forragem dos Campos Sulinos.

Como citado anteriormente, houve interação entre a altura do pasto X ferramenta de avaliação X estação. Isso pode ser explicado, pois a ferramenta é utilizada justamente para medir a altura do pasto e a variabilidade climática afeta o crescimento da vegetação ao longo das estações do ano (Fontana *et al.*, 2018), indicando que o verão e a primavera são as estações em que ocorre aumento da produtividade das pastagens devido ao clima predominantemente favorável (Thurow *et al.*, 2009). As variações de temperatura em função das estações do ano influenciam na produtividade das pastagens nativas do RS (Maraschin, 2012).

A utilização do *falling plate* proporciona uma melhor avaliação das áreas sob pastejo, reduzindo tempo de trabalho e custos, além de ser de fácil entendimento, adoção e utilização pelos produtores (Lopes *et al.*, 2000 e Santillan *et al.*, 1979). Contudo, recomenda-se essa técnica de avaliação de massa de forragem principalmente

para áreas com espécies com hábito de crescimento prostrado ou rasteiro e que apresentem folhas e hastes macias.

Em estações do ano e para espécies em que há a presença de colmos grossos e alta proporção de inflorescências há prejuízo na precisão do *falling plate* (Frame, 1981 e Mannetje, 2000). Como observado no trabalho de Cunha (2002), os colmos mantinham a ferramenta em uma posição mais elevada, acima do estrato de folhas, diminuindo a precisão das estimativas de massa de forragem. Em pastagens de crescimento cespitoso, onde ocorre a formação de touceiras, a pastagem pode apresentar grande quantidade de colmos rígidos, interferindo na leitura do *falling plate*, de forma que há a diminuição na correlação com a massa das folhas do dossel (Gomes *et al.*, 2000).

Bransby *et al.* (1977), ao estimar a massa de forragem com o auxílio de um disco medidor, constatou que ao ocorrer uma mudança do estágio reprodutivo para o vegetativo em pastagens homogêneas ou com a mudança na composição botânica de um dossel misto pode alterar as curvas de calibração do método. Dessa forma, o disco medidor, deve ser calibrado frequentemente, garantindo estimativas confiáveis durante as estações do ano e para diferentes tipos de pastagens.

O *sward stick*, por se tratar de uma medida pontual, apresenta alta variabilidade, principalmente em pastos desuniformes, tipicamente com a presença de pastejo (Fagundes *et al.*, 1999). Assim, a medida desse método integra as variações pontuais de altura sem utilizar a densidade na determinação da massa de forragem. Assim, como o método *falling plate*, o *sward stick* também precisa ser calibrado com frequência, já que também está sujeito às mesmas restrições referentes a alterações morfológicas das plantas, estádios de desenvolvimento (vegetativo ou reprodutivo) e estações do ano.

Através da regressão linear, observou-se que a estação do ano em que foram coletadas as amostras influenciou o coeficiente angular, que representa o incremento de massa de forragem para cada cm de incremento na altura do dossel (Righi *et al.*, 2022). Para o *sward stick*, o incremento de massa de forragem por cm de incremento de altura foi de 256,25 kg MS/ha no outono; 172,98 kg MS/ha no inverno; e 129,99 kg MS/ha na primavera e no verão. Para o *falling plate*, o incremento de massa de forragem por cm de incremento de altura foi de 356,48 kg MS/ha no outono; 260,95 kg MS/ha no inverno; e 156,24 kg MS/ha na primavera e no verão. Diferenças no coeficiente angular podem ser explicadas pela variação na estrutura da pastagem ao longo do ano (Hodgson,

1990, Frame, 1981; Aiken & Bransby, 1992; Santillan *et al.* 1979 e Bransby, *et al.* 1997).

Os valores de coeficiente de determinação obtidos foram relativamente altos (0,84 a 0,90 para o *sward stick* e de 0,82 a 0,90 para o *falling platte*), indicando que uma proporção da variação da massa de forragem não pôde ser explicada pela variação em altura e da estação do ano (10 a 16% para o *sward stick* e 10 a 18% para o *falling platte*), o que demonstra os modelos matemáticos gerados para a predição de massa de forragem nas condições deste experimento são promissores.

Dessa forma, é recomendado gerar equações diferentes conforme a estação do ano, pois a geração de única para todas as estações poderia comprometer a precisão e acurácia das equações geradas, assim como a sua relevância na utilização como ferramenta de monitoramento e planejamento do manejo do pastejo. Cada equação reflete a variação na estrutura do pasto conforme a estação do ano. Deve-se considerar as adequações dos métodos para representar as variações nas condições climáticas, estratégia de desfolha e manejo dos pastos em diferentes localidades e épocas do ano (Frame, 1981; Aiken & Bransby, 1992; Santillan *et al.*, 1979 e Bransby *et al.*, 1997).

A Figura 2 mostra a variabilidade dos dados das alturas medidas com as ferramentas *falling plate* e *sward stick* em relação a massa de forragem e estação do ano. É possível observar uma correlação positiva forte entre os dados, pois quando a variável X (altura) aumenta, a variável Y (massa de forragem) também aumenta, havendo pouca dispersão nos dados.

7.2 Matriz de Correlação:

As baixas correlações entre Altura do Pasto (ALT), Massa de Forragem (MF), Massa de Lâminas (ML), Massa Verde (MV) e Massa de Material Morto (MMM) com os IVs possivelmente pode ter diferentes explicações. Uma delas é que foi utilizado todo o conjunto de alturas medidas com o *sward stick* em todas as estações do ano e em todas as regiões, o que pode ter dificultado que houvesse uma correlação forte entre as variáveis analisadas e os IVs.

Pode ser explicado também devido à complexidade inerente ao Campos Sulinos. As pastagens naturais dos Campos Sulinos possuem espécies com metabolismo

fotossintético C3 e C4 coexistindo. Os dois grupos possuem seu ciclo de desenvolvimento em estações diferentes, garantindo que de uma estação para outra o aspecto da vegetação modifique completamente (Boldrini *et al.*, 2015). Isso acaba dificultando a relação forte de um índice com a ALT, a MF, ML, MV e MMM. Espera-se coeficientes de correlação positivos entre IVs e variáveis como a massa de forragem (Jensen, 2009). Neste estudo, houve coeficientes de correlação negativos, resultados que podem ser explicados devido a estrutura do pasto, quantidade presente de material senescente e de touceiras na pastagem (Oligari, 2020).

7.3 Random Forest para Massa de Forragem (MF), Massa Verde (MV), Massa de Material Morto (MMM) e Massa de Lâminas (ML):

Um grande desafio no uso de IVs para avaliar parâmetros de vegetação é minimizar a influência de fatores externos e maximizar a sensibilidade entre a relação dos IVs e dos parâmetros biofísicos. Autores tentaram encontrar o conjunto de IVs mais adequado, ou seja, aqueles para melhor estimativa de MF para um determinado tipo de vegetação. Entretanto, ainda não se encontrou o conjunto de IVs que melhor se adequa a estimativa de MF. Embora os pesquisadores tentem estabelecer relações significativas entre IVs e parâmetros de vegetação no contexto de um único estudo, muitos desses modelos são específicos do local ou da estação, e a transferência bem-sucedida de um local para outro é variável (Ali *et al.*, 2016).

No presente estudo, foram gerados modelos para MF, MV, MMM e ML. Para MF, o modelo de regressão gerado apresentou $R^2 = 82,19$. O modelo de regressão de MV apresentou $R^2 = 78,01$, sendo que esses dois modelos apresentam bons ajustes. Para MMM, o R^2 ficou em 18,54, valor considerado baixo. Já para ML o valor de R^2 ficou em 37,17, também considerado baixo. Os valores apresentados em %IncMSE demonstra o quanto da precisão do modelo diminui se a variável é deixada de fora. Quanto maior o valor do %IncMSE, maior a importância da variável para o modelo.

Quando se observa as variáveis que mais contribuem em cada modelo, o cluster é o que aparece como maior fator de contribuição nos modelos de MF e de MV. Como os clusters são classificados a partir dos dados do piquete, onde há a influência do manejo de entrada e saída dos animais e da conforme a carga, como esperado isso demonstrou como o manejo dos animais é importante em relação à MF e MV. Em

ambos modelos, a estação do ano também possui destaque, demonstrando que as duas variáveis influenciam na precisão do modelo. Quanto aos modelos de MMM e ML, que apresentaram os valores mais baixos de R^2 , a estação do ano teve influência principalmente no modelo de MMM, enquanto que o cluster e a região se destacam no modelo de ML.

No estudo de Numata *et al.* (2007) usaram dados do Landsat TM para analisar o impacto da intensidade de pastejo em características biofísicas do pasto, com vegetação não fotossintética detectada remotamente mostrando a maior correlação com a intensidade de pastejo ($R^2 = 0,70$) quando em comparação com outras características biofísicas medidas, como, por exemplo, massa de forragem, altura do dossel e conteúdo de água. Wu *et al.* (1996) propuseram um modelo físico para simular produtividade em ecossistemas pastoris, com Bénié *et al.* (2005) desenvolvendo o modelo ainda mais para incluir o sensoriamento remoto e parâmetros socioeconômicos para simular a massa de forragem ou capacidade de carga com uma precisão de 80%. Kawamura *et al.* (2005) usou NDVI derivado de dados de sensoriamento remoto para a quantificação da distribuição de pastagens na Mongólia ($R^2 = 0,77$ a $0,83$).

No presente estudo, houve bastante variação quanto a de importância dos IVs, já que não houve um índice que fosse significativo em todos os modelos. Entretanto, pode-se destacar o NDRE, principal IV na explicação do modelo de MF e MV, o que chama a atenção pelo fato de esse IV está relacionado com o teor de clorofila foliar. No modelo MM o SAVI é o IV com maior destaque, enquanto o EVI é o principal IV no modelo ML. As diferenças dos percentuais de importâncias dos IVs podem estar ligadas ao uso de diferentes bandas na construção de cada IV. Assim, a diferença de cálculo dos índices pode ter ocasionado as diferenças na importância relativa destes para estimativas das variáveis de estrutura do pasto (Oligari, 2020).

Os resultados desse estudo corroboram com a literatura, que ainda não encontrou qual o conjunto mais adequado de IVs para a estimativa de forragem e altura do pasto para determinado tipo de vegetação. Ainda mais considerando as variações de espécies e de manejo dos Campos Sulinos no Rio Grande do Sul. Outros trabalhos estudaram os IVs em relação as pastagens, encontrando uma variabilidade de resultados bem expressiva. O presente estudo se enquadra na tentativa de estabelecimento de relações significativas entre IVs e parâmetros de vegetação.

No estudo realizado por Guerini Filho *et al.* (2020), em Santa Maria, utilizando as bandas de imagem MSI convertidas em refletância de superfície foram amostradas nas áreas correspondentes às amostras de campo nos diferentes intervalos entre pastejos (tempo de descanso). Ao comparar os dados da imagem (bandas B2, B3, B4, B5, B8), os índices de vegetação (EVIB5, EVIB8, NDRE, NDVI, PSRI) e dados de campo (massa de forragem total, massa de forragem total, porcentagem de massa de forragem verde, massa de forragem senescente total, porcentagem de massa de forragem senescente) entre os piquetes com diferentes intervalos de descanso, observou-se que massa de forragem total, porcentagem de massa de forragem, B4 e B5 foram significativamente maiores no piquete com menor intervalo de descanso, enquanto EVI8, NDVI e massa de forragem senescente total foram significativamente maiores no piquete com maior intervalo de descanso. No entanto, as bandas B2, B3 e B8, o EVI5, índices NDRE e PSRI não apresentaram diferenças significativas entre os dois piquetes utilizados nesse estudo.

Nesse mesmo estudo, a massa de forragem verde total apresentou correlação direta com o índice B5 e EVIB5, enquanto a porcentagem de massa de forragem verde correlacionou-se diretamente com bandas B3 e B8 e EVI5, EVI8, NDRE e NDVI. Essas bandas correlacionaram-se inversamente com porcentagem de massa de forragem senescente. Já o índice PSRI mostrou correlação inversa com porcentagem de massa de forragem verde e direta com porcentagem de massa de forragem senescente. A partir da análise de regressão múltipla, observou-se que os modelos apresentaram maior coeficientes para o piquete com maior intervalo de descanso ($R^2 = 0,65$ para massa de forragem verde, $R^2 = 0,30$ para massa de forragem senescente e $R^2 = 0,61$ para massa de forragem total). Para o piquete com menor intervalo de descanso, a estimativa da massa de forragem senescente não indicou uma R^2 boa ($R^2 < 0,3$).

Os estudos de Sibanda, Mutanga e Rouget (2015) e Delegido *et al.* (2011), que também encontraram correlação entre a massa de forragem campestre com as bandas na região de bandas do vermelho e do infravermelho (4, 5 e 8) dos dados do MSI Sentinel-2. Numata *et al.* (2007) estimaram a massa de forragem de pastagens plantadas na Amazônia, obtendo um coeficiente de correlação de $R^2 = 0,72$ usando os dados dos sensores do satélite Landsat. Barrachina, Cristóbal e Tulla (2015) encontraram forte correlação ($R^2 = 0,82$) entre a massa de forragem de pastagens montanhosas com EVI e NDVI das bandas Thematic Mapper/Landsat. Essas correlações mais altas podem ser

atribuídos à menor massa de forragem senescente acumulada nesses campos, que podem ser compostos por poucas espécies na Amazônia e tiveram menor alturas do dossel nas montanhas.

Cho e Skidmore (2009) analisaram cinco índices de vegetação e suas variações em imagens hiperespectrais e modelos inferidos com coeficiente $R^2 = 0,55$ para estimar massa de forragem. Clevers *et al.* (2007) realizaram previsões de massa de forragem de pastagens usando métodos de *machine learning* e índices de vegetação, como RVI, NDVI, WDVI e EVI calculados a partir de dados do espectrorradiômetro ASD FieldSpec. Ambos os artigos confirmaram o potencial dos dados do Sentinel-2 para serem usados para realizar análises de pastagens.

O uso de algoritmos de *machine learning* para estimar o rendimento de culturas como o milho (Panda *et al.*, 2010; Serele *et al.*, 2000) e arroz (Ji *et al.*, 2007) tem sido relatado na literatura, no entanto um número reduzido de estudos foi descrito para sua aplicação na estimativa de massa de forragem de pastagem (Ali *et al.*, 2014, 2015). Xie *et al.* (2009) comparou o desempenho de modelos de Rede Neural Artificial (ANN) e regressão linear múltipla para estimativa de massa de forragem na bacia do rio Xilingol, na Mongólia. O ANN apresentou melhores resultados ($R^2 = 0,817$) do que a estimativa pela regressão linear múltipla ($R^2 = 0,591$). Em outro estudo, Yang *et al.* (2012) usou um algoritmo ANN para estimativa de produção de pastagens com base em cinco IVs derivados de dados de satélite MODIS, com NDVI e SAVI mostrando o melhor ajuste com a massa de forragem da amostra *in situ*. Mais uma vez, os modelos de ANN foram mais precisos ($R^2 = 0,56 - 0,71$) do que os modelos estatísticos ($R^2 = 0,54-0,68$).

Em geral, o foco da pesquisa para classificação e recuperação de parâmetros biofísicos de pastagens está mudando para a aplicação algoritmos de *machine learning*. As estratégias de *machine learning* estão se tornando mais amplamente utilizadas no sensoriamento remoto, e métodos como random forest estão mais evidentes na literatura (Barrett *et al.*, 2014), devido à sua capacidade de identificar melhor a importância relativa de diferentes entradas, bem como aprender com o uso repetido. Em resumo, modelos de regressão baseados em IVs têm sido predominantemente usados para estimativa de produção de massa de forragem. Algoritmos de *machine learning* estão provando ser ferramentas úteis na classificação de pastagens, mas ainda precisam ser mais desenvolvidos para estimativa produção de massa de forragem (Mountrakis *et al.*, 2011).

8. CONCLUSÃO

- A partir da correlação da massa de forragem de campo nativo de diferentes fitofisionomias do Rio Grande do Sul com índices de vegetação obtidos a partir de imagens do satélite Sentinel-2, percebeu-se que não houve um único índice que tivesse importância em todos os modelos.
- Pode-se destacar NDRE, pois teve importância nos modelos gerados com maior R^2 , o modelo de Massa de Forragem e o modelo de Massa Verde, possivelmente pelo fato de estar relacionado com o teor de clorofila foliar.
- O uso de *falling plate* e *sward stick* são importantes para estimativa da massa de forragem, ambas possuindo boa precisão na descrição da massa de forragem nas diferentes estações do ano e estruturas do pasto, ambos podendo ser utilizados para determinação da massa de forragem.
- Os Modelos de Regressão para Massa de Forragem ($R^2 = 82,19$) e Massa Verde ($R^2 = 78,01$) foram os resultados mais promissores desse estudo. Eles levaram em consideração os índices de vegetação (EVIB5, GLI, NDRE, NDWI, PSRI, SAVI, EVI, msavi2, NDVI), os clusters gerados, a região e a estação do ano.

REFERÊNCIAS

- AIKEN, G. E.; BRANSBY, D. I. Observer variability for disk meter measurements of forage mass. **Agronomy Journal**, Madison, v. 84, p. 603-605, 1992.
- ALI, I. *et al.* Application of statistical and machine learning models for grassland yield estimation based on a hypertemporal satellite remote sensing time series. *In*: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM – IGARSS, 2014, Quebec City. **Proceedings of the [...]**. Piscataway: IEEE International, 2014. p. 5060–5063.
- ALI, I. *et al.* Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. **Remote Sensing**, Basel, v. 7, p. 16398–16421, 2015.
- ALI, I. *et al.* Satellite remote sensing of grasslands: from observation to management – a review. **Journal of Plant Ecology**, Oxford, v. 9, p. 649–671, 2016.
- AN, N.; PRICE, K. P.; BLAIR, J. M. Estimating above-ground net primary productivity of the tallgrass prairie ecosystem of the Central Great Plains using AVHRR NDVI. **International Journal of Remote Sensing**, London, v. 34, p. 3717–3735, 2013.
- ANDERSON, G.; HANSON, J.; HAAS, R. Evaluating landsat thematic mapper derived vegetation indices for estimating above-ground biomass on semiarid rangelands. **Remote Sensing Environment**, New York, v. 45, p. 165–175, 1993.
- ANDRADE, B. O. *et al.* 12,500+ and counting: biodiversity of the Brazilian Pampa. **Frontiers of Biogeography**, Oakland, v. 15, n. 2, [art.] e59288, 2023.
- BAGGIO, R. *et al.* To graze or not to graze: a core question for conservation and sustainable use of grassy ecosystems in Brazil. **Perspectives in Ecology and Conservation**, Amsterdam, v. 19, p. 256-266, 2021.
- BALDI, G.; GUERSCHMAN, J. P.; PARUELO, J. M. Characterizing fragmentation in temperate South America grasslands. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 116, n. 3/4, p. 197–208, 2006.
- BALLESTEROS, R. *et al.* Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 72, p. 66–75, 2018.
- BARBIERI, C. W. *et al.* Sward structural characteristics and performance of beef heifers reared under rotational grazing management on campos grassland. **American Journal of Plant Sciences**, Irvine, v. 5, p. 1020-1029, 2014.
- BARIONI, L. G. *et al.* Planejamento alimentar e ajustes de taxa de lotação em fazendas de pecuária de corte. *In*: SIMPÓSIO SOBRE DESAFIOS E NOVAS TECNOLOGIAS NA BOVINOCULTURA DE CORTE – SIMBOI, 2., 2006, Brasília-DF. **Anais**. Brasília, DF: Faculdade UPIS, 2006. [p. 1-31].

BARRACHINA, M.; CRISTÓBAL, J.; TULLA, A. F. Estimating above-ground biomass on mountain meadows and pastures through remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 38, p. 84–192, 2015.

BARRETT, B. *et al.* Assessment of multi-temporal, multisensory radar and ancillary spatial data for grasslands monitoring in Ireland using machine learning approaches. **Remote Sensing of Environment**, New York, v. 152, p. 109–124, 2014.

BARTHAM, G. T. Experimental techniques: the HFRO sward stick. *In*: ALCOCK, M. M. (ed.). **Biennial report of the Hill Farming Research Organization**. Midlothian: HFRO, 1985. p. 29-30.

BÉNIÉ, G. B. *et al.* Remote sensing-based spatiotemporal modeling to predict biomass in Sahelian grazing ecosystem. **Ecological Modelling**, Amsterdam, v. 184, p. 341–354, 2005.

BOLDRINI, I. I. **Dinâmica da vegetação de uma pastagem natural sob diferentes níveis de oferta de forragem e tipos de solo, Depressão Central**. 1993. 262 f. Tese (Doutorado) – Programa de Pós-Graduação em Zootecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1993.

BOLDRINI, I. I. Campos do Rio Grande do Sul: caracterização fisionômica e problemática ocupacional. **Boletim do Instituto de Biociências**, Porto Alegre, v. 1, n. 56, p. 1-39, 1997.

BOLDRINI, I. I. Biodiversidade dos campos sulinos. *In*: SIMPÓSIO DE FORRAGEIRAS E PRODUÇÃO ANIMAL, 1., 2006, Porto Alegre. **Anais [...]**. Canoas: Editora Ulbra, 2006. p. 11-24.

BOLDRINI, I. L. A flora dos campos do Rio Grande do Sul. *In*: PILLAR, V. D. P. *et al.* **Campos sulinos: conservação e uso sustentável da biodiversidade**. Brasília, DF: Ministério do Meio Ambiente, 2009. p. 63-77.

BOLDRINI, I. I. *et al.* **Bioma Pampa: diversidade florística e fisionômica**. Porto Alegre: Editora Pallotti, 2010. 64 p.

BOLDRINI, I. L.; OVERBECK, G.; TREVISAN, R. Biodiversidade de plantas. *In*: PILLAR, V. P.; LANGE, O. **Os campos do sul**. Porto Alegre: Rede Campos Sulinos UFRGS, 2015. p. 53-62.

BOSCHETTI, M.; BOCCHI, S.; BRIVIO, P. A. Assessment of pasture production in the Italian Alps using spectrometric and remote sensing information. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 118, p. 267–272, 2007.

BRANTLEY, S. T.; ZINNERT, J. C.; YOUNG, D. R. Application of hyperspectral vegetation indices to detect variations in high leaf area index temperate shrub thicket canopies. **Remote Sensing of Environment**, New York, v. 115, n. 2, p. 514–523, 2011.

BRANSBY, D. I.; MATCHES, A. G.; KRAUSE, G. F. Disk meter for rapid estimation of herbage yield in grazing trials. **Agronomy Journal**, Madison, v. 69, p. 393-396, 1977.

CARVALHO, P. C. F. *et al.* Importância da estrutura da pastagem na ingestão e seleção de dietas pelo animal em pastejo. *In*: PEDREIRA, C. G. S.; SILVA, S. C. (ed.). **A Produção animal na visão dos brasileiros**. Piracicaba: FEALQ, 2001. p. 853-871.

CARVALHO, P. C. F. *et al.* Produção animal no bioma campos sulinos. **Brazilian Journal of Animal Science**, São Paulo, v. 35, p. 156-202, 2006. Número especial.

CARVALHO, P. C. F.; BATELLO, C. Access to land, livestock production and ecosystem conservation in the Brazilian Campos biome: the natural grasslands dilemma. **Livestock Science**, Amsterdam, v. 120, n. 1/2, p. 158-162, 2009.

CAUDURO, G. F. *et al.* Comparação de métodos de medida indireta de massa de forragem em pasto de azevém anual (*Lolium multiflorum* Lam). **Ciência Rural**, Santa Maria, v. 36, n. 5, p. 1617-1623, set./out. 2006.

CERONI, M.; ACHKAR, M.; GAZZANO, I. Evolución temporal del NDVI en el Uruguay, mediante imágenes SPOT en el período 1998-2012. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 16., 2013, Foz do Iguaçu, PR, Brasil. **Anais**. Brasília, DF: INPE, 2013. p. 1314-1321.

CHO, M. A.; SKIDMORE, A. K. Hyperspectral predictors for monitoring biomass production in mediterranean mountain grasslands: Majella National Park, Italy. **International Journal of Remote Sensing**, London, v. 30, n. 2, p. 499-515, 2009.

CHOMENKO, L.; BENCK, G. A. Nosso pampa desconhecido. Porto Alegre: Fundação Zoobotânica do Rio Grande do Sul, 2016.

CLEVERS, J. *et al.* Estimating grassland biomass using SVM band shaving of hyperspectral data. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 73, [art.] 1141, 2007.

COLE, B.; MCMORROW, J.; EVANS, M. Spectral monitoring of moorland plant phenology to identify a temporal window for hyperspectral remote sensing of peatland. **ISPRS Journal of Photogrammetry and Remote Sensing**, Falls Church, v. 90, p. 49-58, 2014.

CUNHA, W. F. **Métodos indiretos para estimativa de massa de forragem em pastagens de *Cynodon spp.*** 2002. 71 f. Dissertação (Mestrado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2002.

DELEGIDO, J. J. *et al.* A red-edge spectral index for remote sensing estimation of green lai over agroecosystems. **European Journal of Agronomy**, Amsterdam, v. 46, p. 42-45, 2003.

DIAS, A. C. **Efeito de diferentes intensidades de pastejo sobre a comunidade de artrópodes nos campos sulinos**. 2016. 66 f. Dissertação (Mestrado) - Programa de Pós-

Graduação em Biologia Animal, Instituto de Biociências, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

DUAN, T. *et al.* Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle. **Field Crops Research**, Amsterdam, v. 210, p. 71-80, 2017.

FAGUNDES, J. L. **Efeito de intensidades de pastejo sobre o índice de área foliar, interceptação luminosa e acúmulo de forragem em pastagens de *Cynodon spp.*** 1999. 59 f. Dissertação (Mestrado) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 1999.

FÁVARO V. R. *et al.* Produção animal e variáveis climáticas em pastagem de azevém-anual tetraploide. **Revista Científica Rural**, Santa Maria, v. 22, n. 22, p. 356-369, 2020.

FLYNN, E. S.; DOUGHERTY, C. T.; WENDROTH, O. Assessment of pasture biomass with the normalized difference vegetation index from active ground-based sensors. **Agronomy Journal**, Madison, v. 100, p. 114-121, 2008.

FONSECA, E. L. **Caracterização espectral e índices de vegetação em *Paspalum notatum* Flüge var. *Notatum* com vistas à modelagem de crescimento.** 2000. 60 f. Dissertação (Mestrado em Fitotecnia) – Programa de Pós-Graduação em Fitotecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

FONSECA, E. L. **Desenvolvimento de modelo da disponibilidade de fitomassa aérea para formações campestres naturais a partir de dados espectrais orbitais e agrometeorológicos.** São José dos Campos: Instituto Nacional de Pesquisas Espaciais - INPE, 2005.

FONTANA, D. C.; ALMEIDA, T. S.; JACÓBSEN, L. O. Caracterização da dinâmica temporal dos Campos do Rio Grande do Sul por meio de imagens AVHRR/NOAA. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 15, p. 69-83, 2007.

FONTANA, D. C. *et al.* NDVI and meteorological data as indicators of the Pampa biome natural grasslands growth. **Bragantia**, Campinas, v. 77, n. 2, p. 404-414, 2018.

FORTES, A. B. **Geografia física do Rio Grande do Sul.** Porto Alegre: Globo, 1959.

FRAME, J. Herbage mass. *In*: HODGSON, J. **Sward measurement handbook.** Berkshire: Bristh Grassland Society, 1981. cap. 3, p. 39-67.

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

GAO, J. Quantification of grassland properties: how it can benefit from geoinformatics technologies? **Journal Remote Sensing**, London, v. 27, p. 1351-1365, 2006.

- GARAGORRY, F. C. *et al.* Produção animal em pastagem natural e pastagem sobre semeada com espécies de estação fria com e sem o uso de glyphosate. **Acta Scientiarum. Animal Sciences**, Maringá, v. 30, n. 2, p. 127-134, 2008.
- GOMES, K. E.; MARASCHIN, G. E.; RIBOLDI, J. Efeitos de ofertas de forragem, diferimentos e adubações sobre a dinâmica de uma pastagem natural. I. Acumulação e matéria seca. *In: REUNIAO ANUAL DA SOCIEDADE BRASILEIRA DE ZOOTECNIA*, 37., 2000, Viçosa, MG. **Anais**. Viçosa, MG: SBZ, 2000. p. 120-132.
- GONZÁLEZ-DUGO, M. P.; MATEOS, L. Spectral vegetation indices for benchmarking water productivity of irrigated cotton and sugarbeet crops. **Agricultural Water Management**, Amsterdam, v. 95, n. 1, p. 48–58, 2008.
- GUERINI FILHO, M. **Estimativas de variáveis biofísicas de vegetação campestre sob manejo pastoril por meio de sensoriamento remoto**. 2018. 33 f. Dissertação (Mestrado em Sensoriamento Remoto) - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.
- GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS F. L. F. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data, **International Journal of Remote Sensing**, London, v. 41, n. 8, p. 2861-2876, 2020.
- HASENACK, H. *et al.* Biophysical delineation of grassland ecological systems in the State of Rio Grande do Sul, Southern Brazil. **Iheringia, Série Botânica**, Porto Alegre, v.78, [art.] e2023001, 2023.
- HILL, M. J. Vegetation index suites as indicators of vegetation state in grassland and savanna: an analysis with simulated SENTINEL 2 data for a north american transect. **Remote Sensing of Environment**, New York, v. 137, p. 94–111, 2013.
- HILL, M. J. *et al.* Estimation of pasture growth rate in the south west of western Australia from AVHRR NDVI and climate data. **Remote Sensing of Environment**, New York, v. 93, n. 4, p. 528–545, 2004.
- HMIMINA, G. *et al.* Evaluation of the potential of MODIS satellite data to predict vegetation phenology in different biomes: an investigation using ground-based NDVI measurements. **Remote Sensing of Environment**, New York, v. 132, p. 145–158, 2013.
- HODGSON, J. **Grazing management: science practice**. Essex: Longman Scientific & Technical, 1990. 203 p.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, New York, v. 25, n. 3, p. 295-309, 1988.
- HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, New York, n. 83, p. 195–213, 2002.

HUNT, E. R. Jr. *et al.* Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, Dordrecht, v. 6, n. 4, p. 359–378, 2005.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **IBGE lança o Mapa de Biomas do Brasil e o Mapa de Vegetação do Brasil, em comemoração ao dia mundial da biodiversidade**. Rio de Janeiro: IBGE, 2004. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/12789-asi-ibge-lanca-o-mapa-de-biomas-do-brasil-e-o-mapa-de-vegetacao-do-brasil-em-comemoracao-ao-dia-mundial-da-biodiversidade> . Acesso em: 10 jan. 2023

INIA – INSTITUTO NACIONAL DE INVESTIGACIÓN AGROPECUARIA. **NDVI medio mensual**. Montevideo: INIA, 2022. Disponível em: <http://www.inia.uy/gras/Monitoreo-Ambiental/Monitoreo-de-la-vegetaci%C3%B3n/NDVI-Medio-Mensual>. Acesso em: 17 abr. 2023.

INMET – INSTITUTO NACIONAL DE METEOROLOGIA. **Normais climatológicas do Brasil 1991-2020**. Brasília, DF: INMET, 2020. Disponível em: <https://portal.inmet.gov.br/normais#>. Acesso em: 17 abr. 2023.

JADHAV, R. N.; KIMOTHI, M. M.; KANDYA, A. K. Grassland mapping/monitoring of Banni, Kachchh (Gujarat) using remotely-sensed data. **Internacional Journal Remote Sensing**, London, v. 14, p. 3093–3103, 1993.

JAMES, G. *et al.* **An introduction to statistical learning: with applications in R**. (Springer Texts in Statistics). New York: Springer US, 2021.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 604 p.

Ji, B. *et al.* Artificial neural networks for rice yield prediction in mountainous regions. **Journal of Agricultural Science**, Toronto, v. 145, p. 249–261, 2007.

JIA, W. *et al.* Estimation and uncertainty analyses of grassland biomass in Northern China: comparison of multiple remote sensing data sources and modeling approaches. **Ecological Indicators**, New York, v. 60, p. 1031–1040, 2016.

JOCHIMS, F. *et al.* Desempenho de ovelhas e cordeiros manejados com diferentes métodos de pastoreio e ofertas de forragem em campo natural. **Revista de la Facultad de Agronomía. UNLPam**, Santa Rosa, AR, v. 22, p. 85-88, 2013. Serie suplementar 2. Congreso de Pastizales.

JOCHIMS, F. *et al.* Improving forage nutritive value and botanical composition in a natural grassland using different grazing methods and herbage allowances. **Animal Production Science**, Melbourne, v. 58, n. 9, p. 1677-1685, 2017.

JONES, H. G.; VAUGHAN, R. A. **Remote sensing of vegetation: principles, techniques, and applications**. Oxford: Oxford University Press, 2010. 353 p.

JORGE, J.; VALLBÉ, M.; SOLER, J. A. Detection of irrigation in homogeneities in an olive grove using the NDRE vegetation index obtained from UAV images. **European Journal of Remote Sensing**, London, v. 52, n. 1, p. 169-177, 2019.

JU, C. H. *et al.* Estimating leaf chlorophyll content using red edge parameters. **Pedosphere**, Beijing, v. 20, n. 5, p. 633-644, 2010.

JUNGES, A. H. *et al.* Temporal profiles of vegetation indices for characterizing grazing intensity of natural grasslands in Pampa biome. **Scientia Agrícola**, Piracicaba, v. 73, n. 4, p. 332-337, 2016.

KAWAMURA, K. *et al.* Comparing MODIS vegetation indices with AVHRR NDVI for monitoring the forage quantity and quality in Inner Mongolia grassland, China. **Grassland Science**, Tochigi, v. 51, p. 33-40, 2005.

KUMAR, L. *et al.* Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, Bellingham, v. 9, n. 1, [art.] 097696, 2015.

KUPLICH, T. M.; MOREIRA, A.; FONTANA, D. C. Série temporal de índice de vegetação sobre diferentes tipologias vegetais no Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 10, n. 17, p. 1116-1123, 2013.

KUPLICH, T. M.; COSTA, L. F. F.; CARDOSO, M. A. G. Avanço da soja no bioma Pampa em Aceguá, RS. *In*: CONGRESSO INTERNACIONAL DO PAMPA, 1.; SEMINÁRIO DA SUSTENTABILIDADE DA REGIÃO DA CAMPANHA, 3., 2016, Santa Maria. **Anais** [...]. Santa Maria: UFSM, 2016. p. 1-10.

KUPLICH, T. M. *et al.* **Algumas aplicações de sensoriamento remoto em estudos de vegetação campestre no RS (INPE-17705-RPQ/917)**. São José dos Campos: INPE, 2016.

LEEUWEN, W. J. D. *et al.* Multi-sensor NDVI data continuity: uncertainties and implications for vegetation monitoring applications. **Remote Sensing of Environment**, New York, v. 100, p. 67-81, 2006.

LIAW, A.; WIENER, M. Classification and regression by random forest. **R News**, Seattle, v. 2, n. 3, p. 18-22, 2002.

LOPES, R. S. *et al.* Avaliação de métodos para estimação da disponibilidade de forragem em pastagem de capim-elefante. *In*: REUNIAO ANUAL DA SOCIEDADE BRASILEIRA DE ZOOTECNIA, 37., Viçosa, 2000. **Anais**. Viçosa: SBZ, 2000. p. 40-47.

MAPBIOMA. **Mata Atlântica: evolução anual da cobertura e uso da terra (1985-2021)**. [S.l.], 2021. Disponível em: <https://mapbiomas-br-site.s3.amazonaws.com/Infograficos/Cole%C3%A7%C3%A3o%207.1/MBI-Infograficos-7.1-mataatlantica-BR.jpg>. Acesso em: 14 abr. 2023.

- MAPBIOMA. **Pampa**: evolução anual da cobertura e uso da terra (1985-2021). [S.l.], 2021. Disponível em: <https://mapbiomas-br-site.s3.amazonaws.com/Infograficos/Cole%C3%A7%C3%A3o%207.1/MBI-Infograficos-7.1-pampa-BR.jpg>. Acesso em: 14 abr. 2023.
- MANNETJE’T, L. Measuring biomass of grassland vegetation. *In*: MANNETJE’T, L.; JONES, R. M. (ed.) **Field and laboratory methods for grassland and animal production research**. Wallingford: CAB International, 2000. cap.7, p. 151-177.
- MARASCHIN, G. E. Production potential os South America grasslands. *In*: INTERNATIONAL GRASSLAND CONGREE, 19., 2001, São Pedro. **Proceedings of the [...]**. São Pedro: Fundação de Estudos Agrários Luiza de Queiroz, 2001. p. 5-15.
- MARASCHIN, G. E. Manejo do campo nativo, produtividade animal, dinâmica da vegetação e adubação de pastagens nativas do sul do Brasil. *In*: PILLAR, V. D. P. *et al.* (ed.). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília, DF: Ministério do Meio Ambiente, 2009. Cap. 19, p. 248–259.
- MARSHALL, G. S. **Drought detection & quantification**: using field-based spectral measurements of vegetation in semi-arid regions. Lincoln: National Drought Mitigation Centre, 2005.
- MENEZES, L. S. *et al.* **A conservação dos Campos Sulinos nas normas ambientais**. São Paulo: Nexo Políticas Públicas, 2021a. Disponível em: https://pp.nexojornal.com.br/linha-do-tempo/2021/A-conserva%C3%A7%C3%A3o-dos-Campos-Sulinos-nas-normas-ambientais?fbclid=IwAR1TPyUEBnkGtKhwe_8jzQQs77E7yUtHWbWQ476C6JkKzvy1tnf7PF4aei0. Acesso em: 8 set. 2021.
- MENEZES, L. S. *et al.* **9 perguntas que a ciência já respondeu sobre os Campos Sulinos**. São Paulo: Nexo Políticas Públicas, 2021b. Disponível em: <https://pp.nexojornal.com.br/perguntas-que-a-ciencia-ja-respondeu/2021/9-perguntas-que-a-ci%C3%Aancia-j%C3%A1-respondeu-sobre-os-Campos-Sulinos>. Acesso em: 8 set. 2021.
- MENESES, P. R.; ALMEIDA, T. D. **Introdução ao processamento digital de imagens de sensoriamento remoto**. Brasília, DF: Universidade de Brasília, 2012. 266 p.
- MELIZZARA, J. C. *et al.* The ingestive behavior of cattle in large-scale and it application to pasture management in heterogeneous pastoral environment. **Journal of Agricultural Science and Technology A**, Libertyville, v. 2, p. 909-916, 2012.
- MOOJEN, E. L.; MARASCHIN, G. E. Potencial produtivo de uma pastagem nativa do Rio Grande do Sul submetida a níveis de oferta de forragem. **Ciência Rural**, Santa Maria, v. 32, n. 1, p. 127-132, 2002.
- MOREIRA, A. **Caracterização fenológica de tipologias campestres do Rio Grande do Sul a partir de produtos MODIS (NDVI, EVI E GPP)**. 2018. Tese (Doutorado) – Programa de Pós-Graduação em Sensoriamento Remoto, Centro Estadual de Pesquisas

em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, Basel, v. 66, n. 3, p. 247–259, 2011.

MUTANGA, O.; SKIDMORE, A. K. Hyperspectral band depth analysis for a better estimation of grass biomass (*Cenchrus ciliaris*) measured under controlled laboratory conditions. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 5, p. 87–96, 2004.

NABINGER, C. Princípios da exploração intensiva de pastagens. *In*: SIMPOSIO SOBRE MANEJO DA PASTAGEM, 13., 1996, Piracicaba. **Anais**: produção de bovinos a pasto. Piracicaba: Fealq, 1997. p. 15-95.

NABINGER, C. Manejo e produtividade das pastagens nativas do subtropico brasileiro. *In*: SIMPÓSIO DE FORRAGEIRAS E PASTAGENS, 1., 2006, Porto Alegre. **Anais** [...]. Canoas: Ulbra, 2006. p. 25-76.

NABINGER, C. *et al.* Produção animal com base no campo nativo: aplicações de resultados de pesquisa. *In*: PILLAR, V. D. P. *et al.* **Campos Sulinos**: conservação e uso sustentável da biodiversidade. Brasília, DF: Ministério do Meio Ambiente, 2009. p. 175-198.

NABINGER, C.; CARVALHO, P. C. F. Ecofisiología de sistemas pastoriles: aplicaciones para su sustentabilidad. **Agrociencia**, Buenos Aires, v. 13, n. 3, p. 18-27, 2009. Número especial.

NEVES, F. P. *et al.* Caracterização da estrutura da vegetação numa pastagem natural do Bioma Pampa submetida a diferentes estratégias de manejo da oferta de forragem. **Revista Brasileira de Zootecnia**, Viçosa, MG, v. 38, n. 9, p. 1685–1694, 2009.

NUMATA, I. *et al.* Characterization of pasture biophysical properties and the impact of grazing intensity using remotely sensed data. **Remote Sensing of Environment**, New York, v. 109, p. 314–327, 2007.

OGLIARI, D. G. P. **Índices espectrais em pastagem natural, sob diferentes ofertas de forragem, no Bioma Pampa**. 2020. 65 f. Tese (Doutorado) – Programa de Pós-Graduação em Fitotecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2020.

OVERBECK, G. E. *et al.* Brazil's neglected biome: the south brazilian campos. **Perspectives in Plant Ecology, Evolution and Systematics**, Amsterdam, v. 9, n. 2, p. 101–116, 2007.

OVERBECK, G. E. *et al.* Os campos sulinos: um bioma negligenciado. *In*: PILLAR, V. D. P. *et al.* (ed.). **Campos sulinos**: conservação e uso sustentável da biodiversidade. Brasília, DF: MMA, 2009. p. 26-41.

- OVERBECK, G. E. *et al.* Conservation in Brazil needs to include non-forest ecosystems. **Diversity and Distributions**, New York, v. 21, p. 1455–1460, 2015.
- PACHECO, M. F. S. D. Divisão regional do Rio Grande do Sul. **Boletim Geográfico**, Porto Alegre, n. 4, p. 7–17, 1956.
- PAN, Z. *et al.* Mapping crop phenology using NDVI time-series derived from HJ-1 A/B data. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 34, n. 1, p. 188–197, 2015.
- PANDA, S. S.; AMES, D. P.; PANIGRAHI, S. Application of vegetation indices for agricultural crop yield prediction using neural network techniques. **Remote Sensing**, Basel, v. 2, p. 673–696, 2010.
- PALLARÉS, R. O.; BERRETTA, E. J.; MARASCHIN, G. E. The South American campos ecosystem. In: SUTTIE, J. M.; REYNOLDS, S. G.; BATELLO, C. **Grasslands of the world**. Rome: FAO, 2005. p. 171-179.
- PEREZ, G. G. **Uso de imagens do Sentinel 2 na estimativa de parâmetros biofísicos da vegetação em áreas de Mata Atlântica**. 2018. Dissertação (Mestrado) - Programa de Pós-Graduação em Ciências Ambientais, Universidade Federal de São Carlos, São Carlos, 2018.
- PILLAR, V. D. P. *et al.* (ed.). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília, DF: MMA, 2012.
- PILLAR, V. D. P. *et al.* **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília, DF: Ministério do Meio Ambiente, 2009.
- PINTO, C. E.; WALLAU, M.; BOLDRINI, I. I. A estrutura da vegetação e composição florística. In: CARVALHO, P. C. F. *et al.* **Nativão: 30 anos de pesquisa em campo nativo**. Porto Alegre: UFRGS, 2017. v. 1, p. 16-20.
- POLI, C. H. E. C. *et al.* Ovinocultura no bioma Pampa. In: PILLAR, V. D. P. *et al.* **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília, DF: Ministério do Meio Ambiente, 2009. p. 229-236.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. 160 p.
- PRABHAKARA, K.; DEAN HIVELY, W.; MCCARTY, G. W. Evaluating the relationship between biomass, percent groundcover and remote sensing indices across six winter cover crop fields in Maryland, United States. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 39, p. 88–102, 2015.
- RAUTIAINEN, M, M. M, *et al.* Seasonal reflectance dynamics of common understory types in a northern European boreal forest. **Remote Sensing of Environment**, New York, v. 115, n. 12, p. 3020–3028, 2011.

RAYBURN E.; LOZIER, J. **A Falling Plate Meter for Estimating pasture forage mass**. Charleston: West Virginia University, Extension Service, Nov. 2003.
REED, B. C.; WHITE, M.; BROWN, J. F. Remote sensing phenology. *In*: SCHWARTZ, M. D. (ed.). **Phenology: an integrative environmental science**. Dordrecht: Springer, 2003. p. 365-381.

RIGHI, R. S. M., *et al.* Estimativa de massa de forragem de braquiárias por meio da altura do pasto. *In*: MEDEIROS, J. A.; NIRO, C. M. (org.). **II Congresso brasileiro de produção vegetal e animal: produção animal e vegetal: inovações e atualidades**. Jardim do Seridó, RN: Agron Food Academy, 2022. v. 2, cap. 24, 288-294. Disponível em: <https://agronfoodacademy.com/e-book-producao-animal-e-vegetal-inovacoes-e-atualidades-vol-2/>. Acesso em: 10/03/2023.

RIO GRANDE DO SUL. Departamento de Políticas Agrícolas e Desenvolvimento Rural. **Radiografia da agropecuária gaúcha**. Porto Alegre, 2020. Disponível em: <https://www.agricultura.rs.gov.br/upload/arquivos/202009/26185534-radiografia-da-agropecuaria-gaucha-2020-1.pdf>. Acesso em: 28 set. 2022.

RIZZI, R.; RUDORFF, B.F.T. Imagens do sensor MODIS associadas a um modelo agrônomico para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 42, n. 1, p. 73-80, 2007.

SANTILLAN, R. A.; OCUMPAUGH, W. R.; MOTT, G. O. Estimating forage yield with a disk meter. **Agronomy Journal**, Madison, v. 71, p. 71-74, 1979.

SARMENTO, M. B.; MACEDO, I. G.; RAMBORGGER, B. M. Serviços ecossistêmicos e práticas de manejo de campo na visão dos pecuaristas dos campos sulinos. *In*: RIBEIRO, J. C.; SANTOS, C. A. (org.). **Competência técnica e responsabilidade social e ambiental nas ciências agrárias**. Ponta Grossa, PR: Atena Editora, 2020. v. 2, cap. 13, p. 109-121.

SILVA, S. C.; CUNHA, W. F. Métodos indiretos para estimar a massa de forragem em pastos de *Cynodon* spp. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 38, n. 8, p. 981-989, ago. 2003.

SHELLITO B. A. Digital image processing. *In*: LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 6th ed. New York: John Wiley, 2007. p. 491-503.

SZABÓ, S.; GÁCSI, Z.; BALÁZS, B. Specific features of NDVI, NDWI and MNDWI as reflected in land cover categories. **Landscape & Environment**, Washington, DC, v. 10, n. 3/4, p. 194–202, 2016.

SERELE, C. Z. *et al.* Corn yield prediction with artificial neural network trained using airborne remote sensing and topographic data. *In*: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2000, Honolulu. **Proceedings of the IGARSS 2000**. Piscataway: IEEE, 2000. v. 1, p. 384–386.

SIBANDA, M.; MUTANGA, O.; ROUGET, M. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. **ISPRS Journal of Photogrammetry and Remote Sensing**, Basel, v. 110, p. 55–65, 2015.

SIMS, D. A. *et al.* Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, New York, v. 81, n. 2/3, p. 337–354, 2002.

TAN, B. *et al.* An enhanced TIMESAT algorithm for estimating vegetation phenology metrics from MODIS data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 4, n. 2, p. 361-371, 2011.

TIECHER, T. *et al.* Phosphorus application and liming effects on forage production, floristic composition and soil chemical properties in the Campos biome, southern Brazil. **Grass and Forage Science**, Oxford, v. 69, n. 4, p. 567–579, 2013.

TIEDEMANN, J. L. Fenología del bosque de las subregiones naturales: Chaco, Semiárido y Chaco Serrano, de Santiago del Estero, Argentina. **Ecología Aplicada**, Lima, v. 10, n. 2, p. 51-59, 2011.

THERNEAU, T.; ATKINSON, B. **Rpart**: recursive partitioning and regression trees. Vienna: R Foundation, 2019. Disponível em: <https://cran.r-project.org/web/packages/rpart/rpart.pdf> . Acesso em: 10 mar. 2023.

THUROW, J. M. *et al.* Estrutura da vegetação e comportamento ingestivo de novilhos em pastagem natural do Rio Grande do Sul. **Revista Brasileira de Zootecnia**, Viçosa, MG, v. 38, n. 5, p. 818-826, 2009.

TODD, S. W.; HOFFER, R. M.; MILCHUNAS, D. G. Biomass estimation on grazed and ungrazed rangelands using spectral indices. **International Journal of Remote Sensing**, London, v. 19, p. 427–438, 1998.

TOIVONEN, T.; LUOTO, M. Landsat TM images in mapping of semi-natural grasslands and analysing of habitat pattern in an agricultural landscape in south-west Finland. Fenn. **International Journal of Geographical Information Science**, London, v. 181, p. 49–67, 2003.

ULLAH, S.; SI, Y. *et al.* Estimation of grassland biomass and nitrogen using MERIS data. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 19, p. 196–204, 2012.

VERMOTE, E. F. *et al.* Second simulation of the satellite signal in the solar spectrum, 6s: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 35, n. 3, p. 675–686. 1997.

WU, H. *et al.* A semi-arid grazing ecosystem simulation model with probabilistic and fuzzy parameters. **Ecological Modelling**, Amsterdam, v. 90, p. 147–160, 1996.

- XIE, Y. *et al.* A comparison of two models with Landsat data for estimating above ground grassland biomass in Inner Mongolia, China. **Ecological Modelling**, Amsterdam, v. 220, p. 1810–1818, 2009.
- XU, B. *et al.* MODIS-based remote sensing monitoring of grass production in China. **International Journal Remote Sensing**, London, v. 29, p. 5313–5327, 2008.
- XU, D. *et al.* Measuring the dead component of mixed grassland with landsat imagery. **Remote Sensing of Environment**, New York, v. 142, p. 33–43, 2014.
- WAGNER, A. P. L. *et al.* Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 48, n. 9, p. 1192-1200, 2013.
- WEIER, J.; HERRING, D. **Measuring vegetation (NDVI & EVI)**. [S.l.]: NASA Earth Observatory, 30 Aug. 2000. Disponível em: <https://earthobservatory.nasa.gov/features/MeasuringVegetation>. Acesso em: 25 jan. 2023.
- WYLIE, B. K. *et al.* Satellite and ground-based pasture production assessment in Niger: 1986–1988. **International Journal Remote Sensing**, London, v. 12, n. 6, p. 1281–300, 1991.
- ZAGAJEWSKI, B. *et al.* Intraspecific differences in spectral reflectance curves as indicators of reduced vitality in high-arctic plants. **Remote Sensing**, Basel, v. 9, [art.] 1289, 2017.
- ZHA, Y. *et al.* A spectral reflectance-based approach to quantification of grassland cover from Landsat TM imagery. **Remote Sensing Environment**, New York, v. 87, p. 371–375, 2003.
- ZHANG, X. *et al.* Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, New York, v. 84, p. 471-475, 2003.