

AVALIAÇÃO DOS VALORES DE ERRO DO MODELO LINEAR DE MISTURA ESPECTRAL EM IMAGENS ETM+/LANDSAT 7 A PARTIR DE REAMOSTRAGENS PELO VIZINHO MAIS PRÓXIMO E CONVOLUÇÃO CÚBICA

EVALUATION OF THE ERROR VALUES OF THE SPECTRAL MIXTURE LINEAR MODEL IN ETM+/LANDSAT 7 IMAGES FROM RESEARCH BY THE NEAREST NEIGHBORHOOD AND CUBIC CONVOLUTION

Guilherme Zavatti CECCATO, Nilcilene das Graças MEDEIROS, José Marinaldo GLERIANI, Julio Cesar de OLIVEIRA

Universidade Federal de Viçosa. Av. Peter Henry Rolfs, s/n - Campus Universitário, Viçosa - MG. E-mail: gzceccato@gmail.com; nilcilene.medeiros@ufv.br; gleriani@ufv.br; oliveirajc@ufv.br

Introdução

Dados livres e características das imagens
Modelo Linear de Mistura Espectral

Metodologia

Localização e caracterização da área de estudo
Materiais utilizados
Métodos

Resultados e discussão

Conclusão

Agradecimentos

Referências

RESUMO - Este trabalho comparou a influência de dois tipos de reamostragens em imagens orbitais quais sejam a do método do vizinho mais próximo e a da convolução cúbica, por meio do uso do modelo linear de mistura espectral (MLME). A cena ETM+/Landsat 7, originalmente, disponibilizada pelo método do vizinho mais próximo, teve sua reamostragem alterada para convolução cúbica, incitando a discussão se essa alteração, em face da mudança dos valores de números digitais, influenciaria na classificação das imagens. Assim, para esta análise foram extraídas 30 amostras aleatórias e 30 amostras manuais das áreas de transição das frações nas imagens erro (B3, B4 e B5) de cada modelo resultante, e aplicou-se o teste *t* de *Student* pareado para médias. Os resultados estatísticos comprovaram, que não existem evidências suficientes, a um nível de significância de 5%, de que a média dos valores de erro das imagens geradas pelos dois métodos de reamostragem no modelo linear de mistura espectral são diferentes, indicando que a aplicação do modelo e da análise de suas frações para futuras classificações não serão influenciadas utilizando-se desta metodologia. Ademais, a classificação supervisionada das imagens e das frações, para ambas reamostragens, constataram que por meio da matriz de confusão, com média de 99% de exatidão global, as classificações são praticamente idênticas, legitimando que a aplicação de diferentes reamostragens, por meio desta metodologia, não influenciaram na cartografia final.

Palavras-chave: Modelo Linear de Mistura Espectral. Teste *t* de *Student* Pareado. Sensoriamento Remoto. Reamostragem.

ABSTRACT - This work compared the influence of two types of resampling on orbital images, which are the nearest neighbor method and the cubic convolution, using the linear spectral mixing model (LSMM). The ETM + / Landsat 7 scene, originally available by the nearest neighbor method, had it resampling changed to cubic convolution, prompting the discussion whether this change, given the change in digital number values, would influence the classification of images. Thus, for this analysis, 30 random and 30 manual points were extracted from the transition areas of the fractions in the error images (B3, B4 and B5) of each resulting model and the paired Student's *t* test for means was applied. The statistical results proved that there is not enough evidence, at a significance level of 5%, that the average of the error values of the images generated by the two resampling methods in the linear spectral mixture model are different, indicating that the application of the model and the analysis of its fractions in future classifications will not be influenced using this methodology. Furthermore, the supervised classification of images and fractions, for both resamplings, found that through the confusion matrix, with an average of 99% of global accuracy, the classifications are practically identical, legitimizing that the application of different resamplings, through this methodology, did not influence the final cartography.

Keywords: Linear Spectral Mixture Model. Student's Paired *t*-Test. Remote Sensing. Resampling.

INTRODUÇÃO

Nos últimos anos, o desenvolvimento de novas tecnologias de sensores embarcados em satélites gerou um célere e grande fornecimento na quantidade de informações e dados multiescala em relação as resoluções radiométricas, espectrais e espaciais. Muitos desses

dados são disponibilizados à comunidade internacional de modo gratuito, os quais, quando associados a processamentos e a inúmeros aplicativos livres, permitem o aumento de estudos científicos facilitando assim o desenvolvimento da ciência e a

capacitação de profissionais.

De acordo com Shimabukuro & Ponzoni (2018), esta evolução pode ser apresentada em três momentos: O primeiro representa o aperfeiçoamento da fotografia, permitindo o avanço de novas técnicas de fotogrametria e fotointerpretação; O segundo, apareceu quase que, concomitantemente à primeira, só que executada em imagens orbitais (sensores eletro-ópticos), especialmente quando vinculada as discussões sobre as mudanças climáticas. E por fim, o terceiro, caracterizado por aplicações relativas aos modelos e parâmetros bio- e geofísicos, ressaltando o sistema Landsat, com seus sensores de média resolução espacial que auxiliaram e auxiliam muitos estudos sobre a dinâmica da Terra.

De modo geral, o desenvolvimento das técnicas de sensoriamento remoto foram se aprimorando e evoluindo ao longo dos anos e estão presentes em estudos de diversas áreas do conhecimento, bem como em técnicas de modelos de mistura espectral.

Os estudos em sensoriamento remoto apresentam grande potencial quando se trata da aplicação da mistura espectral em dados de média resolução espacial, como imagens do satélite Landsat por exemplo, visto que os pixels puros são mais difíceis de serem encontrados.

Quando decorre de o mesmo pixel ter duas ou mais classes espectrais (água e solo ou vegetação e solo, por exemplo) este fenômeno é chamado de mistura espectral, sendo que a resultante da resposta espectral é uma combinação de todas as respostas espectrais destes membros de referência (DE Freitas et al., 2008).

Ainda neste contexto, e de acordo com De Freitas et al. (2008), o Modelo Linear de Mistura Espectral (MLME) permite assumir que a modelagem da resposta espectral de um pixel é feita a partir da combinação linear das respostas espectrais dos membros de referência. Neste sentido, conhecendo-se as feições de referência e a resposta espectral do pixel, estima-se a partir de programas computacionais, as conhecidas imagens-fração para cada uma das feições de referência.

Dados livres e características das imagens

Nos dias atuais, inúmeros portais disponibilizam dados orbitais e aerotransportados gratuitos os quais são imprescindíveis à comunidade científica. Desde o portal brasileiro com dados do programa Sino-Brasileiro -

CBERS, Landsat, Resourcesat, até portais da agência espacial japonesa JAXA (*Japan Aerospace eXploration Agency*) e estadunidense sob responsabilidade da USGS (*United States Geological Survey*) como o Earth Explorer e o GLOVIS.

Todos esses dados são disponibilizados em projeção UTM para o elipsoide de referência WGS-84 e amostragem por convolação cúbica. É praticamente um “padrão” adotado, sem uma publicação a qual os descrevam. Tucker et al. (2004) ao descreverem os dados do portal *Land Cover Facility* (atualmente desativado) da Universidade de Maryland, discutiram a mudança dos dados Landsat, inicialmente, com reamostragem pelo método do vizinho mais próximo ou *nearest neighborhood* (NN) para reamostragem pelo método da convolução cúbica ou *cubic convolution* (CC) durante o processo de ortorretificação, por meio de imposições de certas estações de recepção europeia e da Tailândia.

Impactos e consequências das reamostragens são pouco discutidas na literatura talvez por desconhecimento dos usuários ou pela não leitura dos arquivos descritores, fornecidos em formato de texto (txt), que acompanham os dados matriciais. Baboo & Devi (2010) afirmam que os impactos dos diferentes tipos de reamostragens são maiores em dados categóricos (classificação do uso e cobertura ou fatiamento de declividade) do que em dados contínuos, no entanto, nestes dados contínuos a amostragem pela CC pode mascarar pequenas depressões ou picos em um Modelo Numérico do Terreno (MNT) gerando valores fora do intervalo dos dados de entrada.

Uma analogia que pode ser feita é a da uniformidade de uma cobertura florestal com perturbações pontuais como dados contínuos, explicado no trabalho de Graça (2004) onde trabalhou-se a necessidade de utilizar imagens com reamostragem NN para a detecção visual de perturbações pontuais na floresta Amazônica, as quais foram impossíveis com as imagens com reamostragem CC. A textura é fortemente descrita por dados contínuos e os descritores de textura ganham um maior realce em imagens provenientes de sensores com melhor resolução espacial (Mather & Koch, 2011).

Roy & Dikshit (1994) analisaram o impacto da reamostragem e notaram que em descritores texturais a homogeneidade tende a aumentar, ao passo que descritores que descrevem a

heterogeneidade tendem a diminuir, além dos relatos sobre os impactos na exatidão de classificação derivados de classificadores pixel a pixel, como o Máxima Verossimilhança. Neste sentido, Afwani & Danoedoro (2019) testaram números de pontos, ordem do polinômio e três processos lineares, também discutidos neste artigo, para a exatidão de classificação em que a reamostragem NN resultou em uma melhor exatidão de classificação.

Em 2017, esforços dos usuários também foram realizados por meio do portal “CHANGE.ORG” com o título “*Reinstate option for nearest neighbor resampling of LIT Landsat Imagery*” onde foi feita uma solicitação para o restabelecimento, por parte da EROS (*Earth Resources Observation and Science*), de distribuição de dados orbitais com reamostragem NN a fim de evitar distorções estatísticas e espectrais causadas pela reamostragem CC.

Vale ressaltar que antes dos procedimentos de análise de uma imagem orbital deve-se atentar para a forma como a qual está reamostrada. Atualmente, as imagens do sistema Landsat possuem somente reamostragem do tipo convolução cúbica, favorecendo assim a interpretação visual da imagem em face da suavização e homogeneização causada pelos ajustes matemáticos empregados nessa abordagem, por meio da média ponderada, os quais podem ocasionar em mais mistura espectral dos alvos (devido a homogeneidade).

Neste sentido, este trabalho foi direcionado a estabelecer um comparativo entre os erros gerados em cada banda, utilizando-se de dois tipos de reamostragem para uma mesma imagem, e verificar a significância estatística de tais valores no MLME. Isto corrobora para o auxílio no uso do MLME em estudos de uso e cobertura do solo, estudos florestais e de agricultura.

A premissa a ser testada baseia-se no fato de que a reamostragem pela convolução cúbica, que por utilizar a média dos 16 vizinhos mais próximos, para estabelecer o novo valor do pixel analisado, teria um erro maior no MLME em relação à imagem reamostrada pelo vizinho mais próximo, que por sua vez, usa o valor do pixel mais próximo espacialmente.

Assim, o objetivo principal desta pesquisa foi o de comparar, do ponto de vista estatístico, a influência da reamostragem pelo vizinho mais próximo e pela convolução cúbica no MLME em uma imagem ETM+/Landsat 7 de 2002.

Modelo Linear de Mistura Espectral

O somatório das radiações dos materiais inseridos no campo de visão do sensor corresponde a radiação registrada pelos sensores, na qual tal radiação captada é causada por uma mistura de diversos materiais diferentes e pelos efeitos atmosféricos. O fato da maioria das cenas naturais não possuírem homogeneidade, normalmente acarretam um número elevado de componentes na mistura, podendo ser ainda maior em face da proporção das componentes específicas dentro de um determinado pixel (Shimabukuro & Smith, 1991).

O “problema” da mistura espectral foi discutido em diversos trabalhos científicos (Adams & Adams, 1984; Lu et al., 2003; Silva, 2008; Wang et al., 2008 e Yu et al., 2017) e uma das abordagens seguida pelos pesquisadores foi a de tentar modelar a relação entre os tipos e proporções das componentes dentro de um elemento em trabalhos relacionados a recursos naturais (Shimabukuro & Smith, 1991).

De acordo com Shimabukuro & Ponzoni (2018), a ocorrência de uma mistura espectral acontece quando os objetos são menores que o tamanho do elemento de resolução da imagem ou quando os objetos forem maiores, neste caso um pixel sobrepõe o limite de outro.

A partir de um MLME tornou-se possível investigar as misturas de assinaturas de vegetação e rocha (Adams et al., 1982 e Adams & Adams, 1984), uso do solo (Defries et al., 2000 e Theseira et al., 2002), estipular os tipos e abundâncias minerais (Smith et al., 1985), mapeamentos de habitats (Novo & Shimabukuro, 1997) e na análise da variação da estrutura de uma floresta usando frações sombra (Shimabukuro, 1987).

Neste contexto Shimabukuro & Smith (1991) mostraram que a mistura espectral é representada por uma relação linear da componente dentro da resolução do pixel, sendo que a resposta de cada pixel pode ser considerada como a combinação linear das respostas de cada componente que se pressupõe existir na mistura, ou seja, os pixels puros.

A Equação 1 apresenta a representação matemática do MLME.

$$\rho_i = \sum_{j=1}^n f_j \rho_{ij} + \varepsilon_i \quad (1)$$

onde ρ_i é o valor de reflectância média para i-ésima banda; f_j é o valor da proporção ou a fração do j-ésimo componente no pixel; ρ_{ji} é o valor de refletância espectral da j-ésima componente do membro final na banda i; ε_i é o erro para a i-ésima banda espectral; $j = 1, 2, \dots, n$ ($n =$ número de componentes); $i = 1, 2, \dots, m$ ($m =$ número de bandas espectrais).

Assim, para uma determinada imagem

multiespectral é possível modelar cada espectro de pixels por meio de uma combinação linear de um conjunto finito de componentes e para que haja um significado físico ao resultado, duas observações devem ser respeitadas à Equação 1:

A primeira é que os valores das frações geradas devem estar compreendidos entre o intervalo de 0 e 1, e a segunda que a soma de todas as frações deve ser menor ou igual a 1.

METODOLOGIA

Localização e caracterização da área de estudo

A área de estudo está compreendida entre as coordenadas geográficas 19° 85' e 20° 45' de latitude sul e 48° e 47° 35' de longitude oeste, localizada na divisa dos estados de Minas Gerais e São Paulo (Figura 1).

De acordo com a classificação sugerida por Köppen & Geiger (1928) o clima pertencente à área em questão é classificado como Aw – Tropical, com temperatura média de 22°C e pluviosidade em torno dos 1.500 mm anuais. A vegetação típica é a floresta tropical com transição para o cerrado, já próximo a região do Triângulo Mineiro. A região concentra extensas áreas para a produção de cana-de-açúcar, a indústria sucroalcooleira e a pecuária

de corte e leite, que são responsáveis pelo emprego de milhares de pessoas; ademais, destaca-se que a região possui alta disponibilidade hídrica por estar inserida na Bacia do Rio Grande, fator que favorece o desenvolvimento do turismo local com a manutenção de clubes náuticos e de pesca amadora.

Materiais utilizados

Para o estudo foi utilizada um recorte de uma imagem do sensor ETM+ do satélite Landsat 7 do dia 16 de julho de 2002, órbita 220 e ponto 74. Esta cena foi obtida, em seu formato original, pelo método vizinho mais próximo. A figura 2 representa o fluxograma metodológico utilizado neste trabalho.

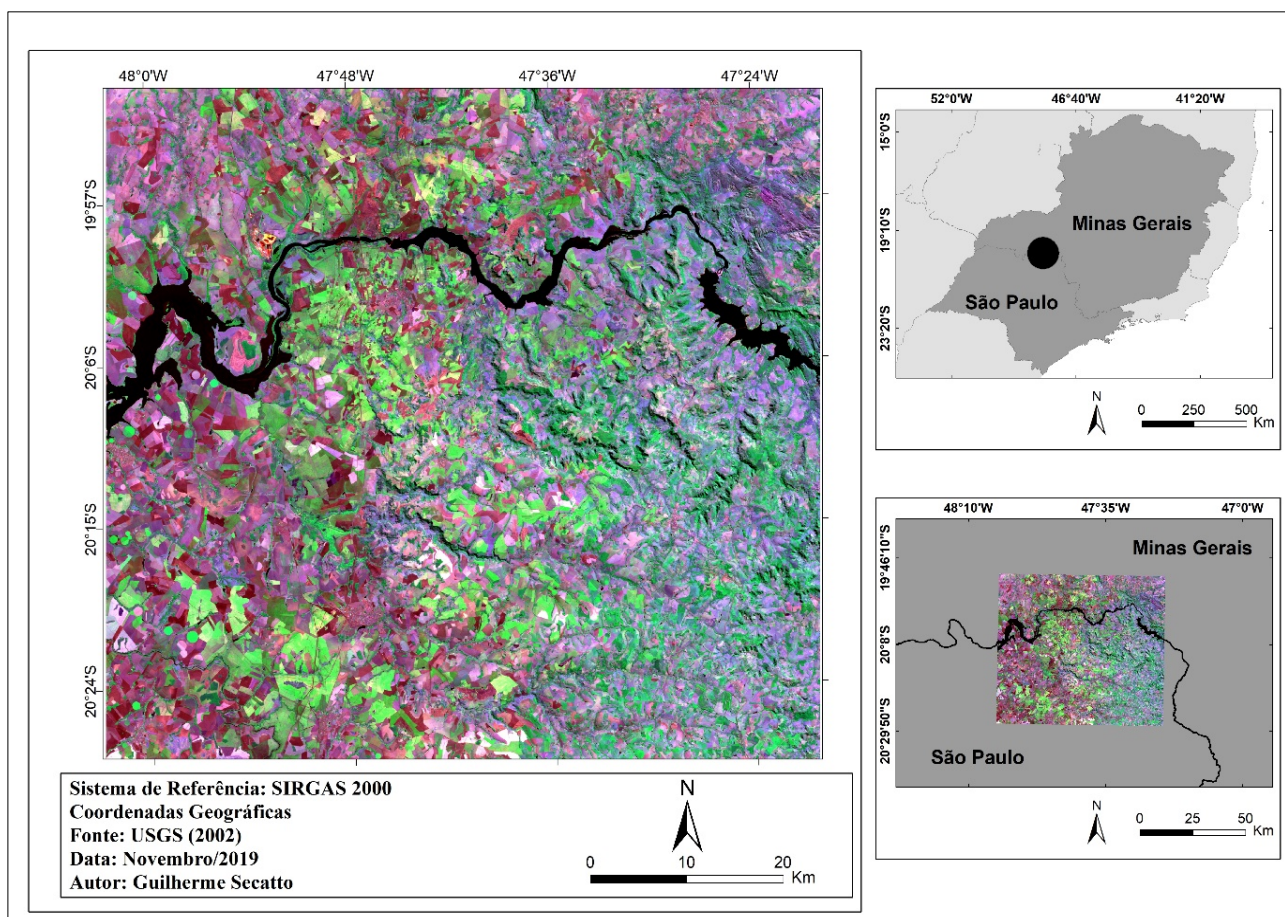


Figura 1 - Mapa de localização da área de estudo.

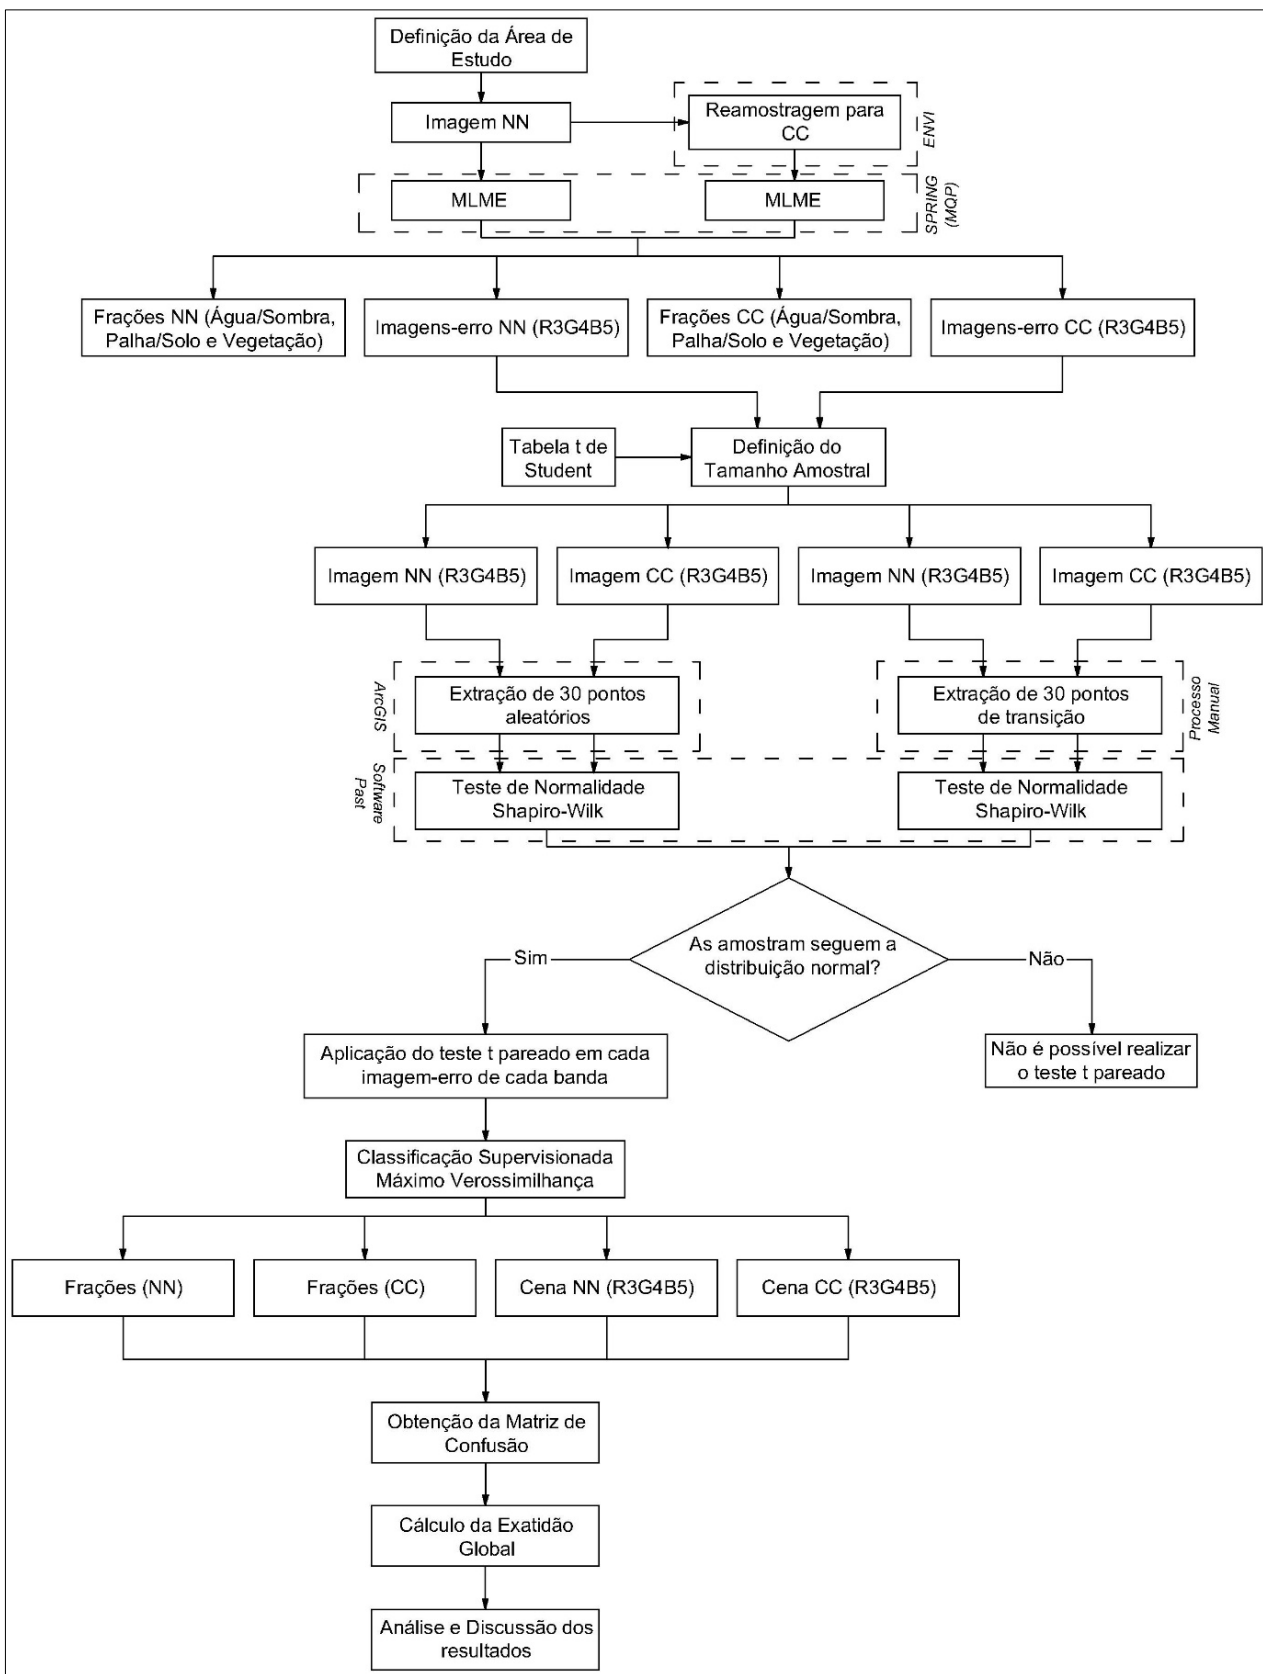


Figura 2 – Fluxograma metodológico.

Em seguida, foi feita a delimitação da área de estudo de modo que, nela estivessem presentes as classes de água/sombra, palha/solo e vegetação, para que desse modo pudessem ser realizadas as modelagens. A partir da área escolhida, utilizou-se o *software* Envi para realizar a conversão da

mesma imagem para o método da convolução cúbica. A diferença visual entre os dois métodos de reamostragens é vista na figura 3.

A figura 3A, reamostrada pelo vizinho mais próximo, apresenta maior simplicidade computacional e não altera os valores de ND presentes,

produzindo um aspecto mais disjuncto dos pixels, ao passo que, a figura 3B, ilustra a imagem que foi reamostrada pela convolução cúbica, o que necessitou um esforço computacional maior em sua operação e gera uma imagem mais homogênea,

auxiliando o operador em uma eventual análise e interpretação visual.

Tal fato pode ser percebido ao analisar as bordas do leito do rio nas duas imagens, onde tais efeitos são mais evidentes.




Figura 3 – A cena à esquerda identificada por “A” representa a imagem reamostrada pelo método do vizinho mais próximo e a “B” pelo método da convolução cúbica.

Métodos

Para a geração do MLME foi feito, inicialmente, a determinação dos membros puros ou *Endmembers* da cena, cujo objetivo foi incluir a variabilidade espectral na imagem multispectral.

Para isso fez-se uso de uma metodologia comumente utilizada e que foi apresentada por Camacho-De Coca (2004) e Quintano et al. (2012), onde a identificação dos *Endmembers* se deu a partir da análise de um espaço abstrato, ou seja, com base em um plano onde as componentes puras

são encontradas nos extremos de uma “nuvem” de pixels mistos formada por bandas pouco correlacionadas. Neste caso, as bandas utilizadas foram a do vermelho e do infravermelho próximo, de forma que se possa visualizar um triângulo onde cada vértice representaria um membro puro e onde a seleção dos membros puros é feita manualmente. Esta operação é ilustrada na figura 4.

Com isso, foi possível visualizar, na cena estudada, os membros puros, conforme apresentado na figura 5.

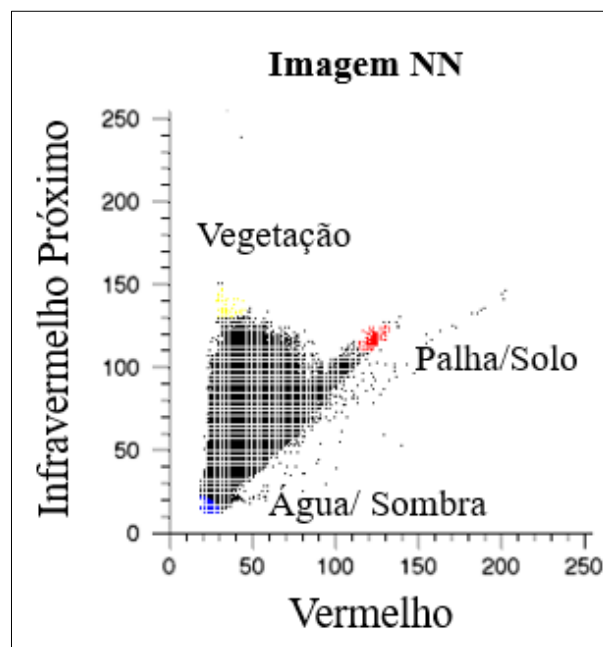


Figura 4 – Determinação dos membros puros da imagem NN.




Figura 5 – *Endmembers* presentes na cena NN.

Ressalta-se que foram usados os mesmos membros puros para a imagem reamostrada pelo método CC. Isto possibilitou que apenas o efeito da reamostragem fosse efetivamente analisado.

Após a determinação dos membros puros realizou-se a modelagem linear de mistura espectral, a partir da aplicação nas bandas de interesse (vermelho, infravermelho próximo e infravermelho médio) no módulo “Modelo de Mistura” do *software* Spring, para cada uma das imagens reamostradas.

Para estimar as componentes de palha/solo, vegetação e água/sombra foi utilizado o método dos Mínimos Quadrados Ponderado, que segundo Galo & Novo (2002) busca a solução interativa do sistema de equações lineares e gera um indicador do erro para cada banda espectral. Após a execução da ferramenta, o Spring forneceu 3 imagens-fração (água/sombra, palha/solo e vegetação) e 3 imagens-erro (para as bandas 3, 4 e 5), representando a distribuição espacial dos erros. Ressalta-se ainda que, os valores destas imagens-erro são encontrados por meio da multiplicação do valor absoluto dos ei pelo fator de escala 255.

Então, a partir dessas imagens-erro, foram realizadas as análises estatísticas com o objetivo de verificar a influência dos dois métodos de reamostragens.

Já a análise estatística foi realizada em 3 etapas, utilizando-se de 3 *softwares* distintos. A primeira etapa consistiu na extração dos valores de erro das amostras a partir de cada uma das imagens-erro (bandas 3, 4 e 5) e para isso foram utilizadas duas estratégias de verificação:

A primeira consistiu na criação de 30 pontos aleatórios, utilizando-se da ferramenta *Create random points* do ArcGis, em uma área previamente delimitada (evitando as regiões de bordas da imagem, devido a convolução cúbica utilizar a média dos 16 pixels vizinhos) e a segunda na inserção manual de outros 30 pontos nas áreas de transição de uma classe para a outra.

A segunda etapa contemplou os procedimentos estatísticos como a execução dos testes de normalidade das amostras no *software* livre Past e por fim, a terceira etapa foi a realização do teste t pareado.

Vale ressaltar que a definição do tamanho amostral - de 30 pontos - se deu a partir da análise da tabela t de Student. Utilizando-se de um nível de significância de 5%, o valor de t tabelado não varia muito a partir de 30 graus de liberdade.

Assim, definiu-se a quantidade de 30 pontos amostrados na imagem para a análise estatística. A figura 6 apresenta a distribuição espacial dos pontos que foram utilizados.

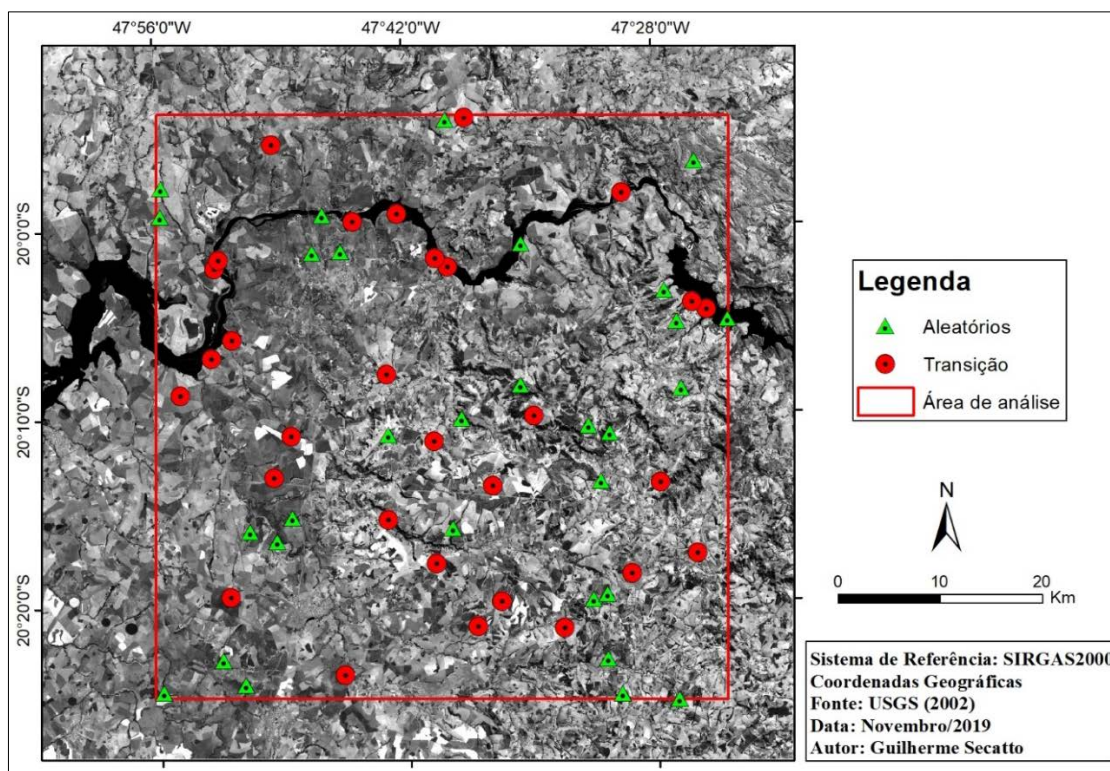


Figura 6 – Mapa com os pontos amostrados aleatoriamente e manualmente.

Ainda neste contexto, foram formuladas as seguintes hipóteses a partir do teste t pareado:

- H_0 : Erro CC = Erro NN \therefore Erro CC – Erro NN = 0 \therefore $\mu D = 0$;
- H_1 : Erro CC > Erro NN \therefore Erro CC – Erro NN > 0 \therefore $\mu D > 0$.

Prova-se que se H_0 é verdadeira quando a Equação 4 tem distribuição t de Student com n-1 graus de liberdade. Ressalta-se ainda que pelo fato de a hipótese alternativa ser do tipo H_1 : $\mu D > 0$ tem-se então um teste unilateral.

Por fim, utilizando-se da imagem original (com reamostragem NN), da imagem reamostrada CC e a das imagens-frações (com reamostragem NN e CC) resultantes após o modelo de mistura, foram realizadas as classificações de cada uma delas por meio do classificador supervisionado de máxima verossimilhança, a fim de avaliar se a influência das reamostragens ocasionaria diferenças significativas no produto final.

RESULTADOS E DISCUSSÃO

Após a modelagem, foram geradas as imagens-erro dos canais do vermelho, infravermelho próximo e médio para cada uma das imagens reamostradas. As figuras 7 e 8 apresentam as imagens-erro com reamostragem pelo vizinho mais próximo e pela convolução cúbica, respectivamente.

Visualmente, é imperceptível encontrar diferenças nos resultados das bandas de erro geradas pelo MLME, por isso foi realizada a

Para a classificação foram coletadas 200 amostras de cada uma das classes sendo que, 150 foram utilizadas para a classificação e 50 para a validação, a partir da geração de matrizes de confusão, assim como os cálculos dos valores de exatidão global por meio da Equação 2.

$$G = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (2)$$

A exatidão global é uma medida derivada da matriz de confusão, em que corresponde a precisão da classe individual do produtor e do usuário, onde seu cálculo é feito por meio da razão entre o somatório da diagonal principal da matriz dos erros x_i , pelo número total de amostras coletadas n (Figueiredo & Vieira, 2007).

Ressalta-se ainda que, a coleta das amostras se deu de forma homogênea dos pixels, buscando contemplar toda área de estudo.

extração dos valores dos pixels visando verificar e analisar as sutis diferenças. Além disso, são apresentadas nas figuras 9 e 10 os resultados do MLME referentes às frações de água/sombra, palha/solo e vegetação, assim como sua composição R (palha/solo), G (vegetação) e B (água/sombra) para a reamostragem pelo método do vizinho mais próximo e pela convolução cúbica. Ademais, a figura 11 mostra a compa-

ração entre a raiz quadrada do erro médio por banda do sensor ETM+/L7 resultantes do MLME após o uso dos mesmos *Endmembers* para as duas reamostragens. Os valores estão em números digitais podendo variar entre 0-255.

A partir destes valores médios de erro constatou-se que os maiores erros estão concentrados na

banda do vermelho e infravermelho próximo, mesmo sendo pequenas as diferenças entre os dois métodos testados, estes valores podem ser explicados pelos altos níveis de espalhamento múltiplo (Clark et al., 2005) em função da distância/ângulo entre a plataforma orbital e a superfície imageada que ocorre nessas regiões.




Figura 7 – Bandas de erro após o MLME da imagem reamostrada pelo método NN. Da esquerda para direita, as bandas do vermelho, infravermelho próximo e médio.




Figura 8 – Bandas de erro após o MLME da imagem reamostrada pelo método CC. Da esquerda para direita as bandas do vermelho, infravermelho próximo e médio.




Figura 9 – À esquerda observa-se as frações geradas pelo MLME da imagem reamostrada pelo método NN e a direita, a composição colorida das frações palha/solo (R), vegetação (G) e água/sombra (B).




Figura 10 – À esquerda observa-se as frações geradas pelo MLME da imagem reamostrada pelo método CC e a direita, a composição colorida das frações palha/solo (R), vegetação (G) e água/sombra (B).




Figura 11 – Valores de ei médio de cada banda e imagem reamostrada após o MLME.

No âmbito estatístico, a análise da normalidade para os 30 pontos amostrados, de maneira aleatória nas bandas, e em ambas as reamostragens, apresentaram normalidade seguindo a estatística W de Shapiro-Wilk, conforme apresentado na Tabela 1.

Considerando que todos os valores-p foram maiores que o nível de significância de 5% e levando em conta que a hipótese H0 tem distribuição normal bivariada, concluiu-se que em todos os casos não há indícios para rejeitar a hipótese H0, justificando assim a ocorrência de normalidade em todas as observações.

A análise supracitada anteriormente serve também para as amostras coletadas manualmente dos pontos de transição das frações, ou seja, todos os valores foram normais conforme apresentados na tabela 2.

Assim, após a conclusão de normalidade sobre os dados, foi calculado o teste t pareado para verificar indícios de diferenças nas médias. A Tabela 3 apresenta os valores da estatística t pareada, o seu valor-p associado, e com base nestas medidas a rejeição ou não da hipótese H0 ao nível de significância de 5% para os dados coletados aleatoriamente.

Tabela 1 – Teste de normalidade dos pontos aleatórios.

Banda - Método	Valor W	Valor-p N.S. = 5%	Rejeita H ₀ H ₀ : $\mu D = 0$
B3 – NN	0,951	0,182	Não
B3 – CC	0,933	0,059	Não
B4 – NN	0,990	0,992	Não
B4 – CC	0,957	0,261	Não
B5 – NN	0,943	0,113	Não
B5 – CC	0,947	0,143	Não

Tabela 2 – Teste de normalidade dos pontos das áreas de transição.

Banda - Método	Valor W	Valor-p N.S. = 5%	Rejeita H ₀ H ₀ : $\mu D = 0$
B3 – NN	0,979	0,799	Não
B3 – CC	0,971	0,568	Não
B4 – NN	0,940	0,096	Não
B4 – CC	0,971	0,568	Não
B5 – NN	0,981	0,869	Não
B5 – CC	0,984	0,924	Não

Para inferência da significância foi utilizado o valor de t tabelado de 2,0422, obtido a partir do valor de 29 graus de liberdade. Assim, os valores das diferenças amostrados aleatoriamente se mostram serem menores que o t tabelado em todos os casos, sobretudo na banda do infravermelho próximo.

Similarmente, o mesmo ocorreu para os valores de erro amostrados nas zonas de transição de uma fração para outra, conforme visto na Tabela 4.

Desse modo, a partir da análise estatística, e fazendo-se uso do teste t pareado, verificou-se

que não há evidências de que as médias das discrepâncias para cada uma das reamostragens sejam diferentes.

Em consonância aos resultados estatísticos, as figuras 12 e 13 apresentam as classificações supervisionadas da imagem original com reamostragem NN e da imagem reamostrada CC, além das imagens-fração referentes às frações água/sombra, palha/solo e vegetação, também para cada um dos métodos de reamostragens, respectivamente, assim como a porcentagem das classes água/sombra, palha/solo e vegetação classificadas em cada uma delas.

Tabela 3 – Estatística t para o conjunto de pontos aleatórios.

Pontos Aleatórios	Valor T	Rejeita H_0 $H_0: \mu D = 0$
Banda 3 NN – CC	0,27013	Não
		Não
Banda 4 NN – CC	0,00004	Não
		Não
Banda 5 NN – CC	0,11252	Não
		Não

Tabela 4 – Estatística t para pontos de transição.

Pontos Transição	Valor T	Rejeita H_0 $H_0: \mu D = 0$
Banda 3 NN – CC	0,24276	Não
		Não
Banda 4 NN – CC	0,00086	Não
		Não
Banda 5 NN – CC	0,41094	Não
		Não

Ambas as classificações não apresentaram diferenças significativas das classes temáticas, resultando em valores de porcentagem muito próximos.

Ainda assim, corroborando para o resultado de mapeamento temático as Tabelas 5 e 6 mostram, respectivamente, as matrizes de confusão para a classificação da imagem NN e da CC.

Novamente, para ambas as imagens, as matrizes de confusão mostraram que não houve diferenças significativas durante a classificação dos alvos, resultando em uma exatidão global de

99% nos dois casos. Por fim, as Tabelas 7 e 8 apresentam os valores das matrizes de confusão para a classificação das imagens-fração NN e da CC, respectivamente.

Assim, como nos valores da imagem NN e CC, a exatidão global para a matriz de confusão da imagem fração NN foi de 98% e para a imagem fração CC foi de 100%, resultando na não ocorrência de mudanças significativas. Desse modo, pode-se constatar que o produto gerado, com os dados e técnicas aplicadas neste estudo, não sofreu alteração quando a reamostragem da imagem foi alterada.

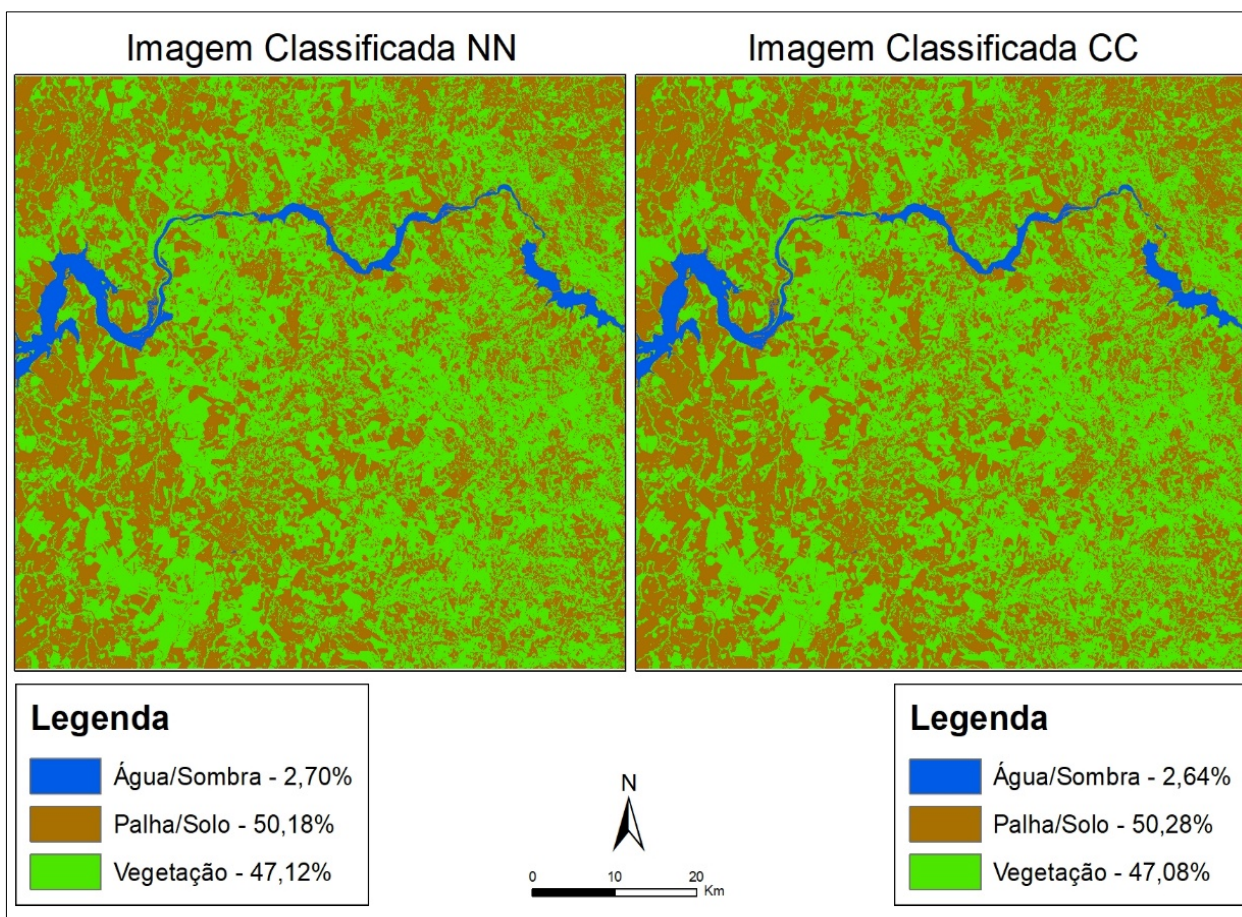


Figura 12 – Estatística t para o conjunto de pontos aleatórios.

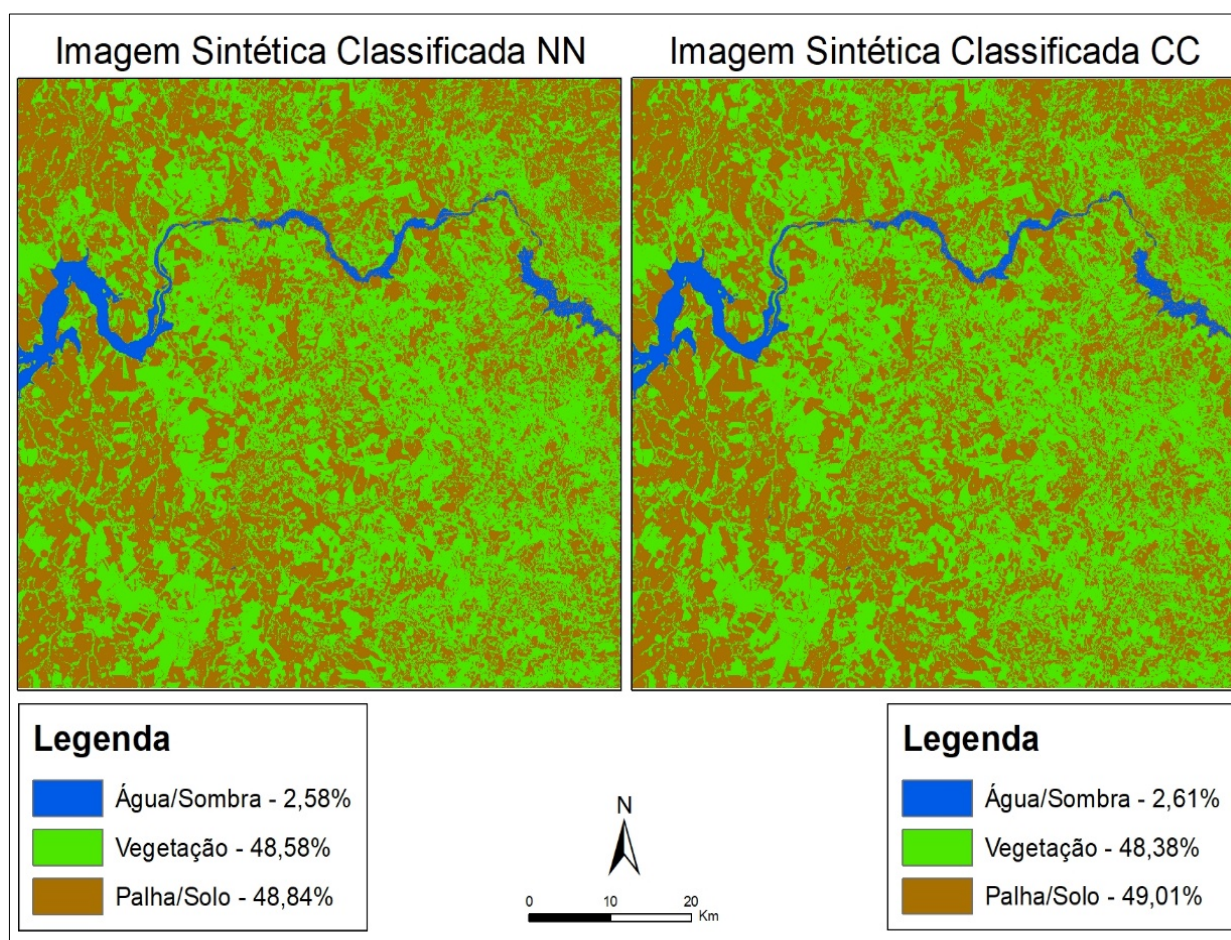


Figura 13 – Estatística t para o conjunto de pontos aleatórios.

Tabela 5 – Matriz de confusão para a imagem classificada pelo método NN.

		Referência		
		Água Sombra	Palha Solo	Vegetação
Predito	Água/Sombra	50	0	0
	Palha/Solo	0	49	0
	Vegetação	0	1	50
Total		50	50	50

Tabela 6 – Matriz de confusão para a imagem classificada pelo método CC.

		Referência		
		Água Sombra	Palha Solo	Vegetação
Predito	Água/Sombra	50	0	0
	Palha/Solo	0	50	0
	Vegetação	0	1	49
Total		50	50	50

Tabela 7 – Matriz de confusão para a imagem fração NN.

		Referência		
		Água Sombra	Palha Solo	Vegetação
Predito	Água/Sombra	50	0	0
	Palha/Solo	0	50	2
	Vegetação	0	0	48
Total		50	50	50

Tabela 8 – Matriz de confusão para a imagem fração CC.

		Referência		
		Água Sombra	Palha Solo	Vegetação
Predito	Água/Sombra	50	0	0
	Palha/Solo	0	50	0
	Vegetação	0	0	50
Total		50	50	50

CONCLUSÃO

O presente trabalho buscou analisar dois dos mais utilizados tipos de reamostragens em imagens de satélites e, a partir dos resultados obtidos, por meio das imagens-erro das bandas espectrais, pode-se concluir que o problema da mistura espectral não é influenciado de maneira significativa, do ponto de vista estatístico, no mapeamento final.

A partir da modelagem linear da mistura espectral, em cada uma das imagens reamostradas, verificou-se que os valores da raiz

quadrada do erro médio foram muito próximos evidenciando que na média, as reamostragens diferentes não influenciaram no MLME.

Ainda assim, e por meio da obtenção dos 30 valores amostrados das bandas das imagens-erro, tanto os pontos aleatórios quanto os das áreas de transição, sem exceção, apresentaram normalidade, e com o uso do teste *t* pareado pôde-se verificar em todos os casos que no comparativo das médias das imagens-erro não ocorreu a rejeição da hipótese nula, sobretudo na banda

do infravermelho próximo, o que indica uma diferença quase nula. A não rejeição da hipótese nula significa que, a partir dos dados utilizados não foi possível demonstrar a sua falsidade.

O mapeamento temático das imagens ETM+/L7 e das frações geradas a partir do MLME para as duas reamostragem mostraram ser praticamente iguais, tanto em relação a porcentagem das classes quanto nos valores da

matriz de confusão, resultando em valores médios de 99% de exatidão global, ou seja, a reamostragem não teve influência determinante neste tipo de análise.

De maneira análoga, sugere-se em estudos futuros esta mesma análise, contudo levando-se em conta as informações topográficas do terreno, ou seja, analisar se a média dos erros do MLME em áreas planas e montanhosas sofrem influência da reamostragem.

AGRADECIMENTOS

Este estudo contou com o incentivo da Universidade Federal de Viçosa por meio do Departamento de Engenharia Civil (DEC), curso de Pós-Graduação em Engenharia Civil que disponibilizaram seus equipamentos, instalações e aplicativos computacionais. Ao apoio financeiro concedido pela CAPES por meio do consentimento da bolsa de estudos.

REFERÊNCIAS

- ADAMS, J. B. & ADAMS, J. D. Geologic mapping using Landsat MSS and TM images: Removing vegetation by modeling spectral mixtures. **Remote Sensing of Environment 3rd Thematic Conf.**, Remote Sensing for Exploration Geology (Colorado Springs, CO), v. 2, p. 615-622, 1984.
- ADAMS, J. B.; EVANS, D. L.; FARR, T. G.; SMITH, M. Interpretation of weathered surfaces in arid regions using Landsat multispectral images. In: Thematic conference: remote sensing of arid and semi-arid lands. **Anais...Cairo: 1982.** Disp.em: <http://agris.fao.org/agris-search/search.do?recordID=US8245635>. Acesso em: 25 nov. 2019.
- AFWANI, M.Z. & DANOEDORO, P. The effects of polynomial interpolation and resampling methods in geometric correction on the land-cover classification accuracy of Landsat-8 OLI imagery: a case study of Kulon Progo area, Yogyakarta. In: SIXTH GEOINFORMATION SCIENCE SYMPOSIUM. INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS, 2019. **Anais**, p. 1131.
- BABOO, S.S. & DEVI, M. R. An analysis of different resampling methods in Coimbatore, District. **Global Journal of Computer Science and Technology**, Delaware (USA), v. 10, n. 15, p. 61-66, 2010. Disp.em: <http://computerresearch.org/stpr/index.php/gjst/article/view/474/433>. Acesso em: 20 nov. 2019.
- CAMACHO-DE COCA, F.; GARCÍA-HARO, F.J.; GILBERT, M.A.; MELIÁ, J. Vegetation cover seasonal changes assessment from TM imagery in a semi-arid landscape. **International Journal of Remote Sensing**. v. 25, n. 17, p.3451–3476, 2004.
- CLARK, M. L.; ROBERTS, D. A.; CLARK, D. B. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. **Remote Sensing of Environment**, v. 96, n. 3-4, p. 375-398, 2005.
- DE FREITAS, R.; HAERTEL, V.; SHIMABUKURO, Y.E. Modelo linear de mistura espectral em imagem de moderada resolução espacial. **Boletim de Ciências Geodésicas**, v. 14, n. 1, p. 55-71, 2008.
- DEFRIES, R.S.; HANSEN, M.C.; TOWNSHEND, J.R.G. Global continuous fields of vegetation characteristics: A linear mixture model applied to multi-year 8 km AVHRR data. **International Journal of Remote Sensing**, v. 21, n. 6-7, p. 1389-1414, 2000.
- FIGUEIREDO, G.C. & VIEIRA, C.A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, Florianópolis. **Anais...Florianópolis: INPE**, v. 13, p. 5755-5762.
- GALO, M.L.B.T. & NOVO, E.M.L.M. Aspectos relacionados com o fenômeno de mistura espectral e ambiguidade na classificação usando redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE GEOMÁTICA, **Anais do** p. 150-161, 2002.
- GRAÇA, P. M. L. A. **Monitoramento e Caracterização de Áreas Submetidas à Exploração Florestal na Amazônia por Técnicas de Detecção de Mudanças**. 2004, 275 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2004.
- KÖPPEN, W. & GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes. 1928.
- LU, D.; MORAN, E.; BATISTELLA, M. Linear mixture model applied to Amazonian vegetation classification. **Remote Sensing of Environment**, v. 87, n. 4, p. 456-469, 2003.
- MATHER P.M.; KOCH M. **Computer processing of remotely-sensed images: an introduction**. John Wiley-Blackwell, 2011.
- NOVO, E. M. & SHIMABUKURO, Y. E. Identification and mapping of the Amazon habitats using a mixing model. **International Journal of Remote Sensing**, v. 18, n. 3, p. 663-670, 1997.
- QUINTANO, C.; FERNÁNDEZ-MANSO, A.; SHIMABUKURO, Y. E.; PEREIRA, G. Spectral unmixing. **International Journal of Remote Sensing**. v. 33, n. 17, p.37-41, 2012.
- ROY, D.P. & DIKSHIT, O. Investigation of image resampling effects upon the textural information content of a high spatial resolution remotely sensed image. **International Journal of Remote Sensing**. v. 15, n. 5, p. 1123-1130, 1994.
- SHIMABUKURO, Y. E. & PONZONI, F. J. **Spectral Mixture for Remote Sensing: Linear Model and Applications**. Springer, 2018.
- SHIMABUKURO, Y.E. **Shade images derived from linear mixing models of multispectral measurements of forested areas**. Colorado State University, Fort Collin, 1987. Tese (Doutorado em Ciências Florestais/Sensoriamento Remoto).
- SHIMABUKURO, Y.E. & SMITH, J.A. The Least-Squares Mixing Models to Generate Fraction Images Derived from Remote Sensing Multispectral Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16-20, 1991.
- SILVA, W.C.S. **Aplicação da técnica de modelo linear de mistura espectral (MLME) para o mapeamento de diferentes tipos de água no rio Solimões e no Lago de Coari utilizando imagens LANDSAT-5 TM**. Rio de Janeiro, 2008. 109 p. Tese (Doutorado em Engenharia Civil), Universidade Federal do Rio de Janeiro.
- SMITH, M.O.; JOHNSON, P. E.; ADAMS, J. B. Quantitative determination of mineral types and abundances from reflectance spectra using principal components analysis.

- Journal of Geophysical Research**, v. 90, p. 797-804, 1985.
- THESEIRA, M. A.; THOMAS, G.; SANNIER, C. A. D. An evaluation of spectral mixture modelling applied to a semi-arid environment. **International Journal of Remote Sensing**, v. 23, n. 4, p. 687-700, 2002.
- TUCKER, C.J.; GRANT, D.M.; DYKSTRA, J.D. NASA's global orthorectified Landsat data set. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 3, p. 313-322, 2004.
- WANG, T.; CHEN, S.; MA, Y. Accuracy assessment of linear spectral mixture model due to terrain undulation. In: **International conference on earth observation data processing and analysis**, 7, 2008. **Anais...** Wuhan, 2008. Disp. em: <https://www.spiedigitallibrary.org/conference-proceeding-s-of-spie/7285/72853R/Accuracy-assessment-of-linear-spectral-mixture-model-due-to-terrain/10.1117/12.815017.short?SSO=1>. Acesso em: 6 out. 2019.
- YU, J.; CHEN, D.; LIN, Y.; YE, S. Comparison of linear e nonlinear spectral unmixing approaches: a case study with multispectral TM imagery. **International Journal of Remote Sensing**, v. 38, n. 3, p. 773-795, 2017.

Submetido em 27 de maio de 2020
Aceito para publicação em 16 de agosto de 2021