

GUILHERME ZAVATTI CECCATO

**INFLUÊNCIA DA REAMOSTRAGEM DOS VALORES DIGITAIS EM MODELOS
DE MISTURA ESPECTRAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

Orientadora: Nilcilene das Graças Medeiros

Coorientadores: José Marinaldo Gleriani
Júlio César de Oliveira

**VIÇOSA - MINAS GERAIS
2020**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

C387i
2020
Ceccato, Guilherme Zavatti, 1991-
Influência da reamostragem dos valores digitais em
modelos de mistura espectral / Guilherme Zavatti Ceccato. –
Viçosa, MG, 2020.
84 f. : il. (algumas color.) ; 29 cm.

Inclui anexo.

Orientador: Nilcilene das Graças Medeiros.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Sensoriamento Remoto. 2. Redes Neurais (Computação).
3. Reamostragem (Estatística). I. Universidade Federal de
Viçosa. Departamento de Engenharia Civil. Programa de
Pós-Graduação em Engenharia Civil. II. Título.

CDD 22 ed. 621.3678

GUILHERME ZAVATTI CECCATO

**INFLUÊNCIA DA REAMOSTRAGEM DOS VALORES DIGITAIS EM MODELOS
DE MISTURA ESPECTRAL**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Magister Scientiae*.

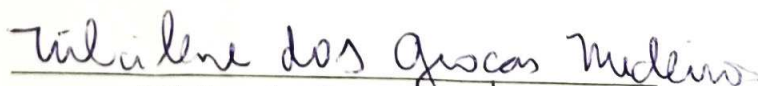
APROVADA: 28 de fevereiro de 2020.

Assentimento:



Guilherme Zavatti Ceccato

Autor



Nilcilene das Graças Medeiros

Orientadora

*Dedico este trabalho aos meus pais, José Donizete e
Neide Aparecida e ao meu irmão Gabriel.*

AGRADECIMENTOS

A Deus pela vida, saúde e resiliência em continuar caminhando sempre à frente e nunca para trás, nem para pegar impulso.

Ao meu herói, José Donizete e a minha eterna professora e mentora, Neide (*in memoriam*), e ao meu advogado e irmão, Gabriel por todo suporte moral e emocional, incentivo aos estudos e estoicismo sempre.

A minha querida e amada Janine, pela paciência, companheirismo, amor, entusiasmo, assessoria e por sempre estar ao meu lado em todos os momentos durante esta incrível e estupenda jornada, que foi a do mestrado, e um agradecimento especial ao fiel companheirismo cósmico e de amor incondicional da minha irmã de quatro patas, Mell.

A Dona Selma, Seu Zé Carlos, Ju e Dinha pelo acolhimento, por nunca me deixarem sentir só e pelas orações durante esta fase.

A todos os professores do curso de Engenharia de Agrimensura e Cartográfica – UFV, em especial à minha orientadora Dra. Nilcilene das Graças Medeiros e aos meus coorientadores, Dr. José Marinaldo Gleriani e Dr. Júlio César de Oliveira por todo o apoio, disponibilidade, paciência, ideias, simpatia e contribuições que foram fundamentais para o cumprimento deste trabalho.

Aos funcionários do Departamento de Engenharia Civil da UFV, em especial ao Tiago e Cilene pelo excelente serviço prestado a nós.

Aos amigos da pós: Marconi (Amigo), Larissa, Raiane, Lucas, Youlia, Priscila, Iann, Marotta por toda a ajuda e pelos infinitos momentos de alegria e descontração. Ao amigo e mestre João Flávio, pela gentileza de sempre estar disposto a me ajudar nos processamentos e discussões que deram forma a este trabalho, sobretudo nos momentos em que eu estava no limite da honra.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Em építome, a todos que, de forma direta ou indireta, contribuíram para a realização desta conquista.

EPÍGRAFE

“Se o dinheiro for a sua esperança de independência, você jamais a terá. A única segurança verdadeira consiste numa reserva de sabedoria, de experiência e de competência.”

Henry Ford

RESUMO

CECCATO, Guilherme Zavatti, M.Sc., Universidade Federal de Viçosa, fevereiro de 2020. **Influência da reamostragem dos valores digitais em modelos de mistura espectral.** Orientadora: Nilcilene das Graças Medeiros. Coorientadores: José Marinaldo Gleriani e Júlio César de Oliveira.

As imagens ETM+/Landsat 7, originalmente disponibilizadas pelos portais de distribuição com reamostragem pelo método do vizinho mais próximo, começaram a ser cedidas somente pelo método da convolução cúbica, que por sua vez altera, por meio de processos matemáticos, o valor do pixel analisado em relação a média dos 16 pixels vizinhos. Em face dessa mudança e utilizando-se de uma cena Landsat 7, reamostrada pelo vizinho mais próximo, e depois convertida para convolução cúbica, realizou-se a modelagem linear de mistura espectral em ambas as imagens. Para tanto, foram utilizadas 30 amostras aleatórias e 30 amostras coletadas manualmente, estas localizadas nas áreas de transição das frações nas imagens-erro (B3, B4 e B5), resultantes de cada modelo. Em seguida, foram aplicados os testes de normalidade Shapiro-Wilk e o t de Student pareado para médias, com o intuito de verificar se havia diferenças significativas dos valores de erro. Os resultados mostraram que não há evidências suficientes de que as médias dos valores de erro das imagens, a um nível de significância de 5% geradas pelos dois métodos de reamostragem, no modelo linear de mistura espectral, são diferentes. Assim, a classificação supervisionada das imagens e das frações, para ambas reamostragens, que apresentaram a partir da geração de uma matriz de confusão, uma média de 99% de exatidão global, são praticamente idênticas, legitimando que, no estudo dessas imagens, a aplicação de diferentes reamostragens, por meio desta metodologia, não influenciou no mapeamento das classes de uso e cobertura do solo. Outra proposta desse estudo foi avaliar a precisão das estimativas de proporção subpixel a partir dos erros médios absolutos por fração e o erro médio absoluto total entre as abordagens linear e não linear de mistura espectral. Para isso, fez-se uso de uma classificação de máximo verossimilhança, de uma cena Planet de 3 metros de resolução espacial, com o intuito de se obter as referências de campo, separando-as nas classes de água/sombra, palha/solo e vegetação. A partir destes dados, estruturou-se uma rede neural artificial, onde com o uso do algoritmo de retropropagação foi feito seu treinamento, obtendo como saída as proporções de uma imagem OLI/L8 de 30 metros. Concomitantemente, realizou-se uma modelagem linear da mesma imagem OLI/L8 e com 6491 amostras pôde-se então comparar os resultados das frações. Os resultados alcançados apresentaram que a abordagem linear obteve valores de erro médio absoluto por fração e total maiores que a do

modelo não linear. Os valores corresponderam a um valor de erro médio total de 1,023 e 0,310 para o modelo linear e não linear, respectivamente, comprovando que a partir de uma mesma referência de dados, a abordagem não linear se mostra ser uma modelagem mais adequada.

Palavras-chave: Sensoriamento Remoto. Modelo de Mistura Espectral. Teste t de Student Pareado. Reamostragem. Rede Neural Artificial.

ABSTRACT

CECCATO, Guilherme Zavatti, M.Sc., Universidade Federal de Viçosa, February, 2020. **Influence of resampling of digital values in spectral mixtures models.** Advisor: Nilcilene das Graças Medeiros. Co-advisers: José Marinaldo Gleriani and Júlio César de Oliveira

The ETM + / Landsat 7 images, originally available by portals with the resample using the nearest neighbor method, began to be provided only by the method of cubic convolution, which changes, through mathematical processes, the value of the pixel analyzed in relation to the average of the 16 neighboring pixels. In face of this change and using a Landsat 7 scene, resampled by the closest neighbor, and then converted to cubic convolution, it was carried out on both images a linear modeling of spectral mixing. For this, 30 random samples and 30 samples collected manually were used, these located in the transition areas of the fractions in the error images (B3, B4 and B5), resulting from each model. Then, the Shapiro-Wilk normality test and the Student's paired *t*-test for means were applied, in order to verify if there were significant differences in the error values. The results showed that there are not enough evidences that the average of the error values of the images, at a significance level of 5% generated by the two resampling methods, in the linear spectral mixture model are different. Thus, the supervised classification of images and fractions, for both resamplings, which showed, from the generation of a confusion matrix, an average of 99% of global accuracy, are practically identical, legitimizing that, in this study of these images, the application from different resamples, using this methodology, did not influence the mapping of land-use and land-cover classes. Another proposal of this study was evaluate the precision of the subpixel proportion estimates from the mean absolute errors per fraction and total between the linear and nonlinear spectral mixing approaches. For this, a maximum likelihood classification was used, of a Planet scene of 3 meters of spatial resolution, in order to obtain the field references, separating them in the classes of water/shadow, straw/soil and vegetation. From these data, an artificial neural network was structured, where using the backpropagation algorithm, training was performed, obtaining the proportions of an OLI/L8 image of 30 meters as an output. Concomitantly, a linear modeling of the same OLI/L8 image was performed and with 6491 samples it was then possible to compare the results of the fractions. The results achieved showed that the linear approach obtained values of mean absolute error per fraction and total greater than that of the nonlinear model. The mean absolute error total value was 1.023 and 0.310 for

the linear and nonlinear model, respectively, proving that from the same data reference, the nonlinear approach proves to be a more adequate model.

Keywords: Remote Sensing. Spectral Mixing Model. Student's paired t -test. Resampling. Artificial Neural Network.

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Justificativa	15
1.2	Hipóteses.....	15
1.3	Objetivos.....	16
1.4	Estrutura da dissertação	16
2	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.....	17
2.1	INTRODUÇÃO	19
2.1.1.	Dados livres e características das imagens	20
2.2	OBJETIVOS	21
2.2.1	Geral	21
2.2.2	Específicos	21
2.3	FUNDAMENTAÇÃO TEÓRICO METODOLÓGICA	21
2.3.1	Modelo Linear de Mistura Espectral	21
2.3.2	Imagens-erro do MLME	23
2.3.3	Reamostragem de dados matriciais	24
2.3.4	Sistema ETM+/ Landsat 7.....	26
2.3.5	Teste <i>t</i> para amostras pareadas	28
2.4	MATERIAL E MÉTODOS	29
2.4.1	Características gerais da área de estudo	29
2.4.2	Reamostragens das cenas pelos métodos NN e CC.....	30
2.4.3	Geração do MLME.....	32
2.4.4	Análise Estatística	35
2.5	RESULTADOS E DISCUSSÕES.....	37
2.5.1	MLME	37
2.5.2	Análise Estatística e Análise de Mapas Finais	40

2.6	CONCLUSÃO.....	46
	REFERÊNCIAS.....	48
3.	ANÁLISE DOS VALORES DE ERRO ABSOLUTO ENTRE OS MODELOS LINEAR E NÃO LINEAR DE MISTURA ESPECTRAL A PARTIR DE IMAGENS MULTIRESOLUÇÃO	51
3.1	INTRODUÇÃO.....	53
3.2	OJETIVOS	54
3.2.1	Objetivo Geral.....	54
3.2.2	Objetivos Específicos	54
3.3	FUNDAMENTAÇÃO TEÓRICO METODOLÓGICA	55
3.3.1	Modelo Não Linear de Mistura Espectral	55
3.3.2	Sistema OLI Landsat 8 e Planet	57
3.3.3	Desempenho e erro médio absoluto de frações em modelos de mistura	59
3.4	MATERIAL E MÉTODOS	61
3.4.1	Características gerais da área de estudo	61
3.4.2	Materiais utilizados	62
3.4.3	Geração do MNLME	62
3.4.3.1	Imagens fração de referência.....	64
3.4.3.2	Modelagem a partir da RNA	65
3.4.3.3	Geração das imagens fração estimadas	66
3.4.4	Geração do MLME da imagem OLI Landsat 8.....	66
3.4.5	Definição das amostras e avaliação do desempenho dos modelos.....	68
3.5	RESULTADOS E DISCUSSÕES.....	69
3.6	CONCLUSÃO	77
	REFERÊNCIAS.....	78
4	CONCLUSÕES E RECOMENDAÇÕES.....	81
	REFERÊNCIAS.....	82
	ANEXO I	84

1 INTRODUÇÃO

Nas últimas décadas o célere desenvolvimento de sensores orbitais permitiu que o planeta Terra fosse monitorado diariamente, fornecendo informações espaciais e espectrais dos alvos disponíveis na superfície terrestre, permitindo um acompanhamento de sua dinâmica em escala global.

Os estudos que usam esses recursos tecnológicos são vastos e multidisciplinares, indo da agricultura ao planejamento urbano, evoluindo concomitantemente à matemática, estatística e computação, por meio de metodologias já consolidadas e outras ainda em desenvolvimento de processamento digital de imagens, para que assim, seja possível extrair a potencialidade dos dados espaciais, com o escopo de fornecer uma elevada confiabilidade e qualidade de produtos e serviços para órgãos públicos e privados.

Neste contexto de aquisição de informações espaciais, a imagem formada por um sensor corresponde ao fluxo radiante refletido por uma porção da superfície terrestre e é composta por dezenas de milhares de unidades conhecidas como pixels, que por sua vez, possuem dimensões quadradas, podendo ter representações espaciais variando de 0,5 a 1000 metros de resolução (SHIMABUKURO e PONZONI, 2018).

Neste sentido, as imagens usadas em sensoriamento remoto são recebidas por centros e bases autorizadas e são distribuídas aos usuários por meio de portais eletrônicos para os mais variados fins. Tais imagens acompanham inúmeras informações em seus metadados, sendo que um deles se refere ao método de reamostragem.

Um dos portais mais conhecidos mundialmente pelo fornecimento de imagens gratuitas do programa Landsat, o EROS Data Center (centro de gerenciamento de dados, pesquisa e desenvolvimento dos Estados Unidos da América), disponibilizava cenas reamostradas pelo método do vizinho mais próximo. Porém, há alguns anos, quando operadores europeus e tailandeses proibiram a sua distribuição em formato original e passaram a disponibilizar somente pelo método de reamostragem da convolução cúbica, o que acarretou em uma distorção espectral e estatística (TUCKER, GRANT e DYKSTRA, 2004).

Estes métodos de reamostragem alteram o valor do número digital (ND) em toda a imagem, em face do processo matemático que ocorre, visto que a interpolação é baseada nos vizinhos do pixel analisado (DE MELO e PACHÊCO, 2004).

Neste contexto, e em muitas das vezes, os NDs que compõem os pixels não possuem características totalmente puras, e sim mistas, ocorrendo em face da variação e proximidade de diferentes objetos na superfície. Verhoeve e De Wulf (2002) mencionam ainda que a mistura dos pixels ocorre quando há a inclusão de mais de uma classe espectral na composição do valor de brilho refletido pelo objeto captado pelo IFOV (*Instantaneous Field of View*) e fatores espúrios durante a captura da cena, como partículas da atmosfera (FERREIRA et al., 2003).

Keshava e Mustard (2002) ressaltam que a mistura ocorre de maneira independente a resolução espacial, onde os pixels mistos de uma cena correspondem a uma função direta da quantidade de coberturas dispostas na superfície e do fracionamento da paisagem (CAMPBELL e WYNNE, 2011). Uma sombra, em uma borda de fragmento florestal, em uma imagem de resolução espacial de 30 metros, pode ter a mesma influência das sombras entre ramos/folhas em uma imagem de resolução de 30 centímetros (QUINTANO et al., 2012).

Neste contexto, os modelos de mistura espectral constituem um dos métodos mais usados quando se pretende modelar conjuntos de dados de origem heterogênea, cujos principais objetivos são destacar os alvos de interesse e minimizar a quantidade de informações a serem utilizadas em um processamento computacional (FERREIRA et al., 2003).

Pode-se separar a análise de mistura espectral em linear e não linear. A abordagem linear foi discutida por diversos autores (SHIMABUKURO e SMITH, 1991; LU, MORAN e BATISTELLA, 2003; YANG e HE, 2017; ETTRITCH et al., 2018; GEBRESLASSIE et al., 2020) em variadas temáticas como na análise de frações em regiões urbanas, na classificação de vegetação na região Amazônica, na dinâmica de dunas em praias, etc.

No Brasil, desde 1988 o projeto PRODES - Monitoramento da Floresta Amazônica Brasileira por Satélite é responsável por realizar o mapeamento sistemático da taxa de desmatamento da Amazônia Legal por meio de imagens orbitais advindas de satélites como os da série Landsat, CBERS, IRS-1, entre outros. Nestes estudos são empregados os modelos de mistura espectral com o objetivo de se obter as frações existentes na cena, normalmente as componentes de sombra, vegetação e solo (CÂMARA, VALERIANO e SOARES, 2013).

Desse modo, a utilidade prática no uso do modelo de mistura espectral reside em seus produtos gerados, tipificado pela sua confiabilidade, desconsiderando muitas vezes o uso de imagens de com melhores resoluções espaciais. Além disso, informações e procedimentos mais pormenorizados como a modelagem não linear de mistura espectral, por meio de rede neural

artificial, e influência do tipo de reamostragem no modelo linear, foram discutidos em dois capítulos desta dissertação.

A abordagem do Modelo Não Linear de Mistura Espectral (MNLME) foi objeto de estudos de diversos autores (VAN DE VOORDE, DE ROECK e CANTERS et al., 2009; HALIMI et al., 2016; DOBIGEON et al. 2016; WEI et al. 2017; YU et al., 2017) onde é apresentado frequentemente um desempenho melhor, quando comparado ao modelo linear, em face da sua construção ser baseada na física e em técnicas orientadas a dados (HEYLEN, PARENTE e GADER, 2014).

Halimi et al. (2016) relatam ainda que em decorrência de variações do relevo e da sistemática mistura de materiais há a necessidade de desenvolvimento de modelos mais sofisticados, para que esses efeitos possam ser levados em conta durante o processo de mapeamento.

Neste sentido, existem diversas metodologias para a análise não linear, como por exemplo o SVM (*Support Vector Machine*), a BFM (*Bilinear-Fan Model*), o PPNM *Polynomial post-nonlinear model*, porém a Rede Neural Artificial (RNA) foi uma das primeiras a serem testadas proporcionando resultados satisfatórios (FOODY et al., 1997).

Uma RNA normalmente é configurada como uma função matemática que representa a relação entre a entrada e os dados de saída desejados e pode ser construída a partir de pesos que se interconectam a unidades definidas de modo aleatório. O treinamento da rede é utilizado para ajustar os pesos da rede até que ela consiga ajustar corretamente o conjunto de classes/membros. Este procedimento pode ser obtido com a aplicação do algoritmo de retropropagação (FOODY, 1996; FOODY et al., 1997; YU et al., 2017).

Neste contexto, este estudo visou propor uma análise detalhada sobre os efeitos das reamostragens, em uma metodologia baseada no uso de imagens orbitais provenientes dos sensores ETM+/Landsat 7 e de testes estatísticos para analisar os efeitos no modelo de mistura espectral. Além disso, discutiu-se também a questão do uso de redes neurais artificiais na geração de um MNLME, assim como a comparação de desempenho com a abordagem linear utilizando-se de uma cena do sensor OLI/Landsat 8.

1.1 Justificativa

Atualmente existem diversos *sites* no Brasil e no mundo que facilitam muito o acesso de pesquisadores às imagens orbitais de média e alta resolução espacial, gerando benefícios para a comunidade científica, a partir do aumento de produções bibliográficas relevantes para a sociedade de modo geral.

Poucos estudos relatam o efeito de reamostragens em modelos de mistura, principalmente quando preceitos não tão esclarecidos de estações receptoras localizadas na Europa e Ásia alteraram deliberadamente o tipo de reamostragens de imagens ETM+/L7, oriundas originalmente pelo método do vizinho mais próximo, para o método da convolução cúbica, durante o processo de ortorretificação das cenas. Com isso, atualmente não é mais possível encontrar essas imagens disponibilizadas nos portais fornecedores destes dados e isto corrobora para uma melhor investigação acerca daquelas imagens, que ainda estão disponíveis em acervos pessoais de pesquisadores e cientistas, para serem aplicadas em estudos voltados ao Modelo Linear de Mistura Espectral (MLME).

Ademais, a comparação entre métodos lineares e não lineares é muito válida, principalmente da ótica de sua utilização e confiabilidade, visto que alguns estudos mostram que o modelo linear, mesmo produzindo frações satisfatórias, não existe do ponto de vista físico (KUMAR et al., 2011). A comparação e o confronto de resultados entre métodos auxiliam pesquisadores na tomada de decisão sobre os objetivos a serem alcançados em seus estudos, viabilizando estratégias inteligíveis para as soluções de problemas.

Nesse sentido, o desenvolvimento de metodologias que permitam a avaliação eficaz e contínua de dados espectrais utilizando-se de modelos de misturas, sejam eles lineares ou não, possibilitam a geração de estudos e trabalhos aplicáveis cada vez mais precisos em áreas de queimadas e/ou vulneráveis a problemas de origem ambiental e antrópica.

1.2 Hipóteses

Esta pesquisa baseou-se nas seguintes hipóteses:

1. O processo de reamostragem pelo método da convolução cúbica produz um erro maior quando comparado ao método do vizinho mais próximo no MLME.
2. O MNLME apresenta resultados superiores ao MLME, ou seja, com menor erro absoluto por fração e total.

1.3 Objetivos

Esta pesquisa destinou-se a trabalhar com os modelos linear e não linear de mistura espectral por meio do uso de imagens provenientes dos sensores ETM+/Landsat 7 e OLI/Landsat 8 com o objetivo de comparar os efeitos de diferentes tipos reamostragens, bem como o desempenho e precisão das estimativas de proporção subpixel a partir dos erros médios absolutos.

A fim de alcançar o objetivo geral, os objetivos específicos foram:

- Verificar se uma cena proveniente do sensor ETM+/Landsat 7 apresenta mais erros no MLME quando reamostrada pelo método da convolução cúbica do que pelo método do vizinho mais próximo;
- Verificar se os erros do MNLME modelado por proporções “verdadeiras” subpixel OLI/L8 por meio de dados Planet são superiores ao do MLME.

1.4 Estrutura da dissertação

Esta dissertação foi estruturada em formato de artigos. O capítulo 1 foi composto por uma introdução ao tema, a justificativa, assim como a hipótese e os objetivos que motivaram o cumprimento deste estudo. O capítulo 2 contém o primeiro artigo, que buscou comparar os efeitos de duas reamostragens em uma imagem ETM+/Landsat 7, no modelo linear de mistura espectral, e avaliar se essas reamostragens são significativas do ponto de vista estatístico. No capítulo 3 é apresentado o segundo artigo, no qual contempla o comparativo da precisão das estimativas de proporção de subpixel a partir dos erros médios absolutos entre os modelos linear e não linear de mistura espectral. O capítulo 4 apresenta as conclusões, recomendações e perspectivas desta pesquisa.

2 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

RESUMO

Este trabalho buscou realizar uma comparação da influência de dois tipos de reamostragens em imagens orbitais a partir do uso do modelo linear de mistura espectral. A cena ETM+/Landsat 7, originalmente, disponibilizada pelo método do vizinho mais próximo, teve sua reamostragem alterada para convolução cúbica, incitando se essa alteração, em face da mudança dos valores de números digitais, influenciaria na classificação espectral das imagens. Para o estudo, 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 há 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 nesta área estudo, 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 métodos de reamostragem, por meio desta metodologia, não influenciaram na cartografia final.

Palavras-chave: Modelo Linear de Mistura Espectral. Teste *t* de Student Pareado. Sensoriamento Remoto. Reamostragem. ETM+/Landsat 7.

ABSTRACT

This work sought to compare the influence of two types of resampling on orbital images using the linear model of spectral mixing. The ETM + / Landsat 7 scenes, originally made available by the method of the nearest neighborhood, had their resampling changed to cubic convolution, prompting the discussion about whether this change, in the face of changing digital number values, would influence the spectral classification of the images. For the study, 30 random samples and 30 manual samples 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 paired t-test for means was applied. The statistical results proved that there is not enough evidence, with a significance level of 5% that the averages of the error values of the images generated by the two resampling methods in the linear spectral mixture model are different in this area of study, thus it shows that the application of the model and the analysis of its fractions for 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 in this study, legitimizing that the application of different resampling methods, through this methodology, it did not influence the final cartography.

Keywords: Linear Spectral Mixture Model. Student's Paired *T*-Test. Remote Sensing. Resampling. ETM +/Landsat 7.

2.1 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 e 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 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.

2.1.1. 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, Grant e Dykstra (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 sobre as consequências das reamostragens são pouco discutidos na literatura. Graça (2004) relata a necessidade de utilizar imagens com reamostragem NN para a detecção de perturbações pontuais na floresta Amazônica, as quais foram impossíveis com as imagens com reamostragem CC. Roy e Dikshit (1994) analisando o impacto da reamostragem notaram que em descritores texturais a homogeneidade tende a aumentar, ao passo que descritores que descrevem a heterogeneidade tendem a diminuir.

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.

2.2 OBJETIVOS

2.2.1 Geral

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.

2.2.2 Específicos

- Análise da reamostragem da imagem original com NN para o método CC;
- Utilização do Teste t de Student pareado visando comparar os valores das médias de erro das bandas 3, 4 e 5, vermelho, infravermelho próximo e infravermelho distante, respectivamente;
- Analisar a cartografia final gerada, a partir de classificações das imagens e das frações e do uso de matrizes de confusão.

2.3 FUNDAMENTAÇÃO TEÓRICA

2.3.1 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

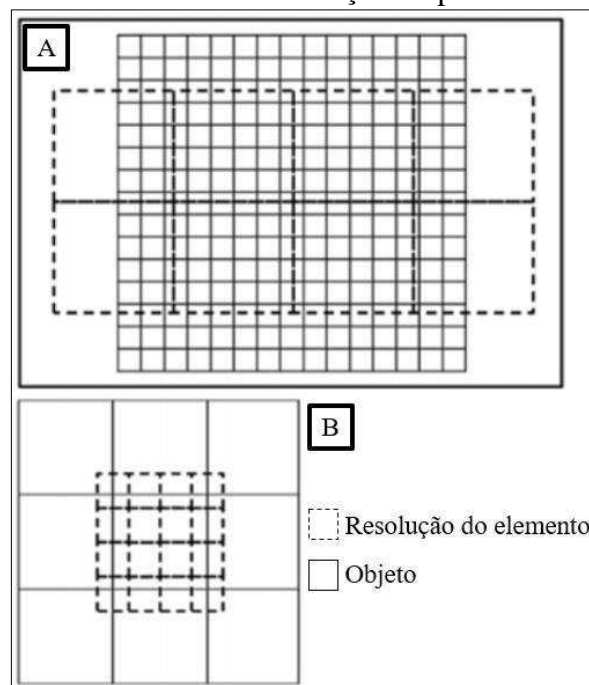
cenas naturais não possuem homogeneidade, normalmente acarretam um número elevado de componentes na mistura, podendo ser ainda maior em face da proporção das componentes específicas dentro de um determinado pixel (SHIMABUKURO; SMITH, 1991).

O “problema” da mistura espectral foi discutido em diversos trabalhos científicos (ADAMS e ADAMS, 1984; LU, MORAN e BATISTELLA, 2003; SILVA, 2008; WANG, CHEN e MA, 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 e SMITH, 1991).

De acordo com Shimabukuro e 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 Figura 1 mostra os problemas da mistura espectral, onde a Figura 1A ilustra a mistura causada pelo tamanho menor dos objetos em relação a resolução do pixel, ao passo que na Figura 1B o objeto é maior que a resolução do pixel, ultrapassando os limites dos outros pixels.

Figura 1 – Ocorrência da mistura espectral em objetos maiores e menores que o tamanho da resolução do pixel



Fonte: Adaptado de Shimabukuro (1987).

A partir de um MLME tornou-se possível investigar as misturas de assinaturas de vegetação e rocha (ADAMS et al., 1982 e ADAMS e ADAMS, 1984), uso do solo (DEFRIES, HANSEN e TOWNSHEND, 2000 e THESEIRA, THOMAS e SANNIER, 2002), estipular os

tipos e abundâncias minerais (SMITH, JONHSON e ADAMS, 1985), mapeamentos de habitats (NOVO e SHIMABUKURO, 1997) e na análise da variação da estrutura de uma floresta usando frações sombra (SHIMABUKURO, 1987).

Neste contexto Shimabukuro e 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.

2.3.2 Imagens-erro do MLME

Conforme apresentado no item anterior, a partir da geração do MLME é exequível os cálculos dos erros para cada uma das bandas espectrais, gerando assim as chamadas imagens-erro, visto que as proporções e as componentes já são de conhecimento do operador (SHIMABUKURO e PONZONI, 2018).

Ainda segundo Shimabukuro e Ponzoni (2018) as imagens-erro permitem constatar a performance do modelo gerado a partir do destaque/realce de uma componente que não tenha sido considerado durante a geração do modelo.

Conforme apresentado na Equação 1, o valor do erro de cada banda pode ser expresso, separadamente, como pode ser visto na Equação 2.

$$\varepsilon_i = \rho_i - \sum_{j=1}^n f_j \rho_{ij} \quad (2)$$

Shimabukuro e Ponzoni (2018) ressaltam ainda que, em função da precisão dos modelos, as imagens-erro apresentam baixos valores, sendo comumente utilizadas para quantificar e examinar a qualidade da definição dos modelos, realçando alguma componente que, eventualmente, não tenha sido representada durante a geração do modelo de mistura.

2.3.3 Reamostragem de dados matriciais

Em processamento digital de imagens existem inúmeras aplicações de técnicas de interpolação, e este procedimento é visto nas mais diversas áreas das ciências exatas. Em sensoriamento remoto, um de seus usos consiste na melhoria visual que impacta diretamente na identificação e interpretação de objetos nas imagens. Para a geração de uma imagem digital, é necessário realizar a conversão dos dados contínuos em um formato digital, e para isso são realizados dois tipos de procedimentos: a amostragem e quantização (GONZALEZ e WOODS, 2018).

Jensen (2015) afirma que o processo de interpolação de intensidade, na prática conhecido por reamostragem, refere-se à remoção de um determinado valor de brilho na imagem de entrada e sua transferência para o local na imagem de saída. De Melo e Pachêco (2004), ressaltam ainda que em face desta mudança de posição altera-se também o valor do nível de cinza baseando-se na vizinhança. Mesmo havendo diversos métodos de reamostragem, os mais comuns encontrados na literatura são: O vizinho mais próximo, o bilinear e a convolução cúbica.

A Tabela 1 apresenta as características mais importantes das duas reamostragens que foram utilizadas nesta pesquisa.

Tabela 1 – Características dos métodos de reamostragem pelo vizinho mais próximo e convolução cúbica

Método	Técnica	Vantagens	Desvantagens
Vizinho mais próximo	Transfere o ND do vizinho mais próximo	Simples de computar; Mantém o ND original.	Imagem pouco estética; Qualidade visual inferior
Convolução Cúbica	Utiliza uma média dos 16 pixels vizinhos mais próximos	Melhor qualidade visual; Suaviza os ruídos.	Perda da integridade dos valores de pixel; Mais moroso computacionalmente; Cálculos complexos.


Fonte: Adaptado de Crósta (1992).

Conforme apresentado na Tabela 1, a reamostragem pelo vizinho mais próximo utiliza o número digital do pixel que está espacialmente mais próximo, transferindo este valor para o pixel correspondente na grade, dando a imagem um efeito de bloco.

Além disso, este procedimento é muito eficiente do ponto de vista computacional, pela sua rapidez em processar os dados, sendo comumente preferido por pesquisadores que fazem estudo de uso e cobertura da terra, por conta de não alterar os valores de brilho do pixel durante a reamostragem (JENSEN, 2015).

Já o processo da convolução cúbica é baseada no ajuste de uma superfície de 4 polinômios de grau 3 à região circundando o pixel em análise (Figura 2), fazendo com que, neste caso, para determinar o valor do pixel testado, são utilizados os valores dos 16 pixels vizinhos mais próximos, resultando em uma imagem mais suavizada, com efeito mais natural, porém este método altera os parâmetros estatísticos da imagem (GONZALEZ e WOODS, 2018).

Figura 2 – Exemplificação da reamostragem pelo método da convolução cúbica



Fonte: Adaptado de Rotta (2012).

Além disso, Jensen (2015) apresenta, na Equação 3, como é computado o novo valor de brilho (VBmp), após o uso do método da convolução cúbica:

$$\text{Convolução Cúbica BVmp} = \frac{\sum_{k=1}^{16} \frac{Z_k}{D_k^2}}{\sum_{k=1}^{16} \frac{1}{D_k^2}} \quad (3)$$

Onde Z_k corresponde aos valores dos 16 pixels próximos e D_k^2 são as distâncias ao quadrado do ponto em questão.

Roy e Dikshit (1994) trabalharam com os efeitos da reamostragem pelos métodos da convolução cúbica e bilinear em texturas de imagens do sensor MSS, e os resultados mostraram que o grau de modificação decorre da variação do nível de cinza da imagem e das propriedades de suavização do algoritmo de reamostragem. Neste caso os autores encontraram valores mais pronunciados na imagem reamostrada pelo método bilinear.

2.3.4 Sistema ETM+/ Landsat 7

O projeto do programa Landsat iniciou-se em meados dos anos 60 pela NASA (*National Aeronautics and Space Administration*) denominado, em sua gênese, como ERTS-1 (*Earth*

Resources Technology Satellite) recebendo no ano de 1975 o nome Landsat. O principal escopo do programa é fornecer informações diretamente relacionadas a recursos naturais, tais como, geologia, agricultura, florestas, entre outros, a partir de dados multiespectrais de seus sistemas imageadores (EMBRAPA, 2013).

A série composta por 8 satélites mantém fortemente sua relevância e utilidade para com a comunidade de usuários por conta tanto do seu rico e importante acervo multitemporal quanto pela atualização contínua dos dados imageados.

O Landsat 7 lançado em 15 de abril de 1999, possui a bordo o instrumento/sensor ETM+ (*Enhanced Thematic Mapper Plus*) que, por sua vez, ofereceu tanta eficiência e versatilidade quanto aos seus predecessores, cooperando na ampliação dos produtos gerados em face do significativo melhoramento da acurácia do sistema, da ampliação da resolução espacial do infravermelho termal e por possibilitar a fusão, em composição colorida de 15 metros de resolução espacial, a partir da banda pancromática (EMBRAPA, 2013).

Os produtos gerados pelo sensor ETM+/Landsat 7 consistem em 8 bandas multiespectrais e suas especificidades são apresentadas na Tabela 2.

Tabela 2 – Características do sensor imageador ETM+

Bandas ETM+/L7	Resolução Espectral (µm)	Resolução Espacial (m)	Resolução Radiométrica	Resolução Temporal
(B1) AZUL	0,45 – 0,51	30	8 bits	16 dias
(B2) VERDE	0,52 – 0,60			
(B3) VERMELHO	0,63 – 0,69			
(B4) INFRAVERMELHO PRÓXIMO	0,76 – 0,90			
(B5) INFRAVERMELHO MÉDIO	1,55 – 1,75			
(B6) INFRAVERMELHO TERMAL	10,4 – 12,5	60		
(B7) INFRAVERMELHO MÉDIO	2,09 – 2,35	30		
(B8) PANCROMÁTICO	0,52 – 0,90	15		

Fonte: Adaptado de Embrapa (2013).

O sensor ETM+ apresentou, em maio de 2003, problemas técnicos referentes ao seu *hardware* e começou a trabalhar com o espelho corretor de linha (*Scan Line Corrector - SLC*)

desligado, e a partir de então as imagens precisaram passar por calibrações de pixels e correções de acurácia para serem utilizadas (EMBRAPA, 2013).

2.3.5 Teste t para amostras pareadas

O processo de teste de hipótese permite examinar se uma afirmação sobre uma particularidade de uma determinada população é válida ou não, e para isso, usa-se um conjunto de dados extraídos desta determinada população (PINHEIRO et al., 2009).

Desenvolvido pelo estatístico britânico Willian Gosset em 1908, o teste t possui inúmeras aplicações em diversas áreas do conhecimento, contudo há uma limitação em seu uso quando se refere a comparação de duas médias e nas hipóteses a serem testadas (ALVES, 2017).

O teste t para amostras pareadas tem como escopo principal a comparação direta entre dois elementos do mesmo par por meio da diferença entre as respectivas medidas (PINHEIRO et al., 2009).

Sejam $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ pares de variáveis aleatórias e considerando as diferenças $D_i = X_i - Y_i$, para todo i , admite-se que D_1, D_2, \dots, D_n são variáveis aleatórias com distribuição normal $(\mu_D; \sigma_D^2)$.

Neste teste são analisadas duas hipóteses, a nula e a alternativa:

- $H_0: \mu_D = 0$;
- $H_1: \mu_D \neq 0$.

Neste sentido, o teste para duas amostras pareadas segue a Equação (4).

$$t_{obs} = \frac{\bar{d} - \mu d}{\frac{s_d}{\sqrt{n}}} \quad (4)$$

Onde

- \bar{d} é a média amostral dos D_i 's, $i=1, \dots, n$;
- μd é a média populacional;
- s_d é o desvio padrão D_i 's, $i=1, \dots, n$;
- n é número de graus de liberdade.

Desse modo, a partir da escolha de um valor de nível de significância, e conforme o valor de t tabelado, a partir dos dados coletados, rejeita-se H_0 quando o $t_{observado} > t_{tabelado}$.

Ainda nesta abordagem, é necessário realizar o teste de normalidade bivariada que, por sua vez é a pressuposição para o teste que comprova se o teste t é significativo. O teste de normalidade tem como hipóteses:

- H_0 : Variável X e Y tem distribuição normal bivariada;
- H_1 : Variável X e Y não tem distribuição normal bivariada.

Neste sentido, apresenta-se o teste estatístico multivariado Shapiro-Wilk que, segundo Royston (1983), uma amostra aleatória, com X_1, X_2, \dots, X_n onde $X_j \in \mathbb{R}^p$ e $X_{(1)k}, X_{(2)k}, \dots, X_{(n)k}$ a amostra aleatória referente a k -ésima variável é ordenada de maneira crescente.

Na Equação 5, segundo Royston (1983), é apresentado o cálculo da estatística W.

$$W_k = \frac{[\sum_{j=1}^n \tilde{a}_j X_{(j)k}]^2}{\sum_{j=1}^n (X_{jk} - \bar{X}_{.k})^2} \quad (5)$$

Onde: $\bar{X}_{.k} = \sum_{j=1}^n \frac{X_{jk}}{n}$ e \tilde{a}_j é o coeficiente estimado associado a j -ésima ordem.

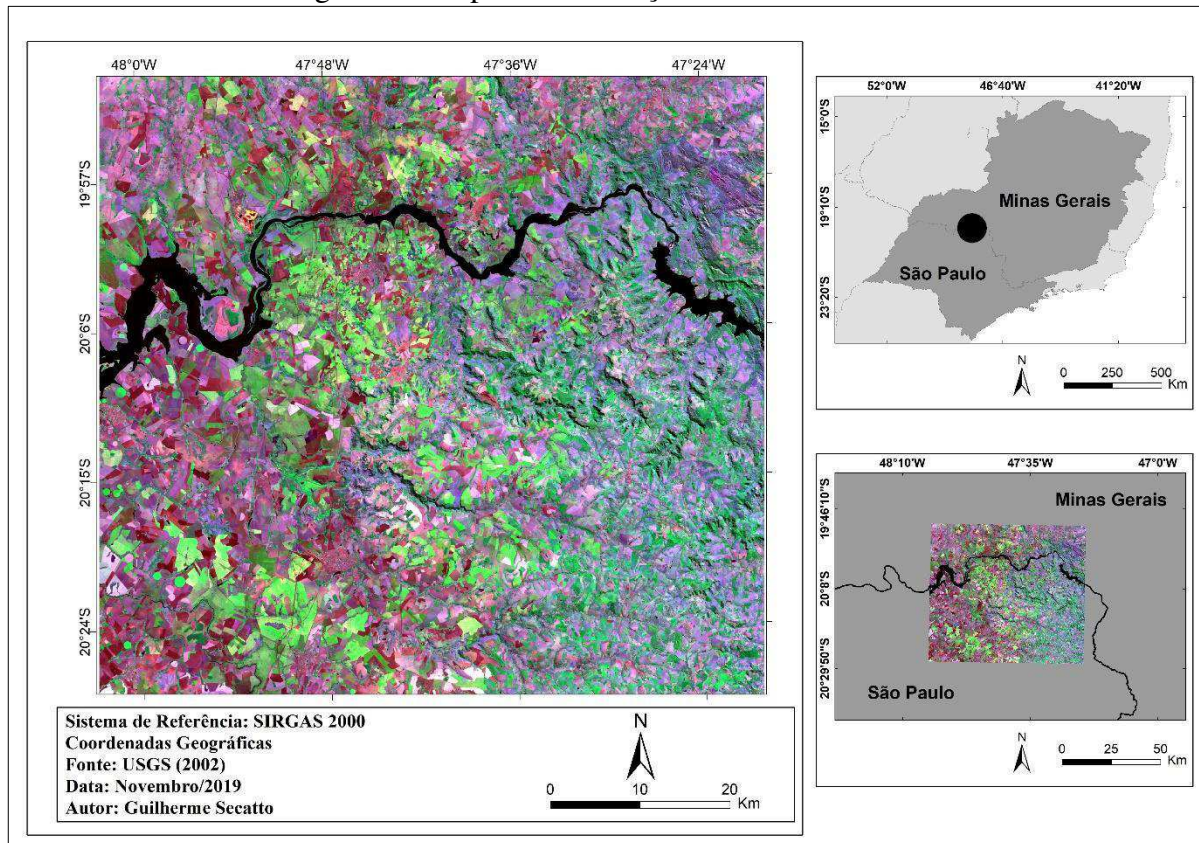
2.4 MATERIAL E MÉTODOS

2.4.1 Características gerais 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 3).

De acordo com a classificação sugerida por Köppen e 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.

Figura 3 – Mapa de localização da área de estudo



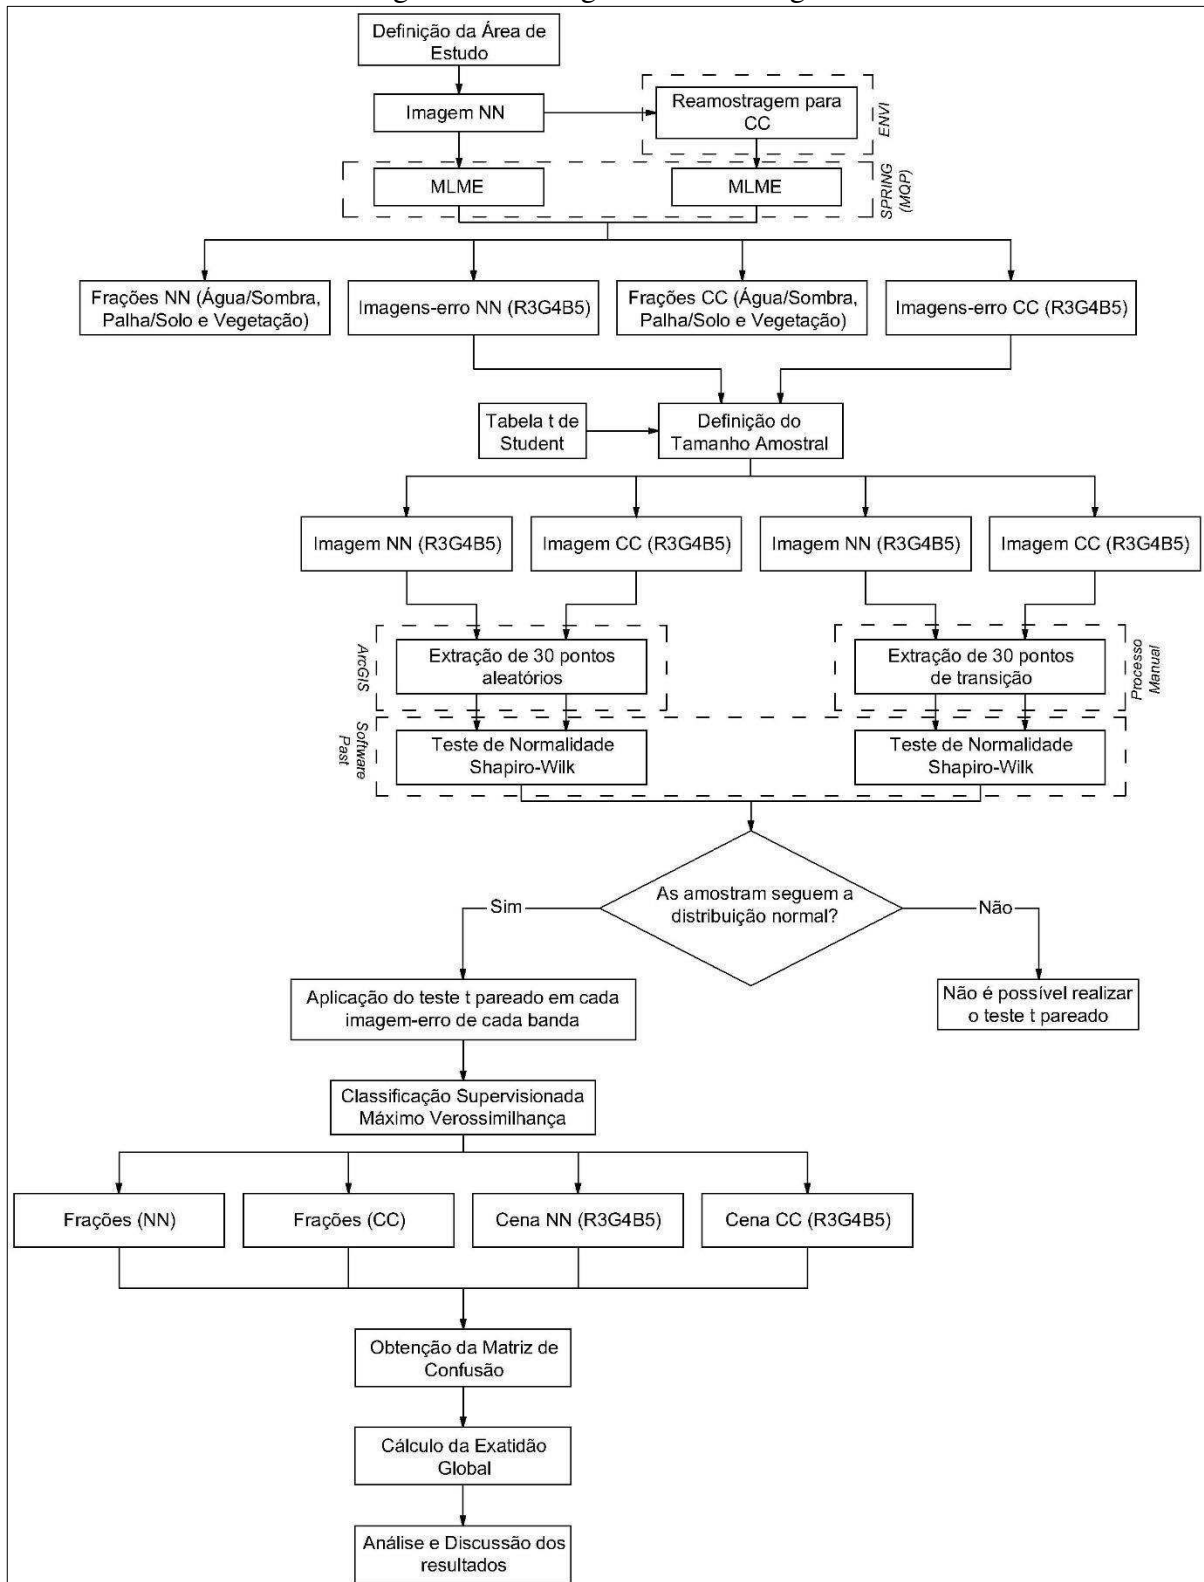
Fonte: Autor.

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.

2.4.2 Reamostragens das cenas pelos métodos NN e CC

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 4 representa o fluxograma metodológico utilizado neste trabalho.


Figura 4 – Fluxograma metodológico



Fonte: Autor.

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 5.

Figura 5 – 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



Fonte: Autor.

A Figura 5A, reamostrada pelo vizinho mais próximo, apresenta maior simplicidade computacional e não altera os valores de ND presentes, produzindo um aspecto mais disjunto dos pixels, ao passo que, a Figura 5B, 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.

2.4.3 Geração do MLME


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 multiespectral.

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 6.

Figura 6 – Determinação dos membros puros da imagem NN



Fonte: Autor.

Com isso, foi possível visualizar, na cena estudada, os membros puros, conforme apresentado na Figura 7.

Figura 7 – *Endmembers* presentes na cena NN

Fonte: Autor.

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 e Novo (2002) busca a solução iterativa 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), calculadas a partir da Equação 2, 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 e_i 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.

2.4.4 Análise Estatística

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:

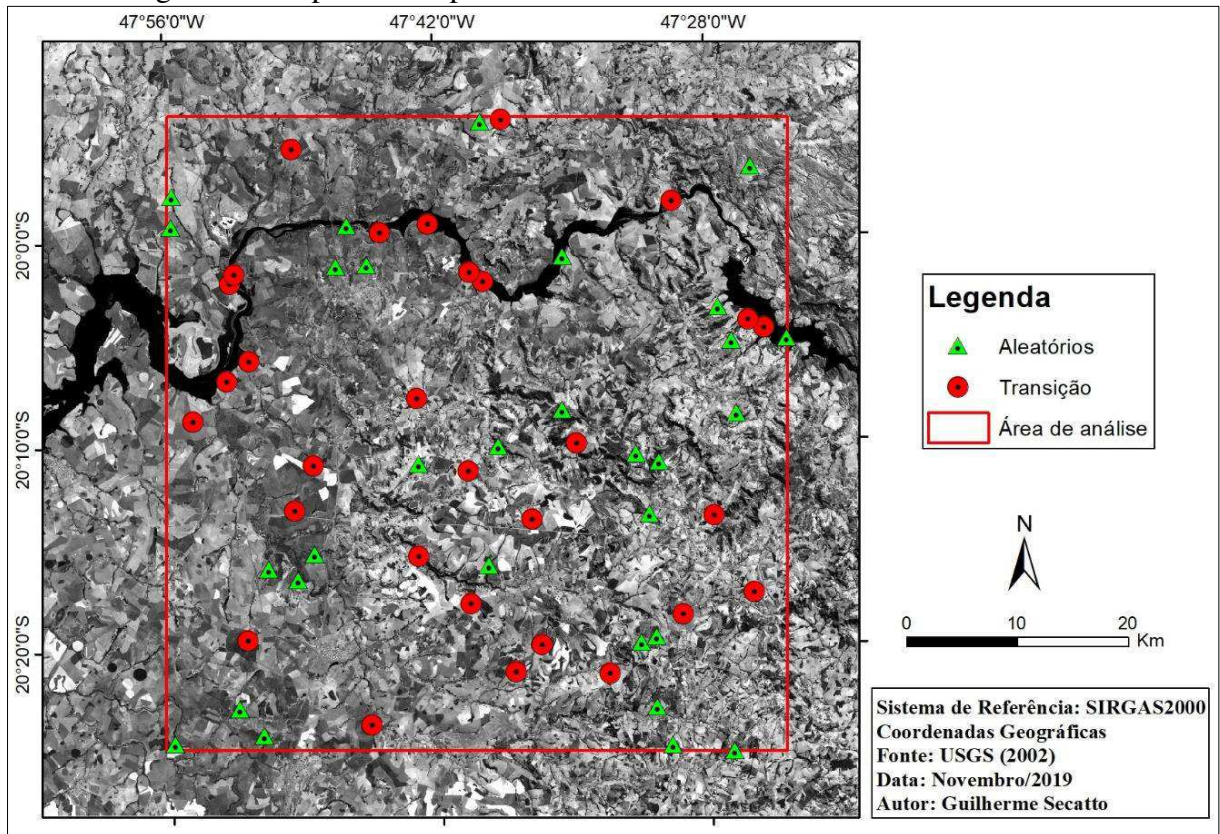
- 1ª. Criação de 30 pontos aleatórios, utilizando-se da ferramenta *Create random points* do ArcGis, em uma área previamente delimitada (evitando as regiões de bordas da imagem, devido a convolução cúbica utilizar a média dos 16 pixels vizinhos);
- 2ª. Inserção manual de outros 30 pontos nas áreas de 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 (Anexo I).

Assim, definiu-se a quantidade de 30 pontos amostrados na imagem para a análise estatística. A Figura 8 apresenta a distribuição espacial dos pontos que foram utilizados.

Figura 8 – Mapa com os pontos amostrados aleatoriamente e manualmente



Fonte: Autor.

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.

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 6.

$$G = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (6)$$

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_{ii} , pelo número total de amostras coletadas n (FIGUEIREDO e VIEIRA, 2007).


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

2.5 RESULTADOS E DISCUSSÕES

2.5.1 MLME


Após a modelagem, foram geradas as imagens-erro dos canais do vermelho, infravermelho próximo e médio para cada uma das imagens reamostradas. As Figuras 9 e 10 apresentam as imagens-erro com reamostragem pelo vizinho mais próximo e pela convolução cúbica, respectivamente.

Figura 9 – Bandas de erro após o MLME da imagem reamostrada pelo método NN. Da esquerda para direita, as bandas do vermelho, infravermelho próximo e médio



Fonte: Autor.


Figura 10 – Bandas de erro após o MLME da imagem reamostrada pelo método CC. Da esquerda para direita as bandas do vermelho, infravermelho próximo e médio



Fonte: Autor.


Visualmente, é imperceptível encontrar diferenças nos resultados das bandas de erro geradas pelo MLME, por isso foi realizada a extração dos valores dos pixels visando verificar e analisar as sutis diferenças. Além disso, são apresentadas nas Figuras 11 e 12 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.

Figura 11 – 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)



Fonte: Autor.

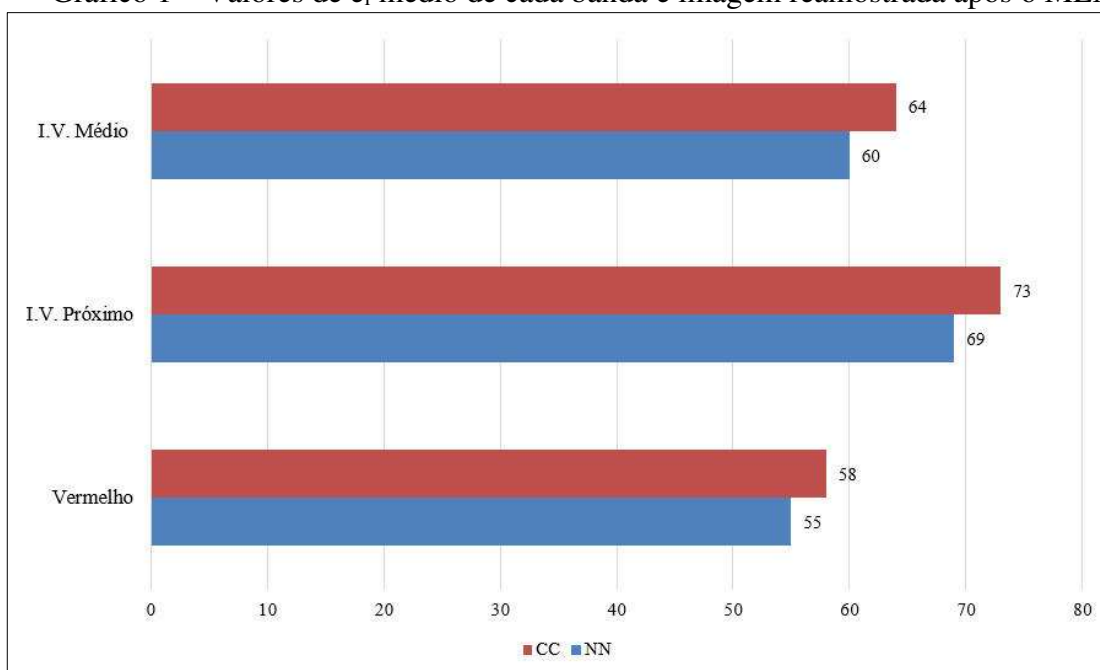
Figura 12 – À esquerda observa-se as frações geradas pelo MLME da imagem reamostrada pelo método CC e a direita, a composição colorida das frações palha/solo (R), vegetação (G) e água/sombra (B)



Fonte: Autor.

Ademais, o Gráfico 1 mostra a comparação 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.

Gráfico 1 – Valores de e_i médio de cada banda e imagem reamostrada após o MLME



Fonte: Autor.

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.

2.5.2 Análise Estatística e Análise de Mapas Finais

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 3.

Tabela 3 – Teste de normalidade dos pontos aleatórios

Banda - Método	Valor W	Valor-p N.S. = 5%	Rejeita H₀ 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

Fonte: Autor.

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 4.

Tabela 4 – Teste de normalidade dos pontos das áreas de transição

Banda - Método	Valor W	Valor-p N.S. = 5%	Rejeita H₀ H₀: $\mu_D = 0$
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

Fonte: Autor.

Assim, após a conclusão de normalidade sobre os dados, foi calculado o teste *t* pareado para verificar indícios de diferenças nas médias. A Tabela 5 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 5 – 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

Fonte: Autor.

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 6.

Tabela 6 – Estatística t para pontos de transição

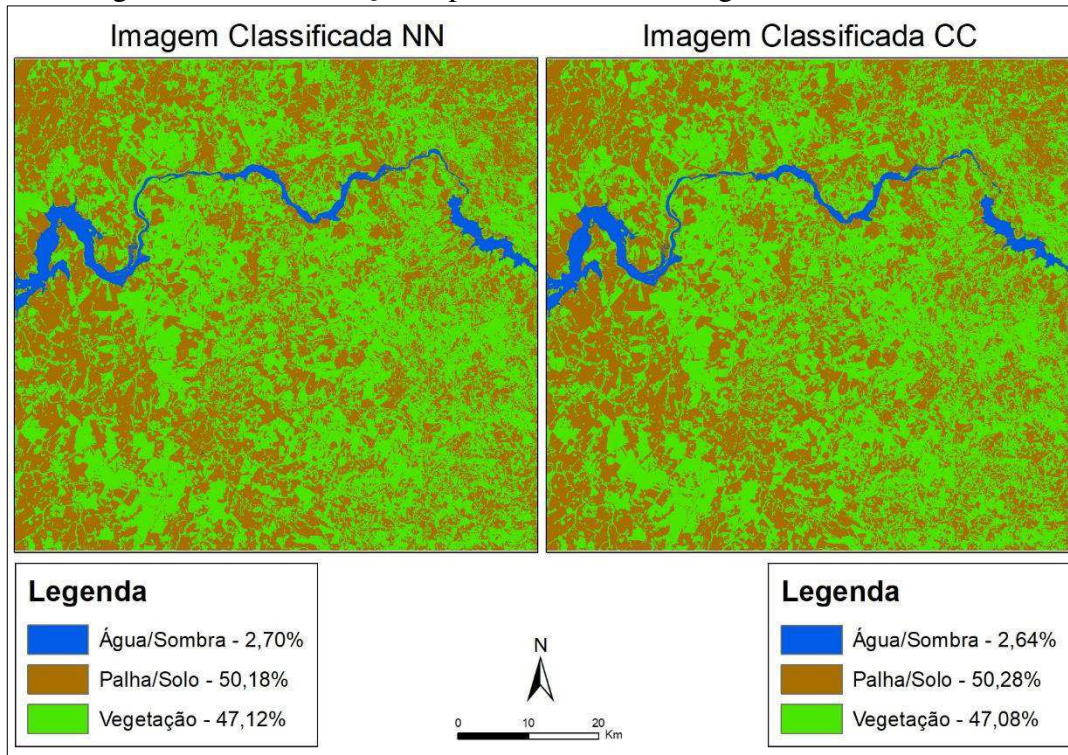
Pontos Transição	Valor T	Rejeita H₀ H0: $\mu_D = 0$
Banda 3 NN – CC	0,24276	Não
		Não
Banda 4 NN – CC	0,00086	Não
		Não
Banda 5 NN – CC	0,41094	Não
		Não

Fonte: Autor.

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.

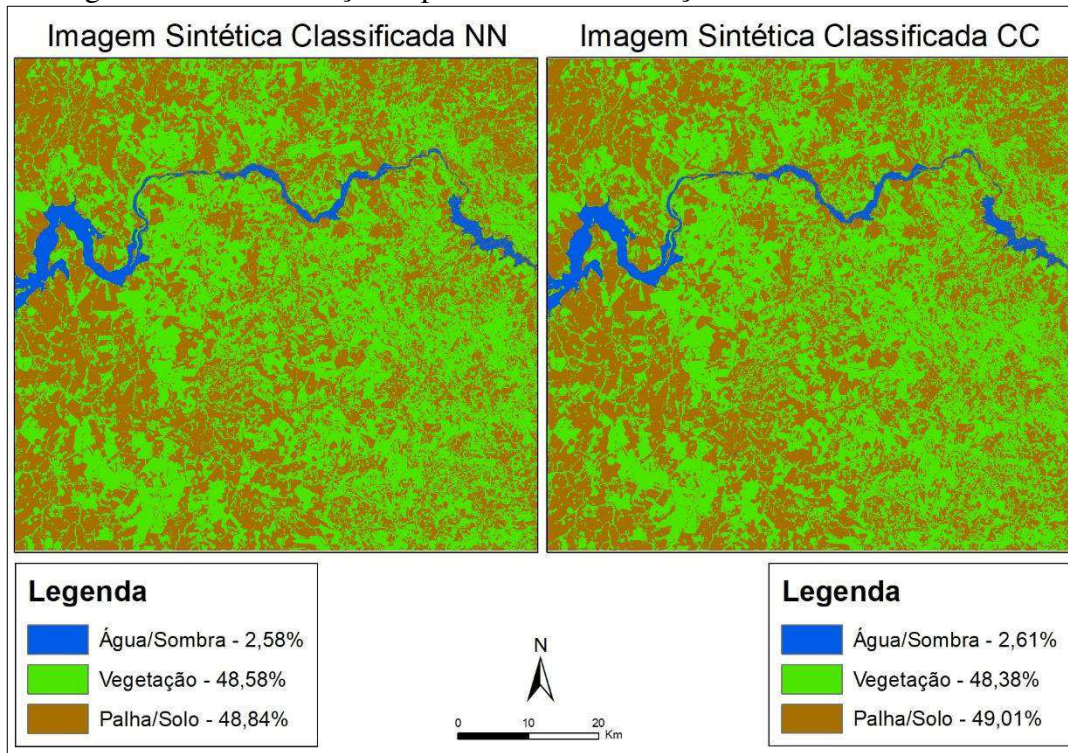
Em consonância aos resultados estatísticos, as Figuras 13 e 14 apresentam as classificações supervisionadas da imagem original com reamostragem NN e da imagem reamostrada CC, além das imagens-fração referentes às frações água/sombra, palha/solo e vegetação, também para cada um dos métodos de reamostragens, respectivamente, assim como a porcentagem das classes água/sombra, palha/solo e vegetação classificadas em cada uma delas.

Figura 13 – Classificação supervisionada das imagens ETM+/Landsat7



Fonte: Autor.

Figura 14 – Classificação supervisionada das frações resultantes do MLME



Fonte: Autor.

Ambas 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 7 e 8 mostram, respectivamente, as matrizes de confusão para a classificação da imagem NN e da CC.

Tabela 7 – Matriz de confusão para a imagem classificada pelo método NN

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

Fonte: Autor.

Tabela 8 – Matriz de confusão para a imagem classificada pelo método CC

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

Fonte: Autor.

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 9 e 10 apresentam os valores das matrizes de confusão para a classificação das imagens-fração NN e da CC, respectivamente.

Tabela 9 – Matriz de confusão para a imagem fração NN

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

Fonte: Autor.

Tabela 10 – Matriz de confusão para a imagem fração CC

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

Fonte: Autor.

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.

2.6 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.

REFERÊNCIAS BIBLIOGRÁFICAS

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 eletrônicos. Cairo, Egito, 1982. Disponível em: <http://agris.fao.org/agris-search/search.do?recordID=US8245635>. Acesso em: 25 nov. 2019.

ALVES, M. C. Teste t de Student. Seção Técnica de Informática. Data completa 2017. Notas de Aula. Universidade de São Paulo Escola Superior de Agricultura - Luiz de Queiroz.

CAMACHO-DE COCA, F., GARCÍA-HARO, F.J.; GILABERT, 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.

CRÓSTA, A.P. **Processamento Digital de Imagens de Sensoriamento Remoto**. ed. rev. Campinas, SP: UNICAMP, 1992.

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.

DE MELO, I. D. F.; PACHÊCO, A. P. Aspectos da correção geométrica de imagens orbitais. Em: anais eletrônicos. **I Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação**, 2004. Disponível em: <https://docplayer.com.br/5914225-Aspectos-da-correcao-geometrica-de-imagens-orbitais-ivan-dornelas-falcone-de-melo-1-admilson-p-pacheco-2.html>. Acesso em: 27 nov. 2019.

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.

EMBRAPA. **Monitoramento por satélite**. Campinas: Embrapa Monitoramento por Satélite, 2013. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 10 nov. 2019.

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. **Anais do Simpósio Brasileiro de Sensoriamento Remoto**, 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. **Anais do Simpósio Brasileiro de Geomática**, p. 150-161, 2002.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. ed. 4. New York: Pearson, 2018.

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.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. ed 4. Glenview, Illinois: Prentice Hall, 2015.

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.

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.

PINHEIRO, J. I. D.; DA CUNHA, S. B.; CARVAJAL, S. R.; GOMES, G. C. **Estatística Básica - A Arte de Trabalhar com Dados**. Elsevier Brasil, 2009.

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.

ROYSTON, J. P. Some techniques for assessing multivariate normality based on the Shapiro-Wilk W. **Journal of the Royal Statistical Society: Series C (Applied Statistics)**, v. 32, n. 2, p. 121-133, 1983.

SHIMABUKURO, Y. E. **Shade images derived from linear mixing models of multispectral measurements of forested areas**. 1987. Tese (Doutorado em Ciências Florestais/Sensoriamento Remoto), Colorado State University, Fort Collins, 1987.

SHIMABUKURO, Y. E.; PONZONI, F. J. **Spectral Mixture for Remote Sensing: Linear Model and Applications**. Springer, 2018.

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. 2008. 109 f. Tese (Doutorado em Engenharia Civil), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

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 eletrônicos. Wuhan, 2008. Disponível em: <https://www.spiedigitallibrary.org/conference-proceedings-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.

3. ANÁLISE DOS VALORES DE ERRO ABSOLUTO ENTRE OS MODELOS LINEAR E NÃO LINEAR DE MISTURA ESPECTRAL A PARTIR DE IMAGENS MULTIRESOLUÇÃO

RESUMO

O objetivo da análise de mistura espectral é estimar as proporções de diferentes tipos de coberturas da superfície ao nível subpixel, fazendo-se uso de classificadores que permitem rotular o pixel, como por exemplo, um classificador “*hard*”. Em geral, existem dois modelos que são utilizados para essa finalidade, podendo ser categorizados em lineares e não lineares. Embora seja senso comum associar que quanto melhor for a resolução espacial de uma imagem maior será a pureza dos pixels, a relação entre o tamanho do pixel e a mistura espectral ainda não é totalmente esclarecida. Problemas como classificações equivocadas e estimativas com baixa precisão fazem com que mapeamentos se tornem dúbios e incoerentes, principalmente pelo fato de haver mistura de componentes da superfície terrestre, e para isso é necessário aplicar metodologias de misturas espectrais. Assim, esta pesquisa buscou avaliar a precisão das estimativas de proporção subpixel, a partir dos erros médios absolutos por fração e o erro médio absoluto total, entre os modelos linear e não linear de mistura espectral. Para isso, foi utilizada uma imagem Planet, de 3 metros de resolução espacial, e realizou-se uma classificação supervisionada, pelo método da máxima verossimilhança, visando a extração das classes de água/sombra, palha/solo e vegetação (referência). A partir destes dados foi estruturada uma rede neural artificial e realizou-se seu treinamento por meio do algoritmo de retropropagação. Com isso, ela foi capaz de estimar as proporções, tendo como entrada dados espectrais de uma imagem OLI/Landsat de 30 metros. Paralelamente, foi feita uma modelagem linear de mistura espectral da mesma imagem Landsat, a fim de comparar os resultados das frações, utilizando 6491 amostras, por meio de equações do erro médio absoluto. Os resultados mostraram que o modelo linear obteve valores de erro médio absoluto por fração e total maiores, este último sendo de 1,023, ao passo que o modelo não linear apresentou 0,310, o que, na prática, comprova que quando comparadas a uma mesma referência de dados, o modelo não linear resultou em menores valores de erro médio, sendo considerada, portanto, uma modelagem mais adequada.

Palavras-chave: Modelo Linear de Mistura Espectral. Modelo Não Linear de Mistura Espectral. Sensoriamento Remoto. Rede Neural Artificial. Erro Médio Absoluto.

ABSTRACT

The purpose of the spectral mixture analysis is to estimate the proportions of different types of surface coverings at the subpixel level, using classifiers that allow the pixel to be labeled, such as a “hard” classifier. In general, there are two models that are used for this purpose, which can be categorized as linear and nonlinear. Although it is common sense to associate that better the spatial resolution of an image, the purity of the pixels will be greater, the relationship between the pixel size and the spectral mixture is still not fully understood. Problems such as misclassifications and estimates with low precision cause mappings to become dubious and incoherent, mainly due to the mixing of components of the Earth's surface, and for this it is necessary to apply spectral mix methodologies. Thus, this research sought to evaluate the precision of the subpixel proportion estimates, from the mean absolute errors per fraction and the mean absolute error total, between the linear and nonlinear spectral mixture models. For this, a Planet image of 3 meters of spatial resolution was used, and a supervised classification was carried out, using the maximum likelihood method, aiming to extract the classes of water/shade, straw/soil and vegetation (reference). Based on these data, an artificial neural network was structured and trained using the error backpropagation algorithm. With this, it was possible to estimate the proportions, using as input a spectral data from an OLI/Landsat image of 30 meters. In parallel of this, it was modeling of the spectral mixture of the same Landsat image was made, in order to compare the results of the fractions, using 6491 samples, by equations of the mean absolute error. The results showed that the linear model obtained higher mean absolute error values per fraction and total, the latter being 1.023, while the nonlinear model presented 0.310, which, in practice, proves that when compared to the same data reference, the nonlinear model resulted in lower values of the mean error, being considered, therefore, a more adequate modeling.

Keywords: Linear Spectral Mixture Model. Non-Linear Spectral Mixture Model. Remote Sensing. Artificial Neural Network. Mean Absolute Error.

3.1 INTRODUÇÃO

A evolução do sensoriamento remoto ao longo das últimas décadas apresentou uma série de melhorias na obtenção e no processamento de dados das mais variadas resoluções espaciais e espectrais. Do ponto de vista espectral, o uso de sensores multi e hiperespectrais consolidaram uma nova fase de opulentos resultados expressivos em várias áreas como mapeamentos urbanos, rurais, geológicos, agricultura de precisão, entre outros.

Já com a perspectiva espacial que, motivada pelo anseio em lograr informações mais detalhadas, acerca das especificidades dos materiais contidos nos pixels das cenas, apresentou inovações em sensores de pequeno e médio formato com resoluções submétricas para uso em diversos tipos de temas e áreas de estudo.

Neste sentido, é senso comum imaginar o modo que se deve analisar o pixel e o que ele representa em uma imagem. É sabido que a superfície terrestre é constituída de mais de um tipo de cobertura do solo, tendo, naturalmente, assinaturas espectrais diferentes, contudo uma resultante geralmente é registrada e caracterizada pelo sensor, ofuscando assim, sua composição heterogênea (ICHOKU e KARNIELI, 1996).

Os autores supracitados ainda mencionam que os pixels mistos são, majoritariamente, os responsáveis por problemas na classificação de uma imagem orbital e isso corrobora a utilização de modelos no reconhecimento da heterogeneidade dos pixels.

Nesta perspectiva, o estudo sobre o conteúdo de pixels puros e mistos são estudados por diversos autores, utilizando-se de uma técnica conhecida por Análise de Mistura Espectral, que pode ser ramificada entre os modelos lineares (SHIMABUKURO e SMITH, 1991; ICHOKU e KARNIELI, 1996; LU, MORAN e BATISTELLA 2003 e CAMACHO-DE COCA et al., 2004) e não lineares (LIU e WU, 2005; VAN DE VOORDE, DE ROECK e CANTERS, 2009 e HEYLEN, PARENTE e GADER, 2014). Ambas as técnicas são utilizadas para estimar proporções de diferentes tipos de coberturas contidas em um pixel.

Ichoku e Karnieli (1996) e Keshava e Mustard (2002) afirmaram em seus estudos que é possível obter melhor precisão na estimativa da composição do uso do solo em um processo conhecido como “desmistificação” de misturas, que consiste na dissociação quantitativa do pixel misto da cena para que possa ser determinada a proporção ou fração de seus verdadeiros tipos de cobertura, comumente chamado de *endmembers* ou membros puros. Na abordagem

linear o espectro de refletância de pixels mistos deve ser uma combinação linear ponderada dos *endmembers* (LU, MORAN e BATISTELLA, 2003 e ZANOTTA et al., 2013).

Estudos acerca do modelo de mistura espectral não linear usam a abordagem da rede neural artificial (RNA) em face da desconsideração de pressupostos físicos, fato que vai em contrapartida ao do modelo linear, onde os pressupostos físicos são levados em conta (HEYLEN, PARENTE e GADER, 2014). Outras metodologias também foram empregadas na abordagem não linearizada, como a SVM - *Support Vector Machine*, porém a RNA utilizando-se de uma rede de estrutura MLP (*MultiLayer Perceptron*) obteve melhor desempenho (YU et al., 2017).

Neste sentido, este trabalho foi direcionado a determinar a análise dos erros absolutos das frações do MLME e MNLME, objetivando corroborar na tomada de decisão para o uso do melhor modelo em situações que envolvam classificação de imagens com aplicações em estudos de florestas, uso e cobertura do solo e agricultura.

A premissa a ser testada neste trabalho envolve a desmistificação da mistura espectral apoiada no trabalho de Kumar et al. (2011) que relatou que o modelo de mistura linear produz resultados irreais do ponto de vista físico, e assim, motivando o anseio em modelar uma mistura espectral não linearizada e confrontá-la com a linear para avaliar suas respectivas diferenças.

3.2 OJETIVOS

3.2.1 Objetivo Geral

O objetivo principal desta pesquisa foi avaliar e comparar os desempenhos entre os modelos linear e não linear de mistura espectral.

3.2.2 Objetivos Específicos


- Explorar o potencial do MLME e do MNLME, a partir de dados espectrais de um sensor de baixa resolução espacial e das proporções usadas como referência;
- Analisar o MLME e suas frações a partir de uma cena OLI/Landsat 8;
- Avaliar os valores dos erros médios de cada fração, assim como o do erro médio absoluto de cada modelo.

3.3 FUNDAMENTAÇÃO TEÓRICA

3.3.1 Modelo Não Linear de Mistura Espectral

O espectro de reflectância de uma mistura é o conjunto sistemático dos espectros de reflectância de componentes da mistura final, assim tanto o MLME (SHIMABUKURO e SMITH, 1991) quanto o MNLME (SOMERS et al., 2009; VAN DE VOORDE, DE ROECK e CANTERS, 2009) são constantemente empregados na aferição de proporção dos mais variados tipos de coberturas dentro do pixel.

Van de Voorde, De Roeck e Canters (2009) e Yu et al. (2017) relataram em seus estudos um desempenho superior da abordagem não linear quando comparada a linear. A principal diferença entre os dois modelos é que o MNLME considera um múltiplo espalhamento entre diferentes coberturas, ao passo que no MLME isso não ocorre (CLARK et. al, 2005). A Figura 15 ilustra o cenário teórico de um MNLME.



Fonte: Keshava e Mustard (2002).

Existem diversas formas de analisar a questão da mistura não linear, entre as mais comuns disponíveis na literatura estão a RNA (LICCIARDI e DEL FRATE, 2011), o modelo bilinear (HALIMI et al., 2016) e a *Support Vector Machines* (SVMs) (TANG et al., 2008).

Heylen, Parente e Gader (2014), citam que a análise de mistura espectral a partir de uma rede neural artificial (RNA) é classificada como uma abordagem não linear, por conta da hipótese física do MLME não ser contemplada. Foody (1996) afirmou que a utilização da RNA foi uma das primeiras metodologias a serem empregadas na análise do MNLME, e esse fato é justificado, segundo Heylen, Parente e Gader (2014), por conta de sua sólida construção e pelo uso de uma rede de estrutura MLP (*MultiLayer Perceptron*).

Zhang e Foody (2001) relatam que uma RNA pode ser arquitetada como sendo uma complexa função matemática, cujo objetivo é simular a relação entre entrada e saída de dados, e seu uso em análises de misturas espectrais está relacionada a sua robustez em conseguir utilizar amostras com baixo nível de precisão ou incompletas.

Zhang e Foody (2001) mencionam ainda que a montagem de uma RNA consiste em uma camada de entrada, uma oculta e uma de saída, onde o número de nós ocultos é subjetivo, e é determinado com base nas execuções de teste, tendo a função de armazenar, e tornar disponível para uso, o conhecimento treinado.

Neste sentido o conjunto de unidades interligadas que realizam o processamento são denominadas por nós ou neurônios, recebendo o nome de Rede Neural *feedforward* (HAYKIN, 2001). Um exemplo de rede *feedforward* é a MLP que é constituída de múltiplas camadas, onde cada uma possui um conjunto de nós. Cada nó está conectado por pesos, com todos os nós da camada subsequente. O MLP transforma entradas em saídas por meio de alguma função não-linear, como exemplo uma função sigmoide (YILMAZ e KAYNAR, 2011), conforme pode ser vista na Equação 7.

$$x_0 = \frac{1}{1 + e^{(-\sum_{h=1}^H (x_h * w_{h,0}))}} \quad (7)$$

Yilmaz e Kaynar (2011) relatam ainda que a função de ativação é aplicada no h-ésimo neurônio da camada escondida e no o-ésimo neurônio da camada de saída, sendo que um erro é definido a partir da diferença entre a saída e o valor esperado. Yilmaz e Kaynar (2011) complementam ainda que o objetivo é minimizar o erro, por meio dos ajustes dos pesos entre as camadas, conforme pode ser visto na Equação 8.

$$E = \frac{1}{N} * \sum_{S=1}^N \left(\frac{1}{2} * \sum_{O=1}^L (t_0^{(S)} - x_0^{(S)})^2 \right) \quad (8)$$

Onde N representa a quantidade de padrões de entrada referente ao conjunto de dados do treinamento, L refere-se ao número de neurônios da camada de saída, $t_0^{(s)}$ é o valor estimado de saída para o o-ésimo neurônio e $x_0^{(s)}$ é o cálculo da saída do o-ésimo neurônio da camada de saída.

Neste contexto, para aprendizagem em redes *feedforward* de MLP o método desenvolvido e proposto por Rumelhart (1986), conhecido por *error backpropagation*, é amplamente aplicado em treinamentos de RNAs.

Este algoritmo baseia-se em um ajuste iterativo dos pesos, com o escopo de reduzir eventuais diferenças entre a saída atual e a treinada. Ao longo da aprendizagem, um dado de entrada é evidenciado para a rede e propagado para definir os valores da saída, resultando em um erro, que por sua vez é retropropagado, proporcionando o ajuste dos pesos. Este procedimento é iterativo e perdura até o momento em que a rede responda, que para cada dado de entrada, produza dados satisfatoriamente próximos dos valores desejados (TISSOT, CAMARGO e POZO, 2012).

3.3.2 Sistema OLI Landsat 8 e Planet

O satélite Landsat 8 foi lançado a partir da Base da Força Aérea de Vandenberg, na Califórnia, EUA em 11 de fevereiro de 2013, carregando consigo os sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*) (EMBRAPA, 2013).

A Tabela 11 apresenta as características espectrais do sensor OLI.

Tabela 11 – Características do sensor imageador OLI

Bandas OLI/LS	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Radiométrica	Resolução Temporal
(B1) AZUL COSTEIRO	0,43 – 0,45	30	12 bits	16 dias
(B2) AZUL	0,45 – 0,51			
(B3) VERDE	0,53 – 0,59			
(B4) VERMELHO	0,64 – 0,67			
(B5) INFRAVERMELHO PRÓXIMO	0,85 – 0,88			
(B6) INFRAVERMELHO MÉDIO	1,57 – 1,65			
(B7) INFRAVERMELHO MÉDIO	2,11 – 2,29			
(B8) PANCROMÁTICO	0,50 – 0,68	15		
(B9) CIRRUS	1,36 – 1,38	30		

Fonte: Adaptado de Embrapa (2013).

Os produtos gerados pelo referido sensor consistem em nove bandas multiespectrais, com resoluções espaciais de 15 metros para a banda 8 (pancromática) e 30 metros para as bandas de 1 a 7 e 9. Já a resolução radiométrica de 12 bits permite uma melhora na relação ruído/sinal e na descrição das condições e estados dos alvos em uma cena (EMBRAPA, 2013).

Já o sistema Planet opera diversos tipos de constelações satelitais de imageamento da Terra, tais como o PlanetScope (PS), RapidEye (RE) e SkySat (SS). As cenas são adquiridas e é realizado um processamento em diversos formatos com o escopo de atender os mais variados tipos de uso, como resposta a desastres ambientais, mapeamento de expansão urbana e infraestrutura, controle de queimadas e desmatamento, apoio à agricultura de precisão e análises multitemporais (PLANET, 2018).

A constelação da PlanetScope consiste em lançamentos de grupos de satélites individuais possuindo, atualmente, cerca de 120 satélites imageando o globo todos os dias, a uma taxa de 150 milhões km^2 por dia (PLANET, 2018).

A Tabela 12 apresenta as principais características do sensor PS2 Planet.

Tabela 12 – Características do sensor PS2 Planet

Bandas PS2	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Radiométrica	Resolução Temporal
(B1) AZUL	0,45 – 0,51	3	12 bits	Diariamente
(B2) VERDE	0,52 – 0,58			
(B3) VERMELHO	0,59 – 0,67			
(B4) INFRAVERMELHO PRÓXIMO	0,78 – 0,86			

Fonte: Adaptado de Planet (2018).

O sistema Planet oferece três segmentos de produtos para imagens PlanetScope: o *Basic Scene*, que consiste em imagens corrigidas geometricamente; o *Ortho Scene* que se refere a imagens em quadro único e ortorretificadas; e o *Ortho Tile* que versa um conjunto de várias cenas ortorretificadas em um único quadro (PLANET, 2018).

3.3.3 Desempenho e erro médio absoluto de frações em modelos de mistura

A avaliação de desempenho de modelos lineares e não lineares de mistura espectral é constantemente estudada e discutida, por diversos autores, desde a década de 90. Para este tipo de análise são adotadas as frações de referência e frações estimadas, nas quais os métodos de comparação podem ser via *scatter plot* ou por meio de cálculos estatísticos do erro absoluto.

Liu e Wu (2005), Van de Voorde, De Roeck e Canters (2009) e Yu et al. (2017) utilizaram em seus trabalhos dados de sensores de alta resolução espacial como referência para calcular o erro de modelos de mistura. Nestes casos, foram usados como referência as imagens dos sensores MS/Ikonos (4 metros), ETM+/L7 (30 metros) e GeoEye (2 metros), respectivamente.

Van de Voorde, De Roeck e Canters (2009) apresentaram em seus estudos o cálculo do erro médio absoluto por classe ou fração (Equação 9), e erro médio absoluto total (Equação 10).

$$EMA_{Cj} = \sum_{i=1}^N \frac{|P'_{ij} - P_{ij}|}{N} \quad (9)$$

$$EMAT = \sum_{j=1}^C (EMA)_{Cj} \quad (10)$$

Onde:

- EMA é o erro médio absoluto de cada fração;
- $EMAT$ é o erro médio absoluto total;
- N é o número total das amostras;
- C é a quantidade de frações analisadas (água/sombra, palha/solo e vegetação);
- P'_{ij} é a proporção da classe j dentro do pixel i (valor estimado pela rede);
- P_{ij} é a proporção da classe j dentro do pixel i (valor de referência).

A Equação 9 tem por finalidade avaliar a quantidade de erro em cada fração (água/sombra, palha/solo e vegetação) e pode ser interpretada como uma porcentagem média de erro, ao passo que a Equação 10 representa o desempenho geral dos dois modelos e um valor de precisão generalizado, o qual consiste, simplesmente, no somatório de cada classe-alvo.

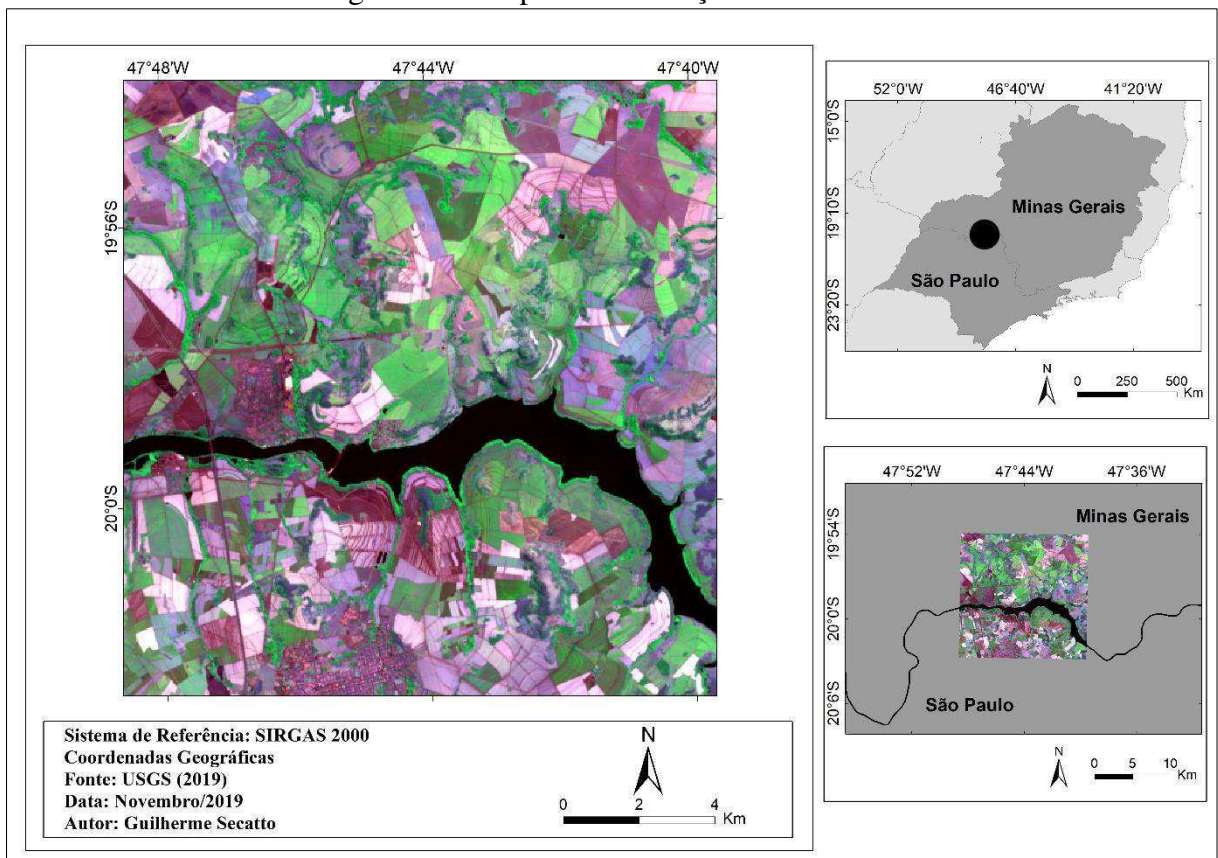
No estudo de Van de Voorde, De Roeck e Canters (2009) foi verificado que o MNLME apresentou um desempenho melhor em termos de precisão quando comparado ao MLME.

3.4 MATERIAL E MÉTODOS

3.4.1 Características gerais da área de estudo

A área de estudo está localizada na divisa entre os estados de São Paulo e Minas Gerais, compreendida entre as coordenadas geográficas 19° 90' e 20° 04' de latitude sul e 47° 80' e 47° 65', conforme apresentado na Figura 16.

Figura 16 – Mapa de localização da área de estudo



Fonte: Autor.

O clima da região é classificado como Aw – Tropical, de acordo com a classificação proposta por Köppen e Geiger (1928). A temperatura e pluviosidade média anual é de 22 °C e 1.500mm, respectivamente. A vegetação típica é composta, majoritariamente, pela floresta tropical com transição para o cerrado.

A região de estudo está inserida na Bacia do Rio Grande e sua economia baseia-se na produção de cana-de-açúcar, assim como a indústria sucroalcooleira e a pecuária de corte e leite. O turismo local também é bastante desenvolvido, com a manutenção de clubes náuticos e de locais para pesca amadora.

3.4.2 Materiais utilizados

Para este trabalho foram utilizados os seguintes materiais:

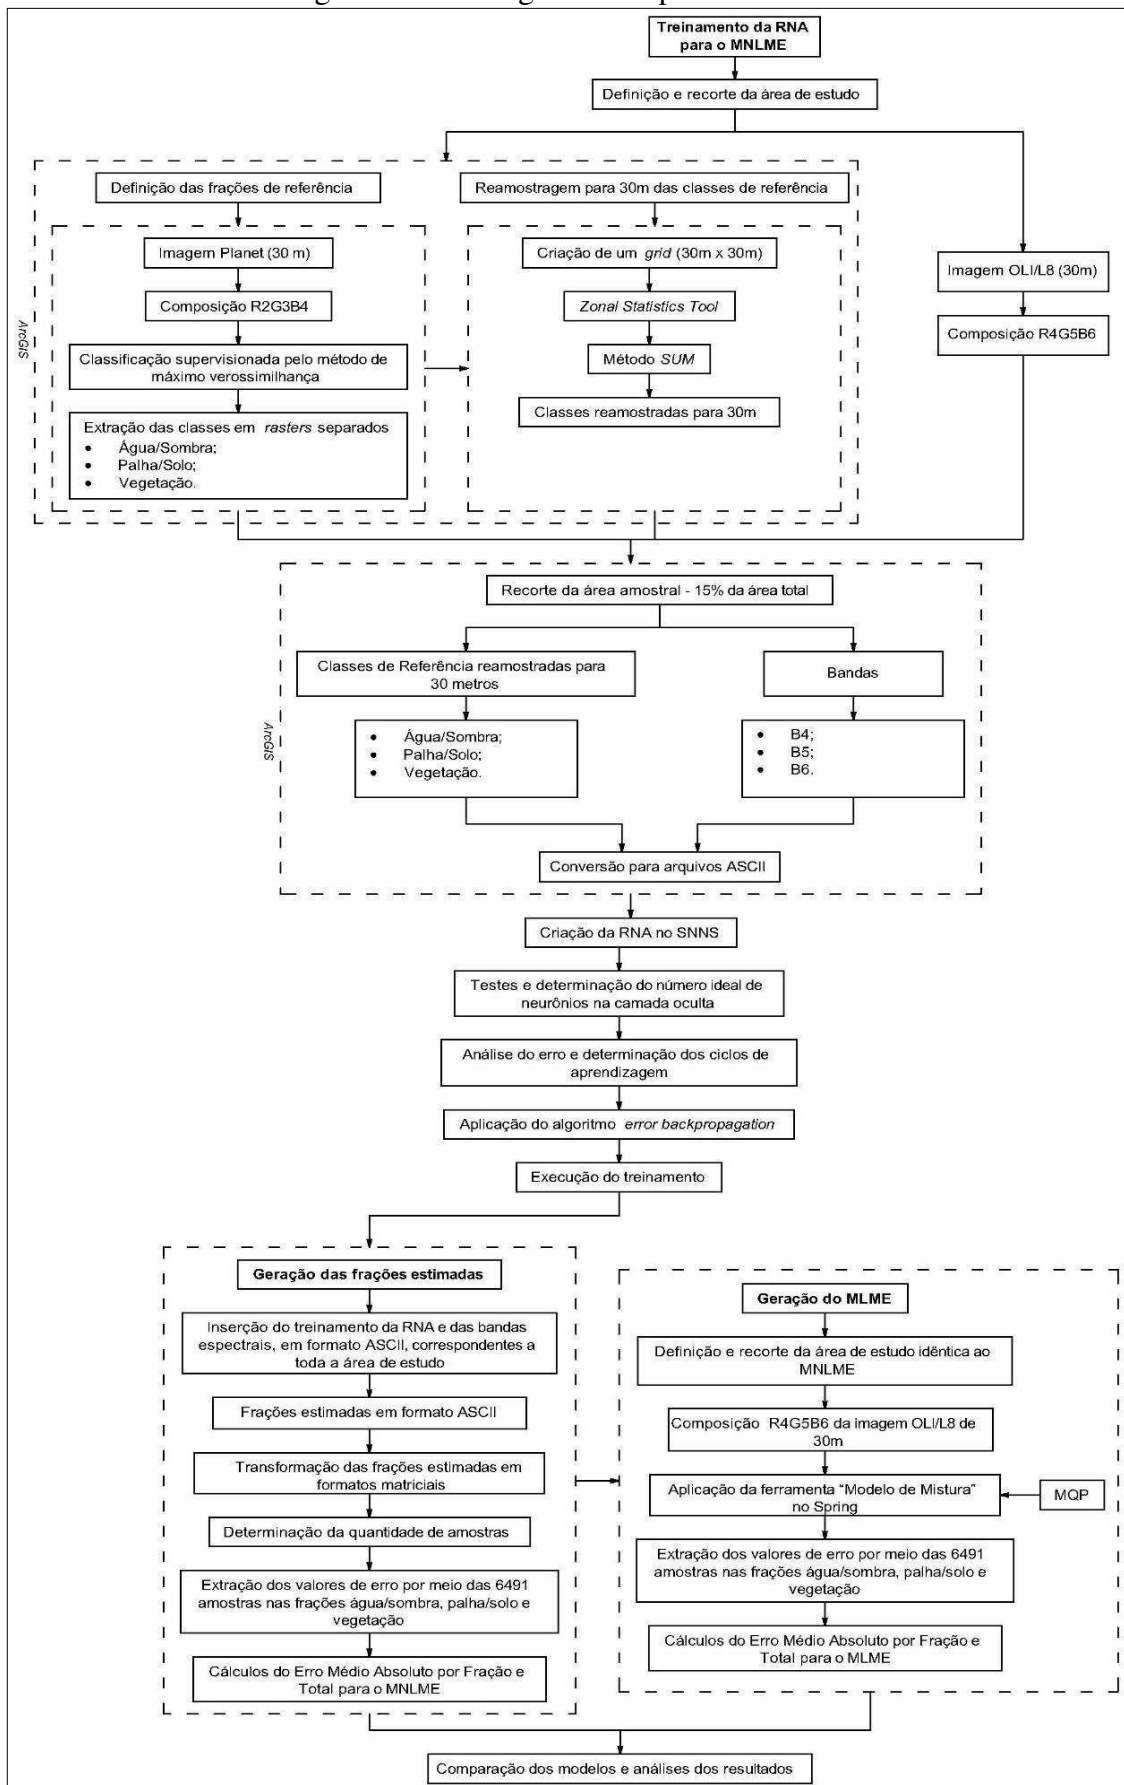
- Uma imagem OLI/Landsat 8 de 30 metros de resolução espacial (220/74), datada de 09/09/2019, disponibilizada gratuitamente no site do Serviço Geológico Estadunidense (<https://www.earthexplorer.usgs.gov/>);
- Uma imagem Planet de 3 metros de resolução espacial, datada de 09/09/2019, disponibilizada gratuitamente, mediante a um cadastro com endereço eletrônico acadêmico, no site da empresa (www.planet.com);
- *Softwares* Arc Gis 10.5 e Envi 5.1 licenciados nos laboratórios do Departamento de Engenharia Civil da UFV;
- Os *softwares* JAVA SNNS (*Stuttgart Neural Network Simulator*) desenvolvido pela Universidade de Stuttgart e mantido pela Universidade de Tübingen, na Alemanha, o Libre Office e o RStudio, todos disponíveis gratuitamente para uso.

3.4.3 Geração do MNLME

A geração do MNLME foi estabelecida em duas etapas: A primeira consistiu na seleção e organização dos dados para treinamento da RNA, nos quais os dados utilizados foram as amostras representadas pelas frações água/sombra, palha/solo e vegetação de referência e dos valores de reflectância das bandas espectrais do vermelho (B4), infravermelho próximo (B5) e do infravermelho médio (B6).

A segunda etapa correspondeu na modelagem e aplicação da rede treinada para estimar as frações palha/solo, água/sombra e vegetação. Os itens seguintes detalham as etapas de maneira mais pormenorizada e o fluxograma da Figura 17 apresenta os procedimentos supracitados.

Figura 17 – Fluxograma dos procedimentos



Fonte: Autor.

3.4.3.1 Imagens fração de referência

Para o treinamento da RNA foi necessário utilizar uma referência para que, a partir desta, a rede conseguisse estimar as proporções *a posteriori*. Além disso, o uso de uma imagem de referência teve sua utilidade na avaliação da qualidade do modelo.

Para isso, foi adotada uma imagem orbital de “resolução mais fina”, que neste caso foi a Planet (3m) e, em seguida foi verificado o ajuste da imagem em relação a OLI/L8, que estando sobrepostas, não houve a necessidade de se realizar um registro entre elas.


Então, foi utilizada uma classificação “*hard*” e neste caso foi escolhido o método da máxima verossimilhança, para que se obtivesse as proporções definida como referência. Essas referências correspondem às proporções das classes de água/sombra, vegetação e palha/solo, que posteriormente foram modeladas pela RNA.

No processo de classificação foram utilizadas 75% das amostras e as outras 25%, para a geração do cálculo da matriz de confusão, por meio da exatidão global, objetivando verificar a qualidade da classificação.

Na sequência, foram extraídas individualmente por meio da ferramenta *Extract by Attributes* cada classe, e criado um *grid* de 30 x 30 metros (Figura 18), cujo objetivo foi reamostrar para 30 metros as frações geradas a partir da classificação supervisionada da imagem de resolução mais “fina”, para que assim tivesse compatibilidade com a imagem OLI/L8.

Esta reamostragem se deu a partir da ferramenta *Zonal Statistics*, no ArcGis, por meio do tipo “*Sum*”, onde a soma de todos os valores das células em cada zona é atribuída a todas as células nessa zona. Por fim, necessitou-se utilizar a ferramenta *raster calculator* para transformar os arquivos *No Data* em zero em todas as frações, com intuito de indicar que naquele pixel não existiria determinada fração, e desse modo, obteve-se os valores de 0 a 1 para todas as frações.

Figura 18 – *Grid* de reamostragem das proporções de 3m para 30m



Fonte: Autor.

Após a realização do pré-processamento, iniciou-se o procedimento de separação das imagens de treinamento da rede, no qual determinou-se uma região de aproximadamente 15% da área total de estudo, onde estivessem presentes, de maneira significativa, as amostras (água/sombra, palha/solo e vegetação), fazendo com que no final fossem obtidos 6 arquivos, sendo eles: As 3 frações e as 3 bandas espectrais; do vermelho (B4), infravermelho próximo (B5) e do infravermelho médio (B6).

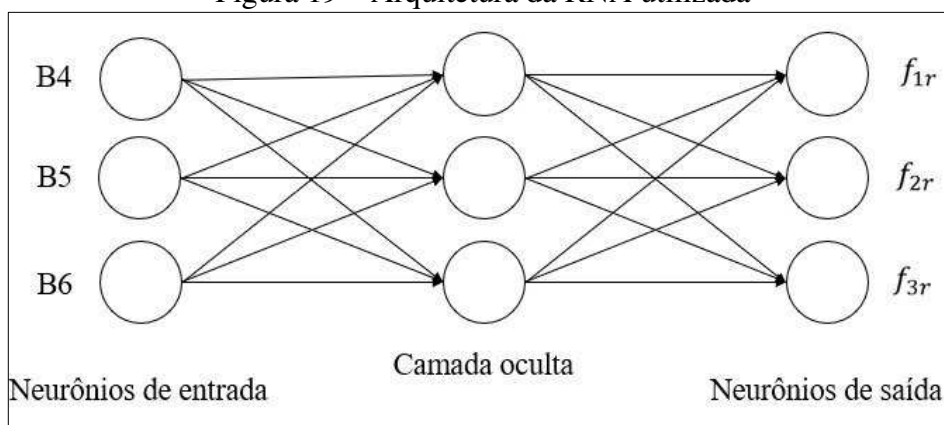
Por fim, os 6 arquivos matriciais foram convertidos para o formato ASCII (*American Standard Code for Information Interchange*), para possibilitar a compatibilidade de leitura da rede.

3.4.3.2 Modelagem a partir da RNA

Para a abordagem do MNLME foi utilizada a rede *Multilayer Perceptron* com o uso da função não linear de ativação sigmoideal logística [0-1], que possui propriedades assintóticas e de ajuste dos pesos dos elementos. Assim, a partir dela foi escolhido o algoritmo de aprendizado *Error Backpropagation*.

Para o sensor OLI/Landsat 8 foi estruturada uma rede com três camadas, quais sejam, a de entrada, a oculta e a de saída, como pode ser visto na Figura 19. Na camada de entrada, os três neurônios utilizados foram para inserir os dados de reflectância das bandas espectrais do vermelho (B4), infravermelho próximo (B5) e do infravermelho médio (B6).

Figura 19 – Arquitetura da RNA utilizada



Fonte: Autor.

Durante a montagem da camada oculta foram testadas diversas configurações (de 3 a 10 neurônios), sendo que a composta por 3 proporcionou um menor erro associado a uma taxa de 100 ciclos. Por fim, na camada de saída os três neurônios utilizados corresponderam as respectivas frações de referência referentes a palha/solo, água/sombra e vegetação.

3.4.3.3 Geração das imagens fração estimadas

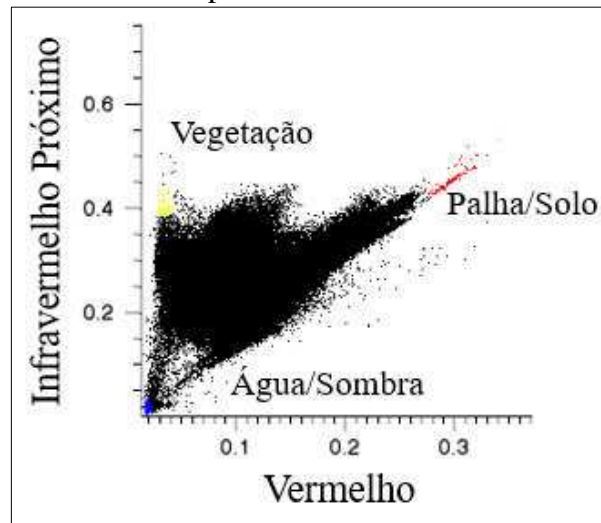
Após o treinamento da rede, foram inseridos os arquivos ASCII das bandas 4, 5 e 6, contemplando área total de estudo, para que desse modo, a RNA pudesse estimar cada uma das frações totais. Posteriormente a geração das frações, o resultado em arquivos com o formato ASCII, foi novamente convertido em arquivo matricial para as consequentes análises.

3.4.4 Geração do MLME da imagem OLI Landsat 8

O MLME foi modelado do mesmo modo, conforme já apresentado no item 2.4.3, segundo a metodologia apresentada por Camacho-De Coca (2004) e Quintano (2012).

Em seus estudos, para a identificação das respostas espectrais dos *endmembers*, os referidos autores utilizaram a observação de um espaço abstrato, isto é, baseando-se em um plano onde os componentes puros são encontrados nos extremos de um gráfico de dispersão formado por bandas que possuem baixa correlação - no caso foram utilizadas as bandas do vermelho e do infravermelho próximo - de modo que pudesse ser visualizado um triângulo onde cada vértice representaria um membro puro, caracterizado pelas componentes vegetação, palha/solo e água/sombra, conforme apresentado na Figura 20.

Figura 20 – Determinação dos *endmembers* da imagem, por meio do gráfico de dispersão de bandas pouco correlacionadas



Fonte: Autor.

A Figura 21 apresenta o resultado do procedimento explanado anteriormente, onde é possível observar os *endmembers* na imagem OLI/L8 com suas respectivas cores.

Figura 21 – *Endmembers* na cena



Fonte: Autor.

Após a determinação dos *endmembers*, foi utilizada a ferramenta “Modelo de Mistura” do *software* SPRING, onde foram assinalados os *endmembers* identificados anteriormente.

3.4.5 Definição das amostras e avaliação do desempenho dos modelos

A determinação das amostras se deu em função da área da imagem e da resolução espacial nominal do pixel do sensor OLI Landsat 8, e para garantir que não houvesse sobreposição de nenhum ponto utilizou-se a Equação 11.


$$X = 2\sqrt{2} * D \quad (11)$$

Onde:

- X é a distância mínima;
- D é a resolução espacial do pixel da imagem.

Desse modo, foram gerados aleatoriamente 6.491 pontos que preencheram toda a imagem a uma distância, de aproximadamente 85 metros entre si, conforme é apresentado na Figura 22.

Figura 22 – Pontos amostrados nas frações para análise dos valores de erro



Fonte: Autor.

Após este procedimento, foram extraídos os valores de cada amostra das frações água/sombra, palha/solo e vegetação do MLME e do MNLME e, por fim, para contemplar o objetivo principal desta pesquisa, o cálculo do erro médio absoluto dos modelos foi realizado em dois momentos, seguindo a metodologia proposta por Van de Voord, De Roeck e Canters (2009).

Em um primeiro momento foram calculados os erros médios absolutos de cada uma das frações e por último o erro médio absoluto total de cada um dos modelos de acordo com as Equações 9 e 10, por meio do uso de 6941 amostras coletadas em toda a imagem.

3.5 RESULTADOS E DISCUSSÕES

Inicialmente, como resultado dos procedimentos do MNLME, obtiveram-se os valores da matriz de confusão da classificação supervisionada pelo método da máxima verossimilhança, que foi utilizado como referência por meio da imagem Planet. A Tabela 13 contempla os valores obtidos.

Tabela 13 – Matriz de confusão resultante da classificação de máximo verossimilhança

		Referência		
		Água/Sombra	Palha/Solo	Vegetação
Preditó	Água/Sombra	45	0	0
	Palha/Solo	0	42	1
	Vegetação	0	3	44
Total		45	45	45


Fonte: Autor.

Como pode ser observado, as classes que geraram confusão foi a de vegetação com a de palha/solo, e isso pode ser justificado pelas áreas de transição e de intensidade de brilho relativamente semelhantes em alguns pontos. Porém, este fato não influenciou significativamente no decorrer do procedimento, podendo ser analisado a partir da Figura 23,

onde as áreas em azul correspondem a classe água/sombra, as verdes referem-se à vegetação e a bege equivale a palha/solo.

É válido ressaltar que o índice global de exatidão desta classificação foi de 92%, o que denota ser um resultado satisfatório do ponto de vista da precisão temática, auxiliando no processo de caracterização dos erros.

Figura 23 – A esquerda, a imagem Planet de 3 metros de resolução e a direita o resultado da classificação por máxima verossimilhança, contemplando as três classes




Fonte: Autor.

Ademais, a partir do uso da classificação acima reportada, o resultado do processo de geração das frações é visto na Figura 24.

Nele, foi possível constatar que as frações resultaram em modelos coerentes com a realidade de campo, mesmo tomando conhecimento de que esta classificação “hard” assumiu que cultivos agrícolas e fragmentos de florestas nativas fossem pixels da mesma classe, assim como as áreas urbanas e de solo exposto sendo palha/solo. Na imagem, os valores mais claros revelam que não há mistura de pixel, ou seja, o pixel é o mais puro possível.


Figura 24 – À esquerda, observa-se as imagens usadas como referência para o treinamento da RNA, e a direita, a composição colorida das frações palha/solo (R), vegetação (G) e água/sombra (B)



Fonte: Autor.

Durante o processo de treinamento da rede no SNNS, por meio do método da retropropagação, que auxiliou na realização dos ajustes dos pesos, o valor do erro médio quadrático ou *Mean Squared Error* (MSE) encontrado foi menor que de 0,1 e tornando-se assintótico a partir de 30 ciclos de aprendizado e estabilizando-se em 0,075 (Figura 25). Este baixo valor de erro permitiu concluir que a aprendizagem teve um bom desempenho.


Figura 25 – MSE durante a aprendizagem no SNNS



Fonte: Autor.

Após o treinamento, foram estimadas as três frações da rede utilizada, as quais são apresentadas na Figura 26.


Figura 26 – À esquerda, as frações de água/sombra, palha/solo e vegetação, e a direita, a composição colorida das frações palha/solo (R), vegetação (G) e água/sombra (B) resultantes da RNA



Fonte: Autor.

Já para o caso do MLME, a partir das respostas espectrais de cada *endmember*, foram calculadas e geradas as imagens fração (Figura 27).

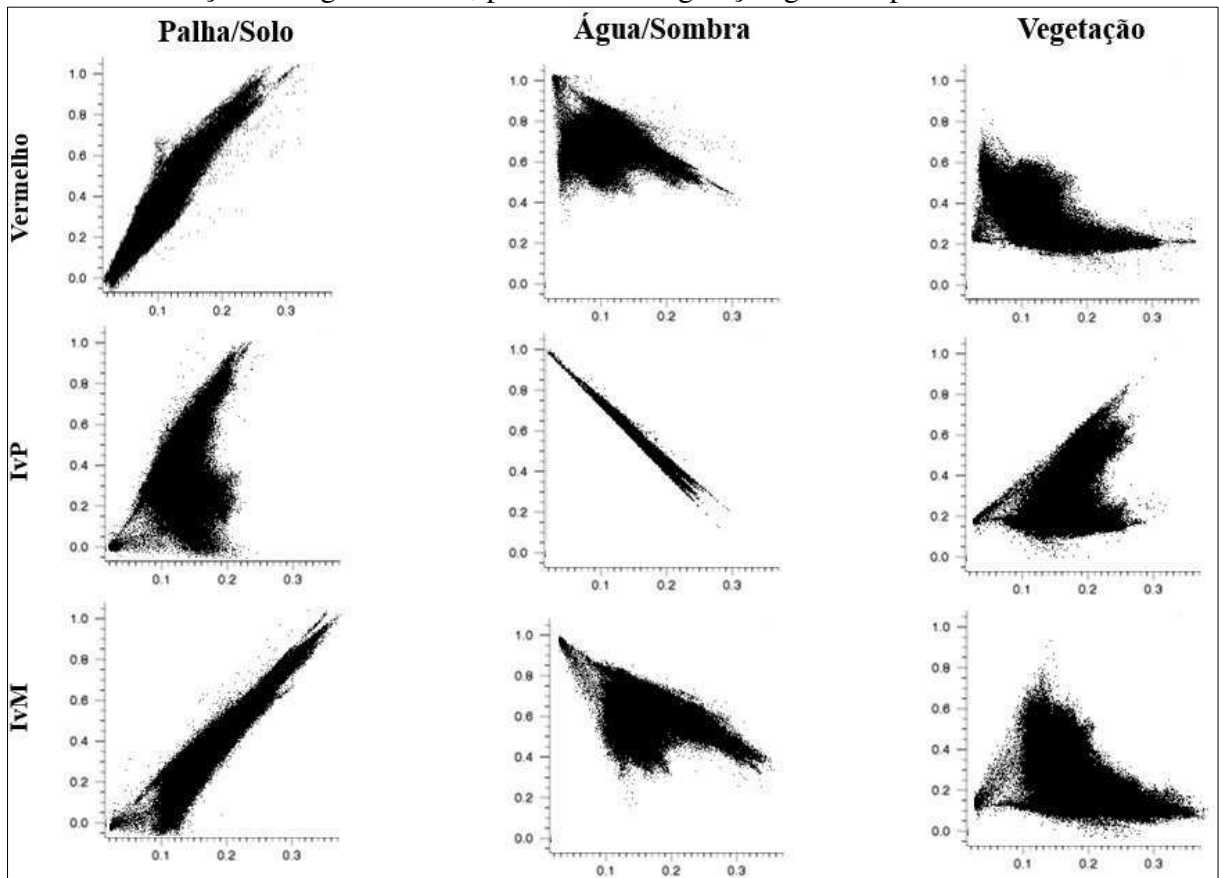
Figura 27 – À esquerda, as frações de água/sombra, palha/solo e vegetação, e a direita, a composição colorida das frações palha/solo (R), vegetação (G) e água/sombra (B) resultantes do MLME do sensor OLI/L8



Fonte: Autor.

Para melhor representação dos resultados do MLME, buscou-se a estratégia de gerar gráficos de dispersão utilizando as bandas 4, 5 e 6, localizada nos eixos das ordenadas e as frações, inserida nos eixos das abcissas (Figura 28). Desse modo, algumas relações espectrais puderam ser determinadas.


Figura 28 – Gráficos de dispersão entre as bandas espectrais do sensor OLI/L8 com as frações de água/sombra, palha/solo e vegetação geradas pelo MLME



Fonte: Autor.

A fração palha/solo correlacionou-se positivamente com a banda do vermelho e do infravermelho médio (IvM), ao passo que a fração sombra apresentou uma relação linear negativa na banda do infravermelho (IvP). Já a vegetação apresentou um comportamento exponencial decrescente nas bandas IvM.

Concomitantemente às frações, foram apresentados os valores de e_i médio de cada banda espectral analisada. Estes erros apresentam-se em números digitais que podem variar de 0 a 65.536 e são apresentados no Gráfico 2.

Gráfico 2 – Valores de e_i médio de cada banda do OLI/L8 após o MLME

Fonte: Autor.

Os valores de RMSE das bandas do MLME não diferiram significativamente, tendo o maior valor de erro observado nas regiões do infravermelho próximo e médio. Os elevados valores de erro nestas regiões, em relação a banda do vermelho, podem ser explicados, em parte, pelo fato da mistura linearizada não existir efetivamente (KUMAR et al., 2011) e ao múltiplo espalhamento (CLARK et al., 2005). Somers et al. (2009) também observaram que os maiores valores de erro foram mais pronunciados no comprimento de onda do infravermelho.

Após os cálculos do erro absoluto médio por fração e total, foram obtidos os valores utilizados na comparação de desempenho entre os dois modelos, conforme pode ser observado na Tabela 14.

Tabela 14 – Valores do desempenho de cada modelo

Frações	MLME	MNLME
	Erro médio absoluto por classe	
Palha	0,3502	0,1315
Vegetação	0,2172	0,1418
Sombra/Água	0,4559	0,0367
Erro Médio Absoluto Total	1,0234	0,3101

Fonte: Autor.

Os valores obtidos mostraram um desempenho melhor do modelo não linearizado em todas as frações, o que, conseqüentemente, resulta em um erro médio absoluto total 3 vezes menor, quando comparado ao MLME. De todos os valores de erros obtidos nas frações, o da água/sombra foi o menor, se aproximando de zero, quando comparado aos outros.

Em suma, outra consideração relevante a ser feita é que, neste estudo, os dados orbitais obtiveram aquisições simultâneas, o que pode suprimir a possibilidade de erro sistemático no valor de RMSE causado, principalmente, em função de mudanças na cobertura da superfície ou até mesmo de oscilações geométricas de visada do sensor e de iluminação solar, bem como variações nas condições atmosféricas.

Van de Voord, De Roeck e Canters (2009) mencionam ainda que, quando há simultaneidade de data durante a aquisição dos dados não ocorre limitações na análise deste tipo abordagem.

3.6 CONCLUSÃO

Neste trabalho foi apresentada uma abordagem de avaliação de desempenho sobre a qualidade das estimativas de um modelo não linearizado de mistura espectral a partir de informações subpixel das imagens Planet. O uso simultâneo dos dados espectrais da região de estudo garantiu, mesmo de satélites diferentes, uma mínima alteração da geometria de aquisição/iluminação da cena e da cobertura da superfície, assim como de variações de efeitos atmosféricos.

Por meio de uma classificação rígida, foi possível treinar a RNA por meio das classes e das bandas espectrais do sensor OLI/L8, de modo satisfatório. O treinamento ocorreu de maneira aceitável, resultando em 30 ciclos de aprendizagem com erro médio quadrático próximo de zero. Assim, foi possível obter como saída da rede neural, valores de proporções de 3 grandes grupos: água/sombra, palha/solo e vegetação, podendo então ser comparados os valores de erro médio absoluto e total com as frações geradas a partir de um modelo linear.

Os resultados encontrados nesta área de estudo mostraram que a modelagem não linear pode ser estimada com maior precisão, onde os maiores erros observados foram relacionados ao aspecto linear de modelagem, o que indica que, em uma comparação direta, há necessidade de aplicar uma modelagem não linear. Assim, quando comparadas a uma mesma referência de dados, o modelo não linear resultou em menores valores de raiz quadrada do erro médio, sendo considerada, portanto, uma modelagem mais adequada.

A metodologia proposta neste estudo mostrou ser eficiente na determinação e apresentação dos resultados, porém recomenda-se em trabalhos futuros, acerca da mesma temática, o emprego de diferentes arquiteturas e parâmetros durante a montagem da RNA, como por exemplo, fazendo-se uso de mais de uma camada oculta, a fim de verificar se existe uma melhora nas frações estimadas pela RNA.

REFERÊNCIAS BIBLIOGRÁFICAS

CAMACHO-DE COCA, F., GARCÍA-HARO F.J.; GILABERT, 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.

EMBRAPA. **Monitoramento por satélite**. Campinas: Embrapa Monitoramento por Satélite, 2013. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 10 nov. 2019.

FERREIRA, M.E.; FERREIRA, L.G.; SANO, E.E.; SHIMABUKURO, Y.E. Uso do Modelo Linear de Mistura Espectral para o mapeamento sistemático e operacional do bioma cerrado: possibilidades, implicações e procedimentos metodológicos. **Anais do XI Simpósio Brasileiro de Sensoriamento Remoto**, p. 657-664, 2003. Disponível em: <https://www.researchgate.net/profile/Edson_Sano/publication/237599888_Uso_do_modelo_linear_de_mistura_espectral_para_o_mapeamento_sistematico_e_operacional_do_bioma_cerrado_possibilidades_implicacoes_e_procedimentos_metodologicos/links/55d1c7bd08ae2496e6581ee.pdf>. Acesso em: 25 dez. 2019.

FOODY, G.M. Approaches for the Production and Evaluation of Fuzzy Land Cover Classifications from Remotely-Sensed Data. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1317-1340, 1996.

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. **Anais. Presidente Prudente: Simpósio Brasileiro de Geomática**, p. 150-161, 2002.

HALIMI, A.; ALTMANN, Y.; DOBIGEON, N.; TURNER, J.Y. Nonlinear Unmixing of Hyperspectral Images Using a Generalized Bilinear Model. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 11, p. 4153-4162, 2016.

HAYKIN, S. S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.

HEYLEN, R. ; PARENTE, M. ; GADER, P. A Review of Nonlinear Hyperspectral Unmixing Methods. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 6, p. 1844-1868, 2014.

ICHOKU, C.; KARNIELI, A. (1996). A review of mixture modeling techniques for sub-pixel land cover estimation. **Remote Sensing Reviews**, v. 13, n. 3-4, p. 161-186, 1996.

KESHA, N.; MUSTARD, J. F. Spectral Unmixing. **IEEE Signal Processing Magazine**, v. 19, n. 1, p. 44, 2002.

KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes. 1928.

KUMAR, U.; RAJA, S. K. ; MUKHOPADHYA, Y. C. ; RAMACHANDRA, T. V. A multi-layer perceptron based non-linear mixture model to estimate class abundance from mixed pixels. In: **IEEE Technology Students' Symposium**. IEEE, p. 148-153, 2011.

LICCIARDI, G.A.; DEL FRATE, F. Pixel Unmixing in Hyperspectral Data by Means of Neural Networks. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 11, p. 4163-4172, 2011.

LIU, W.; WU, E. Y. Comparison of non-linear mixture models: Sub-pixel classification. **Remote Sensing of environment**, v. 94, n. 2, p. 145-154, 2005.

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.

PLANET. **Planet imagery product specifications**. Planet Team: San Francisco, CA, USA, 2018. Disponível em: <https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf>. Acesso em: 20 de dez, 2019.

QUINTANO, C.; FERNÁNDEZ-MANSO, A.; SHIMABUKURO, Y. E.; PEREIRA, G. Spectral unmixing. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5307-5340, 2012.

RUMELHART, D. E. ; HINTON, G. E. ; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533-536, 1986.

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.

SOMERS, B.; COOLS, K.; DELALIEUX, S.; STUCKENS, J.; VAN DER ZANDE, D.; VERSTRATEN, W.; COPPIN, P. Nonlinear Hyperspectral Mixture Analysis for tree cover estimates in orchards. **Remote Sensing of Environment**, v. 113, n. 6, p. 1183-1193, 2009.

TANG, Y. ; KRASSER, S. ; HE, Y. ; YANG, W. ; ALPEROVITCH, D. 2008. Support Vector Machines and Random Forests Modeling for Spam Senders Behavior Analysis. In: **Paper presented at the IEEE Global Telecommunications Conference**. Anais eletrônicos. New Orleans. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/4698194>>. Acesso em: 14 dez. 2019.

TISSOT, H. C.; CAMARGO, L. C.; POZO, A. Treinamento de redes neurais feedforward: comparativo dos algoritmos backpropagation e differential evolution. In: Brazilian Conference on Intelligent Systems. 2012. **Anais eletrônicos**. Disponível em: https://www.researchgate.net/profile/Hegler_Tissot/publication/273950621_Treinamento_de_redes_neurais_feedforward_comparativo_dos_algoritmos_backpropagation_e_differential_evolution/links/551148d80cf2a8dd79c01777.pdf. Acesso em: 09 ago. 2019.

VAN DE VOORDE, T.; DE ROECK, T.; CANTERS, F. A comparison of two spectral mixture modelling approaches for impervious surface mapping in urban areas. **International Journal of Remote Sensing**, v. 30, n. 18, p. 4785-4806, 2009.

YILMAZ, I.; KAYNAR, O. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. **Expert Systems with Applications**, v. 38, n. 5, p. 5958-5966, 2011.

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.

ZANOTTA, D. C.; HAERTEL, V.; SHIMABUKURO, Y. E.; RENNO, C. D. Linear Spectral Mixing Model for Identifying Potential Missing Endmembers in Spectral Mixture Analysis. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 5, p. 3005-3012, 2013.

ZHANG, J.; FOODY, G. M. Fully-Fuzzy Supervised Classification of Sub-Urban Land Cover from Remotely Sensed Imagery: Statistical and Artificial Neural Network Approaches. **International Journal of Remote Sensing**, v. 22, n. 4, p. 615-628, 2001.

4 CONCLUSÕES E RECOMENDAÇÕES

Dados de sensoriamento remoto de resoluções mais “grosseiras”, podem estar repletos de pixels mistos, sendo estes uma fonte muito comum de erro nas análises de dados, visto que são erroneamente considerados puros. Ao realizar a desmistificação acerca da composição das classes inclusas nos pixels mistos, é possível ampliar a precisão das análises.

Com a realização dessa pesquisa, pode-se verificar que a aplicação de metodologias clássicas de análise de mistura espectral, com apoio de análises estatísticas e tendo como escopo verificar a influência de dois tipos diferentes de reamostragens em imagens orbitais, proporcionou apresentar resultados que mostraram ser concisos acerca das implicações e consequências do uso da mistura espectral em mapeamentos de modo geral.

Destaca-se ainda o emprego de *softwares* de processamento digital de imagens e estatístico, assim como o uso de RNAs que revelaram ter o potencial em auxiliar na desmitificação, tanto da abordagem linear quanto não linear de mistura espectral.

O uso de dados subpixel do satélite Planet permitiu uma abordagem ao modelo não linear de mistura espectral satisfatória, onde a partir da utilização do algoritmo de retropropagação foram estimadas as frações para uma imagem OLI/Landsat 8, que obtiveram um desempenho, em termos de erro absoluto médio, superior ao tradicional modelo linear.

A aplicação prática destes estudos, circunda o potencial de estender as informações geradas a partir de uma pequena amostra para referência de nível regional e global, permitindo assim estudos relevantes nas ciências florestais e do solo.

De modo geral, diante da metodologia aplicada, permite-se dizer que é possível empregar sensores de diferentes resoluções espaciais para se realizar uma modelagem linear, porém existem observações que limitam um pouco a geração de resultados mais contundentes, como por exemplo o uso de mais classes para distinguir feições e da obtenção de cenas simultâneas de diferentes resoluções.

Recomenda-se para trabalhos futuros, uso de novos sensores multiespectrais na abordagem não linearizada, para uma avaliação comparativa dos resultados utilizando-se por exemplo, de uma classificação difusa - a *fuzzy*, que considera diferentes graus de associação de suas classes e avaliação de sua precisão. Além disso, testes e análises em áreas planas e com relevo mais acidentado da superfície, poderiam também ser investigadas, assim como alterações nos parâmetros e construção da RNA.

REFERÊNCIAS BIBLIOGRÁFICAS

CÂMARA, G.; VALERIANO, D. M.; SOARES, J. V. **Metodologia para o cálculo da taxa anual de desmatamento na Amazônia Legal**. São José dos Campos: INPE, 2013.

CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. 5 ed. New York: Guilford Press, 2011.

DE MELO, I. D. F.; PACHÊCO, A. P. Aspectos da correção geométrica de imagens orbitais. Em: anais eletrônicos. **I Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação**, 2004. Disponível em: <https://docplayer.com.br/5914225-Aspectos-da-correcao-geometrica-de-imagens-orbitais-ivan-dornelas-falcone-de-melo-1-admilson-p-pacheco-2.html>. Acesso em: 27 nov. 2019.

DOBIGEON, N.; ALTMANN, Y.; BRUN, N.; MOUSSAOUI, S. Linear and nonlinear unmixing in hyperspectral imaging. In: **Data Handling in Science and Technology**, v. 30, p. 185-224, 2016.

ETTRITCH, G.; BUNTING, P.; JONES, G.; HARDY, A. Monitoring the coastal zone using earth observation: application of linear spectral unmixing to coastal dune systems in Wales. **Remote Sensing in Ecology and Conservation**, v. 4, n. 4, p. 303-319, 2018.

FERREIRA, M E.; FERREIRA, L.G., SANO, E.E.; SHIMABUKURO, Y.E. Uso do Modelo Linear de Mistura Espectral para o mapeamento sistemático e operacional do bioma cerrado: possibilidades, implicações e procedimentos metodológicos. **Anais do XI Simpósio Brasileiro de Sensoriamento Remoto**, p. 657-664, 2003. Disponível em: <https://www.researchgate.net/profile/Edson_Sano/publication/237599888_Uso_do_modelo_linear_de_mistura_espectral_para_o_mapeamento_sistematico_e_operacional_do_bioma_cerrado_possibilidades_implicacoes_e_procedimentos_metodologicos/links/55d1c7bd08ae2496e6581ee.pdf>. Acesso em: 25 dez. 2019.

FOODY, G.M. Approaches for the Production and Evaluation of Fuzzy Land Cover Classifications from Remotely-Sensed Data. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1317-1340, 1996.

FOODY, G. M.; LUCAS R.M.; CURRAN P.J.; HONZAK M. Non-linear mixture modelling without end-members using an artificial neural network. **International Journal of Remote Sensing**, v. 18, n. 4, p. 937-953, 1997.

GEBRESLASSIE, H. G.; MELESSE, A. M.; BISHOP, K.; GEBREMARIAM, A. G. Linear spectral unmixing algorithm for modelling suspended sediment concentration of flash floods, upper Tekeze River, Ethiopia. **International Journal of Sediment Research**, v. 35, n. 1, p. 79-90, 2020.

HALIMI, A.; BIOUCAS-DIAS, J. M.; DOBIGEON, N.; BULLER, G. S.; MCLAUGHLIN, S. Fast Hyperspectral Unmixing in Presence of Nonlinearity or Mismodeling Effects. **IEEE Transactions on Computational Imaging**, v. 3, n. 2, p. 146-159, 2016.

HEYLEN, R. ; PARENTE, M. ; GADER, P. A Review of Nonlinear Hyperspectral Unmixing Methods. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 6, p. 1844-1868, 2014.

KESHAVA, N.; MUSTARD, J. F. Spectral unmixing. **IEEE Signal Processing Magazine**, v. 19, n. 1, p. 44-57, 2002.

KUMAR, U.; RAJA, S. K.; MUKHOPADHYAY, C.; RAMACHANDRA, T. V. A multi-layer perceptron based non-linear mixture model to estimate class abundance from mixed pixels. **IEEE Technology Students' Symposium**. doi:10.1109/techsym.2011.5783815, 2011.

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.

QUINTANO, C.; FERNÁNDEZ-MANSO, A.; SHIMABUKURO, Y. E.; PEREIRA, G. Spectral unmixing. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5307-5340, 2012.

SHIMABUKURO, Y. E.; PONZONI, F. J. **Spectral Mixture for Remote Sensing: Linear Model and Applications**. Springer, 2018.

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.

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.

VAN DE VOORDE, T. ; DE ROECK, T. ; CANTERS, F. A comparison of two spectral mixture modelling approaches for impervious surface mapping in urban areas. **International Journal of Remote Sensing**, v. 30, n. 18, p. 4785-4806, 2009.

VERHOEYE, J.; DE WULF, R. Land cover mapping at sub-pixel scales using linear optimization techniques. **Remote Sensing of Environment**, v. 79, n. 1, p. 96-104, 2002.

WEI, Q. ; CHEN, M. ; TURNER, J. Y. ; GODSILL, S. Unsupervised nonlinear spectral unmixing based on a multilinear mixing model. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 8, p. 4534-4544, 2017.

YANG, J.; HE, Y. Automated mapping of impervious surfaces in urban and suburban areas: Linear spectral unmixing of high spatial resolution imagery. **International journal of applied earth observation and geoinformation**, v. 54, p. 53-64, 2017.

YU, J.; CHEN, D.; LIN, Y.; YE, S. Comparison of linear and nonlinear spectral unmixing approaches: a case study with multispectral TM imagery. **International Journal of Remote Sensing**, v. 38, n. 3, p. 773-795, 2017.

ANEXO I

Tabela T - student						
	0.5	0.2	0.1	0.05	0.02	0.01
1	1	3.07768	6.31375	12.70620	31.82052	63.6567
2	0.816497	1.88562	2.91999	4.302653	6.964557	9.9248
3	0.764892	1.63774	2.35336	3.182446	4.540703	5.8409
4	0.740697	1.53321	2.13185	2.776445	3.746947	4.6041
5	0.726687	1.47588	2.01505	2.570582	3.364930	4.0321
6	0.717558	1.43976	1.94318	2.446912	3.142668	3.7074
7	0.711142	1.41492	1.89458	2.364624	2.997952	3.4995
8	0.706387	1.39682	1.85955	2.306004	2.896459	3.3554
9	0.702722	1.38303	1.83311	2.262157	2.821438	3.2498
10	0.699812	1.37218	1.81246	2.228139	2.763769	3.1693
11	0.697445	1.36343	1.79588	2.200985	2.718079	3.1058
12	0.695483	1.35622	1.78229	2.178813	2.680998	3.0545
13	0.693829	1.35017	1.77093	2.160369	2.650309	3.0123
14	0.692417	1.34503	1.76131	2.144787	2.624494	2.9768
15	0.691197	1.34061	1.75305	2.131450	2.602480	2.9467
16	0.690132	1.33676	1.74588	2.119905	2.583487	2.9208
17	0.689195	1.33338	1.73961	2.109816	2.566934	2.8982
18	0.688364	1.33039	1.73406	2.100922	2.552380	2.8784
19	0.687621	1.32773	1.72913	2.093024	2.539483	2.8609
20	0.686954	1.32534	1.72472	2.085963	2.527977	2.8453
21	0.686352	1.32319	1.72074	2.079614	2.517648	2.8314
22	0.685805	1.32124	1.71714	2.073873	2.508325	2.8188
23	0.685306	1.31946	1.71387	2.068658	2.499867	2.8073
24	0.684850	1.31784	1.71088	2.063899	2.492159	2.7969
25	0.684430	1.31635	1.70814	2.059539	2.485107	2.7874
26	0.684043	1.31497	1.70562	2.055529	2.478630	2.7787
27	0.683685	1.31370	1.70329	2.051831	2.472660	2.7707
28	0.683353	1.31253	1.70113	2.048407	2.467140	2.7633
29	0.683044	1.31143	1.69913	2.045230	2.462021	2.7564
30	0.682756	1.31042	1.69726	2.042272	2.457262	2.7500
31	0.682486	1.30946	1.69552	2.039513	2.452824	2.7440
32	0.682234	1.30857	1.69389	2.036933	2.448678	2.7385
33	0.681997	1.30774	1.69236	2.034515	2.444794	2.7333
34	0.681774	1.30695	1.69092	2.032245	2.441150	2.7284
35	0.681564	1.30621	1.68957	2.030108	2.437723	2.7238
36	0.681366	1.30551	1.68830	2.028094	2.434494	2.7195
37	0.681178	1.30485	1.68709	2.026192	2.431447	2.7154
38	0.681001	1.30423	1.68595	2.024394	2.428568	2.7116
39	0.680833	1.30364	1.68488	2.022691	2.425841	2.7079
40	0.680673	1.30308	1.68385	2.021075	2.423257	2.7045
41	0.680521	1.30254	1.68288	2.019541	2.420803	2.7012
42	0.680376	1.30204	1.68195	2.018082	2.418470	2.6981
43	0.680238	1.30155	1.68107	2.016692	2.416250	2.6951
44	0.680107	1.30109	1.68023	2.015368	2.414134	2.6923
45	0.679981	1.30065	1.67943	2.014103	2.412116	2.6896
46	0.679861	1.30023	1.67866	2.012896	2.410188	2.6870