

## Aplicação de diferentes metodologias com utilização de imagens OLI e TIRS do LANDSAT 8 para classificação da cobertura da terra em áreas do bioma Pampa – Brasil

### Application of different methodologies with the use of OLI and TIRS LANDSAT 8 images for classification of land cover in areas of the Pampa – Brazil biome

Patricia Michele Pereira Trindade<sup>1</sup>  
Daniela Wancura Barbieri Peixoto<sup>2</sup>  
Tatiana Mora Kuplich<sup>3</sup>

#### Resumo

A operacionalização de técnicas de processamento, como as classificações do uso e cobertura da terra, ainda necessita de estudos e testes para estimar suas eficácias, principalmente em função dos diferentes tipos de imagens disponíveis com foco na vegetação campestre ou não-florestal no Brasil. Este artigo teve como objetivo avaliar o desempenho de classificadores paramétricos e não-paramétricos para classificação de uso e cobertura da terra em áreas do bioma Pampa – Brasil, incluindo a comparação da utilização de bandas ópticas e termais dos sensores OLI e TIRS/Landsat 8. Assim, foram geradas 8 classificações a partir dos algoritmos Maxver, Mahalanobis, Spectral Angle Mapper (SAM) e Support Vector Machine (SVM) considerando a seguinte combinação de dados: 1 - somente bandas ópticas e 2 - combinação de bandas ópticas e termais. As classes consideradas para as classificações foram: vegetação arbórea, área de cultivo, campo, água e outros. Os classificadores paramétricos apresentaram Exatidão Global de 72% a 83%, e os não paramétricos de 66% a 80%, a classe área de cultivo foi a que apresentou maior confusão com as áreas de campo em todos os classificadores. Nas classificações SVM (somente bandas ópticas) e Maxver (bandas ópticas e termais) foram verificados os valores mais elevados de acurácia. A inclusão das imagens termais apresentou aumento de 1% a 3% na acurácia dos mapas gerados, valores que ainda devem ser superados a partir de novos testes de classificações.

**Palavras-Chave:** Imagens ópticas; Pampa; Algoritmos paramétricos; Algoritmos não paramétricos; Imagens termais.

- 1 Coordenação Espacial Sul (COESU)/Instituto Nacional de Pesquisas Espaciais (INPE). patriciatrindade.sr@gmail.com.ORCID: <https://orcid.org/0000-0002-8090-328X>
- 2 Coordenação Espacial Sul (COESU)/Instituto Nacional de Pesquisas Espaciais (INPE). daniwbarbieri@gmail.com.ORCID: <https://orcid.org/0000-0003-1853-9496>
- 3 Coordenação Espacial Sul (COESU)/Instituto Nacional de Pesquisas Espaciais (INPE). tatiana.kuplich@inpe.br.ORCID: <https://orcid.org/0000-0003-0657-4024>

## Abstract

The operationalization of processing techniques, such as the classification of usage and coverage of land, still needs studies and tests in order to estimate its efficacy, especially due to the function of different types of images available with a focus on rural or non-forest vegetation in Brazil. This essay had as its objective to assess the performance of parametric and non-parametric classifiers for the classification of usage and coverage of land in areas of the Pampa – Brazil biome, including the comparison of the use of optical and thermal bands of the OLI and TIRS/Landsat 8 sensors. Thus, 8 classifications were generated from the Maxver, Mahalanobis, Spectral Angle Mapper (SAM), and Support Vector Machine (SVM) algorithms considering the following combination of data: 1 –optical bands only, and 2 – combination of optical and thermal bands. The classes considered for classification were: arboreal vegetation, cultivation area, field, water, and others. The parametric classifiers presented Global Precision of 72% to 83%, and the non-parametric of 66% to 80%. The class of cultivation area was that which most presented confusion with the field areas in all of the classifiers. The highest rates of accuracy were ascertained in the SVM (optical bands only) and Maxver (optical and thermal bands) classifiers. The inclusion of thermal images presented a rise of 1% to 3% in the accuracy of the generated maps, values that still must be superseded through new classification tests.

**Keywords:** Optical images; Pampa; Parametric algorithms; Nonparametric algorithms; Thermal images.

## Introdução

O bioma Pampa é considerado uma das áreas de campos temperados mais importantes do mundo por sua rica biodiversidade e tradição pecuária, ocupando 63% do território do Rio Grande do Sul - Brasil, a totalidade do Uruguai e parte da Argentina. Nas últimas décadas os campos vêm sendo substituídos por cultivos agrícolas e monoculturas florestais, além das conversões devidas ao crescimento urbano. Entre as consequências dessas conversões estão a redução da biodiversidade e dos serviços ecossistêmicos prestados pelo Pampa, diminuindo também seu papel como reservatório de carbono (NABINGER et al. 2009; MMA, 2019).

O monitoramento da supressão da vegetação é essencial para conhecer o status de conservação dos biomas e planejar estratégias de manejo e preservação. O sensoriamento remoto como fonte principal de informações espectrais, espaciais e temporais, torna possível construir bases sólidas de conhecimento ambiental, tendo sido utilizado há décadas em projetos como o PRODES

(monitoramento por satélites do desmatamento por corte raso na Amazônia Legal), desenvolvido pelo INPE desde 1988 (VALERIANO et al. 2004). Os métodos do PRODES foram usados na expansão para o Monitoramento Ambiental dos Biomas Brasileiros, do Ministério do Meio Ambiente - MMA, e ainda executado pelo INPE e FUNCATE (Fundação de Ciência, Aplicações e Tecnologia Espaciais) e cujos resultados vem sendo disponibilizados na Plataforma Terrabrasilis (ASSIS et al., 2019, ALMEIDA, 2020). Mais recentemente e com métodos distintos, o projeto MapBiomas atua no mapeamento de uso e cobertura da terra dos biomas brasileiros, divulgando mapas consistentes em série temporal que inicia em 1985 (SOUZA e AZEVEDO, 2017).

Os mapas das coberturas da terra e suas dinâmicas, no Pampa e demais campos no Brasil, dão suporte a atividades de manejo ambiental e definição de prioridades de conservação, além de suprirem carências históricas de iniciativas e pesquisas com foco na vegetação campestre ou não-florestal no Brasil (OVERBECK et al. 2007, 2015). A disponibilidade de mais de 35 anos de imagens de satélite permite a construção de perfis temporais que decifram a fenologia e o status de conservação das formações campestres (PONZONI et al. 2012, MOREIRA et al. 2019).

A aplicação do SR em estudos de vegetação campestre, entretanto, na operacionalização de técnicas de processamento, como as classificações, ainda necessita de estudos e testes para estimar suas eficácias, principalmente em função dos diferentes tipos de imagens disponíveis (ópticas, termais). As abordagens tradicionais de classificação de imagens muitas vezes têm sido preteridas pelas técnicas de aprendizado de máquina (machine learning) (TALIKDAR et al. 2020), mas, para mapeamento da cobertura vegetal no Pampa, desafios ainda impõem a realização de estudos com diferentes classificadores disponíveis em programas de processamento de imagens.

Cada método de classificação apresenta suas particularidades e potencialidades, o que não torna fácil responder qual o melhor método a ser utilizado. Uma mesma área pode apresentar diferentes resultados na classificação dependendo do classificador escolhido. Os classificadores de imagens podem seguir regras paramétricas e não paramétricas (Lu e Weng, 2007). O modelo paramétrico de classificação adota algumas medidas de definição de regras do classificador para cada classe escolhida como média e matriz de covariância, o que gera certa homogeneidade nas

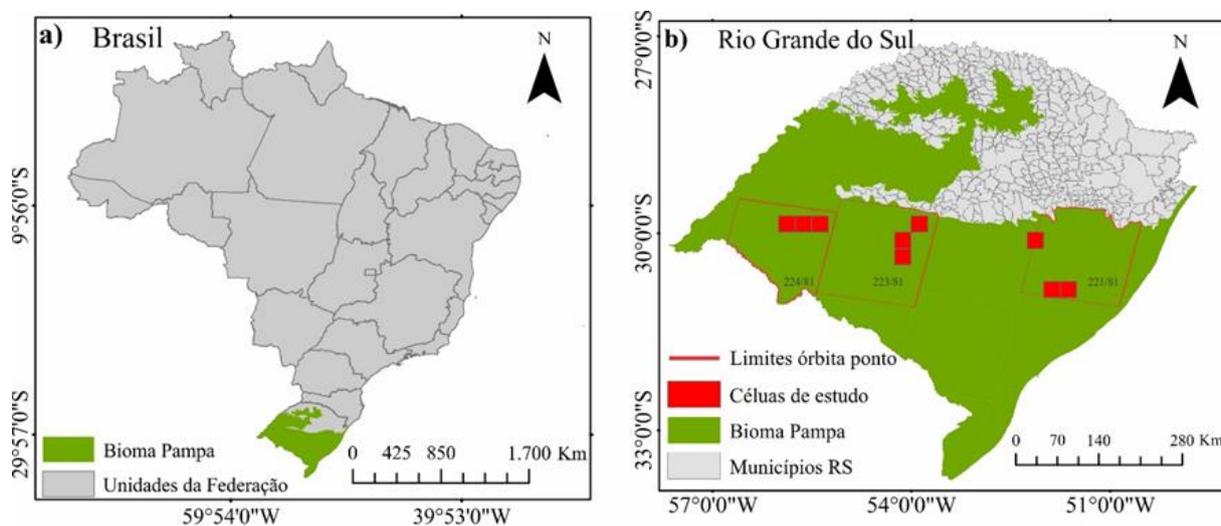
propriedades espectrais das classes (ANDREOLA et al., 2009). Os classificadores não paramétricos podem ser empregados com distribuições que não obedecem aos parâmetros da curva normal (SEMOLINI, 2002). Neste método, a classificação de cada pixel pode depender inclusive de todos os pixels da imagem, além das informações da vizinhança do pixel serem analisadas na classificação (Andrade, 2014).

Este artigo teve como objetivo avaliar o desempenho de classificadores paramétricos e não-paramétricos para classificação de uso e cobertura da terra em áreas do bioma Pampa – Brasil, incluindo a comparação da utilização de bandas ópticas e termais dos sensores OLI e TIRS/Landsat 8.

### Área de estudo

Para a realização das etapas metodológicas, selecionou-se nove células teste (Figura 1), distribuídas nas regiões leste, centro e oeste do bioma Pampa. Essas células foram selecionadas pois não apresentaram cobertura de nuvens nas imagens de diferentes datas, o que poderia comprometer as análises.

Figura 1 - Localização das células classificadas no bioma Pampa – Brasil.



Limites órbitas/ponto (22481, 22381, 22181) de Imagens OLI/Landsat 8  
 Dados vetoriais (limites estaduais, municipais e bioma) IBGE  
 Sistema de Coordenadas Geográficas DATUM WGS84

Adaptado de Trindade et al. 2021.

## Metodologia

### Materiais

Os materiais utilizados corresponderam a 9 imagens dos sensores OLI e TIRS do satélite Landsat 8, abrangendo três órbitas ponto para seguintes datas: 06/02/2018, 17/08/2018 e 07/12/2018 (órbita ponto 224/81); 15/02/2018, 26/08/2018 e 16/12/2018 (órbita ponto 223/81); e 13/01/2017, 25/08/2017 e 15/12/2017 (órbita ponto 221/81). As imagens foram adquiridas no Serviço Geológico dos Estados Unidos (USGS), e foram consideradas as bandas do espectro óptico (B2 azul 0.450 – 0.515  $\mu\text{m}$ ; B3 verde 0.525 – 0.600  $\mu\text{m}$ ; B4 vermelho 0,630 – 0,680  $\mu\text{m}$ ; B5 infravermelho próximo 0.845 – 0.885  $\mu\text{m}$ ; B6 infravermelho médio 1.560 – 1.660  $\mu\text{m}$  e B7 infravermelho médio 2.100 – 2.300  $\mu\text{m}$ ) em reflectância de superfície (SR) com resolução espacial de 30 metros e a banda termal (B10 10.30 – 11.30  $\mu\text{m}$ ) em temperatura de brilho (TB), cabe destacar que é possível adquirir imagens a partir do sensor TIRS a bordo do satélite Landsat 8 e estes produtos já estão disponibilizados em resolução espacial de 30 metros (reamostradas) para compatibilizar com as demais bandas do OLI (USGS 2022). Para o processamento e interpretação das imagens foram utilizados os softwares ENVI 5.3 e QGIS 2.14.18.

### Métodos

Os procedimentos metodológicos seguiram quatro etapas: Etapa 1 – pré-processamento das imagens; Etapa 2 – coleta de amostras de treinamento; Etapa 3 – classificação supervisionada com os algoritmos paramétricos e não paramétricos; e Etapa 4 – análise de acurácia das classificações.

Na etapa 1, as imagens OLI e TIRS foram preparadas para a posterior classificação. Nas imagens OLI em Reflectância de Superfície foi aplicado o fator escalar de 0,0001 (USGS, 2021) na ferramenta Band Math do ENVI. As imagens termais em Temperatura de Brilho (TB) passaram pelo processo de correção de emissividade (Equação 1) com auxílio do software QGIS e metodologia implementada por Ndossi e Avdan (2016). As imagens de emissividade consideram os valores de NDVI, conforme a relação apresentada na Tabela 1 e utilizada em diferentes pesquisas (VAN De GRIEND & OWE, 1993; VALOR & CASELLES, 1996; SOBRINO, JIMÉNEZ-MUÑOZ, & PAOLINI, 2004; ZHANG, WANG, & LI, 2006).

$$TS = T_b / (1 + (\lambda T_b / \rho) * \ln \epsilon)$$

Equação 1

TS= temperatura de superfície;  $T_b$  = temperatura de brilho registrada pelo sensor em Kelvin;  $\ln \epsilon$  = logaritmo natural da emissividade da superfície;  $\lambda$ = comprimento de onda médio do infravermelho termal;  $\rho = hc/\sigma = 1.438 \times 10^{-2} mK$ ;  $\epsilon$  = emissividade.

Tabela 1. Algoritmo para cálculo de emissividade ( $\epsilon$ ) baseado no NDVI

Valores NDVI	Valores Emissividade
<b>NDVI &lt; -0.185</b>	<b>0.995</b>
<b>-0.185 ≤ NDVI &lt; 0.157</b>	<b>0.985</b>
<b>0.157 ≤ NDVI ≤ 0.727</b>	<b>1.009 + 0.04 x ln(NDVI)</b>
<b>NDVI &gt; 0.727</b>	<b>0.990</b>

Fonte: Adaptado Ndossi e Avdan (2016).

Na etapa 2, foram coletadas as amostras de treinamento. A partir da análise de elementos como cor, textura e forma identificou-se as classes de uso e cobertura da terra: área de cultivo (AC), campo (CA) e vegetação arbórea (VA) (Figura 2), assim como outros trabalhos de mapeamento de uso e cobertura da terra (KUPLICH 2016; TRINDADE et al, 2021; TRINDADE et al. 2022; PEIXOTO, 2022).

A classe área de cultivo, corresponde a áreas que sofreram intervenção antrópica, transformando a vegetação natural, geralmente são encontradas nestas áreas plantio de soja e arroz e no período de entressafra ocorre o plantio de pastagens. A classe campo (CA) corresponde às áreas com vegetação predominantemente de gramíneas, leguminosas e vegetação arbustiva, com mais de 2.200 espécies (BOLDRINI, 2009). O bioma apresenta a coexistência de duas espécies de gramíneas dos grupos fotossintéticos C3 e C4 (BOLDRINI, 2009; NABINGER et al., 2009). A classe vegetação arbórea inclui os remanescentes florestais, mata galerias e florestas. Neste sentido, foram identificadas as classes de cobertura da terra e a melhor composição colorida para a identificação das mesmas.

Todos os alvos que não se enquadravam nessas classes foram atribuídos à classe outros (não computada nas análises). Uma máscara de corpos hídricos disponível na Plataforma TerraBrasilis (ASSIS et al., 2019, ALMEIDA, 2020) foi aplicada em cada classificação.

Figura -2: Chave de interpretação para as classes área de cultivo (AC), campo (CA) e vegetação arbórea (VA).

Landsat 8				
Classe	RGB 432	Forma	Tonalidade	Textura
<b>Campo (CA)</b>		Irregular, podendo ser fragmentado	Cor: verde Tonalidade: Médio	Fina a média
<b>Vegetação Arbórea (VA)</b>		Irregular; fragmentado	Cor: verde Tonalidade: escuro	Média a grossa
<b>Área de Cultivo (AC)</b>		Regular, com tamanhos variados	Cor: verde Tonalidade: Médio	Fina

Elaborado pelos autores.

A etapa 3 correspondeu às classificações supervisionadas considerando algoritmos paramétricos (Máxima Verossimilhança - Maxver e distância de Mahalanobis -MH) e não-paramétricos (Spectral Angle Mapper- SAM e Support Vector Machine- SVM).

Os métodos de classificação MaxVer e MH usam distâncias transformadas ou ponderadas (SOHN, 2002) e são amplamente utilizados em pesquisas de sensoriamento remoto (GAROFALO, 2015). São considerados paramétricos, pois consideram parâmetros (vetor média e matriz de covariância) da distribuição gaussiana multivariada partindo do pressuposto que as estatísticas para cada classe em cada banda são normalmente distribuídas (Moura, 2016). Os pixels são classificados e cada um é atribuído à classe que tem a maior probabilidade de pertencer (INPE 2002).

O método não paramétrico Spectral Angle Mapper (SAM) determina a similaridade espectral entre dois espectros e em seguida calcula o ângulo entre eles, o valor obtido é usado como medida de discriminação para atribuir os pixels a uma determinada classe (DU et al., 2004; YONEZAWA 2007). Outro método não paramétrico utilizado é o SVM, desenvolvido pelo pesquisador Vladimir Vapnik e colaboradores (CORTES & VAPNIK, 1995; VAPNIK, 1995), este é basicamente uma máquina linear, cuja ideia principal é constituir um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima. O SVM se destaca, pois tem apresentado resultados mais satisfatórios quando comparado aos classificadores tradicionais (MOUNTRAKIS et al. 2011).

Na etapa 4, realizou-se a validação das classificações geradas. Como recomendado na literatura, as amostras de treino e validação foram coletadas de forma independente, pois as necessidades do treinamento são diferentes das da etapa de validação (STEHMAN e FOODY, 2019). Por exemplo, na etapa de treinamento, a amostragem proposital de seleção local é aceitável para a classificação, entretanto, uma amostragem probabilística é um requisito de “boa prática” para a validação dos mapas gerados (OLOFSON et al., 2014; STEHMAN e FOODY, 2019; CONGALTON e GREEN, 2019).

A validação foi realizada a partir da definição de amostras de referência seguindo protocolo de “boas práticas” encontradas em Pontius e Millones (2011), Olofsson et al. (2014), Stehman e Foody (2019) e Congalton e Green (2019). Neste sentido, foram consideradas as etapas de desenho amostral, desenho resposta e análises. O desenho amostral escolhido foi amostragem aleatória sistemática com intervalo de confiança de 95% ( $z = 1,96$ ) (Congalton e Green 2019) e distanciamento de 1,5 km entre pontos para amostrar a totalidade da área classificada, para que todas as células tivessem a mesma distribuição e evitar que pontos ficassem concentrados em uma pequena porção da imagem. No desenho resposta, cada ponto foi interpretado a partir de composições coloridas das imagens Landsat 8 para diferentes estações do ano e imagens de alta resolução disponíveis no Google Earth com datas próximas das imagens utilizadas para as classificações.

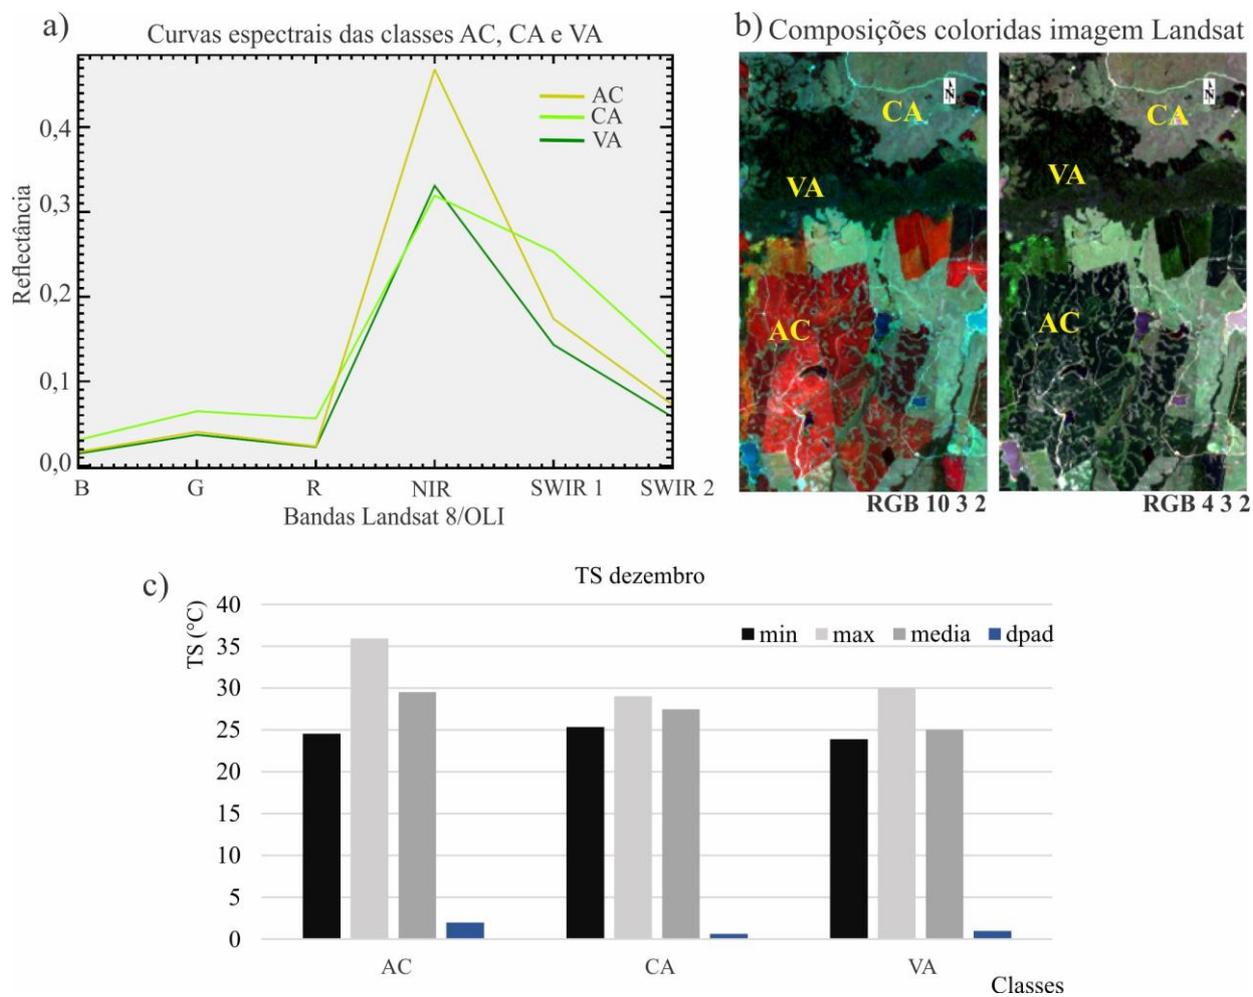
As análises da qualidade da classificação foram realizadas a partir das matrizes de erros de cada classificação, e assim calculadas as métricas de acurácia como Exatidão Global (EG), Exatidão do Produtor (EP) e Exatidão do Usuário (EU), erros de alocação (Allocation Disagreement – AD) e erro de quantidade (Quantity Disagreement – QD) (PONTIUS e MILLONES, 2011; OLOFSSON et al. 2014; CONGALTON e GREEN, 2019).

### **Resultados e Discussão**

Em relação ao conhecimento do padrão dos alvos, a figura 3 apresenta as características de cada classe identificada nas imagens desta pesquisa. O comportamento espectral das classes (espectro refletido) pode ser observado na figura 3a, sendo possível verificar que as curvas são semelhantes, no entanto, os valores de reflectância apresentam maior diferença a partir do infravermelho próximo. De modo geral, verificou-se que para as bandas do visível, a reflectância não ultrapassou o valor de 0,1, no NIR as classes VA e CA com valor de 0,3 e a AC apresentou valor superior a 0,4. As bandas do SWIR 1 e SWIR 2, as classes apresentaram valor de 0,1 a 0,3 de reflectância.

Na figura 3b é possível identificar o incremento da banda termal na definição das áreas de cultivo quando comparadas às composições RGB 1032 e RGB 432. A composição RGB 1032 foi realizada com a combinação da banda 10 (dezembro) e as bandas 3 e 2 de fevereiro (Trindade et al. 2021), o que permitiu melhor diferenciar as classes campo, área de cultivo e vegetação arbórea. Na imagem de dezembro (Figura 3c), verificou-se valores mais elevados de TS nas áreas de cultivo (média 29°C) e menor valor (média 25°C) para áreas com vegetação arbórea. Nas áreas de campo a TS variou de 25°C a 29°C, valor intermediário entre a área de cultivo e vegetação arbórea. Esta variação da temperatura nas imagens de diferentes estações foi possível verificar o destaque das áreas de cultivo em vermelho na composição RGB.

Figura -3: Características das classes área de cultivo (AC), campo (CA) e vegetação arbórea (VA): a) curvas espectrais de cada classes na imagem OLI 15/02/2018; b) composições coloridas identificando cada classe; c) estatísticas da TS para cada classe na imagem 16/12/2018.



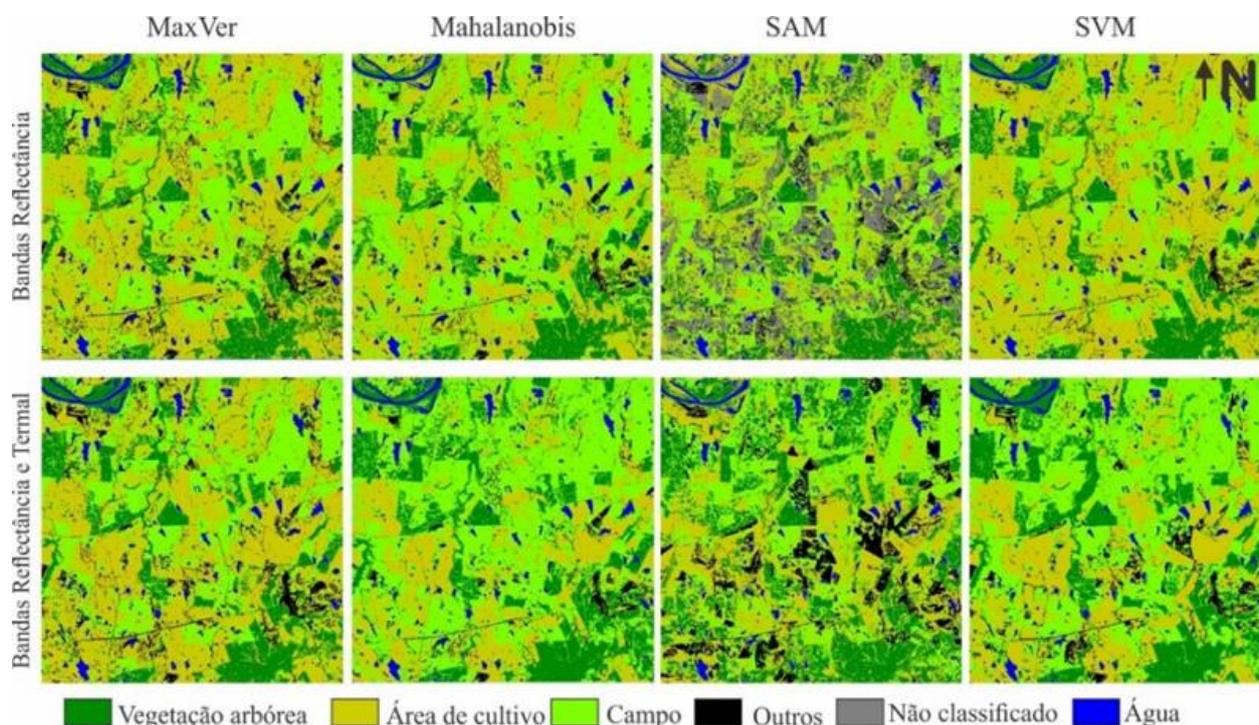
Elaborado pelos autores.

A combinação de imagens de diferentes sensores e diferentes datas facilitou a diferenciação visual entre as áreas de cultivo, campo e vegetação arbórea, isto se deve ao fato de que o comportamento espectral dos alvos pode variar conforme a época do ano. Por exemplo, as áreas destinadas ao cultivo agrícola mudam seu padrão de cobertura frequentemente (BLASCHKE, et al., 2000). Para a área de estudo, as imagens de dezembro apresentaram pouca ou nenhuma cobertura

vegetal (maior TS) e um alto vigor vegetativo (menor TS) em fevereiro. Diferentes pesquisas também verificaram o potencial da utilização de imagens termais (Eisavi et al. 2015, Zhao et al. 2019, Mehta et al. 2021, Trindade et al. 2021) e multitemporais (Lunetta e Balogh, 1999; Chen et al. 2021; Mardian et al. 2021) para a classificação e análise da cobertura da terra.

Assim, a combinação de dados multitemporais e multisensores com a aplicação de algoritmos classificadores auxilia e otimiza a análise espacial e temporal de coberturas da terra, permitindo mais eficiência no monitoramento dos biomas. Na figura 4 é possível verificar as diferenças das classificações geradas com e sem a inclusão da banda termal a partir dos classificadores paramétricos (Maxver e MH) e não paramétricos (SAM e SVM). Os resultados obtidos demonstraram que as diferentes técnicas e dados de entrada geraram produtos (mapas classificados) distintos, o que cabe ao pesquisador escolher a melhor metodologia para sua área de estudo. Portanto, a análise de acurácia das classificações é uma etapa importante para garantir a confiabilidade das análises geradas.

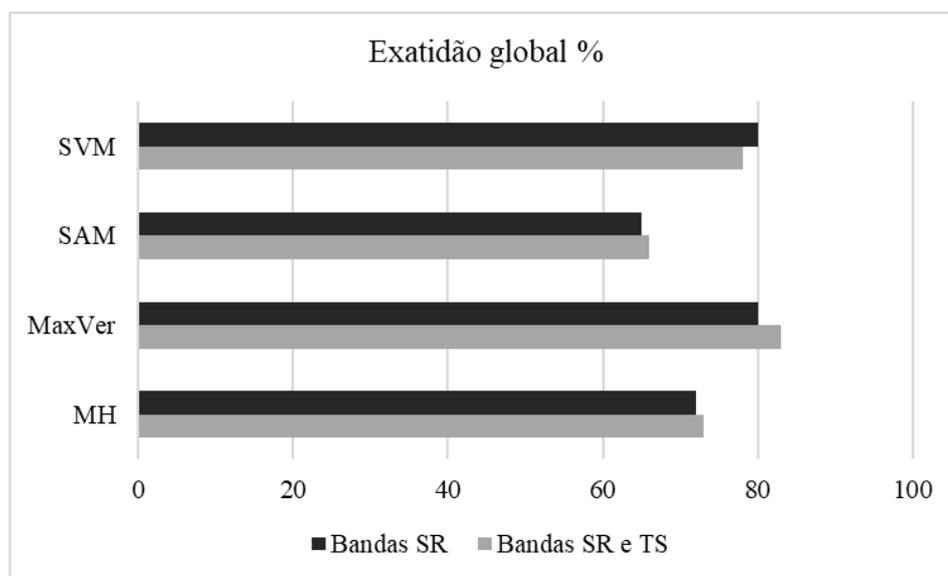
Figura – 4: Exemplo de célula classificada com os classificadores MH, Maxver, SAM e SVM.



Elaborado pelos autores.

Nos classificadores paramétricos a EG variou de 72% a 83% (Figura 5), os melhores desempenhos foram verificados quando a banda termal foi utilizada. A maior EG foi verificada no classificador Maxver com a inclusão da banda termal. Nos classificadores não paramétricos os valores de EG variaram de 66% a 80%, sendo que o SVM apresentou maior EG (80%) quando foram utilizadas somente as bandas de reflectância de superfície (SR). Ao compararem os algoritmos SAM e SVM para a classificação de diferentes fisionomias, Lenzi e Nunes (2016) também verificaram melhor desempenho do classificador SVM. Ao comparar os classificadores Maxver e SVM, Deilmai et al. (2014) encontraram valores acurácia global superiores para o primeiro algoritmo (91,67% - Maxver, 78,33 – SVM), sendo que o SVM apresentou um melhor desempenho em áreas mais heterogêneas.

Figura – 5: Valores de exatidão global para os classificadores MH, Maxver, SAM e SVM.



Elaborado pelos autores.

A exatidão do produtor (EP) representa a frequência com que as características reais da cobertura da terra são apresentadas corretamente no mapa classificado. O erro de omissão (EO) é o complemento de EP e informa a quantidade de falsos negativos, ou seja, classes que deveriam ser detectadas e foram omitidas (CONGALTON e GREEN, 2019). Ao considerar somente as bandas SR

para gerar as classificações (Tabela 2), a EP variou de 42% a 90%. A classe campo apresentou os maiores valores de EP (média 84,32%) em todas as classificações. Os menores valores de EP foram verificados na classe área de cultivo (média 68,38%) para as classificações MH, SAM e SVM. A classe vegetação arbórea apresentou média de 78,40%, com valor mais elevado na classificação MH.

A exatidão do usuário (EU) aponta ao usuário com que frequência a classe do mapa estará presente na referência. O erro de comissão (EC) complementa a EU e informa a quantidade de falsos positivos presentes na classificação (CONGALTON e GREEN, 2019). Os maiores valores de EU foram verificados na classe área de cultivo (média 84,46%) em todas as classificações, e os menores valores para a classe vegetação arbórea (média 63,94%) nas classificações MH, SAM e SVM. A classe campo apresentou melhor resultado de EU (76,98%) na classificação SVM.

O cálculo dos erros de Quantidade (Quantity Disagreement – QD) e erros de Alocação (Allocation Disagreement – AD) permite identificar falhas na classificação, separando a natureza das discordâncias em quantidade e alocação (PONTIUS e MILLONES, 2011). Se o valor de QD for relativamente alto, infere-se diferenças substanciais nas quantidades de amostras categorizadas na classificação ou na referência. Se o valor de AD for elevado, existe diferença na alocação espacial das categorias. Os erros que superam a margem de 10% são considerados elevados. Para as classificações geradas (somente bandas SR), os erros de quantidade (QD) variaram de 3,77% a 22,18% e alocação (AD) de 13,2% a 16,17%. A classificação Maxver apresentou menor valor de QD (3,77%), entretanto, o maior valor de AD (16,17%).

Tabela 2. Exatidões do produtor e usuário, Quantity Disagreement (QD) e Allocation Disagreement (AD) para as classes área de cultivo, campo e vegetação arbórea nas classificações.

Classificação		Exatidão do produtor (%)			Exatidão do usuário (%)			QD	AD
		AC	CA	VA	AC	CA	VA		
		MH	SR	60,43	84,57	81,29	87,54		
	SR e TS	55,31	88,46	91,37	95,86	67,22	57,99	20,23	6,74

Maxver	SR	77,83	84,07	77,10	84,46	76,41	77,10	3,77	16,17
	SR e TS	79,68	88,50	81,54	89,26	78,33	79,70	5,18	11,58
SAM	SR	42,98	90,19	69,75	81,22	70,50	40,29	22,18	13,2
	SR e TS	47,82	84,42	72,99	82,21	68,82	41,84	19,68	14,81
SVM	SR	76,34	83,84	79,71	85,96	76,98	69,62	5,41	14,97
	SR e TS	66,67	88,89	85,51	94,70	70,48	65,92	14,15	8,07

Nas classificações que foram utilizadas as bandas SR e Termal, a EP variou de 47% a 91,37% e EU de 41% a 95,86%. Os maiores valores de EP foram verificados para a classe campo (média 88,48%) nas classificações Maxver, SAM e SVM, e os menores valores para a classe área de cultivo (média 60,99%) em todas as classificações. A classe vegetação arbórea apresentou média de EP de 83,52%, com valor mais elevado (91,37%) na classificação MH e menor valor (72,99%) na classificação SAM. Em relação à Exatidão do Usuário, a classe que apresentou os melhores resultados foi área de cultivo (média de 91,98%) em todas as classificações, e os menores valores foram verificados na classe vegetação arbórea (média 61,95%) para as classificações MH, SAM e SVM. A classe campo apresentou média de EU de 69,65%, com valor mais elevado (78,33%) na classificação Maxver.

Os erros de quantidade variaram de 5,18% a 20,23% e de alocação de 6,74% a 14,81%. O melhor resultado para QD foi verificado na classificação Maxver, e para AD no classificador MH. Os valores mais elevados de QD (19,68%) e AD (14,81%) foram verificados na classificação com o algoritmo SAM.

As classes que apresentaram maior confusão entre si foram as classes área de cultivo e campo, tanto nos algoritmos paramétricos, quanto não paramétricos. O estado de conservação de campos, com exposição do solo e baixa vegetação em caso de degradação, pode ter causado esta confusão, assim como os campos verdes e densos poderiam confundir com algumas culturas quando em fase de vigor vegetacional. De modo geral, o Maxver foi o classificador que apresentou o melhor desempenho. Em uma pesquisa de revisão sobre os principais algoritmos de classificação de imagens utilizados no Brasil, Silveira et al. (2020) constataram que o Maxver apresentou melhor desempenho em 64% das aplicações realizadas. O que pode justificar o fato de ser o classificador mais utilizado

em diferentes aplicações do sensoriamento remoto (RICHARDS e Jia, 2006; ANDRADE, 2014; PRADO; HAYAKAWA; KAWAKUBO, 2016).

Para os classificadores MH e SAM, a inclusão da banda termal contribuiu para o aumento de 1% na exatidão global, já o Maxver apresentou um aumento de 3%. Embora com valores baixos, a inclusão da banda termal demonstrou ser possível aumentar a acurácia dos classificadores Maxver, MH e SAM. A utilização da banda termal apresentou resultados semelhantes em outras pesquisas, como as de Sun e Schulz (2015), Eisavi et al. (2015), Zhao et al. 2019 e Abdalkadhum et al. 2020. O trabalho realizado por Sun e Schulz (2015), por exemplo, combinou bandas do espectro emitido (termal) com as bandas do espectro refletido (visível e infravermelho próximo) para classificar os padrões de cobertura do solo. Os autores encontraram um aumento de 3% a 6% de acurácia nos mapas gerados. Zhao et al. (2019) utilizaram imagens Landsat 8 de diferentes estações do ano, e verificaram um aumento de 1% de acurácia nas classificações com a inclusão de bandas termais. Eisavi et al. (2015), ao analisarem diferentes coberturas da terra no noroeste do Irã, verificaram que as classificações que consideraram apenas bandas ópticas apresentaram exatidão global de 86,48%, com a combinação de banda termal e ópticas a acurácia aumentou para 90,63%, já a utilização de apenas bandas termais apontou uma acurácia inferior, de 82,26%. Abdalkadhum et al. 2020 alcançaram uma acurácia geral de 94% ao combinar as bandas ópticas e termais do satélite Landsat 8 para classificação de cobertura da terra.

Aliado a isso, o fator multitemporal também colabora para a análise e interpretação das classes de cobertura da terra, resultando em mapas classificados de melhor qualidade (LUNETTA e BALOGH, 1999; CHEN et al. 2021; MARDIAN et al. 2021). Lunetta e Balogh (1999) constaram essa afirmativa há 22 anos ao utilizarem imagens sensor TM (Landsat 5) das estações de primavera e verão para um mapeamento de pântanos nos EUA. Os autores verificaram uma acurácia de 88% com imagens de diferentes datas, em contrapartida, a classificação gerada com apenas uma data apresentou 69% de acurácia. Em relação ao monitoramento de coberturas campestres, Martian et al. 2021 também destacaram a importância da utilização de análise multitemporal para estudos de conversão de campos em áreas agrícolas nas pradarias canadenses. O que destaca que a importância

do monitoramento e conservação de áreas de campos nativos é uma questão discutida globalmente, assim como através do sensoriamento remoto.

### **Conclusões**

Tendo em vista que o objetivo do trabalho foi avaliar o desempenho de classificadores paramétricos e não-paramétricos para classificação de uso e cobertura da terra em áreas do bioma Pampa – Brasil, incluindo a comparação da utilização de bandas ópticas e termiais dos sensores OLI e TIRS/Landsat 8, pode-se afirmar que o Maxver foi o algoritmo paramétrico com melhor desempenho (EG- 83%) e SVM o algoritmo não paramétrico com melhor desempenho (EG-80%, imagens SR).

Em relação à confusão entre as classes, verificou-se que a classe área de cultivo foi a que apresentou maior confusão com as áreas de campo em todos os classificadores. O estado de conservação de campos, com exposição do solo e baixa vegetação em caso de degradação, pode ter causado esta confusão, assim como os campos verdes e densos poderiam confundir com algumas culturas quando em fase de vigor vegetacional. As imagens termiais utilizadas apresentaram aumento de 1% a 3% na acurácia dos mapas gerados, valores que ainda devem ser superados a partir de novos testes de classificações.

Os resultados obtidos demonstraram valores satisfatórios de acurácia para as classificações, entretanto, uma mesma área apresentou diferentes mapas de cobertura dependendo do algoritmo utilizado para classificar. Sendo que, a inclusão de dados termiais demonstrou que é possível trabalhar com dados de diferentes sensores a fim de alcançar melhor desempenho nas classificações. No entanto, os resultados alcançados demonstram que ainda são necessários mais estudos sobre a combinação de dados ópticos e termiais, e assim, melhorar os valores de acurácia dos mapas gerados. Desta forma, não existe uma rotina de classificação ideal para atender todas as áreas, sendo necessária avaliação do pesquisador para a escolha da melhor metodologia a ser empregada, considerando tempo para processar, recursos computacionais e disponibilidades de dados e *softwares* com diferentes algoritmos classificadores.

### **Agradecimentos**

Agradecimento ao Conselho Nacional de Desenvolvimento Científico e Tecnológico -CNPq processos: 422354/2023-6 (Monitoramento e avisos de mudanças de cobertura da terra nos biomas brasileiros –capacitação e semiautomatização do Programa BIOMASBR); 301423/2024-5; n. 384905/2023-4; n. 409336/2021-1, apoiados pelo Instituto Nacional de Pesquisas Espaciais –INPE.

## Referências

- ABDALKADHUM, A. J.; SALIH, M. M.; JASIM, O. Z. Combination of visible and thermal remotely sensed data for enhancement of Land Cover Classification by using satellite imagery. **IOP Conf. Series: Materials Science and Engineering** 737, 2020. doi:10.1088/1757-899X/737/1/012226
- ALMEIDA, C.A.; VALERIANO, D.M; MAURANO, L.; VINHAS, L.; FONSECA, L.M.G.; SILVA, D.; SANTOS, C.P.F; MARTINS, F. S. R. V.; LARA, F.C.B.; MAIA, J.S.; PROFETA, E.R.; SANTOS, L.O.; SANTOS, F.C.O; RIBEIRO, V. 'Deforestation monitoring in different Brazilian Biomes: challenges and lessons.'In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume IV-3/W2-2020, 2020, Santiago, Chile.
- FERNANDES, B. M. Agronegócio nas Américas: o mito do desenvolvimento e a resistência do campesinato. In: ENCONTRO DE GEÓGRAFOS DA AMÉRICA LATINA, 10, 2005, São Paulo, 2005. Anais [...] São Paulo: EGAL/USP, 2005. p.4860-4874.
- ANDRADE, A. C; FRANCISCO, C. N; ALMEIDA C. M. Desempenho de classificadores paramétrico e não paramétrico na classificação da fisionomia vegetal. **Revista Brasileira de Cartografia**, Rio de Janeiro, NO 66/2, p. 349-363, Mar/Abr, 2014.
- ANDREOLA, R. & HAERTEL, V. Support Vector Machines na Classificação de Imagens Hiperespectrais. In: Simpósio Brasileiro de Sensoriamento Remoto, 14, 2009, Natal, Brasil. **Anais...** São José dos Campos: INPE, p. 6757- 6764
- ASSIS, L. F. F. G, FERREIRA, K. R., VINHAS, L., MAURANO, L., ALMEIDA, C., CARVALHO, A., CAMARGO, C. 2019. TerraBrasilis: A Spatial Data Analytics Infrastructure for Large-Scale Thematic Mapping. **ISPRS International Journal of Geo-Information**, 8(11), 513. doi: 10.3390/ijgi8110513
- BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL,P.; "Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications". In: Cremers, A. B. & Greve, K. (Hrsg). (2000)
- BOLDRINI, I. I. A flora dos campos do Rio Grande do Sul. In: Pillar, V.P., Müller, S.C., CASTILHOS, Z.M.S, Jacques, A.V.A. (ed). **Campos Sulinos: conservação e uso sustentável da biodiversidade**. Brasília: MMA, 2009. 403p.
- CONGALTON R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data**. 3ª ed. Taylor & Francis Group, 2019.
- CORTES, C.; VAPNIK, V. Support vector networks. **Machine Learning**. v. 20, n. 3, p. 273- 297, 1995.

- CHEN, H.; CHEN, C.; ZHANG, Z.; LU, C.; WANG, L.; HE, X.; CHU, Y.; CHEN, J. Changes of the spatial and temporal characteristics of land-use landscape patterns using multi-temporal Landsat satellite data: A case study of Zhoushan Island, China. **Ocean and Coastal Management** v. 213, p. 1 – 15. 2021 <https://doi.org/10.1016/j.ocecoaman.2021.105842>
- DEILMAI, B.R., AHMAD, B. BIN, ZABIHI, H. Comparison of two Classification methods (MLC and SVM) to extract land use and land cover in Johor Malaysia. **IOP Conf. Ser. Earth Environ. Sci.** 20, 012052, 2014. doi:10.1088/1755-1315/20/1/012052
- DU, Y., CHANG, C.I., REN, H., CHANG, C.C., JENSEN, J.O., D'AMICO, F.M., 2004. New hyperspectral discrimination measure for spectral characterization. **Opt. Eng.** 43, 1777. doi:10.1117/1.1766301
- EISAVI, V., HOMAYOUNI, S., YAZDI, A. M., & ALIMOHAMMADI, A. (2015). Land cover mapping based on random forest classification of multitemporal spectral and thermal images. **Environmental Monitoring and Assessment**, 187(5), 1–14. DOI: <https://doi.org/10.1007/s10661-015-4489-3>
- FOODY, G.M., 2002. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, 80, pp. 185–201.
- FOODY, G.M., 2004, Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. **Photogrammetric Engineering and Remote Sensing**, 70, pp. 627–633
- GAROFALO, D. F. T.; MESSIAS, C. G.; LIESENBERG, V.; BOLFE, E. L.; FERREIRA, M. C. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicados ao mapeamento temático. **Pesq. agropec. bras.**, Brasília, v.50, n.7, p.593-604, 2015.
- INPE, 2002.Tutorial SPRING. INPE, São José dos Campos.
- KUPLICH, T. M., BARBIERI, D. W., MOREIRA, A., QUADROS, F. L. F., TRENTIN, A. B., CORAZZA, R., AND DEPRÁ, B. Algumas aplicações de sensoriamento remoto em estudos de vegetação campestre no RS. São José dos Campos: Relatório de Pesquisa (RPQ) INPE. 2016. <http://urlib.net/rep/8JMKD3MGP3W34P/3LQEG78>
- LENZI, I. L. C. & NUNES, G.M. Comparação entre os classificadores Support Vector Machine e Spectral Angle Mapper aplicado à diferenciação das fitofisionomias do Parque Estadual do Araguaia (MT). **Revista Eletrônica Geoaraguaia**. Barra do Garças-MT. V 6, n.1, p.99 a 114. Janeiro/julho. 2016
- LU, D. & WENG, Q. A Survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, Vol. 28, No. 5, 823–870, March 2007.
- LUNETTA, R.S. & BALOGH, M.E. Application of multi-temporal Landsat 5 TM imagery for wetland identification. **Photogrammetric Engineering and Remote Sensing**, 65, pp. 1303–1310, 1999.
- MARDIAN, J.; BERG, A.; DANESHFAR, B. Evaluating the temporal accuracy of grassland to cropland change detection using multitemporal image analysis. **Remote Sensing of Environment**, 255, p. 1 – 10. 2021.

MEHTA, A.; SHUKLA, S.; RAKHOLIA, S. Vegetation Change Analysis using Normalized Difference Vegetation Index and Land Surface Temperature in Greater Gir Landscape. **Journal of Scientific Research**. V. 65, n. 3. 2021. DOI: 10.37398/JSR.2021.650301

MMA (Ministério do Meio Ambiente). "Pampa". Folder Pampa. (2019) Acesso: 15 Abril 2020. <https://www.mma.gov.br/biomas/pampa>

MOREIRA, A.; BREMM, C.; FONTANA, D. C.; KUPLICH, T. M. Seasonal dynamics of vegetation indices as a criterion for grouping grassland typologies. **Scientia Agricola**, v. 76, p. 24-32, 2019.

MOURA, N. V. A. de. Comparação entre classificadores supervisionados para fins de análise multitemporal do uso e cobertura da terra no entorno do reservatório da Usina Hidrelétrica de Corumbá IV/GO. 2016. 53 f. Dissertação (Mestrado em Geografia) Programa de Pós-Graduação em Geografia, Universidade de Brasília, Brasília, 2016.

MOUNTRAKIS, G., IM, J., OGOLE, C., 2011. Support vector machines in remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.* 66, 247–259. doi:10.1016/j.isprsjprs.2010.11.001

NABINGER, C.; FERREIRA, E.T.; FREITAS, A.K.; CARVALHO, P.C.F.; SANT'ANNA, D.M. Produção animal em campo nativo: aplicações de resultados de pesquisa. In: Pillar, V.P.; Müller, S.C.; Castilhos, Z.M.S.; Jacques, A.V.A. (Org.). **Campos sulinos: conservação e uso sustentável da biodiversidade**. Brasília: Ministério do Meio Ambiente - MMA, p. 175-198. 2009.

NDOSSI, M. I. & AVDAN, U. 2016. Application of open source coding technologies in the production of Land Surface Temperature (LST) maps from Landsat: A PyQGIS plugin. **Remote Sensing**, 8 (5), 1 - 31. doi: 10.3390/rs8050413

NOVO, E. M. L. M. Sensoriamento remoto: princípios e aplicações. 4. ed. rev. SP: Blucher, 201.

OLOFSSON, P.; FOODY G. M.; HEROLD, M.; STEHMAN S. V.; WOODCOCK, C. E.; WULDER, M. A. Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, 148, p. 42 – 57, 2014.

OVERBECK, G.E. et al. Fisionomia dos Campos. In: PILLAR, V.P., LANGE, O. (Ed.) **Os Campos do Sul**. Rede Campos Sulinos. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2015. p. 31-39

PEIXOTO, D. W. B.; TRINDADE, P. M. P.; KUPLICH, T. M. Análise da temperatura de superfície em diferentes coberturas do Bioma Pampa. **Revista Brasileira de Geografia Física**, v. 15, n. 01, p.268-281, 2022. Disponível em: <<https://periodicos.ufpe.br/revistas/rbgfe/article/view/250644/40704>> . Acesso em: 29-07-22

PONTIUS JR., R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407 – 4429, 2011.

PONZONI, F. J., SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto aplicado ao estudo da vegetação**. 2. ed. São José Dos Campos, Saraiva, 2012.

PRADO, D. F. C.; HAYAKAWA, E. H.; KAWAKUBO, F. S. Mapeamento do cultivo de café no sul de Minas Gerais utilizando imagens Landsat-5 TM e variáveis topográficas. **Revista do Departamento de Geografia**, v. 31, p. 43-57, 2016.

RICHARDS, J. & JIA, X. **Remote sensing digital image analysis**, Four. ed. Springer, Berlin, 2006.

SARTORI, M. G. B. **O Vento Norte**. Santa Maria/RS: Pallotti, 2016.

SEMOLINI, R. Support Vector Machines, Revista Brasileira de Cartografia, Rio de Janeiro, N 363 066/2, p. 349-363, Mar/Abr/2014 Inferência Transdutiva e o Problema de Classificação. Dissertação (Mestrado em Engenharia de Computação) - UNICAMP. Campinas, SP, 2002.

SILVEIRA, A.H. de m.; SILVA,F.M.; HADAD, R.M.;LIBÓRIO, M.O. Aplicações, preferências e comparações entre métodos de classificação supervisionada: o caso de Natal/RN. **Ra' e Ga**. Curitiba, v.47, n.1, p.120-135.

SOBRINO, J. A., JIMÉNEZ-MUÑOZ, J. C., AND PAOLINI, L. 2004. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**, 90(4), 434–440. doi: 10.1016/j.rse.2004.02.003

SOHN, Y. & REBELLO, S. Supervised and Unsupervised Spectral Angle Classifiers, **Photogrammetric Engineering e Remote Sensing**, Vol. 68, No. 12, pp. 1271-1280, December 2002.

SOUZA, C., & AZEVEDO, T. (2017). **MapBiomass general handbook**. MapBiomass: São Paulo, Brazil, 1-23.

STEHMAN S. V.; FOODY G. M. Key issues in rigorous accuracy assessment of land cover products. **Remote Sensing of Environment**, 231 p. 1 – 23, 2019.

SUN, L., SCHULZ, K., 2015. The Improvement of Land Cover Classification by Thermal Remote Sensing. **Remote Sensing**, 7, 8368-8390. Disponível: <https://doi.org/10.3390/rs70708368> Acesso: 03-01-21

TRINDADE, P. M. P., PEIXOTO, D. B. W., KUPLICH, T. M., ALMEIDA, C. A. DE., 2021. Desempenho da classificação supervisionada com a inclusão da banda termal em áreas selecionadas do bioma Pampa – Brasil. In: XIII Congresso Brasileiro de Agroinformática, 2021, Bagé/Rio Grande do Sul. Anais Eletrônicos... p. 62 – 70, 2021 (a) Disponível: <https://sol.sbc.org.br/index.php/sbiagro/article/view/18376>. Acesso: 28-01-22

TRINDADE, P. M. P., PEIXOTO, D. B. W., KUPLICH, T. M., ALMEIDA, C. A. de., 2021 Land cover mapping in the brazilian Pampa with landsat OLI and TIRS bands. São Paulo, UNESP, **Geociências**, v. 40, n. 4, p. 1115 – 1124.

USGS – United States Geological Survey Landsat Collection 2 Level-2 Science Products. Disponível em <https://www.usgs.gov/core-science-systems/nli/landsat/landsat-collection-2-level-2-science-products>. Acesso em 29.out.2021.

VALERIANO, D.M.; MELLO, E.M.K.; MOREIRA, J.C.; SHIMABUKURO, Y.E.; DUARTE, V. Monitoring tropical forest from space: The prodes digital project. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 2004, 35, 272–274

VALOR, E. & CASELLES, V. 1996. Mapping land surface emissivity from NDVI: Application to European, African, and South American areas. *Remote Sensing of Environment*, 57(3), 167–184. doi: 10.1016/0034-4257(96)00039-9

VAPNIK, V.N. **The Nature of Statistical Learning Theory**. New York, Springer-Verlag, 332 p. 1995.

VAN DE GRIEND, A. A., AND OWEN, M. 1993. On the relationship between thermal emissivity and the normalized difference vegetation index for natural surfaces. *International Journal of Remote Sensing*, 14(6), 1119–1131. doi: 10.1080/01431169308904400

YONEZAWA, C. Maximum likelihood classification combined with spectral angle mapper algorithm for high resolution satellite imagery C. Yonezawa. *International Journal of Remote Sensing*, Vol. 28, No. 16, 3729–373, August, 2007.

ZHANG, J., WANG, Y.; LI, Y. 2006. A C++ program for retrieving land surface temperature from the data of Landsat TM/ETM+ band6. *Computers and Geosciences*, 32(10), 1796–1805. doi: 10.1016/j.cageo.2006.05.001

ZHAO, J., YU, L., XU, Y., REN, H., HUANG, X., AND GONG, P., 2019. Exploring the addition of Landsat 8 thermal band in land-cover mapping. *International Journal of Remote Sensing*, 40(12), 4544–4559. Disponível: doi: 10.1080/01431161.2019.1569281