



OBTENÇÃO DE ATRIBUTOS DE PASTAGENS POR MEIO DE IMAGENS DO SENSOR OLI/LANDSAT-8

Vinícius Tauan **Cassaniga**¹; Hilton Luís Ferraz da **Silveira**²

Nº 20517

RESUMO – A agropecuária é uma atividade com alta taxa de geração de empregos e significativa participação no produto interno bruto (PIB) do país. Grande parte das pastagens do território brasileiro apresenta algum tipo de degradação, que as torna menos rentáveis e menos eficientes, portanto o seu mapeamento é de grande importância para a identificação e recuperação das áreas. O sensoriamento remoto tem grande potencial para identificar e classificar essas áreas, porém depende, entre outras coisas, de conhecimento sobre o comportamento espectral das áreas ocupadas por este uso. O presente estudo busca estabelecer uma metodologia para obter atributos de pastagens oriundos de dados de sensoriamento remoto, para seu uso em algoritmos de classificação. Foram definidos como atributos de pastagens os valores mínimos, máximos, de média e de desvio padrão para quatro índices de vegetação e para seis bandas espectrais do sensor OLI/Landsat-8 nos períodos secos e chuvosos dos anos de 2017, 2018 e 2019. Esses atributos foram calculados nos polígonos de pastagens identificados nos dados do Mapbiomas durante o período de interesse (2017 a 2019). O resultado obtido foi um arquivo vetorial com 160 atributos para mais de 125 mil áreas de pastagens na área de estudo.

Palavras-chaves: Cerrado, degradação de pastagens, EVI, NDII, NDVI.

1 Autor, Estagiário: Graduação em Engenharia Ambiental e Sanitária, PUCC, Campinas-SP; vinicius.tauan@colaborador.embrapa.br.

2 Orientador: Analista da Embrapa Territorial, Campinas-SP; hilton.ferraz@embrapa.br.



ABSTRACT – *Great part of Brazilian pastures show some degree of degradation, which makes them less profitable and efficient. Mapping these areas is an important step for their identification and recovery. Remote sensing shows good potential for identifying and classifying these areas, but depends on knowledge about the spectrotemporal signature of grassland areas, among other data. This study aims to propose a remote-sensing method for acquiring pasture metrics to be used in classification algorithms. Minimum, maximum, average, and standard deviation values were defined for four vegetation indices and six OLI/Landsat-8 spectral bands, for dry and rainy seasons in the years 2017, 2018, and 2019. These metrics were calculated on pasture polygons identified in Mapbiomas data for the 2017–2019 period. The result obtained was a geospatial vector data file with 160 attributes for over 125.000 pasture areas on the study area.*

Keywords: *Cerrado, pasture degradation, EVI, NDII, NVDI.*

1 INTRODUÇÃO

O Brasil tem o segundo maior rebanho bovino do mundo (superior a 238 milhões de cabeças), perdendo apenas para o rebanho da Índia. Porém, em termos comerciais, apresenta a maior exportação e o segundo maior consumo mundial, visto que na Índia, por motivos culturais, muitos não consomem esse animal (USDA, 2020). No Brasil, a forma majoritária de criação de rebanhos é por pastejo, em virtude da facilidade para alimentar o gado, que torna mais rentável essa forma de manejo em comparação à criação em confinamento, como ocorre em países europeus, Austrália e EUA. Essa condição faz com que nossa produção de carne tenha alta qualidade e custos menores (Raupp; Fuganti, 2014).

Segundo dados do “Atlas digital das pastagens brasileiras”, em 2018, o total de áreas de pastagens no Cerrado brasileiro correspondia a aproximadamente 35% do total de pastagens nacional. Este bioma apresenta a maior área de pastagens, com quase 63 milhões de hectares, correspondendo a 30% de sua área total (Lapig, 2020).

Apesar da importância da pecuária, as áreas de pastagem no Cerrado que apresentam algum nível de degradação ocupam mais de 60% da área total (Lapig, 2020). O resultado disso é um impacto econômico direto, dado que, na fase de engorda, uma pastagem em bom estado de



manutenção pode corresponder a uma quantidade de produção de carne até seis vezes maior que uma pastagem degradada, o que mostra quão importante é a recuperação das áreas degradadas (Macedo, 1995).

O mapeamento busca suprir a carência de informações atualizadas sobre as áreas de pastagens, facilitando a implementação de políticas e a manutenção das áreas que apresentam degradação, de forma a evitar o desmatamento de novas áreas e a aumentar a produção (Sano et al., 2000). Para fazer o mapeamento em larga escala – como é o caso de mapear todo o Cerrado brasileiro –, é necessário usar uma ferramenta robusta e que ofereça constante monitoramento, de modo que o sensoriamento remoto tem papel importante.

Entretanto, as pastagens apresentam padrões difíceis de serem caracterizados, pois misturam elementos em sua composição, como árvores, gramas, arbustos, entre outros (Seyler et al., 2002), e, para produzir um amplo mapeamento, um bom número de amostras para treinamento e teste dos classificadores é necessário. Neves et al. (2017), por exemplo, utilizaram 500 amostras de dados de referência, contendo atributos como índices de vegetação e análises estatísticas, e obtiveram um desempenho satisfatório na detecção de pastagens nos classificadores J48, *Random Forest* e *Multilayer Perceptron*.

A Embrapa aprovou o projeto “Mapeamento de níveis de degradação de pastagens no bioma Cerrado por meio de geotecnologias”, no qual este trabalho se insere. Nesse contexto, o presente estudo busca estabelecer uma metodologia para obter atributos de pastagens oriundos de dados de sensoriamento remoto, para uso em algoritmos de classificação. Os resultados aqui obtidos serão utilizados neste mesmo projeto, como amostras de treinamento e teste para algoritmos de classificação supervisionada de imagens, a fim identificar níveis de degradação em pastagens do Cerrado brasileiro.

2 MATERIAL E MÉTODOS

A metodologia utilizada neste trabalho é apresentada na Figura 1, sob a forma de um fluxograma.

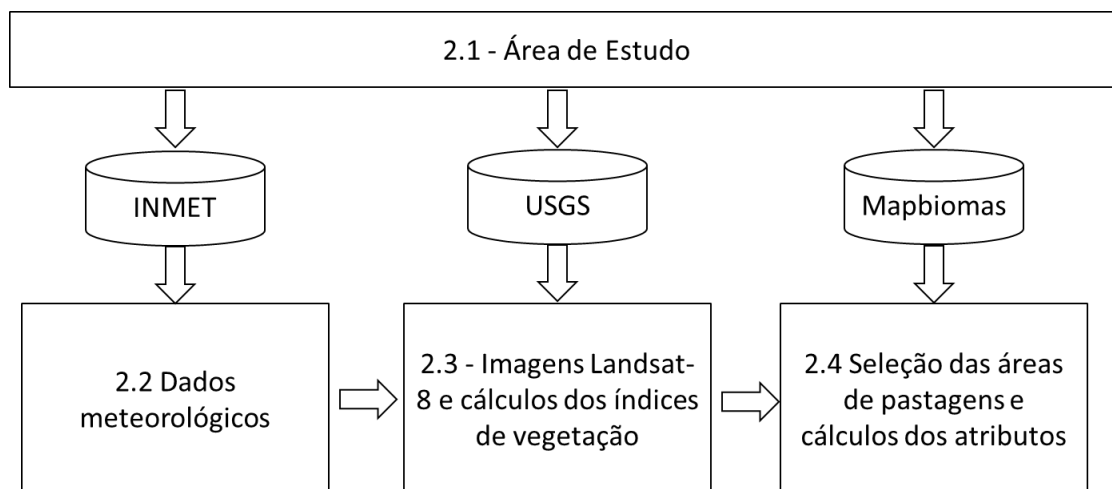


Figura 1. Fluxograma das etapas de trabalho.

2.1 Área de estudo

Embora o objetivo seja o mapeamento de todo o Cerrado brasileiro, inicialmente foi definida como piloto uma área de 20 municípios dos estados de São Paulo, Mato Grosso do Sul e Mato Grosso, totalizando aproximadamente 130 mil quilômetros quadrados. Foram utilizadas cenas do Landsat-8 que recobrem esses municípios. As cenas e os municípios estão representados na Figura 2.

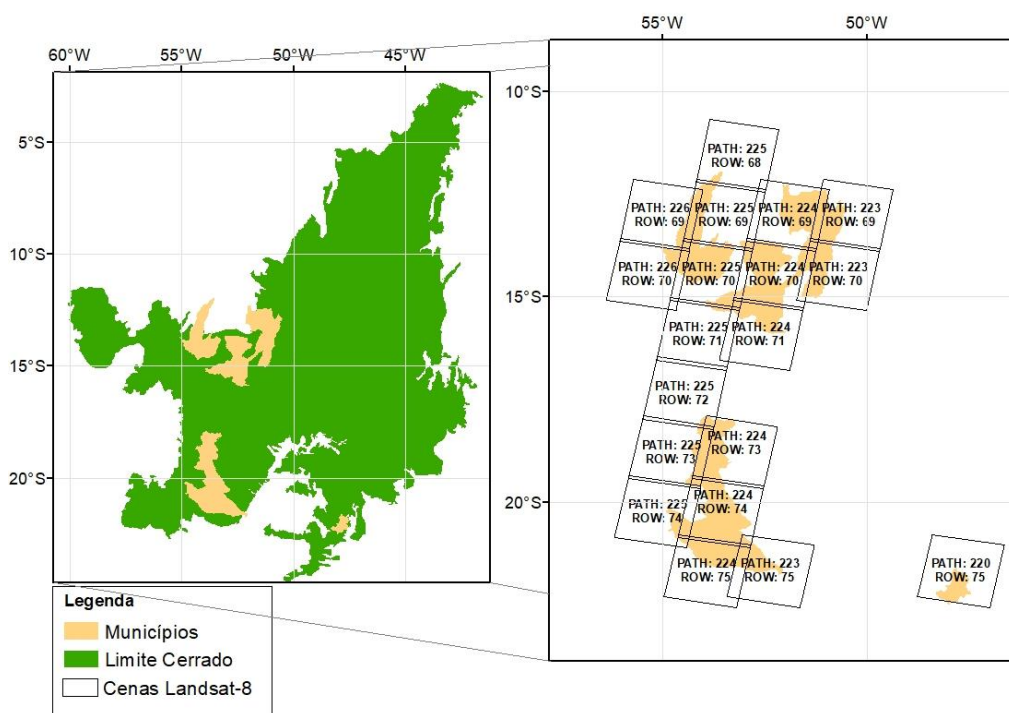


Figura 2. Área de estudo e o mosaico de imagens do sensor OLI/Landsat-8 (órbita/ponto) responsáveis pelo recobrimento da área.

2.2 Dados meteorológicos

A vegetação responde diretamente aos períodos de chuva e estiagem anuais. Entretanto, embora sejam conhecidos, esses períodos podem apresentar variação de ano para ano. Para entender o comportamento fenológico da vegetação durante a aquisição das imagens orbitais e a definição dos períodos secos e chuvosos de cada ano específico, foi efetuado *download* de dados do Banco de Dados Meteorológicos para Ensino e Pesquisa, sob responsabilidade do Instituto Nacional de Meteorologia (Inmet), referentes a 16 estações meteorológicas localizadas na área de estudo ou em suas imediações (Inmet, 2019).

Após a aquisição dos dados, foi feita a seleção das estações, visando eliminar os postos meteorológicos que não contassem com uma série histórica robusta (mais de dez anos) ou que tivessem falhas na coleta durante o período de estudo (2017-2019). Para os estados de Mato Grosso do Sul e São Paulo foram utilizados os bancos de dados das estações de Campo Grande e São Carlos, respectivamente (Figura 3). Para o estado de Mato Grosso, em virtude da falta de dados consistentes, foram utilizadas as estações de Nova Xavantina e Canarana, localizadas na vizinhança da área de estudo. a) b)



Figura 3. Precipitação mensal nos municípios de São Carlos, SP (a), e Campo Grande, MS (b).

2.3 Imagens Landsat-8 e cálculos dos índices de vegetação

A atmosfera interfere na radiação que chega à superfície terrestre ou ao sensor, pois pode absorver ou espalhar radiação (Ponzoni; Shimabukuro, 2010). Essa interferência pode causar alteração do brilho da cena e diminuição de contrastes (Antunes et al., 2012). Dessa forma, foram obtidos os dados de refletância de superfície para o sensor OLI (*Operational Land Imager*), a bordo do satélite Landsat-8, para o período correspondente aos anos de 2017, 2018 e 2019 e de imagens livres de nuvens, a partir do portal Earth Explorer (USGS, 2019).

Para realçar as características dos alvos e dos processos fenológicos envolvidos na degradação de pastagens, foram calculados índices de vegetação, representados na Tabela 1.



Tabela 1. Índices de vegetação utilizados no estudo. Os valores B2, B4, B5, B6 e B7 utilizados nas equações correspondem à refletância nas bandas do sensor OLI/Landsat-8.

Índice	Equação	Referência
NDVI	$((B5-B4))/((B5+B4))$	(Rouse et al., 1973)
NDIIa	$(B5-B7)/(B5+B7)$	(Hunt; Rock, 1989)
NDIIb	$(B5-B6)/(B5+B6)$	(Hunt; Rock, 1989)
EVI	$\frac{2,5 * (B5-B4)}{((B5+6 * B4-7,5 * B2+1))}$	(Huete et al., 1997)

O primeiro índice escolhido para este trabalho foi o NDVI (*Normalized Difference Vegetation Index*), que retrata a diferença normalizada entre a refletância do infravermelho próximo e do vermelho, com resultados para cada pixel variando entre 1 e -1. Valores próximos ou iguais a 1 representam vegetação com maior presença de estrutura celular e maior quantidade de clorofila, valores próximos a 0 representam solos expostos e, abaixo de 0, representam corpos hídricos (Rouse et al., 1973).

Outro índice normalizado utilizado foi o NDII (*Normalized Difference Infrared Index*), que retrata a diferença normalizada entre as bandas do infravermelho próximo e infravermelho de ondas curtas. Seus resultados variam entre 1 e -1. Valores próximos ou iguais a 1 indicam grande teor de água na estrutura da planta, valores próximos ou iguais a 0 representam baixa ou escassa quantidade de água na estrutura da planta (Huete et al., 1997). Neste trabalho foram empregadas duas variações deste índice. A primeira, NDIIa, utiliza a banda entre 1.570 nm e 1.650 nm e a segunda, NDIIb, emprega a banda entre 2.110 nm e 2.290 nm.

Tabela 2. Cenas utilizadas para obter os atributos de pastagens em cada um dos períodos considerados.

Orbita/ ponto	2017		2018		2019	
	Seco	Chuvoso	Seco	Chuvoso	Seco	Chuvoso
220-075	17/07/2017	02/07/2017	20/07/2018	30/03/2018	08/08/2019	30/12/2019
223-069	23/08/2017	17/04/2017	26/08/2018	06/05/2018	29/08/2019	09/05/2019
223-070	08/09/2017	17/04/2017	11/09/2018	04/04/2018	14/09/2019	09/05/2019
223-075	08/09/2017	01/04/2017	11/09/2018	04/04/2018	14/09/2019	17/01/2019
224-069	15/09/2017	24/04/2017	02/09/2018	27/04/2018	05/09/2019	08/01/2019
224-070	15/09/2017	07/03/2017	02/09/2018	11/04/2018	05/09/2019	17/06/2019
224-071	15/09/2017	08/04/2017	02/09/2018	27/04/2018	05/09/2019	08/01/2019
224-073	15/09/2017	23/03/2017	17/08/2018	11/04/2018	21/09/2019	16/05/2019
224-074	15/09/2017	23/03/2017	17/08/2018	11/04/2018	04/08/2019	29/03/2019
224-075	15/09/2017	24/04/2017	17/08/2018	11/04/2018	04/08/2019	29/03/2019
225-069	06/09/2017	15/04/2017	09/09/2018	02/04/2018	12/09/2019	23/05/2019
225-070	06/09/2017	15/04/2017	09/09/2018	02/04/2018	11/08/2019	07/05/2019
225-071	06/09/2017	15/04/2017	09/09/2018	02/04/2018	11/08/2019	07/05/2019
225-072	22/09/2017	15/04/2017	24/08/2018	17/03/2018	07/05/2019	07/05/2019
225-073	22/09/2017	30/03/2017	09/09/2018	04/05/2018	11/08/2019	31/01/2019
225-074	22/09/2017	30/03/2017	09/09/2018	17/03/2018	11/08/2019	-
226-069	29/09/2017	08/05/2017	15/08/2018	25/04/2018	18/08/2019	30/05/2019
226-070	13/09/2017	08/05/2017	-	25/04/2018	19/09/2019	-



O índice EVI (*Enhanced Vegetation Index*) apresenta coeficientes de correção – coeficiente de ganho (2,5) e ajuste para efeitos de aerossóis da atmosfera (6; 7,5) –, minimizando efeitos causados pela resposta do solo ou atmosfera (Justice et al., 1998), com isso minimiza erros de distorção de pixels causados por efeitos como sombra do solo no fundo dossel.

Após a classificação das imagens por ano (2017, 2018 e 2019) e período (seco ou chuvoso, em função dos dados das estações meteorológicas), foram selecionadas as melhores imagens de cada ano/período, compondo um mosaico para cada época de cada ano, conforme a Tabela 2.

Os cálculos foram efetuados para cada imagem, por meio de códigos Python, usando o software ArcGIS. Esses cálculos auxiliam na interpretação da imagem, para diagnosticar a vegetação e a variação e, com isso, facilitar a identificação de áreas de pastagem em conjunto com outros fatores.

2.4 Seleção das áreas de pastagens e cálculos dos atributos

Foi feito o *download*, da plataforma Mapbiomas, dos dados de uso e cobertura da terra para o território pertencente ao Cerrado brasileiro, referente à coleção 4.1, para os anos de 2017, 2018 e 2019. Por meio de álgebra de mapas no *software* ArcGIS, foram escolhidas as áreas que se mantiveram na classe pastagem (que considera as áreas referentes às pastagens plantadas) durante o triênio de 2017 a 2019 e que estavam inteiramente contidas na área piloto selecionada.

Cada área contínua de pastagem foi utilizada para selecionar o conjunto de pixels correspondente ao mosaico de imagens obtido no item 2.3, de onde foram feitos cálculos estatísticos (mínimo, máximo, média e desvio-padrão) para cada banda e índice de vegetação, usando código Python. Por fim, foi gerada uma tabela com todos os atributos do mosaico de imagens selecionadas dentro das pastagens indicadas.

3 RESULTADOS E DISCUSSÃO

O resultado obtido foi um arquivo vetorial com 160 atributos para mais de 125 mil áreas de pastagens na área de estudo, o qual foi disponibilizado na plataforma GeoInfo (http://geoinfo.cnpm.embrapa.br/account/login/?next=/layers/geonode:atributos_past_17_18_semo). A Figura 4 mostra os valores médios dos índices de vegetação encontrados nos polígonos de áreas de pastagem em cada estado.

Na região do estado de São Paulo, no ano de 2017, o início do período seco apresentou um volume pluvial acima da média histórica, o que se refletiu em baixa queda nos valores dos índices

de vegetação. Já no ano de 2018, o início do período seco apresentou volume abaixo da média histórica e níveis acima no período chuvoso, o que se reflete em queda mais acentuada.

Para o estado de Mato Grosso do Sul, o ano de 2017 apresentou valores de volume pluvial maiores que a média histórica no período chuvoso e o ano de 2018 foi regular, com poucas distorções da média histórica. Para o estado de Mato Grosso, não foi possível encontrar dados da região de estudo ou listar uma série histórica eficiente, devido à falta de dados. No ano de 2017, essa região apresentou volume pluvial muito baixo no período seco e alto (acima da média histórica) no período chuvoso. Já no ano de 2018, apresentou valores próximos à média histórica, porém a região tem os menores valores de volume pluvial quando comparada aos demais estados.

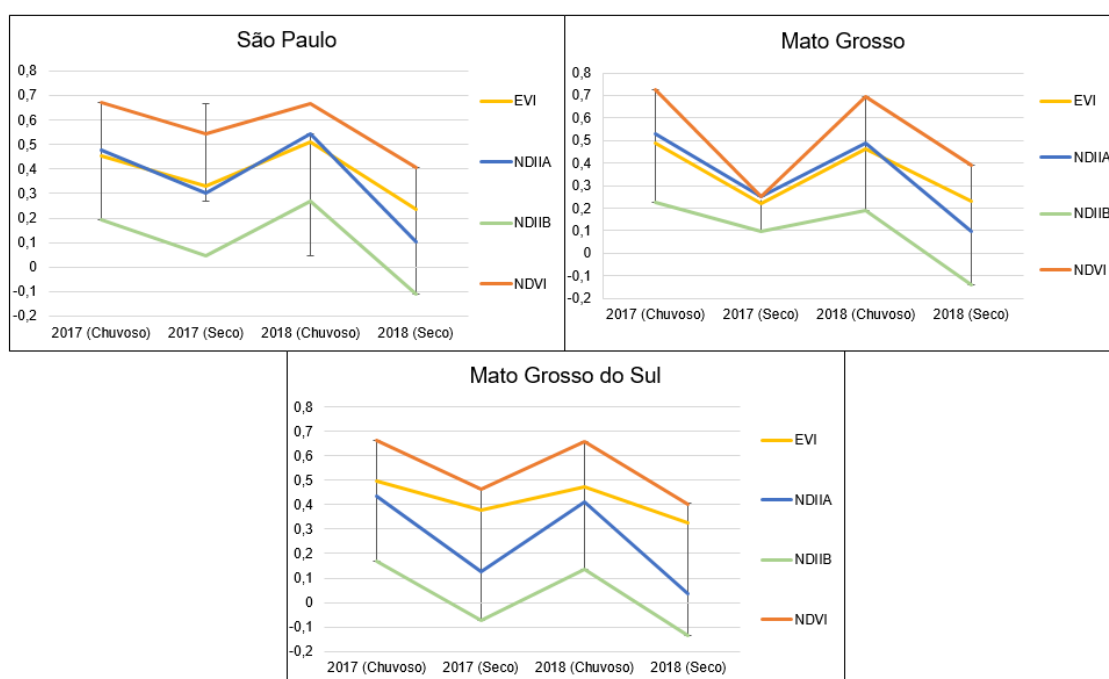


Figura 4. Índices de vegetação de áreas de pastagens em função dos períodos chuvoso e seco.

Demarchi et al. (2011) em estudo desenvolvido em área do estado de São Paulo, concluíram que o índice NDVI tem grande eficiência para distinguir classes de solo entre cobertura vegetal e solo exposto, pois apresenta medição eficiente de vigor vegetativo, tornando possível determinar períodos secos e chuvosos. Já Ravaglia et al. (2010) observaram alta correlação positiva com a fração vegetação e negativa com a fração solo. No trabalho desenvolvido por Santos et al. (2019) no estado de Goiás, os valores de NDVI detectados para a cobertura pastagem variaram entre 0,6 no período chuvoso e 0,3 no período seco, números que se assemelham aos encontrados neste trabalho, principalmente para o estado de Mato Grosso do Sul, isso em razão de a área estar em um mesmo bioma e apresentar características climáticas e vegetativas muito parecidas.



O EVI, no estudo desenvolvido por Bayma-Silva et al. (2014), apresentou boa discriminação entre classes de pastagem e de vegetação savânica gramíneo-lenhosa, com uma discriminação maior no período seco. Para Borges e Sano (2014), o EVI também foi fundamental para a distinção de classes em área do Cerrado, onde o EVI variou entre 0,3 em períodos chuvosos e 0,2 em períodos secos. A ocorrência de um valor menor quando comparado à região de estudo apresentada neste trabalho pode decorrer de mudanças climáticas locais, pois, embora os estudos tenham sido desenvolvidos para o mesmo bioma, as regiões eram distintas e apresentavam características locais com algumas diferenças.

No estudo feito por Felix et al. (2017) em área de transição do bioma Cerrado e para período chuvoso, com o objetivo de classificar áreas por classes de cobertura de vegetação, definindo valores de distinção entre as classes, o índice NDII apresentou baixa consistência, com resultado de distinção de 0,31, mostrando-se nesse caso insuficiente para o mapeamento. O resultado negativo obtido para o índice vegetativo NDII por esses autores pode ter influência da falta de análise temporal e de sobreposições de vegetação, devido a características dos biomas, principalmente do Cerrado, que apresenta plantas rasteiras e arbustivas entre a vegetação nativa, causando sobreposições principalmente entre as vegetações de pastagem, vegetação em regeneração e várzea e, assim, dificultando a diferenciação dessas classes (Batista et al., 2014).

4 CONCLUSÃO

Os índices de vegetação, como foi observado em outros trabalhos, mostram-se de grande eficiência para a obtenção de imagens com diferença de vigor vegetativo, principalmente entre vegetação nativa (savânica) e vegetação de pastagem. Serão fundamentais na diferenciação das pastagens em comparação às demais vegetações, e possivelmente nas classes de degradação das pastagens em outras etapas do projeto. A utilização dos dados meteorológicos foi eficiente para a seleção de cenas dos períodos seco e chuvoso. Com base nos resultados obtidos e na discussão feita, concluímos que a metodologia aqui desenvolvida foi eficiente, principalmente nas etapas de escolhas de imagens de distintos períodos, nos cálculos de índices de vegetação e cálculos estatísticos.

Para as etapas futuras, os atributos gerados e apresentados neste trabalho serão relacionados a índices de degradação de pastagens obtidos em campo e utilizados no treinamento, na validação e no teste de classificadores para o mapeamento dos níveis de degradação de pastagens.



5 AGRADECIMENTOS

Os autores agradecem à Embrapa, pelo financiamento do projeto de pesquisa "Mapeamento de níveis de degradação de pastagens no bioma Cerrado por meio de geotecnologias" (nº 10.18.03.062.00.00).

6 REFERÊNCIAS

ANTUNES, M. A. H.; DEBIASI, P.; COSTA, A. D.; GLERIANI, J. M. Correção atmosférica de imagens ALOS/AVINIR-2 utilizando o modelo 6S. **Revista Brasileira de Cartografia**, v. 4, n. 64, p. 531–539, 2012.

BAYMA-SILVA, G.; ROSA, C. M.; VICENTE, L. E.; NOGUEIRA, S. F.; VICTORIA, D. C.; GOMES, D.; GUIMARÃES, R. A. Discriminação de áreas de pastagens plantadas por meio de séries temporais EVI-2. In: SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL, 5., 2014, Campo Grande. **Anais...** Campo Grande: Embrapa Informática Agropecuária; INPE, 2014. p. 739-747.

BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p. 526-547, 2014.

BATISTA, M. de A.; DE PAIVA, D. W.; MARCOLINO, A. **Solos para todos: perguntas e respostas**. Rio de Janeiro: Embrapa Solos, 2014. 87 p.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo–SP usando imagens LANDSAT-5. **Raega-O Espaço Geográfico em Análise**, v. 21, p. 234-271, 2011.

FELIX, F. C.; AVALOS, F. A. P.; SILVA, M. L. N.; MINCATO, R. L. Mapeamento da cobertura vegetal a partir de imagens de alta resolução obtidas por VANT. In: SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA APLICADA, 17.; CONGRESSO NACIONAL DE GEOGRAFIA FÍSICA, 1., 2017. **Os desafios da geografia física na fronteira do conhecimento**. Campinas, 2017. v. 1, p. 5095-5105.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K. V.; VAN LEEUWEN, W. J. D. A. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, 1997.

HUNT JR, E. R.; ROCK, B. N. Detection of changes in leaf water content using Near and Middle-Infrared reflectances. **Remote Sensing of Environment**, v. 30, n. 1, p. 43-54, 1989.

INMET. **Banco de dados meteorológicos para ensino e pesquisa**. Disponível em: <https://bdmep.inmet.gov.br/#>. Acesso em: 10 out. 2019.

JUSTICE, C. O.; VERMOTE, E.; TOWNSHEND, J. R.; DEFRIES, R.; ROY, D. P.; HALL, D. K.; LUCHT, W. The moderate resolution imaging spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

LAPIG. Laboratório de Processamento de Imagens e Geoprocessamento. **Lapig-Maps**. Disponível em: <http://maps.lapig.iesa.ufg.br/lapig.html>. Acesso em: 01 ago. 2020.

MACEDO, M. C. M. Pastagens nos ecossistemas de cerrados: pesquisas para o desenvolvimento sustentável. In: SIMPÓSIO SOBRE PASTAGENS NOS ECOSISTEMAS BRASILEIROS, 1995, Brasília, DF. **Anais...** Brasília: SBZ, 1995. p. 28-62.

NEVES, A. K.; KÖRTING, T. S.; NETO, C. D. G.; FONSECA, L. M. G. Mineração de dados de sensoriamento remoto para detecção e classificação de áreas de pastagem na Amazônia Legal. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos. **Anais...** São José dos Campos: INPE, 2017. p. 2508-2515.



PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2010, p. 136.

RAUPP, F. M.; FUGANTI, E. N. Gerenciamento de custos na pecuária de corte: um comparativo entre a engorda de bovinos em pastagem e em confinamento. **Custos e Agronegócio online**, v. 10, n. 3, p. 282-316, 2014.

RAVAGLIA, A. G.; da SILVA, L. C. F.; SANTOS, S. A.; SHIMABUKURO, Y. E.; PELLEGRIN, L. A.; SORIANO, B.; da SILVA, G. A. Uso de um modelo linear de mistura espectral e índice de vegetação na avaliação de pastagens em degradação no Pantanal. In: SIMPÓSIO SOBRE RECURSOS NATURAIS E SOCIOECONÔMICOS DO PANTANAL, 5., 2010, Corumbá. **Anais...** Corumbá: Embrapa Pantanal, 2010. p. 1-5.

ROUSE JR, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

SANO, E. E.; CHAVES, J. M.; BEZERRA, H. S.; FEITOZA, L. Identificação dos principais tipos de pastagens cultivadas do Cerrado a partir de Sensoriamento Remoto. In: INTERNATIONAL SYMPOSIUM: SOIL FUNCTIONING UNDER PASTURES IN INTERTROPICAL AREAS, 2000, Brasília. **Anais...** Brasília: Embrapa Cerrados; IRD, 2000.

SANTOS, D. L. Da S.; FERREIRA, R. G. G. Dos A. B.; MALHEIRO, A. M.; OLIVEIRA-SANTOS, C. comparação dos valores de NDVI em áreas vegetação nativa, pastagens com muitas árvores e pastagens sem árvores. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais...** Santos: INPE, 2019. p. 2287-2290.

SEYLER, F.; CHAPLOT, V.; MULLER, F.; CERRI, C. E. P.; BERNOUX, M.; BALLESTER, V.; FELLER, C.; CERRI, C. C. C. Pasture mapping by classification of Landsat TM images. Analysis of the spectral behavior of the pasture class in a real medium scale environment: the case of the Piracicaba Catchment (12 400 km², Brazil). **International Journal of Remote Sensing**. v. 23. n. 23. p. 4985-5004, 2002.

USGS. **EarthExplorer**. Disponível em: <https://earthexplorer.usgs.gov/>. Acesso em: 07 jul. 2019.

USDA. United States Department of Agriculture. **Agricultural Research Service 2020**. Disponível em: <https://apps.fas.usda.gov/psdonline/app/index.html#/app/downloads>. Acesso em: 30 jul. 2020.