



# Avaliação de Dados Hiperespectrais como Preditores para Biomassa de Campos Nativos

Evaluation of Hyperspectral Data as Predictors for Natural Grassland Biomass

*Marildo Guerini Filho<sup>1</sup>*  
*Tatiana Mora Kuplich<sup>2</sup>*

Recebido em agosto de 2018.  
Aprovado em agosto de 2019.

## RESUMO

O Bioma Pampa representa 63% do território 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 duas alternativas de manejo pastoril com o auxílio de dados de campo. A área de estudo são parcelas pastoreadas por bovinos em duas alternativas 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 dados espectrais simularam os CO utilizados nas bandas do sensor MSI do satélite Sentinel 2, disponíveis gratuitamente desde 2015. Os resultados mostraram excelentes correlações entre as variáveis e verificou-se que nas regiões espectrais do Azul, Red edge e os índices NDLI e DMCI diferiram estatisticamente entre as alternativas 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. Dados remotos. Espectrorradiometria. Geociência.

---

<sup>1</sup> Universidade Federal do Rio Grande do Sul; Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia; [guerinimarildo@gmail.com](mailto:guerinimarildo@gmail.com)

<sup>2</sup> Instituto Nacional de Pesquisas Espaciais; Universidade Federal do Rio Grande do Sul; Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia; [tkuplich@gmail.com](mailto:tkuplich@gmail.com)

## **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 spectroradiometer 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. Remote data. Spectroradiometry. Geoscience.

\* \* \*

## **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 e 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, BATISTELLA e FERREIRA, 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 espectrorradiometria 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.

## 1 Materiais e métodos

Em linhas gerais, na Figura 1 é apresentado o fluxograma metodológico para realização do estudo.



Fonte: Elaborada pelos autores.

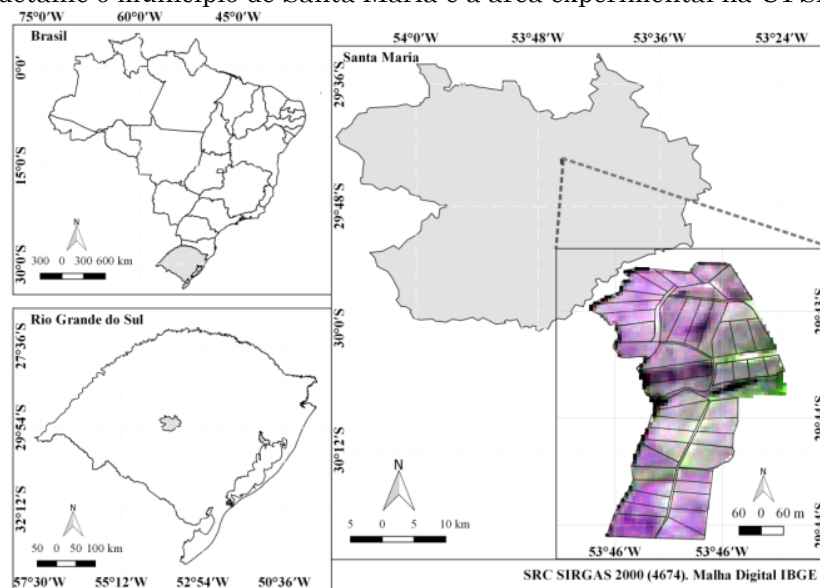
### 1.1 Área de estudo

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 2). 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 2 – 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



Fonte: Elaborada pelos autores.

## 1.2 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. Todos as

medidas foram feitas com 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 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.

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 1. Os intervalos foram definidos com base nas bandas das imagens MSI (*Multispectral Imager*) dos satélites Sentinel 2.

Tabela 1 – 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

Fonte: Elaborada pelos autores.

\*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.

### 1.3 Índices de vegetação

Esta pesquisa explorou 10 IVs (Tabela 2), alguns amplamente conhecidos por suas correlações com a biomassa verde (GONZÁLEZ-DUGO e 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 2 – 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 e 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 reflectance index</i>	Merzlyak et al. (1999)	$B = \rho_{681} - \rho_{498}/\rho_{752}$
NDLI	<i>Normalized difference lignin index</i>	Serrano, Penuelas e Ustin (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 e Gamon (2002)	$B = (\rho_{750} - \rho_{705}) / (\rho_{750} + \rho_{705} - 2 \times \rho_{445})$
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, Aguado e Yebra (2012)	$B = (\rho_{2305} - \rho_{1495}) / (\rho_{2305} + \rho_{1495})$


Fonte: Elaborada pelos autores.

\* $\rho$  é reflectância e o subíndice é comprimento de onda (nm). lre é banda na faixa do *rededge*. lr é a banda do vermelho. lb representa a banda do azul e lir utiliza a banda do infravermelho.

### 1.4 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 (Figura 3).

Figura 3 – 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



Fonte: Elaborada pelos autores.

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 e 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.

### 1.5 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:

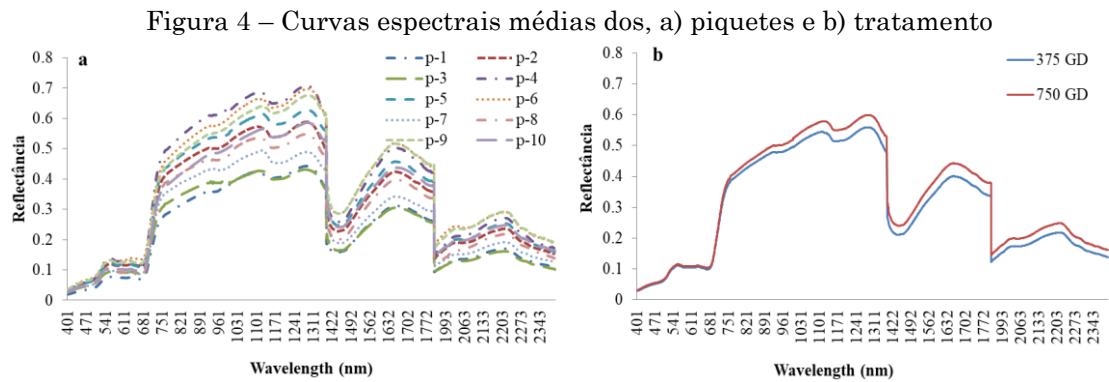
$$B = \theta_0 + \theta_1 X + \theta_2 Y \dots + \theta_n N + \epsilon \quad (1)$$

em que,  $\theta_0$ ,  $\theta_1$ ,  $\theta_2$  e  $\theta_n$  são coeficientes desconhecidos, X, Y e N são os dados espectrais e  $\epsilon$  é o erro aleatório. Em todas as expressões aplicou-se métodos para verificação dos pressupostos p-valor, multicolinearidade, homogeneidade, 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  $R^2_{\text{ajustado}}$  e *Root mean square error* (RMSE).

## 2 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 4 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 reflectância dos intervalos do espectrorradiômetro descritos na Tabela 2 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 todos nos dois tratamentos ( $p < 0.05$ ) Tabela 3.



Fonte: Elaborada pelos autores.

Tabela 3 - 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	<0.001	0.446	0.120	<0.001	<0.001
	2	0.370	0.134		0.308	0.090		
	3	0.270	0.079		0.308	0.106		
	4	0.472	0.137		0.450	0.119		
	5	0.425	0.124		0.396	0.098		
ISWIR2	1	0.145	0.029	<0.001	0.235	0.044	<0.001	<0.001
	2	0.189	0.073		0.162	0.042		
	3	0.132	0.031		0.151	0.044		
	4	0.246	0.059		0.236	0.049		
	5	0.220	0.053		0.213	0.035		
Ib	1	0.048	0.016	<0.001	0.083	0.023	<0.001	0.030
	2	0.074	0.026		0.062	0.019		
	3	0.059	0.019		0.057	0.020		
	4	0.089	0.030		0.082	0.023		
	5	0.080	0.026		0.068	0.021		
Ig	1	0.078	0.012	<0.001	0.129	0.015	<0.001	0.492
	2	0.116	0.021		0.098	0.012		
	3	0.093	0.012		0.093	0.015		
	4	0.148	0.021		0.129	0.013		
	5	0.129	0.019		0.112	0.009		

I <sub>r</sub>	1	0.077	0.012	<0.001	0.132	0.014	<0.001	0.434
	2	0.108	0.030		0.092	0.014		
	3	0.089	0.019		0.079	0.016		
	4	0.137	0.019		0.123	0.010		
	5	0.120	0.017		0.103	0.016		
I <sub>re</sub>	1	0.145	0.034	<0.001	0.231	0.043	<0.001	0.992
	2	0.196	0.047		0.169	0.036		
	3	0.165	0.034		0.161	0.041		
	4	0.260	0.053		0.219	0.040		
	5	0.222	0.049		0.200	0.038		
I <sub>re1</sub>	1	0.260	0.046	<0.001	0.415	0.048	<0.001	0.941
	2	0.396	0.053		0.313	0.052		
	3	0.294	0.040		0.333	0.053		
	4	0.460	0.068		0.403	0.038		
	5	0.407	0.049		0.356	0.030		
I <sub>ir</sub>	1	0.326	0.059	<0.001	0.519	0.064	<0.001	0.330
	2	0.495	0.068		0.385	0.062		
	3	0.360	0.052		0.413	0.065		
	4	0.563	0.084		0.500	0.050		
	5	0.499	0.059		0.442	0.045		
I <sub>s</sub>	1	0.154	0.026	<0.001	0.250	0.039	<0.001	<0.001
	2	0.200	0.073		0.171	0.040		
	3	0.141	0.029		0.160	0.042		
	4	0.262	0.055		0.251	0.044		
	5	0.233	0.050		0.225	0.029		

Fonte: Elaborada pelos autores.

\*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; I<sub>r</sub>: intervalo faixa do vermelho; I<sub>re</sub>: intervalo faixa do *rededge*; I<sub>ir</sub>: intervalo faixa do infravermelho; intervalo na faixa da senescência da vegetação. \*\*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 (I<sub>b</sub>, I<sub>g</sub>, I<sub>r</sub>, I<sub>re</sub>, I<sub>ir</sub> 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 4 e Figura 5, verificou-se que no tratamento 375 GD a BT apresentou correlação inversa com DMCI e NDVI; a BST correlação inversa com o intervalo I<sub>ir</sub>, 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.

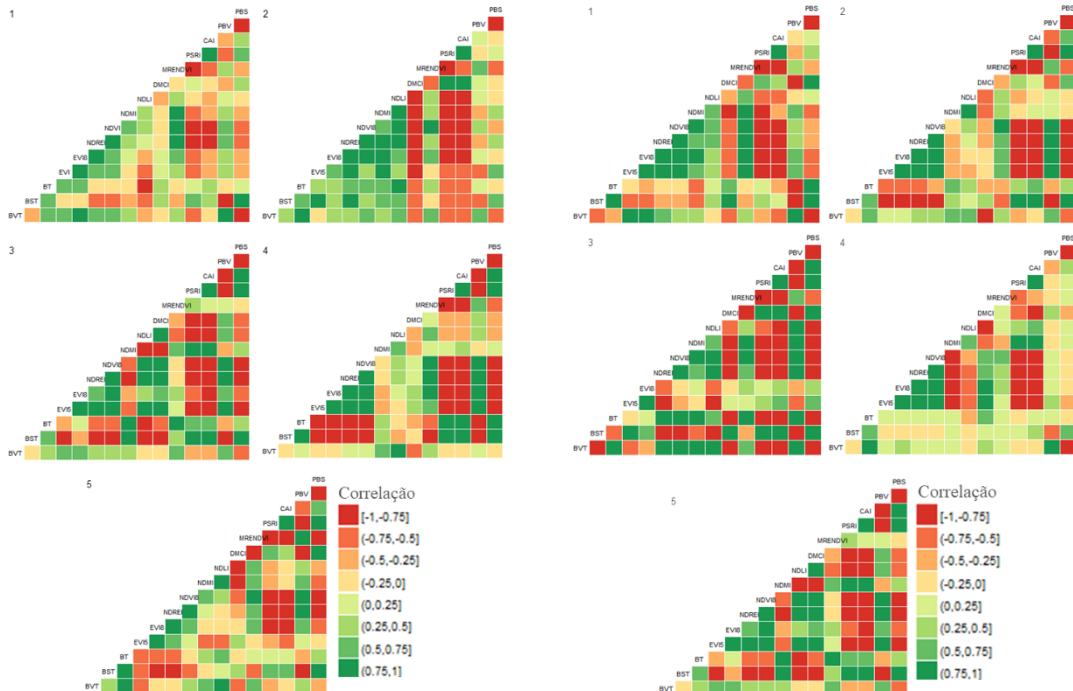
Tabela 4 - Diferença entre tratamentos

	375 GD		750 GD		p
	Média	DP	Média	DP	
Ib	0.064	0.015	0.071	0.012	0.05
Ig	0.101	0.024	0.113	0.018	0.066
Ir	0.097	0.025	0.108	0.023	0.126
Ire	0.179	0.040	0.197	0.038	0.077
Iir	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
NDLI	0.538	0.083	0.473	0.075	0.004
DMCI	-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



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.

Figura 6 – Correlação dos dados entre os piquetes no tratamento 375 GD (a) e tratamento 750 GD (b)



Fonte: Elaborada pelos autores.

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 predizer a BVT ( $R^2 = 0.46$  e  $RMSE = 0.190$ ). Na Figura 7 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.

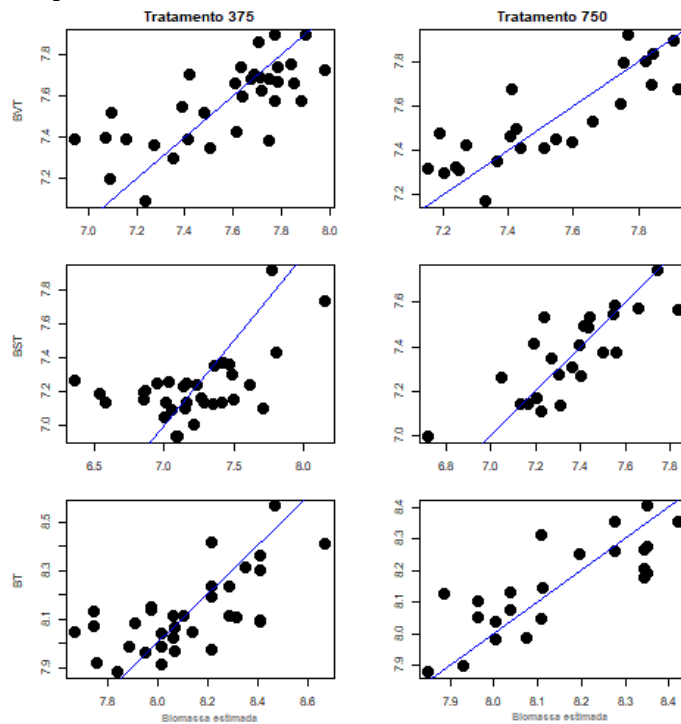
Tabela 5 - Regressão multivariada

Tratamento 375				
Biomassa	Equação	$R^2$ ajusted	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

Fonte: Elaborada pelos autores.

\*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.

Figura 7 – Dispersão valores reais vs estimados com a devida reta de regressão



Fonte: Elaborada pelos autores.

### 3 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 ( $R^2_{\text{ajustado}}$ ) e pelo erro médio quadrático (RMSE). Os resultados se aproximam do estudo realizado por Marabel e 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, Zinnert e Young (2011); Cho e Skidmore (2009); Moreira, Fontana e Kuplich (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, Penuelas e Ustin (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,



Cristóbal e Tulla (2015); Hmimina et al. (2013); Moreira, Fontana e Kuplich (2015) e Zhou et al. (2014).

Apesar da importância ambiental dos ecossistemas campestres, poucos são os estudos de espectrorradiômetria 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 e Alvarez-Taboada (2013); Maselli et al. (2013); Ren, Chen e An (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.

#### **4 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 e 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**

Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES (processo nº 1586394) e apoiado pela Universidade Federal do Rio Grande do Sul (UFRGS), pela Universidade Federal de Santa Maria (UFSM) e pelo Instituto Nacional de Pesquisas Espaciais (INPE), Brasil. Os autores gostariam de agradecer a Jéssica Schuster e Diniz Arruda pelo apoio técnico fornecido para o estudo. Aos funcionários do Laboratório de Ecologia de Pastagens Naturais (LEPAN) da UFSM, agradecemos os dados.

### **Contribuição dos autores**

Conceitualização, investigação, metodologia, validação, Marildo Guerini Filho e Tatiana Mora Kuplich; Software, análise formal, redação - preparação do documento original, Marildo Guerini Filho; redação - revisão e edição, supervisão, Tatiana Mora Kuplich.

## 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**. 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. **Pesquisa Agropecuária Brasileira** 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 Sensing Environmental**. 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. **International Journal Remote Sensing**. 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. **Photogrammetric Engineering and 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. **Rangeland Ecology & Management**. 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. **Journal Photochemistry Photobiology B: Biology**. 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 benchmarking water productivity of irrigated cotton and sugarbeet crops. **Agricultural Water Management**. 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 Sensing Environmental**. 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 Sensing Environmental**. 132, 145–158. 2013. <https://doi.org/10.1016/j.rse.2013.01.010>
- HUETE, A.R., LIU, H.Q., BATCHILY, K., VAN LEEUWEN, W. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. **Remote Sensing Environmental**. 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 Sensing**. 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. Ecosystems Environmental**. 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. **Physiologia 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. **Anais do XVII Simpósio Bras. Sensoriamento Remoto (SBSR)**, João Pessoa-PB, 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 Sensing Environmental**. 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 Sensing Environmental.** 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 en map. 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. **International Journal 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. **International Journal Remote Sensing.** 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 \rfrom AVIRIS data:\rDecomposing biochemical from structural signals. **Remote Sensing Environmental.** 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 Sensing Environmental.** 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.
- 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. **Anais do XV Simpósio Bras. Sensoriamento Remoto (SBSR)**, Curitiba, PR, Brasil, 2011. <https://doi.org/10.1152/jn.00167.2006>
- TUCKER, C.J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing Environmenyal.** 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. **International Journal of Applied Earth Observation.** 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. **International Journal Remote Sensing**. 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 Sensing Environmental**. 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. **Ecological Indicators**. 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. **Rangeland Ecology & Management**. 67, 9–18. 2014. <https://doi.org/10.2111/REM-D-13-00059.1>