




## Identificação do processo de degradação de pastagens plantadas em áreas de Cerrado em Mato Grosso do Sul e São Paulo usando dados do sensor OLI/Landsat-8 e 9 e distintos classificadores



**Empresa Brasileira de Pesquisa Agropecuária**  
**Embrapa Territorial**  
**Ministério da Agricultura e Pecuária**

**BOLETIM DE PESQUISA**  
**E DESENVOLVIMENTO**  
**41**

Identificação do processo de degradação  
de pastagens plantadas em áreas de  
Cerrado em Mato Grosso do Sul e São  
Paulo usando dados do sensor OLI/  
Landsat-8 e 9 e distintos classificadores

*Hilton Luís Ferraz da Silveira*  
*Ricardo Guimarães Andrade*  
*Cristina Aparecida Gonçalves Rodrigues*  
*Carlos Cesar Ronquim*  
*Sérgio Galdino*

**Embrapa Territorial**  
*Campinas, SP*  
2023

**Embrapa Territorial**  
Av. Soldado Passarinho, nº 303  
Fazenda Chapadão  
13070-115, Campinas, SP  
Fone: (19) 3211.6200  
www.embrapa.br/territorial  
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações  
da Embrapa Territorial

Presidente  
*Luciola Alves Magalhães*

Secretária-executiva  
*Bibiana Teixeira de Almeida*

Membros

*André Luiz dos Santos Furtado, Celina Maki  
Takemura, Janice Freitas Leivas, Rafael Mingoti,  
Suzilei Francisca de Almeida Gomes Carneiro, Vera  
Viana dos Santos Brandão, Jaudete Daltio, Cristina  
Crisculo, Rogério Resende Martins Ferreira e  
Daniela Tatiane de Souza*

Supervisão editorial  
*Bibiana Teixeira de Almeida e Suzilei Carneiro*

Revisão de texto  
*Bibiana Teixeira de Almeida*

Normalização bibliográfica  
*Vera Viana dos Santos Brandão*

Projeto gráfico da coleção  
*Carlos Eduardo Felice Barbeiro*

Editoração eletrônica e tratamento das ilustrações  
*Suzilei Carneiro*

Ilustração da capa  
*Image Landsat / Copernicus - ©2023 Maxar  
Technologies*

**1ª edição**  
Publicação digital (2023): PDF

**Todos os direitos reservados.**

A reprodução não autorizada desta publicação, no todo ou em parte,  
constitui violação dos direitos autorais (Lei nº 9.610).

**Dados Internacionais de Catalogação na Publicação (CIP)**

Embrapa Territorial

---

Identificação do processo de degradação de pastagens plantadas em áreas de Cerrado em Mato Grosso do Sul e São Paulo usando dados do sensor OLI/Landsat-8 e 9 e distintos classificadores / Hilton Luís Ferraz da Silveira ...[et al.]. – Campinas: Embrapa Territorial, 2023.  
PDF (34 p.). : il. – (Boletim de Pesquisa e Desenvolvimento / Embrapa Territorial, ISSN 1806-3322 ; 41)

1. Imagem de satélite. 2. Mapeamento. 3. Sistema de informação geográfica. I. Silveira, Hilton Luís Ferraz da. II. Andrade, Ricardo Guimarães. III. Rodrigues, Cristina Aparecida Gonçalves. IV. Ronquim, Carlos Cesar. V. Galdino, Sérgio. VI. Título. VII. Série.

CDD (21. ed.) 621.367 8

*Vera Viana dos Santos Brandão* (CRB-8/7283)

© 2023 Embrapa

## Sumário

---

Resumo .....	7
Abstract .....	9
Introdução.....	10
Material e métodos .....	11
Resultados e discussão.....	22
Conclusões.....	28
Agradecimentos.....	29
Referências .....	29
Apêndice A .....	33
Apêndice B .....	34



# Identificação do processo de degradação de pastagens plantadas em áreas de Cerrado em Mato Grosso do Sul e São Paulo usando dados do sensor OLI/Landsat–8 e 9 e distintos classificadores

Hilton Luís Ferraz da Silveira<sup>1</sup>

Ricardo Guimarães Andrade<sup>2</sup>

Cristina Aparecida Gonçalves Rodrigues<sup>3</sup>

Carlos Cesar Ronquim<sup>4</sup>

Sérgio Galdino<sup>5</sup>

**Resumo** – Este trabalho objetivou identificar pastagens degradadas em duas áreas do bioma Cerrado, nos estados de Mato Grosso do Sul e São Paulo. Foram coletadas 380 amostras de campo nos anos de 2022 e 2023, que identificaram níveis de degradação que foram sintetizados em três níveis (pastagens não degradadas, em degradação e degradadas) e duas classes (pastagens em boas condições e em más condições). Para treinamento e classificação, dados do sensor OLI/Landsat–8 e 9 em datas próximas às das coletas em campo foram divididos em três conjuntos: a) apenas valores de reflectância das bandas espectrais, b) somente índices espectrais e c) bandas e índices espectrais juntos, que foram submetidos a oito classificadores. Os três melhores resultados obtidos apresentaram acurácias de 0,486, 0,709 e 0,726. A falta de pontos qualificados para pastagem não degradada influenciou negativamente no processo de seleção, assim como a inexistência de um trabalho de campo no período seco. O grande número de métricas não contribuiu necessariamente para melhorar os resultados de classificação.

---

<sup>1</sup> Geógrafo, mestre em Sensoriamento Remoto, analista da Embrapa Territorial, Campinas, SP

<sup>2</sup> Engenheiro agrícola, doutor em Agronomia, pesquisador da Embrapa Gado de Leite, Juiz de Fora, MG

<sup>3</sup> Zootecnista, doutora em Biologia Vegetal, pesquisadora da Embrapa Territorial, Campinas, SP

<sup>4</sup> Agrônomo, doutor em Ecologia e Recursos Naturais, pesquisador da Embrapa Territorial, Campinas, SP

<sup>5</sup> Agrônomo, doutor em Engenharia Agrícola, pesquisador da Embrapa Territorial, Campinas, SP

Uma análise do impacto da segmentação no processo de classificação é necessária em estudos futuros. A metodologia empregada não é adequada ao mapeamento de degradação de pastagens, em função dos baixos scores de acurácia obtidos.

**Termos para indexação:** Aprendizagem de máquina, classificação, índices espectrais, sensoriamento remoto.

## Identification of the degradation process of planted pastures in Cerrado areas of Mato Grosso do Sul and São Paulo using OLI/Landsat–8 and 9 data and different classifiers

**Abstract** – This work aimed to identify degraded pastures in two areas of the Cerrado biome, in the states of Mato Grosso do Sul and São Paulo. In 2022 and 2023, we collected 380 field samples to identify three levels (non-degraded, under degradation, and degraded pastures) and two classes (pastures in good condition and in poor condition) of degradation. For training and classification, data from the OLI/Landsat–8 and 9 sensors on dates close to those of the field collections were divided into three sets: a) only spectral band reflectance values, b) only spectral indices, and c) both spectral bands and indices together. These sets were then subjected to eight classifiers. The three best results obtained showed accuracies of 0.486, 0.709, and 0.726. The lack of qualified points for non-degraded pastures negatively influenced the selection process, as did the absence of fieldwork during the dry season. The large number of metrics did not necessarily contribute to improving the classification results. An analysis of the impact of segmentation on the classification process is needed in future studies. The methodology employed is not suitable for mapping pasture degradation due to the low accuracy scores obtained.

**Index terms:** Machine learning, classification, spectral indices, remote sensing.



## Introdução

---

A pecuária brasileira representa uma importante cadeia produtiva do Brasil. É responsável por 27% do produto interno bruto (PIB) da agropecuária, 730 bilhões de reais em 2022 (Cepea, 2023). Dentro do universo da pecuária, as pastagens destinadas à criação do gado bovino dominam a paisagem e ocupam 150 milhões de hectares para quase 225 milhões de cabeças em 2021, o segundo maior rebanho do mundo (IBGE, 2021; Mapbiomas, 2023; Santos et al., 2022).

Apesar de sua importância econômica, as pastagens brasileiras apresentam baixa produtividade quando comparadas às da Europa e dos Estados Unidos, resultado do manejo inadequado nas áreas de sistema de criação extensiva (Santos et al., 2022). Esse manejo inadequado afeta com algum grau de degradação cerca de um terço das áreas destinadas à criação de gado (Gosch et al., 2021). Esse processo de degradação reduz ainda mais a oferta de recursos para investimentos, levando proprietários rurais a venderem propriedades em áreas consolidadas no Centro-Sul do País, principalmente no Cerrado, para investir em novas áreas na região amazônica, cujas terras têm preço mais baixo, contribuindo para o processo de desmatamento da Amazônia (Barona et al., 2010).

No bioma Cerrado, Mato Grosso do Sul é um dos principais estados para a atividade pecuária, com um rebanho de mais de 18 milhões de cabeças (IBGE, 2021). Por sua vez, no estado de São Paulo, as áreas de pastagens estão sendo reduzidas ano após ano, resultado da expansão de áreas agrícolas, principalmente da cana-de-açúcar (Mapbiomas, 2023). Apesar dessa condição, o estado é um dos principais mercados consumidores para a carne, em razão de sua maior concentração populacional.

Neste contexto, o sensoriamento remoto tem potencial para identificar as áreas de pastagens degradadas e em degradação, a fim de contribuir para a gestão e a recuperação dessas áreas. Para fazer o mapeamento de áreas extensas em escalas maiores, de relativo detalhe, é conveniente usar um sistema sensor de média resolução espacial, com revisita frequente e que consiga captar desde as grandes áreas de pastagens de Mato Grosso do Sul quanto as áreas menores em São Paulo. Os satélites da série Landsat apresentam um longo histórico nas análises de pastagens degradadas (Smahi; Bensaid, 1998; Ringrose, 1999; Santos et al., 2022). Atualmente ativos, os

satélites Landsat–8 e Landsat–9 contam com o sensor *Operational Land Imager* (OLI) a bordo, que segue as mesmas características de resolução espacial, espectral e temporal utilizadas ao longo das últimas décadas pelos outros sensores do programa Landsat (USGS, 2019, 2022).

Todavia, a partir dos dados de sensoriamento remoto, os tomadores de decisão não são capazes de inferir diretamente as condições das pastagens, portanto é necessária a classificação desses dados em um número relativamente menor de classes e, assim, a tradução dos valores de reflectância em diversas bandas para uma informação mais tangível (Tso; Mather, 2001).

Uma forma de agrupar dados em classes é por meio do uso de algoritmos classificadores. No sensoriamento remoto, seu desenvolvimento remonta ao início da década de 1980, e atualmente existe um grande número de técnicas de classificação (Li et al., 2014). Com o desenvolvimento do aprendizado de máquina, como *Random Forest* (RF), *Support Vector Machine* (SVM) e as redes neurais (RN), aliado a uma classificação baseada em objetos, um novo paradigma tem sido oferecido à classificação no sensoriamento remoto (Li et al., 2014).

Este trabalho tem o objetivo de identificar pastagens degradadas em áreas do bioma Cerrado nos estados de Mato Grosso do Sul e de São Paulo utilizando dados do sensor OLI/Landsat–8 e 9 classificados pelos algoritmos *Tree*, redes neurais, *K-Nearest Neighbors* (kNN), AdaBoost, RF e SVM.

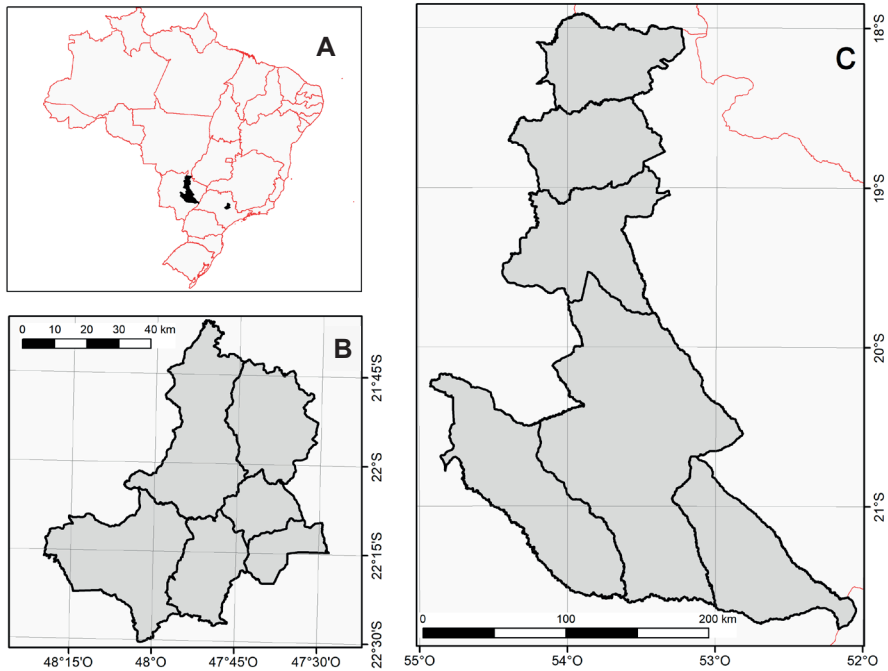
## Material e métodos

---

### Área de estudo

Foram definidas duas áreas de estudo (Figura 1), uma em São Paulo, composta pelos municípios de Analândia, Brotas, Corumbataí, Descalvado, Itirapina e São Carlos (totalizando 416.116 ha) e outra em Mato Grosso do Sul, abrangendo os municípios de Alcinópolis, Camapuã, Campo Grande, Figueirão, Ribas do Rio Pardo e Santa Rita do Pardo (totalizando 4.705.365 ha).

O Cerrado, também conhecido como savana brasileira, é o segundo maior bioma da América do Sul, ocupa cerca de um quarto do território nacional e é caracterizado por solos profundos, bem drenados e de baixa fertilidade (Arantes et al., 2016).



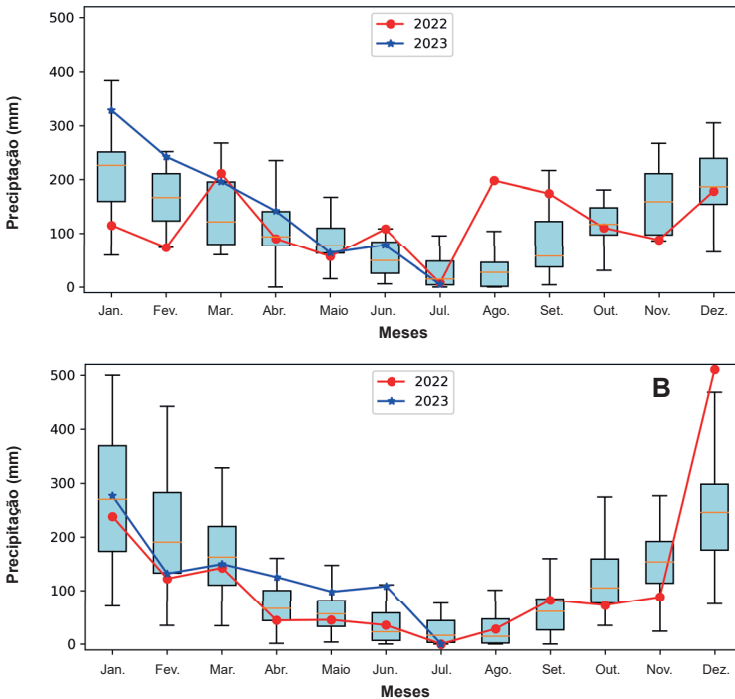
**Figura 1.** Mapa de localização das áreas de estudo com sua posição em relação ao Brasil (A) e em detalhe para os estados de São Paulo (B) e Mato Grosso do Sul (C).

Apresenta duas estações bem definidas, uma chuvosa (entre os meses de dezembro e março) e outra seca (entre os meses de abril e setembro) (Arantes et al., 2016).

A Figura 2 (A e B) mostra as distribuições das precipitações mensais (*boxplots*) e a precipitação acumulada para os anos de 2022 (linha vermelha) e 2023 (linha azul, com dados até julho) para as cidades de Campo Grande (a) e São Carlos (b), localizadas nas duas áreas de estudo, onde se observa o comportamento mais chuvoso de 2023 em relação ao primeiro semestre de 2022.

## Coleta de campo

Para este trabalho utilizou-se o banco de dados de condições de pastagens gerado pelo projeto Geopasto Cerrado da Embrapa Territorial (Rodrigues, 2022). A metodologia de campo consistiu no arremesso aleatório de um




**Figura 2.** *Boxplot* da distribuição da pluviosidade mensal e a precipitação acumulada mensal ocorrida em 2022 (vermelho) e 2023 (azul) para as cidades de (A) Campo Grande e de (B) São Carlos.

Fonte: Adaptado de Cemaden (2023), Cemtec (2023), Inmet (2023).

quadrado de 0,25 m<sup>2</sup> (0,5 m x 0,5 m) de policloreto de vinil (PVC) e, a partir deste, no traçado de duas retas perpendiculares cuja intersecção é sobre a posição desse primeiro arremesso.

Essas linhas dividem a área de amostra em quatro quadrantes, que são amostrados novamente com dois novos arremessos dos quadrados a uma distância de 15 m do ponto central, totalizando nove subamostras por ponto amostrado (Figura 3), as quais são avaliadas em conjunto, para determinar a condição geral do piquete. Mais detalhes da metodologia podem ser obtidos em Rodrigues et al. (2022).

Inicialmente no projeto, três coletas foram programadas: duas na estação chuvosa (fevereiro/março de 2020 e 2021) e uma na estação seca (agosto/setembro de 2020) (Rodrigues et al., 2022).



**Figura 3.** Esquema amostral para a avaliação de pastagens, com exemplos de quadrados amostrais avaliados (em marrom).

Fonte: Adaptado de Rodrigues et al. (2022).

Com o advento da pandemia de Covid-19 e as restrições de movimentação impostas a partir de fevereiro de 2020, foram feitos apenas dois trabalhos de campo, ambos no fim da estação chuvosa, entre março e abril.

A primeira campanha de campo, feita entre os dias 21 de março 2022 e 8 de abril de 2023, coletou 180 pontos, 120 no estado de Mato Grosso do Sul e outros 60 no estado de São Paulo. A segunda coletou 182 amostras, 120 no estado de Mato Grosso e 62 no estado de São Paulo, resultado do limite operacional das equipes.

Em ambas as coletas de campo, as pastagens avaliadas foram classificadas em quatro níveis distintos segundo Rodrigues et al. (2022). As informações são apresentadas na Tabela 1. Para avaliar a capacidade de separação das classificações, além do conjunto de dados originais, foram criados mais dois conjuntos, baseados na junção de classes do conjunto original.

**Tabela 1.** Classes de condição de pastagens (CP) e suas características de acordo com quatro, três e dois níveis de degradação.

Grau de degradação	Descrição	Forrageira (% de área)	Invasoras (% de área)	Serrapilheira + solo (% de área)
Quatro classes CD4	Não degradada (ND)	≥ 90	0	≤ 10
	Em degradação I (ED1)	≥ 70 e < 90	> 0 e ≤ 25	> 5 e ≤ 15
	Em degradação II (ED2)	≥ 50 e < 70	> 25 e ≤ 50	> 15 e ≤ 35
	Degradada (De)	< 50	> 50	> 35
Três classes CD3	Não degradada (ND)	≥ 90	0	≤ 10
	Em degradação (ED)	≥ 50 e < 90	> 0 e ≤ 50	> 5 e ≤ 35
	Degradada (De)	< 50	> 50	> 35
Duas classes CD2	Em boas condições (EBC)	≥ 70	≤ 25	≤ 15
	Em más condições (EMC)	< 70	> 25	> 15

Fonte: Adaptado de Rodrigues et al (2022).

## Dados do sensor OLI/Landsat-8 e 9

O sensor *Operational Land Imager* (OLI), a bordo dos satélites Landsat-8 e Landsat-9, dispõe de nove bandas espectrais com resolução espacial de 15 m na banda pancromática e 30 m nas demais (USGS, 2019). Para abranger a área de estudo, foram selecionadas as cenas (ponto-órbita) que cobrem a área de estudo em São Paulo (apenas a cena 220-075) e Mato Grosso do Sul (223-075, 224-073, 224-074, 224-075, 225-072, 225-073 e 225-074), em reflectância de superfície. Uma vez que não foi encontrada uma única cena cuja condição de observação fosse completamente livre de nuvens e de data próxima à realização das duas campanhas de campo, foram adquiridas todas as cenas que contassem com pelo menos parte da imagem com céu limpo e que estivessem no intervalo de 120 dias antes ou após o início das coletas dos dados de campo. A partir dessas imagens, uma nova imagem foi gerada pela seleção, pixel a pixel, do valor de reflectância mais próximo da data do trabalho de campo (2 de abril de 2022 ou 25 de março de 2023) e com melhor qualidade (ausência de cobertura de nuvem ou sombra) segundo a banda de qualidade.

Portanto, conforme a Tabela 2, para a cena 220–075, que cobre a área de estudo no estado de São Paulo, em 2023, foram selecionados dados prioritariamente de 20/3/2023 (cinco dias de diferença). Entretanto, quando o valor do pixel  $P_{i,j}$  estava sinalizado com cobertura de nuvens ou sombra na banda de qualidade, buscou-se então o valor de  $P_{i,j}$  da imagem de 5/4/2023 (11 dias de diferença).

**Tabela 2.** Data das cenas originais, diferença em dias da data central dos levantamentos de campo e porcentagem da cena usada para a geração da imagem sintética.

Ponto-órbita	Data	2022 Dias	% da cena	Data	2023 Dias	% da cena
220–075	10/4/2022	8	91,5	20/3/2023	3	54,7
	18/4/2022	16	7,9	5/4/2023	13	41,7
	26/4/2022	24	0,4	13/4/2023	21	2,9
	27/12/2021	96	0,1	21/4/2023	29	0,8
	3/12/2021	120	0,1			
223–075	22/3/2022	11	91,1	25/3/2023	2	93,6
	15/4/2022	13	7,7	2/4/2023	10	6,0
	6/3/2022	27	1,0	9/3/2023	14	0,3
	1/1/2022	91	0,2	10/4/2023	18	0,1
	8/12/2021	115	<0,1			
	26/2/2022	35	<0,1			
	9/1/2022	83	<0,1			
224–073	6/4/2022	4	94,5	24/3/2023	1	28,4
	29/3/2022	4	3,6	1/4/2023	9	20,2
	22/4/2022	20	1,0	8/3/2023	15	17,5
	25/2/2022	36	0,7	16/3/2023	7	16,0
	17/2/2022	44	0,1	17/4/2023	25	9,1
	5/3/2022	28	<0,1	9/4/2023	17	8,8
	9/2/2022	52	<0,1			
223–075	22/3/2022	11	91,1	25/3/2023	2	93,6
	15/4/2022	13	7,7	2/4/2023	10	6,0
	6/3/2022	27	1,0	9/3/2023	14	0,3
	1/1/2022	91	0,2	10/4/2023	18	0,1
	8/12/2021	115	<0,1			
	26/2/2022	35	<0,1			
	9/1/2022	83	<0,1			
224–074				24/3/2023	1	49,0
				1/4/2023	9	44,7
	6/4/2022	4	100	8/3/2023	15	5,5
				17/4/2023	25	0,5
				9/4/2023	17	0,3

continua...

**Tabela 2.** Continuação.

Ponto-órbita	Data	2022 Dias	% da cena	Data	2023 Dias	% da cena
224-075	6/4/2022	4	95,1	24/3/2023	1	67,0
	29/3/2022	4	2,5	1/4/2023	9	32,9
	21/3/2022	12	0,1	17/4/2023	25	0,1
	22/4/2022	20	1,8	8/3/2023	15	< 0,1
	5/3/2022	28	<0,1			
	17/2/2022	44	0,5			
	9/2/2022	52	<0,1			
225-072	5/4/2022	3	98,6	23/3/2023	0	68,2
	28/3/2022	5	1,3	31/3/2023	8	31,8
	21/4/2022	19	< 0,1			
225-073	5/4/2022	3	98,7	23/3/2023	0	93,9
	28/3/2022	5	1,3	31/3/2023	8	5,1
				27/2/2023	24	1,0
225-074	5/4/2022	3	99,1	31/3/2023	8	95,0
	21/4/2022	19	0,9	27/2/2023	24	5,0

Entretanto, se nesta última  $P_{i,j}$  ainda estava com cobertura de nuvens, adquiriu-se o valor da terceira imagem, distante temporalmente 27 dias (21/4/2023). Dessa forma, conseguiu-se uma imagem que é fruto das melhores condições de aquisição e o mais próximo possível da data de interesse, de modo análogo ao obtido pelo produto MYD09Q1 do sensor Modis, a bordo dos satélites Terra/Aqua (Vermote et al., 2015).

No processo de classificação, apesar da importância das bandas espectrais, os índices espectrais constituem uma importante ferramenta discriminatória da informação, uma vez que, segundo Mingoti (2005), os índices sintetizam, em uma única variável, diversas medidas sobre um fenômeno multivariado. Os índices espectrais exploram comportamentos diferenciados dos alvos em bandas espectrais distintas, a fim de evidenciá-los (Ponzoni; Shimabukuro, 2009).

No caso específico da vegetação, seu comportamento espectral é regulado pela maior absorção na região do visível, principalmente nas regiões do azul e do vermelho, resultado da presença da clorofila nas folhas, de maior reflectância na região do infravermelho próximo (IVP), resultado da estrutura celular das folhas (em especial da lignina e da celulose) e uma absorção pela presença de água na região do infravermelho de ondas curtas (Ivoc) (Ponzoni; Shimabukuro, 2009).



Os índices espectrais *Normalized Difference Vegetation Index* (NDVI) e *Green Normalized Difference Vegetation Index* (GNDVI), que fazem uso da diferença nas respostas espectrais da vegetação nas regiões do infravermelho, do vermelho e do verde, respectivamente, para indicar maior ou menor exuberância da vegetação (Gitelson et al., 1996; Rouse et al., 1973). Outros autores utilizaram-se dessa mesma lógica, mas amenizando as limitações do NDVI, como é o caso do *Soil Adjusted Vegetation Index* (SAVI), que utiliza um fator de correção (chamada de linha do solo) para corrigir a influência do solo (Huete, 1988), o *Atmospherically Resistant Vegetation Index* (ARVI) que, tal como o SAVI, emprega fatores de correção para minimizar a interferência da atmosfera (Kaufman; Tanré, 1992), e o *Enhanced Vegetation Index* (EVI), que utiliza a banda do azul para corrigir a influência da atmosfera (Huete et al., 1997).

Outros índices utilizam-se da absorção da energia eletromagnética das bandas do infravermelho de ondas curtas da água nas folhas, para destacar estresse hídrico. O *Moisture Stress Index* (MSI) e o *Normalized Difference Moisture Index* (NDMI) fazem uso da diferença entre as bandas do Ivoc e o IVP. Quanto maior for a sua distância relativa, maior será o conteúdo de estrutura celular e de água nas folhas; o primeiro índice é uma razão simples, e o segundo, uma diferença normalizada (Hunt Junior; Rock, 1989; Jin; Sader, 2005). Dessa forma, partir das imagens sintéticas, foram calculados nove índices espectrais, conforme a Tabela 3.

**Tabela 3.** Índices espectrais com suas respectivas fórmulas e referências. As variáveis b2, b3, b4, b5 e b6 e b7 correspondem às bandas espectrais do sensor OLI.

Índice	Fórmula	Referência
ARVI <sup>(1)</sup>	$(b5 - (2 * b4) + b2) / (b5 + (2 * b4) + b2)$	Kaufman; Tanré (1992)
AVI <sup>(2)</sup>	$(b5 * (1 - b4) * (b5 - b4))^{1/3}$	Rikimaru et al. (2002)
BSI <sup>(3)</sup>	$(b6 + b4) - (b5 + b2) / (b6 + b4) + (b5 + b2)$	Rikimaru et al. (2002)
EVI <sup>(4)</sup>	$2.5 * ((b5 - b4) / (b5 + 6 * b4 - 7.5 * b2 + 1))$	Huete et al. (1997)
GNDVI <sup>(5)</sup>	$(b5 - b3) / (b5 + b3)$	Gitelson et al. (1996)
MSI <sup>(6)</sup>	$b6 / b5$	Hunt Junior; Rock (1989)
NDMI <sup>(7)</sup>	$(b5 - b6) / (b5 + b6)$	Jin; Sader (2005)
NDVI <sup>(8)</sup>	$(b5 - b4) / (b5 + b4)$	Rouse et al. (1973)
SAVI <sup>(9)</sup>	$((b5 - b4) / (b5 + b4 + 0.5)) * (1.5)$	Huete (1988)

<sup>(1)</sup>Atmospherically Resistant Vegetation Index; <sup>(2)</sup>Advanced Vegetation Index; <sup>(3)</sup>Bare Soil Index; <sup>(4)</sup>Enhanced Vegetation Index; <sup>(5)</sup>Green Normalized Difference Vegetation Index; <sup>(6)</sup>Moisture Stress Index; <sup>(7)</sup>Normalized Difference Moisture Index; <sup>(8)</sup>Normalized Difference Vegetation Index; <sup>(9)</sup>Soil Adjusted Vegetation Index.

## Segmentação, métricas de pastagens e classificadores

Diversos autores reportaram a superioridade da abordagem baseada em objetos em relação à abordagem pixel-a-pixel para contextos complexos, como áreas urbanas e imagens de alta resolução (Hussain et al., 2013; Franca et al., 2015; Martins et al., 2020). Uma vez que se trata de um polígono que abarca diversos pixels, é possível obter medidas que vão além do valor absoluto do pixel (como reflectância, por exemplo). Esses valores, denominados de métricas, auxiliam os classificadores, ao ofertar novas dimensões para os dados, como o desvio-padrão, que pode ser interpretado como rugosidade da imagem naquele polígono. Tal como no trabalho de Martins et al. (2020), para extrair as métricas relativas ao comportamento espectral das pastagens, foi feita a segmentação das cenas a partir da composição colorida das bandas do vermelho, do IVP e do Ivoc para os anos de 2022 e 2023, utilizando o algoritmo *Mean Shift* não supervisionado e não paramétrico, que usa uma janela móvel para avaliar e calcular um valor médio e determinar qual pixel deve ser ou não ser incluído em cada segmento (Zhou et al., 2015). Apesar de ser essencialmente não paramétrico, no caso de dados espaciais ele se utiliza de parâmetros quanto ao detalhe espectral, detalhe espacial e tamanho mínimo do segmento (Zhou et al., 2015).

A fim de definir os melhores parâmetros para a segmentação, diversos valores foram testados, e a melhor combinação foi a de 20 para o detalhe espectral e 25 para o detalhe espacial, conforme trabalho realizado por Souza et al. (2023), que testaram diversos parâmetros visando à segmentação de áreas de pastagens na área de estudo e estabeleceram métricas de qualidade de segmentação. A segmentação foi feita somente nas áreas definidas como pastagens no mapa das pastagens do Brasil, produzido pelo Laboratório de Processamento de Imagens e Geoprocessamento (Lapig) para o ano de 2021 (Lapig, 2021). A partir dos segmentos gerados (áreas de pastagens), foram extraídas métricas baseadas na estatística descritiva — média, mediana, desvio-padrão, valores mínimo e máximo, amplitude, valores do primeiro e terceiro quartil — para cada uma das seis bandas espectrais consideradas e dos nove índices calculados.

Para classificar os dados, seis classificadores distintos foram testados utilizando o Orange Data Mining, um software baseado em componentes e que utiliza bibliotecas em Python para fazer o processamento.

O primeiro e mais simples deles é chamado de *k-Nearest Neighbors* (kNN) e baseia-se na distância (que pode ser euclidiana, Manhattan, máxima e Mahalanobis) entre o conjunto de dados de treinamento e o dado a ser classificado, procurando o valor mais próximo entre eles, de acordo com um número máximo de vizinhos (Fix; Hodges, 1951). Para este trabalho foram calculadas as distâncias euclidianas entre cinco vizinhos. Outro classificador testado foi o de redes neurais (NN), baseado na biologia do sistema nervoso, que é uma abordagem não paramétrica capaz de lidar com sistemas não lineares complexos; o *multilayer perceptron* é uma variação amplamente utilizado em aplicações de sensoriamento remoto (Hu; Weng, 2009; Mishra; Rai, 2016).

O algoritmo *Support Vector Machine* (SVM) é um classificador supervisionado que tem sido amplamente utilizado em aplicações de sensoriamento remoto atualmente, uma vez que tem a habilidade de aprender bem, mesmo com número limitado de amostras (Mountrakis et al., 2011). Como o SVM, o *Random Forest* (RF) é um algoritmo de aprendizado de máquina que foi introduzido no sensoriamento remoto na última década, e usa como base a combinação de árvores de decisão geradas por meio de um vetor aleatório (Breiman, 2001; Lary et al., 2016). Precursor do RF, o algoritmo *Tree* baseia-se na construção de uma árvore de decisão na qual os nós são baseados na classe de pureza da métrica avaliada, isto é, na separabilidade do dado de entrada em classes (Jiang et al., 2010). Outro algoritmo testado foi o *Adaptive boosting* (AdaBoost ou AB), um método de classificação e de incremento da acurácia de outros algoritmos de aprendizado de máquina (Freund; Schapire, 1999). Neste trabalho, o AdaBoost foi utilizado de duas formas: de maneira isolada, classificando diretamente os dados; e associado com o *Random Forest* (AB+RF) e com o *Support Vector Machine* (AB+SVM).

Para a classificação dos dados, foi adotado um conjunto de estratégias de classificação, conforme a Tabela 4. As métricas foram separadas naquelas que utilizaram apenas as bandas espectrais (BE), apenas índices de espectrais (IE) e aquela que utilizou todo o conjunto de métricas (BE+IE). Para cada conjunto de dados e em cada classificador, os dados de campo foram separados em dois grupos: o primeiro, de treinamento, com cerca de 66% das amostras; e outro de validação, com 34% das amostras restantes. Essa seleção é feita de maneira aleatória, mas estratificada para as classes de condição de pastagens, e é repetida 20 vezes.

**Tabela 4.** Acurácia de classificação de acordo com o nível de classes de pastagens, o conjunto de dados e o algoritmo de classificação utilizados.

Classes de pastagens	Conjunto de dados	AB	RF	AB + RF	SVM	AB + SVM	kNN	NN	Tree
CD4	BE	0,391	0,484	0,486 <sup>(1)</sup>	0,398	0,382	0,325	0,362	0,388
	IE	0,389	0,422	0,415	0,418	0,389	0,396	0,448	0,372
	BE+IE	0,383	0,449	0,468	0,438	0,211	0,368	0,433	0,377
CD3	BE	0,588	0,709 <sup>(2)</sup>	0,707	0,681	0,683	0,604	0,620	0,589
	IE	0,587	0,690	0,697	0,697	0,683	0,674	0,704	0,596
CD2	BE+IE	0,577	0,701	0,705	0,696	0,683	0,635	0,685	0,608
	BE	0,628	0,709	0,711	0,668	0,650	0,622	0,616	0,625
	IE	0,646	0,714	0,713	0,693	0,609	0,675	0,706	0,637
	BE+IE	0,628	0,725	0,726 <sup>(3)</sup>	0,705	0,650	0,624	0,672	0,638

<sup>(1)</sup>/<sup>(2)</sup>/<sup>(3)</sup>Correspondem, respectivamente, à melhor acurácia para 4, 3 e 2 classes de pastagens.

Além da classificação, foram também gerados mapas de confiança do classificador, que indicam o grau de convicção na separação de cada segmento em uma classe distinta, e não deve ser confundida com precisão ou acurácia de classificação, pois a classificação pode estar errada mesmo nas áreas de elevada confiança (mais próximas a 1). Uma vez que a confiança do classificador é dada para todas as classes em análise, a soma dos valores de todas as classes é igual a 1. Dessa forma, a classificação com menor número de classes apresenta valores absolutos de confiança normalmente maiores, por apresentar menor número de alternativas para o classificador, ficando o valor mínimo da confiança em torno de  $1/n$ , em que  $n$  é o número de classes. Para algoritmos baseados em clusters, a confiança baseia-se na distância euclidiana entre os pontos centrais dos clusters e os valores submetidos à classificação. Para os algoritmos como RF, a confiança baseia-se no número de votos obtidos pelas árvores de decisão. Para SVM, a confiança é dada pela distância do teste e o limite da decisão, por meio da regressão logística.

Para comparação dos mapas, os valores de confiança foram normalizados por meio do método Max-Min, com valores variando entre 0 e 1, utilizando a função da Equação 1, na qual  $Vn$  corresponde ao valor normalizado,  $v$  é o valor absoluto da confiança,  $v_{\min}$  é o valor mínimo possível com aquele número de classes, e  $v_{\max}$  é o valor máximo possível.


$$Vn = \frac{(v - v_{\min})}{(v_{\max} - v_{\min})} \quad (1)$$

## Resultados e discussão

---

A partir dos dados de campo e das imagens do sensor OLI obtidas o mais próximo possível, obteve-se o comportamento espectral das classes de condição das pastagens para toda a área de estudo, conforme a Figura 4.

Como é possível observar, as pastagens seguem o comportamento esperado para alvos vegetados, com baixa reflectância na região do visível (bandas do azul, verde e vermelho), alta reflectância na região do infravermelho próximo e redução na reflectância na região do infravermelho de ondas curtas.



**Figura 4.** Comportamento espectral de classes degradação das pastagens (CD) — não degradada (ND), em degradação I (ED1), em degradação II (ED2) e degradada (De) —, gerado nas faixas do azul, verde, vermelho, infravermelho próximo (IVP) e infravermelho de ondas curtas (Ivoc), usando dados do sensor OLI nos anos de 2022 e 2023.

Também conforme esperado, a reflectância na região do visível é maior para as pastagens em piores condições (Ponzoni; Shimabukuro, 2009). No IVP, embora as médias estejam bastante próximas, a classe ND conservou baixa variabilidade, em virtude de sua maior homogeneidade, enquanto, nas áreas com alguma degradação, a exposição de parte do solo com presença de espécies invasoras arbustivas aumentou a variabilidade dentro do segmento.

Quando comparadas as métricas de bandas espectrais entre as duas áreas de estudo, observam-se valores diferentes estatisticamente segundo o teste U de Mann-Whitney (10%) para as bandas do azul (p-valor = 0,015), verde (p-valor = 0,041), Ivoc I (p-valor = 0,052) e Ivoc II (p-valor = 0,094), com todos os valores médios menores para o estado de São Paulo no ano de 2023.

Métricas das bandas espectrais e de índices espectrais e o conjunto de classes de degradação foram inseridos nos oito algoritmos de classificação. Na Tabela 4, observa-se a classificação de cada combinação e baixos valores de acurácia (inferiores a 0,5) para quatro classes de degradação de pastagens. As melhores pontuações foram obtidas para três classes e a melhor foi atingida com duas classes e o uso do AB associado ao RF (0,726 de acurácia de classificação), tal como obtiveram Jakimow et al. (2018) ao estudar manejo de pastagens na Amazônia Brasileira.

Ainda na Tabela 4, apesar de a associação entre bandas e índices espectrais obter menores valores, foi nessa configuração que os dois melhores resultados foram obtidos. Outro ponto que merece destaque é o fato de o AB não conseguir melhorar o desempenho do SVM, piorando, na maioria dos casos, seus resultados. Quando associado ao RF, por sua vez, o AB melhora a acurácia, muito embora não de maneira expressiva, uma vez que o classificador RF alcança bons resultados individualmente.

Para detalhar os resultados, a melhor classificação de nível de classes de pastagens foi explicitada. A Tabela 5 traz a matriz de confusão para a melhor classificação (0,486 de acurácia de classificação) para quatro níveis de condições das pastagens.

Nota-se que a classe "pastagem degradada" apresenta elevada confusão com a classe "em degradação II", ambas com praticamente a mesma quantidade de acertos. Para a classe "não degradada", o classificador acertou muito pouco, confundindo-se muito com a classe "em degradação I".

**Tabela 5.** Matriz de confusão para CD4 utilizando bandas espectrais com AB+RF, com os valores de acurácia do usuário (AU) e acurácia do produtor (AP).

		Classificado				$\Sigma$	AU
		De	ED1	ED2	ND		
Referência	De	281	139	228	12	660	42,5%
	ED1	140	286	246	68	740	38,6%
	ED2	271	243	385	41	940	40,9%
	ND	17	58	34	11	120	9,2%
	$\Sigma$	709	726	893	132	2.460	
	AP	39,6%	39,4%	43,1%	8,3%		

A confusão entre as classes em degradação (I e II) é significativa, o que mostra a incapacidade dos classificadores (em especial do AB associado com o RF) em separar estas duas classes.

Já a Tabela 6 mostra a classificação das bandas espectrais utilizando o RF para três níveis de degradação de pastagens que, de maneira semelhante à classificação com quatro níveis, apresentou elevada confusão entre os extremos (ND e De) com o nível intermediário (ED). Os valores de acurácia (do usuário e do produtor) são menores que os encontrados por Santos et al. (2022), que também utilizaram três níveis de degradação (ausente, intermediário e severo). A Tabela 7, por sua vez, mostra a classificação com apenas dois níveis de pastagens utilizando um conjunto completo de métricas (bandas e índices de espectrais) por meio do AB+RF.

**Tabela 6.** Matriz de confusão para CD4 utilizando bandas espectrais com RF.

		Classificado			$\Sigma$	AU
		De	ED	ND		
Referência	De	259	380	20	660	39,2%
	ED1	434	1.134	112	1.680	67,5%
	ND	19	86	15	120	12,5%
	$\Sigma$	712	1.601	147	2.460	
	AP	36,4%	70,9%	10,2%		



**Tabela 7.** Matriz de confusão para CP4 utilizando bandas espectrais e índices espectrais com AB+RF.

		Classificado			
		EBC	EMC	$\Sigma$	AU
Referência	EBC	259	380	660	39,2%
	EMC	434	1.135	1.680	67,6%
	$\Sigma$	712	1.601	2.460	
	AP	36,4%	70,9%		

Apesar de a quantidade total de pontos ser compatível com outros trabalhos na área de degradação de pastagens em extensões territoriais semelhantes (Aguiar et al., 2010, 2017), o número baixo de pontos na classe não degradada (apenas 18 pontos nas duas áreas de estudo ou 4% do total) pode ter contribuído para sua baixa acurácia e pouca representatividade nos mapas finais.

A Figura 5 (Apêndice A) mostra a distribuição da confiança da classificação. É possível notar que as classificações com quatro e duas classes apresentam baixa confiança, o que significa que o algoritmo teve maior dúvida em separar cada polígono em uma classe. Esse comportamento é esperado, em certa medida, uma vez que a redução no número de classes aumenta os valores mínimos de confiança, que são de 25% para quatro classes, 33% para três classes e 50% para duas classes e correspondem à probabilidade de escolha de um classificador aleatório. A classificação com três classes, por sua vez, apresentou maior valor de confiança, embora tenham predominado valores abaixo de 0,5. Também não existem diferenças significativas entre a confiança do classificador e as duas áreas de estudo nos estados, uma vez que ambas as áreas comportam-se da mesma maneira. No trabalho de Silveira et al. (2018) com mapeamento de Caatinga, a abordagem monotemporal (apenas no período úmido) apresentou confiança menor de classificação que a abordagem multitemporal, uma vez que aumenta o escopo dos dados, com características e comportamentos espectrais muitas vezes ocultadas pelo vigor vegetativo do ambiente, como resiliência.

Por fim, a Figura 6 (Apêndice B) mostra os mapas com quatro, três e dois níveis de condições de pastagens das duas áreas de estudos, ao passo que a Tabela 8 mostra as áreas ocupadas por classe em cada mapa.

Como é possível ver em ambas, as classes ND ocuparam uma porção ínfima de área. Santos et al. (2022), estudando todo o Brasil, encontraram uma área sem degradação ocupando mais de um quarto da área de estudo em 2018, embora as piores áreas encontradas por esses autores tenham elevada concentração na área de estudo localizada em Mato Grosso do Sul. Para os mesmos autores, o nível de degradação de pastagens diminuiu entre o período de 2010 e 2018. Neste aspecto, oferta de crédito agrícola para a modalidade de pastagens (entre investimentos, custeios e comercialização) entre 2013 e 2018 foi de cerca de 20 bilhões de reais (corrigidos para janeiro de 2023), enquanto, entre os anos de 2018 e 2023, o total financiado para pastagens foi cerca de 8 bilhões de reais, mostrando um retraimento na oferta de crédito para reforma e manejo das pastagens (Banco Central do Brasil, 2023).

Em outro trabalho, também no bioma Cerrado (estado de Goiás) e utilizando quatro níveis de degradação de pastagens, Gosch et al. (2021) detectaram um total de 78% de pastagens com algum grau de degradação em 2017, bem abaixo do encontrado neste trabalho para a mesma quantidade de classes e muito diferente do encontrado por Andrade et al. (2014) para o ano de 2014.

Outro ponto que merece ser considerado é o impacto da segmentação no resultado de classificação. Embora Souza et al. (2023) tenham medido a qualidade da segmentação na mesma área e com os mesmos objetivos deste trabalho, pouco se pode afirmar sobre a adequabilidade dos parâmetros da segmentação na separação das classes de degradação de pastagens, principalmente no caso da ocorrência de variações dentro de um mesmo piquete. Testes com diferentes parâmetros de segmentação podem auxiliar na melhora da classificação, ao oferecer métricas mais assertivas para a classificação. A incorporação de outros sistemas sensores, como o MSI/Sentinel-2, também pode auxiliar na melhora dos índices de mapeamento, ao oferecer respostas espectrais em bandas com elevada correlação com processos biológicos da vegetação, como é o caso da região do *red-edge* (Clevers; Gitelson, 2013; Gitelson et al., 2002), além de análises no período seco, que mostram as diferentes características da vegetação diante do período de senescência por estresse hídrico, tal como no trabalho de Silveira et al. (2018).

**Tabela 8.** Áreas ocupadas (ha) das classes de degradação de pastagens para as áreas de estudo de Mato Grosso do Sul e São Paulo. Os valores entre parênteses correspondem à porcentagem da área em relação à área de estudo no estado.

Classe de pastagem	Classe	Mato Grosso do Sul	São Paulo	Total
	ND	101 (< 0,1)	7 (< 0,1)	108 (< 0,1)
CD4	ED1	2.156.030 (47,7)	201.659 (70,6)	2.357.689 (49,1)
	ED2	2.173.386 (48,1)	84.089 (29,4)	2.257.476 (47,0)
	De	190.676 (4,2)	–	190.676 (4)
CD3	ND	35.525 (0,8)	24.819 (8,7)	60.344 (1,3)
	ED	4.402.131 (97,4)	249.722 (87,4)	4.651.854 (96,8)
	De	82.537 (1,8)	11.214 (3,9)	93.751 (2)
CD2	EBC	3.724.461 (82,4)	257.366 (90,1)	3.981.827 (82,9)
	EMC	795.733 (17,6)	28.389 (9,9)	824.122 (17,1)

## Conclusões

Com base nos resultados obtidos, conclui-se que o grande número de métricas não contribui necessariamente com a melhoria dos resultados de classificação usando dados do sensor OLI/Landsat-8 e 9, e que uma análise acerca do impacto de como usar a segmentação no processo de classificação é necessária em estudos futuros.

Além disso, conclui-se que a metodologia aqui empregada, por seus baixos scores de acurácia, não foi satisfatória para o mapeamento de degradação de pastagens plantadas no bioma Cerrado, embora permita a escolha das melhores métricas de classificação. Nesse caso, o limitado número de pontos amostrais qualificados em um dos níveis de condição da pastagem (não degradada) pode ter influenciado no baixo desempenho dos classificadores. Assim, para trabalhos futuros, recomenda-se um número maior de pontos qualificados da condição da pastagem coletados nas estações seca e chuvosa.

## Agradecimentos

---

À Embrapa, pelos recursos para a execução deste projeto (Projeto SEG nº 10.18.03.062.00.00). A Letícia Vanzella Castro (Prefeitura de Alcinoópolis, MS), Luís Carlos Pereira Ramos (Agência de Desenvolvimento Agrário e Extensão Rural, Agraer/MS) e Pascoal Rezende França (Agraer/MS), pela assistência nos trabalhos de campo. E aos bolsistas Izabela Chiarato de Souza, Vinicius Tauan Cassaniga e Thaís Nasato Fioravanti, pelo auxílio nas atividades rotineiras do projeto.

## Referências

---

- AGUIAR, D. A.; ADAMI, M.; SILVA, W. F.; RUDORFF, B. F. T.; MELLO, M. P.; SILVA, J. dos S. V. da. MODIS time series to assess pasture land. **International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 2123–2126, 2010. DOI: 10.1109/IGARSS.2010.5649388.
- AGUIAR, D. A.; MELLO, M. P.; NOGUEIRA, S. F.; GONÇALVES, F. G.; ADAMI, M.; RUDORFF, B. F. T. MODIS time series to detect anthropogenic interventions and degradation processes in tropical pasture. **Remote Sensing**, v. 9, n. 73, 2017.
- ANDRADE, R. G.; TEIXEIRA, A. H. de C.; SANO, E. E.; LEIVAS, J. F.; VICTORIA, D. de C.; NOGUEIRA, S. F. Pasture evapotranspiration as indicators of degradation in the Brazilian Savanna: a case study for Alto Tocantins watershed. **Remote Sensing for Agriculture, Ecosystems, and Hydrology XVI**, v. 9239, p. 92391Z, 2014.
- ARANTES, A. E.; FERREIRA, L. G.; COE, M. T. The seasonal carbon and water balances of the Cerrado environment of Brazil: Past, present, and future influences of land cover and land use. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 117, p. 66–78, 2016. DOI: <http://dx.doi.org/10.1016/j.isprsjprs.2016.02.008>.
- BANCO CENTRAL DO BRASIL. **Matriz de Dados do Crédito Rural**. 2023. Disponível em: <https://www.bcb.gov.br/estabilidadefinanceira/micrrural>. Acesso em: 21 ago. 2023.
- BARONA, E.; RAMANKUTTY, N.; HYMAN, G.; COOMES, O. T. The role of pasture and soybean in deforestation of the Brazilian Amazon. **Environmental Research Letters**, v. 5, n. 2, 2010.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.
- CEMADEN. Centro Nacional de Monitoramento e Alertas de Desastres Naturais. **Mapa Interativo da Rede Observacional para Monitoramento de Risco de Desastres Naturais**. 2023. Disponível em: <http://www2.cemaden.gov.br/mapainterativo/#>. Acesso em: 27 ago. 2023.
- CEMTEC. Centro de Monitoramento do Tempo e do Clima de Mato Grosso do Sul. **Banco de dados**. 2023. Disponível em: <https://www.cemtec.ms.gov.br/bancodedados/>. Acesso em: 25 ago. 2023.
- CEPEA. Centro de Estudos Avançados em Economia Aplicada. **PIB do agronegócio**. Piracicaba, 2023. Disponível em: <https://cepea.esalq.usp.br/upload/kceditor/files/PIB-DO-AGRO-27JUN2023.pdf>. Acesso em: 25 ago. 2023.

- CLEVERS, J. G. P. W.; 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**, v. 23, n. 1, p. 344–351, 2013.
- FIX, E.; HODGES, J. L. **Discriminatory Analysis - Nonparametric Discrimination**: consistency properties. Randolph Field, TX:USAF School of Aviation Medicine, 1951.
- FRANCA, D. G. M.; LOTTE, R. G.; ALMEIDA, C. M. de.; SIANI, S. M. O.; KORTING, T. S.; FONSECA, L. G. M.; SILVA, L. T. da. Object-based image analysis for urban land cover classification in the city of Campinas - SP, Brazil. In: JOINT URBAN REMOTE SENSING EVENT (JURSE)., 2015, Lausanne, Switzerland. **Proceedings...** Lausane, 2015.
- FREUND, Y.; SCHAPIRE, R. E. A Short Introduction to Boosting. **Journal of Japanese Society for Artificial Intelligence**, v. 14, n. 5, p. 771–780, 1999. Disponível em: <http://arxiv.org/abs/1508.01136>. Acesso em: 25 ago. 2023.
- GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 2002.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289–298, 1996. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0034425796000727>. Acesso em: 25 ago. 2023.
- GOSCH, M. S. PARENTE, L. L.; SANTOS, C. O. dos; MESQUITA, V. V.; FERREIRA, L. G. Landsat-based assessment of the quantitative and qualitative dynamics of the pasture areas in rural settlements in the Cerrado biome, Brazil. **Applied Geography**, v. 136, nov. 2021.
- HU, X.; WENG, Q. Estimating impervious surfaces from medium spatial resolution imagery using the self-organizing map and multi-layer perceptron neural networks. **Remote Sensing of Environment**, v. 113, n. 10, p. 2089–2102, 2009. Disponível em: <http://dx.doi.org/10.1016/j.rse.2009.05.014>. Acesso em: 25 ago. 2023.
- HUETE, A. R.; LIU, H. Q.; BATCHILY, K. J. L.; VAN, W. A comparison of vegetation indices over a Global set of TM images for EO-MODIS. **Remote Sensing of Environment**, v. 59, p. 440–451, 1997.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295–309, 1988.
- HUNT JUNIOR, 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. Disponível em: <http://www.sciencedirect.com/science/article/B6V6V-489S4D3-5/2/e212c3d527f084e034818d702c55b99e>. Acesso em: 25 ago. 2023.
- HUSSAIN, M.; CHEN, D.; CHENG, A.; WEI, H.; STANLEY, D. Change detection from remotely sensed images: from pixel-based to object-based approaches. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 80, p. 91–106, 2013. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2013.03.006>. Acesso em: 25 ago. 2023.
- IBGE. **Tabela 3939 - Efetivo dos rebanhos, por tipo de rebanho**. Rio de Janeiro, 2021. Disponível em: <https://sidra.ibge.gov.br/tabela/3939>. Acesso em: 8 out. 2021.
- INMET. **Banco de Dados Meteorológicos**. 2023. Disponível em: <https://bdmep.inmet.gov.br/>. Acesso em: 28 ago. 2023.
- JAKIMOW, B.; GRIFFITHS, P.; LINDEN, S. van der.; HOSTERT, P. Mapping pasture management in the Brazilian Amazon from dense Landsat time series. **Remote Sensing of Environment**, v. 205, p. 453–468, 2018.

- JIANG, L.; WANG, W.; YANG, X. Classification methods of remote sensing image based on decision tree technologies. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMPUTING TECHNOLOGIES IN AGRICULTURE, 2010. **Proceedings...** Nanchang, China, 2010. p. 353–358. Disponível em: [https://link.springer.com/content/pdf/10.1007%2F978-3-642-18333-1\\_41.pdf](https://link.springer.com/content/pdf/10.1007%2F978-3-642-18333-1_41.pdf). Acesso em: 28 ago. 2023.
- JIN, S.; SADER, S. A. Comparison of time series tasseled cap wetness and the Normalized Difference Moisture Index in detecting forest disturbances. **Remote Sensing of Environment**, v. 94, n. 3, p. 364–372, 2005.
- KAUFMAN, Y. J.; TANRÉ, D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261–270, 1992.
- LAPIG. **Mapa de pastagens do Brasil**. 2021. Disponível em: <https://atlasdaspastagens.ufg.br/map>. Acesso em: 15 jan. 2023.
- LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3–10, 2016. Disponível em: <http://dx.doi.org/10.1016/j.gsf.2015.07.003>. Acesso em: 15 jan. 2023.
- LI, M.; ZANG, S.; ZHANG, B.; LI, S.; WU, C. A review of remote sensing image classification techniques: The role of Spatio-contextual information. **European Journal of Remote Sensing**, v. 47, n. 1, p. 389–411, 2014.
- MAPBIOMAS. **Plataforma Mapbiomas uso e cobertura Brasil**. 2023. Disponível em: <https://plataforma.brasil.mapbiomas.org/>. Acesso em: 24 ago. 2023.
- MARTINS, V. S.; KALEITA, A. L.; GELDER, B. K.; SILVEIRA, H. L.F. da; ABE, C. A. Exploring multiscale object-based convolutional neural network (multi-OCNN) for remote sensing image classification at high spatial resolution. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 168, p. 56–73, 2020. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.08.004>. Acesso em: 24 ago. 2023.
- MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem prática**. Belo Horizonte: Editora UFMG, 2005.
- MISHRA, V. N.; RAI, P. K. A remote sensing aided multi-layer perceptron-Markov chain analysis for land use and land cover change prediction in Patna district (Bihar), India. **Arabian Journal of Geosciences**, v. 9, n. 4, 2016. Disponível em: <http://dx.doi.org/10.1007/s12517-015-2138-3>. Acesso em: 24 ago. 2023.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247–259, 2011. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2010.11.001>. Acesso em: 24 ago. 2023.
- PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. 2. ed. São José dos Campos: Parêntese, 2009.
- RIKIMARU, A.; ROY, P. S.; MIYATAKE, S. Tropical forest cover density mapping. **Tropical Ecology**, v. 43, n. 1, p. 39–47, 2002.
- RINGROSE, S. Use of Landsat thematic mapper data to assess seasonal rangeland changes in the Southeast Kalahari, Botswana. **Environmental Management**, v. 23, n. 1, p. 125–138, 1999. Disponível em: <http://link.springer.com/10.1007/s002679900173>. Acesso em: 24 ago. 2023.
- RODRIGUES, C. A. G. **Banco de dados: primeiros resultados da S11 do projeto GeoPastoCerrado (geopackage)**. 2022. Disponível em: <https://geoinfo.cnpm.embrapa.br/documents/6254>. Acesso em: 1 jan. 2023.

RODRIGUES, C. A. G.; QUEIROZ, H. P. de; QUARTAROLI, C. F. **Avaliação em campo de pastagens de *Urochloa* spp. (syn. *Brachiaria* spp.) no bioma Cerrado para estimar níveis de degradação: parâmetros qualitativos.** Campinas: Embrapa Territorial, 2022. 34 p. (Embrapa Territorial. Documentos, 146). Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/doc/1152378/1/6108.pdf>. Acesso em: 1 jan. 2023.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: THIRD EARTH RESOURCES TECHNOLOGY SATELLITE (ERTS) SYMPOSIUM, 1973. **Proceedings...** 1973. p. 309–317.

SANTOS, C. O. dos; MESQUITA, V. V.; PARENTE, L. L.; PINTO, A. DE S.; FERREIRA JÚNIOR, L. G. Assessing the Wall-to-Wall Spatial and Qualitative Dynamics of the Brazilian Pasturelands 2010–2018, Based on the Analysis of the Landsat Data Archive. **Remote Sensing**, v. 14, n. 4, 2022.

SILVEIRA, H. L. F. da; GALVÃO, L. S.; SANCHES, I. D.; SÁ, I. B. DE; TAURA, T. A. Use of MSI/Sentinel-2 and airborne LiDAR data for mapping vegetation and studying the relationships with soil attributes in the Brazilian Semi-arid region. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 179–190, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243418304483>. Acesso em: 1 jan. 2023.

SMAHI, Z.; BENSALD, A. The use of Remote Sensing and GIS for pastoral activities management on a semiarid area: Integration of the socio-economic and physical data on GIS. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, PROCEEDINGS: INFORMATION FOR SUSTAINABILITY, 27., 1998. **Postboks.** Oslo, Norway: Norsk Romsenter, 1998. p. 838–841.

SOUZA, I. C. DE; SILVEIRA, H. L. F. da; RODRIGUES, C. A. G.; FRANZIN, J. P.; RONQUIM, C. C. Conformidade e adequabilidade na segmentação de imagens OLI/Landsat 8–9 para mapeamento de pastagens degradadas. In: CONGRESSO INTERINSTITUCIONAL DE INICIAÇÃO CIENTÍFICA, 17., 2023, Campinas. **Anais [...]**. Campinas: Embrapa Territorial, 2023. 11 p. CIIC 2023.

TSO, B.; MATHER, P. M. **Classification Methods for Remotely Sensed Data.** 1. ed. Boca Raton: CRC Press, 2001. E-book. Disponível em: <https://www.taylorfrancis.com/books/9781420090741>. Acesso em: 1 jan. 2023.

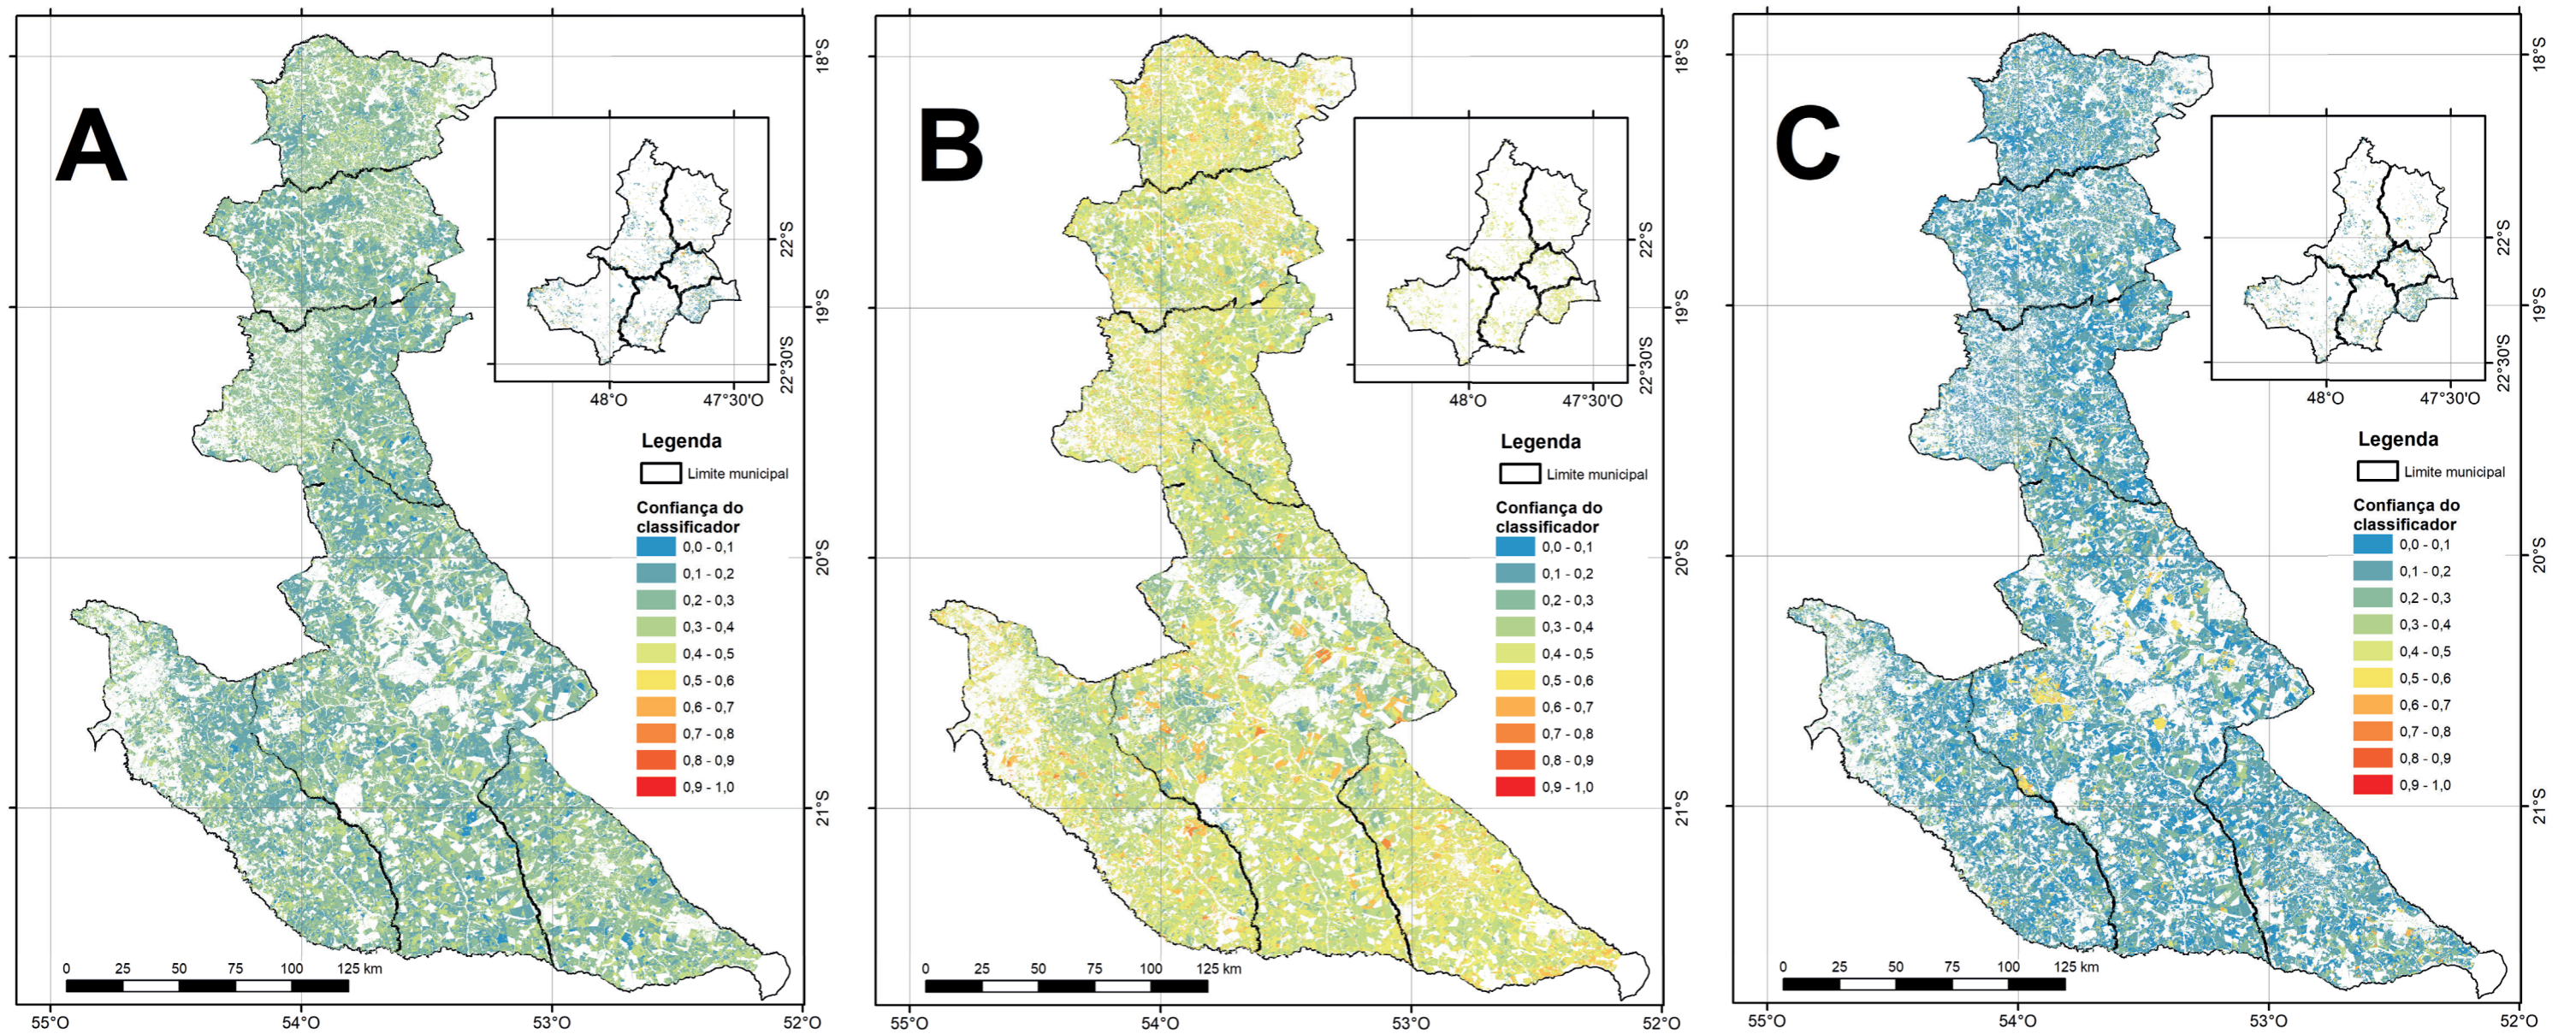
USGS. Landsat 8-9 Level 2 Science Product ( L2SP ) Guide March 2022 Landsat 8-9. **Landsat Missions**, v. 2, 2022. Disponível em: <https://www.usgs.gov/media/files/landsat-8-9-collection-2-level-2-science-product-guide>. Acesso em: 1 jan. 2023.

USGS. Landsat 8 Data Users Handbook. **Nasa**, v. 8, p. 114, 2019. Disponível em: <https://landsat.usgs.gov/documents/Landsat8DataUsersHandbook.pdf>. Acesso em: 1 jan. 2023.

VERMOTE, E. F.; ROGER, J. C.; RAY, J. P. MYD09GA MODIS/Aqua Surface Reflectance Daily L2G Global 1km and 500m SIN Grid V006. **NASA EOSDIS Land Processes DAAC**, p. 1–35, 2015.

ZHOU, J. X.; LI, Z. W.; FAN, C. Improved fast mean shift algorithm for remote sensing image segmentation. **IET Image Processing**, v. 9, n. 5, p. 389–394, 2015.

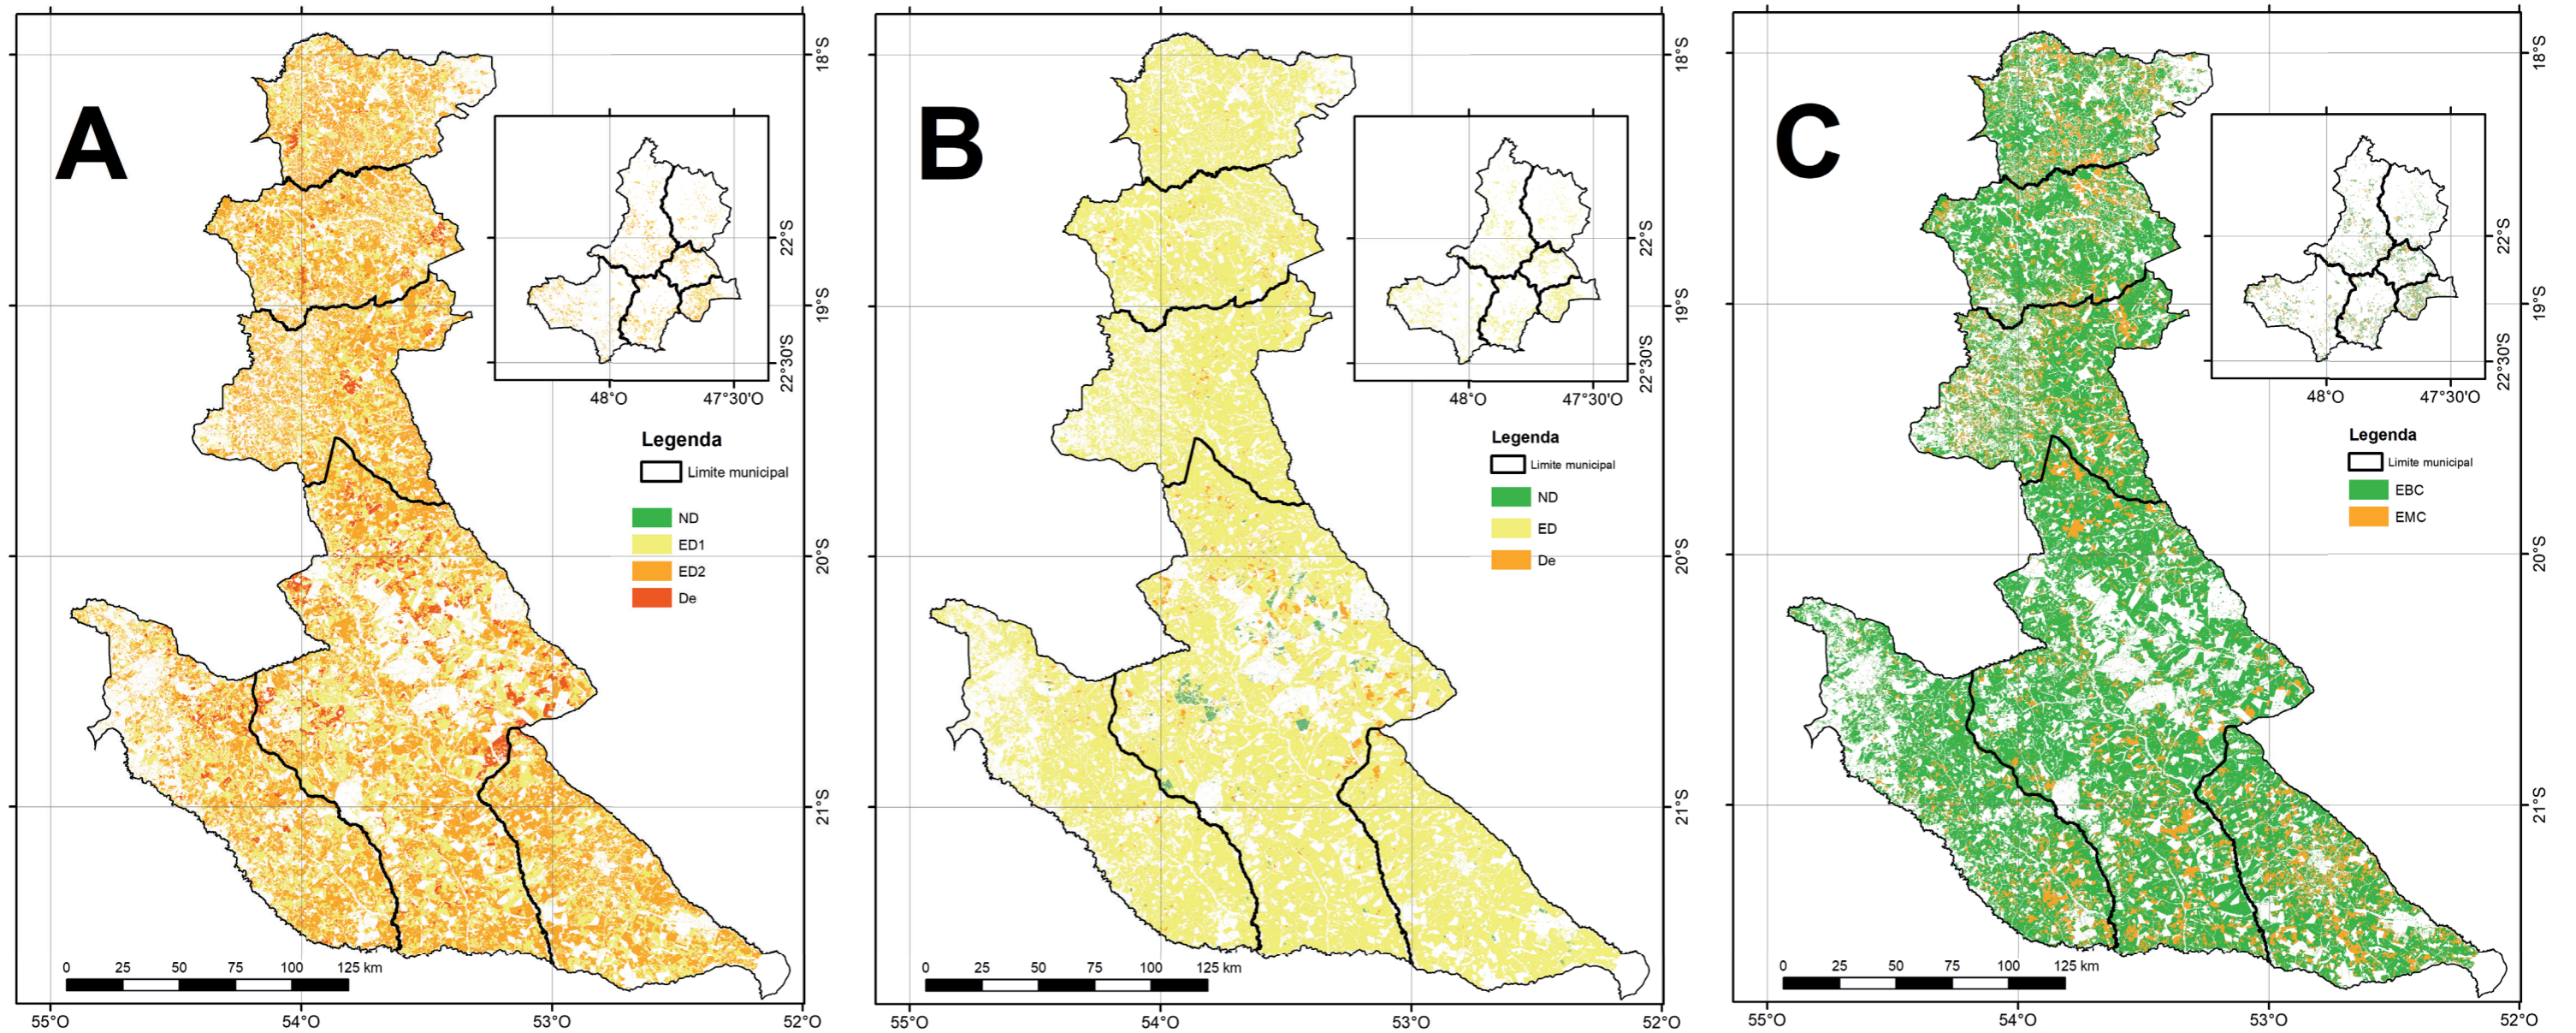
## Apêndice A



**Figura 5.** Mapa de confiança de classificação normalizada para as regiões de Mato Grosso do Sul e São Paulo (no detalhe) com (A) quatro classes de pastagens, utilizando apenas bandas espectrais classificadas com AdaBoost associado ao *Random Forest*, (B) com três classes, utilizando bandas espectrais e *Random Forest*, e (C) com duas classes de pastagens, utilizando bandas espectrais e índices de vegetação e classificadas com AdaBoost associado ao *Random Forest*.



## Apêndice B



**Figura 6.** Mapa de condições de pastagens para as regiões de Mato Grosso do Sul e São Paulo (no detalhe), no qual (A) corresponde à classificação com quatro classes de pastagens, utilizando apenas bandas espectrais classificadas com AdaBoost associado ao *Random Forest*, enquanto (C) corresponde à classificação com duas classes de pastagens, utilizando bandas espectrais e índices espectrais e classificada com AdaBoost associado ao *Random Forest*.

**Embrapa**

---

**Territorial**



MINISTÉRIO DA  
AGRICULTURA  
E PECUÁRIA

