



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

ESTIMATIVAS DE VARIÁVEIS BIOFÍSICAS DE VEGETAÇÃO CAMPESTRE SOB
MANEJO PASTORIL POR MEIO DE SENSORIAMENTO REMOTO

Marildo Guerini Filho

Porto Alegre, 05 de maio de 2018

Marildo Guerini Filho

**ESTIMATIVAS DE VARIÁVEIS BIOFÍSICAS DE VEGETAÇÃO CAMPESTRE SOB
MANEJO PASTORIL POR MEIO DE SENSORIAMENTO REMOTO**

Dissertação apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul (UFRGS), como requisito para obtenção do grau de Mestre em Sensoriamento Remoto.

Orientado: Marildo Guerini Filho

Orientador: Prof. Dr^a. Tatiana Mora Kuplich

Porto Alegre, 05 de maio de 2018

FICHA CATALOGRÁFICA

Marildo Guerini Filho

**ESTIMATIVAS DE VARIÁVEIS BIOFÍSICAS DE VEGETAÇÃO CAMPESTRE SOB
MANEJO PASTORIL POR MEIO DE SENSORIAMENTO REMOTO**

Dissertação apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul (UFRGS), como requisito para obtenção do grau de Mestre em Sensoriamento Remoto.

Aprovado em 05 de maio de 2018:

Tatiana Mora Kuplich, Dr^a. (INPE)
(Orientadora)

Denise Cybis Fontana, Dr^a. (UFRGS)

Valério De Patta Pillar, Dr. (UFRGS)

Cláudio Wilson Mendes Junior, Dr. (UFRGS)

Porto Alegre, 05 de maio de 2018.

“Os principais problemas ambientais são a apatia, a ganância e o egoísmo. E para lidar com estes, necessitamos de uma transformação espiritual e cultural”.

Gus Speth

*À minha família, pela dedicação e esforço em
minha educação.
Ao Senhor maior, por me conceder mais esta
etapa de muito conhecimento e sabedoria.*

AGRADECIMENTOS

Aos meus pais, Marildo Carnetti Guerini e Marilene Zenati Guerini e à minha irmã, Viviane Guerini, pelo carinho e apoio, fundamentais para a realização desta etapa de minha vida;

À minha orientadora, Prof. Dr^a. Tatiana Mora Kuplich, pela oportunidade concedida, paciência, exemplo, ensinamentos e por acreditar na minha capacidade de realizar este trabalho. Pelo incentivo e apoio dispensados ao longo da construção desta dissertação, gratidão;

Aos Professores, Fernando Luiz Ferreira de Quadros e Valério De Patta Pillar por todas as contribuições na realização deste trabalho;

À minha namorada, Jéssica, pelo carinho, compreensão e apoio em todos os momentos desta caminhada;

Aos colegas, Bruno Castro Kuinchtner, Virindiana Colet Bortolotto, Diniz Carvalho de Arruda, Adriana Coromoto Becerra Rondon, Alberto Senra Gonçalves pela colaboração, companheirismo e pela amizade;

À Universidade Federal de Rio Grande do Sul, pela oportunidade de desenvolver e concluir este projeto;

À CAPES pelo auxílio financeiro e concessão da bolsa durante a realização deste estudo;

Com carinho, emano a todos minha gratidão.

RESUMO

O Bioma Pampa representa aproximadamente 63% do território do Estado do Rio Grande do Sul - Brasil caracteriza-se pela alta biodiversidade de espécies vegetais e por sua formação predominantemente campestre. Em função da contínua incorporação de espécies exóticas, monoculturas e a práticas por vezes inadequadas de manejo pastoril para produção pecuária, os campos do Bioma Pampa estão rapidamente sendo degradados, fragmentados e descaracterizados. A Biomassa é uma das variáveis biofísicas estratégicas de interesse em estudos de controle, monitoramento e estimativas da vegetação campestre. O objetivo principal deste estudo é contribuir no desenvolvimento de novas estratégias de manejo e monitoramento adequados da vegetação campestre e inferir regressão linear multivariada para estimar a biomassa dos campos nativos a partir de dados remotos e dados de campo. As avaliações foram realizadas em área pertencente à Universidade Federal de Santa Maria, localizada na região central do Rio Grande do Sul. Os manejos pastoris correspondem a duas somas térmicas acumuladas, em dias, de 375 e 750 graus-dias (GD), que determinaram os intervalos entre pastoreio. Os dados remotos utilizados foram oriundos de imagem MSI do Satélite Sentinel-2 e dados de espectrorradiômetro com amplitude de 350-2500 nm. Verificou-se que as duas técnicas apresentaram resultados satisfatórios, em que inferiu-se regressões com $r^2_{\text{ajustado}} = 0.65$ para estimar biomassa verde e regressões com $r^2_{\text{ajustado}} = 0.61$ para biomassa total e biomassa senescente. Desta forma, o estudo verificou que é possível minimizar os esforços de campo para auxiliar no monitoramento, organização e conservação dos campos nativos do Bioma Pampa utilizando dados de sensoriamento remoto como ferramenta de manejo buscando a sustentabilidade destes complexos ambientes naturais.

Palavras-chave: Bioma Pampa, campos nativos, biomassa, sensoriamento remoto

ABSTRACT

The Pampa Biome represents approximately 63% of the territory in the State of Rio Grande do Sul - Brazil, characterized by the high biodiversity of plant species and its predominantly rural formation. As a result of the continuous incorporation of exotic species, monocultures and excessive cattle production, the Pampa Biome fields are rapidly being degraded, fragmented and decharacterized. Biomass is one of the strategic biophysical variables of interest in studies of prevention, monitoring and estimates of the country vegetation. The main objective of this study is to contribute to the development of new strategies for the proper management and monitoring of the country vegetation and to infer multivariate linear regression to estimate the biomass of the natural grassland in native fields from remote data and field data. The evaluations were carried out in an area belonging to the Federal University of Santa Maria, located in the central region of Rio Grande do Sul. Pastoral management correspond to two accumulated thermal sums in days of 375 and 750 degrees-days (GD), which determined the intervals between grazing. The remote data used came from MSI image of Sentinel-2 Satellite and spectroradiometer data with amplitude of 350-2500 nm. It was verified that the two techniques presented satisfactory results, in which regressions with adjusted r^2 of 0.65 were estimated to estimate green biomass and regressions with adjusted $r^2 > 0.61$ for total biomass and dry biomass. In this way, the study verified that it is possible to minimize the field efforts to assist in the monitoring, organization and conservation of the natural grassland in native fields of the Pampa Biome using remote sensing data as a management tool seeking the sustainability of these complex natural environments.

Keywords: Pampa biome, natural grassland, native fields, biomass, remote sensing

LISTA DE TABELAS

CAPITULO I

Tabela 01 – Características das bandas MSI na imagem Sentinel-2.....	24
Tabela 02 – índices de vegetação utilizados	25
Tabela 03 - Valores médios por tratamento das bandas espectrais (Tabela 1), índices de vegetação (Tabela 2) e variáveis relacionadas à biomassa aérea da pastagem natural.....	27
Tabela 04 - Associação dos pontos de imagem com os dados de biomassa coletados em campo nos dois tratamentos	29
Tabela 05 - Associação dos pontos de imagem com os dados de biomassa coletados em campo no tratamento 375.....	29
Tabela 06 - Associação dos pontos de imagem com os dados de biomassa coletados em campo no tratamento 750.....	30
Tabela 07 - Regressões múltiplas	31

CAPÍTULO II

Tabela 01 – Divisão do espectro em intervalos	43
Tabela 02 – Índices de vegetação utilizados	43
Tabela 03 - Comparação entre os piquetes	45
Tabela 04 - Diferença entre tratamentos.....	47
Tabela 05 - Regressão multivariada.....	49

LISTA DE FIGURAS

CAPITULO I

Figura 01 – Metodologia seguida para estimativas de biomassa	22
Figura 02 - Localização da área de estudo. Santa Maria situa-se na área central do estado do Rio Grande do Sul, no sul do Brasil. Em detalhe a divisão dos piquetes sobre imagem do satélite Sentinel 2	23
Figura 03 - a) Fisionomia característica do tratamento 375 GD e detalhe da unidade amostral; b) fisionomia característica do tratamento 750 GD e detalhe da unidade amostral.	25
Figura 04 – Matrizes de correlação entre as variáveis avaliadas: a) matriz de correlação do tratamento 375 GD. b) matriz de correlação tratamento 750 GD	28
Figura 05 – Dispersão dos valores estimados por sensoriamento remoto vs estimados por avaliação de campo em conjunto com a reta de regressão.	32

CAPITULO II

Figura 01 – Fluxograma metodológico	42
Figura 02 – Estado do RS no Brasil; Santa Maria situa-se na área central do RS e, em detalhe o município de Santa Maria e a área experimental na UFSM.	42
Figura 03 – a) momento da coleta das unidades amostrais de biomassa e dados do espectrorradiômetro; b) fisionomia característica do tratamento 375 GD; c) fisionomia característica do tratamento 750 GD.....	44
Figura 04 – Curvas espectrais médias dos, a) piquetes e b) tratamento	45
Figura 05 – Matriz de correlação a) 375 GD e b) 750 GD.....	48
Figura 06 – Correlação dos dados entre os piquetes no tratamento 375 GD	48
Figura 07 – Correlação dos dados entre os piquetes no tratamento 750 GD	48

SUMÁRIO

1	APRESENTAÇÃO	12
1.1	Introdução	12
1.2	Proposição.....	13
1.3	Revisão bibliográfica	14
2	CAPITULO I	19
	Estimativa de biomassa de pastagem natural por dados de sensoriamento remoto	
3	CAPITULO II.....	Erro! Indicador não definido.
	Avaliação de dados hiperespectrais como preditores para biomassa de campos nativos em dois métodos de manejo pastoril	
4	CONSIDERAÇÕES FINAIS.....	55
5	CONCLUSÕES.....	57
	REFERÊNCIAS GERAIS	58

1 APRESENTAÇÃO

1.1 Introdução

O espaço geográfico é considerado um conjunto de realizações que se apresentam como testemunho de uma história escrita por processos do passado e do presente. A paisagem é influenciada diretamente pela intervenção humana que determina a formação da paisagem nos distintos biomas e ecossistemas brasileiros (BRITO, 2006).

O ritmo, amplitude e alcance espacial das alterações humanas da superfície terrestre do planeta são sem precedentes. O uso da terra e as mudanças na cobertura desta afetam diretamente a diversidade biótica em todo o mundo, contribuindo para as alterações climáticas, sendo a principal fonte de degradação do solo e alterando a biodiversidade dos ecossistemas. Tais mudanças também podem determinar, em parte, a vulnerabilidade de lugares e pessoas para mudanças climáticas, descaracterização da paisagem, perturbações econômicas ou sócio-políticas (TILIO NETO, 2010).

Entre as formações vegetais mais importantes do planeta, por sua extensa área de cobertura e por ser habitat de incontáveis espécies animais e vegetais, estão as formações campestres. Apesar de servirem de fonte de alimento e serem tratados como “úteis” para a sociedade, os campos se encontram em permanente estado de ameaça, sendo facilmente fragmentados, convertidos ou degradados (OVERBECK *et al.*, 2015). Mesmo com a longa convivência do homem com os campos, vários aspectos da biologia e dos serviços ecossistêmicos fornecidos pelos campos encontram-se ainda desconhecidos.

Em busca da conservação e do uso sustentável dos Campos dos Biomas Pampa e Mata Atlântica, no Estado do Rio Grande do Sul, o Programa Ecológico de Longa Duração – PELD Campos Sulinos (CNPq - chamadas CNPq/Capes/FAPs/BC-Fundo Newton n°s 59/2009, 34/2012 315/2016) foi estruturado e esta pesquisa faz parte dele. O PELD está embasado em três questões fundamentais: (1) Como se estruturam as comunidades biológicas dos ecossistemas campestres e seus padrões funcionais de organização? (2) como essas comunidades respondem ao manejo pastoril e à dinâmica climática? e (3) como essas comunidades afetam processos e serviços ecossistêmicos? Algumas respostas a essas questões já estão disponíveis e junto com elas o melhor entendimento dos ecossistemas campestres contribuindo para tomadas de decisões referentes a conservação e manejo dos

Campos Sulinos. Neste contexto, como parte integrante do PELD, esta proposta visa avaliar e quantificar os serviços ecossistêmicos, concentrando-se na produção de biomassa, resultantes da combinação de dados de sensoriamento remoto e dados de campo.

O sensoriamento remoto (SR) tem sido bastante utilizado para estudos da vegetação, porém são menos numerosos os estudos para estimativas remotas de variáveis biofísicas, como a biomassa e/ou produtividade primária de áreas campestres (HILL *et al.*, 2004; OVERBECK *et al.*, 2007). A avaliação e quantificação de biomassa por SR ainda é um grande desafio, em que investigações se fazem necessárias para compreender e identificar os melhores métodos para minimizar as falhas e diminuir as incertezas (KUMAR *et al.*, 2015). Não há um consenso sobre as melhores práticas e métodos a serem abordados na caracterização e estimativa de biomassa nos ambientes campestres, nos quais, a utilização de dados coletados em campo é essencial para compreender e aferir a biomassa através do SR (JIA *et al.*, 2016).

Neste contexto, a caracterização e estimativa da biomassa campestre é essencial para a avaliação de práticas de manejo, para que a densidade de animais domésticos por unidade de área possa ser mais facilmente ajustada à capacidade suporte dos ecossistemas. Assim, desenvolver ferramentas que possibilitem auxiliar no mapeamento, monitoramento e conservação dos serviços ecossistêmicos prestados pelas áreas campestres é um desafio a todos os pesquisadores destes complexos ambientes, almejando a sustentabilidade dos recursos naturais, visando minimizar impactos negativos da utilização inadequada dos campos.

1.2 Proposição

A preservação e conservação das áreas campestres vêm sendo negligenciada há anos (OVERBECK *et al.*, 2007, 2009). Conforme o Ministério do Meio Ambiente (2010) o Bioma Pampa é o segundo bioma mais devastado do Brasil, do qual restam apenas 36% de sua área original. Segundo Cordeiro & Hasenack (2009), a transformação dos campos em áreas agrícolas/pastagens e de silvicultura já ultrapassou 50% da área originalmente campestre. Essas mudanças estão causando a perda de habitat e a fragmentação desses ecossistemas, acarretando consequências graves nos padrões da biodiversidade e aumento no

risco de extinção de espécies nativas da flora e da fauna silvestre (VÉLEZ-MARTIN, E. *et al.*, 2015).

Este estudo tem como objetivo quantificar as relações entre as respostas espectrais e biomassa da vegetação campestre de duas tipologias de manejo pastoril utilizando dados de sensoriamento remoto. Uma vez que os diferentes manejos pastoris possam ser discriminados e suas biomassas estimadas remotamente, a minimização de esforços de coletas de campo e o monitoramento remoto dos campos nativos dos biomas Pampa e Mata Atlântica serão facilitados.

1.3 Revisão bibliográfica

Os campos do sul do Brasil, são ecossistemas naturais que já caracterizavam essa região bem antes da expansão das formações florestais ocorrida após a metade do Holoceno (BEHLING; PILLAR, Valério DePatta, 2007; DÚMIG *et al.*, 2008). Esses ecossistemas campestres, pela classificação do IBGE, estão incluídos no bioma Pampa na porção sul e oeste do Rio Grande do Sul e no Bioma Mata Atlântica nas partes mais altas do Planalto Meridional, onde estão associados a florestas com Araucária.

As pastagens que compõem esta região possuem grande sazonalidade na geração de biomassa vegetal, que são determinadas pelas variações climáticas interanuais e em relação às técnicas de pastejo adotadas. Segundo Fonseca (2007) o manejo pastoril atuou fortemente para a caracterização e composição florística atual da vegetação campestre. Os campos fornecem importantes serviços ecossistêmicos, e entre eles, conforme Boldrini (2009) e Boldrini & Overbeck (2015), a principal fonte forrageira para as atividades pastoris, que no Rio Grande do Sul é um dos principais setores da economia (PILLAR, V. D. P. *et al.*, 2009).

O manejo pecuário por vezes incorreto e excessivo tem levado a extenuação e degradação (ANDRADE *et al.*, 2015) desses ecossistemas, tanto na diversidade de espécies como na sua composição e nos processos ecológicos, podendo assim afetar funções que garantem os serviços ecossistêmicos já mencionados. Desta forma, há necessidade de que as boas práticas de manejo pastoril para o aproveitamento do potencial forrageiro dos campos e a conservação da sua biodiversidade sejam aprimoradas e que sejam efetivamente adotadas nos sistemas de produção como forma de desenvolver uma atividade econômica sustentável e competitiva neste tipo singular de ecossistema. Além disso, o cumprimento da Lei de

Proteção da Vegetação Nativa (Lei 12.651/2012), com a delimitação da Reserva Legal em áreas de campos nativos, demandará conhecimento adequado sobre as melhores práticas de manejo com vistas à conservação e uso sustentável da biodiversidade.

Imagens e dados obtidos por sensoriamento remoto são ferramentas essenciais para a caracterização de ambientes naturais ou manejados. Além das imagens de SR cobrirem extensas áreas na superfície terrestre e tornar possíveis mapeamentos de grande escala, existe a possibilidade de extrapolar relações obtidas em regiões específicas, dependendo da consistência e estabilidade da variável ecossistêmica estudada (KUPLICH *et al.*, 2016).

O estudo de ecossistemas campestres com dados de sensoriamento remoto já conta com algumas décadas de resultados, e, entre estes, está a possibilidade de monitoramento da produtividade/biomassa, já que a fenologia dos campos exhibe padrões característicos registráveis. Exemplo da utilização bem-sucedida do NDVI para o monitoramento da produtividade de campos acontece na Austrália (HILL *et al.*, 2004), servindo de subsídio para os pecuaristas na região.

Mesmo com a existência de usos já operacionais dos dados de sensoriamento remoto para ecossistemas campestres, ainda se encontram lacunas no conhecimento a respeito do comportamento espectral e espacial das tipologias campestres com suas diversas características funcionais. Para o caso da detecção e quantificação de serviços ecossistêmicos nestas áreas, os estudos, apesar de pouco numerosos, reforçam a importância da utilização de dados de sensoriamento remoto. Mapas de cobertura da terra, para áreas com diferentes usos, e mapas específicos com a espacialização de variáveis representativas do funcionamento dos ecossistemas em estudo, como a biomassa, são exemplos de dados gerados com suporte de sensoriamento remoto.

Atualmente a utilização de imagens e técnicas de sensoriamento remoto para estudos da vegetação em suas diferentes formas é essencial para, entre outros, mapeamentos, como dados de entrada em modelos agrometeorológicos, estimativas de fluxos de carbono e conservação do solo (CASSOL, 2013; FONSECA, E. L. da; FORMAGGIO; PONZONI, 2007; KUPLICH; MOREIRA; FONTANA, 2013; OVERBECK, G. *et al.*, 2015; SANTOS *et al.*, 2006; TRENTIN *et al.*, 2011). Desta forma, os padrões de resposta espectrais avaliados a partir de sensoriamento remoto são condicionados pelas características das comunidades vegetais, sendo assim possível identificar diferenças nos padrões de refletância em função do manejo pastoril.

O monitoramento da cobertura vegetal bem como estimativas de produção de biomassa com dados de SR são abordados há aproximadamente quatro décadas. Especificamente para vegetação campestre, Tucker et al. (1985), estimaram a produção de biomassa herbácea de uma área em Senegal com produtos NOAA-6 e 7 para o período de 1980 a 1984 e verificaram forte correlação dos dados de biomassa seca e dados do satélite NOAA-7. Anos depois Anderson; Hanson & Haas (1993), verificaram a potencialidade de índices de vegetação para avaliar biomassa de áreas de pastagens no Nordeste do Colorado utilizando dados Landsat TM (*Thematic Mapper*). Com a abordagem foram encontradas fortes associações entre a biomassa e o Índice de vegetação de diferença normalizada (NDVI) e indicando a possibilidade de previsão de biomassa utilizando modelos de regressão univariada naquela região.

De acordo com Jensen (2009), os índices de vegetação (IV), são medidas radiométricas adimensionais, que indicam a abundância relativa e a atividade da vegetação verde, incluindo o índice de área foliar (IAF), porcentagem de cobertura verde, teor de clorofila, biomassa verde e radiação fotossinteticamente absorvida (RFAA). Que minimizam os efeitos da iluminação da cena, declividade da superfície e geometria de aquisição que influenciam os valores de refletância da vegetação. Muitos índices usam a relação inversa entre as reflectâncias no vermelho e no infravermelho próximo associadas a vegetação verde sadia.

Os IV são combinações matemáticas da resposta espectral de diferentes bandas do espectro eletromagnético, sendo que os principais índices citados na literatura utilizam os valores da reflectância em duas faixas de comprimento de onda, o vermelho e o infravermelho próximo. Além disto, estes índices condensam o volume de dados a ser analisado e permitem a avaliação de diferenças nas condições de crescimento, com base nas relações existentes entre estes índices e as variáveis biofísicas da vegetação, bem como, com as características estruturais e fisiológicas da mesma (FONSECA, E. L. Da, 2004; PAN *et al.*, 2015; PRABHAKARA; DEAN HIVELY; MCCARTY, 2015)

Du Plessis (1999) abordou a relação entre o IV NDVI, a vegetação (biomassa) e dados de precipitação pluviométrica no Parque Nacional de Etosha – Namíbia através de regressão linear. Os resultados do estudo mostraram-se eficazes e satisfatórios para relacionar cobertura vegetal e biomassa com NDVI e precipitação pluviométrica. Fonseca (2004) em sua tese desenvolveu um modelo denominado JONG – assim denominado em

homenagem ao pesquisador José Otavio Neto Gonçalves, para estimar a disponibilidade de fitomassa aérea nas formações campestres naturais a partir de dados espectrais orbitais e agrometeorológicos. O submodelo espectral avalia as condições iniciais de vegetação, as reflectâncias das bandas ETM + 7 e ETM + 3 e a componente Wetness da transformação de Tasseled Cap. Os resultados mostraram que o modelo foi sensível para as variações espaciais de forragem e a diminuição da produção em função de déficit hídrico durante o período de crescimento vegetativo das plantas após a total cobertura do solo, não sendo válido para outros estádios fenológicos da vegetação.

Terra; Fonseca & Saldanha (2010) concentraram seus estudos para avaliar o desempenho preditivo do modelo JONG com o acréscimo de variáveis espectrais que contemplassem a densidade de biomassa do dossel e as contribuições dos diferentes solos subjacentes. Os índices calculados pela diferença e razão simples – entre as bandas 4 e 3, 4 e 5, 4 e 7, do satélite Landsat 7/sensor ETM+ – foram sugeridos para representar a contribuição espectral dos solos e a influência das diferenças estruturais dos dosséis. Com a aplicação dos novos parâmetros a componente espectral do modelo JONG apresentou maior sensibilidade para eliminar as influências do solo e do dossel na predição de biomassa, facilitando a interpretação dos resultados.

Na Nova Zelândia, Edirisinghe; Clark & Waugh (2012), examinaram o NDVI, oriundo de imagens de sensores de média resolução espacial dos satélites SPOT-4 e SPOT-5 para prever a biomassa de pastagens para gado leiteiro com alta pressão de pastejo. Na análise, os autores encontraram dependência significativa do tempo ao longo das estações, e forte correlação positiva entre o NDVI e a biomassa indicando alto potencial do SR para prever e monitorar a biomassa de pastagens.

Áreas compostas por campos ou pastagens são facilmente fragmentadas e encontram-se em uma zona de conflito entre a agricultura/pecuária e a conservação da biodiversidade destes ecossistemas. Buscando apoiar esquemas de manejo e manutenção destas áreas, os estudos de Franke; Keuck e Siegert (2012) avaliaram o potencial de utilização de imagens de alta resolução (RapidEye) para diferenciar tipos de manejos em uma área no sul da Alemanha e obtiveram resultados relativamente melhores a este estudo apresentando classificações com precisão geral de 82% para áreas de pastagens.

Hill (2013), verificou que a partir de dados Sentinel 2 simulados a partir de dados hiperespectrais Hyperion foi possível caracterizar os tipos de uso do solo a partir de dados

brutos em conjunto com índices de vegetação. Os estudos de Frampton et. al (2013), avaliaram por meio de índices de vegetação a eficácia do Sentinel 2 para estimar variáveis biofísicas de vegetação, indicando correlações significativas entre os dados remotos com LAI (índice de área foliar) e índice de clorofila.

A pesquisa realizada por Sibanda et al. (2015), comparou o potencial para estimar biomassa em diferentes condições de fertilidade de pastagens utilizando dados Sentinel 2 e Landsat 8, os resultados apresentaram excelentes ajustes e acurácias nas avaliações para ambos os satélites, com r^2 de 0.81 para Sentinel 2 e r^2 de 0.72 para Landsat, os resultados superaram os valores encontrados nesta pesquisa, podendo ser explicado em função da característica amostral, das condições ambientais nas datas de coletas e também pelo estado fisiológico das gramíneas.

Considerando as diferentes interações que influenciam a detecção remota da biomassa para diferentes sensores, bem como as variações nas características das biomassas para obter os valores dos dados remotos, os resultados obtidos nesta pesquisa indicam que a utilização de dados oriundos de imagem de satélite e de espectrorradiômetro apresentam capacidade e robustez para avaliações e monitoramento de campos nativos, corroborando com os resultados de outros autores que dedicam suas pesquisas para analisar a relação da biomassa com dados de diferentes satélites (CLEVERS *et al.*, 2007; DELEGIDO *et al.*, 2011; FRAMPTON *et al.*, 2013; KUPLICH; MOREIRA; FONTANA, 2013; WEBER, D.; SCHAEPMAN-STRUB; ECKER, 2018)

Para finalizar, os estudos realizados por Corbane *et al.* (2015) através da análise de 128 referências sobre mapeamento e monitoramento da conservação de habitats naturais e os trabalhos de (GÓMEZ GIMÉNEZ *et al.*, 2017; KUPLICH *et al.*, 2016; LIMA JUNIOR *et al.*, 2014; SCHUSTER *et al.*, 2015; SUN *et al.*, 2017; WAGNER *et al.*, 2013; ZHU, Xiaolin; LIU, D., 2015) observaram que, técnicas de sensoriamento remoto podem contribuir consideravelmente e para o entendimento e compreensão das dinâmicas temporais de diversas fenologias individualmente.

2 CAPITULO I

ESTIMATIVA DE BIOMASSA DE PASTAGEM NATURAL POR DADOS DE SENSORIAMENTO REMOTO

Este capítulo após tradução será submetido para a revista **Remote Sensing**.

ESTIMATIVA DE BIOMASSA DE PASTAGEM NATURAL POR DADOS DE SENSORIAMENTO REMOTO

Marildo Guerini Filho¹, Tatiana Mora Kuplich², Fernando L. F. de
Quadros³

¹Universidade Federal do Rio Grande do Sul

Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia

guerinimarildo@gmail.com

²Instituto Nacional de Pesquisas Espaciais, Universidade Federal do Rio Grande do Sul

Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia

tkuplich@gmail.com

³Universidade Federal de Santa Maria

Laboratório de Ecologia de Pastagens Naturais

flfquadros@gmail.com

Resumo - A estimativa da biomassa foi realizada em uma pastagem natural do Bioma Pampa no sul do Brasil, através de uma abordagem que incluiu dados de campo, dados de sensoriamento remoto e modelos estatísticos para previsão da biomassa. Foram avaliadas duas alternativas de pastoreio rotativo com intervalos de descanso baseados em somas térmicas (375 e 750 Graus Dia) com uma imagem do sensor MSI (*MultiSpectral Instrument*) a bordo do satélite Sentinel-2 e calibradas por 57 unidades amostrais de biomassa coletadas a campo. Inicialmente realizou-se o pré-processamento da imagem, extração dos valores de refletância das bandas Sentinel-2, reamostragem dos pixels para 20 metros e cálculo dos índices de vegetação. Na sequência foram computadas as análises estatísticas dos dados e verificaram-se significativas correlações entre os valores de biomassa obtidos no campo com os dados remotos. Consideradas significativas as correlações, aplicaram-se análises de regressão linear múltipla, em cada intervalo de descanso, usando as variáveis de sensoriamento remoto como preditoras (independentes) da biomassa (dependente). Dentre as variáveis, cabe destacar a significativa correlação da faixa do *Red Edge* do espectro com a biomassa. As equações para estimativa de biomassa verde apresentaram coeficientes de determinação de $r^2=0.51$ para o tratamento 375 GD e $r^2=0.65$ para o tratamento 750 GD, já a biomassa senescente e a biomassa total geraram ajustes com $r^2 \leq 0.50$ nos dois tratamentos. Independente dos intervalos avaliados demonstrarem estimativas de biomassa com coeficientes de determinação satisfatórios, esquemas de amostragem em diferentes períodos do ano e diferentes variáveis devem ser exploradas visando melhorar a acurácia nas estimativas.

Palavras-chave: campos nativos, biomassa, Sentinel-2, dados remotos, geoinformações

1 Introdução

A copiosidade da biodiversidade do Bioma Pampa vem sendo ameaçada há décadas. A introdução progressiva de monoculturas de espécies exóticas e agrícolas e a utilização por vezes inadequada para produção agropecuária estão ocasionando rápida degradação e descaracterização dos campos do Bioma Pampa (OVERBECK, G. *et al.*, 2015; OVERBECK, G. E. *et al.*, 2007). Além da perda de habitat, essas transformações estão causando a fragmentação dos ecossistemas campestres, gerando mudanças nos padrões da biodiversidade e principalmente aumento nos riscos de extinção de espécies nativas da flora e da fauna silvestre (PILLAR, V. De P.; VÉLEZ, 2010; VÉLEZ-MARTIN, E. *et al.*, 2015). O Bioma Pampa corresponde a 63% do território do Rio Grande do Sul, comporta a maior parte do aquífero Guaraní e estima-se que restam apenas 36% da área original de campos nativos do Bioma (CORDEIRO; HASENACK, 2009).

A biomassa da vegetação campestre é diretamente influenciada pelas diferentes formas de manejo pastoril às quais é submetida, sendo de grande importância avaliar, quantificar e monitorar os processos envolvidos e seus efeitos na vegetação, que também terão efeito nas taxas de produção pecuária.

Imagens e dados obtidos por sensoriamento remoto são ferramentas essenciais para a caracterização de ambientes naturais ou manejados. Além das imagens de SR cobrirem extensas áreas na superfície terrestre e tornar possíveis mapeamentos de grande escala, existe a possibilidade de extrapolar relações obtidas em regiões específicas, dependendo da consistência e estabilidade da variável ecossistêmica estudada (KUPLICH *et al.*, 2016). A detecção remota da biomassa campestre gera informações espectrais, temporais e espaciais, possibilitando medições de extensas áreas simultaneamente, minimizando os esforços com procedimentos laboratoriais e de coletas de campo.

Os índices de vegetação são combinações matemáticas da resposta espectral de diferentes bandas do espectro eletromagnético, sendo que os principais índices citados na literatura utilizam os valores da reflectância em três faixas de comprimento de onda, o vermelho, a borda do vermelho (red edge) e o infravermelho próximo. Além disto, estes índices condensam o volume de dados a ser analisado e permitem a avaliação de diferenças nas condições de crescimento, com base nas relações existentes entre estes índices e as variáveis biofísicas da vegetação, bem como, com as características estruturais e fisiológicas da mesma (FONSECA, E. L., 2004; PAN *et al.*, 2015; PRABHAKARA; DEAN HIVELY; MCCARTY, 2015). Os índices de vegetação são indicadores da atividade fotossintética e vigor da vegetação, apresentando-se como variáveis preditoras para análises de series

temporais, monitoramentos, estimativas e estudos de detecção de mudanças de vegetação (BRANTLEY; ZINNERT; YOUNG, 2011; HILL, 2013).

Há uma longa história de pesquisas utilizando dados de sensoriamento remoto para caracterização e estimativa de biomassa campestre (DUSSEUX *et al.*, 2015; JIA *et al.*, 2016). Muitos deles apresentam estimativas com precisões superiores a 80%, porém apresentam alta complexidade para reprodução dos modelos, não estabelecendo relações diretas entre biomassa e índices de vegetação derivados de imagens de satélite (FALLDORF *et al.*, 2014). Para vegetação campestre, onde a matéria senescente é parte importante do dossel, estas relações podem se apresentar fracas, já que a maior parte dos índices mede o vigor da vegetação verde.

Neste contexto, com o intuito de contribuir no desenvolvimento de novas estratégias de manejo e monitoramento da vegetação campestre, com vistas à minimização de esforços para coletas de campo, esta pesquisa objetivou avaliar a sensibilidade de dados gratuitos do sensor multiespectral MSI Sentinel 2 para estimar biomassa em duas alternativas de pastoreio rotativo com intervalos de descanso baseados em somas térmicas.

2 Materiais e métodos

A **Figura 01** apresenta o fluxograma metodológico desenvolvido nesta pesquisa, detalhado nos subitens seguintes.

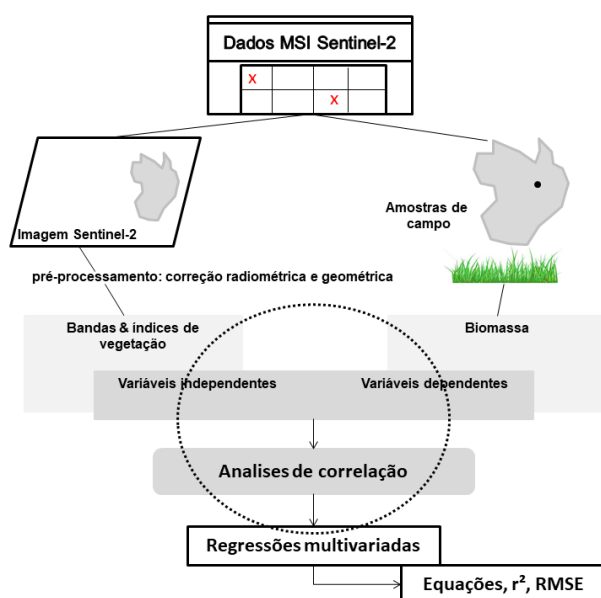


Figura 01 – Metodologia seguida para estimativas de biomassa

2.1 Área de estudo

O estudo foi realizado em área de 23 ha de campo nativo pertencente à Universidade Federal de Santa Maria, localizada na região fisiográfica Depressão Central do Rio Grande

do Sul com coordenadas geográficas 29°43'37.98''S e 53°46'43.11''W (**Figura 02**). As coletas de campo foram conduzidas entre os dias 23 e 30 de novembro de 2017. A área está a 95 m de altitude em relação ao nível do mar e apresenta clima subtropical úmido (Cfa) segundo a classificação de Köppen. Santa Maria tem média mensal de temperatura mínima de 19.4 °C e máxima de 30.4 °C e pluviosidade média anual de 1688mm (STRECK, 2008).

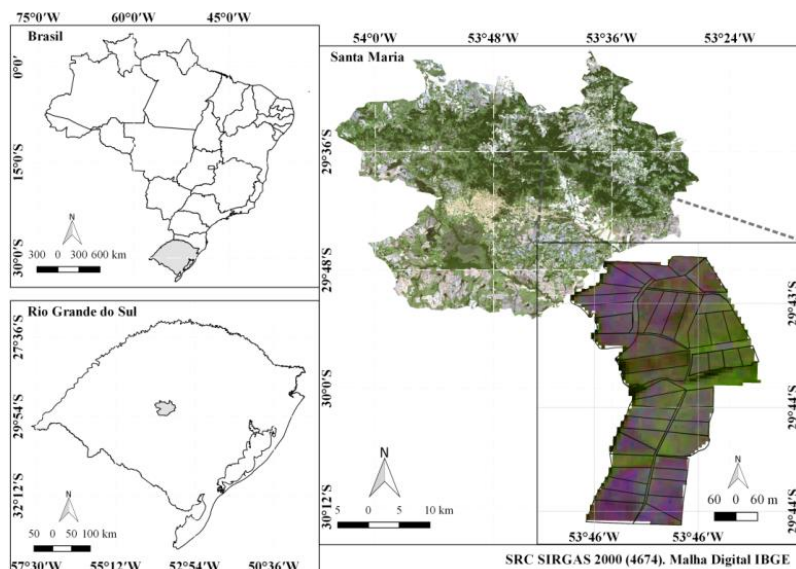


Figura 02 - Localização da área de estudo. Santa Maria situa-se na área central do estado do Rio Grande do Sul, no sul do Brasil. Em detalhe a divisão dos piquetes sobre imagem do satélite Sentinel 2

Nesta área, duas alternativas de pastoreio rotativo são utilizadas, com intervalos de descanso baseados na soma térmica acumulada, em dias, para atingir 375 e 750 graus, respectivamente. Esses intervalos permitem atingir a duração da expansão de lâminas foliares de dois grupos funcionais de gramíneas classificados conforme o estudo proposto por Cruz et al. (2010). Estes critérios resultaram em tratamentos com intervalos de 375 e 750 graus dia (GD). Cada tratamento é subdividido em unidades experimentais (piquetes) de aproximadamente 0,5 ha cada. Para o estudo foram selecionados previamente 5 piquetes em cada tratamento. No período de estudo, esses piquetes tiveram intervalos de descanso entre 11 a 22 dias, respectivamente para os tratamentos 375 e 750 GD.

2.2 Processamento da imagem

A missão SENTINEL está sendo desenvolvida pela Agência Espacial Europeia – ESA e pela Comissão Europeia – CE. Dentre os satélites em operação, foram utilizados dados da série SENTINEL-2. O lançamento da missão SENTINEL-2 ocorreu em 23 de junho de 2015 (são dois satélites com órbita sol-síncrona e 13 bandas espectrais (**Tabela 01**), com variada resolução espacial (10, 20 ou 60 m, dependendo da banda) e uma resolução temporal de 5 dias com os dois satélites operacionais.

Para a pesquisa utilizou-se uma imagem Sentinel 2 com data de 24 de novembro de 2017. Em função das características da área de estudo foram selecionadas as bandas do sensor MSI (Multispectral Instrument) B2,B3,B4,B5 e B8 para a pesquisa. Para atenuar os efeitos causados por componentes ativos da atmosfera na reflectância de superfície, a imagem foi submetida ao processo de correção atmosférica com aplicação do modelo 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) desenvolvido por Vermote et al. (1997) e todos os pixels foram reamostrados para 20m.

Tabela 01 – Características das bandas MSI na imagem Sentinel-2

Sensor	Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Temporal
MSI – MultiSpectral Instrument	(B1) aerossol	0.443	60 m	5 dias
	(B2) azul	0.490	10 m	
	(B3) verde	0.560		
	(B4) vermelho	0.665	20 m	
	(B5) NIR-RE*	0.705		
	(B6) NIR-RE*	0,740	10 m	
	(B7) NIR-RE*	0.783		
	(B8) NIR*	0.842	20 m	
	(B8a) NIR-RE*	0.865	60 m	
	(B9) SWIR**	0.940	20 m	
	(B10) SWIR**	1.375		
	(B11) SWIR**	1.610		
(B12) SWIR**	2.190			

*Infravermelho próximo e *Red Edge*; **Infravermelho de ondas curtas;

Os índices de vegetação (IVs) são comumente utilizados como variáveis preditoras para qualificar e quantificar a biomassa de florestas e vegetação em geral. Este estudo examinou, além das bandas já mencionadas, 5 IVs (**Tabela 02**), dois deles (NDVI e EVI) amplamente conhecidos por suas correlações com a biomassa (GONZÁLEZ-DUGO; MATEOS, 2008; HMIMINA *et al.*, 2013; XU, D. *et al.*, 2014).

Foram testadas variações nos índices normalmente utilizados, com a inclusão da primeira banda da região da borda do vermelho (*red edge*) do espectro. A utilização desta região vem se intensificando a partir do lançamento das missões dos satélites Sentinel e Rapideye, uma vez que alguns estudos abordaram a importante relação entre a reflectância do *red edge* com clorofila e outros nutrientes presentes na estrutura celular da planta (FRAMPTON *et al.*, 2013; JU *et al.*, 2010). Considerando a presença de biomassa senescente, o índice PSRI é utilizado em análises, estimativas e monitoramento da atividade fotosinteticamente ativa, mas também níveis de senescência da vegetação (SIMS; GAMON, 2002).

Tabela 02 – índices de vegetação utilizados

Índice	Nome	Citação	Formula
EVI-B5	<i>Enhanced vegetation index</i>	Huete (1997)	$B = 2.5(B5 - B4)/(B5 + 6 \times B4 - 7.5 \times B2 + 1)$
EVI-B8	<i>Enhanced vegetation index</i>	Huete (1997)	$B = 2.5(B8 - B4)/(B8 + 6 \times B4 - 7.5 \times B2 + 1)$
NDREI	<i>Normalized difference red edge index</i>	Gitelson and Merzlyak (1994)	$B = (B5 - B4)/(B5 + B4)$
NDVI	<i>Normalized difference vegetation index</i>	Tucker (1979)	$B = (B8 - B4)/(B8 + B4)$
PSRI	<i>Plant senescence reflectance index</i>	Merzlyak et al. (1999)	$B = (B4 - B2)/B5$

2.3 Análises de campos

As coletas dos dados de campo foram realizadas com o auxílio da equipe técnica do Departamento do Zootecnia da Universidade Federal de Santa Maria no período de 23 a 30 de novembro de 2017. A biomassa total - BT, biomassa verde total – BVT e biomassa senescente total – BST dos piquetes selecionados foram determinadas através da técnica de estimativa visual por comparação de padrões, calibrada por dupla amostragem (HAYDOCK; SHAW, 1975), com 10 estimativas cortadas em quadros de 0,25 m² e estimativas visuais. Já para a estimativa do percentual de biomassa verde e senescente em cada amostra foi realizada a avaliação visual por meio de fotos utilizando a metodologia descrita pelo Instituto Nacional de Investigação Agropecuária - Uruguai. Na **Figura 03** são apresentadas imagens da fisionomia de cada tipo de manejo pastoril. Em função da experiência no assunto, esta avaliação foi realizada com o acompanhamento da equipe do Laboratório de Ecologia de Pastagens Naturais (LEPAN) da UFSM. Em cada amostra foram anotadas as medidas de altura média do dossel, com o auxílio de régua graduada.




Figura 03 - a) Fisionomia característica do tratamento 375 GD e detalhe da unidade amostral; b) fisionomia característica do tratamento 750 GD e detalhe da unidade amostral.

2.4 Análises estatísticas

Os dados foram analisados nos programas estatísticos SPSS 22.0 e RStudio 1.0.153. Foram avaliadas estatísticas descritivas (frequências, percentuais, médias e desvios-padrão) e bivariadas (testes t de Student para amostras independentes, Mann-Whitney, ANOVA, Kruskal-Wallis, Pearson, Spearman e regressão linear múltipla). A normalidade dos dados foi testada através do teste de Kolmogorov-Smirnov. Em função da característica do banco de dados e para fortalecer a relação entre os mesmos, as variáveis de BT, BVT e BST foram transformadas para escala de logaritmo natural para aplicação das regressões.

Os modelos para estimativas de biomassa foram obtidos através de regressão linear múltipla de primeira ordem, dado pela equação genérica:

$$B = \beta_0 + \beta_1 X + \beta_2 Y \dots + \beta_n N + \epsilon \quad \text{Equação (1)}$$

em que B é biomassa, X, Y e N são as variáveis independentes, β_0 , β_1 , β_2 , β_n são coeficientes desconhecidos e ϵ é o erro aleatório. Para todas as equações foi observado o cumprimento de todos os pressupostos para uma regressão satisfatória. Os pressupostos utilizados foram: p-valor, multicolinearidade, homogeneidade, independência dos erros e normalidade dos resíduos. Para avaliar o desempenho dos modelos, utilizou-se os testes de t de Student e Mann Whitney. Gerou-se o coeficiente de determinação r^2 ajustado para verificar a acurácia dos ajustes e também o erro quadrático médio (RMSE) para avaliar a precisão dos modelos.

3 Resultados

Em relação ao campo, 57 unidades amostrais de vegetação tiveram sua biomassa estimada conforme método de análise visual descrito acima. As diferentes bandas convertidas para reflectância de superfície foram amostradas nas áreas correspondentes aos tratamentos e piquetes, gerando 585 pixels, sendo 327 pixels (55,9%) referentes a 5 piquetes no tratamento de 375 GD e 258 pixels (44,1%) referentes a 5 piquetes no tratamento de 750 GD. Foram gerados os IVs conforme Tabela 2.

Comparando os dados da imagem (bandas B2, B3, B4, B5, B8 e os índices de vegetação EVI-B5, EVI-B8, NDREI, NDVI, PSRI) e os dados de campo (biomassa total - BT, biomassa verde total - BVT, porcentagem de biomassa verde - PBV, biomassa senescente total - BST, porcentagem de biomassa senescente - PBS) entre os tratamentos observou-se que a BVT, a PBV, a B4 e a B5 foram significativamente maiores no tratamento de 375 GD, enquanto que o EVI8, o NDVI, a PBS e a BST foram significativamente maiores no tratamento de 750 GD. Já as bandas B2, B3 e B8, os índices

EVI5, NDREI e PSRI, e a BT não apresentaram diferenças significativas entre os dois intervalos de descanso ($p < 0,05$) (**Tabela 3**).

Tabela 03 - Valores médios por tratamento das bandas espectrais (Tabela 1), índices de vegetação (Tabela 2) e variáveis relacionadas à biomassa aérea da pastagem natural

	375 GD		750 GD		p
	média	DP	média	DP	
B2	0.044	0.001	0.043	0.003	0.066
B3	0.061	0.004	0.060	0.003	0.227
B4	0.074	0.003	0.070	0.008	0.031
B5	0.123	0.006	0.120	0.006	0.037
B8	0.275	0.028	0.286	0.024	0.140
EVI5	0.101	0.012	0.103	0.010	0.501
EVI8	0.363	0.047	0.390	0.050	0.048
NDREI	0.252	0.025	0.265	0.035	0.124
NDVI	0.575	0.040	0.605	0.051	0.021
PSRI	0.240	0.025	0.225	0.034	0.062
TB (kg.ha ¹)	3472.01	562.59	3635.83	770.31	0.376
PGB	64.26	6.00	52.41	6.10	<0.001
PSB	35.74	6.00	47.59	6.10	<0.001
TGB (kg.ha ¹)	2230.08	381.22	1893.66	411.97	0.003
TSB (kg.ha ¹)	1241.93	289.27	1742.17	471.10	<0.001

Resultados descritos em média e desvio-padrão (DP). p = nível de significância. Testes t de Student para amostras independentes e Mann-Whitney para a comparação entre as variáveis, considerando significativo $p < 0,05$ (IC 95%). BT: biomassa total; PBV: percentual de biomassa verde; PBS: percentual de biomassa senescente; BVT: Biomassa verde total; BST: biomassa senescente total.

Na **Figura 04a e 04b** as matrizes apresentam as correlações entre as variáveis inseridas no estudo. Percebe-se que os valores de BT, BVT e BST apresentaram melhores associações no tratamento 750 GD. Enquanto o PBV e PBS se correlacionaram melhor no tratamento 375. Ainda, verifica-se que, no tratamento 375 GD, a BST não apresentou correlação, a BT e BVT apresentaram correlações diretamente proporcionais com os dados remotos, exceto a relação inversa com o índice PSRI. No tratamento 750, as bandas B2, B3, B4 e B5 e o índice PSRI apresentaram fortes correlações inversas com os valores de biomassa e os demais dados remotos foram diretamente correlacionados com a biomassa.

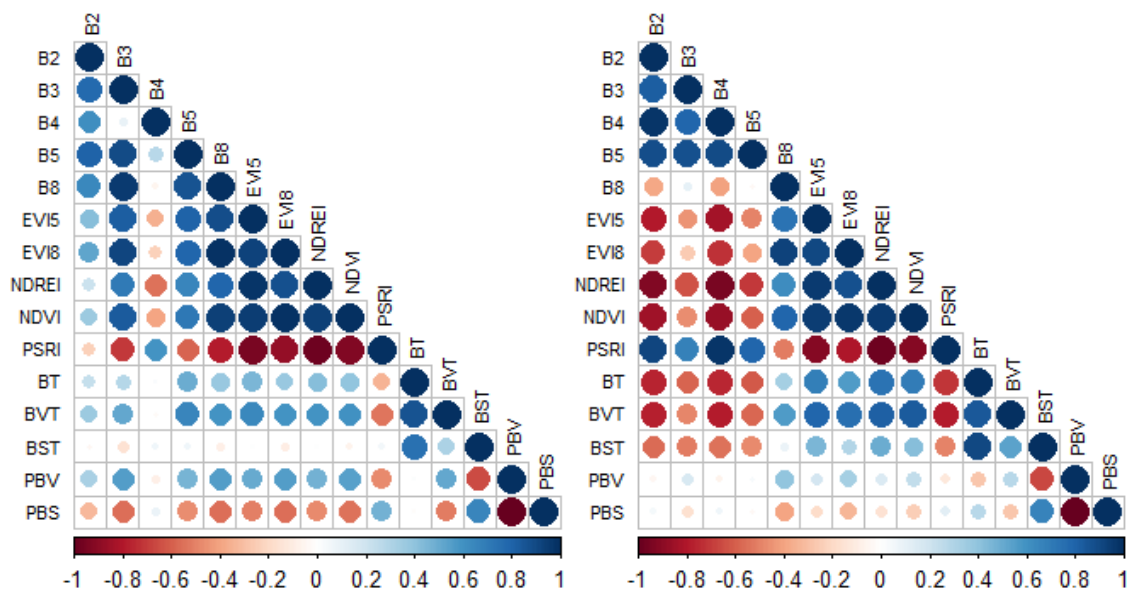


Figura 04– Matrizes de correlação entre as variáveis avaliadas: a) matriz de correlação do tratamento 375 GD. b) matriz de correlação tratamento 750 GD

Dentro de cada tratamento, foram analisados também os valores de reflectância dos piquetes. Observou-se que no tratamento de 375 GD as bandas, os índices de vegetação, a BT, PBV, PBS e a BVT foram significativamente diferentes entre os piquetes ($p < 0,05$) e no tratamento de 750 GD todos os parâmetros exceto PBV e PBS, diferiram significativamente ($p < 0,05$).

Na **Tabela 04** é apresentada a análise da correlação entre os dados MSI e os dados de campo dos dois tratamentos, observando-se correlação direta da BT com todos os índices de vegetação (exceto PSRI) e inversa com PSRI, B2 e B4; correlação direta do PBV com B2, B3 e B5; correlação inversa da BVT com B4 e PSRI e direta com todos os demais índices de vegetação e B8; correlação inversa do PBS com B2, B3 e B5; correlação inversa da BST com B2, B3, B4 e B5 e direta com os índices PSRI e NDREI.

Nas **tabelas 05 e 06**, são apresentados os resultados por tratamento. No tratamento 375 GD verifica-se que a BT e a BST não apresentaram correlações estatisticamente significativas com os dados remotos, a BVT apresentou correlação direta com a B5 e o índice EVI5, as bandas B3 e B8 e os índices EVI5, EVI8, NDREI e NDVI foram diretamente correlacionados com o PBV e inversamente com o PBS, o PSRI apresentou correlação inversa com a PBV e direta com a PBS.

Observando a existência de correlação entre as variáveis obtidas por sensoriamento remoto com a biomassa realizaram-se posteriormente as análises de regressão múltipla. Na **Tabela 07** são apresentadas as equações obtidas para cada tratamento seguidas de seus coeficientes.

Tabela 04 - Associação dos pontos de imagem com os dados de biomassa coletados em campo nos dois tratamentos

	BT		BVT		PBV		BST		PBS	
	r	p	r	p	r	p	r	p	r	p
B2	-0.527	<0,001	-0.21	0.127	0.288	0.035	-0.509	<0.001	-0.288	0.035
B3	-0.26	0.057	0.061	0.663	0.376	0.005	-0.431	0.001	-0.376	0.005
B4	-0.565	<0,001	-0.288	0.035	0.191	0.166	-0.46	<0.001	-0.191	0.166
B5	-0.236	0.086	0.115	0.406	0.399	0.003	-0.434	0.001	-0.399	0.003
B8	0.271	0.011	0.343	0.011	0.176	0.204	0.2	0.888	-0.176	0.204
EVI5	0.55	<0,001	0.573	<0,001	0.2	0.147	0.17	0.219	-0.2	0.147
EVI8	0.413	0.002	0.422	0,001	0.134	0.335	0.133	0.339	-0.134	0.335
NDREI	0.634	<0,001	0.539	<0,001	0.059	0.67	0.325	0.016	-0.059	0.67
NDVI	0.532	<0,001	0.488	0,001	0.062	0.658	0.252	0.066	-0.062	0.658
PSRI	-0.59	<0,001	-0.429	0.001	0.028	0.839	0.351	0.009	-0.028	0.839

r = coeficiente de correlação. p = nível de significância da correlação. Testes de Pearson e Spearman para análise de associação entre as variáveis, considerando significativo $p < 0,05$ (IC 95%). Em Itálico é realçado as correções significativas. BT: biomassa total; PBV: percentual de biomassa verde; PBS: percentual de biomassa senescente; BVT: Biomassa verde total; BST: biomassa senescente total.

Tabela 05 - Associação dos pontos de imagem com os dados de biomassa coletados em campo no tratamento 375

	BT		BVT		PBV		BST		PBS	
	r	p	r	p	r	p	r	p	r	p
B2	0.238	0.233	0.246	0.217	0.342	0.081	-0.181	0.367	-0.342	0.081
B3	0.135	0.503	0.243	0.221	0.499	0.008	-0.338	0.085	-0.499	0.008
B4	0.195	0.329	0.102	0.611	-0.047	0.815	0.05	0.806	0.047	0.815
B5	0.325	0.098	0.368	0.05	0.355	0.069	-0.179	0.371	-0.355	0.069
B8	0.081	0.678	0.206	0.302	0.524	0.005	-0.363	0.063	-0.524	0.005
EVI5	0.236	0.236	0.263	0.05	0.44	0.022	-0.197	0.324	-0.44	0.022
EVI8	0.124	0.539	0.262	0.187	0.515	0.006	-0.311	0.114	-0.515	0.006
NDREI	0.218	0.274	0.341	0.082	0.373	0.05	-0.128	0.525	-0.373	0.05
NDVI	0.109	0.588	0.265	0.181	0.519	0.006	-0.31	0.115	-0.519	0.006
PSRI	-0.173	0.387	-0.312	0.114	-0.377	0.05	0.14	0.488	0.377	0.05

r = coeficiente de correlação. p = nível de significância da correlação. Testes de Pearson e Spearman para análise de associação entre as variáveis, considerando significativo $p < 0,05$ (IC 95%). Em Itálico são realçadas as correções significativas. BT: biomassa total; PBV: percentual de biomassa verde; PBS: percentual de biomassa senescente; BVT: Biomassa verde total; BST: biomassa senescente total.

Tabela 06 - Associação dos pontos de imagem com os dados de biomassa coletados em campo no tratamento 750

	BT		BVT		PBV		BST		PBS	
	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>
B2	<i>-0.806</i>	<i><0,001</i>	<i>-0.778</i>	<i><0,001</i>	<i>-0.002</i>	<i>0.994</i>	<i>-0.619</i>	<i>0.001</i>	<i>0.002</i>	<i>0.994</i>
B3	<i>-0.571</i>	<i>0.002</i>	<i>-0.498</i>	<i>0.009</i>	<i>0.102</i>	<i>0.611</i>	<i>-0.546</i>	<i>0.003</i>	<i>-0.102</i>	<i>0.611</i>
B4	<i>-0.742</i>	<i><0,001</i>	<i>-0.741</i>	<i><0,001</i>	<i>-0.021</i>	<i>0.917</i>	<i>-0.556</i>	<i>0.003</i>	<i>0.021</i>	<i>0.917</i>
B5	<i>-0.6</i>	<i>0.001</i>	<i>-0.562</i>	<i>0.002</i>	<i>0.041</i>	<i>0.841</i>	<i>-0.539</i>	<i>0.004</i>	<i>-0.041</i>	<i>0.841</i>
B8	<i>0.42</i>	<i>0.029</i>	<i>0.651</i>	<i><0,001</i>	<i>0.404</i>	<i>0.037</i>	<i>0.052</i>	<i>0.797</i>	<i>-0.404</i>	<i>0.037</i>
EVI5	<i>0.717</i>	<i><0,001</i>	<i>0.809</i>	<i><0,001</i>	<i>0.142</i>	<i>0.481</i>	<i>0.432</i>	<i>0.024</i>	<i>-0.142</i>	<i>0.481</i>
EV8	<i>0.562</i>	<i>0.002</i>	<i>0.754</i>	<i><0,001</i>	<i>0.333</i>	<i>0.09</i>	<i>0.209</i>	<i>0.295</i>	<i>-0.333</i>	<i>0.09</i>
NDREI	<i>0.730</i>	<i><0,001</i>	<i>0.841</i>	<i><0,001</i>	<i>0.166</i>	<i>0.409</i>	<i>0.461</i>	<i>0.015</i>	<i>-0.166</i>	<i>0.409</i>
NDVI	<i>0.713</i>	<i><0,001</i>	<i>0.806</i>	<i><0,001</i>	<i>0.19</i>	<i>0.343</i>	<i>0.411</i>	<i>0.033</i>	<i>-0.19</i>	<i>0.343</i>
PSRI	<i>-0.730</i>	<i><0,001</i>	<i>-0.795</i>	<i><0,001</i>	<i>-0.107</i>	<i>0.594</i>	<i>-0.495</i>	<i>0.009</i>	<i>0.107</i>	<i>0.594</i>

r = coeficiente de correlação. p = nível de significância da correlação. Testes de Pearson e Spearman para análise de associação entre as variáveis, considerando significativo $p < 0,05$ (IC 95%). Em Itálico são realçadas as correções significativas. BT: biomassa total; PBV: percentual de biomassa verde; PBS: percentual de biomassa senescente; BVT: Biomassa verde total; BST: biomassa senescente total.

Tabela 07 - Regressões múltiplas

Dados médios dos tratamentos (375 + 750 DD)				
Biomassa	Equação	r² ajustado	RMSE	p-value*
Verde	$B = 5.23 + (-34.20*B2) + (24.74*EVI5) + (5.78*PSRI)$	0.4	0.13	0.87
Senescente	$B = 4.94 + (100.64*B2) + (-90.64*B3) + (5.76*NDVI)$	0.3	0.24	0.684
Total	$B = 8.11 + (-19.76*B3) + (12.09*EVI5)$	0.42	0.14	0.63
Treatmento 375				
Verde	$B = 10.38 + (-199.86*B2) + (140.23*B4) + (-17.52*PSRI)$	0.51	0.004	0.97
Senescente	$B = 5.67 + (-62.18*B3) + (42.18*B5)$	<0.3	0.009	0.81
Total	$B = -3.48 + (87.25*B5) + (-26.31*B8) + (20.55*NDVI) + (-36.92*EVI5)$	0.46	0.002	0.97
Treatmento 750				
Verde	$B = 6.14 + (0.86*EVI8) + (3.94*NDREI)$	0.65	0.12	0.97
Senescente	$B = 7.10 + (-4.26*B8) + (5.79*NDREI)$	0.3	0.22	0.83
Total	$B = 3.11 + (25.11*B5 + (-12.88*B8) + (9.46*NDVI)$	0.61	0.12	0.56

* Valores >10 apresentam multicolinearidade. **Para equações que seguem normalidade (p>0.05) foi utilizado o t test e para dados não normais (p<0.05) utilizou-se Mann Whitney test.

A partir da regressão múltipla constatou-se que os modelos apresentaram maiores coeficientes de determinação ajustado para o tratamento 750 GD (r²_{ajustado} 0.65 para biomassa verde, 0.30 para biomassa senescente e 0.61 para biomassa total) e que a Biomassa verde total (BVT) obteve os melhores parâmetros nos dois tratamentos. Todas as equações foram estatisticamente significativas, no entanto, os resultados para estimativa de biomassa senescente não indicaram valor satisfatório de r²_{ajustado} (r²<0.3) no tratamento 375 GD. Na **Figura 05** é apresentada a dispersão do valores estimados vs os valores reais.

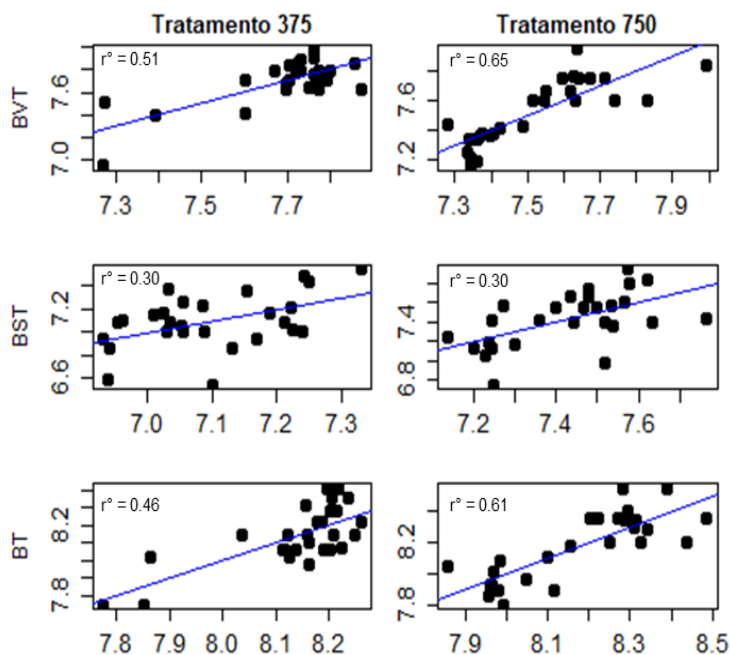


Figura 05 – Dispersão dos valores estimados por sensoriamento remoto vs estimados por avaliação de campo em conjunto com a reta de regressão.

4 Discussão

Os índices de vegetação para estimativas de biomassa em áreas em campos nativos são utilizados há décadas. No entanto, alguns índices como NDVI e Simple Ratio (SR) podem apresentar problemas de saturação quando medidos para áreas de vegetação vigorosa (HILL, 2013; LI, F. *et al.*, 2014; SCHUSTER *et al.*, 2015). Nos últimos anos, alguns índices foram propostos buscando melhorias para minimizar as influências do solo e da atmosfera, entre eles o EVI-B8 e o NDREI para vegetação verde (GITELSON, A.; MERZLYAKB, 1994; HUETE, 1997; MERZLYAK *et al.*, 1999). No entanto, em função da resolução espectral apresentada pelas imagens orbitais de satélite de média resolução, poucos são os índices sensíveis para matéria senescente, como por exemplo PSRI (*Plant senescence reflectance index*). Para isso faz-se necessário a utilização de dados de sensores hiperespectrais ou dados oriundos de satélites com melhores resoluções espectrais (NAGLER *et al.*, 2003; RAYMOND HUNT *et al.*, 2012). Esta pesquisa buscou avaliar a sensibilidade de dados gratuitos do sensor multiespectral MSI Sentinel 2 em duas alternativas de pastoreio rotativo.

Os achados deste estudo são consistentes com os de Sibanda *et al.* (2015) e Delegido *et al.* (2011), que também verificaram associação principalmente entre as bandas na região da borda do vermelho e infra vermelho (4, 5 e 8) do sentinel-2 com biomassa de gramíneas.

Numata et al. (2007), estimaram a biomassa de pastagens plantadas na Amazônia, obtendo precisões ligeiramente abaixo ($r^2 = 0.72$) que os achados neste estudo utilizando dados do satélite Landsat. Já no estudo de Barrachina; Cristóbal and Tulla (2015) foram encontradas fortes correlações da biomassa com os índices EVI e NDVI, e em suas estimativas os autores chegaram a precisões com $r^2 = 0.82$.

Cho and Skidmore (2009), analisaram cinco índices de vegetação e suas variações em imagens hiperespectrais e inferiram modelos com coeficientes de determinação ($r^2 = 0.55$) para estimar biomassa de gramíneas, indicando excelentes resultados neste estudo com imagem Sentinel-2. Clevers et al. (2007), realizaram previsões de biomassa de pastagem utilizando métodos de *machine learning* (SVM) e índices de vegetação, como o RVI, NDVI, WdVI, e EVI calculados com base em dados de espectrorradiômetro *ASD FieldSpec* e encontraram precisões semelhantes a este estudo.

O estudo realizado por Frampton et al. (2013), avaliou dados Sentinel 2 para estimar variáveis biofísicas na vegetação e verificaram associações da região *red edge* com o conteúdo de clorofila das plantas, sugerindo sua utilização como parâmetros de monitoramento biológico da vegetação. Já Shoko and Mutanga (2017) compararam dados do Sentinel 2 com Landsat e Worldview para detectar e discriminar espécies de gramíneas. Conforme os autores em função da presença de bandas na região do red edge e SWIR e a resolução espacial refinada, o Sentinel 2 apresentou desempenhos superior aos demais sensores. Neste estudo, é possível verificar que as regiões *red edge*, NIR e SWIR apresentaram fortes associações com a biomassa corroborando com os estudos citados.

Considerando a melhor sensibilidade às diferenças biofísicas da vegetação dos índices de vegetação em relação às bandas únicas (SIBANDA; MUTANGA, Onisimo; ROUGET, 2015), os resultados desta pesquisa apontam que a combinação das bandas isoladas e os índices de vegetação oriundos de imagens do satélite Sentinel-2 apresentam potencial e robustez para estimativas de biomassa de campos nativos, corroborando com os resultados de outros autores que pesquisaram a relação de biomassa com diferentes satélites (CLEVERS; GITELSON, A. A., 2013; FONSECA, E. L. Da, 2004; FRAMPTON *et al.*, 2013; HILL, 2013; QUAN *et al.*, 2017; YANG, Xiuchun *et al.*, 2015).

A pesquisa de Prabhakara; Dean Hively & Mccarty (2015), avaliou a relação entre dez índices de vegetação em seis campos com cobertura de inverno, cabe ressaltar que o estudo abordou espécies anuais com estádios de desenvolvimento bem uniformes ao longo do ciclo, diferente das gramíneas perenes que dominam a fisionomia das nossas pastagens

naturais. Isso explica porque o NDVI apresentou melhor resultado. Os índices NDVI e TVI apresentaram os melhores resultados. Também contabilizaram a saturação de índices e que a senescência e queimadura de geadas em folhas podem diminuir significativamente a precisão das estimativas de percentagem de cobertura vegetal e biomassa para culturas de cobertura de inverno.

Salientando-se a forte relação, exhaustivamente citada na literatura, da região do vermelho e NIR e mais recentemente do *red edge* com a vegetação, foi possível verificar a forte associação dos índices NDVI e EVI bem como suas variações utilizando a faixa espectral do *red edge*, NDREI e EVI8. Estes resultados corroboram com os achados de (DELEGIDO, J. *et al.*, 2013; GRIGERA; OESTERHELD; PACÍN, 2007; LI, F. *et al.*, 2016; MUTANGA, Onesimo; SKIDMORE, Andrew K., 2007; WEBER; SCHAEPMAN-STRUB; ECKER, 2018)

Para finalizar, os resultados desta pesquisa indicam que o tratamento com intervalo de 750 GD entre pastejos gera melhores previsões tanto para biomassa verde como seca e total. Essa diferença poderia ser atribuída ao fato de que um maior intervalo permite maior acúmulo de biomassa, mas também variações internas nos piquetes, permitindo uma maior amplitude de valores de biomassa registrados (manchas com pouca e muita biomassa acumuladas). Estes resultados demonstram que a estrutura do dossel (e seus efeitos sobre a biomassa), e quantidade de matéria senescente, entre outras variáveis devem ser incluídas em modelos para a estimativa de biomassa campestre.

5 Conclusão

Esta pesquisa demonstrou que índices de vegetação utilizados conjuntamente com as bandas espectrais oferecidas pelo sensor do Sentinel-2 fornecem indicadores quantitativos do estado da biomassa em campos nativos. Os resultados apresentaram estimativas relativamente acuradas de biomassa verde, no entanto as estimativas de biomassa senescente e total apresentaram ajustes fracos e moderados. Neste sentido, deve-se considerar que a biomassa total resulta do acúmulo de biomassa produzida ao longo do tempo e que se torna, em partes, senescente.

Considerando as significativas relações da biomassa com os dados remotos apresentados na Figura 4, a região do *red edge* e infra vermelho apresentam-se como excelentes opções para análises e estimativas de biomassa em campos nativos. Os dados adquiridos através das imagens gratuitas do satélite Sentinel-2 mostraram potencial

apreciável para estudos e pesquisas relacionadas a ecologia dos campos nativos, estimativas de produtividade e para auxílio no monitoramento dos manejos pastoris.

Agradecimentos

Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e apoiado pela Universidade Federal do Rio Grande do Sul (UFRGS), pela Universidade Federal de Santa Maria (UFSM) pelo Instituto Nacional de Pesquisas Espaciais (INPE). Os autores gostariam de agradecer Jéssica Schuster, Diniz Arruda e Alberto Senra Gonçalves pelo apoio técnico prestado para a realização do estudo. Ao Dr. Fernando Quadros e pessoal do Laboratório de Ecologia de Pastagens Naturais (LEPAN) da UFSM, agradecemos os dados.

Referências

- 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**, 2015. v. 38, p. 184–192. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0303243414002657>>.
- 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**, 2011. v. 115, n. 2, p. 514–523. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2010.09.020>>.
- 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**, 2009. v. 30, n. 2, p. 499–515.
- CLEVERS, J. G. P. W. *et al.* Estimating grassland biomass using SVM band shaving of hyperspectral data. **Photogrammetric Engineering and Remote Sensing**, 2007. v. 73, n. 9, p. 1141–1148. Disponível em: <http://skgr0103.wur.nl/~schae001/paper/2007_BandShaving_PERS_JC.pdf>.
- _____; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. **International Journal of Applied Earth Observation and Geoinformation**, 2013. v. 23, n. 1, p. 334–343. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2012.10.008>>.
- CORDEIRO, J. L. P.; HASENACK, H. Cobertura vegetal atual do Rio Grande do Sul. **Pillar, V. D.; Müller, S. C.; Castilhos, Z. M. S.; Jacques, A. V. A. Campos Sulinos conservação e uso sustentável da biodiversidade**. Brasília - DF: Ministério do Meio Ambiente, 2009, p. 285–299.
- CRUZ, P. *et al.* Leaf traits as functional descriptors of the intensity of continuous grazing in native grasslands in the South of Brazil. **Rangeland Ecology and Management**, 2010. v. 63, n. 3, p. 350–358.
- DELEGIDO, J. *et al.* Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. **Sensors**, 2011. v. 11, n. 7, p. 7063–7081.
- DELEGIDO, J. *et al.* A red-edge spectral index for remote sensing estimation of green LAI

over agroecosystems. **European Journal of Agronomy**, 2013. v. 46, p. 42–52. Disponível em: <<http://dx.doi.org/10.1016/j.eja.2012.12.001>>.

DUSSEUX, P. *et al.* Evaluation of SPOT imagery for the estimation of grassland biomass. **International Journal of Applied Earth Observation and Geoinformation**, 2015. v. 38, p. 72–77. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0303243414002669>>.

FALLDORF, T. *et al.* Estimating lichen volume and reindeer winter pasture quality from Landsat imagery. **Remote Sensing of Environment**, 2014. v. 140, p. 573–579. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.09.027>>.

FONSECA, E. L. Da. **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, 2004.

FRAMPTON, W. J. *et al.* Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2013. v. 82, p. 83–92. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2013.04.007>>.

GITELSON, A.; MERZLYAKB, M. N. Quantitative experiments estimation of chlorophyll-*a* using reflectance with autumn chestnut and maple leaves and spectra : **Journal of Photochemistry and Photobiology B: Biology**, 1994. v. 22, p. 247–252.

GONZÁLEZ-DUGO, M. P.; MATEOS, L. Spectral vegetation indices for benchmarking water productivity of irrigated cotton and sugarbeet crops. **Agricultural Water Management**, 2008. v. 95, n. 1, p. 48–58.

GRIGERA, G.; OESTERHELD, M.; PACÍN, F. Monitoring forage production for farmers' decision making. **Agricultural Systems**, 2007. v. 94, n. 3, p. 637–648.

HAYDOCK, K. P.; SHAW, N. H. The comparative yield method for estimating dry matter yield of pasture. **Australian Journal of Agriculture and Animal**, 1975. v. 15, p. 66–70.

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**, 2013. v. 137, p. 94–111. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.06.004>>.

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**, 2013. v. 132, p. 145–158. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.01.010>>.

HUETE, A. R. Et Al. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. **Remote Sensing Environmental**, 1997. v. 59, p. 440–451.

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**, 2016. v. 60, p. 1031–1040.

JU, C. H. *et al.* Estimating leaf chlorophyll content using red edge parameters. **Pedosphere**, 2010. v. 20, n. 5, p. 633–644. Disponível em: <[http://dx.doi.org/10.1016/S1002-0160\(10\)60053-7](http://dx.doi.org/10.1016/S1002-0160(10)60053-7)>.

- KUPLICH, T. M. *et al.* Algumas aplicações de sensoriamento remoto em estudos de vegetação campestre no RS (INPE-17705-RPQ/917). **Instituto Nacional de Pesquisas Espaciais - INPE**, Brasil, 2016. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3LQEG78>>. Acesso em: 2 jan. 2017.
- LI, F. *et al.* Improving estimates of grassland fractional vegetation cover based on a pixel dichotomy model: A case study in Inner Mongolia, China. **Remote Sensing**, 2014. v. 6, n. 6, p. 4705–4722.
- _____. *et al.* Modeling grassland aboveground biomass using a pure vegetation index. **Ecological Indicators**, 2016. v. 62, p. 279–288. Disponível em: <<http://dx.doi.org/10.1016/j.ecolind.2015.11.005>>.
- MERZLYAK, M. N. *et al.* Non-destructive optical detection of leaf senescence and fruit ripening. **Physiologia Plantarum**, 1999. v. 106, p. 135.
- MUTANGA, O.; SKIDMORE, A. K. Red edge shift and biochemical content in grass canopies. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2007. v. 62, n. 1, p. 34–42.
- NAGLER, P. L. *et al.* Cellulose absorption index (CAI) to quantify mixed soil-plant litter scenes. **Remote Sensing of Environment**, 2003. v. 87, n. 2–3, p. 310–325.
- NUMATA, I. *et al.* Characterization of pasture biophysical properties and the impact of grazing intensity using remotely sensed data. **Remote Sensing of Environment**, 2007. v. 109, n. 3, p. 314–327.
- OVERBECK, G. *et al.* Conservation in Brazil needs to include non-forest ecosystems. **Diversity and Distributions**, 2015. v. 21, n. 12, p. 1455–1460.
- OVERBECK, G. E. *et al.* Brazil's neglected biome: The South Brazilian Campos. **Perspectives in Plant Ecology, Evolution and Systematics**, 2007. v. 9, n. 2, p. 101–116.
- 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**, 2015. v. 34, n. 1, p. 188–197. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.08.011>>.
- PILLAR, V. De P.; VÉLEZ, E. Extinção dos Campos Sulinos em unidades de conservação: Um fenômeno natural ou um problema ético? **Natureza e Conservação**, 2010. v. 8, n. 1, p. 84–86.
- 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**, 2015. v. 39, p. 88–102. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2015.03.002>>.
- QUAN, X. *et al.* A radiative transfer model-based method for the estimation of grassland aboveground biomass. **International Journal of Applied Earth Observation and Geoinformation**, 2017. v. 54, p. 159–168. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2016.10.002>>.
- RAYMOND HUNT, E. *et al.* Remote sensing of fuel moisture content from canopy water indices and normalized dry matter index. **Journal of Applied Remote Sensing**, 2012. v. 6, n. 1, p. 061705. Disponível em: <<http://remotesensing.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JRS.6.061705>>.

SCHUSTER, C. *et al.* Grassland habitat mapping by intra-annual time series analysis - Comparison of RapidEye and TerraSAR-X satellite data. **International Journal of Applied Earth Observation and Geoinformation**, 2015. v. 34, n. 1, p. 25–34. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.06.004>>.

SHOKO, C.; MUTANGA, O. Examining the strength of the newly-launched Sentinel 2 MSI sensor in detecting and discriminating subtle differences between C3 and C4 grass species. **ISPRS Journal of Photogrammetry and Remote Sensing**, jul. 2017. v. 129, p. 32–40. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0924271616306128>>.

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**, 2015. v. 110, p. 55–65. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2015.10.005>>.

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

STRECK, E. V. **Solos do Rio Grande do Sul**. 2^a ed. Porto Alegre: Revista e ampl. Porto Alegre: Emater-RS, 2008.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, 1979. v. 8, n. 2, p. 127–150.

VÉLEZ-MARTIN, E. *et al.* Conversão e fragmentação. In: 1^a (Org.). **V.D. Pillar & O. Lange. Os campos do sul**. Porto Alegre: Rede de campos Sulinos - UFRGS, 2015, p. 123–129.

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**, 1997. v. 35, n. 3, p. 675–686.

WEBER, D.; SCHAEPMAN-STRUB, G.; ECKER, K. Predicting habitat quality of protected dry grasslands using Landsat NDVI phenology. **Ecological Indicators**, 2018. v. 91, n. February, p. 447–460. Disponível em: <<https://doi.org/10.1016/j.ecolind.2018.03.081>>.

XU, D. *et al.* Measuring the dead component of mixed grassland with Landsat imagery. **Remote Sensing of Environment**, 2014. v. 142, p. 33–43. Disponível em: <<http://dx.doi.org/10.1016/j.rse.2013.11.017>>.

YANG, X. *et al.* Remote sensing monitoring of grassland vegetation growth in the Beijing-Tianjin sandstorm source project area from 2000 to 2010. **Ecological Indicators**, 2015. v. 51, p. 244–251. Disponível em: <<http://dx.doi.org/10.1016/j.ecolind.2014.04.044>>.

3 CAPITULO II

AVALIAÇÃO DE DADOS HIPERESPECTRAIS COMO PREDITORES PARA BIOMASSA DE CAMPOS NATIVOS EM DOIS MÉTODOS DE MANEJO PASTORIL

Capitulo baseado nas normas de submissão para a revista **Revista Brasileira de
Cartografia.**

AVALIAÇÃO DE DADOS HIPERESPECTRAIS COMO PREDITORES PARA BIOMASSA DE CAMPOS NATIVOS EM DOIS MÉTODOS DE MANEJO PASTORIL

EVALUATION OF HYPERSPECTRAL DATA AS PREDICTORS FOR NATURAL GRASSLAND BIOMASS IN TWO PASTURE MANAGEMENT METHODS

Marildo Guerini Filho¹

Tatiana Mora Kuplich²

¹Universidade Federal do Rio Grande do Sul

Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia

guerinimarildo@gmail.com

²Instituto Nacional de Pesquisas Espaciais, Universidade Federal do Rio Grande do Sul

Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia

tkuplich@gmail.com

Resumo

O Bioma Pampa representa aproximadamente 63% do território no Estado do Rio Grande do Sul – Brasil. Em função da contínua incorporação de monoculturas de espécies exóticas, cultivos agrícolas e a práticas por vezes inadequadas de produção pecuária, os campos nativos estão rapidamente sendo degradados, fragmentados e descaracterizados. Buscando colaborar no desenvolvimento de novas estratégias de manejo e monitoramento adequado dos campos nativos, com vistas à minimização de esforços para coletas de campo, esta pesquisa objetivou caracterizar e quantificar a relação entre dados hiperespectrais coletados por espectrorradiômetro como preditores de biomassa campestre em dois métodos de manejo pastoril com o auxílio de dados de campo. A área de estudo são parcelas com pastoreio pelo gado em dois métodos (tratamentos) de manejo (375 e 750 graus dia - GD) de onde foram adquiridas curvas espectrais de reflectância com espectrorradiômetro ao longo do intervalo de 350-2500 nm de comprimento de onda (CO). Foram calculados 10 índices de vegetação e utilizados juntamente com 11 intervalos de CO nas análises de regressão. Os índices e intervalos de CO selecionados simularam os CO utilizados nas bandas do sensor MSI do satélite Sentinel 2, disponíveis gratuitamente desde 2015. Os resultados mostraram fortes correlações entre as variáveis e verificou-se que nas regiões espectrais do Azul, Red edge e os índices NDLI e DMCI diferiram estatisticamente entre os métodos de manejo. As regiões espectrais do Azul, NIR e SWIR foram significativamente maiores no tratamento 750 GD. O modelo mais preciso para estimar biomassa envolveu os índices EVI e CAI com r^2 ajustado = 0.72 e RMSE = 0.10.

Palavras-chave: campos nativos, biomassa vegetal, espectrorradiometria, dados remotos, geociência

Abstract

The Pampa Biome represents approximately 63% of the territory in the State of Rio Grande do Sul - Brazil. Due to the continuous incorporation of monocultures of exotic species, agricultural crops and sometimes inadequate practices of livestock production, native fields are rapidly being degraded, fragmented and uncharacterized. Seeking to collaborate in developing new management strategies and appropriate monitoring of natural grassland, with a view to minimizing efforts for field collection, this study aimed to characterize and quantify the relationship between hyperspectral data collected by spectroradiometer as biomass predictors country in two methods pasture management with the aid of field data. The study area are plots of grazing cattle by two methods (treatments) management (day 375 to 750 degrees - DG) which were acquired spectral reflectance curves with esptorradiômetro over the range 350-2500 nm wavelength. 10 vegetation indices were used and used along with 11 CO intervals in the regression analyzes. Selected indices and ranges simulated wavelength used in the Sentinel 2 satellite MSI sensor bands, available free of charge since 2015. The results showed strong correlations between the variables and it was found that in the spectral regions of blue, red edge and NDLI and DMCI differed statistically among management methods. The spectral regions of Blue, NIR and SWIR were significantly higher in 750 GD treatment. The most accurate model to biomass estimation involved the EVI and CAI indices with adjusted $r^2 = 0.72$ and RMSE = 0.10.

Keywords: natural grassland, plant biomass, spectroradiometry, remote data, geoscience

1 INTRODUÇÃO

Os campos nativos do Bioma Pampa representam aproximadamente 63% do território do Rio Grande do Sul – Brasil, porém, estima-se que restam apenas 36% de sua área original (Cordeiro and Hasenack, 2009). São amplamente conhecidos pela alta biodiversidade de espécies de fauna e flora. No entanto, práticas por vezes inadequadas de produção pecuária, a introdução de espécies arbóreas exóticas e a conversão de campos para agricultura vêm degradando e fragmentando o Bioma em um ritmo bastante acelerado (Overbeck et al., 2009).

O Pampa é responsável por importantes serviços ambientais e tem função reguladora nos ciclos de matéria (vegetação, fauna, flora...) e energia geradas pelos ecossistemas naturais, mantendo o ambiente equilibrado (Bolfe et al., 2012). A forma que os campos são manejados e as condições ambientais da região influenciam diretamente na sua capacidade de regeneração, alterando sua composição vegetal e também a quantidade de

biomassa. A biomassa dos campos nativos apresenta-se como uma importante variável para controle e monitoramento da dinâmica dos campos e seus efeitos em relação biodiversidade de fauna e flora (Numata et al., 2007).

Os estudos que utilizam técnicas de sensoriamento remoto (SR) para monitoramento, controle e avaliação de variáveis biofísicas da vegetação campestre são escassos quando comparados a outros tipos de vegetação (Hill, 2013; Ullah et al., 2012; Yang et al., 2015). Considerando as limitações de imagens de satélites de média resolução espectral (e.g., Landsat, Terra e Aqua), as relações com a biomassa e os dados de SR muitas vezes são insatisfatórias. Na vegetação campestre, onde a matéria senescente é parte importante do dossel, estas relações podem se apresentar ainda mais fracas, já que a maior parte dos índices de vegetação, usados frequentemente nas estimativas de biomassa, mede o vigor da vegetação verde.

Os dados de esptorradiômetria possibilitam adquirir espectros

instantaneamente, permitindo uma vasta gama de combinações e relações entre os comprimentos de onda amostrados e, principalmente, fornecem informações em faixas do espectro não disponibilizadas por imagens orbitais de média resolução espectral. Em especial, as faixas específicas para análises de biomassa seca ou senescente, geralmente no infravermelho médio (ou de ondas curtas), estão disponíveis em determinados espectrorradiômetros.

Neste contexto, buscando colaborar no desenvolvimento de novas estratégias de manejo e monitoramento adequado dos campos nativos, com vistas à minimização de esforços para coletas de campo, esta pesquisa objetivou caracterizar e quantificar a relação entre dados hiperespectrais como preditores de biomassa campestre em dois métodos de manejo pastoril com o auxílio de dados de campo.

2 MATERIAIS E MÉTODOS

Em linhas gerais, na **Figura 01** é apresentado o fluxograma metodológico para realização do estudo.

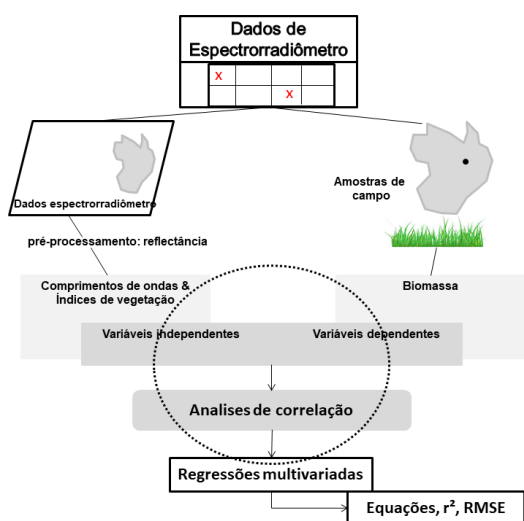


Figura 01 – Fluxograma metodológico

2.1 Área de estudo

O estudo foi realizado em área de campo nativo pertencente à Universidade Federal de Santa Maria (UFSM) possuindo 23 hectares, localizada na região

fisiográfica Depressão Central do Rio Grande do Sul com coordenadas geográficas 29°43'36.11''S e 53°46'41.25''W (Figura 02). As coletas de campo foram realizadas em novembro de 2017. A área apresenta clima subtropical úmido (Cfa) segundo a classificação de Köppen e está a 95 m de altitude. Santa Maria tem pluviosidade média anual de 1688mm e média de temperatura mínima de 19.4 °C e máxima de 30.4°C mensal (Streck, 2008).

A área é dividida em duas formas de manejo pastoril, chamados tratamentos, baseadas na soma térmica acumulada para o crescimento médio foliar de dois grupos funcionais de gramíneas classificados conforme o estudo proposto por Cruz et al. (2010). Estes tratamentos, com intervalos de 375 e 750 graus dia (GD), consideram o tempo necessário, em dias, para a temperatura atmosférica atingir o total de 375 e 750 graus, quando o gado é introduzido para pastejo.

A área é dividida em unidades experimentais (piquetes) de aproximadamente 0,5 ha cada. Para a pesquisa, selecionou-se previamente 5 piquetes em cada tratamento.

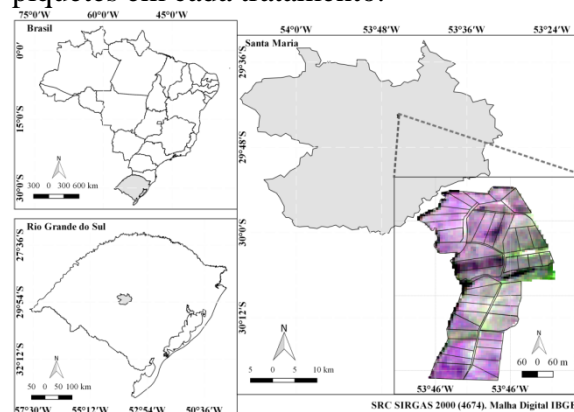


Figura 02 – Estado do RS no Brasil; Santa Maria situa-se na área central do RS e, em detalhe o município de Santa Maria e a área experimental na UFSM.

2.2 Dados do espectrorradiômetro

Os dados hiperespectrais foram coletados com espectrorradiômetro portátil ASD FieldSpec® 3 que registra dados na faixa de 350 – 2500 nm de comprimento de

onda. Foram selecionados dez piquetes entre os dois tratamentos de manejo pastoril. As medições para cada piquete foram feitas em tempo com alta luminosidade, sem presença de nuvens no céu. Todas as medidas foram feitas com antes das medidas da reflectância da vegetação. A calibração prévia permite a conversão das medidas de radiação espectral em reflectância. Foram realizadas dez leituras para cada unidades amostral e gerada a média para os espectros finais. As medições foram tomadas no período das 11:00 às 15:00 horas.

ângulo de visada de 90° na direção do norte e a cerca de 1 m acima do dossel da vegetação, gerando assim um campo de visada de aproximadamente 0.5 x 0.5 m. Um painel de referência branco Spectralon foi utilizado para medição e calibração

Para melhor compreensão das variações dos comprimentos de onda em cada piquete e tratamento, o espectro foi previamente dividido em intervalos que estão apresentados na Tabela 01. Os intervalos foram definidos com base nas bandas das imagens MSI (Multispectral Imager) dos satélites Sentinel 2.

Tabela 01 – Divisão do espectro em intervalos

ID*	Intervalo (nm)**	
	início	fim
Ivis	400	700
INIR	700	1300
ISWIR 1	1301	1900
ISWIR 2	1901	2500
Ib	447	546
Ig	538	582
Ir	646	669
Ire	695	715
Ire1	731	749
Iir	762	907
Is	2000	2200

*Ivis: intervalo na faixa do visível; INIR: intervalo faixa do infravermelho próximo; ISWIR: intervalo faixa do infravermelho de ondas curtas; Ib: intervalo faixa do azul; Ig: intervalo faixa do verde; Ir: intervalo faixa do vermelho; Ire: intervalo faixa do rededge; Iir: intervalo faixa do infravermelho; intervalo na faixa da senescência da vegetação. **Os intervalos foram baseados na largura das bandas do satélite Sentinel-2.

2.3 Índices de vegetação

Esta pesquisa explorou 10 IVs (Tabela 02), alguns amplamente conhecidos por suas correlações com a biomassa verde

(González-Dugo and Mateos, 2008; Hmimina et al., 2013; Xu et al., 2014) e outros por avaliar a biomassa senescente (Nagler et al., 2003; Wang et al., 2011b).

Tabela 02 – Índices de vegetação utilizados

Índice	Nome	Citação	Fórmula*
EVI	<i>Enhanced vegetation index</i>	Huete et al. (1997)	$B = 2.5(lre - lr)/(lre + 6 \times lr - 7.5 \times lb + 1)$
EVI8	<i>Enhanced vegetation index</i>	Huete et al. (1997)	$B = 2.5(lir - lr)/(lir + 6 \times lr - 7.5 \times lb + 1)$
NDREI	<i>Normalized difference red edge index</i>	Gitelson and Merzlyak (1994)	$B = (lre - lr)/(lre + lr)$
NDVI	<i>Normalized difference vegetation index</i>	Tucker (1979)	$B = (lir - lr)/(lir + lr)$
PSRI	<i>Plant senescence</i>	Merzlyak et al.	$B = \rho_{681} - \rho_{498}/\rho_{752}$

	<i>reflectance index</i>	(1999)	
NDLI	<i>Normalized difference lignin index</i>	Serrano et al. (2002)	$B = [\log(1/\rho_{1754}) - \log(1/\rho_{1680})] / [\log(1/\rho_{1754}) + \log(1/\rho_{1680})]$
MRENDVI	<i>Modified red edge NDVI</i>	Sims and Gamon (2002)	$B = (\rho_{750} - \rho_{705}) / (\rho_{750} + \rho_{705} - 2 * \rho_{445})$
NDMI	<i>Normalized dry matter index</i>	Wang et al. (2011a, 2011b)	$B = (\rho_{1649} - \rho_{1722}) / (\rho_{1649} + \rho_{1722})$
CAI	<i>Cellulose absorption index</i>	Nagler et al. (2003)	$B = 0.5(\rho_{2031} + \rho_{2211}) - \rho_{2101}$
DMCI	<i>Dry matter content index</i>	Romero et al. (2012)	$B = (\rho_{2305} - \rho_{1495}) / (\rho_{2305} + \rho_{1495})$

* ρ é reflectância e o subíndice é comprimento de onda (nm). Ir é banda na faixa do red edge. Ir é a banda do vermelho. lb representa a banda do azul e lir utiliza a banda do infra vermelho.

2.4 Amostragem de biomassa campestre

Os dados de campo foram coletados no mês de novembro de 2017 com a colaboração da equipe técnica do Laboratório de Ecologia de Pastagens Naturais (LEPAN) do Departamento de Zootecnia da Universidade Federal de Santa Maria. A biomassa total das unidades amostrais (50 x 50cm) foram determinadas através da técnica de estimativa visual por comparação de padrões, calibrada com duas amostragens (Haydock and Shaw, 1975), com 10 estimativas visuais em cada piquete. Já para a estimativa do percentual de biomassa verde e senescente foi realizada a avaliação visual por meio de fotos específicas de cada unidade amostral conforme descrito pelo Instituto Nacional de Investigação Agropecuária do Uruguai. Foram anotadas as medidas de altura do dossel, com o auxílio de régua graduada e foi realizada a coleta dos espectros utilizando o equipamento FieldSpec® 3. Em uma análise preliminar, visualmente, foi possível verificar maior presença de touceiras e biomassa senescente nos piquetes do tratamento 750 GD (Figura 03).




Figura 03 – a) momento da coleta das unidades amostrais de biomassa e dados do espectrorradiômetro; b) fisionomia característica do tratamento 375 GD; c) fisionomia característica do tratamento 750 GD.

2.5 Análises estatísticas

Para o processamento dos dados utilizou-se os softwares estatísticos RStudio 1.0.153 e SPSS 22.0. A normalidade dos dados foi testada através do teste de Kolmogorov-Smirnov. Foram calculadas estatísticas descritivas (médias e desvios-padrão, frequências, percentuais) e bivariadas (Mann-Whitney, ANOVA, testes t de Student para amostras independentes, Kruskal-Wallis, Spearman, Pearson e regressão linear múltipla).

A relação entre as variáveis espectrais (na forma de índices) e a biomassa campestre foi inferida por meio

de modelos de regressão linear múltipla de primeira ordem, dado pela expressão:

$$B = \theta_0 + \theta_1 X + \theta_2 Y \dots + \theta_n N + \epsilon \text{ equação (1)}$$

em que, θ_0 , θ_1 , θ_2 e θ_n são coeficientes desconhecidos, X, Y e N são os dados espectrais e ϵ é o erro aleatório. Em todas as expressões aplicou-se métodos para verificação dos pressupostos p-valor, multicolinearidade, homogeneidade,

3 RESULTADOS

Foram incluídos na pesquisa 96 pares de dados de biomassa e espectros coletados com espectrorradiômetro, sendo 50 pares (52,1%) referentes a 5 piquetes no tratamento de 375 GD e 46 pontos (47,9%) referentes a 5 piquetes no tratamento de 750 GD. Na Figura 04 são apresentados os espectros médios (10 leituras) para cada piquete e tratamento. Os piquetes 1 a 5 foram medidos no tratamento 375 e os piquetes 6 ao 10 no tratamento 750. Em função de ruídos nos extremos do espectro e nos picos de absorção da água, os intervalos entre 350-400, 1360-1400, 1800-1950 e 2400-2500 nm foram removidos das análises.

Analisando os valores médios de refletância dos intervalos do espectrorradiômetro descritos na Tabela 02 observou-se que o INIR, ISWIR1, ISWIR2, Ib e Is foram significativamente maiores no tratamento 750 GD ($p < 0.05$), os demais intervalos não diferiram significativamente. Dentro de cada tratamento também foram analisadas as diferenças entre os piquetes e verificou-se alta variabilidade com diferenças significativas na refletância entre

independência dos erros e normalidade dos resíduos. O desempenho dos modelos de regressão foi avaliado aplicando os testes de t de Student e Mann Whitney. A acurácia dos modelos foi avaliada mediante o cálculo do coeficiente de determinação r^2 ajustado e Root mean square error (RMSE).

todos nos dois tratamentos ($p < 0.05$) Tabela 03.

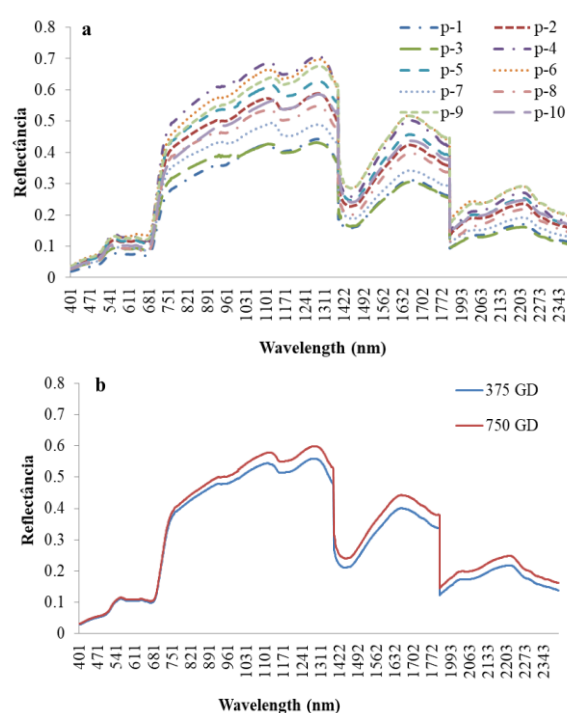


Figura 04 – Curvas espectrais médias dos, a) piquetes e b) tratamento

Tabela 03 - Comparação entre os piquetes

Variável	Piquete	375 GD		p*	750 GD		p**	p***
		Média	DP		Média	DP		
Ivis	1	0.061	0.024	<0.001	0.104	0.038	<0.001	0.177
	2	0.089	0.037		0.075	0.028		
	3	0.073	0.028		0.068	0.027		
	4	0.112	0.045		0.100	0.035		
	5	0.098	0.038		0.085	0.032		
INIR	1	0.372	0.089	<0.001	0.579	0.117	<0.001	<0.001
	2	0.532	0.104		0.422	0.088		
	3	0.386	0.074		0.446	0.099		

	4	0.625	0.129		0.561	0.110		
	5	0.553	0.109		0.504	0.096		
ISWIR1	1	0.280	0.083		0.446	0.120		
	2	0.370	0.134		0.308	0.090		
	3	0.270	0.079	<0.001	0.308	0.106	<0.001	<0.001
	4	0.472	0.137		0.450	0.119		
	5	0.425	0.124		0.396	0.098		
ISWIR2	1	0.145	0.029		0.235	0.044		
	2	0.189	0.073		0.162	0.042		
	3	0.132	0.031	<0.001	0.151	0.044	<0.001	<0.001
	4	0.246	0.059		0.236	0.049		
	5	0.220	0.053		0.213	0.035		
Ib	1	0.048	0.016		0.083	0.023		
	2	0.074	0.026		0.062	0.019		
	3	0.059	0.019	<0.001	0.057	0.020	<0.001	0.030
	4	0.089	0.030		0.082	0.023		
	5	0.080	0.026		0.068	0.021		
Ig	1	0.078	0.012		0.129	0.015		
	2	0.116	0.021		0.098	0.012		
	3	0.093	0.012	<0.001	0.093	0.015	<0.001	0.492
	4	0.148	0.021		0.129	0.013		
	5	0.129	0.019		0.112	0.009		
Ir	1	0.077	0.012		0.132	0.014		
	2	0.108	0.030		0.092	0.014		
	3	0.089	0.019	<0.001	0.079	0.016	<0.001	0.434
	4	0.137	0.019		0.123	0.010		
	5	0.120	0.017		0.103	0.016		
Ire	1	0.145	0.034		0.231	0.043		
	2	0.196	0.047		0.169	0.036		
	3	0.165	0.034	<0.001	0.161	0.041	<0.001	0.992
	4	0.260	0.053		0.219	0.040		
	5	0.222	0.049		0.200	0.038		
Ire1	1	0.260	0.046		0.415	0.048		
	2	0.396	0.053		0.313	0.052		
	3	0.294	0.040	<0.001	0.333	0.053	<0.001	0.941
	4	0.460	0.068		0.403	0.038		
	5	0.407	0.049		0.356	0.030		
Iir	1	0.326	0.059		0.519	0.064		
	2	0.495	0.068		0.385	0.062		
	3	0.360	0.052	<0.001	0.413	0.065	<0.001	0.330
	4	0.563	0.084		0.500	0.050		
	5	0.499	0.059		0.442	0.045		
Is	1	0.154	0.026		0.250	0.039		
	2	0.200	0.073		0.171	0.040		
	3	0.141	0.029	<0.001	0.160	0.042	<0.001	<0.001
	4	0.262	0.055		0.251	0.044		
	5	0.233	0.050		0.225	0.029		

*p referente a comparação entre tratamentos; **p referente a comparação entre piquetes 375GD; ***p referente a comparação entre piquetes 750GD; Resultados descritos em média e desvio-padrão (DP). p = nível de significância. Testes de ANOVA e Kruskal-Wallis para a comparação entre as variáveis, considerando significativo $p < 0,05$ (IC 95%).

Comparando os dados de reflectância (Ib, Ig, Ir, Ire, Iir e os índices de vegetação EVI, EVI8, NDREI, NDVI, PSRI, NDLI, MRENDVI, NDMI, DMCI, CAI) com os dados de campo (biomassa total - BT, biomassa verde total - BVT, porcentagem de biomassa verde - PBV, biomassa senescente total - BST, porcentagem de biomassa senescente - PBS) entre os tratamentos Tabela 04 e Figura 05, verificou-se que no tratamento 375 GD a BT apresentou correlação inversa com DMCI e NDVI; a BST correlação inversa com o intervalo Iir, com os índices NDVI, DMCI, MRENDVI, NDREI, EVI8 e PBV e correlação direta com PSRI e PBS; já a BVT apresentou correlação inversa com os índices DMCI e PSRI e direta com EVI; os intervalos Ib, Ig, Ir, Ire e Iir apresentaram fortes correlações diretas entre eles e correlação inversa com NDLI; o PBV apontou correlação inversa com PSRI e CAI e direta com MRENDVI, NDVI e EVI8; a PBS apontou correlação inversa com MRENDVI, NDVI, NDREI, EVI8 e EVI.

No tratamento 750 GD observou-se correlação inversa da BT com os intervalos de reflectância nas faixas do Ib, Ig, Ir, Ire e Iir e com os índices PSRI e CAI, e correlação direta com NDLI; a BST mostrou correlação inversa com os intervalos Ib, Ig, Ir, Ire e Iir e com os índices EVI, EVI8 e NDMI e PBV; já a BVT apresentou forte correlação inversa com os intervalos Ib, Ig, Ir, Ire e Iir e com PSRI e CAI, e correlação direta com NDVI, NDLI, MRENDVI e PBV; os intervalos CAI, PSRI e os índices Ib, Ig, Ir, Ire e Iir apresentaram correlação inversa com PBV; e a PBS correlação Inversa com NDLI, NDVI, MRENDVI e NDREI.

As diferenças verificadas na região da banda do azul, no infravermelho e nos índices DMCI e NDLI podem naturalmente ser explicadas em função da quantidade de biomassa fotossinteticamente ativa entre os tratamentos. É possível verificar menor quantidade de biomassa senescente no tratamento 375 GD e maior quantidade de biomassa verde.

Tabela 04 - Diferença entre tratamentos

	375 GD		750 GD		P
	Média	DP	Média	DP	
<i>Ib</i>	0.064	0.015	0.071	0.012	0.05
<i>Ig</i>	0.101	0.024	0.113	0.018	0.066
<i>Ir</i>	0.097	0.025	0.108	0.023	0.126
<i>Ire</i>	0.179	0.040	0.197	0.038	0.077
<i>Iir</i>	0.406	0.090	0.452	0.071	0.044
EVI	0.158	0.036	0.171	0.030	0.165
EVI8	0.506	0.102	0.549	0.077	0.091
NDREI	0.298	0.051	0.297	0.048	0.910
NDVI	0.611	0.068	0.615	0.051	0.808
PSRI	0.116	0.038	0.113	0.029	0.713
NDMI	0.031	0.004	0.030	0.003	0.780
<i>NDLI</i>	0.538	0.083	0.473	0.075	0.004
<i>DMCI</i>	-0.198	0.018	-0.186	0.017	0.018
MRENDVI	0.381	0.058	0.391	0.037	0.473
CAI	0.004	0.004	0.006	0.006	0.310
BT	3452.22	843.44	3534.79	626.82	0.687
BVT	1991.81	504.47	1915.85	485.23	0.571
BST	1460.41	584.04	1618.94	377.34	0.250
PBV	58.18	10.06	53.96	8.07	0.096
PBS	41.82	10.06	46.04	8.07	0.096

Resultados descritos em média e desvio-padrão (DP). p = nível de significância. Testes t de Student para amostras independentes e Mann-Whitney para a comparação entre as variáveis, considerando significativo $p < 0,05$ (IC 95%).




Figura 05 – Matriz de correlação a) 375 GD e b) 750 GD

Para uma análise mais minuciosa, gerou-se as matrizes de correlação separadamente para cada piquete (Figuras 06 e 07). Cabe destacar as fortes correlações observadas com os índices (CAI, PSRI, DMCI e NDLI) que abrangem comprimentos de ondas nas faixas onde as respostas de biomassa seca e/ou senescente se acentuam, indicando a presença de

biomassa neste estágio. Através das matrizes é possível verificar que os dados no tratamento 750 GR estão melhor correlacionados com a biomassa, isto é justificado com as cores mais intensas (proporcional ou inversamente proporcional) nas matrizes dos 5 piquetes.




Figura 06 – Correlação dos dados entre os piquetes no tratamento 375 GD




Figura 07 – Correlação dos dados entre os piquetes no tratamento 750 GD

Observando a forte correlação existente entre as variáveis obtidas por detecção remota com a biomassa realizou-se regressão multivariada de primeira ordem para gerar equações que possibilitassem estimativas de biomassa. Na Tabela 05 são apresentadas as equações obtidas para cada tratamento seguidas de seus coeficientes. Em função da característica do banco de dados e para fortalecer a relação entre os dados, as unidades amostrais de BT, BVT e BST foram transformadas para escala de logaritmo natural para aplicação das regressões.

Com a inferência da regressão multivariada constata-se que os dados do tratamento 750 GD apresentam maior homogeneidade resultando em modelos com maiores acurácias. O modelo que melhor se ajustou aos dados considerou os índices CAI e EVI8 como variáveis predictoras da Biomassa Total ($r^2 = 0.722$ e $RMSE = 0.100$) para dados do tratamento 750 GD. O modelo mais acurado utilizando dados do tratamento 375 GD considerou o EVI, DMCI e NDMI para prever a BVT ($r^2 = 0.46$ e $RMSE = 0.190$). Na Figura 08

estão exibidas as dispersões dos valores reais vs os valores preditos através das estimativas.

Verificou-se forte relação dos índices CAI, PSRI, NDLI e DMCI com a biomassa, os quais estão presentes diretamente em todas as equações para estimativa de biomassa, exceto na equação para BVT do tratamento 750.

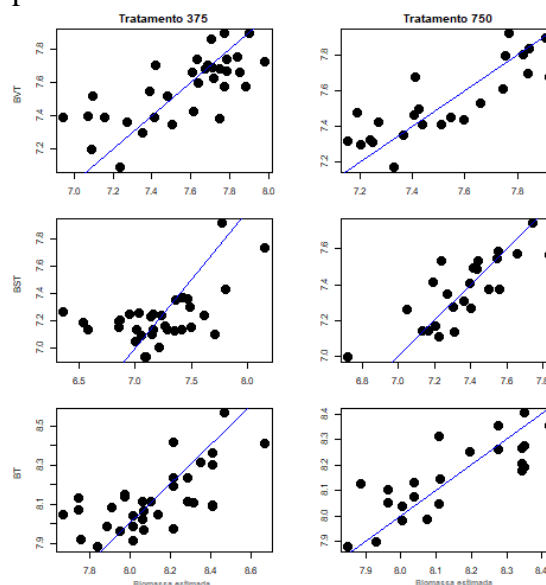


Figura 08 – Dispersão valores reais vs estimados com a devida reta de regressão

Tabela 05 - Regressão multivariada

Tratamento 375				
Biomassa	Equação	r^2 ajustado	RMSE	p-valor**
Verde	$B = 5.40 + (1.02*EVI) + (-11.01*DMCI) + (-17.41*NDMI)$	0.460	0.190	0.880
Senescente	$B = 5.25 + (-7.30*DMCI) + (4.39*PSRI)$	<0.400	0.316	0.908
Total	$B = 7.87 + (-7.46*DMCI) + (-1.88*NDVI) + (-18.06*CAI)$	0.400	0.17	0.777
Tratamento 750				
Verde	$B = 6.70 + (1.94*NDLI) + (-16.42*CAI)$	0.700	0.135	0.742
Senescente	$B = 15.10 + (-24.36*Ig) + (-5.96*NDLI) + (-8.23*PSRI) + (-4.13*NDREI)$	0.562	0.140	0.951
Total	$B = 9.15 + (-1.51*EVI8) + (-26.76*CAI)$	0.722	0.100	0.975

*Para equações que seguem normalidade ($p > 0.05$) foi utilizado o t test e para dados não normais ($p < 0.05$) utilizou-se Mann Whitney test.

4 DISCUSSÃO

A presente pesquisa avaliou a acurácia de variáveis preditoras hiperespectrais para estimar a biomassa de campos nativos utilizando dados do espectrorradiômetro FieldSpec® 3 em dois métodos de manejo pastoril. Devido à presença de altos teores de biomassa senescente (25 – 60%) característica da vegetação campestre, observou-se a importância de dados nas faixas espectrais (notadamente do infravermelho médio) que possibilitem a interpretação deste componente, uma vez que índices comumente utilizados são mais sensíveis à biomassa verde.

Este estudo avaliou os modelos de regressão estatística em função do coeficiente de determinação ajustado (r^2 ajustado) e pelo erro médio quadrático (RMSE). Os resultados se aproximam do estudo realizado por Marabel and Alvarez-Taboada (2013) que avaliaram a biomassa acima do solo utilizando diferentes regiões do espectro e visualizaram modelos com acurácia e erros em torno de 0.80 e 15%, respectivamente.

As pesquisas realizadas por Brantley et al. (2011); Cho and Skidmore (2009); Moreira et al. (2015); Trentin et al. (2011) verificaram que, com a utilização de apenas um índice de vegetação, é possível avaliar a dinâmica temporal da vegetação, porém não apresentaram bons resultados para estimar a biomassa. Neste trabalho foi possível verificar que os índices se relacionaram de forma significativa com a biomassa e a combinação de dois ou mais índices geraram modelos mais acurados corroborando com os estudos de Hill (2013).

Considerando os índices para detecção de biomassa senescente, o presente estudo corrobora os achados de Nagler et al. (2003); Serrano et al. (2002) e Wang et al. (2011b) constatando que,

conforme a biomassa senescente aumenta, os índices CAI, NDLI e DMCI também aumentavam. Já para a biomassa verde, os índices NDVI e EVI tiveram significativas correlações, corroborando com outros autores Barrachina et al. (2015); Hmimina et al. (2013); Moreira et al. (2015) e Zhou et al. (2014).

Apesar da importância ambiental dos ecossistemas campestres, poucos são os estudos de espectrorradiometria para conhecimento e entendimento da dinâmica de biomassa campestre. Nota-se que em função de grande variabilidade e biodiversidade presente nas formações campestres, não existe um consenso do melhor conjunto de variáveis para estimativa de biomassa como por exemplo Clevers et al. (2007); Li et al. (2014); Marabel and Alvarez-Taboada (2013); Maselli et al. (2013); Ren et al. (2017) e Wang (2011a) apontam diferentes conjuntos de dados para avaliações de biomassa vegetal. Nesta pesquisa, visualizou-se que a combinação de índices sensíveis a diferentes formas e estádios fenológicos da vegetação campestre, apresenta-se como a melhor opção para analisar e estimar a biomassa vegetal da área de estudo.

5 CONCLUSÃO

Cada índice estudado apresentou características específicas que devem ser ainda exploradas para ambientes campestres. Percebeu-se que quando as condições da unidade amostral apresentavam menor percentual de matéria senescente os índices EVI, NDVI, MRENDVI foram mais correlacionados com a biomassa. Já os índices CAI, PSRI, NDLI, DMCI apresentaram maior robustez nas amostras com maior percentual de biomassa senescente. A combinação de pares de índices espectrais - um para biomassa senescente e outro para biomassa verde - apresenta-se como boa opção para melhorar a precisão geral da estimativa de biomassa.

A utilização de índices de vegetação apresenta-se como uma excelente opção para a caracterização e estimativa de biomassa de áreas campestres. Nesta abordagem, observou-se que a combinação entre os índices EVI e CAI tiveram a melhor acurácia para a área de estudo com $r^2 = 0.72$ e RMSE = 0.10. A presença de biomassa senescente influencia diretamente as avaliações das variáveis espectrais com os dados de biomassa evidenciando a importância da utilização de dados e índices obtidos por sensores hiperespectrais. A utilização destes resultados em escala regional será possível com o lançamento das futuras missões orbitais com sensores hiperespectrais, já em planejamento e testes pela NASA e Alemanha (Kampe and Good, 2017; Palubinskas et al., 2017). Igualmente, alguns dos resultados apresentados aqui podem ser replicados com a utilização dos dados Sentinel 2. Os resultados desta pesquisa são importantes para apurar preditores hiperespectrais para monitoramento e estimativa de biomassa de campos nativos do Bioma Pampa.

AGRADECIMENTOS

REFERÊNCIAS BIBLIOGRÁFICAS

- BARRACHINA, M., CRISTÓBAL, J., TULLA, A.F. Estimating above-ground biomass on mountain meadows and pastures through remote sensing. *Int. J. Appl. Earth Obs. Geoinf.* 38, 2015. <https://doi.org/10.1016/j.jag.2014.12.002>
- BOLFE, É.L., BATISTELLA, M., FERREIRA, M.C. Correlação de variáveis espectrais e estoque de carbono da biomassa aérea de sistemas agroflorestais. *Pesqui. Agropecu. Bras.* 47, 1261–1269. 2012. <https://doi.org/10.1590/S0100-204X2012000900011>
- 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 Sens. Environ.* 115, 514–523. 2011. <https://doi.org/10.1016/j.rse.2010.09.020>
- CHO, M.A., SKIDMORE, A.K. Hyperspectral predictors for monitoring biomass production in Mediterranean mountain grasslands: Majella National Park, Italy. *Int. J. Remote Sens.* 30, 499–515. 2009. <https://doi.org/10.1080/01431160802392596>
- CLEVERS, J.G.P.W., VAN DER HEIJDEN, G.W. A. M., VERZAKOV, S., SCHAEPMAN, M.E. Estimating grassland biomass using SVM band shaving of hyperspectral data. *Photogramm. Eng. Remote Sensing* 73, 1141–1148. 2007. <https://doi.org/10.14358/PERS.73.10.1141>
- CORDEIRO, J.L.P., HASENACK, H. Cobertura vegetal atual do Rio Grande do Sul., in: Pillar, V. D.; Müller, S. C.; Castilhos, Z. M. S.; Jacques, A. V. A. Campos Sulinos Conservação E Uso Sustentável Da Biodiversidade. Ministério do Meio Ambiente, Brasília - DF, pp. 285–299. 2009.
- CRUZ, P., DE QUADROS, F.L.F., THEAU, J.P., FRIZZO, A., JOUANY, C., DURU, M., CARVALHO, P.C.F. Leaf traits as functional descriptors of the intensity of continuous grazing in native grasslands in the South of Brazil. *Rangel. Ecol. Manag.* 63, 350–358. 2010. <https://doi.org/10.2111/08-016.1>
- GITELSON, A., MERZLYAKB, M.N. Quantitative experiments estimation of chlorophyll-u using reflectance with autumn chestnut and maple leaves and spectra : *J. Photochem. Photobiol. B Biol.* 22, 247–252. 1994. [https://doi.org/10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)
- GONZÁLEZ-DUGO, M.P., MATEOS, L. Spectral vegetation indices for
- Revista Brasileira de Cartografia No XX/YY, 2018. (ISSN 0560-4612)

- benchmarking water productivity of irrigated cotton and sugarbeet crops. *Agric. Water Manag.* 95, 48–58. 2008. <https://doi.org/10.1016/j.agwat.2007.09.001>
- HAYDOCK, K.P., SHAW, N.H. The comparative yield method for estimating dry matter yield of pasture. *Aust. J. Agric. Anim.* 15, 66–70. 1975.
- 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 Sens. Environ.* 137, 94–111. 2013. <https://doi.org/10.1016/j.rse.2013.06.004>
- HMIMINA, G., DUFRÊNE, E., PONTAILLER, J.Y., DELPIERRE, N., AUBINET, M., CAQUET, B., DE GRANDCOURT, A., BURBAN, B., FLECHARD, C., GRANIER, A., GROSS, P., HEINESCH, B., LONGDOZ, B., MOUREAUX, C., OURCIVAL, J.M., RAMBAL, S., SAINT ANDRÉ, L., SOUDANI, K. Evaluation of the potential of MODIS satellite data to predict vegetation phenology in different biomes: An investigation using ground-based NDVI measurements. *Remote Sens. Environ.* 132, 145–158. 2013. <https://doi.org/10.1016/j.rse.2013.01.010>
- HUETE, A.R. ET AL, A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. *Remote Sens. Environ.* 59, 440–451. 1997.
- KAMPE, T.U., GOOD, W.S. Pathway to future sustainable land imaging: the compact hyperspectral prism spectrometer. *SPIE* 10402. 2017. <https://doi.org/10.1117/12.2270932>
- LI, F., CHEN, W., ZENG, Y., ZHAO, Q., WU, B., Improving estimates of grassland fractional vegetation cover based on a pixel dichotomy model: A case study in Inner Mongolia, China. *Remote Sens.* 6, 4705–4722. 2014. <https://doi.org/10.3390/rs6064705>
- MARABEL, M., ALVAREZ-TABOADA, F. Spectroscopic determination of aboveground biomass in grasslands using spectral transformations, support vector machine and partial least squares regression. *Sensors (Switzerland)* 13, 10027–10051. 2013. <https://doi.org/10.3390/s130810027>
- MASELLI, F., ARGENTI, G., CHIESI, M., ANGELI, L., PAPALE, D. Simulation of grassland productivity by the combination of ground and satellite data. *Agric. Ecosyst. Environ.* 165, 163–172. 2013. <https://doi.org/10.1016/j.agee.2012.11.006>
- MERZLYAK, M.N., GITELSON, A.A., CHIVKUNOVA, O.B., RAKITIN, V.Y. Non-destructive optical detection of leaf senescence and fruit ripening. *Physiol. Plantarum* 106, 135. 1999.
- MOREIRA, A., FONTANA, D.C., KUPLICH, T.M. Aplicação de ondaleta em série temporal NDVI/MODIS para avaliação da fenologia de fisionomias campestres no Rio Grande do Sul. *An. XVII Simpósio Bras. Sensoriamento Remoto - SBSR, João Pessoa-PB, Bras.* 7, 6381–6388. 2015. <https://doi.org/10.1017/CBO9781107415324.004>
- NAGLER, P.L., INOUE, Y., GLENN, E.P., RUSS, A.L., DAUGHTRY, C.S.T. Cellulose absorption index (CAI) to quantify mixed soil-plant litter scenes. *Remote Sens. Environ.* 87, 310–325. 2003. <https://doi.org/10.1016/j.rse.2003.06.001>
- NUMATA, I., ROBERTS, D.A., CHADWICK, O.A., SCHIMEL, J., SAMPAIO, F.R., LEONIDAS, F.C., SOARES, J. V., Characterization of pasture biophysical properties and the impact of grazing intensity using remotely sensed data. *Remote Sens. Environ.* 109, 314–327. 2007. <https://doi.org/10.1016/j.rse.2007.01.013>
- OVERBECK, G.E., MÜLLER, S.C.,

- FIDELIS, A., PFADENHAUER, J., PILLAR, V.D.P., BLANCO, C.C., BOLDRINI, I.I., BOTH, R., FORNECK, E.D. Os Campos Sulinos: um bioma negligenciado, in: PILLAR, V. D.; MULLER, S. C.; CASTILHOS, Z. M. S.; JACQUES, A.V.A. (Ed.), Campos Sulinos - Conservação E Uso Sustentável Da Biodiversidade. MMA, Brasília - DF, pp. 28–40. 2009.
- PALUBINSKAS, G., BACHMANN, M., CARMONA, E., GERASCH, B., KRAWCZYK, H., MAKARAU, A., SCHNEIDER, M., SCHWIND, P. Image products from a new german hyperspectral mission enmap. 2017.
- REN, S., CHEN, X., AN, S. Assessing plant senescence reflectance index-retrieved vegetation phenology and its spatiotemporal response to climate change in the Inner Mongolian Grassland. *Int. J. Biometeorol.* 61, 601–612. 2017. <https://doi.org/10.1007/s00484-016-1236-6>
- ROMERO, A., AGUADO, I., YEBRA, M. Estimation of dry matter content in leaves using normalized indexes and prospect model inversion. *Int. J. Remote Sens.* 33, 396–414. 2012. <https://doi.org/10.1080/01431161.2010.532819>
- SERRANO, L., PENUELAS, J., USTIN, S.L. Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals. *Remote Sens. Environ.* 81, 355–364. 2002.
- SIMS, D.A., GAMON, J.A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sens. Environ.* 81, 337–354. 2002. [https://doi.org/10.1016/S0034-4257\(02\)00010-X](https://doi.org/10.1016/S0034-4257(02)00010-X)
- STRECK, E. V. Solos do Rio Grande do Sul, 2a. ed. Revista e ampl. Porto Alegre: Emater-RS, Porto Alegre. 2008.
- Revista Brasileira de Cartografia No XX/YY, 2018. (ISSN 0560-4612)
- TRENTIN, A.B., KUPLICH, T.M., MOREIRA, A., GARAGORY, F., QUADROS, F. Relação da biomassa aérea com a resposta espectral de parcelas de campo com diferentes tipos de manejo. An. XV Simpósio Bras. Sensoriamento Remoto - SBSR, Curitiba, PR, Bras. 30 abril a 05 maio 2011, INPE 1555–1562. <https://doi.org/10.1152/jn.00167.2006>
- TUCKER, C.J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* 8, 127–150. 1979. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- ULLAH, S., SI, Y., SCHLERF, M., SKIDMORE, A.K., SHAFIQUE, M., IQBAL, I.A. Estimation of grassland biomass and nitrogen using MERIS data. *Int. J. Appl. Earth Obs. Geoinf.* 19, 196–204. 2012. <https://doi.org/10.1016/j.jag.2012.05.008>
- WANG, L., HUNT, E.R., QU, J.J., HAO, X., DAUGHTRY, C.S.T. Towards estimation of canopy foliar biomass with spectral reflectance measurements. *Remote Sens. Environ.* 115, 836–840. 2011a. <https://doi.org/10.1016/j.rse.2010.11.011>
- WANG, L., QU, J.J., HAO, X., HUNT, E.R. Estimating dry matter content from spectral reflectance for green leaves of different species. *Int. J. Remote Sens.* 32, 7097–7109. 2011b. <https://doi.org/10.1080/01431161.2010.494641>
- XU, D., GUO, X., LI, Z., YANG, X., YIN, H. Measuring the dead component of mixed grassland with Landsat imagery. *Remote Sens. Environ.* 142, 33–43. 2014. <https://doi.org/10.1016/j.rse.2013.11.017>
- YANG, X., XU, B., JIN, Y., QIN, Z., MA, H., LI, J., ZHAO, F., CHEN, S., ZHU, X. Remote sensing monitoring of grassland vegetation growth in the Beijing-Tianjin sandstorm source project area from 2000 to 2010. *Ecol. Indic.* 51, 244–251. 2015. <https://doi.org/10.1016/j>

ecolind.2014.04.044

ZHOU, Y., ZHANG, L., XIAO, J.,
CHEN, S., KATO, T., ZHOU, G. A
comparison of satellite-derived vegetation

indices for approximating gross primary
productivity of grasslands. *Rangel. Ecol.
Manag.* 67, 9–18. 2014. [https://doi.org/10.
2111/REM-D-13-00059.1](https://doi.org/10.2111/REM-D-13-00059.1)

4 CONSIDERAÇÕES FINAIS

Esta pesquisa proporcionou visualizar o grande desafio que é realizar o monitoramento e avaliações nos complexos ambientes campestres e a necessidade de aprimoramento de ferramentas práticas e simplificadas para auxiliar na conservação dos campos e conseqüentemente contribuir para a sustentabilidade destes ecossistemas.

Este estudo foi um importante passo na utilização de dados remotos para monitoramento dos campos nativos, uma vez que, grande parte dos estudos em áreas destes ecossistemas utilizam dados de satélite com baixa resolução espacial e espectral. São raros os estudos que utilizam dados hiperespectrais e sensores de média/alta resolução para monitoramento da vegetação campestre.

Considerando o alto custo para utilização de sensores hiperespectrais, bem como a limitação para sua utilização em escalas locais, os resultados no Capítulo I mostraram que os dados adquiridos através das imagens Sentinel-2 apresentam alto potencial para estudos e pesquisas relacionadas a ecologia dos campos nativos, estimativas de produtividade e para auxílio no monitoramento dos manejos pastoris.

No Capítulo II, analisando os resultados, observou-se que dados hiperespectrais apresentam uma gama imensa de possibilidades para monitoramento de vegetação campestre. Especificamente neste estudo, foi possível verificar que a combinação de pares de índices espectrais - um para biomassa senescente e outro para biomassa verde - apresentou a melhor precisão geral da estimativa de biomassa.

Embora a pesquisa seja dividida em dois capítulos/artigos, podemos afirmar que os dois métodos apresentaram comportamentos semelhantes, com a biomassa senescente influenciando diretamente os dados remotos, e a região *Red Edge* do espectro mostrando significativas associações com a biomassa. Ressalta-se a importância dos dados

hiperespectrais para a geração de índices mais sensíveis para biomassa senescente auxiliando na caracterização geral da vegetação.

A pesquisa apresentou resultados satisfatórios para os objetivos propostos. No entanto, se faz necessária a utilização de dados em diferentes períodos do ano considerando as diferenças sazonais no monitoramento e nas estimativas. Desta forma, realizar os ajustes necessários para conseguir efetivar o acompanhamento da biomassa nos campos em qualquer condição ambiental.

Com a finalização desta pesquisa pode-se afirmar que é possível minimizar os esforços de campo para auxiliar no monitoramento, organização e conservação dos campos nativos do Bioma Pampa utilizando dados de sensoriamento remoto como ferramenta de manejo buscando a sustentabilidade destes complexos ambientes naturais.

Considerando as diferenças e as peculiaridades encontradas entre os tipos de manejo pastoral verificou-se que estas diferenças podem ter ocorrido devido às condições geomorfométricas, que induzem à diferentes níveis de umidade (áreas de baixada, de topo, insolação, precipitação pluviométrica, etc). Para a sequência da pesquisa, sugere-se:

- Avaliar valores amostrais absolutos, uma vez que, trabalhar com valores médios do tipo de manejo possa ter influenciando os resultados;
- Utilizar diferentes combinações de índices e principalmente explorar exaustivamente a região *Red Edge* do espectro, considerando as significantes associações encontradas com a biomassa neste estudo;
- Verificar a influência da umidade, características geomorfológicas e tipologia de solos da região; e
- Realizar a estimativa em diferentes estações do ano.

5 CONCLUSÕES

Os resultados apresentados neste estudo demonstram que a utilização de dados e técnicas de Sensoriamento Remoto apresenta-se como uma alternativa bastante viável e produz bons resultados para monitoramento e avaliações dos campos nativos do Bioma Pampa, permitindo verificar a qualidade e a quantidade da biomassa vegetal, bem como ser utilizado como uma ferramenta para auxiliar na conservação ambiental do Bioma.

Os achados desta pesquisa atendem aos objetivos propostos, em que se almejava quantificar as relações entre as respostas espectrais e biomassa da vegetação campestre de dois tipos de manejo pastoril utilizando dados de imagem de satélite e dados espectrorradiométricos, com vistas à minimização de esforços de coletas de campo e monitoramento remoto dos Campos nativos do Bioma Pampa. Neste contexto, as avaliações permitiram caracterizar cada tipo de manejo pastoril (375 e 750 GD) e obter estimativas relativamente acuradas da quantidade de biomassa. Para obter estimativas mais acuradas, a realização de avaliações em diferentes estações do ano deverá ser considerada em estudos futuros.

REFERÊNCIAS GERAIS

ANDERSON, G. L.; HANSON, J. D.; HAAS, R. H. Evaluating landsat thematic mapper derived vegetation indices for estimating above-ground biomass on semiarid rangelands.

Remote Sensing of Environment, 1993. v. 45, n. 2, p. 165–175.

ANDRADE, B. O. *et al.* Grassland degradation and restoration: A conceptual framework of stages and thresholds illustrated by southern Brazilian grasslands. **Natureza e Conservacao**, 2015. v. 13, n. 2, p. 95–104. Disponível em:

<<http://dx.doi.org/10.1016/j.ncon.2015.08.002>>.

BEHLING, H.; PILLAR, V. D. Late Quaternary vegetation, biodiversity and fire dynamics on the southern Brazilian highland and their implication for conservation and management of modern Araucaria forest and grassland ecosystems. **Philosophical transactions of the Royal Society of London. Series B, Biological sciences**, 2007. v. 362, n. 1478, p. 243–251.

BOLDRINI, I. I.; OVERBECK, G. E. Estudos fitossociológicos em vegetação campestre. **Eisenlohr, P.V. Felfili, J.M. De Melo, M.M.R.F. De Andrade, L.A. Meira Neto, J.A.A. Fitossociologia no Brasil**. 1ª ed. Viçosa - Minas Gerais: [s.n.], 2015, p. 228–248.

BRITO, F. **Corredores ecológicos: uma estratégia integrada na gestão de ecossistemas**. Florianópolis: UFSC, 2006.

CASSOL, H. L. G. **Estimativa de Biomassa e estoque de carbono em um fragmento de floresta ombrófila mista com uso de dados ópticos de sensores remotos**. Porto Alegre: Biblioteca Instituto de Geociências - UFRGS, 2013.

CLEVERS, J. G. P. W. *et al.* Estimating grassland biomass using SVM band shaving of hyperspectral data. **Photogrammetric Engineering and Remote Sensing**, 2007. v. 73, n. 9,

p. 1141–1148. Disponível em:

<http://skgr0103.wur.nl/~schae001/paper/2007_BandShaving_PERS_JC.pdf>.

CORBANE, C. *et al.* Remote sensing for mapping natural habitats and their conservation status – New opportunities and challenges. **International Journal of Applied Earth Observation and Geoinformation**, 1 maio. 2015. v. 37, p. 7–16. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0303243414002451>>. Acesso em: 1º ago. 2018.

CORDEIRO, J. L. P.; HASENACK, H. Cobertura vegetal atual do Rio Grande do Sull. **Pillar, V. D.; Müller, S. C.; Castilhos, Z. M. S.; Jacques, A. V. A. Campos Sulinos conservação e uso sustentável da biodiversidade**. Brasília - DF: Ministério do Meio Ambiente, 2009, p. 285–299.

DELEGIDO, J. *et al.* Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. **Sensors**, 2011. v. 11, n. 7, p. 7063–7081.

DÜMIG, A. *et al.* Araucaria forest expansion on grassland in the southern Brazilian highlands as revealed by ^{14}C and $\delta^{13}\text{C}$ studies. **Geoderma**, 2008. v. 145, n. 1–2, p. 143–157.

EDIRISINGHE, A.; CLARK, D.; WAUGH, D. Spatio-temporal modelling of biomass of intensively grazed perennial dairy pastures using multispectral remote sensing.

International Journal of Applied Earth Observation and Geoinformation, 2012. v. 16, n. 1, p. 5–16. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2011.11.006>>.

FONSECA, E. L. Da. **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, 2004.

_____; FORMAGGIO, A. R.; PONZONI, F. J. Forecast the available forage of natural pastures of Campos Sulinos biome using satellite spectral data: parameterization for the spectral submodel. **Ciência Rural**, 2007. v. 37, n. 6, p. 1668–1674. Disponível em: <http://www.scielo.br/scielo.php?pid=S0103-84782007000600025&script=sci_arttext&tlng=es>.

FRAMPTON, W. J. *et al.* Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and**

Remote Sensing, 2013. v. 82, p. 83–92. Disponível em:

<<http://dx.doi.org/10.1016/j.isprsjprs.2013.04.007>>.

FRANKE, J.; KEUCK, V.; SIEGERT, F. Assessment of grassland use intensity by remote sensing to support conservation schemes. **Journal for Nature Conservation**, 1 jun. 2012. v. 20, n. 3, p. 125–134. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S1617138112000234>>. Acesso em: 31 jul. 2018.

GÓMEZ GIMÉNEZ, M. *et al.* Determination of grassland use intensity based on multi-temporal remote sensing data and ecological indicators. **Remote Sensing of Environment**, 1 set. 2017. v. 198, p. 126–139. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0034425717302638>>. Acesso em: 31 jul. 2018.

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**, 2004. v. 93, n. 4, p. 528–545.

_____. 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**, 2013. v. 137, p. 94–111. Disponível em:

<<http://dx.doi.org/10.1016/j.rse.2013.06.004>>.

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**, 2016. v. 60, p. 1031–1040.

KUMAR, L. *et al.* Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, 2015. v. 9, n. 1, p. 097696. Disponível em:

<<http://remotesensing.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JRS.9.097696>>.

KUPLICH, T. M. *et al.* Algumas aplicações de sensoriamento remoto em estudos de vegetação campestre no RS (INPE-17705-RPQ/917). **Instituto Nacional de Pesquisas Espaciais - INPE**, Brasil, 2016. Disponível em:

<<http://urlib.net/8JMKD3MGP3W34P/3LQEG78>>. Acesso em: 2 jan. 2017.

_____; MOREIRA, A.; FONTANA, D. C. Série temporal de índice de vegetação sobre

diferentes tipologias vegetais no Rio Grande do Sul Time series of vegetation index for different vegetation types in Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2013. v. 17, n. 55, p. 1116–1123.

LIMA JUNIOR, C. *et al.* **Índices de vegetação para estimativas de biomassa e carbono em uma área de caatinga. XX Congresso Latinoamericano y XVI Congreso Peruano de la Ciencia del Suelo.** Disponível em:

<<http://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1014221/1/CongressoLatinoamericanoPeruanoCienciadoSolo17.pdf>>.

MMA. **Bioma Pampa. - Ministério do Meio Ambiente.** Disponível em:

<<http://www.mma.gov.br/biomas/pampa>>. Acesso em: 1º fev. 2018.

OVERBECK, G. *et al.* Conservation in Brazil needs to include non-forest ecosystems. **Diversity and Distributions**, 2015. v. 21, n. 12, p. 1455–1460.

OVERBECK, G. E. *et al.* Brazil's neglected biome: The South Brazilian Campos.

Perspectives in Plant Ecology, Evolution and Systematics, 2007. v. 9, n. 2, p. 101–116.

OVERBECK, G. E. *et al.* Os Campos Sulinos: um bioma negligenciado. *In*: PILLAR, V. D.; MULLER, S. C.; CASTILHOS, Z. M. S.; JACQUES, A. V. A. (Org.). **Campos Sulinos - conservação e uso sustentável da biodiversidade**. 1ª ed. Brasília - DF: MMA, 2009, p. 28–40.

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**, 2015. v. 34, n. 1, p. 188–197. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.08.011>>.

PILLAR, V. D. P. *et al.* **Campos Sulinos - Conservação e uso sustentável da biodiversidade**. Brasília - DF: Ministério do Meio Ambiente, 2009.

PLESSIS, W. P. DU. Linear regression relationships between NDVI, vegetation and rainfall in Etosha National Park, Namibia. **Journal of Arid Environments**, 1999. v. 42, n. 4, p. 235–260.

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**, 2015. v. 39, p. 88–102. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2015.03.002>>.

SANTOS, J. R. Dos *et al.* Tropical forest biomass and its relationship with P-band SAR data. **Revista Brasileira de Cartografia No**, 2006. v. 58, n. 01, p. 37–43.

SCHUSTER, C. *et al.* Grassland habitat mapping by intra-annual time series analysis - Comparison of RapidEye and TerraSAR-X satellite data. **International Journal of Applied Earth Observation and Geoinformation**, 2015. v. 34, n. 1, p. 25–34. Disponível em: <<http://dx.doi.org/10.1016/j.jag.2014.06.004>>.

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**, 2015. v. 110, p. 55–65. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2015.10.005>>.

SUN, B. *et al.* Grassland degradation and restoration monitoring and driving forces analysis based on long time-series remote sensing data in Xilin Gol League. **Acta Ecologica Sinica**, 1 ago. 2017. v. 37, n. 4, p. 219–228. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1872203217300367>>. Acesso em: 31 jul. 2018.

TILIO NETO, P. De. **Ecopolítica das mudanças climáticas: o IPCC e o Ecologismo dos Pobres**. Rio de Janeiro: Centro Edelstein de Pesquisas Sociais, 2010.

TRENTIN, A. B. *et al.* Relação da biomassa aérea com a resposta espectral de parcelas de campo com diferentes tipos de manejo. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE**, 2011. p. 1555–1562.

TUCKER, C. J. *et al.* Satellite remote sensing of total herbaceous biomass production in the senegalese sahel: 1980-1984. **Remote Sensing of Environment**, 1985. v. 17, n. 3, p. 233–249.

VÉLEZ-MARTIN, E. *et al.* Conversão e fragmentação. In: 1^a (Org.). **V.D. Pillar & O. Lange. Os campos do sul**. Porto Alegre: Rede de campos Sulinos - UFRGS, 2015, p. 123–129.

WAGNER, A. P. L. *et al.* Tendências temporais de índices de vegetação nos campos do Pampa do Brasil e do Uruguai. **Pesquisa Agropecuária Brasileira**, 2013. v. 48, n. 9, p. 1192–1200.

WEBER, D.; SCHAEPMAN-STRUB, G.; ECKER, K. Predicting habitat quality of

protected dry grasslands using Landsat NDVI phenology. **Ecological Indicators**, 2018. v. 91, n. February, p. 447–460. Disponível em: <<https://doi.org/10.1016/j.ecolind.2018.03.081>>.

ZHU, X.; LIU, D. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2015. v. 102, p. 222–231. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2014.08.014>>.