



UNIVERSIDADE DE BRASÍLIA – UnB
INSTITUTO DE GEOCIÊNCIAS – IG
II CURSO DE GEOPROCESSAMENTO AMBIENTAL

PROPOSTA DE UM ALGORITMO PARA BUSCA DE *ENDMEMBERS* A PARTIR DA
ESTATÍSTICA DOS DADOS ESPECTRAIS DA AMOSTRA

GUSTAVO FARHAT DE ARAUJO

Orientador: Prof. Dr. Gustavo Macedo de Mello Baptista

Brasília

Dezembro de 2013



UNIVERSIDADE DE BRASÍLIA – UnB
INSTITUTO DE GEOCIÊNCIAS – IG
II CURSO DE GEOPROCESSAMENTO AMBIENTAL

PROPOSTA DE UM ALGORITMO PARA BUSCA DE *ENDMEMBERS* A PARTIR DA
ESTATÍSTICA DOS DADOS ESPECTRAIS DA AMOSTRA

GUSTAVO FARHAT DE ARAUJO

Monografia apresentada junto ao II Curso de
Especialização em Geoprocessamento
Ambiental, para obtenção do título de
Especialista em Geoprocessamento Ambiental.

Orientador: Prof. Dr. Gustavo Macedo de Mello Baptista

Brasília

Dezembro de 2013

RESUMO

O objetivo deste trabalho foi propor um algoritmo alternativo para identificação de *endmembers*. O algoritmo proposto, implementado em IDL e denominado *Spectral Statistics Sampler* (SSS), determina, a partir de uma região de interesse, os valores de referência a serem buscados na imagem. Os valores espectrais dos pixels que compõem a imagem são, então, comparados com os valores de referência. Como resultado, o algoritmo gera uma imagem *rule*, com valores digitais de oito bits, sendo os valores mais significativos atribuídos aos pixels que mais se aproximam da referência. Na metodologia de testes do algoritmo, foi utilizado um conjunto de pixels puros, como *endmember*, para a busca do padrão em uma imagem hiperespectral do sensor AVIRIS. Os resultados do algoritmo proposto, SSS, foram comparados com os resultados dos algoritmos *Spectral Angle Mapper* (SAM) e *Spectral Feature Fitting* (SFF), por meio de uma análise pixels concordantes e de precisão e erro (matriz de confusão). Na conclusão constatou-se que o algoritmo SSS obteve resultados altamente satisfatórios, com desempenho equivalente ao algoritmo SAM e superior ao algoritmo SFF.

Palavras chaves: Amostrador de Estatística Espectral, AVIRIS, SAM, SFF.

ABSTRACT

The aim of this study was to propose an alternative algorithm to search for endmembers. The proposed algorithm, implemented in IDL and called Spectral Statistics Sampler (SSS), identifies the endmembers in the image from a region of interest. The spectral values of the pixels are compared with the ROIs endmember. As a result, the algorithm generates a rule image with 8 bits digital values, with highest values assigned to the pixels that are closer to the reference. In the validation methodology of the SSS algorithm, it was used a set of pure pixels as endmember in order to search the pattern in an AVIRIS hyperspectral data. The proposed algorithm results were compared with the results of the Spectral Angle Mapper (SAM) and Spectral Feature Fitting (SFF) algorithms by means of an analysis of pixel's consistency and the pixel's accuracy and error (confusion matrix). At the conclusion it was verified that the SSS algorithm obtained highly satisfactory results and its performance was equivalent to SAM and superior to SFF.

Keywords: Spectral Statistics Sampler, AVIRIS, SAM, SFF.

SUMÁRIO

APRESENTAÇÃO	4
1. INTRODUÇÃO	5
1.1 Objetivo do Trabalho	5
2. ARTIGO SUBMETIDO À REVISTA BRASILEIRA DE CARTOGRAFIA	6
3. CONCLUSÃO	22
ANEXO 1 – SINOPSE DE SUBMISSÃO	23

APRESENTAÇÃO

A presente Monografia é o trabalho final do II Curso de Especialização em Geoprocessamento Ambiental, promovido pelo Laboratório de Sensoriamento Remoto do Instituto de Geociências da Universidade de Brasília. O trabalho foi redigido em formato de artigo científico, submetido à Revista Brasileira de Cartografia (RBC), e foi organizado da seguinte forma: 1) **INTRODUÇÃO** - Consta uma descrição geral do tema da monografia e seu o; 2) Artigo submetido à RBC – Compreende o algoritmo proposto, a metodologia aplicada, o processamento dos dados e a análise dos resultados; 3) **CONCLUSÃO** – São apresentados os resultados obtidos ao longo da pesquisa.

1. INTRODUÇÃO

Dentre as várias técnicas de identificação de pixels ou espectros de referências, também conhecidos como *endmembers*, em imagens multi ou hiperespectrais, existem algoritmos implementados em diversos softwares comerciais. Esses algoritmos empregam técnicas distintas que, embora seja empregada uma mesma referência de busca, levam a resultados também distintos. O resultado superior de um algoritmo comparado a outro não implica necessariamente na ineficácia do algoritmo de pior resultado. A mesma comparação aplicada a uma imagem, advinda de outro sensor, ou a um diferente *endmember* poderia levar a resultados invertidos.

Alguns algoritmos são largamente utilizados e implementados em softwares de processamento de imagens, tais como o ENVI. Desses algoritmos, podemos destacar: *Spectral Angle Mapper* (SAM) (KRUSE et al., 1993) e *Spectral Feature Fitting* (SFF) (CLARK et al., 1990, 1991, 1992; CLARK e SWAYZE, 1995).

De acordo com a Research System, Inc. (2004) o algoritmo SAM compara o ângulo entre o espectro do *endmember* (transformado em vetor n-dimensional, onde n é o número de bandas) e o vetor de cada pixel da cena no espaço n-dimensional. Quanto menor o ângulo resultante maior a similaridade com o espectro de referência. Já o SFF utiliza uma técnica baseada na comparação dos erros mínimos quadráticos entre o espectro de referência e os pixels da imagem.

Assim, vislumbrou-se o desenvolvimento de um novo algoritmo que, tomando como *endmember* de referência uma Região de Interesse (ROI – *Region of Interest*), comparasse cada pixel da imagem, em todo o seu espectro, gerando uma imagem onde, a cada pixel, é atribuído um índice proporcional à possibilidade do mesmo pertencer à mesma classe do *endmember*.

1.1 Objetivo do Trabalho

O presente trabalho tem como objetivo propor um algoritmo alternativo para pesquisa de *endmembers*, chamado *Spectral Statistics Sampler* (SSS). O SSS foi desenvolvido a partir da adaptação das técnicas utilizadas por dois algoritmos de classificação supervisionada, conhecidos como: Paralelepípedo e Máxima Verosimillhança (MaxVer) e implementado em IDL (*Interactive Data Language*).

2. ARTIGO SUBMETIDO À REVISTA BRASILEIRA DE CARTOGRAFIA

PROPOSTA DE UM ALGORITMO PARA BUSCA DE *ENDMEMBERS* A PARTIR DA ESTATÍSTICA DOS DADOS ESPECTRAIS DA AMOSTRA

Proposal of an endmembers search algorithm based on sample's spectral data statistics

Gustavo Farhat de Araujo¹
Gustavo Macedo de Mello Baptista²

¹**Força Aérea Brasileira – FAB**
Comando-Geral de Operações Aéreas – COMGAR
 SQS 110, Bloco H, Apt. 206 – Brasília – DF – 70.373-080
 gustavo.farhat@gmail.com

²**Universidade de Brasília - UnB**
Instituto de Geociências – IG
 Campus Darcy Ribeiro – Asa Norte – Caixa Postal 4465 – Brasília – DF – 70.910-900
 gmbaptista@unb.br

RESUMO

O objetivo deste trabalho foi propor um algoritmo alternativo para identificação de *endmembers*. O algoritmo proposto, implementado em IDL e denominado *Spectral Statistics Sampler* (SSS), determina, a partir de uma região de interesse, os valores de referência a serem buscados na imagem. Os valores espectrais dos pixels que compõem a imagem são, então, comparados com os valores de referência. Como resultado, o algoritmo gera uma imagem *rule*, com valores digitais de oito bits, sendo os valores mais significativos atribuídos aos pixels que mais se aproximam da referência. Na metodologia de testes do algoritmo, foi utilizado um conjunto de pixels puros, como *endmember*, para a busca do padrão em uma imagem hiperespectral do sensor AVIRIS. Os resultados do algoritmo proposto, SSS, foram comparados com os resultados dos algoritmos *Spectral Angle Mapper* (SAM) e *Spectral Feature Fitting* (SFF), por meio de uma análise pixels concordantes e de precisão e erro (matriz de confusão). Na conclusão constatou-se que o algoritmo SSS obteve resultados altamente satisfatórios, com desempenho equivalente ao algoritmo SAM e superior ao algoritmo SFF.

Palavras chaves: Amostrador de Estatística Espectral, AVIRIS, SAM, SFF.

ABSTRACT

The aim of this study was to propose an alternative algorithm to search for endmembers. The proposed algorithm, implemented in IDL and called *Spectral Statistics Sampler* (SSS), identifies the endmembers in the image from a region of interest. The spectral values of the pixels are compared with the ROIs endmember. As a result, the algorithm generates a rule image with 8 bits digital values, with highest values assigned to the pixels that are closer to the reference. In the validation methodology of the SSS algorithm, it was used a set of pure pixels as endmember in order to search the pattern in an AVIRIS hyperspectral data. The proposed algorithm results were compared with the results of the *Spectral Angle Mapper* (SAM) and *Spectral Feature Fitting* (SFF) algorithms by means of an analysis of pixel's consistency and the pixel's accuracy and error (confusion matrix). At the conclusion it was verified that the SSS algorithm obtained highly satisfactory results and its performance was equivalent to SAM and superior to SFF.

Keywords: Spectral Statistics Sampler, AVIRIS, SAM, SFF.

1. INTRODUÇÃO

Dentre as várias técnicas de identificação de pixels ou espectros de referências, também conhecidos como *endmembers*, em imagens multi ou hiperespectrais, existem algoritmos implementados em diversos softwares comerciais. Esses algoritmos

empregam técnicas distintas que, embora seja empregada uma mesma referência de busca, levam a resultados também distintos. O resultado superior de um algoritmo comparado a outro não implica necessariamente na ineficácia do algoritmo de pior resultado. A mesma comparação aplicada a uma

imagem, advinda de outro sensor, ou a um diferente *endmember* poderia levar a resultados invertidos.

Alguns algoritmos são largamente utilizados e implementados em softwares de processamento de imagens, tais como o ENVI. Desses algoritmos, podemos destacar: Spectral Angle Mapper (SAM) (KRUSE et al., 1993) e Spectral Feature Fitting (SFF) (CLARK et al., 1990, 1991, 1992; CLARK e SWAYZE, 1995).

De acordo com a Research System, Inc. (2004) o algoritmo SAM compara o ângulo entre o espectro do *endmember* (transformado em vetor n-dimensional, onde n é o número de bandas) e o vetor de cada pixel da cena no espaço n-dimensional. Quanto menor o ângulo resultante maior a similaridade com o espectro de referência. Já o SFF utiliza uma técnica baseada na comparação dos erros mínimos quadráticos entre o espectro de referência e os pixels da imagem.

Para classificação pixels a pixels existem outros algoritmos bastante testados e validados na literatura, como o de paralelepípedo e o de máxima verossimilhança (CRÓSTA, 1993).

O classificador Paralelepípedo estima, a partir dos pixels de uma Região de Interesse (*Region of Interest* - ROI), os valores máximos e mínimos, em cada banda, utilizando-os como limiar para a classe na regra de decisão. Esse classificador pode ainda empregar o desvio-padrão como limiar em substituição aos valores máximos e mínimos.

Na Figura 1, Meneses e Almeida (2012, cap. 12, p. 199) mostram, em um escatograma bidimensional, a representação das dimensões dos paralelepípedos das classes selecionadas levando em conta um limiar (*threshold*) de desvio-padrão.

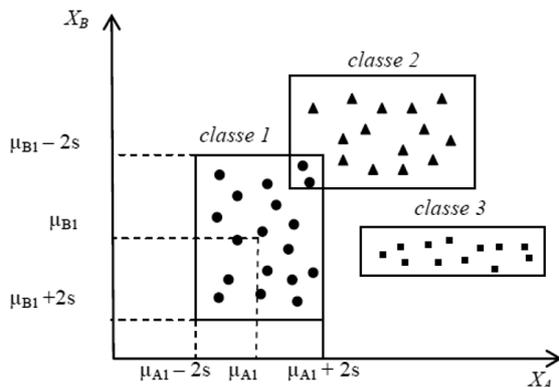


Fig. 1 – Classificador Paralelepípedo.

Segundo Meneses e Almeida (2012), esse classificador tem a vantagem de ser rápido e simples, porém, apresenta, como desvantagem, a existência de “cantos”, possibilitando que pixels, apesar de distantes da média da classe, sejam classificados como apresentado na Figura 2.

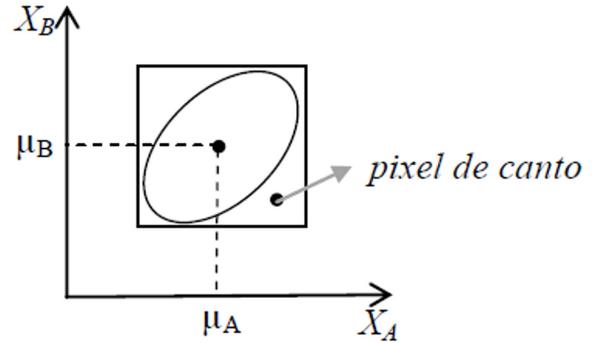


Fig. 2 – Classificador Paralelepípedo (pixels de canto).

O classificador por Máxima Verossimilhança (MaxVer) considera a ponderação das distâncias entre a média dos valores dos pixels das classes, utilizando parâmetros estatísticos. Assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixels pertencer a uma classe específica (INPE, 2008).

O presente trabalho tem como objetivo propor um algoritmo alternativo para pesquisa de *endmembers*, chamado *Spectral Statistics Sampler* (SSS). O SSS foi desenvolvido a partir da adaptação das técnicas utilizadas por dois algoritmos de classificação supervisionada, conhecidos como: Paralelepípedo e Máxima Verossimilhança (MaxVer).

2. ALGORITMO SPECTRAL STATISTICS SAMPLER - SSS

O algoritmo SSS (Figura 3) utiliza valores mínimos e máximos dos pixels da ROI, da mesma forma que o classificador paralelepípedo, para definição do limiar do *endmember*. A distância entre o valor de cada pixel da imagem e o desvio-padrão dos valores dos pixels contidos na ROI é ponderada, resultando em um índice que determina os pixels da imagem, com maior probabilidade de pertencer ao *endmember*.

Ele tem como funcionalidade buscar e identificar, na própria imagem, regiões com alta probabilidade de conter o *endmember* investigado, a partir de uma ROI que contenha a referência espectral.

Inicialmente, o algoritmo faz uma análise estatística dos pixels que compõem a ROI, estabelecendo os parâmetros, conforme a Tabela 1, que serão utilizados como referência.

Os pixels são então multiplicados pela razão entre o valor médio da ROI e a média de seus valores espectrais, gerando uma imagem equalizada, diminuindo o efeito do relevo.

Em seguida, os valores espectrais de cada pixels da imagem equalizada são comparados com os parâmetros resultantes da análise estatística do *endmember* contidos na Tabela 1.

Por fim, é atribuído um grau de pertinência a cada pixels, gerando uma imagem, na qual são

destacados os pixels que mais se identificam com o *endmember* buscado.

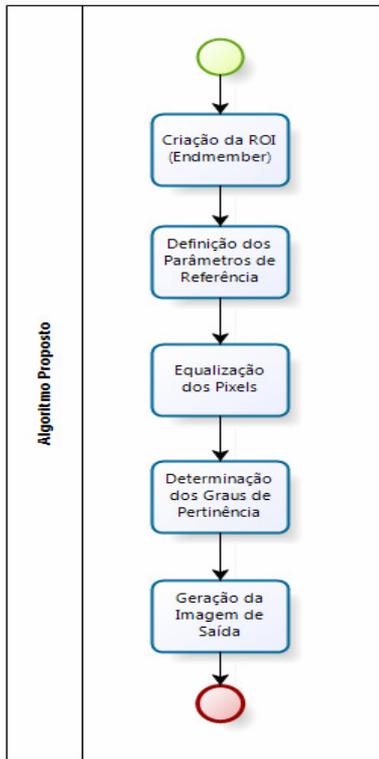


Fig. 3 - Algoritmo SSS.

O algoritmo é detalhado nos quatro passos a seguir.

2.1 Determinação dos parâmetros de referência

Nesse primeiro passo, o algoritmo utiliza uma ROI como referência para a busca de um *endmember* em uma imagem de C colunas, L linhas e N bandas.

Com base nos dados estatísticos dos pixels que compõem a ROI, são registrados, para cada banda, o valor médio, o desvio padrão, o valor máximo e o valor mínimo. A Figura 4 apresenta, para cada banda de uma ROI de um *endmember* fictício, a distribuição estatística dos valores dos pixels, que podem ser de radiância ou de reflectância. Não foram testados nesse artigo ROI de dados em número digital.

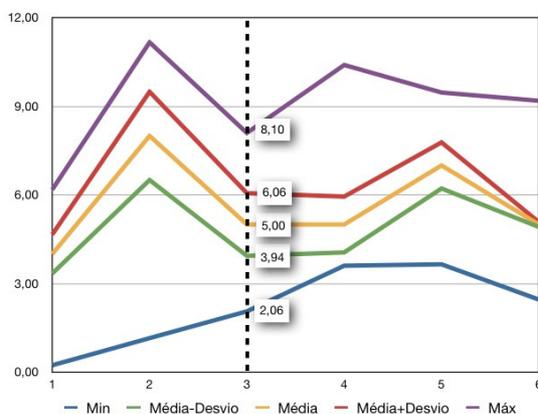


Fig. 4 - Distribuição estatística dos valores dos pixels de uma ROI.

Os seguintes parâmetros são então definidos para cada uma das N bandas da imagem, conforme definido na Tabela 1:

TABELA 1 - CONSTANTES DE REFERÊNCIA DA ROI

Parâmetro	Significado
$MIN[i]$	Menor valor dos pixels componentes da ROI na banda i .
$DESVINF[i]$	Desvio padrão subtraído da média dos valores dos pixels componentes da ROI na banda i .
$MEDIA[i]$	Média aritméticas dos valores dos pixels componentes da ROI na banda i .
$DESVSUP[i]$	Desvio Padrão somado à média dos valores dos pixels componentes da ROI na banda i .
$MAX[i]$	Maior valor dos pixels componentes da ROI na banda i .

Um exemplo da definição das constantes de uma banda pode ser visualizado na Figura 4. As constantes da banda 3 do sensor fictício de 6 bandas ($N=6$) são: $MIN[3] = 2,06$; $DESVINF[3] = 3,94$; $MEDIA[3] = 5,00$; $DESVSUP[3] = 6,06$ e $MAX[3] = 8,10$.

Além disso, é calculada a média aritmética de todos os pixels componentes da ROI (\overline{ROI}), por meio da Equação 1:

$$\overline{ROI} = \frac{\sum_{i=1}^N MEDIA[i]}{N} \quad (1)$$

2.2 Equalização dos pixels

Nesse passo é feita uma transformação dos pixels originais da Imagem ($p[c,l,i]$) em pixels equalizados ($e[c,l,i]$).

O objetivo dessa transformação é minimizar o efeito causado pelo relevo, uma vez que, como afirma Schowengerdt (2007), “a radiância é proporcional ao cosseno do ângulo formado pela irradiação solar e o vetor normal à superfície”.

Isso significa que, para um determinado ponto no terreno, a radiância medida pelo sensor será amplificada ou atenuada, na mesma proporção, em todo o espectro.

Nesse passo são amplificados ou atenuados os valores dos pixels, de maneira que a média dos seus valores espectrais seja igual à média da ROI.

Primeiramente é calculada, para cada pixels, a média aritmética dos valores de todas as N bandas. A média dos pixels ($\overline{P}[c,l]$) é obtida por meio da Equação 2.

$$\overline{P}[c,l] = \frac{\sum_{i=1}^N p[c,l,i]}{N} \quad (2)$$

Em seguida, para cada pixel, calcula-se a proporção ($K[c,l]$) entre a média da ROI (\overline{ROI}) e a média do Pixels ($\overline{P}[c,l]$) (Equação 3).

$$K[c,l] = \frac{\overline{ROI}}{\overline{P}[c,l]} \quad (3)$$

Por fim, os valores dos pixels ($p[c,l,i]$), em cada banda, são multiplicados por $K[c,l]$, gerando os pixels equalizados ($e[c,l,i]$) (Equação 4).

$$e[c,l,i] = K[c,l].p[c,l,i] \quad (4)$$

2.3 Determinação do Grau de Pertinência Equivalente dos pixels para cada banda

Uma vez definidas as constantes de referência para cada uma das N bandas e equalizados os pixels da imagem, deve-se determinar o grau de pertinência equivalente ou GPE ($g[c,l,i]$), em cada banda, para todos os pixels da imagem.

O GPE na banda i é um valor que expressa o quanto determinado pixels se assemelha à ROI de referência, considerada apenas a banda i . Assim, quanto maior o grau de pertinência, mais o pixel se aproxima da referência obtida a partir da ROI.

A Figura 5 apresenta o GPE na banda i , que assumirá um valor entre 0 e 255, de acordo com o valor do pixels e as constantes do *endmember*.

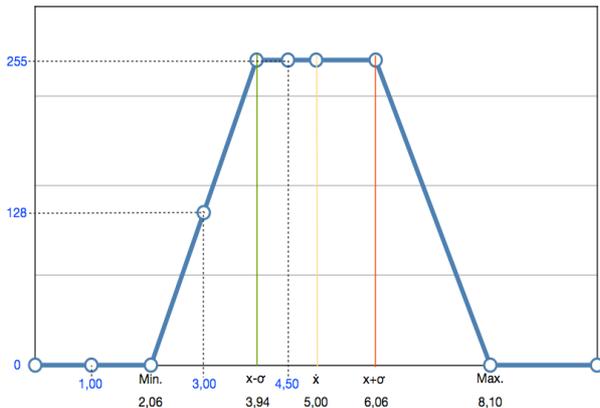


Fig. 5 - Determinação do Grau de Pertinência Equivalente

Quando o valor do pixel estiver entre o desvio padrão inferior e o superior, será atribuído um valor 255 ao grau de pertinência.

Se o valor for menor ou maior que os respectivos valores de referência mínimo e máximo, será atribuído um valor 0 (zero) ao grau de pertinência.

Em último caso, para valores entre o valor de referência mínimo (ou máximo) e o desvio padrão inferior (ou superior) será atribuído um grau de

pertinência proporcional ao valor, considerada a reta que une os dois pontos.

Em resumo, o GPE dos pixels, em cada banda, será determinado de acordo com as equações 5, 6, 7 e 8.

Se $e[c,l,i] < MIN[i]$ ou $e[c,l,i] > MAX[i]$,

$$g[c,l,i] = 0 \quad (5)$$

Se $DESVINF[i] < e[c,l,i] < DESVSUP[i]$,

$$g[c,l,i] = 255 \quad (6)$$

Se $MIN[i] < e[c,l,i] < DESVINFI[i]$,

$$g[c,l,i] = 255 \frac{e[c,l,i] - MIN[i]}{DESVINF[i] - MIN[i]} \quad (7)$$

Se $DESVSUP[i] < e[c,l,i] < MAX[i]$,

$$g[c,l,i] = 255 \frac{MAX[i] - e[c,l,i]}{MAX[i] - DESVSUP[i]} \quad (8)$$

Para exemplificar a determinação do GPE, foram considerados os três pixels consecutivos e seus respectivos valores equalizados na banda 3 (Figura 5): $e[1,1,3] = 1,00$; $e[2,1,3] = 3,00$ e $e[3,1,3] = 4,50$.

Aplicando-se a regra das equações 5, 6, 7 e 8, obtêm-se os GPE dos três pixels, para a banda 3, cujos valores abaixo podem ser visualizados na Figura 5: $g[1,1,3] = 0$; $g[2,1,3] = 128$ e $g[3,1,3] = 255$.

Assim, considerando-se apenas a banda 3 da imagem, poder-se-ia concluir que o pixels da coluna 3 é o que mais se assemelha à referência. No entanto, para tal afirmação, é necessário verificar o grau total de pertinência equivalente dos pixels, considerando todas as bandas da imagem.

2.4 Determinação do Grau Total de Pertinência Equivalente dos pixels

Após a determinação do grau de pertinência equivalente dos pixels para cada banda da imagem ($g[c,l,i]$), resta determinar o grau total de pertinência equivalente (GTPE) de cada pixels da imagem ($G[c,l]$), que é obtido computando a média aritmética dos GPE de todas as bandas.

O GTPE de cada pixel pode ser expresso pela Equação 9.

$$G[c,l] = \sum_{c=1}^C \sum_{l=1}^L \sum_{i=1}^N \frac{g[c,l,i]}{N} \quad (9)$$

Com base nesse resultado é montada uma imagem, na qual cada pixel receberá um valor entre 0 e 255, correspondente ao seu GTPE. Os pixels com valores mais próximos de 255 terão maior probabilidade de corresponderem ao *endmember* buscado e serão destacados na imagem.

3. METODOLOGIA

A metodologia aplicada nesse trabalho (Figura 6) visou validar o algoritmo proposto SSS,

implementado em linguagem IDL, com os resultados obtidos por meio de outros dois algoritmos, o SAM (*Spectral Angle Mapper*) e o SFF (*Spectral Feature Fitting*).

Essa metodologia tem, como ponto de partida, a seleção de uma imagem multiespectral ou hiperespectral.

Com o objetivo de definir o *endmember* a ser utilizado como referência para a busca em toda a imagem, realizou-se um processo para destacar os pixels puros de determinada região.

Inicialmente, foi aplicada à imagem, uma transformação linear do tipo *Minimum Noise Fraction* - MNF (BOARDMAN e KRUSE, 1994; GREEN et al., 1988). Com a finalidade de eliminar a correlação existente entre as centenas de bandas dos sensores hiperespectrais, o MNF reduz a dimensão do conjunto de dados da imagem, concentrando os principais componentes em um número reduzido de bandas.

Da análise dos autovalores associados a cada um dos componentes resultantes da aplicação do MNF à imagem, foram selecionados os principais componentes, para serem utilizados como entrada do algoritmo *Pixels Purity Index* (PPI) (BOARDMAN et al., 1995).

A aplicação do PPI tem como finalidade gerar uma imagem, na qual sejam destacados os pixels considerados puros. São considerados puros os pixels que, computada cada iteração do algoritmo, aparecerem, por mais vezes, nas extremidades de projeções *n*-dimensionais, tomados como referência, vetores aleatórios.

Com base na imagem resultante do PPI e na visualização da dispersão *n*-dimensional (BOARDMAN et al., 1995) dos pixels puros, foi criada uma ROI, sendo então definida como padrão de referência para a busca, em toda a imagem, pelo algoritmo proposto e pelos algoritmos SAM e SFF.

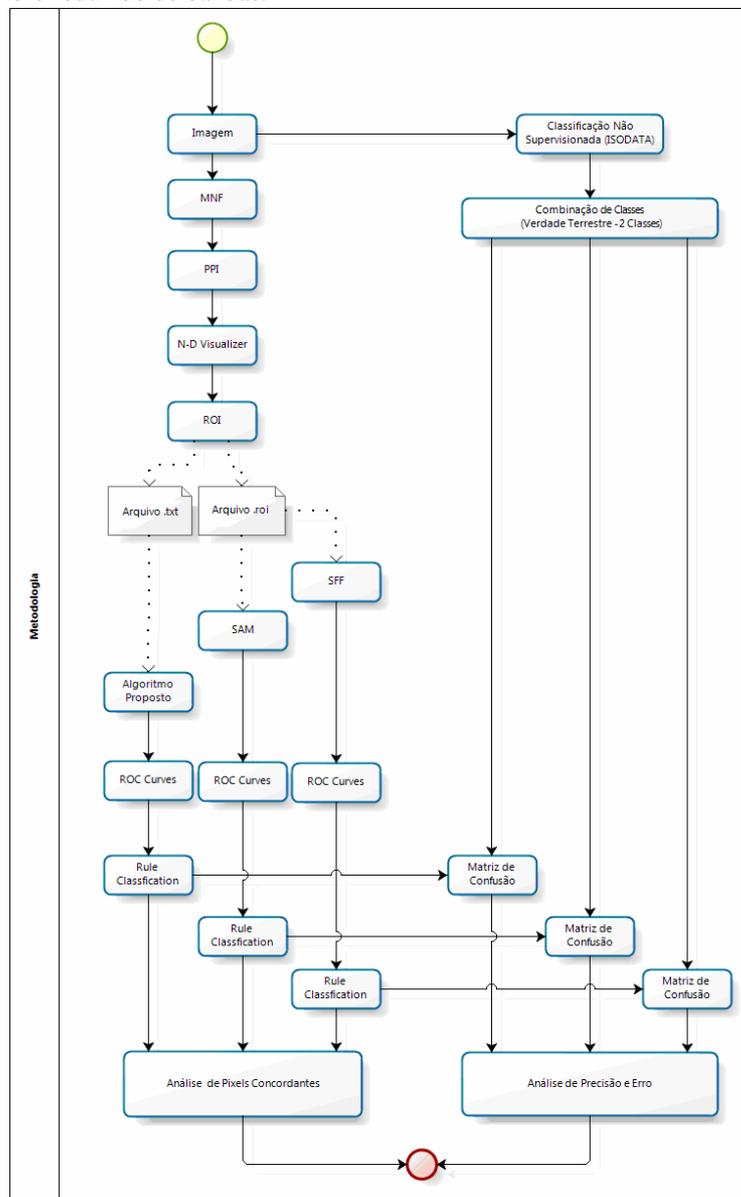


Fig. 6 - Metodologia

Como resultado, cada algoritmo resultou em uma imagem, na qual são destacados os pixels com maior probabilidade de pertencerem à mesma classe de referência utilizada.

Foram então realizadas duas análises distintas dos resultados obtidos, a de pixels concordantes e de precisão e erro.

3.1 Análise de Pixels Concordantes

A primeira análise teve como objetivo verificar o percentual de pixels concordantes, entre aqueles melhores ranqueados por cada algoritmo. Para tal, foi realizada uma classificação, a partir do resultado de cada algoritmo, contendo seus pixels melhores ranqueados. Para determinar o valor de corte dos pixels classificados, tomou-se como referência a quantidade de pixels gerados pelo algoritmo SAM, abaixo do seu valor de limiar (0,10 radianos). Assim, a quantidade de pixels classificados conforme o *endmember*, por cada algoritmo, foi de aproximadamente 13.400 pixels para a imagem de radiância e 10.200 pixels para a imagem de reflectância.

A partir das três classificações geradas, determinou-se o percentual de pixels concordantes e discordantes, comparando-se, dois a dois, os resultados dos algoritmos.

3.2 Análise de Precisão e Erro

Uma segunda análise foi realizada para verificar a precisão e o erro dos algoritmos. Nessa análise, a fim de proporcionar uma referência para a determinação da precisão e do erro dos algoritmos por meio de matrizes de confusão, tomou-se, como verdade terrestre, o resultado de uma classificação não-supervisionada da imagem por meio do algoritmo ISODATA.

A partir do resultado da classificação ISODATA, foi preservada apenas a classe do *endmember*. As demais classes foram combinadas na classe dos pixels *unclassified* ou não-classificados.

Para o resultado de cada algoritmo foram traçadas ROC (*Receiver Operating Characterist*) Curves. A partir das ROC Curves, foram determinados os valores de corte para classificação dos algoritmos (*Rule Classification*), de maneira a compará-los em dois percentuais distintos de detecção: 80% e 50%.

Um a um, os resultados classificados dos algoritmos foram comparados em matrizes de confusão, perante a verdade terrestre adotada: a classificação não-supervisionada ISODATA. Como resultado, foram calculadas a exatidão global, o índice Kappa, a precisão e o erros de omissão e comissão de cada algoritmo, para cada percentual de detecção.

4. PROCESSAMENTO DOS DADOS

Podendo o algoritmo ser aplicado a qualquer tipo de imagem de sensores ópticos, optou-se por concentrar os trabalhos em uma imagem hiperespectral, obtida pelo sensor aerotransportado AVIRIS (*Airborne Visible / Infrared Imaging Spectrometer*) do *Jet Propulsion Laboratory* da NASA, na região de São João D'Aliança, Goiás, Brasil (Figura 7).

A escolha de tal cena se deve ao fato de que resultados de trabalhos anteriores (BAPTISTA, 2001; BAPTISTA et al., 2011; VIVALDI et al., 2013) proporcionaram um bom esclarecimento da composição do solo na região tanto por meio de dados multi como hiperespectrais. Além disso, o uso de uma imagem hiperespectral possibilita uma maior distinção dos alvos, por parte dos algoritmos.

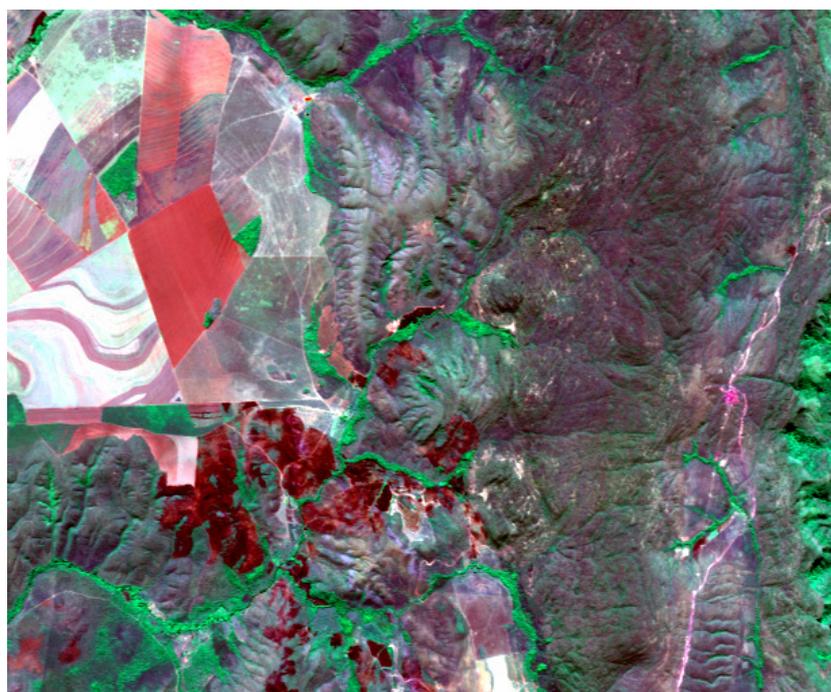


Fig. 7 - Imagem hiperespectral (AVIRIS) - São João D'Aliança - R(0,6579 μ m) G (0,9242 μ m) B (1,2124 μ m)

A imagem utilizada, subcena 3 do voo 2 da missão SCAR-B, produzida pelo sensor AVIRIS embarcado na aeronave ER-2, em 16 de agosto de 1995 (BAPTISTA, 2006, p166), possui uma resolução espectral de 224 bandas contíguas cobrindo o espectro eletromagnético entre 0,4 e 2,5 μm .

A resolução espacial da imagem é de 20 metros, cobrindo uma área de 125,7472 km^2 (12,28 km x 10,24 km) ou 314.368 pixels (614 x 512).

Optou-se por trabalhar com a mesma imagem, porém, com dois conjuntos distintos de dados, ou seja, a imagem original de radiância e a de reflectância, empregando-se o algoritmo Green para a correção atmosférica.

De acordo com as estatísticas da imagem de reflectância, foi observado que, nas bandas de 1 a 4, de 109 a 112 e de 156 a 165, todos os pixels possuem valores nulos. As quatro primeiras bandas apresentam essa característica devido ao deslocamento realizado quando do procedimento de correção atmosférica e posterior redução dos dados de radiância para reflectância de superfície por meio do método GREEN (GREEN et al., 1991). Os outros dois intervalos referem-se às feições de absorção de água centradas a 1,4 e a 1,9 μm , também removidas quando da correção atmosférica. Essas bandas foram então excluídas, no passo seguinte, resultando em 206 bandas de entrada no algoritmo MNF.

Aplicando-se o algoritmo MNF e analisando-se os autovalores resultantes, foram selecionados os 20 primeiros MNFs gerados, para serem utilizados como entrada do algoritmo PPI (Figuras 8 e 9).

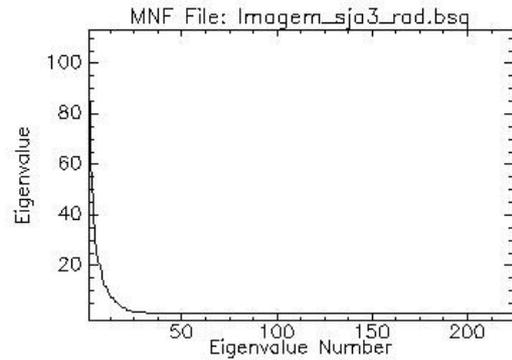


Fig. 8 - Autovalores do MNF referentes à imagem de radiância.

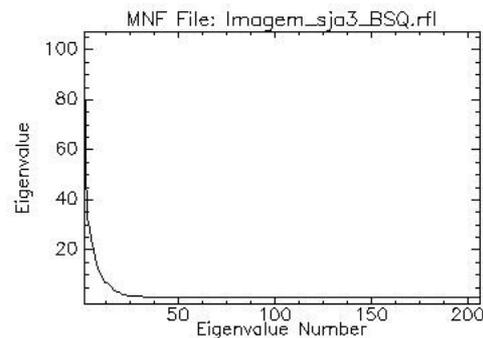


Fig. 9 - Autovalores do MNF referentes à imagem de reflectância.

Com base na imagem resultante do PPI e na visualização do escatergrama n -dimensional dos pixels puros, foi criada uma ROI (de 267 pixels para a imagem de radiância e de 274 pixels para a imagem de reflectância) em uma área que, segundo Baptista (2001), é composta predominantemente por solos caulínicos (Figura 10).

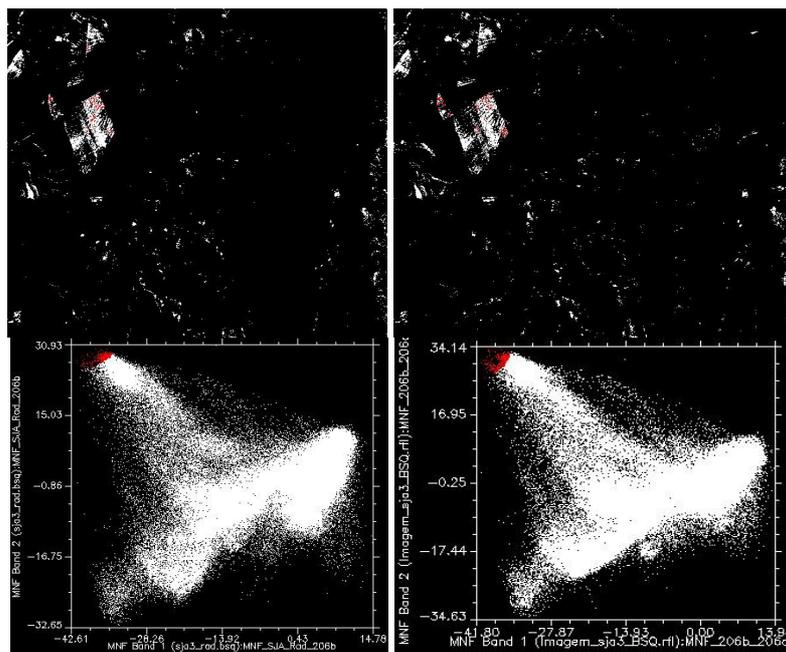


Fig. 10 - Espacialização dos pixels puros referentes à ROI de solos caulínicos a partir do escatergrama n -dimensional obtido sobre os dados de radiância e de reflectância, respectivamente.

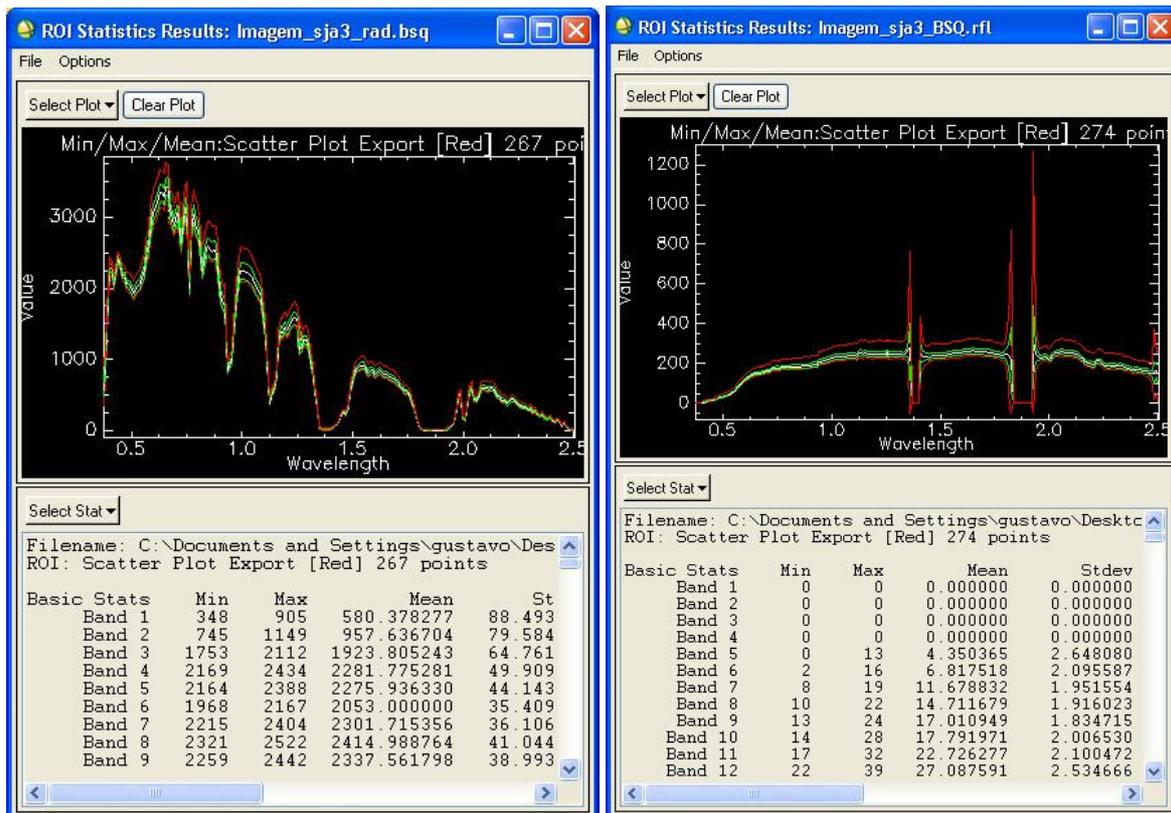


Fig. 11 - Estatísticas da ROI dos dados de radiança e de reflectância, respectivamente.

A ROI criada foi utilizada como *endmember* a ser buscado pelos algoritmos SAM e SFF. Os dados estatísticos da ROI foram salvos em um arquivo em formato txt (Figura 11), que foi utilizado pelo algoritmo SSS como *endmember* de referência.

5. ANÁLISE DOS RESULTADOS

Para a análise dos resultados, as imagens de saída (*rule*), geradas pelos três algoritmos, foram trabalhadas de forma distinta.

Como resultado da busca do *endmember* nas imagens de radiança e de reflectância, foram obtidas, respectivamente, as saídas do tipo *rule image* obtidas em níveis de cinza e coloridas por meio da Tabela de cores *rainbow*, conforme apresentado nas Figuras 12 e 13.

Analisando as imagens de radiança (Figura 12), observa-se que os algoritmos SAM e SSS tenderam

a diferenciar, com maior destaque no topo de suas escalas, os pixels com maior probabilidade de pertencerem ao *endmember* buscado. Por outro lado, o algoritmo SFF destacou uma quantidade muito pequena de pixels em vermelho, apresentando a maioria dos pixels na metade inferior da escala (abaixo do ciano).

No caso das imagens de reflectância (Figura 13), o algoritmo proposto apresentou um resultado bastante similar ao apresentado para a imagem de radiança. Diferentemente, os resultados dos demais algoritmos foram inferiores para a imagem corrigida. Os valores dos pixels resultantes do algoritmo SAM, apesar de destacarem o *endmember*, ficaram aglomerados no topo da escala, variando do vermelho ao verde. Enquanto isso, o algoritmo SFF resultou em pixels agrupados na parte inferior da escala, com pouca diferenciação para o *endmember* de referência.

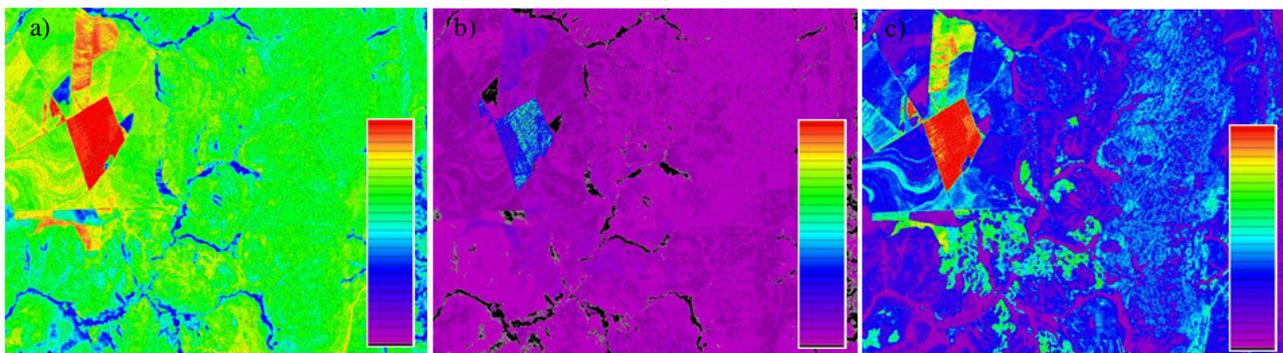


Fig. 12 – a) SAM *rule*; b) SFF *rule*; c) SSS *rule* obtidas sobre os dados de radiança.

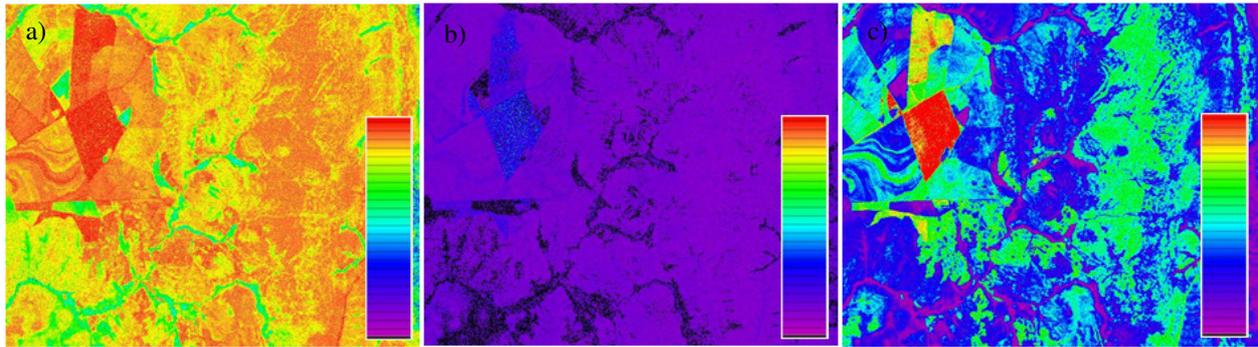


Fig. 13 – a) SAM rule; b) SFF rule; c) SSS rule obtidas sobre os dados de reflectância.

5.1 Análise de Pixels Concordantes

Com base na quantidade de pixels melhores ranqueados, definida na metodologia, 13.400 pixels melhores classificados para a imagem de radiância e 10.200 pixels para a imagem de reflectância, foram geradas as imagens classificadas (Figuras 14 e 15). Os resultados da comparação dos pixels melhores ranqueados pelos três algoritmos podem ser visualizados na Tabela 2 e na Figura 16 (para a imagem de radiância) e na Tabela 3 e na Figura 17 (para a imagem de reflectância).

Na comparação dos algoritmos dois a dois, estão excluídos os pixels concordantes entre os três algoritmos.

TABELA 2 – ANÁLISE DOS PIXELS CONCORDANTES NOS RESULTADOS OBTIDOS SOBRE OS DADOS DE RADIANCIA CONSIDERADOS (13.373 PIXELS).

Algoritmos Comparados	Pixels Concordantes
SAM x SFF x SSS	11.259 (84,2%)
SAM x SFF	691 (5,2%)
SSS x SAM	834 (6,2%)
SSS x SFF	181 (1,4%)

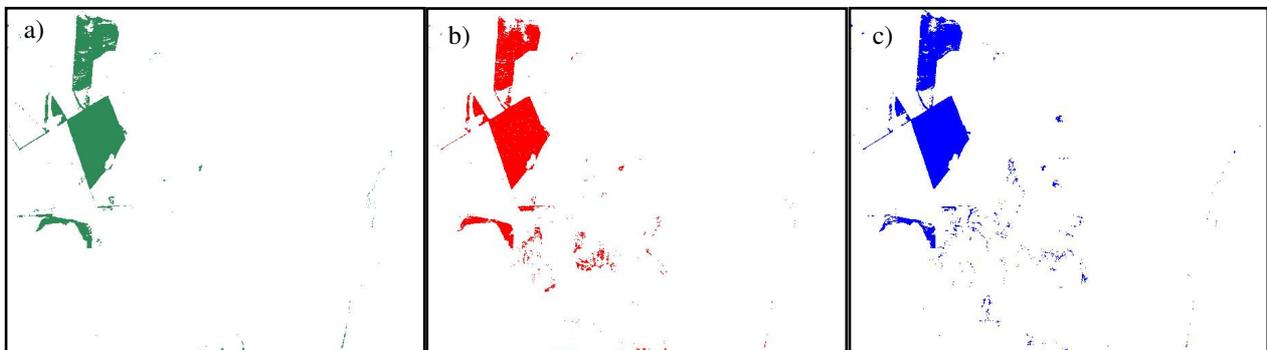


Fig. 14 – a) 13.380 pixels melhores ranqueados pelo SAM; b) 13.373 pixels melhores ranqueados pelo SFF; c) 13.426 pixels melhores ranqueados pelo SSS sobre os dados de radiância.

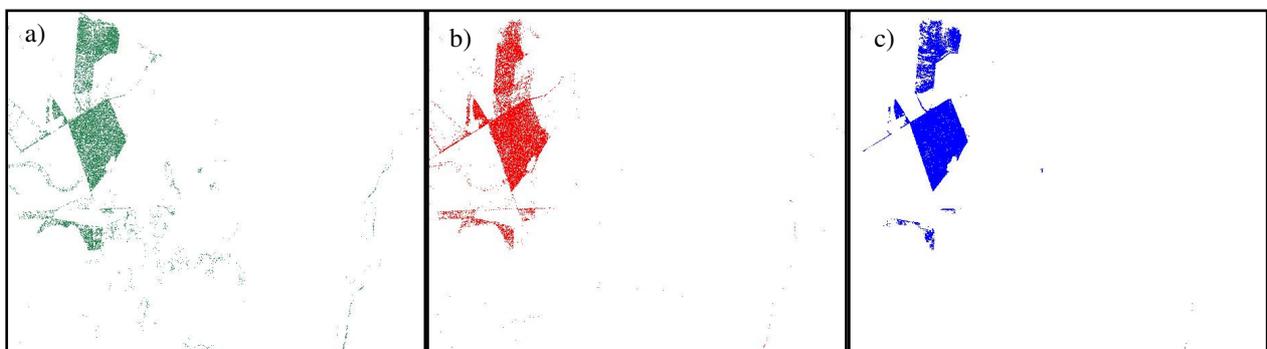


Fig. 15 – a) 10.192 pixels melhores ranqueados pelo SAM; b) 10.116 pixels melhores ranqueados pelo SFF; c) 10.242 pixels melhores ranqueados pelo SSS sobre os dados de reflectância.

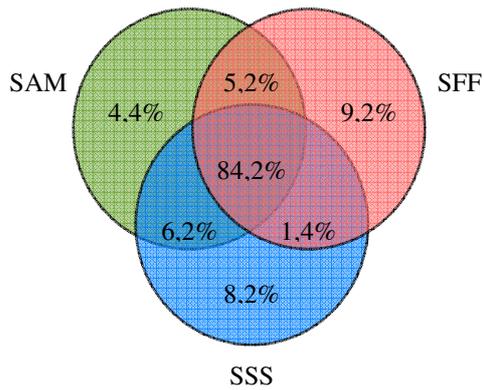


Fig. 16 - Análise dos Pixels Concordantes nos resultados obtidos sobre os dados de radiância.

Analisando os resultados obtidos, verifica-se que, para a imagem de radiância, o algoritmo SAM foi o que apresentou uma maior concordância de pixels, comparando-o com os outros dois algoritmos. Um total de 95,6% dos 13.373 pixels melhores ranqueados pelo algoritmo SAM foram também classificados pelos outros dois algoritmos, contra 91,8% (SSS) e 90,8% (SFF).

TABELA 3 – ANÁLISE DOS PIXELS CONCORDANTES NOS RESULTADOS OBTIDOS SOBRE OS DADOS DE REFLECTÂNCIA CONSIDERADOS (10.116 PIXELS).

Algoritmos Comparados	Pixels Concordantes
SAM x SFF x SSS	5.945 (58,8%)
SAM x SFF	953 (9,4%)
SSS x SAM	1.1235 (12,2%)
SSS x SFF	1.598 (15,8%)

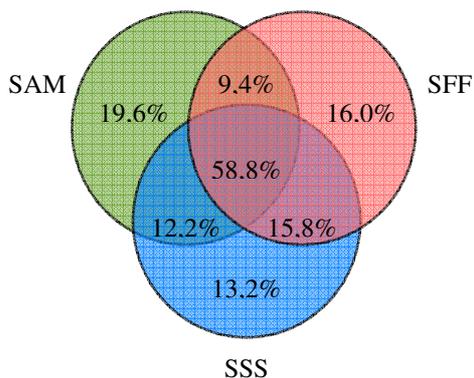


Fig. 17 - Análise dos Pixels Concordantes nos resultados obtidos sobre os dados de reflectância.

Entretanto, para a imagem de reflectância, o algoritmo proposto obteve o melhor resultado. Dos 10.116 pixels melhores ranqueados pelo algoritmo, 86,8% foram também classificados pelos demais algoritmos. Os algoritmos SFF e SAM tiveram, respectivamente, 84,0% e 80,4% de seus pixels classificados também por outro algoritmo.

A Tabela 4 resume o desempenho dos algoritmos.

TABELA 4 – COMPARAÇÃO DE DESEMPENHO DOS ALGORITMOS

Melhor Desempenho	Pixels Concordantes	
	Imagem de Radiância	Imagem de Reflectância
1	SAM (95,6%)	SSS (86,8%)
2	SSS (91,8%)	SFF (84,0%)
3	SFF (90,8%)	SAM (80,4%)

5.2 Análise de Precisão e Erro

Para analisar a precisão e o erro do algoritmo proposto, comparando-o com os demais algoritmos (SAM e SFF), foi necessário definir uma verdade terrestre comum. Com isso foi possível gerar matrizes de confusão, para os resultados de cada algoritmo, aplicados a cada tipo de dado: radiância ou reflectância.

Devido ao elevado custo e ao tempo necessário para se realizar um levantamento de campo satisfatório da área, optou-se por utilizar uma imagem gerada a partir de uma classificação não-supervisionada da própria região. O algoritmo ISODATA foi empregado, gerando as imagens classificadas de radiância e reflectância. Cada imagem classificada foi gerada com sete classes (Figura 18).

Em seguida, a Classe 5 de cada imagem, representada pela cor ciano (Figura 18), foi renomeada para *endmember*. As demais classes foram combinadas na classe *unclassified*. Essa combinação resultou nas imagens apresentadas na Figura 19, que foram utilizadas como verdade terrestre na matriz de confusão de cada algoritmo.

Por outro lado, as *rule images* geradas por cada algoritmo (Figuras 12 e 13) foram submetidas ao procedimento de geração de ROC (*Receiver Operating Characterist*) *Curves*, para determinar a relação entre a Probabilidade de Detecção (PD) e a Probabilidade de Falso Alarme (PFA). Além disso, as ROC *Curves* foram utilizadas para determinar o valor de corte (*threshold*) da imagem *rule* de cada algoritmo, a fim de possibilitar a geração de imagens de entrada para as matrizes de confusão.

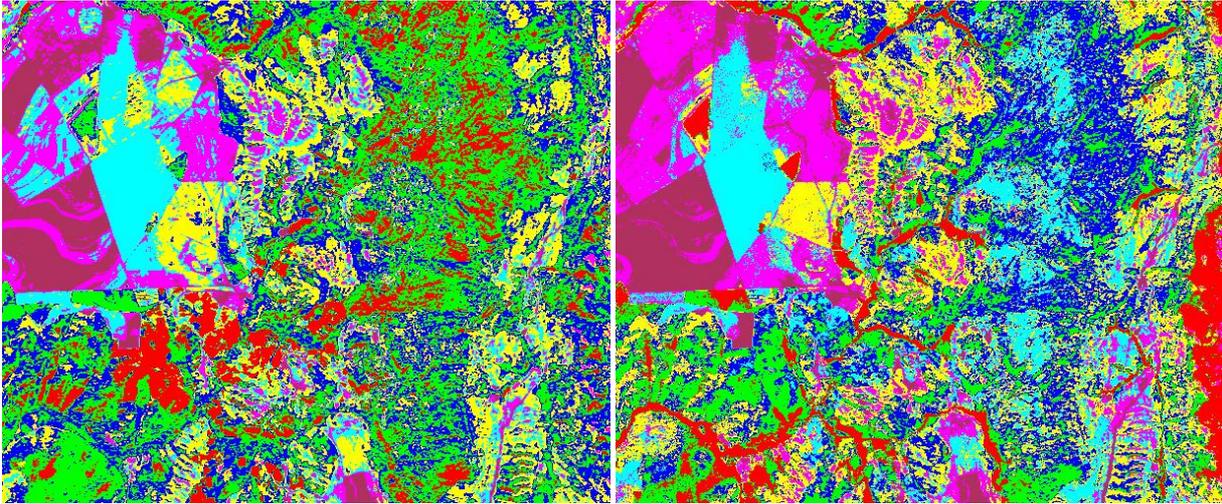


Fig. 18 – Classificação ISODATA (7 classes) sobre os dados de radiância e de reflectância, respectivamente.

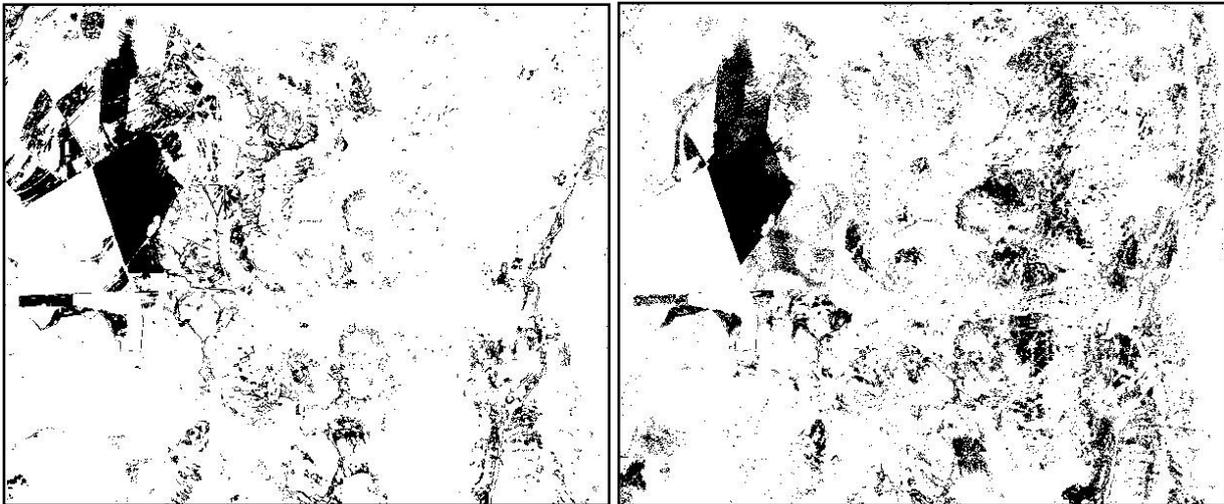


Fig. 19 – Combinação em duas classes, sendo a do *endmember* destacada em preto e *unclassified*, em branco, obtida a partir da pós-processamento dos resultados ISODATA sobre os dados de radiância e de reflectância, respectivamente.

A Figura 20 apresenta as ROC Curves (PD x PFA) dos três algoritmos, aplicados, respectivamente, as imagens *rule* de radiância e reflectância.

Analisando a Figura 20, referente à imagem de radiância, observa-se, para qualquer valor de corte aplicado, que o algoritmo SAM apresenta uma maior probabilidade de detecção, para uma mesma

probabilidade de falso alarme. Analogamente, o algoritmo SAM apresenta uma menor probabilidade de falso alarme, para uma mesma probabilidade de detecção. Ainda é possível verificar que o algoritmo SFF apresentou o segundo melhor desempenho comparado com o algoritmo proposto.

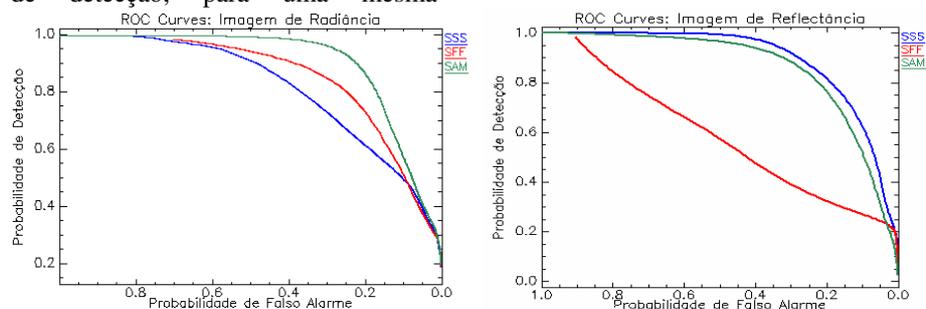


Fig. 20 – ROC Curves (PD x PFA) sobre as imagens de radiância e reflectância, respectivamente.

No caso da imagem de reflectância, as ROC Curves (Figura 20) mostram que o algoritmo proposto apresentou uma melhor relação entre Probabilidade de Detecção e Probabilidade de Falso Alarme que os algoritmos SAM e SFF. Também é possível verificar que o algoritmo SAM apresentou o segundo melhor desempenho e que os resultados do algoritmo SFF foi bem aquém dos demais.

Para comprovar e quantificar o desempenho dos algoritmos, estimado pelas ROC Curves (PD x PFA), foram utilizadas matrizes de confusão.

Com base nas ROC Curves (*Threshold* x PD) foram estabelecidos dois valores de corte a serem testados nas matrizes de confusão: Probabilidade de Detecção de 50% e de 80%.

As Figuras de 21 a 26 mostram os valores de corte (*threshold*) associados a cada Probabilidade de Detecção (50% e 80%), para as imagens *rule* resultantes da aplicação de cada algoritmo à imagem de radiância.

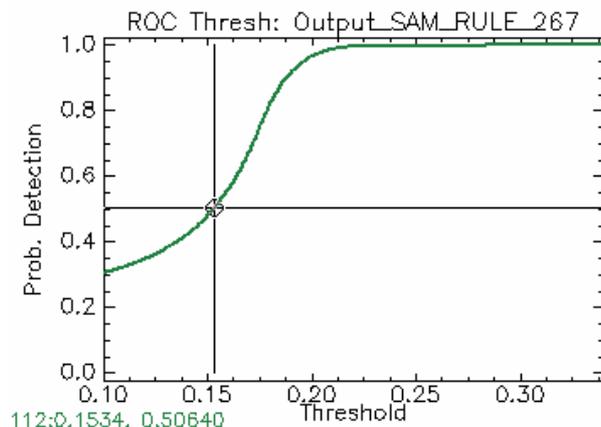


Fig. 21 – ROC Curves (*Threshold* x PD) - Imagem de radiância – SAM (PD = 50%)

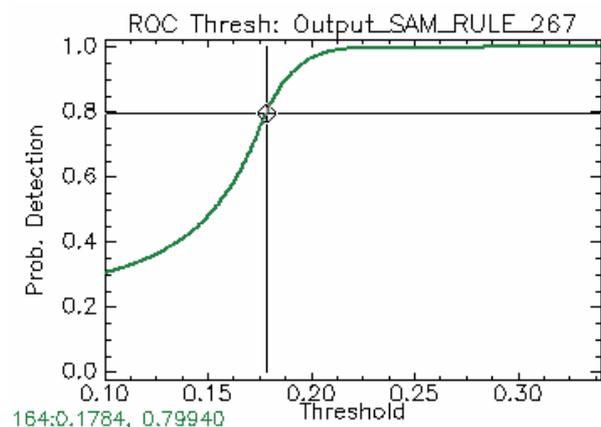


Fig. 22 – ROC Curves (*Threshold* x PD) - Imagem de radiância – SAM (PD = 80%)

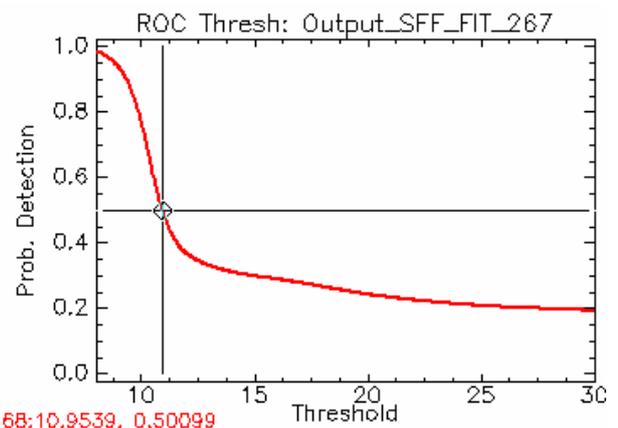


Fig. 23 – ROC Curves (*Threshold* x PD) - Imagem de radiância – SFF (PD = 50%)

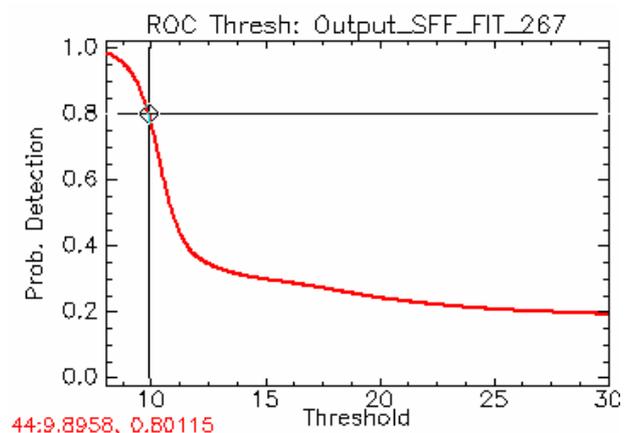


Fig. 24 – ROC Curves (*Threshold* x PD) - Imagem de radiância – SFF (PD = 80%)

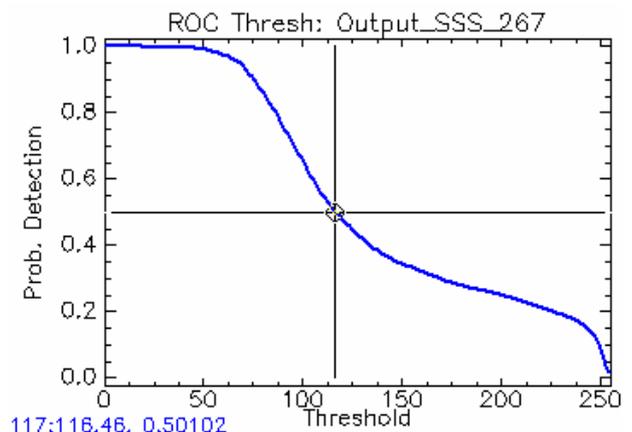


Fig. 25 – ROC Curves (*Threshold* x PD) - Imagem de radiância – SSS (PD = 50%)

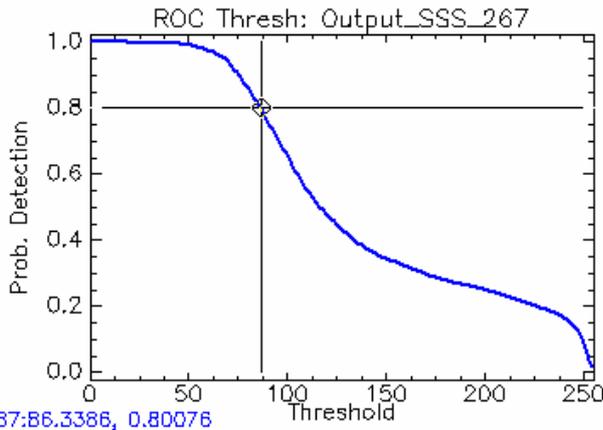


Fig. 26 – ROC Curves (Threshold x PD) - Imagem de radiância – SSS (PD = 80%)

As figuras de 27 a 32 mostram os valores de corte (*threshold*) associados a cada Probabilidade de Detecção (50% e 80%), para as imagens *rule* resultantes da aplicação de cada algoritmo à imagem de reflectância.

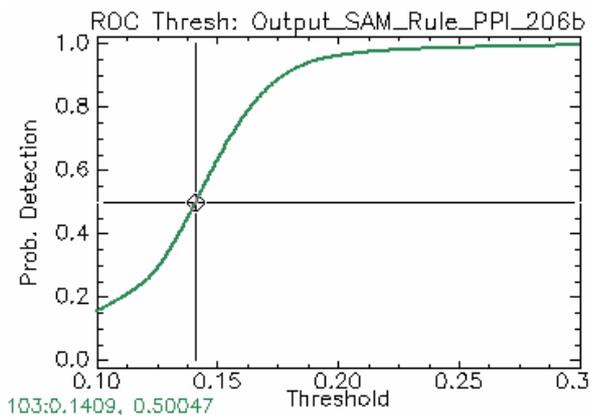


Fig. 27 – ROC Curves (Threshold x PD) - Imagem de reflectância – SAM (PD = 50%)

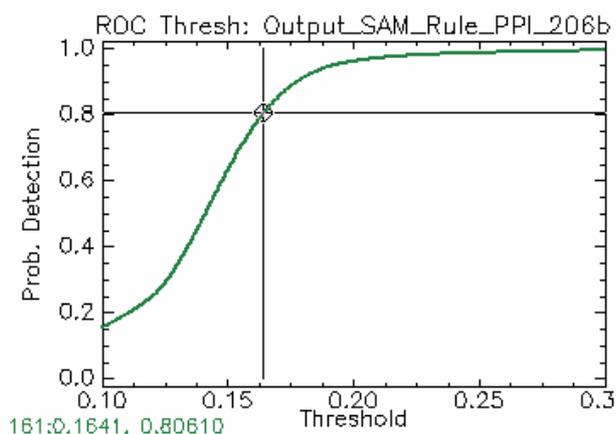


Fig. 28 – ROC Curves (Threshold x PD) - Imagem de reflectância – SAM (PD = 80%)

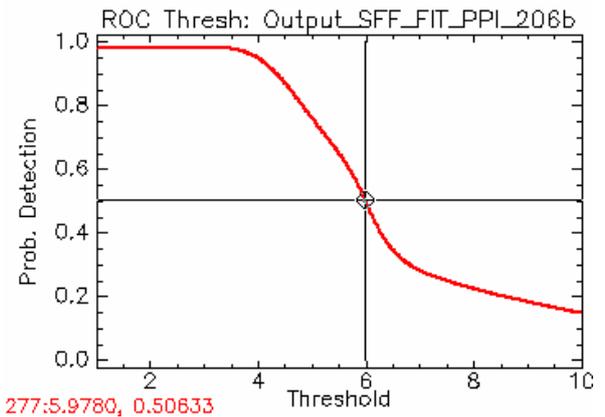


Fig. 29 – ROC Curves (Threshold x PD) - Imagem de reflectância – SFF (PD = 50%)

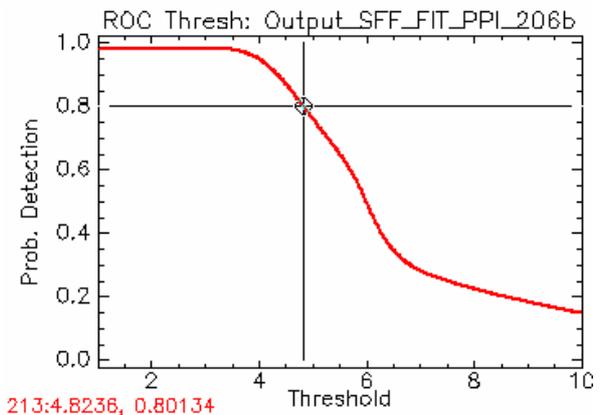


Fig. 30 – ROC Curves (Threshold x PD) - Imagem de reflectância – SFF (PD = 80%)

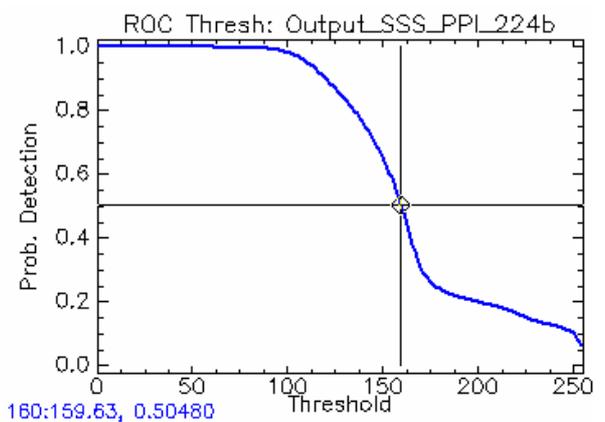


Fig. 31 – ROC Curves (Threshold x PD) - Imagem de reflectância – SSS (PD = 50%)

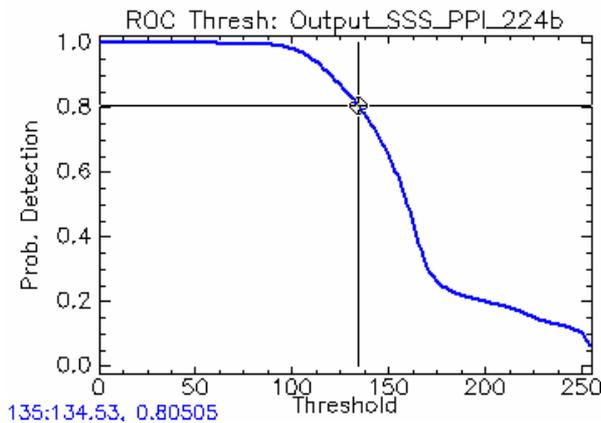


Fig. 32 – ROC Curves (Threshold x PD) - Imagem de reflectância – SSS (PD = 50%)

Resumidamente, os valores de corte são apresentados na Tabela 5.

TABELA 5 – VALORES DE CORTE (THRESHOLD).

Alg.	Imagem de Radiância		Imagem de Reflectância	
	PD 50%	PD 80%	PD 50%	PD 80%
SAM	0,1534	0,1784	0,1409	0,1641
SFF	10,9539	9,8958	5,9780	4,8236
SSS	116,46	86,3386	159,63	134,53

Adotando os valores de corte obtidos das ROC Curves (Threshold x PD), foram geradas doze imagens por meio do procedimento *Rule Classifier*. Cada imagem foi então inserida, individualmente, em uma matriz de confusão, contendo a classificação combinada ISODATA (Figura 19) como verdade terrestre de referência.

Os resultados das matrizes de confusão encontram-se resumidos nas Tabelas 6 (radiância) e 7 (reflectância).

Conforme esperado, os resultados obtidos através da aplicação das matrizes de confusão comprovaram a análise feita a partir das ROC Curves (PD x PFA).

Considerando a imagem de radiância, o algoritmo SAM apresentou o melhor desempenho. Como pode ser visualizado na Tabela 6, o algoritmo SAM apresentou a maior Exatidão Global e o menor Erro de Comissão, para uma mesma Probabilidade de Detecção. O índice Kappa (acima de 0,4) revelou uma qualidade de classificação boa para o algoritmo SAM, de acordo com Landis e Koch (1977). Para os outros dois algoritmos, a qualidade de classificação ficou entre ruim e razoável.

TABELA 6 – RESUMO DOS RESULTADOS DAS MATRIZES DE CONFUSÃO (RADIÂNCIA)

PD	Alg.	Exat. Global	Índice Kappa	Erro de Comis.	Erro de Omis.
50%	SAM	87,76%	0,4007	55,98%	49,69%
	SFF	86,14%	0,3601	61,14%	49,90%
	SSS	85,52%	0,3461	62,81%	49,90%
80%	SAM	82,86%	0,4124	63,59%	20,67%
	SFF	75,71%	0,3043	71,97%	19,89%
	SSS	65,34%	0,1948	79,04%	19,92%

Em relação à imagem de reflectância, o melhor desempenho verificado coube ao algoritmo proposto, que apresentou um menor Erro de Comissão e uma maior Exatidão Global, dada uma mesma Probabilidade de Detecção (Tabela 7). Além disso, o índice Kappa para o algoritmo proposto esteve sempre acima de 0,4, o que qualifica sua classificação como boa. Já os algoritmos SAM e SFF apresentaram, respectivamente, índice Kappa razoável (entre 0,2 e 0,4) e ruim (entre 0 e 0,2).

TABELA 7 – RESUMO DOS RESULTADOS DAS MATRIZES DE CONFUSÃO (REFLECTÂNCIA)

PD	Alg.	Exat. Global	Índice Kappa	Erro de Comis.	Erro de Omis.
50%	SAM	84,80%	0,3910	54,08%	49,77%
	SFF	56,25%	0,0410	83,91%	49,37%
	SSS	87,35%	0,4540	44,90%	49,52%
80%	SAM	77,69%	0,3834	63,55%	19,49%
	SFF	32,06%	0,0153	85,35%	19,88%
	SSS	80,74%	0,4331	59,56%	19,49%

6. CONCLUSÕES

Os resultados obtidos neste trabalho demonstram que o algoritmo proposto, o SSS foi tão eficiente quanto o algoritmo SAM na identificação do *endmember* selecionado. Enquanto o algoritmo SAM obteve o melhor desempenho para a imagem de radiância o algoritmo proposto foi mais eficiente na imagem de reflectância.

Além disso, seu desempenho, comparado com o algoritmo SFF, mostrou-se superior em ambos os tipos de imagem.

Um fato importante a ser considerado é a possibilidade de implementação do algoritmo proposto em softwares livres, como alternativa a softwares de alto custo, proprietários de algoritmos similares.

Para uma análise mais abrangente da aplicabilidade do algoritmo, sugere-se a verificação de seu desempenho diante de outros sensores (multi e hiperespectrais), além de outros *endmembers*.

Outros trabalhos devem ser incentivados com o objetivo de verificar a eficiência do algoritmo, para *endmembers* específicos, como áreas mineralógicas distintas, por meio de ajustes dos valores de referência.

Recomenda-se, também, o desenvolvimento de pesquisa para avaliar a implementação de pesos diferenciados a cada banda, de maneira a enfatizar os pontos de absorção característicos do *endmember*, proporcionando uma maior diferenciação dos alvos.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- BAPTISTA, G. M. M. **Mapeamento e Quantificação da Relação Mineralógica Caulinita/(Caulinita/Gibsit) de Solos Tropicais, por meio dos Dados do Sensor AVIRIS (JPL/NASA)**. 2001. Tese (Doutorado em Geologia) – Instituto de Geociências, Universidade de Brasília, Brasília, 2001.
- BAPTISTA, G. M. M. **Sensoriamento Remoto Hiperespectral: o novo paradigma nos estudos de solos tropicais**. Brasília: Universa, 2006.
- BAPTISTA, G. M. M.; CORREA, R. S. ; SANTOS, P. F.; MADEIRA NETTO, J. S.; MENESES, P. R. Use of Imaging Spectroscopy for Mapping and Quantifying The Weathering Degree of Tropical Soils in Central Brazil. **Applied and Environmental Soil Science**, v. 2011, p. 1-7, 2011.
- BOARDMAN J. W., KRUSE, F. A. Automated spectral analysis: A geologic example using AVIRIS data, north Grapevine Mountains, Nevada: in **Proceedings, Tenth Thematic Conference on Geologic Remote Sensing**, Environmental Research Institute of Michigan, Ann Arbor, MI, p. I-407 - I-418. 1994.
- BOARDMAN, J. W., KRUSE, F. A., GREEN, R. O. Mapping target signatures via partial unmixing of AVIRIS data: in **Summaries, Fifth JPL Airborne Earth Science Workshop**, JPL Publication 95-1, v. 1, p. 23-26. 1995.
- CLARK, R. N., GALLAGHER, A. J., SWAYZE, G. A. Material absorption band depth mapping of imaging spectrometer data using the complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials: in **Proceedings of the Third Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop**, JPL Publication 90-54, p. 176 - 186. 1990.
- CLARK, R.N.; SWAYZE, G.A.; GALLAGHER, A.; GORELICK, N.; KRUSE, F.A. Mapping with imaging spectrometer data using the complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials. **Proceedings of the Third Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop**, JPL Publication 91-28, Jet Propulsion Laboratory, Pasadena, California, 2-3. 1991.
- CLARK, R. N., SWAYZE, G. A., GALLAGHER, A. Mapping the mineralogy and lithology of Canyonlands, Utah with imaging spectrometer data and the multiple spectral feature mapping algorithm: in **Summaries of the Third Annual JPL Airborne Geoscience Workshop**, JPL Publication 92-14, v 1, p. 11-13. 1992.
- CLARK, R. N., SWAYZE, G. A. Mapping minerals, amorphous materials, environmental materials, vegetation, water, ice, and snow, and other materials: The USGS Tricorder Algorithm: in **Summaries of the Fifth Annual JPL Airborne Earth Science Workshop**, JPL Publication 95-1, p. 39 - 40. 1995.
- CROSTA, A. P. **Processamento Digital de Imagens. Campinas**: Campinas, IG/UNICAMP, 1993.
- GREEN, A. A., BERMAN, M., SWITZER, P, CRAIG, M. D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal: **IEEE Transactions on Geoscience and Remote Sensing**, v. 26, no. 1, p. 65-74. 1988.
- GREEN, R.O.; CONEL, J.E.; MARGOLIS, J.S.; BRUGGE, C.J.; HOOVER, G.L. An inversion algorithm for retrieval of atmospheric and leaf water absorption from AVIRIS radiance with compensation for atmospheric scattering. **Proceedings of the Third Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop**. JPL Publications 91-28, pp.51-61. 1991.
- KRUSE, F. A., LEFKOFF, A. B., BOARDMAN, J. W., HEIDEBRECHT, K. B., SHAPIRO, A. T., BARLOON, J. P., GOETZ, A. F. H. The spectral image processing system (SIPS) - Interactive visualization and analysis of imaging spectrometer data: **Remote Sensing of Environment**, v. 44, p. 145 – 163. 1993.
- LANDIS, J.R.; KOCK, G.G. The measurements of observer agreement for categorical data. **Biometrics**, v.33, n.1, p.159-174, 1977.
- MENESES, P.R.; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: CNPq, 2012.
- INSTITUTO DE PESQUISAS ESPACIAIS (INPE). **Manuais: Tutorial de Geoprocessamento SPRING**. 2008.

RESEARCH SYSTEMS, INC. **ENVI User's Guide**.
EUA: 2004, 1150p.

SCHOWENGERDT R. A. **Remote Sensing: Models and Methods for Image Processing**. Tucson, Arizona: Elsevier, 2007.

VIVALDI, D. D.; BAPTISTA, G. M. M.; MENESES, P. R. . Avaliação dos processamentos de crosstalk e de correção atmosférica em dados ASTER para identificação da relação mineralógica caulinita/(caulinita + gibbsita) em solos no município de São João d'Aliança (GO). **Brazilian Journal of Geology**, v. 43, p. 571-582, 2013.

3. CONCLUSÃO

Os resultados obtidos neste trabalho demonstram que o algoritmo proposto, o SSS foi tão eficiente quanto o algoritmo SAM na identificação do *endmember* selecionado. Enquanto o algoritmo SAM obteve o melhor desempenho para a imagem de radiância o algoritmo proposto foi mais eficiente na imagem de reflectância.

Além disso, seu desempenho, comparado com o algoritmo SFF, mostrou-se superior em ambos os tipos de imagem.

Um fato importante a ser considerado é a possibilidade de implementação do algoritmo proposto em softwares livres, como alternativa a softwares de alto custo, proprietários de algoritmos similares.

Para uma análise mais abrangente da aplicabilidade do algoritmo, sugere-se a verificação de seu desempenho diante de outros sensores (multi e hiperespectrais), além de outros *endmembers*.

Outros trabalhos devem ser incentivados com o objetivo de verificar a eficiência do algoritmo, para *endmembers* específicos, como áreas mineralógicas distintas, por meio de ajustes dos valores de referência.

Recomenda-se, também, o desenvolvimento de pesquisa para avaliar a implementação de pesos diferenciados a cada banda, de maneira a enfatizar os pontos de absorção característicos do *endmember*, proporcionando uma maior diferenciação dos alvos.

ANEXO 1 – SINOPSE DE SUBMISSÃO