

AVALIAÇÃO DA TÉCNICA DE MODELO LINEAR DE MISTURA ESPECTRAL COMO SUBSÍDIO À CLASSIFICAÇÃO DO USO E OCUPAÇÃO DO SOLO

EVALUATION OF THE LINEAR MODEL TECHNIQUE OF SPECTRAL MIXING AS A SUBSIDY TO THE CLASSIFICATION OF LAND USE AND OCCUPATION

Fernanda Paula Bicalho PIO¹, Plínio da Costa TEMBA¹, Marcelo Antonio NERO¹, Marcos Antônio Timbó ELMIRO¹, Eliane Maria VIEIRA², Helder Lages JARDIM¹

¹Universidade Federal de Minas Gerais. Instituto de Geociências. Laboratório de Geoprocessamento do Departamento de Cartografia. Avenida Presidente Antônio Carlos, 6627 - Pampulha, Belo Horizonte – MG.

E-mail: fppbicalho@gmail.com; temb@ufmg.br; marcelo-nero@ufmg.br; mtimbo@ufmg.br; hljardim@gmail.com

²Universidade Federal de Itajubá - Instituto de Ciências Puras e Aplicadas. Avenida B P S, 1303 - Pinheirinho, Itajubá – MG.
E-mail: elianeveira@unifei.edu.br

Introdução
Materiais e métodos
Área de estudo
Materiais
Modelo linear de mistura espectral
Classificação do uso e ocupação do solo
Validação das classificações
Resultados e discussões
Conclusões
Referências

Resumo - O desenvolvimento das tecnologias de sensoriamento remoto tem incentivado a aplicação de imagens digitais em variadas circunstâncias, inclusive em estudos ambientais e do monitoramento da Terra. Para os estudos de classificação do uso e ocupação do solo diversas técnicas de classificação podem ser aplicadas. Estas, porém, variam em função das características dos sensores imageadores e da finalidade do experimento. Em estudos de classificação de imagens é comum se deparar com problemas de mistura espectral que podem ser limitadores, assim, métodos de trabalho são utilizados para extrair informações das imagens com maior riqueza de detalhes considerando as propriedades dos materiais presentes dentro de um pixel e para auxiliar nas técnicas de classificação. Este trabalho aborda o modelo linear de mistura espectral como subsídio à classificação do uso e ocupação do solo. Os resultados foram comparados com a classificação realizada a partir de imagens do satélite Sentinel 2-A. A precisão geral para as classificações originárias dos dados do Sentinel-2A e do MLME foi de 65% e 62%, respectivamente, e o coeficiente *Kappa* foi de 0,53 (dados espectrais do satélite) e 0,62 (resultado do MLME) indicando que a qualidade dos dois mapeamentos pode ser considerada como moderada, suficientemente boa ou boa.

Palavras-chave: Mistura espectral. Modelo linear de mistura espectral. Classificação de imagens. Sentinel-2A.

Abstract - The development of remote sensing technologies has encouraged the application of digital images in various circumstances, including environmental studies and Earth monitoring. For classification studies of land use and occupation, several classification techniques can be applied. These, however, vary depending on the characteristics of the imaging sensors and the purpose of the experiment. In image classification studies, it is common to encounter problems of spectral mixing that can be limiting, so working methods are used to extract information from images with greater detail, considering the properties of the materials present within a pixel and to help in classification techniques. This work approaches the linear model of spectral mixture as subsidy to the classification of land use and occupation. The results were compared with the classification performed from Sentinel 2-A satellite images. The overall accuracy for the ratings sourced from the Sentinel-2A and LMSM data was 65% and 62%, respectively, and the Kappa coefficient was 0.53 (satellite spectral data) and 0.62 (LMSM result) indicating that the quality of the two mappings can be considered as moderate, good enough or good.

Keywords: Spectral mixing. Linear spectral mixing model. Image classification. Sentinel-2A.

INTRODUÇÃO

O avanço das tecnologias de sensoriamento remoto tem favorecido o uso de imagens digitais em diferentes aplicações (Pereira et al., 2016; Silva, 2018; Mokhtari, 2019), inclusive em estudos de classificação do uso e ocupação do solo (Cheng et al., 2020). Observa-se também um crescimento no uso de dados de sensoriamento remoto de acesso livre para estudos ambientais, sendo aqueles derivados dos satélites *Moderate*

Resolution Imaging Spectroradiometer (MODIS), Landsat 8 e Sentinel-2 os mais utilizados (Radočaj et al., 2020).

Um dos procedimentos frequentemente utilizados para a caracterização de áreas é a classificação das cenas para interpretação do uso e ocupação do solo, podendo ela ser realizada a partir de diversos métodos e em diferentes condições, como no âmbito do pixel, de objeto e

da cena (Cheng et al., 2020).

Dependendo do tipo de análise a ser realizada a classificação do pixel, que é uma das formas frequentemente aplicadas em análises da superfície da terra, pode apresentar limitações devido à resolução espacial dos sensores. Com a evolução do sensoriamento remoto e das técnicas de trabalho com dados multiespectrais, alguns métodos foram estudados para permitir extrair informações com maior riqueza de detalhes sobre as propriedades dos materiais presentes dentro de um pixel, surgindo assim uma outra vertente com estudos que buscam analisar as substâncias constituintes de um pixel, ou seja, uma análise em escala de subpixel (Keshava & Mustard, 2002). Esta análise pode ser realizada a partir do estudo de mistura espectral quando se considera que um elemento de área (pixel) apresenta uma combinação de diferentes objetos e para analisá-lo detalhadamente utiliza-se de técnicas de decomposição espectral dos pixels (Keshava &

Mustard, 2002).

Neste estudo apresenta-se a aplicação do modelo linear de mistura espectral (MLME) baseado no método dos mínimos quadrados com restrição.

O estudo consiste em realizar dois mapeamentos de classificação do uso e ocupação do solo na região da sub-bacia do Ribeirão Jirau, localizada nos municípios de Itabira e de Santa Maria de Itabira, no interior de Minas Gerais. Os dois mapeamentos se diferem pelo tipo de dado de entrada utilizado sendo um obtido a partir do uso de bandas espectrais do satélite Sentinel-2A e o outro obtido a partir do uso do resultado do MLME. Utilizou-se uma matriz de erros para analisar os coeficientes de concordância de ambos os resultados e fez-se uma análise da qualidade dos mapeamentos obtidos. Cabe ressaltar que o modelo linear de mistura espectral não deve ser considerado um classificador, mas, uma técnica de transformação de imagem para facilitar a obtenção de informações (Shimabukuro & Ponzoni, 2017).

ÁREA DE ESTUDO

A área de estudo utilizada para este trabalho compreende a região da bacia hidrográfica do Ribeirão Jirau, localizada nos municípios de Itabira e de Santa Maria de Itabira, no interior do estado de Minas Gerais, a cerca de 137 quilômetros da capital do estado (Figura 1).

A região está inserida na sub-bacia hidrográfica do Rio Santo Antônio, pertencente a bacia hidrográfica federal do Rio Doce.

Ao todo, o curso d'água apresenta cerca de 38 quilômetros e a sua bacia possui aproximadamente 28.262 hectares.

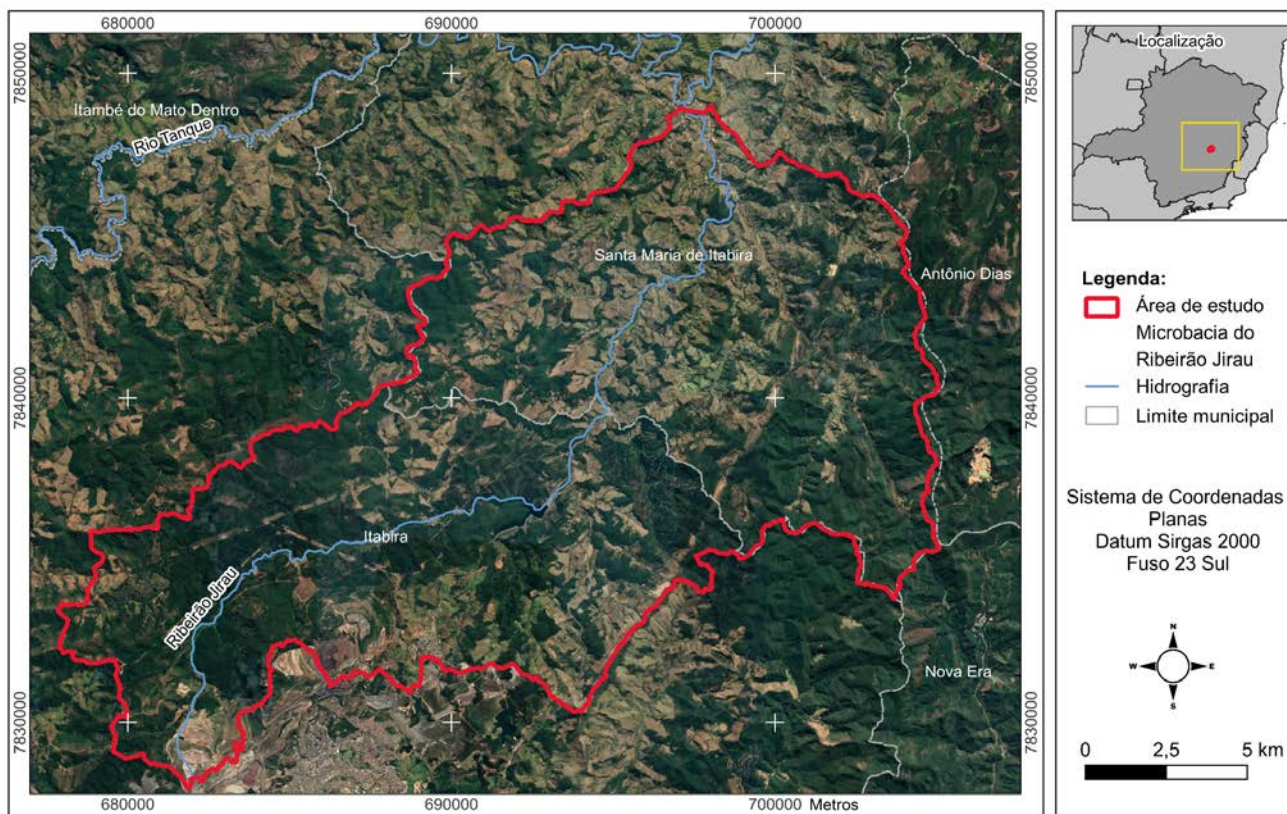


Figura 1 – Mapa de localização da área de estudo, na microbacia do Ribeirão Jirau.

Seu território é caracterizado por relevo acidentado, solos sensíveis e atividade mineradora, fatores estes que contribuem para uma forte suscetibilidade dos solos à erosão (CBH-Santo Antônio, 2022).

A região está inserida no bioma Mata Atlântica e apresenta áreas de remanescente de vegetação nativa, de floresta plantada, principalmente das culturas de eucalipto, pastagem, solo exposto e mineração, sendo está uma forte característica

da parcela inserida no município de Itabira (Itabira, 2018).

A seleção da área de estudo deu-se em função das características locais que permitiam a identificação por meio de imagens de satélites de áreas de vegetação, água e solo exposto necessárias para o desenvolvimento da metodologia proposta no presente trabalho. Além disso, o conhecimento prévio da região também contribuiu para sua seleção.

MATERIAIS E MÉTODOS

Materiais

Para o desenvolvimento deste estudo foram utilizados os materiais detalhados na figura 2. Os dados orbitais do satélite Sentinel-2A foram adquiridos a partir da plataforma *online* de dados da *Copernicus Hub* gerenciada pela Agência Espacial Europeia (*European Space Agency - ESA*) (ESA, 2022).

Foram utilizadas as cenas do nível 2A (L2A dados de reflectância corrigida do fundo da atmosfera), da zona T23KPU, em projeção

UTM/WGS84, capturadas no dia 15 de setembro de 2021.

Selecionou-se as bandas B2 (azul), B3 (verde), B4 (vermelho) e B8 (infravermelho próximo) e realizou-se o empilhamento das referidas bandas e manteve-se para os trabalhos a composição colorida RGB-432. Todos os dados geográficos utilizados neste trabalho foram adequados ao sistema de coordenadas planas, *Universal Transversa de Mercator* (UTM), datum SIRGAS 2000, fuso 23 sul.

Material	Fonte
Limite vetorial da região da bacia do Ribeirão Jirau	ANA (2022)
Imagens orbitais do satélite Sentinel, bandas B2, B3, B4 e B8, sensor MSI, já corrigidas para o nível 2A, coletadas no dia 15/09/2021, zona T23KPU, 100 x 100 km ² , UTM/WGS84	ESA (2022)
Base de dados da Infraestrutura de Dados Espaciais do Sistema Estadual de Meio Ambiente e Recursos Hídricos de Minas Gerais, utilizados para a caracterização da área de estudo	IDE-SISEMA (2022)
<i>Softwares</i> livres: QGIS versão 3.16.8 e TerraAmazon versão 7.3.2	QGIS <i>Development Team</i> (2021), INPE (2021)
Materiais bibliográficos citados durante o presente estudo.	-

Figura 2 - Relação de materiais utilizados para o desenvolvimento do estudo.

Modelo linear de mistura espectral

O modelo linear de mistura espectral é um dos métodos utilizados com maior frequência para análises de mistura espectral (Keshava & Mustard, 2002). O modelo assume que a resposta espectral em cada pixel em qualquer banda espectral é decorrente de uma combinação linear das respostas espectrais de cada componente presente na mistura. Assim, entende-se que conhecendo a proporção dos componentes no elemento de área é possível conhecer a resposta espectral de cada um deles (Shimabukuro & Ponzoni, 2017; Shimabukuro et al., 2020).

Uma das premissas do modelo é a definição

prévia de *endmembers*, que são espectros de referência utilizados durante a modelagem (pixels puros). Assim, a seleção dos *endmembers* exige o conhecimento da resposta espectral destes componentes (Shimabukuro & Ponzoni, 2017; Dutra et al., 2019).

Partindo do pressuposto de que para aplicação de um modelo linear de mistura espectral considera-se que o resultado da resposta espectral de um pixel em qualquer comprimento de onda é uma combinação linear das assinaturas espectrais puras de seus componentes constituintes ponderados pela cobertura fracionada de subpixel entende-se que cada pixel apresenta informações

sobre a proporção e resposta espectral de cada componente dentro da área do pixel (Shimabukuro & Smith, 1991; INPE, 2022). Dessa forma, os autores explicam que em uma imagem multiespectral é possível modelar cada espectro dentro da imagem como uma combinação linear de um conjunto finito de componentes (Shimabukuro & Smith, 1991). O modelo pode ser escrito como:

$$\begin{aligned} r_1 &= a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n + e_1 \\ r_2 &= a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n + e_2 \\ &\dots \\ r_m &= a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n + e_m \end{aligned} \quad (1)$$

As equações podem ser expressas como:

$$r_i = \sum_{j=1}^n (a_{ij}x_j) + e_i \quad (2)$$

Sendo:

i : 1, ..., m (número de bandas);

j : 1, ..., n (número de componentes).

Onde:

r_i : reflectância espectral média para a i -ésima banda espectral;

a_{ij} : reflectância espectral do j -ésimo componente no pixel para a i -ésima banda espectral.

x_j : valor de proporção do j -ésimo componente no pixel; e

e_i : erro para a i -ésima banda espectral.

Como os valores de x_j representam proporções de área dentro de um pixel de cena, as estimativas dos estão sujeitas às seguintes restrições apresentadas nas equações 3 e 4.

$$r_i = \sum_{j=1}^n x_j = 1 \quad (3)$$

$$0 \leq x_j \leq 1 \quad (4)$$

As restrições apresentadas são solucionadas a partir de métodos de programação quadrática

$$r_i = a * veg_i + b * solo_i + c * sombra/água_i + e_i \quad (5)$$

Onde: r_i é a resposta do pixel na banda i ;

a , b e c são as proporções de vegetação, solo e sombra (ou água), respectivamente;

e veg_i , $solo_i$ e $sombra_i$, são as respostas espectrais das componentes vegetação, solo e sombra (ou água), respectivamente;

e_i é o erro na banda i ; e

i indica a banda do sensor (Shimabukuro et al., 1997).

Utilizando a composição colorida, foram selecionados na imagem, a partir de interpretação visual, os pixels mais puros correspondentes aos

(Zanotta et al., 2013). O MLME é formado por um sistema de equações sendo uma equação para cada banda do sensor considerado. Durante a aplicação do método não é necessário que o analista utilize todas as bandas disponibilizadas pelo sensor, mas, é necessário que o número de pixels puros, considerados espectros de referência, seja menor que o número de bandas espectrais utilizadas para a modelagem ($n \leq m$) (Shimabukuro & Ponzoni, 2017).

Para a resolução do modelo e estimativa das proporções é necessário conhecer a reflectância espectral do pixel em cada banda (r_i) e a reflectância espectral de cada componente (a_{ij}) em cada banda. O critério utilizado para a estimativa das proporções é o dos mínimos quadrados onde a estimativa das proporções busca minimizar a soma do quadrado dos erros. Três métodos podem ser aplicados e sua escolha será em função do número de componentes da mistura definido e na opção sobre aplicação da restrição (Shimabukuro & Ponzoni, 2017). Neste estudo utilizou-se o método dos mínimos quadrados com restrição disponível no *software TerraAmazon*. Este método utiliza a minimização da soma dos erros ao quadrado para estimar a proporção de cada componente dentro do pixel. Neste, os resultados dos valores de proporção devem ser não negativos e o seu somatório igual a 1 (um) (Shimabukuro & Ponzoni, 2017).

Para a aplicação do modelo foram utilizados três componentes (água/sombra, vegetação e solo) e as quatro bandas do satélite Sentinel-2A (B2, B3, B4 e B8).

A execução do modelo de mistura gera como resultado imagens fração de cada um dos componentes considerados. A seguir, tem-se a sua representação na Equação 5.

componentes considerados, assim, os *endmembers* foram obtidos diretamente na imagem. A seguir, apresenta-se na figura 3 as amostras utilizadas para o modelo de mistura.

Classificação do uso e ocupação do solo

A classificação do uso e ocupação do solo foi o procedimento realizado para comparação da aplicação do resultado do MLME. Utilizou-se as cenas do Sentinel-2A e as imagens fração geradas do modelo de mistura para se obter dois mapeamentos de classificação do uso e ocupação do solo para as classes de água, floresta



Figura 3 - Demonstração das amostras puras de componentes utilizados para o MLME.

natural, solo exposto, floresta plantada, afloramento rochoso, pastagem, área urbana e mineração. Estes procedimentos foram realizados no *software* QGis utilizando o complemento *Semi-Automatic Classification Plugin* (SCP) que é um *plugin* que permite realizar a classificação semiautomática ou supervisionada a partir de imagens de sensoriamento remoto (Congedo, 2021) e o algoritmo de classificação de mínima distância.

Para treinamento do algoritmo realizou-se a aquisição de quinze amostras para cada cate-

goria, com exceção da classe de Afloramento Rochoso que permitiu a coleta de apenas quatro amostras.

Sendo assim, esta metodologia consiste em utilizar cenas do satélite Sentinel-2A para aplicar o modelo linear de mistura espectral e realizar a classificação do uso do solo na área de estudo a partir dos dados originais do Sentinel-2A e das imagens fração geradas a partir do modelo de mistura e, por fim, avaliar a precisão dos resultados gerados. O resumo da metodologia é apresentado na figura 4.

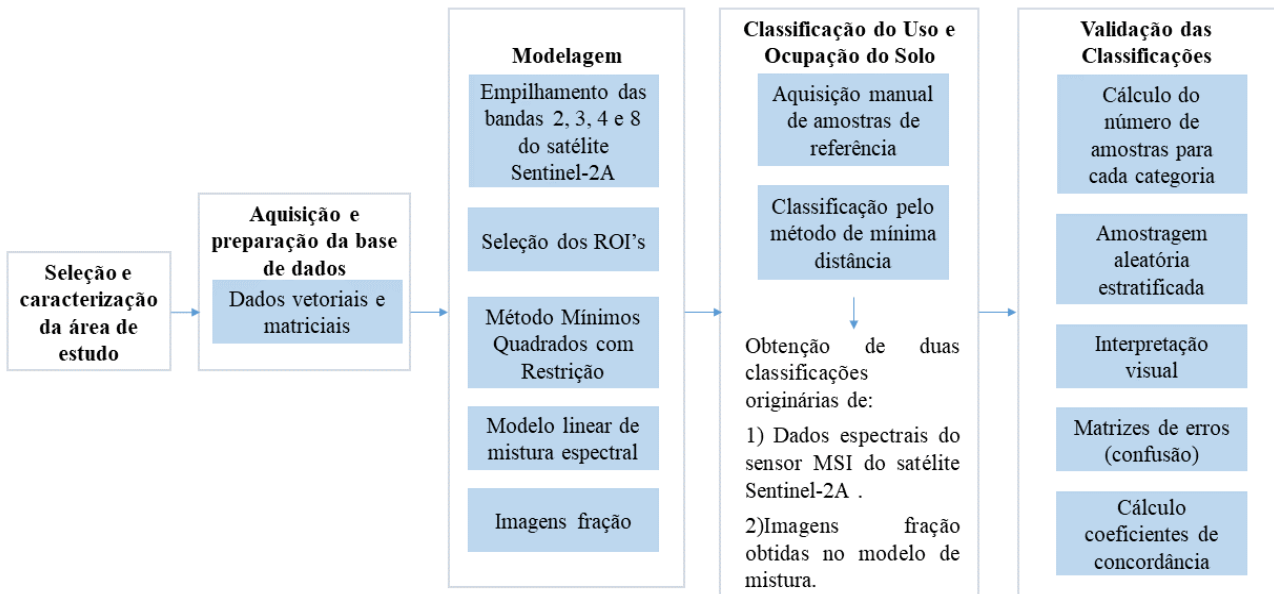


Figura 4 - Fluxograma do processo metodológico utilizado.

Validação das classificações

A validação do procedimento consistiu em quantificar a qualidade dos mapeamentos a partir da avaliação de precisão utilizando os resultados obtidos em uma matriz de confusão. Foram analisados dois dados de entrada: o arquivo raster categórico referente ao mapeamento obtido com as imagens do Sentinel-2A e o arquivo raster categórico referente ao mapeamento obtido a partir das imagens fração do modelo de mistura. A acurácia temática do

mapeamento foi realizada utilizando o *plugin* AcATaMa (*Accuracy Assessment of Thematic Maps*) (Llano, 2021) na interface do *software* QGis sendo necessário definir um projeto de amostragem conforme explicado por Llano (2021).

Considerou-se o pixel como unidade de amostra para a obtenção das amostras de referência que foram obtidas aleatoriamente utilizando a composição colorida do produto Sentinel-2A onde buscou-se pixels puros para

representar cada categoria da classificação. Após a coleta das amostras de referência na imagem realizou-se o cálculo do número de amostras necessárias para validação de cada categoria considerada de uso e ocupação do solo conforme metodologia de distribuição multinomial proposta por Congalton & Green (2009) obtendo 679 amostras de validação para

o mapeamento gerado a partir das cenas multiespectrais e 718 amostras para o mapeamento gerado a partir das imagens fração do MLME. A relação de área e porcentagem de ocupação de cada categoria no espaço analisado bem como o resultado do número de amostras por extrato para cada uma das categorias é apresentada nas figuras 5 e 6.

Classe	Área (h)	Percentual dos Extratos na População	Número de Amostra por Extrato
Corpos d'água	117,52	0,0042	3
Floresta natural	9.597,52	0,3395	231
Solo exposto	266,69	0,0094	6
Floresta plantada	7.226,94	0,2557	174
Afloramento rochoso	1.098,15	0,0388	26
Pastagem	8.081,83	0,2859	194
Área urbana	632,00	0,0224	15
Mineração	1.245,85	0,0441	30

Figura 5 - Tamanho das amostras para a classificação obtida a partir dos dados espectrais do Sentinel-2A.

Classe	Área (h)	Percentual dos Extratos na População	Número de Amostra por Extrato
Corpos d'água	115,03	0,0041	3
Floresta natural	6.171,65	0,2183	157
Solo exposto	704,79	0,0249	18
Floresta plantada	10.928,18	0,3866	278
Afloramento rochoso	1.183,01	0,0419	30
Pastagem	7.645,86	0,2705	194
Área urbana	642,33	0,0227	16
Mineração	875,65	0,0310	22

Figura 6 - Tamanho das amostras para a classificação obtida a partir dos dados espectrais do MLME.

Tendo o número ideal de amostras definido para cada categoria analisada, utilizou-se as ferramentas disponibilizadas pelo *plugin* AcATaMa para se obter a amostragem aleatória estratificada para cada um dos mapeamentos. Os pontos de validação foram então distribuídos na região e rotulados conforme classificação observada na imagem digital considerando a checagem dos pontos por interpretação visual da composição colorida obtida com os dados do Sentinel-2A. Esta fase do trabalho foi ainda auxiliada pelo

conhecimento prévio da região.

O procedimento de indicação das classes para cada ponto foi seguido da análise de acurácia dos mapeamentos obtidos gerando como produto uma matriz de erros para cada uma das duas análises realizadas. Baseado nestes resultados, obteve-se a precisão geral e o índice *Kappa*, que são análises globais da precisão, e as precisões do usuário e do produtor, que são análises que enfatizam a precisão particular de cada categoria da classificação.

RESULTADOS E DISCUSSÕES

O resultado do modelo de mistura pode ser observado nas figuras 7A, B, C, D e E onde apresenta-se cada imagem fração obtida para os componentes solo, vegetação e água/sombra em comparação com a composição colorida das bandas multiespectrais do Sentinel-2A.

As imagens fração indicadas na figura 7 são indicativas dos componentes vegetação (C), solo (D), e água/sombra (E), respectivamente. Observa-se que elas são geradas em escala de tons de cinza onde o valor de cada pixel está associado com as proporções de cada um dos

componentes utilizados no modelo de mistura. Dessa forma, quanto maior for o valor de um pixel em uma imagem fração de um determinado componente, maior será a proporção deste componente dentro do pixel e a sua tonalidade será mais clara (Shimabukuro et al., 2020).

Na figura 7B apresenta-se mais um resultado do modelo de mistura que é uma composição

colorida das imagens fração obtidas. Nesta composição é possível realizar a seleção de um pixel e obter a proporção de cada um dos *endmember*, conforme exemplificado nas figuras a seguir.

Na figura 8 apresenta-se o detalhamento das frações ao selecionar um pixel localizado em área de afloramento rochoso, identificando mistura entre todos os componentes considerados.

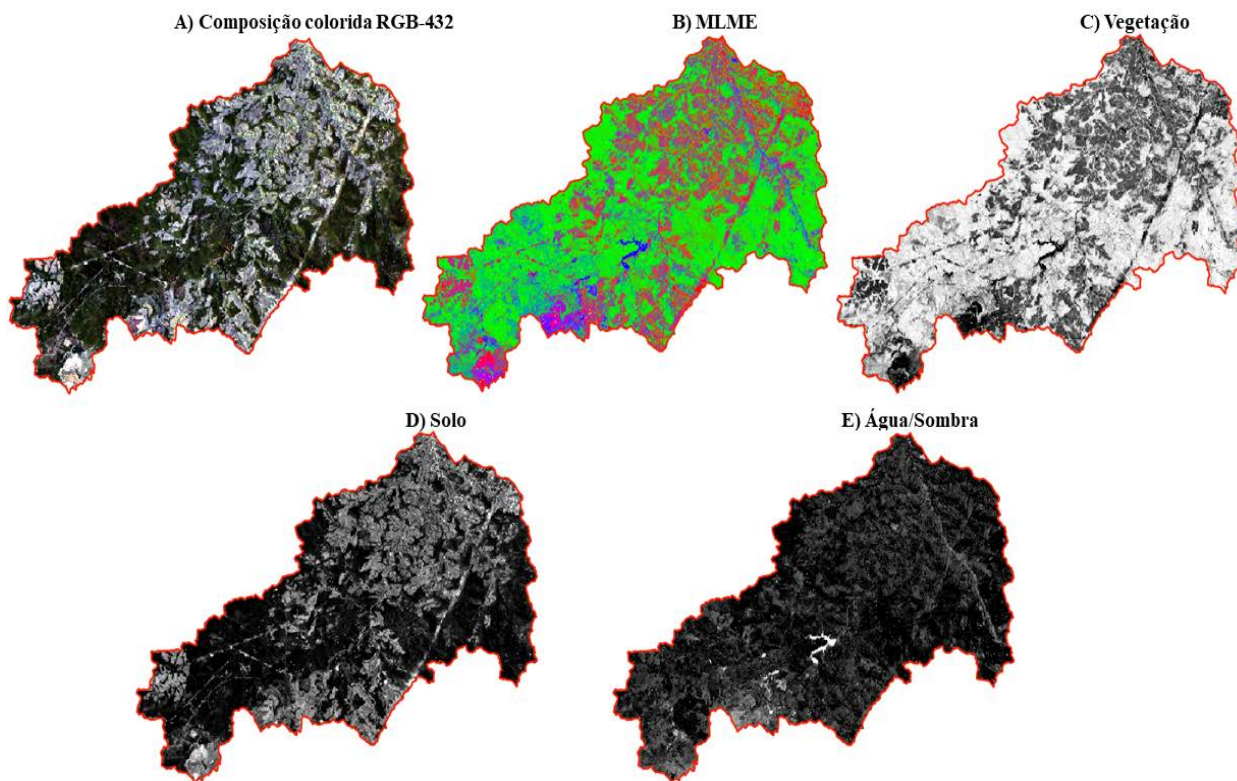


Figura 7 - Figuras das imagens fração. A) Composição colorida RGB-432 do sensor MSI/Sentinel; (B) imagem digital do modelo de mistura; C) imagem fração de vegetação; D) imagem fração do solo; e E) imagem fração de sombra/água.

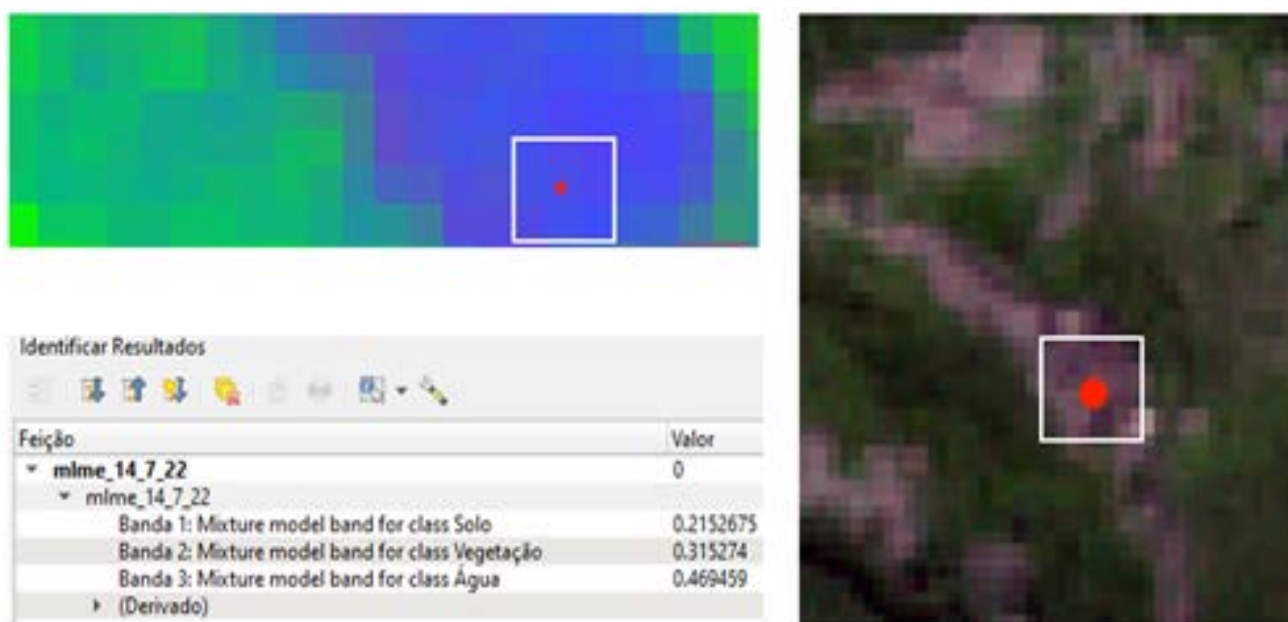


Figura 8 - Seleção de um pixel em área de afloramento rochoso com presença de vegetação para observação do efeito de mistura. Proporções obtidas: 0,21 (solo), 0,31 (vegetação) e 0,46 (água/sombra).

Na figura 9 apresenta-se um exemplo de seleção em área correspondente à presença de vegetação nativa que se localiza fora da região considerada para pixels puros. Neste local foi possível obter pixels com 100% de resposta da vegetação, conforme demonstrado.

Ao observar uma região de solo exposto, provocada pela ação de movimentação de massa na região (Figura 10), identifica-se a mistura entre frações de solo e de vegetação.

A mesma consideração do efeito de mistura é observada para áreas de floresta plantada (Figura 11). Nesta, verifica-se os valores correspondentes à resposta da vegetação e do possível efeito de sombreamento.

Nas figuras 12 e 13 são apresentados os resultados do mapeamento da classificação do uso e ocupação do solo obtido a partir das cenas espectrais do Sentinel-2A e das imagens fração do modelo de mistura.




Figura 9 - Seleção de um pixel em área de vegetação nativa para observação do efeito de mistura sendo obtido 100% de vegetação.




Figura 10 - Seleção de um pixel em área de solo exposto para observação do efeito de mistura. Proporções obtidas: 0,88 (solo), 0,12 (vegetação) e 0,0 (água/sombra).



Figura 11 - Seleção de um pixel em área de floresta plantada para observação do efeito de mistura sendo obtidas frações de vegetação (0,83) e de sombra (0,17).

Como pode ser observado nas figuras 12 e 13, todas as classes consideradas foram mapeadas nos dois processamentos. No entanto, é possível notar diferenças no quantitativo de regiões classificadas para cada categoria. Esta consideração é detalhada na figura 14, onde apresenta-se uma relação das áreas (em hectare) obtidas para cada categoria de classificação.

A partir da relação de áreas obtidas para cada uma das classificações originárias dos dois dados

utilizados (Sentinel-2A e MLME) é possível analisar cada categoria individual e quantitativamente.

Observa-se que a categoria com maior representatividade de área no dado originário do MLME é de floresta plantada, representando cerca de 38% do total classificado. Já nos dados originários do Sentinel-2A esta mesma consideração é observada para a classe de floresta natural que representou cerca de 33% do total classificado.

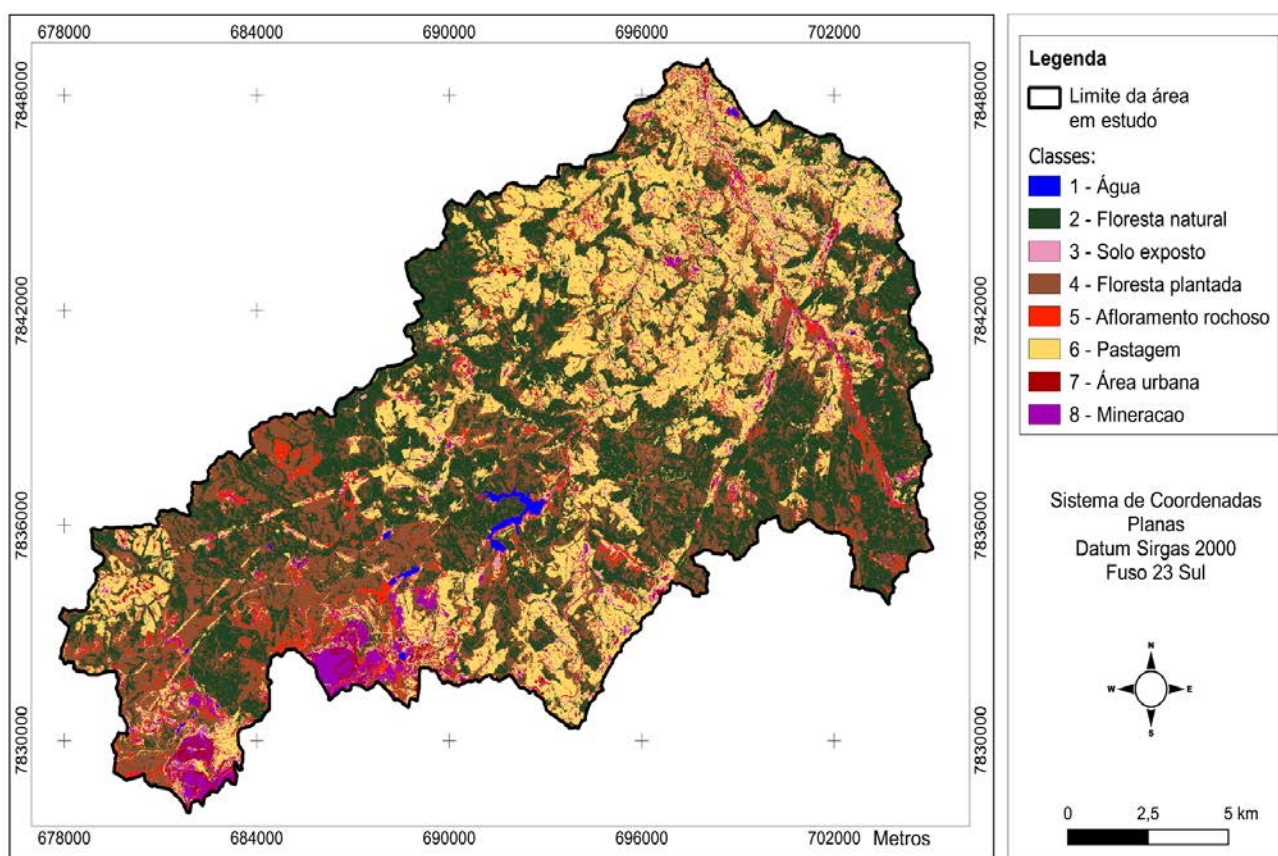


Figura 12 - Mapa de classificação do uso e ocupação do solo gerado a partir das cenas do satélite Sentinel-2A.

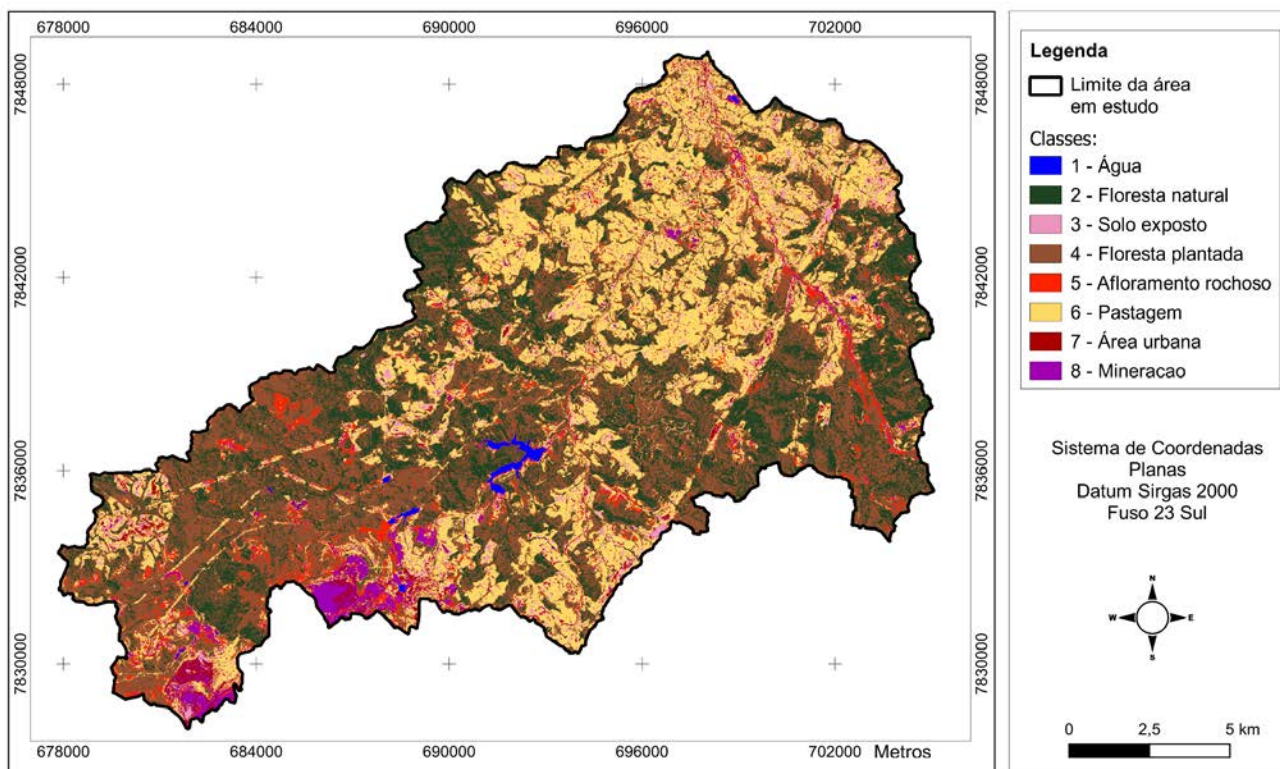


Figura 13 - Mapa de classificação do uso e ocupação do solo gerado a partir do resultado do MLME.

Classe	Código	Classificação MLME		Classificação Sentinel-2A	
		Área (há)	Porcentagem	Área (há)	Porcentagem
Água	1	115,03	0,41%	117,52	0,42%
Floresta natural	2	6.171,65	21,83%	9.597,52	33,95%
Solo exposto	3	704,79	2,49%	266,69	0,94%
Floresta plantada	4	10.928,18	38,66%	7.226,94	25,57%
Afloramento rochoso	5	1.183,01	4,19%	1.098,15	3,88%
Pastagem	6	7.645,86	27,05%	8.081,83	28,59%
Área urbana	7	642,33	2,27%	632,00	2,24%
Mineração	8	875,65	3,10%	1.245,85	4,41%

Figura 14 - Relação de áreas para cada categoria classificada.

As demais categorias analisadas (água, solo exposto, afloramento rochoso, pastagem, área urbana e mineração) apresentaram menor divergência de área entre as duas classificações obtidas (Figura 15).

Código	Classe
1	Água
2	Floresta natural
3	Solo exposto
4	Floresta plantada
5	Afloramento rochoso
6	Pastagem
7	Área urbana
8	Mineração

Figura 15 - Códigos representativos das classes

A partir do raster referente aos dois mapas gerados foi realizado o procedimento de análise de precisão para as duas classificações. Como resultado, obteve-se as matrizes de confusão apresentadas nas figuras 16 e 17.

Ressalta-se que para esta análise, deve-se considerar os códigos de classes indicados na figura 15.

A precisão geral para as classificações originárias dos dados do Sentinel-2A e do MLME foi de 65% e 62%, respectivamente. Esta informação revela a proporção de dados classificados corretamente e indica um melhor desempenho para os dados classificados a partir do Sentinel-2A. Já o coeficiente *Kappa*, que utiliza maior representatividade de dados da matriz para o seu

cálculo, apresentou resultado de 0,53 para a classificação obtida a partir dos dados espectrais

do satélite e 0,62 para a classificação obtida a partir do modelo de mistura.

		Valores Classificados									Precisão do
		1	2	3	4	5	6	7	8	Total	Usuário
Classes do raster temático	1	3	0	0	0	0	0	0	0	3	1,00
	2	0	186	0	38	0	7	0	0	231	0,81
	3	0	0	5	0	0	1	0	0	6	0,83
	4	0	91	0	66	2	14	0	1	174	0,38
	5	2	4	2	4	6	4	0	4	26	0,23
	6	0	1	10	3	1	166	4	9	194	0,86
	7	0	0	1	1	0	3	2	8	15	0,13
	8	0	1	5	0	1	8	1	14	30	0,47
Total		5	283	23	112	10	203	7	36	679	Precisão geral: 0,65
Precisão do Produtor		0,60	0,66	0,22	0,59	0,60	0,82	0,29	0,39		Kappa: 0,53

Figura 16 - Matriz de confusão gerada a partir da análise de precisão dos dados do Sentinel-2A.

		Valores Classificados									Precisão do
		1	2	3	4	5	6	7	8	Total	Usuário
Classes do raster temático	1	3	0	0	0	0	0	0	0	3	1,00
	2	0	141	0	15	0	1	0	0	157	0,90
	3	0	1	13	1	0	0	2	1	18	0,72
	4	0	172	1	78	0	27	0	0	278	0,28
	5	1	7	0	5	8	7	0	2	30	0,27
	6	0	1	3	1	0	186	1	2	194	0,96
	7	0	0	5	0	0	5	5	1	16	0,31
	8	0	0	6	0	0	8	0	8	22	0,36
Total		4	322	28	100	8	234	8	14	718	Precisão geral: 0,62
Precisão do Produtor		0,75	0,44	0,46	0,78	1,00	0,79	0,63	0,57		Kappa: 0,62

Figura 17 - Matriz de confusão gerada a partir da análise de precisão dos dados do MLME.

Considerando que o valor do coeficiente *Kappa* representa a concordância do dado classificado com o dado de referência, percebe-se que o dado classificado a partir do MLME apresentou maior concordância, pois, encontra-se mais próximo do valor 1 da escala de

referência utilizada (de 0 a 1 sendo 0 nenhuma concordância e 1 concordância completa). Para interpretação deste valor, comparou-se os valores obtidos com as referências identificadas na bibliografia e, tendo como base as considerações apresentadas por Congalton & Green (2019),

Fleis et al. (1969) ambas as classificações apresentam concordância moderada, suficientemente boa ou boa.

Analisando individualmente as classes consideradas para o resultado obtido a partir dos dados multiespectrais do satélite Sentinel-2A verifica-se que para a classe de Água (1) o valor de unidade de amostra de referência foi de três amostras e todas elas foram confirmadas com os dados de referência resultando em 100% de acurácia do usuário. No entanto, esta classificação gerou cinco unidades de amostra classificadas com este código, revelando que duas das áreas classificadas a partir dos dados de sensoriamento remoto como Água (1) eram, na verdade, áreas de afloramento rochoso conforme observações de referência. Assim, para a categoria de água a análise resultou em 60% de acurácia do produtor, tendo 40% das unidades amostrais classificadas como Água (1) pertencentes a outra categoria.

Para a classe de Floresta Natural (2) foram avaliadas 231 unidades amostrais. Destas, 186 foram corretamente classificadas e um total de 283 foram consideradas nesta categoria conforme o resultado da classificação do dado de sensoriamento remoto resultando em 66% de acurácia do produtor (unidades amostrais classificadas corretamente) e 81,5% de acurácia do usuário (proporção de unidades amostrais de floresta natural na classificação que são desta categoria conforme dados de referência). Para a categoria de Floresta Natural (2) observou-se que 97 unidades amostrais do mapa de classificação foram incluídas nesta categoria (erro de comissão) e 45 unidades de amostra consideradas pelo dado de referência como sendo pertencentes a esta categoria foram classificadas como sendo de Floresta Plantada (4) (38 unidades de amostra) e Pastagem (6) (7 unidades de amostra), revelando assim os erros de omissão.

Para a classe de Solo Exposto (Cód. 3) foram utilizadas seis unidades de amostras. Destas, cinco foram classificadas corretamente e uma incluída na classe de Pastagem (Cód. 6). Nesta categoria o mapa de classificação considerou 23 unidades amostrais, sendo: duas unidades amostrais de Afloramento Rochoso (Cód. 5), dez de Pastagem (Cód. 6), uma de Área Urbana (Cód. 7) e cinco de Mineração (Cód. 8). Esta categoria teve 22% de precisão do produtor, mostrando baixa relação de unidades amostrais classificadas corretamente e 83% de precisão do usuário.

Para a classe de Floresta Plantada (Cód. 4), 66

das 174 unidades amostrais consideradas foram classificadas corretamente, resultando em 38% de precisão do usuário. Já nos valores classificados, 112 unidades amostrais foram incluídas nesta categoria, obtendo assim 59% de precisão do produtor. De acordo com os valores classificados e os dados de referência, 38 unidades de amostra de Floresta Natural (Cód. 2), quatro de Afloramento Rochoso (Cód. 5), três de Pastagem (Cód. 6) e uma de Área Urbana (Cód. 7) foram incluídas na categoria de Floresta Plantada (Cód. 4). Considerando os erros de omissão, observou-se duas amostras da categoria de Afloramento Rochoso (Cód. 5), 14 de Pastagem (Cód. 6) e 1 de Mineração (Cód. 8).

Para a classe de Afloramento Rochoso (Cód. 5) foram utilizadas 26 unidades amostrais das quais seis foram corretamente classificadas. A categoria obteve 23% de precisão do usuário e 60% de precisão do produtor. De acordo com a classificação, duas amostras de Floresta Plantada (Cód. 4), uma de Pastagem (Cód. 6) e uma de Mineração (Cód. 8) foram incluídas nesta categoria (erros de comissão) e, considerando as amostras de referência, foram omitidas da classe de afloramento rochoso duas amostras classificadas como Água (Cód. 1), quatro amostras classificadas como Floresta Natural (Cód. 2), duas amostras classificadas como Solo Exposto (Cód. 3), quatro classificadas como Floresta Plantada (Cód. 4), quatro classificadas como Pastagem (Cód. 6) e quatro classificadas como Mineração (Cód. 8).

Para a categoria de Pastagem (Cód. 6) foram utilizadas 194 unidades amostrais. Destas, 166 foram classificadas corretamente enquanto que 1 foi incluída na classe de Floresta Natural (Cód. 2), dez na classe de Solo Exposto (Cód. 3), três na classe de Floresta Plantada (Cód. 4), uma na classe de Afloramento Rochoso (Cód. 5), quatro na classe de Área Urbana (Cód. 7) e nove na classe de Mineração (Cód. 8). No resultado da classificação foram incluídas nesta categoria sete unidades amostrais de Floresta Natural (Cód. 2), uma de Solo Exposto (Cód. 3), 14 de Floresta Plantada (Cód. 4), quatro de Afloramento Rochoso (Cód. 5), três de Área Urbana (Cód. 7) e oito de Mineração (Cód. 8), resultando em 203 amostras do mapa classificadas nesta categoria. A classe de Pastagem (Cód. 6) obteve 82% de precisão do produtor e 86% de precisão do usuário.

Para a classe de Área Urbana (Cód. 7) foram

consideradas quinze unidades amostrais das quais duas foram classificadas corretamente enquanto que as demais eram, conforme dados de referência: uma Solo Exposto (Cód. 3), uma Floresta Plantada (Cód. 4), três Pastagem (Cód. 6) e oito Mineração (Cód. 8). A classificação incluiu na categoria de Área Urbana (Cód. 7) quatro amostras de Pastagem (Cód. 6) e uma de Mineração (Cód. 8). Esta categoria obteve 13% de precisão do usuário e 29% de precisão do produtor.

Por fim, para a classe de Mineração (Cód. 8) foram consideradas 30 unidades amostrais sendo catorze classificadas corretamente. As demais amostras eram referentes às classes de Floresta Natural (Cód. 2) (uma amostra), Solo Exposto (Cód. 3) (cinco amostras), Afloramento Rochoso (Cód. 5) (uma amostra), Pastagem (Cód. 6) (oito amostras) e Área Urbana (Cód. 7) (uma amostra). O resultado da classificação incluiu na classe de Mineração (Cód. 8) uma amostra de Floresta Plantada (Cód. 4), quatro de Afloramento Rochoso (Cód. 5), nove de Pastagem (Cód. 6) e oito de Área Urbana (Cód. 7). Para esta categoria obteve-se 47% de precisão do usuário e 39% de precisão do produtor.

Analisando individualmente as classes consideradas para o resultado obtido a partir dos dados do modelo de mistura espectral (imagens fração) verifica-se que para a classe de Água (Cód. 1) também foram utilizadas três unidades amostrais sendo todas elas corretamente classificadas e, portanto, com precisão do usuário de 100%. No entanto, no arquivo classificado foi incluída nesta categoria uma amostra de Afloramento Rochoso (Cód. 5), gerando assim 75% de precisão do produtor.

Para a categoria de Floresta Natural (Cód. 2) foram utilizadas 157 unidades amostrais sendo 141 classificadas corretamente, quinze omitidas e incluídas na classe de Floresta Plantada (Cód. 4) e uma na classe de Pastagem (Cód. 6) resultando em uma precisão do usuário de 90% para a categoria. Os resultados da classificação incluíram nesta classe uma amostra de Solo Exposto (Cód. 3), 172 amostras de Floresta Plantada (Cód. 4), sete amostras de Afloramento Rochoso (Cód. 5) e uma amostra de Pastagem (Cód. 6), resultando em 322 unidades amostrais incluídas nesta categoria conforme o resultado da classificação e 44% de precisão do produtor.

Para a categoria de Solo Exposto (Cód. 3) foram utilizadas 18 unidades amostrais das quais treze foram corretamente classificadas, uma

omitida para a classe de Floresta Natural (Cód. 2), uma para Floresta Plantada (Cód. 4) e duas para Área Urbana (Cód. 7) e uma para Mineração (Cód. 8). Foram incluídas nesta categoria, conforme dados classificados, uma amostra de Floresta Plantada (Cód. 4), três amostras de Pastagem (Cód. 6), cinco de Área Urbana (Cód. 7) e seis de Mineração (Cód. 8). Para esta categoria obteve-se 72% de precisão do usuário e 46% de precisão do produtor.

Para a categoria de Floresta Plantada (Cód. 4) foram consideradas 278 unidades amostrais sendo 78 classificadas corretamente. 172 amostras desta classe foram confundidas com Floresta Natural (Cód. 2), uma com Solo Exposto (Cód. 3) e 27 com Pastagem (Cód. 6). Foram incluídas nesta categoria quinze amostras de Floresta Natural (Cód. 2), uma de Solo Exposto (Cód. 3), cinco de Afloramento Rochoso (Cód. 5) e uma de Pastagem (Cód. 6). Esta categoria resultou em 28% de precisão do usuário e 78% de precisão do produtor.

Para a categoria de Afloramento Rochoso (Cód. 5) foram consideradas 30 unidades amostrais sendo oito classificadas corretamente e não foram incluídas amostras de outras classes nesta categoria resultando em 100% de precisão do produtor.

No entanto, outras unidades amostrais de afloramento rochoso foram classificadas no mapeamento como Floresta Plantada (Cód. 4) (cinco unidades), Floresta Natural (Cód. 2) (sete unidades), Água (Cód. 1) (uma unidade), Pastagem (Cód. 6) (sete unidades) e Mineração (Cód. 8) (duas unidades), resultando em 27% de precisão do usuário.

Para a categoria de Pastagem (Cód. 6) foram consideradas 194 unidades amostrais sendo 186 classificadas corretamente. As demais unidades foram confundidas com as classes de Floresta Natural (Cód. 2) (uma unidade), Solo Exposto (Cód. 3) (três unidades), Floresta Plantada (Cód. 4) e Área Urbana (Cód. 7) (uma unidade em cada) e Mineração (Cód. 8) (duas unidades). Foram incluídas nesta categoria uma unidade de Floresta Natural (Cód. 2), 27 de Floresta Plantada (Cód. 4), sete de Afloramento Rochoso (Cód. 5), cinco de Área Urbana (Cód. 7) e oito de Mineração (Cód. 8). Esta categoria resultou em 96% de precisão do usuário e 79% de precisão do produtor.

Para a categoria de Área Urbana (Cód. 7) foram consideradas 16 unidades amostrais sendo cinco classificadas corretamente. As demais

amostras foram classificadas como Solo Exposto (Cód. 3) e Pastagem (Cód. 6), sendo cinco unidades cada e Mineração (Cód. 8) com uma unidade. Foram incluídas nesta categoria duas unidades amostrais de Solo Exposto (Cód. 3) e uma de Pastagem (Cód. 6). Obteve-se 31% de precisão do usuário e 63% de precisão do produtor.

Por fim, para a categoria de Mineração (Cód. 8) foram consideradas 22 unidades amostrais sendo oito delas classificadas corretamente e as demais confundidas com as categorias de Solo Exposto (Cód. 3) (seis unidades) e Pastagem

(Cód. 6) (oito unidades). Além disso, foram incluídas nesta categoria uma unidade amostral de Solo Exposto (Cód. 3) e de Área Urbana (Cód. 7) e duas unidades de Afloramento Rochoso (Cód. 5) e de Pastagem (Cód. 6). Obteve-se 36% de precisão do usuário e 57% de precisão do produtor.

Buscando ainda melhorar a comparação de ambos os mapeamentos, nas figuras 18 e 19 apresenta-se as precisões dos dois resultados juntos tornando possível a visualização das diferenças identificadas entre o resultado gerado a partir das cenas espectrais e das imagens fração.

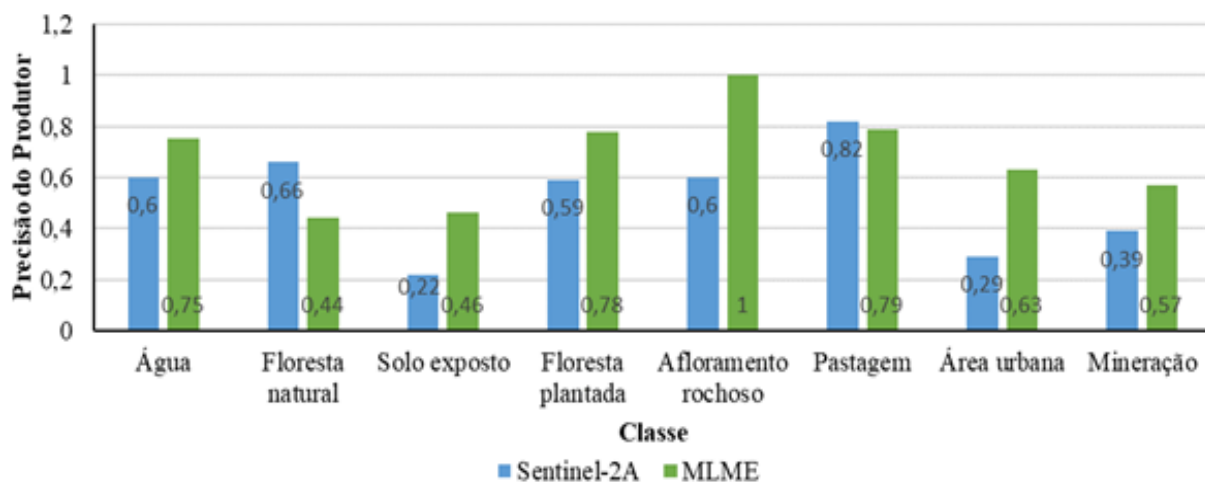


Figura 18 - Comparação entre os resultados de precisão do produtor.

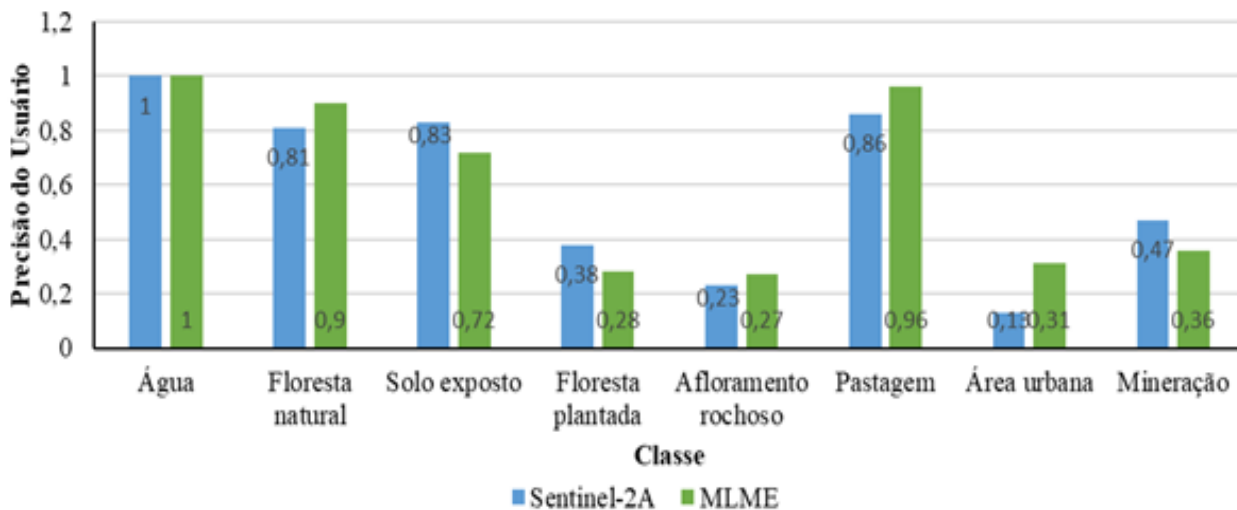


Figura 19 - Comparação entre os resultados de precisão do usuário.

Considerando os resultados apresentados, verifica-se que as imagens fração obtidas a partir do modelo linear de mistura espectral resultaram em arquivos digitais que destacaram adequadamente as áreas dos componentes de analisados no modelo (solo, vegetação e água/sombra), deixando estas regiões apresentadas com pixels de maior abundância e tonalidades mais claras em cada imagem fração correspondente.

Ao observar o arquivo de composição das três imagens fração obtidas no modelo verifica-se

ainda que o processamento utilizado de fato resultou em frações de composição de cada componente considerado, podendo ser possível identificar aquele de maior predominância dentro do pixel.

Os dois tipos de dados considerados para a classificação do uso e ocupação do solo mostraram-se funcionais para o processamento realizado, no entanto, os seus respectivos resultados evidenciam, até mesmo com uma breve análise visual, diferenças de classificação ao comparar

os dois mapeamentos. Esta divergência é notória principalmente para as classes de floresta plantada e de floresta natural dado que as respectivas representatividades de ocupação da área revelam maiores diferenças, tendo o resultado originário do Sentinel-2A maior representatividade da classe de floresta natural (33,95%) e o resultado originário do MLME maior representatividade da classe de floresta plantada (38,66%).

Pode-se considerar que apenas a análise quantitativa de representação do total de área classificada não é suficiente para se obter considerações dos dois dados de entrada utilizados para o processo de classificação. Assim, a análise dos coeficientes de concordância obtidos a partir da matriz de erros permitiu investigar profundamente a precisão dos dois mapeamentos, em condições gerais e específicas para cada classe.

Segundo Osgouei et al. (2019), as classificações originárias de imagens de satélite apresentam desempenhos melhores, com precisão acima de 85%, quando se trabalha apenas com as principais classes de cobertura do solo como vegetação, solo e água. Ao se considerar outras classes que contemplam regiões mais heterogêneas, como é o caso deste estudo, obter melhores precisões torna-se um desafio visto que as semelhanças espectrais e espaciais e a heterogeneidade das áreas dificultam a classificação. Os desafios são justificados ainda pela deficiência na obtenção de amostras de treinamento, elevando as dificuldades de classificação de dados de sensoriamento remoto independente do algoritmo que se esteja fazendo o uso.

De acordo com as duas matrizes de erros obtidas, a classificação gerada a partir das bandas espectrais do Sentinel-2A gerou melhor desempenho de precisão do usuário para as classes de água (100%), floresta natural (81%), solo exposto (83%) e pastagem (86%), assim, estas são as probabilidades de um pixel classificado no mapeamento de fato representar estas respectivas categorias conforme análise do dado de referência. A classe que apresentou menor desempenho foi a de área urbana (13%), que teve parte de suas amostras classificadas principalmente como mineração (aproximadamente 53%).

Considerando a precisão do produtor, que faz relação com as amostras que não foram corretamente classificadas como pertencendo à categoria analisada e omitidas de suas devidas categorias, este mapeamento revelou melhor desempenho para a classe de pastagem (82%) e piores

desempenhos para as classes de solo exposto (22%) e novamente de área urbana (29%).

Analisando a matriz de erros obtida para a classificação originada do resultado do modelo linear de mistura espectral, a classe de água novamente se destaca com 100% de precisão do usuário, seguida pelo bom desempenho das classes de floresta natural (90%) e pastagem (96%). Neste mapeamento, a precisão do produtor resultou em maior valor para a classe de afloramento rochoso (100%), já que o mapeamento não incluiu nenhuma outra amostra de outra categoria como sendo de afloramento rochoso, pastagem com 79% e floresta plantada com 78%.

Nos mapas de classificação e figuras do quantitativo de área e de representatividade de cada classe considerada foi verificada a existência de maior divergência entre as classes de floresta natural e de floresta plantada. A análise da matriz de erros revelou que o mapeamento gerado a partir dos dados do modelo de mistura resultou em melhor classificação para a categoria de floresta plantada pois houve uma menor representatividade de amostras de outra categoria que foram incluídas nesta classificação. No entanto, 62% das amostras consideradas para a validação foram confundidas com a classe de floresta plantada.

Para a categoria de floresta natural a matriz de erros revelou que o mapeamento gerado a partir dos dados do modelo de mistura resultou em melhor desempenho de classificação já que 90% das amostras analisadas realmente pertenciam a esta categoria (precisão do usuário) enquanto que no mapeamento gerado a partir do dado de satélite esta análise resultou em 81%. No entanto, o mapeamento obtido nos dados espectrais do Sentinel-2A incluiu uma menor representatividade de outras categorias nesta classificação.

Para a categoria de floresta plantada, observou-se que o melhor desempenho foi para o dado originário das cenas de satélite (38% das amostras classificadas corretamente), enquanto que para o segundo mapeamento essa precisão foi de 28%. Cabe ressaltar que esta categoria apresentou maior confusão tendo a maior parte das amostras analisadas omitidas desta categoria e incluídas na categoria de floresta natural para os dois resultados.

Segundo Zanotta et al. (2013), os erros de classificação obtidos a partir das imagens fração pode estar associados aos *endmembers* selecionados para o modelo já que o resíduo do MLME

pode ser representativo também de membros finais ausentes. A qualidade da classificação obtida para ambos os dados de entrada pode ser influenciada também pela deficiência das amostras de referência e de validação já que todo o processo foi desenvolvido tendo como base a composição colorida da imagem multiespectral.

Cabe destacar também a categoria de área urbana que normalmente apresenta desafios para a sua adequada classificação já que a heterogeneidade característica desta área dificulta o desempenho dos classificadores e, para o mapeamento obtido a partir dos resultados do MLME esta

categoria apresentou maior desempenho de classificação quanto comparada com os dados das cenas dos satélites, sendo 31% e 13% das amostras classificadas corretamente, respectivamente. O mapeamento do modelo também se mostrou mais eficiente ao incluir menos amostras de outras categorias nesta classe.

Contudo, cabe ressaltar que a qualidade do mapeamento para cada categoria individualizada gerado a partir de dados espectrais pode ser influenciada ainda pelo tipo de componente analisado uma vez que alguns objetos apresentam respostas bem específicas (Osgouei et al., 2019).

CONCLUSÕES

Os resultados obtidos neste trabalho demonstram a funcionalidade da aplicação de imagens fracionadas derivadas de um modelo linear de mistura espectral como subsídio à classificação do uso e ocupação do solo sendo uma complementação para técnicas de classificação convencionais que empregam apenas as cenas multiespectrais de satélites para a aplicação de algoritmos de classificação.

O resultado do modelo de mistura que é fornecido através de imagens fração de cada componente considerado para a modelagem indica que de fato a metodologia evidencia os componentes da área de estudo a partir da abundância do componente obtido em cada elemento de área. Neste estudo foi possível observar que as áreas de vegetação, solo e água foram destacadas em suas respectivas imagens fração. Ambos os arquivos de entrada utilizados para a classificação do uso e ocupação do solo

resultaram em mapeamentos de qualidade moderada, suficientemente boa ou boa conforme avaliação do coeficiente *Kappa*. Verificou-se que as análises de acurácia geral não apresentaram grandes variações entre os dois resultados, diferentemente do que foi observado para as precisões individuais de cada categoria.

O estudo apresentado pode ser melhorado a partir do uso de dados de referência coletados em campo ou com imagens digitais de melhor resolução espacial permitindo melhor confiabilidade durante a validação.

Em síntese, o estudo do uso e ocupação do solo é de grande relevância para auxílio em práticas de gestão territorial. A aplicação de imagens digitais de sensoriamento remoto para este tipo de análise contribui para a possibilidade de alcance de grandes áreas territoriais e para a obtenção de informações detalhadas que variam de acordo com a melhoria dos sensores.

REFERÊNCIAS

- CBH-SANTO ANTÔNIO - Comitê de Bacia Hidrográfica do Rio Santo Antônio.
- CHENG, G.; XIE, X. HAN, J.; GUO, L.; XIA, GS. **Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities**. ArXiv, 2020.
- CONGALTON, R.G. & GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 2nd Edition, Lewis Publishers, Boca Raton, 2009.
- CONGALTON, R.G. GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 3a Ed.; Nova York, Boca Raton: CRC Press, 328 p.; 2019.
- CONGEDO, L **Semi-Automatic Classification Plugin Documentation**, 2016.
- DUTRA, A.C.; SHIMABUKURO, Y.E.; ARAI, E. Linear Spectral Mixing Model Applied in Images from PROBA-V SENSOR: a spatial multiresolution approach. Universidade Federal do Paraná. **Raega - O Espaço Geográfico em Análise, Curitiba**, v. 46, n. 3, p. 48-62, 2019.
- ESA. European Space Agency. **Sentinel-2 MSI User Guide**.
- ESA. European Space Agency. **Copernicus Open Access Hub**.
- ESA. European Space Agency. **Sentinel-2**.
- FLEISS, J.L.; COHEN, J.; EVERITT, B.S. Large sample standard errors of kappa and weighted kappa. *American Psychological Association (APA)*. **Psychological Bulletin**, v. 72, n. 5, p. 323-327, nov. 1969.
- INPE. **Modelos de Mistura**, 2022
- INPE. **TerraAmazon** Copyright (c) 2005-2018 INPE. 2022.
- ITABIRA. Plano de Manejo da Área de Proteção Ambiental Municipal Santo Antônio. Encarte 1. Itabira, MG, 2018, 412 p.
- KESHAVA, N.; MUSTARD, J. F. Spectral unmixing. **IEEE signal processing magazine**, v. 19, n. 1, p. 44-57, 2002.
- LLANO, X. C. SMByC-IDEAM. AcATaMa - **QGIS plugin for Accuracy Assessment of Thematic Maps**, 2021.
- MOKHTARI, A.; NOORY, H.; POURSHAKOURI, F.; HAGHIGHATMEHR, P.; AFRASIABIAN, Y.; RAZAVI, M.; FERAYDOONI, F.; NAENI, A. S. Calculating potential evapotranspiration and single crop coefficient based on energy balance equation using Landsat 8 and Sentinel-2. **Journal of Photogrammetry and Remote Sensing**, v. 154, p. 231-245, ago. 2019. Elsevier BV.
- OSGOUEI, P. E.; KAYA, S.; SERTEL, E.; ALGANCI, U. Separating Built-Up Areas from Bare Land in Mediterranean Cities Using Sentinel-2A Imagery. *MDPI AG*. **Remote**

- Sensing**, v. 11, n. 3, p. 345, 10 fev. 2019.
- PEREIRA, L. E.; LASTORIA, G.; PARANHOS FILHO, A. C.; MARCATO JÚNIOR, J. Application Techniques of Digital Image Processing in Different Orbital Sensors. **Anuário do Instituto de Geociências - UFRJ**, v. 39, n. 3, p. 15, 12 set. 2016.
- QGIS Development Team, **QGIS Geographic Information System**. Open-Source Geospatial Foundation Project. 2021.
- RADOČAJ, D.; OBHOĐAL, J.; JURILIĆ, M.; GALPAROVIĆ, M. Global Open Data Remote Sensing Satellite Missions for Land Monitoring and Conservation: a review. **MDPI AG. Land**, v. 9, n. 11, p. 402, 23 out. 2020.
- SHIMABUKURO, Y.E. & SMITH, J.A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. Institute of Electrical and Electronics Engineers (IEEE). **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16– 20, 1991.
- SHIMABUKURO, Y.E. & PONZONI, F.J. **Mistura Espectral: modelo linear e aplicações**. São Paulo: Oficina de Textos, 2017. 127 p.
- SHIMABUKURO, Y.E.; MELLO, E.M.K.; MOREIRA, J.C.; DUARTE, V. **Segmentação e classificação da imagem sombra do modelo de mistura para mapear desflorestamento na Amazônia**. São José dos Campos: INPE, 1997. 24 p. Republicado em 12-05-2010 por causa de acerto na numeração de controle da capa. (INPE-6147-PUD/83).
- SHIMABUKURO, Y.E.; DUTRA, A.C.; ARAI, E. Modelo Linear de Mistura Espectral: Conceitos Teóricos, Algoritmos e Aplicações em Estudos na Amazônia Legal. EDUFU - Editora da Universidade Federal de Uberlândia. **Revista Brasileira de Cartografia**, v. 72, p. 1140-1169, 30 dez. 2020
- SILVA, R.C.B.A. Revisão da Realidade Brasileira em Termos da Aplicabilidade de Pequenos Satélites para Missões de Sensoriamento Remoto. In: CONGRESSO AEROESPACIAL BRASILEIRO, 1º Foz do Iguaçu, 2018. Actas...Foz do Iguaçu, 2018, Edição Especial Plêiade.
- ZANOTTA, D.C.; HAERTEL, V.; SHIMABUKURO, Y. E.; RENNO, C. D. Linear Spectral Mixing Model for Identifying Potential Missing Endmembers in Spectral Mixture Analysis. Institute of Electrical and Electronics Engineers (IEEE). **Ieee Transactions on Geoscience and Remote Sensing**, v. 52, n. 5, p. 3005-3012, maio 2014.

Submetido em 23 de março de 2023

Aceito para publicação em 30 de novembro de 2023