

UNIVERSIDADE FEDERAL DO PARANÁ

MARIO ERNESTO JIJÓN PALMA

REDUÇÃO DE DIMENSIONALIDADE BASEADO NA CODIFICAÇÃO BINÁRIA
PARA DADOS HIPERESPECTRAIS AVIRIS

CURITIBA

2017

MARIO ERNESTO JIJÓN PALMA

REDUÇÃO DE DIMENSIONALIDADE BASEADO NA CODIFICAÇÃO BINÁRIA
PARA DADOS HIPERESPECTRAIS AVIRIS

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Ciências Geodésicas, no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, da Universidade Federal do Paraná.

Orientador: Prof. Dr. Álvaro Muriel Lima Machado

Co-Orientador: Prof. Dr. Jorge Antonio Silva Centeno

CURITIBA

2017

J61r

Jijón Palma, Mario Ernesto

Redução de dimensionalidade baseado na codificação binária para dados hiperspectrais aviris / Mario Ernesto Jijón Palma. – Curitiba, 2017.

80 f. : il. color. ; 30 cm.

Dissertação - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas, 2017.

Orientador: Álvaro Muriel Lima Machado – Co-orientador: Jorge Antonio Silva Centeno.

Bibliografia: p. 77-80.

1. Geodésia. 2. Codificação binária. 3. Processamento de imagens.
I. Universidade Federal do Paraná. II. Machado, Álvaro Muriel Lima.
III. Centeno, Jorge Antonio Silva. IV. Título.

CDD: 526.1

TERMO DE APROVAÇÃO

MARIO ERNESTO JIJÓN PALMA

“REDUÇÃO DE DIMENSIONALIDADE BASEADO NA CODIFICAÇÃO BINARIA PARA DADOS HIPERESPECTRAIS AVIRIS”

Dissertação nº 306 aprovada como requisito parcial do grau de Mestre no Programa de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

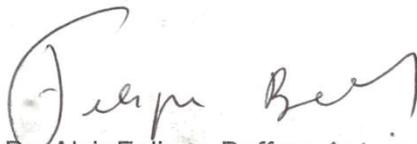
Orientador:



Prof. Dr. Alvaro Muriel Lima Machado
Departamento de Geomática, UFPR



Profª. Drª. Maria de Lourdes Bueno Trindade Galo
Universidade Estadual Paulista, UNESP



Prof. Dr. Alzir Felipe Buffara Antunes
Departamento de Geomática, UFPR

Curitiba, 23 de fevereiro de 2017.

Dedico este trabalho a minha mãe, Clara Elena, por ser guia, inspiração e apoio durante todo o processo do mestrado e de minha vida. A minha irmã Fanny Elena, pela confiança e apoio neste processo. Cada dia estou mais orgulhoso de você porque conheço seu esforço e determinação para alcançar seus objetivos, não esqueça que estarei ao seu lado para sempre. A minha querida princesa Elena Sarahí, como a luz de minha vida, eu vou te amar, proteger e cuidar sempre. Você é uma pessoa que trouxe alegria para o meu coração e para nossa família. A minha avó falecida Mamá Clarita, quem foi a pessoa que me ensinou a ter sucesso contra qualquer obstáculo e alcançar a felicidade.

AGRADECIMENTOS

Eu agradeço aos meus orientadores Dr. Álvaro Muriel Lima Machado e Dr. Jorge Antonio Silva Centeno pelos ensinamentos, guias e orientações, sempre com muita paciência e dedicação, no desenvolvimento deste projeto de pesquisa que foi concluído com sucesso.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo fornecimento da bolsa de Mestrado.

Aos professores e funcionários do Curso de Pós-Graduação em Ciências Geodésicas da Universidade Federal de Paraná.

À secretária do CPGCG, Mônica Kleuser, que sempre esteve disposta para me ajudar quando precisei.

Aos colegas do laboratório de sensoriamento remoto: Carla Casaroti, Natalia Savariego, Caisse Amisse.

A minha família por compartilhar meus momentos felizes e tristes. Agradecimentos especiais para minha tia Inesita e minha avó Fanny, pelo amor que elas dão para mim e porque tenho a certeza que posso contar com elas o resto de minha vida.

Aos meus colegas de curso, pela acolhida e pelos momentos compartilhados durante este processo do mestrado.

Agradeço também ao Lucia, José Luis e Andrea pelo apoio pessoal e profissional no momento desta pesquisa.

Finalmente, eu quero agradecer de forma especial a minha mãe, irmã e sobrinha, por seu amor e apoio incondicional durante os momentos difíceis apresentados durante estes dois anos de mestrado, além, elas são o motor de motivação para alcançar minhas metas e meus objetivos traçados.

RESUMO

Os sensores hiperespectrais fornecem informações em centenas de bandas espectrais que permitem distinguir diferentes classes ou objetos com mais detalhes. Na classificação supervisionada das imagens, obtidas a partir dessas informações, o número de amostras de treinamento disponíveis é limitado frente ao número de bandas espectrais disponíveis. Assim, a redução de dimensionalidade é um passo importante antes da classificação deste tipo de dados. A abordagem desenvolvida neste trabalho para reduzir a dimensionalidade de dados hiperespectrais AVIRIS é a codificação binária. Esta codificação cria uma representação de bandas espectrais que facilita a identificação de classes mediante o estabelecimento de regiões espectrais vizinhas que armazenam uma quantidade de respostas espectrais referidas às classes de cobertura da terra. Para tanto, foram realizados vários experimentos que permitiram a avaliação desta abordagem com fins da classificação da cobertura da terra. As alternativas usadas na codificação binária foram aplicadas para um determinado número de regiões espectrais. Cada alternativa foi testada para um código binário, utilizando-se tanto um limiar, como três limiares. Após a redução de dimensionalidade realizou-se a análise da separabilidade das classes mediante a divergência transformada. Em seguida, realizou-se a classificação temática dos dados hiperespectrais com dimensão reduzida. A técnica utilizada para a classificação foi de máxima verossimilhança. Para a avaliação da acurácia da classificação foram utilizadas as matrizes de confusão, coeficiente kappa e estimativa global para as amostras de verificação. Os resultados mostraram que a utilização da codificação binária baseada em três limiares, por regiões espectrais, com porcentual do limiar de um sexto e modificado, permitem o mapeamento temático dos dados hiperespectrais com dimensão reduzida, de modo mais eficiente que a utilização de um limiar. Neste contexto, a metodologia proposta para a redução de dimensionalidade em dados hiperespectrais mostrou-se promissora, pois este método de extração de atributos é uma abordagem que reduz a complexidade computacional e melhora o desempenho da análise de dados.

Palavras-chave: processamento de imagens, codificação binária, análise de separabilidade, classificação.

ABSTRACT

Hyperspectral sensors provide information in hundreds of spectral bands that allows to discriminate classes or objects with more details. In the supervised classification of images, obtained from this information, the number of training samples available is limited in comparison to the number of available spectral bands. Thus, the dimensionality reduction is very important step before the classification of this type of data. The approach developed in this work to reduce the dimensionality of hyperspectral AVIRIS data is binary coding. This encoding creates a representation of spectral bands that facilitates the identification of classes by establishing neighboring spectral regions that store a quantity of spectral signatures referred to the classes of land cover. Therefore, several experiments that allowed the evaluation of this approach for the purpose of land cover classifications were tested. The alternatives used in binary encoding were applied for a number of spectral regions. Each alternative has been tested to a binary code through one to various thresholds. After the dimensionality reduction, the separation of the spectral classes was analyzed by the transformed divergence. Next, the thematic classification of reduced hyperspectral data was performed. The technique used for the classification was of maximum likelihood. For the evaluation of the accuracy of the classification the confusion matrices, kappa coefficient and global estimate for the verification samples were used. The results showed that the use of binary encoding based on three thresholds by spectral regions, with a percentage of threshold for the one-sixth and modified, allows the thematic mapping of the hyperspectral data with reduced dimension, more efficiently than the use of a threshold. In this context, the methodology proposed for the reduction of dimensionality in hyperspectral data has shown to be promising, since this attribute extraction method is an approach that reduces the computational complexity and improves the performance of the data analysis.

Key-words: image processing, binary encoding, separability analysis, classification.

LISTA DE FIGURAS

FIGURA 1 - CURVAS DE REFLECTÂNCIA ESPECTRAL DO SOLO, VEGETAÇÃO E ÁGUA.....	18
FIGURA 2 - CURVA DE REFLECTÂNCIA MÉDIA DA VEGETAÇÃO FOTOSSINTETICAMENTE ATIVA	19
FIGURA 3 - CURVA DE REFLECTÂNCIA DOS SOLOS	21
FIGURA 4 - COMPORTAMENTO ESPECTRAL DA ÁGUA EM SEUS DIFERENTES ESTADOS FÍSICOS	22
FIGURA 5 - COMPARAÇÃO DA REFLECTÂNCIA DA ÁGUA PURA E TURVA.....	22
FIGURA 6 - COMPARAÇÃO ESPECTRAL ENTRE SENSORES MULTIESPECTRAIS E HIPERESPECTRAIS.....	23
FIGURA 7 - ILUSTRAÇÃO DO CONCEITO DA IMAGEM HIPERESPECTRAL.....	24
FIGURA 8 - EXEMPLO DE DADOS HIPERESPECTRAIS	26
FIGURA 9 - REGIÃO DE SOBREPOSIÇÃO EM UM ESPAÇO ESPECTRAL 2D	31
FIGURA 10 - DEFINIÇÃO DA RAZÃO DE VEROSSIMILHANÇA.....	31
FIGURA 11 - REPRESENTAÇÃO TÍPICA DO FENÔMENO DE HUGHES.....	33
FIGURA 12 - RESPOSTA ESPECTRAL MEDIA DAS CLASSES QUE MOSTRA A FORMAÇÃO DE UM CÓDIGO BINÁRIO BASEADO EM UM LIMAR.....	35
FIGURA 13 - RESPOSTA ESPECTRAL MÉDIA DAS CLASSES QUE MOSTRA A FORMAÇÃO DE UM CÓDIGO BINÁRIO BASEADO EM TRÊS LIMIARES (INFERIOR, MÉDIO E SUPERIOR).....	36
FIGURA 14 - CUBO HIPERESPECTRAL DA IMAGEM INDIAN PINES DO SENSOR AVIRIS	42
FIGURA 15 - VERDADE DE CAMPO DA IMAGEM INDIAN PINES	42
FIGURA 16 - REPRESENTAÇÃO ESPECTRAL DAS CLASSES.....	43
FIGURA 17 - ESQUEMA METODOLÓGICO DESTES TRABALHOS	44
FIGURA 18 - BANDA RUIDOSA SENSOR AVIRIS (BANDA 103).....	45
FIGURA 19 - BANDAS SEM RUÍDO SENSOR AVIRIS (BANDA 120)	45
FIGURA 20 - ESQUEMA DE REDUÇÃO DE DIMENSIONALIDADE POR CODIFICAÇÃO BINÁRIA	46
FIGURA 21 - ESQUEMA PARA CODIFICAÇÃO BINÁRIA (1 LIMAR).....	48
FIGURA 22 - ESQUEMA PARA CODIFICAÇÃO BINÁRIA (3 LIMIARES).....	50
FIGURA 23 - ESQUEMA DIVERGÊNCIA TRANSFORMADA	52
FIGURA 24 - ESQUEMA DE CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA.....	53
FIGURA 25 - CLASSIFICAÇÃO PARA 1 LIMAR.....	57
FIGURA 26 - CLASSIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMAR 1/6)	60
FIGURA 27 - CLASSIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMAR 3/100)	63
FIGURA 28 - CLASSIFICAÇÃO PARA 3 LIMIARES MODIFICADOS	66
FIGURA 29 - CLASSIFICAÇÃO PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMAR 1/6).....	69
FIGURA 30 - CLASSIFICAÇÃO PARA 3 LIMIARES MODIFICADOS E COM CLASSE ÚNICA DE MILHO	71

LISTA DE TABELAS

TABELA 1 - SENSORES HIPERESPECTRAIS ORBITAIS E AEROTRANSPORTADOS	25
TABELA 2 - CARACTERÍSTICAS DO SENSOR HIPERESPECTRAL AVIRIS	27
TABELA 3 - MATRIZ DE CONFUSÃO PARA UM PROBLEMA DE CLASSIFICAÇÃO DE 5 CLASSES	38
TABELA 4 - RELAÇÃO ENTRE O COEFICIENTE KAPPA E O DESEMPENHO DA CLASSIFICAÇÃO	40
TABELA 5 - NÚMERO DE PIXELS DE TREINAMENTO E TESTE PARA AS CLASSES DE ESTUDO	42
TABELA 6 - BANDAS RUIDOSAS ELIMINADAS SENSOR AVIRIS.....	45
TABELA 7 - CRIAÇÃO DE IMAGENS AGREGADAS POR REGIÕES ESPECTRAIS	47
TABELA 8 - ÍNDICES DE SEPARABILIDADE DAS CLASSES POR DIVERGENCIA TRANSFORMADA PARA 1 LIMAR	56
TABELA 9 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO (1 LIMAR).....	57
TABELA 10 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 1 LIMAR	58
TABELA 11 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES (PORCENTUAL DO LIMAR 1/6)	59
TABELA 12 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO (3 LIMIARES E PORCENTUAL DO LIMAR 1/6)	60
TABELA 13 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMAR 1/6).....	61
TABELA 14 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES (PORCENTUAL DO LIMAR 3/100)	62
TABELA 15 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO (3 LIMIARES E PORCENTUAL DO LIMAR 3/100)	63
TABELA 16 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMAR 3/100).....	64
TABELA 17 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES MODIFICADOS	65
TABELA 18 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO PARA 3 LIMIARES MODIFICADOS	66
TABELA 19 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO COM 3 LIMIARES MODIFICADOS	67
TABELA 20 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMAR 1/6)	68
TABELA 21 - IMAGENS UTILIZADAS PARA 3 LIMIARES PARA A CLASSIFICAÇÃO E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMAR 1/6).....	69
TABELA 22 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMAR 1/6)	70
TABELA 23 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES MODIFICADOS E COM CLASSE ÚNICA DE MILHO	71
TABELA 24 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO COM 3 LIMIARES MODIFICADOS	71
TABELA 25 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (LIMAR MODIFICADO)	72
TABELA 26 - VALORES DOS COEFICIENTES KAPPA PARA AMOSTRAS DE VERIFICAÇÃO	73

LISTA DE SIGLAS, NOMENCLATURAS E SÍMBOLOS

ACP Análise de Componentes Principais

ALI Advanced Land Imager

AVIRIS Airborne Visible / Infrared Imaging Spectrometer

CPs Componentes Principais

EO-1 Earth Observing-1

EUA Estados Unidos da América

FOV Field Of View

HyDICE Hyperspectral Digital Imagery Collection Experiment

IFOV Instantaneous Field Of View

JPL Jet Propulsion Laboratory

LAC LEISA Atmospheric Corrector

MATLAB MATrix LABoratory

NASA National Aeronautics and Space Administration

SWIR Short Wavelength Infrared

USGS United States Geological Survey

VNIR Visible and Near Infrared

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	OBJETIVOS	15
1.1.1	Objetivo Geral.....	15
1.1.2	Objetivos Específicos	16
1.2	JUSTIFICATIVA	16
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO	17
2	REVISÃO DA LITERATURA.....	18
2.1	Comportamento espectral de alvos.....	18
2.1.1	Características espectrais da vegetação	19
2.1.2	Características espectrais do solo	20
2.1.3	Características espectrais da água.....	21
2.2	Sensoriamento Remoto Hiperespectral.....	23
2.2.1	O Sistema Sensor AVIRIS.....	26
2.3	Classificação digital das imagens	27
2.3.1	Classificação Supervisionada.....	28
2.4	Análise de separabilidade entre classes	29
2.4.1	Divergência.....	30
2.4.2	Divergência Transformada	31
2.5	Redução De Dimensionalidade.....	32
2.5.1	Extração de atributos.....	33
2.6	Validação da qualidade	37
2.6.1	Matriz de Erros	37
2.6.2	O Coeficiente Kappa.....	39
3	MATERIAL E MÉTODOS	41
3.1	DADOS EXPERIMENTAIS	41
3.2	Metodologia	43
3.2.1	Exclusão de bandas	44
3.2.2	Redução de dimensionalidade.....	46
3.2.3	Processamento de Imagens	51
3.2.4	Validação de Qualidade.....	53

3.2.5	Experimentação.....	54
4	ANÁLISE DE RESULTADOS	55
4.1	Experimentos	55
4.1.1	Experimento 1: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com um limiar.....	56
4.1.2	Experimento 2: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares (porcentual baseado em 1/6).....	58
4.1.3	Experimento 3: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares (porcentual baseado em 3/100).....	61
4.1.4	Experimento 4: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares modificados	64
4.1.5	Experimento 5: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares e com classe única de milho (porcentual do limiar 1/6).....	67
4.1.6	Experimento 6: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares modificados	70
4.2	Coeficiente kappa.....	73
5	CONCLUSÕES E RECOMENDAÇÕES	74
	REFERÊNCIAS.....	77

1 INTRODUÇÃO

O Sensoriamento Remoto é a ciência, tecnologia e arte de obter informação sobre um objeto, área ou fenômeno da superfície terrestre por meio da análise de dados adquiridos por um dispositivo que não está em contato físico direto com o objeto, a área ou fenômeno sob investigação (Lillesand et al., 2007 e Alavipanah et al., 2010). Dentre as atividades do sensoriamento remoto podem-se destacar a detecção, aquisição e análise (interpretação e extração de informações) da energia eletromagnética emitida ou refletida pelos objetos terrestres identificados nas imagens de satélite (Novo, 2010).

Atualmente, existe uma grande variedade de sensores que têm a capacidade de medir características espectrais em diferentes comprimentos de onda e em grandes áreas (Landgrebe, 2002). Assim, o rápido avanço da tecnologia de sensores resultou no desenvolvimento de sensores hiperespectrais. Esses sensores, com seus sistemas, fornecem imagens de satélite com grande número de bandas espectrais e com largura média de banda muito pequena. Essas imagens trouxeram novos desafios no processamento e interpretação de dados que não foram experimentados com as imagens multiespectrais. Por um lado, com a grande variedade espectral de bandas, aumenta-se a possibilidade de discriminar as classes ou objetos de interesse, e por outro lado, incrementa a acurácia na classificação (Benediktsson e Ghamisi, 2015).

Hoje sabe-se que o crescimento da acurácia da classificação não é proporcional ao incremento de bandas. Ele cresce inicialmente até um ponto máximo, a partir do qual o aumento de novas bandas não traz maiores contribuições, pelo contrário, a partir desse ponto a acurácia diminui. Este problema é conhecido como fenômeno de Hughes (Hughes, 1968), e ocorre pelo limitado número de amostras frente à alta dimensionalidade da imagem.

Este fenômeno, junto com as limitações impostas pelo custo computacional, gera a necessidade de técnicas para redução das bandas usadas na classificação digital. Segundo Serpico et al. (2003) existem duas abordagens para a redução de dimensionalidade: a seleção de atributos ou seleção do subconjunto mais relevante de bandas espectrais, e a extração de atributos, baseada na transformação ou combinação das variáveis do conjunto original. À primeira abordagem correspondem trabalhos como os de Su et al. (2016), Yuan et al. (2015), Fauvel et al. (2015), Asl et

al. (2014), Yang et al. (2012). Já no segundo grupo podem ser incluídos os trabalhos de Zhong et al. (2015), Ren et al. (2014), Zhang et al. (2013), Liao et al. (2013). A redução de dimensionalidade explora a inerente estrutura de baixa dimensão, reduzindo a complexidade computacional e melhorando o desempenho de análise de dados.

Uma opção para a extração de atributos é a codificação binária (Mazer et al. 1988, Jia e Richards 1993). Essa abordagem é conhecida como um algoritmo de análise eficaz e com pequena carga computacional para a classificação (Xie et al., 2011 apud Mazer et al., 1988). Como descreve Schowengerdt (2007), na codificação binária o valor do pixel em cada banda é representado por um estado binário (0 ou 1). Usando um critério de binarização, o valor de um pixel em cada imagem pode ser tratado como um bit. A combinação de vários bits permite gerar novos valores e codificar o conjunto de leituras em todas as bandas espectrais. O critério de binarização é alvo de discussão, pois ele influencia significativamente o resultado da representação e, por conseguinte, da classificação.

Jia e Richards (1993) apresentam uma forma de determinar automaticamente os limiares para imagens hiperespectrais. Esses autores propõem o uso de um ou três limiares T_1 , T_2 , e T_3 (limiares inferior, médio e superior) para codificar uma banda com 1 bit ou 2 bits. Inicialmente escolhe-se T_2 como o valor médio geral (todas as classes) dos números digitais dentro de uma região espectral especificada. No trabalho referenciado, os autores consideram insuficiente o uso de apenas um limiar e propõem derivar os outros dois (inferior e superior) analisando a variação das respostas espectrais dos diferentes tipos de cobertura (classes).

Neste trabalho é descrito um método, baseado naquele proposto por Jia e Richards (1993), para reduzir a dimensionalidade, adaptado para as imagens do sensor AVIRIS, com a finalidade de melhorar o desempenho de análise de dados.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Aplicar o algoritmo de codificação binária para reduzir a dimensionalidade em imagens hiperespectrais AVIRIS com fins de classificação da cobertura da terra.

1.1.2 Objetivos Específicos

- Definir regiões espectrais para analisar as respostas espectrais das diferentes classes de cobertura da terra.
- Avaliar o uso de um limiar e três limiares para a codificação binária.
- Avaliar a aplicabilidade do método proposto por Jia e Richards (1993) para a codificação binária de imagens hiperespectrais AVIRIS.
- Propor um método para o cálculo de limiares (superior e inferior) com base nas respostas espectrais das classes identificadas na área de estudo.
- Avaliar os resultados obtidos por meio da classificação dos dados hiperespectrais de dimensão reduzida.

1.2 JUSTIFICATIVA

O mapeamento da cobertura e uso do terreno provê informação de grande importância para realizar um adequado planejamento territorial. Mediante esta informação pode-se conhecer o estado atual da cobertura vegetal natural, com a finalidade de monitorar os impactos ambientais sobre os ecossistemas, entre outros.

Na atualidade, existem vários tipos de sensores que permitem a obtenção de informações dos objetos da superfície terrestre. Entre eles estão os sensores hiperespectrais, que fornecem imagens em centenas de bandas do espectro eletromagnético e com largura média de banda muito pequena (10 nm). Estas propriedades são fundamentais, já que o aumento da quantidade de bandas com pequena largura permite a discriminação dos atributos da superfície terrestre com descrições mais detalhadas.

Sabe-se que, para a obtenção de descrições mais detalhadas, em classificações supervisionadas, necessita-se de uma quantidade de amostras de treinamento compatível com a quantidade de imagens. Em alguns casos, esta quantidade de amostras não está disponível, acarretando procedimentos forçados

de redução de dimensionalidade. Por outro lado, pode-se ter ainda redundância de informação entre bandas vizinhas.

A redução de dimensionalidade transforma as imagens originais em novas imagens e, se bem efetuada, preserva a capacidade de discriminação dos objetos da cena conservando a geometria da imagem.

Neste contexto, este trabalho apresenta uma abordagem de redução da dimensionalidade baseado na codificação binária para dados hiperespectrais AVIRIS. Esta abordagem é uma técnica de extração de atributos conhecida como um algoritmo de análise eficaz e com pequena carga computacional na classificação da cobertura da terra.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

O presente trabalho apresenta uma técnica de redução de dimensionalidade baseado na codificação binária em imagens hiperespectrais. Esta técnica permite compactar a informação, reduzir o esforço computacional sem perda da acurácia na classificação da cobertura da terra. O mesmo se encontra organizado através dos seguintes tópicos:

O primeiro tópico está constituído por introdução, objetivo geral, objetivos específicos e a justificativa. O segundo trata de uma revisão bibliográfica em assuntos concernentes aos objetivos deste trabalho. Neste capítulo revisa-se alguns conceitos fundamentais referentes ao: comportamento espectral de alvos; sensores hiperespectrais e suas características; redução de dimensionalidade; métodos para reduzir a dimensão nas imagens; algoritmo de codificação binária; classificação de imagens digitais; medidas de separabilidade; e validação dos experimentos da qualidade dos resultados. No terceiro capítulo encontra-se a Metodologia deste trabalho, abordando os procedimentos aplicados através da codificação binária para a obtenção dos objetivos propostos. Seguem os resultados dos experimentos realizados, e conclusões obtidas e recomendações sugeridas após os experimentos.

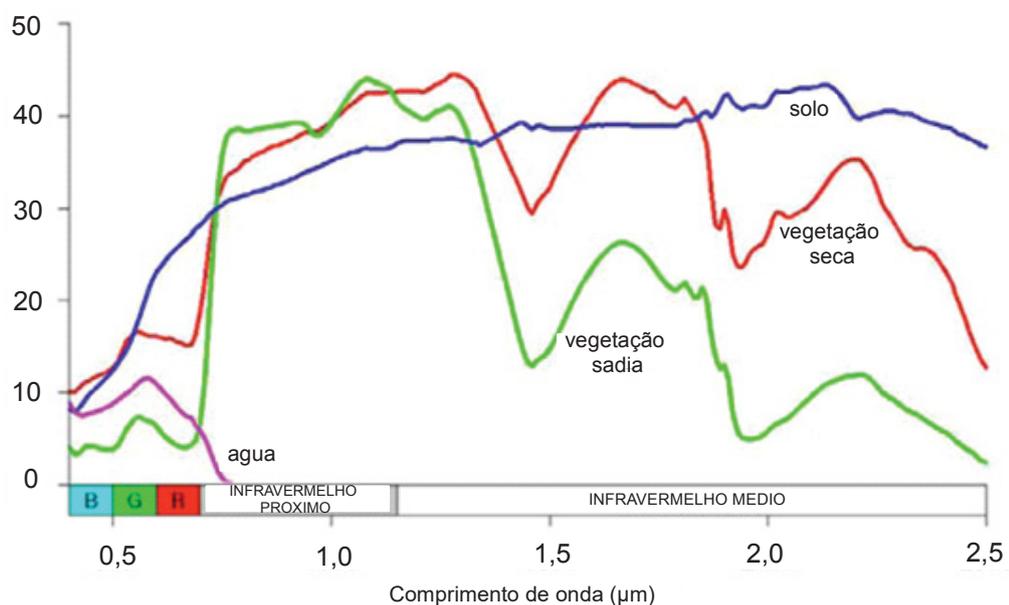
2 REVISÃO DA LITERATURA

2.1 COMPORTAMENTO ESPECTRAL DE ALVOS

Os objetos terrestres refletem, absorvem e transmitem a radiação eletromagnética de maneira diferente em função das propriedades físico-químicas e biológicas (Novo, 2010). Desta forma, cada objeto terrestre possui comportamento espectral específico o qual pode ser determinado com base na energia refletida ao longo do espectro eletromagnético.

Portanto, a variação da energia refletida pelos alvos é representada por meio de curvas de reflectância espectral que são características quando se comparam alvos como vegetação, solos, água, etc. (ver Figura 1). A curva espectral permite representar, através de um gráfico, a reflectância do alvo em função do comprimento de onda.

FIGURA 1 - CURVAS DE REFLECTÂNCIA ESPECTRAL DO SOLO, VEGETAÇÃO E ÁGUA



FONTE: ADAPTADO DE ASHRAF ET AL. (2011)

Deve-se mencionar que as curvas de reflectância espectral podem sofrer alterações e interferências devido a fatores como: a variabilidade natural de um determinado tipo de material e modificações pela atmosfera. Apesar destas alterações, na literatura é possível encontrar curvas padrão obtidas em condições controladas que representam a resposta espectral da reflectância dos alvos.

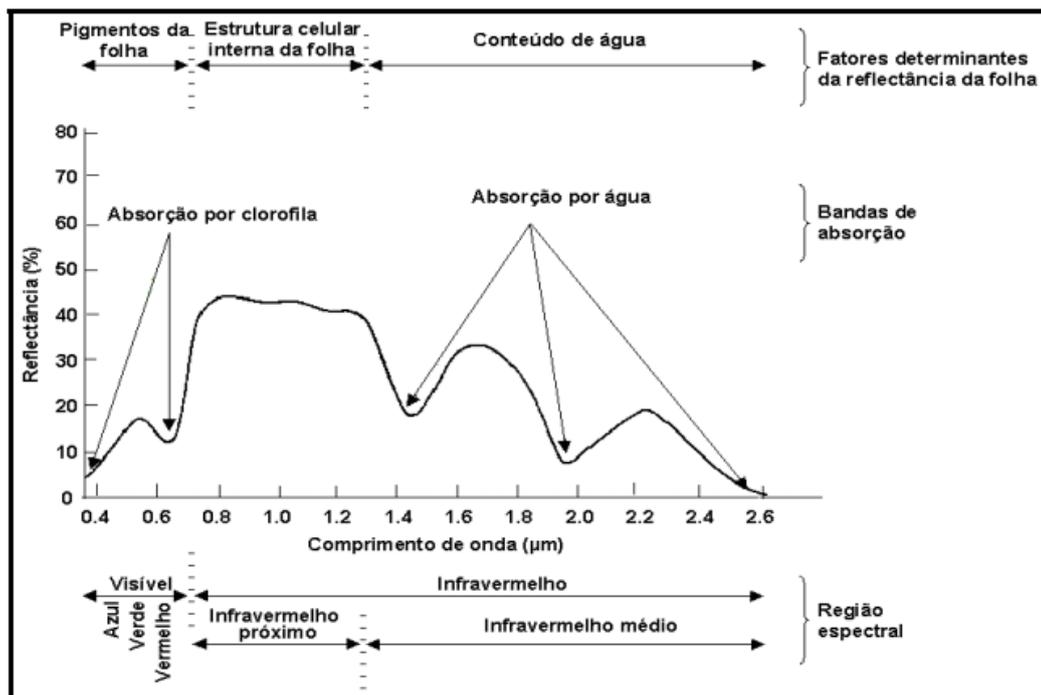
Na continuidade se apresentará um breve detalhe sobre os principais aspectos da reflectância de alguns alvos naturais.

2.1.1 Características espectrais da vegetação

Para a vegetação, a curva espectral está associada com as características das folhas. Na região do visível, a maior parte da radiação eletromagnética absorvida está caracterizada no azul ($0,45 \mu\text{m}$) e no vermelho ($0,65 \mu\text{m}$), devido à presença de pigmentos como a clorofila, ocorrendo um pico de reflectância na zona do verde ($0,54 \mu\text{m}$) (Centeno, 2010).

Na região do infravermelho próximo, a reflectância é muito alta, exceto nas bandas relacionadas com a absorção da água ($0,96$ e $1,1 \mu\text{m}$), as quais dependem dos múltiplos espalhamentos internos decorrentes das propriedades estruturais das folhas. Estas propriedades influenciam fortemente na reflectância, principalmente pela espessura relativa da camada de células do mesofilo (posicionadas entre as epidermes superior e inferior). A camada de mesofilo esponjoso contém cavidades de ar internas que dispersam a radiação incidente. (Chuvienco, 2016).

FIGURA 2 - CURVA DE REFLECTÂNCIA MÉDIA DA VEGETAÇÃO FOTOSSINTETICAMENTE ATIVA



FONTE: NOVO (2010).

Na região do infravermelho médio a presença de água é o principal condicionante no comportamento espectral. Três picos de absorção estão localizados nos comprimentos de onda de 1,45; 1,95 e 2,7 μm . O último é o maior pico de absorção, por isso a folha reflete muito pouco nesta região. Os dois primeiros picos, de menor intensidade, dão origem a uma região de relativa baixa absorvância e, por conseguinte, alta reflectância entre eles. A intensidade destes picos depende da umidade presente na folha; quando a umidade diminui, os picos de absorção também diminuem e a folha passa a refletir maior quantidade de energia incidente (Centeno, 2010).

A figura 2 mostra a curva de reflectância média da vegetação fotossinteticamente ativa na região óptica do espectro eletromagnético. Nesta figura, pode-se observar o comportamento típico da vegetação sadia.

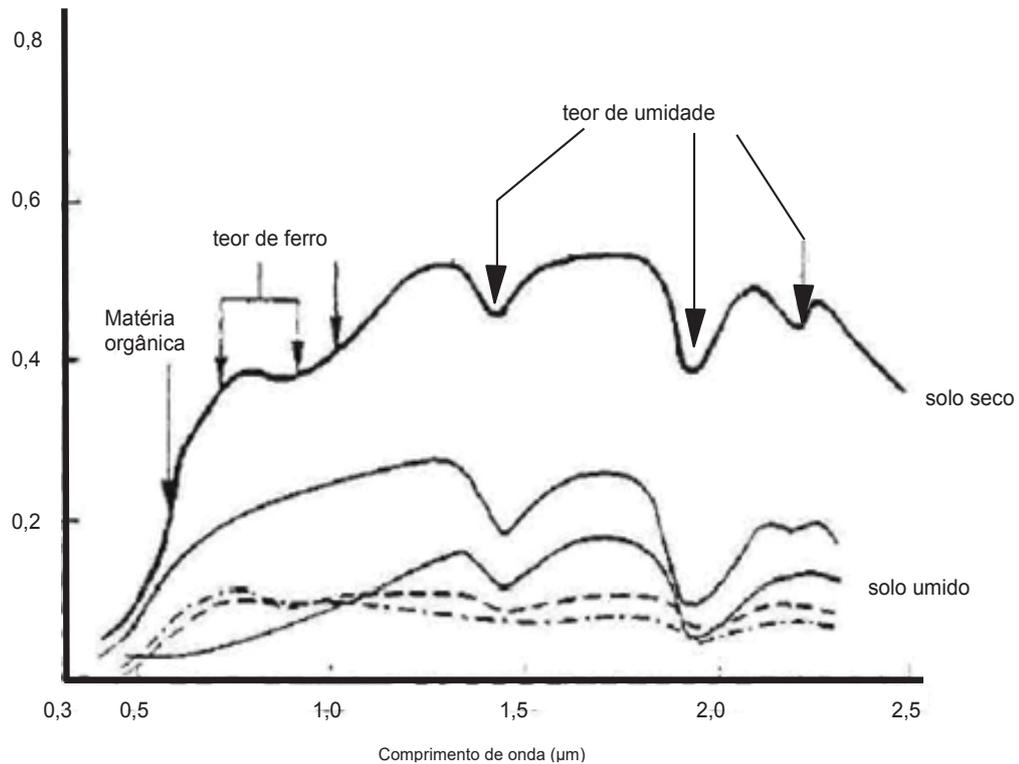
Quando a vegetação se encontra doente ou seca, a produção da clorofila diminui e a vegetação não absorve muita energia. Depois disto, a absorção de energia diminui e a vegetação passa a refletir também nas faixas do azul e vermelho, o que origina a cor amarelada da vegetação seca (Centeno, 2010).

2.1.2 Características espectrais do solo

O comportamento espectral da energia refletida e emitida pelo solo é em grande parte dependente dos constituintes biogeoquímicos (mineral e orgânico), das propriedades de espalhamento óptico-geométricas (tamanho da partícula, aspecto, rugosidade), e das condições de umidade da superfície do solo (Chuvienco, 2016 apud Ben-Dor et al., 2008; Lusch, 1989; Mulders, 1987).

A transmitância no solo não é possível devido ao conteúdo dos materiais do solo, por isto, toda a energia incidente é refletida ou absorvida. Mediante a Figura 3 se pode observar a tendência geral da curva dos solos, na qual verifica-se que nas regiões do visível e do infravermelho a reflectância é crescente com o comprimento de onda e, além disso, pode-se visualizar as características mais representativas dos materiais dos solos, que serão os principais condicionadores das características espectrais.

FIGURA 3 - CURVA DE REFLECTÂNCIA DOS SOLOS



FORNE: CENTENO (2010)

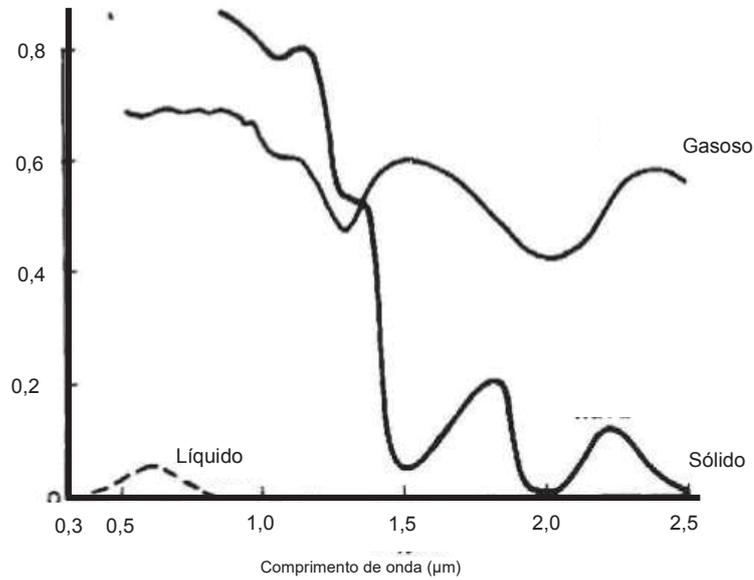
Segundo Lillesand et al. (2004), na região do visível o aumento da quantidade de água causa uma diminuição na reflectância, que explica o fato dos solos drenarem ao serem molhados. Nas regiões do infravermelho próximo e médio, a diminuição da reflectância com o aumento do conteúdo de água deve-se à alta absorção da radiação eletromagnética pela água nestes comprimentos de onda.

2.1.3 Características espectrais da água

O comportamento espectral da água tem relação com o seu estado físico (sólido, líquido ou gasoso) já que apresenta diferentes características para cada um deles (Figura 4).

A água, no estado líquido, apresenta baixa reflectância no intervalo compreendido entre 0,38 e 0,7 μm do espectro visível, absorvendo toda a radiação em comprimentos de onda superiores a 0,7 μm . No estado gasoso, a água apresenta altíssima reflectância no intervalo de 0,38 a 2,5 μm , com bandas de absorção amplas em torno de 1,0, 1,3 e 2 μm . No estado sólido a água apresenta elevada reflectância no intervalo compreendido entre 0,7 e 1,2 μm . (Novo, 2010).

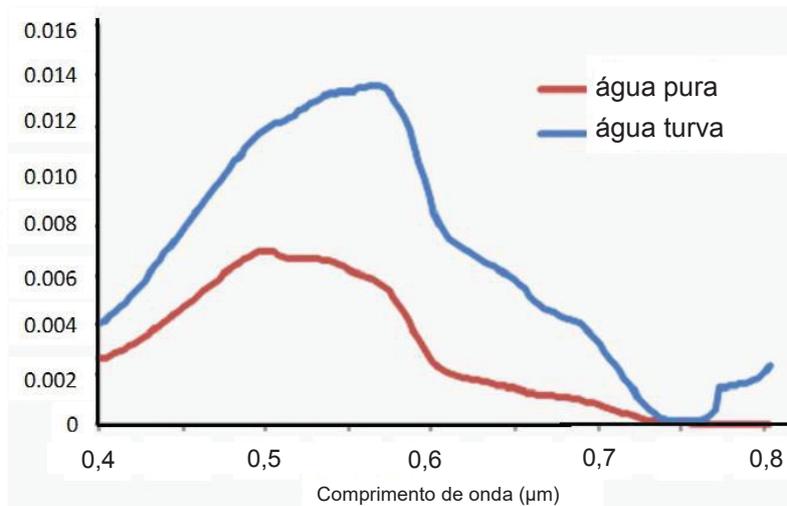
FIGURA 4 - COMPORTAMENTO ESPECTRAL DA ÁGUA EM SEUS DIFERENTES ESTADOS FÍSICOS



FONTE: NOVO (2010)

Os fatores que alteram a resposta espectral da água estão relacionados principalmente pelos processos de absorção e espalhamento produzidos pelos sedimentos em suspensão, pigmentos fotossintetizantes e substâncias que contenham matéria orgânica. A Figura 5 mostra uma comparação entre a reflectância da água pura e água com sedimentos (água turva).

FIGURA 5 - COMPARAÇÃO DA REFLECTÂNCIA DA ÁGUA PURA E TURVA

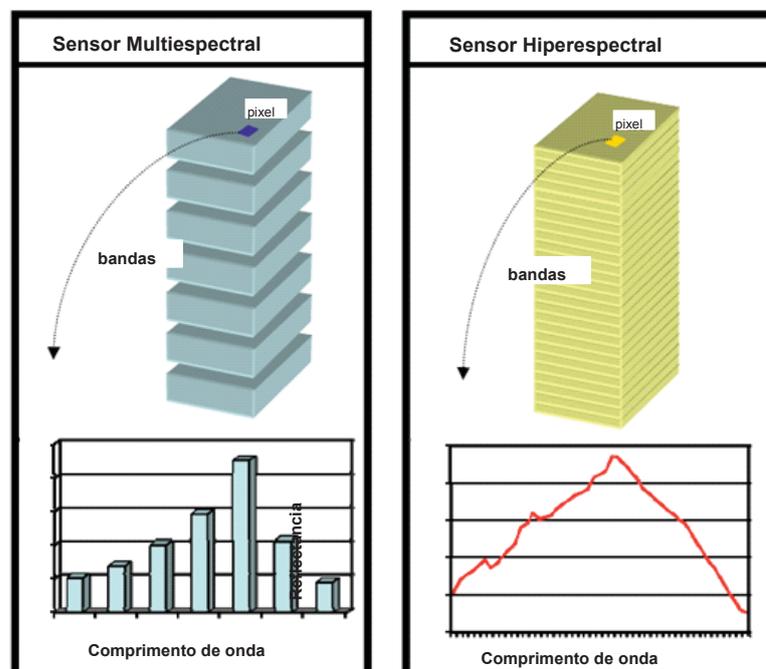


FONTE: ADAPTADO DE LOISEL ET AL. (2013).

2.2 SENSORIAMENTO REMOTO HIPERESPECTRAL

Na década passada, a obtenção das imagens da Terra por sensoriamento remoto orbital foi baseada em dados multiespectrais. Os sensores multiespectrais, além de conterem um número reduzido de bandas espectrais dentro da região do visível e do infravermelho médio do espectro eletromagnético, possuem largura de banda entre 0,1 e 0,2 μm que generalizam a resposta espectral das classes e descartam informações importantes para a detecção (Foster e Townsend, 2004). Entretanto, o sistema de sensores hiperespectrais ganha grande atenção para os pesquisadores, na atualidade. Os sensores hiperespectrais operam a partir do visível até o infravermelho médio em diferentes comprimentos de onda e capturam simultaneamente a resposta do alvo em centenas de bandas espectrais com largura de banda da ordem de 10 nm, para a mesma área na superfície da Terra (Ghamisi, 2015). A Figura 6 apresenta uma comparação espectral entre os sensores multiespectrais e hiperespectrais.

FIGURA 6 - COMPARAÇÃO ESPECTRAL ENTRE SENSORES MULTIESPECTRAIS E HIPERESPECTRAIS



FONTE: ADAPTADO DE SOUZA, SANCHEZ E CRUZ (2012)

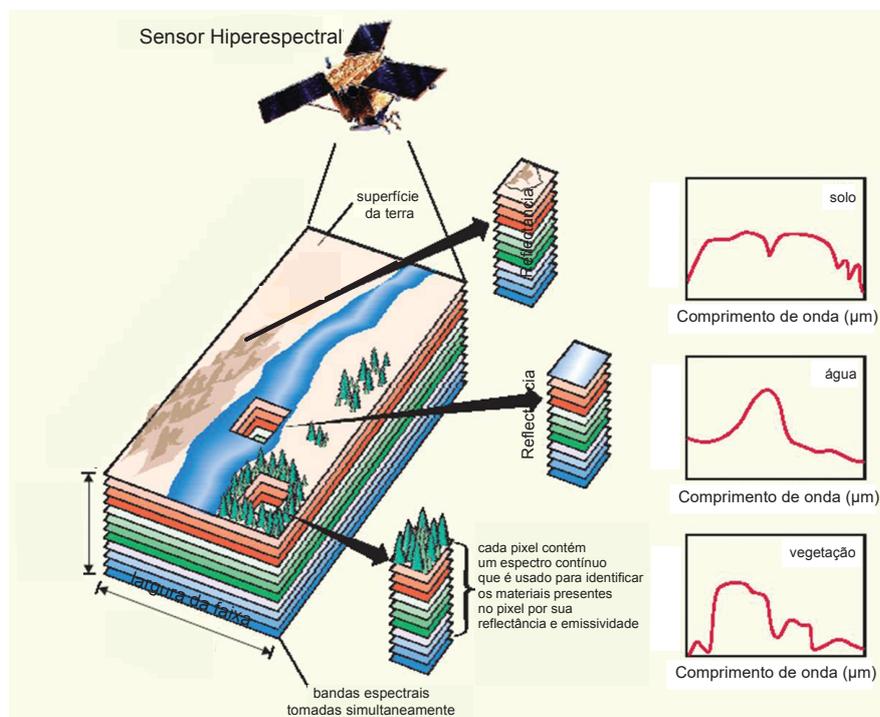
Mediante as imagens hiperespectrais podem-se discriminar os diferentes tipos de cobertura terrestre que possuem características espectrais e componentes

estruturais complexos (Foster e Townsend, 2004).

Os sensores multiespectrais ou hiperespectrais registram dados em pixels que são representados por vetores com seu respectivo comprimento de onda. Mas nos sensores hiperespectrais, cada pixel contém valores de reflectância para um espectro contínuo (intervalo nulo entre bandas consecutivas) o que facilita a identificação baseada nas propriedades de reflectância dos alvos.

Na Figura 7, pode-se visualizar o conceito da imagem hiperespectral. Nos sensores hiperespectrais, a informação espectral detalhada aumenta a possibilidade de discriminar classes ou objetos de interesse com acurácia na classificação em uma área ou cena (Benediktsson e Ghamisi, 2015).

FIGURA 7 - ILUSTRAÇÃO DO CONCEITO DA IMAGEM HIPERESPECTRAL



FONTE: ADAPTADO DE CIZNICKI, KUROWSKI, PLAZA. (2012).

Muitos sensores hiperespectrais operacionais (Tabela 1) estão oferecendo um grande volume de imagens para várias aplicações em áreas do conhecimento (Benediktsson e Ghamisi, 2015), tais como:

- **Ecologia:** aplicações em biomassa e estimação da biodiversidade em zonas densas das florestas que podem ser utilizadas para estudos de mudanças da cobertura da terra.

- **Geologia e Mineralogia:** estudos e análise das propriedades físicas e químicas dos minerais, identificação de minerais e estudos baseados no efeito de fugas de gás e petróleo dos oleodutos.
- **Hidrologia:** para determinar as mudanças em zonas úmidas, além disso, estudos da qualidade da água, ambientes estuarinos e zonas costeiras.
- **Agricultura de precisão:** na classificação de áreas agrícolas, para extrair conteúdo de nitrogênio, detecção de stress da vegetação, detecção de pragas e doenças para fins de agricultura de precisão.
- **Militar:** A informação espectral-espacial de dados hiperespectrais podem ser usados para detecção de alvos.

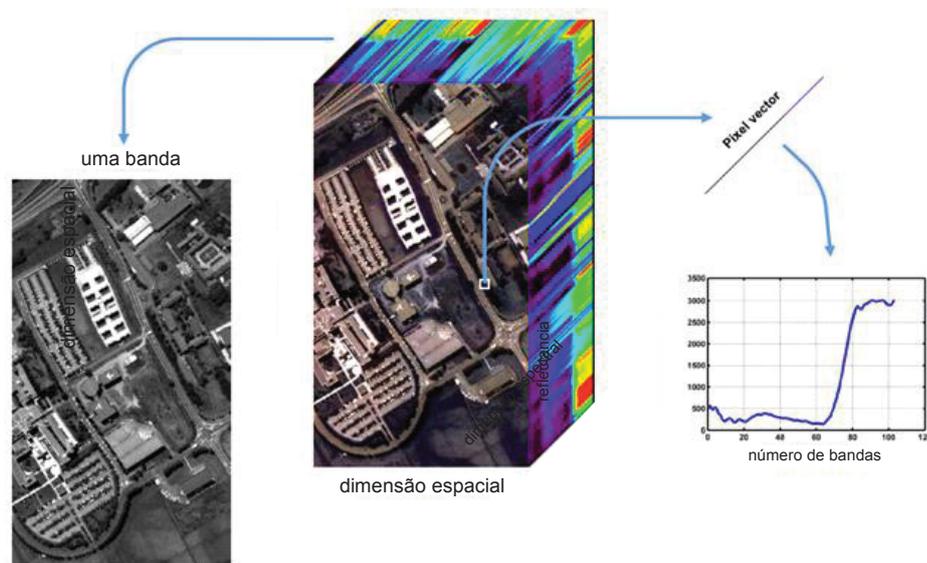
TABELA 1 - SENSORES HIPERESPECTRAIS ORBITAIS E AEROTRANSPORTADOS

SENSOR	PLATAFORMA	ANO	PAIS OU INSTITUIÇÃO	RESOLUÇÃO			INTERVALO ESPECTRAL
				ESPECTRAL	ESPACIAL	RADIOM	
AVIRIS	Aerotransportado	1987	NASA/JPL	224 bandas	4 - 20 m	12-bit	370-2500 nm
DAIS7915	Aerotransportado	1994	Ger. Corp.	79 bandas	3 - 20 m	15-bit	400-12500 nm
HYDICE	Aerotransportado	1995	EUA	210 bandas	1 - 4 m	12-bit	400-2500 nm
HyMAP	Aerotransportado	1996	Australia	126 bandas	2 - 10 m	12 -16 bit	450-2500 nm
HYPERION	Orbital	2000	NASA USGS	242 bandas	30 m	12-bit	400-2500 nm
CRIS Proba	Orbital	2001	ESA	62 bandas	20 - 37 m	-----	400-1050 nm
HySI	Orbital	2008	India	64 bandas	506 m	11-bit	400 -950 nm
HICO	Orbital	2009	ONR/NASA	128 bandas	90 m	8-16-32 bit	353-1080 nm
HERO	Orbital	2010	Canadá	aprox 250 bandas	30 m	12-bit	400-2500 nm
PRISMA	Orbital	2015	Italia	aprox 250 bandas	20 - 30 m	12-bit	400-2500 nm
EnMAP	Orbital	2018 previsão	Alemanha	218 bandas	30 m	14-bit	420-2450 nm
HYPXIM CA	Orbital	2019 previsão	França	> 200 bandas	15 m	-----	400-2500 nm

.FONTE: ADAPTADO DE LINN (2008).

Como mencionado anteriormente, as imagens hiperespectrais são consideradas como um conjunto de imagens com intervalo de comprimento de onda diferente (bandas espectrais contínuas) da mesma cena na superfície da terra. Baseados nesta interpretação, as imagens hiperespectrais podem ser referidas como a continuidade espectral que dá a idéia de um cubo. Assim, cada banda espectral representa uma imagem e todas as bandas espectrais geram um cubo hiperespectral tridimensional. A Figura 8 mostra um exemplo de cubo de dados hiperespectral que consiste em $n1 \times n2 \times d$, onde $n1 \times n2$ representa o número de pixels em cada banda espectral e d representa o número de bandas espectrais.

FIGURA 8 - EXEMPLO DE DADOS HIPERESPECTRAIS



FONTE: ADAPTADO DE BENEDIKTSSON E GHAMISI (2015).

2.2.1 O Sistema Sensor AVIRIS

Um dos primeiros sensores hiperespectrais aerotransportados foi o sensor AVIRIS que continua operando e vem sendo aperfeiçoado pela National Aeronautics and Space Administration (NASA/JPL). Este sensor é o único sensor óptico que fornece imagens calibradas da radiância espectral. Possui 224 bandas espectrais contínuas que permitem a obtenção de assinaturas espectrais contínuas e detalhadas para cada "pixel" em uma cena, com largura média das bandas em torno

de 10 nm com comprimentos de onda compreendidos entre 0,4 e 2,5 μm do espectro eletromagnético.

O AVIRIS possui o ângulo de visão instantâneo, *Instantaneous Field Of View* (IFOV) de 1 mrad e campo de visão conhecido como FOV (*Field Of View*) de 30°. As imagens obtidas a partir de espelhos de varredura com uma largura de faixa de 10,5 km neste sistema definem uma linha de 614 pixels de largura perpendicular à direção de voo, que caracteriza a extensão da imagem (Vane et al., 1993).

O sistema óptico do sensor AVIRIS está composto por quatro espectrômetros que são conectados através de fibra óptica. Para o funcionamento do sensor AVIRIS precisa-se de detectores de linha, os quais facilitam a varredura no modo whisk-broom. Para a leitura da porção do espectro eletromagnético do visível e do infravermelho próximo é necessário quatro detectores, sendo dois para cada faixa.

Na Tabela 2 estão resumidas as principais características relacionadas ao sensor hiperespectral AVIRIS.

TABELA 2 - CARACTERÍSTICAS DO SENSOR HIPERESPECTRAL AVIRIS

Parâmetros	Sensor AVIRIS
Aeronave	ER-2
Altitude de voo	20 km
Intervalo espectral	0,4 - 2,5 μm
Resolução espacial	20 m
Número de bandas espectrais	224
Largura das bandas	10 nm
Largura de faixa	10,5 km
IFOV	1 mrad
FOV	30°
Tipo de scanner	whisk-broom
Velocidade de varredura	12 varreduras / s

FONTE: ADAPTADO DE VANE ET AL.(1993)

2.3 CLASSIFICAÇÃO DIGITAL DAS IMAGENS

A finalidade da classificação de uma imagem é agrupar os pixels que têm propriedades semelhantes em um conjunto finito de classes ou tipos de cobertura da

terra (Lillesand et al., 2004 e Liang et al., 2012). Assim, as técnicas de classificação digital de imagens são as encarregadas de automatizar o processo de extração de informações das imagens reduzindo o esforço de trabalho do analista. Como resultado final de uma classificação obtém-se uma imagem digital que representa um mapa temático com pixels classificados, representando as classes de cobertura da terra de uma cena.

Diferentes técnicas de classificação são usadas para agrupar as classes extraídas das imagens com características espectrais similares. Segundo o grau de intervenção do analista, a classificação pode ser supervisionada e não supervisionada. Tendo em vista o uso da classificação supervisionada neste trabalho detalha-se, a seguir, somente este tipo de classificação.

2.3.1 Classificação Supervisionada

Na classificação supervisionada, o analista supervisiona e controla o processo de categorização dos pixels da imagem. Para isto, o analista precisa definir amostras representativas que permitam distinguir as classes umas das outras em função de parâmetros estatísticos (média e variância, entre outros). Uma vez definidas as classes de interesse e calculados os parâmetros estatísticos destas classes, os pixels da imagem são classificados. As técnicas de classificação supervisionadas desempenham um papel fundamental na análise de imagens hiperespectrais. Existem várias aplicações que permitem a utilização desta abordagem como: mapeamento do uso e cobertura da terra, monitoramento de colheitas, aplicações florestais, desenvolvimento urbano, mapeamento, rastreamento e gestão de riscos.

2.3.1.1 Máxima Verossimilhança

Esta abordagem é uma das técnicas de classificação supervisionadas mais empregadas no sensoriamento remoto e foi o primeiro algoritmo rigoroso a ser amplamente utilizado. Segundo Lillesand et al. (2004), o algoritmo de máxima verossimilhança avalia quantitativamente tanto a variância quanto a covariância dos valores digitais representados pelos valores de brilho dos pixels adquiridos como dados de treinamento de cada classe, no momento de classificar um pixel

desconhecido. Para fazer isso, assume-se que a distribuição de um conjunto de pontos (números digitais) que formam a categoria das amostras de treinamento é Gaussiana (distribuição normal).

Segundo Meneses e Almeida (2012), o algoritmo máxima verossimilhança é um classificador eficiente porque as classes de treinamento são utilizadas para estimar a forma da distribuição dos pixels contidos em cada classe no espaço de n bandas, como também a localização do centro de cada classe.

Para aplicar o algoritmo de máxima verossimilhança no mapeamento temático é necessário conhecer as medias e as matrizes de covariância de cada uma das classes de interesse. Assim, mediante este algoritmo, o analista “ensina” por meio das amostras de treinamento (pixels protótipo) o reconhecimento das características espectrais de cada classe. Com este reconhecimento, cada pixel da imagem será classificado e pertencerá à classe com semelhantes respostas espectrais.

Na classificação de máxima verossimilhança, cada pixel é destinado à classe que tem a mais alta probabilidade, isto significa que para um pixel que se encontra na posição \vec{x} do espaço de n bandas, um conjunto de probabilidades são computadas, e que dão as possibilidades relativas do pixel pertencer a cada classe disponível $p(\vec{x} | \omega_i)$ (Richards, 2013). A classificação de um pixel na posição \vec{x} é realizada de acordo com a seguinte regra de decisão:

$$x \in \omega_i \text{ se } p(\vec{x} | \omega_i) p(\omega_i) > p(\vec{x} | \omega_j) p(\omega_j) \text{ para todos } j \neq i \quad (1)$$

onde a probabilidade $p(\vec{x} | \omega_i)$ dá a possibilidade de \vec{x} pertencer à classe estimada ω_i ; $p(\vec{x} | \omega_i)$ são probabilidades a posteriori; e $p(\omega_i)$ é a probabilidade que o pixel da classe ω_i apareça em qualquer lugar na imagem (conhecida das áreas de treinamento); $p(\omega_i)$ são referidas como as probabilidades a priori.

2.4 ANÁLISE DE SEPARABILIDADE ENTRE CLASSES

Segundo Richards (2013), para avaliar se uma banda é importante na discriminação entre pares de classes espectrais deve-se examinar quanto essas classes espectrais se sobrepõem com a banda avaliada. Assim, a sobreposição

deve ser evitada para que as classes sejam separáveis. Além disso, é útil examinar e sugerir que algumas bandas sejam descartadas em função do grau de sobreposição das classes espectrais, antes da classificação da imagem completa.

A análise de separabilidade entre classes pode ser realizada a partir das áreas de treinamento, para estimar o erro esperado na classificação de várias combinações de bandas (Landgrebe, 2003 apud Swain e Davis, 1978).

Na literatura são propostas várias medidas de distancia multiespectral para analisar a separabilidade entre classes espectrais como: distância de Bhattacharya, distância de Mahalanobis, divergência, divergência transformada, entre outros.

2.4.1 Divergência

Segundo Richards (2013), a Divergência é uma medida de separabilidade de um par de distribuições de probabilidades que tem sua base no grau de sobreposição. Esta abordagem usa a definição da razão de verossimilhança.

$$L_{ij}(x) = p(\vec{x} | \omega_i) / p(\vec{x} | \omega_j) \quad (2)$$

em que $p(\vec{x} | \omega_i)$ e $p(\vec{x} | \omega_j)$ são os valores i -ésimo e j -ésimo das distribuições de probabilidades das classes na posição (\vec{x}) no domínio espectral.

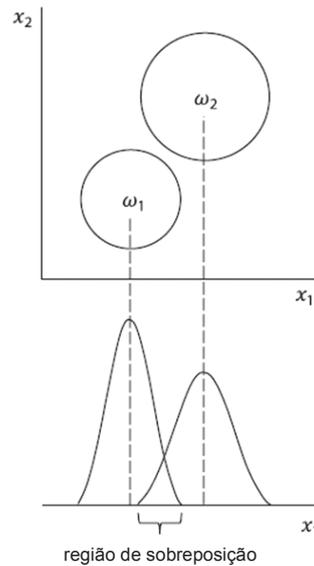
As Figuras 9 e 10 permitem visualizar a região de superposição em um espaço espectral bidimensional, com duas classes espectrais e as probabilidades usadas na definição da razão de verossimilhança.

Mediante a expressão 3 determina-se o valor da medida da divergência em função dos vetores da média e das matrizes de covariância.

$$D_{ij} = \frac{1}{2} \text{tr} [(V_i - V_j)(V_i^{-1} - V_j^{-1})] + \frac{1}{2} \text{tr} [(V_i^{-1} - V_j^{-1})(M_i - M_j)(M_i - M_j)^T] \quad (3)$$

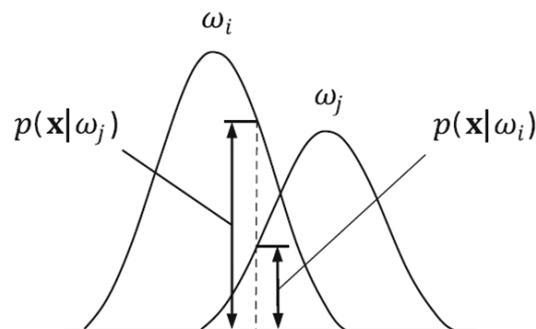
onde D_{ij} é a medida da divergência entre as classes i e j , tr é o traço da matriz resultante do produto entre colchetes, V_i e V_j são as matrizes de covariâncias das amostras nas classes i e j , e M_i e M_j são os vetores das médias das amostras nas classes i e j .

FIGURA 9 - REGIÃO DE SOBREPOSIÇÃO EM UM ESPAÇO ESPECTRAL 2D



FONTE: ADAPTADO RICHARDS (2013)

FIGURA 10 - DEFINIÇÃO DA RAZÃO DE VEROSSIMILHANÇA



FONTE: ADAPTADO RICHARDS (2013)

Para este trabalho se utilizará o método de divergência transformada, devido à simplicidade do método, fundamentado em critérios quantitativos baseados na relação de probabilidades, com pequena exigência computacional (Chuvieco, 1990 apud Swain e Davis, 1978).

2.4.2 Divergência Transformada

Segundo Chuvieco (1990) e Richards (2013), o método de divergência transformada é uma útil modificação do método de divergência, de modo que é uma forma de obter a divergência para uma escala determinada.

Em função da expressão 3 pode-se determinar a medida da divergência transformada (ver expressão 4).

$$D_{ij}^T = C(1 - e^{-D_{ij}/8}) \quad (4)$$

onde D_{ij}^T é o valor da divergência transformada entre as classes i e j ; C indica o valor máximo da divergência, que normalmente leva o valor de $C = 2$ (Richards, 2013) e D_{ij} é o valor da divergência entre as classes i e j proveniente da expressão 3.

O valor de C é discutido por vários autores. Segundo Chuvieco (1990), alguns autores recomendam o valor de $C = 2000$ (Haack, 1987), para outros $C = 100$ para que seja interpretado em valores de porcentagem (Mather, 1998).

Quanto maior for o valor da divergência transformada (mais próximo de C), maior será a separabilidade entre pares de classes.

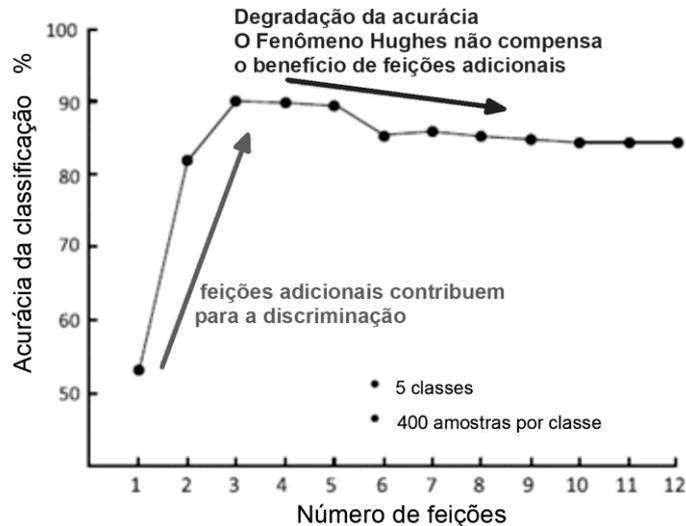
2.5 REDUÇÃO DE DIMENSIONALIDADE

A dimensionalidade dos dados nas imagens hiperespectrais é muito alta devido ao número de bandas espectrais. Por meio das imagens hiperespectrais é possível coletar centenas de bandas espectrais da mesma cena para análise de diferentes objetos de interesse. No domínio espectral, cada pixel está representado por um ponto e cada banda é considerada como uma dimensão no espaço de atributos. Nas imagens hiperespectrais, o aumento das bandas é capaz de melhorar significativamente a identificação da informação dos alvos na superfície terrestre, mas constitui um desafio na análise rigorosa dos dados hiperespectrais para as técnicas convencionais (Benediktsson e Ghamisi, 2015).

Porém, o aumento da acurácia da classificação não é proporcional ao incremento de bandas. Ele cresce inicialmente até um ponto máximo, a partir do qual a inclusão de novas bandas não traz maiores contribuições, pelo contrário, a partir desse ponto a acurácia diminui. Este problema é conhecido como fenômeno de Hughes (Hughes, 1968), e ocorre pelo limitado número de amostras de treinamento frente à alta dimensionalidade da imagem. Isto demonstra que existe um número ideal de bandas para a acurácia na classificação da cobertura da terra, e mais recursos não acarretam necessariamente melhores resultados. Portanto, o uso

de técnicas de redução de atributos pode conduzir a melhoras na acurácia na classificação (Benediktsson e Ghamisi, 2015) (Figura 11).

FIGURA 11 - REPRESENTAÇÃO TÍPICA DO FENÔMENO DE HUGHES



FONTE: ADAPTADO DE RICHARDS (2013)

Este fenômeno, junto com as limitações impostas pelo custo computacional para a classificação, gerou o interesse por técnicas para redução das bandas usadas na classificação digital. Segundo Serpico et al. (2003), existem duas abordagens para a redução de dimensionalidade: a) a seleção de atributos ou seleção do subconjunto mais relevante de bandas; e b) a extração de atributos, baseada na transformação ou combinação das variáveis do conjunto original. Devido ao uso de extração de atributos para redução de dimensionalidade neste trabalho, em seguida se detalha este tipo de redução.

2.5.1 Extração de atributos

Segundo Serpico et al. (2003), o objetivo principal da técnica de extração de atributos é reduzir a dimensionalidade dos dados minimizando a perda de informações, por meio de uma transformação apropriada das bandas espectrais originais. Essa abordagem consiste em encontrar um conjunto de novas imagens, com preservação de atributos de interesse, em um espaço dimensional inferior. Por exemplo, no reconhecimento de padrões, é desejável extrair os atributos essenciais para a discriminação entre as classes analisadas. Embora a redução da

dimensionalidade seja importante, a lacuna na informação, originada pela redução da dimensão, tem que ser tal que não sacrifique o poder discriminativo dos classificadores (Benediktsson e Ghamisi, 2015).

Diversos trabalhos podem ser incluídos na extração de atributos. Zhang et al. (2013) propuseram um método para a redução da dimensionalidade para atributos espectrais-espaciais em imagens hiperespectrais baseado na álgebra multilinear ou álgebra de tensores por pixel para remover informações redundantes e sua posterior classificação. Liao et al. (2013) apresentaram um novo método de análise de discriminante local semi-supervisionado para extração de atributos em imagens hiperespectrais. Este método combina o método não supervisionado (extração de atributos lineares locais) e o método supervisionado (análise discriminante linear) em uma nova estrutura sem parâmetros livres. Ren et al. (2014) aplicaram o método de Componentes Principais modificado para reduzir a dimensionalidade. Este método consiste em empregar elementos estruturados localmente, que aparecem somente em um pequeno número das bandas, para melhorar a discriminação das bandas que vão ser extraídas. Zhong et al. (2015) propuseram um método de extração de atributos integrando a informação espectral-espacial e incorporando a análise de um tensor discriminante (escalar, vetorial ou matricial) para melhorar a classificação de imagens hiperespectrais.

Existem vários métodos de extração de atributos para redução de dimensionalidade que se podem encontrar na literatura. Entre os mais conhecidos está o método de Análise de Componentes Principais, e outro menos conhecido como o método de Codificação Binária.

2.5.1.1 Algoritmo de Codificação Binária

Uma opção para a extração de atributos é a codificação binária (Mazer et al. 1988, Jia e Richards 1993). Essa abordagem é conhecida como um algoritmo de análise eficaz e com pequena carga computacional para a classificação (Xie et al., 2011 apud Mazer et al., 1988). Como descreve Schowengerdt (2007), na codificação binária espectral o valor digital (ND) do pixel em cada banda espectral será representado por um estado binário (0 ou 1), como função de um limiar. Usando um critério de binarização, o valor digital de um pixel em cada imagem pode

ser tratado como um bit. A combinação de vários bits permite gerar novos valores e codificar o conjunto de leituras em todas as bandas espectrais.

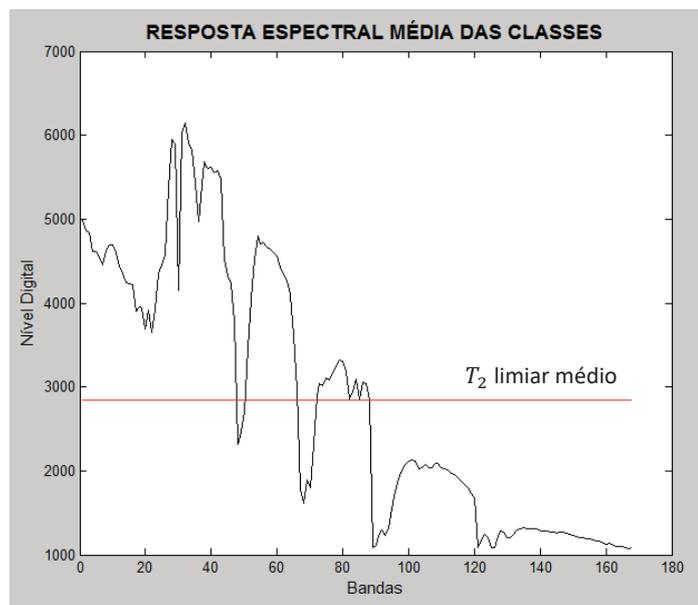
Jia e Richards (1993) apresentam uma forma de determinar automaticamente um ou vários limiares (inferior, médio e superior) para imagens hiperespectrais. Essa abordagem permite codificar cada pixel de cada banda em um ou dois bits, baseado nos limiares.

A regra de codificação binária mais geral consiste em separar os valores digitais de uma imagem em dois grupos, um abaixo e outro acima de um limiar pré-estabelecido (T), conforme descreve a expressão 5.

$$\begin{aligned} h(n) &= 0 \text{ se } x(n) \leq T \\ &= 1 \text{ se } x(n) > T \end{aligned} \quad (5)$$

Na equação 5, $x(n)$ é o valor de brilho de um pixel em uma determinada banda, T é o limiar especificado pelo usuário para a formação do código binário, e $h(n)$ é o símbolo de código binário resultante para o pixel na banda espectral de ordem n . Normalmente, T é escolhido como o valor digital médio de todas as respostas espectrais das classes identificadas na imagem (Figura 12). Tal processo de codificação binária irá produzir um pixel vetor de igual tamanho em bits à quantidade original das bandas espectrais.

FIGURA 12 - RESPOSTA ESPECTRAL MÈDIA DAS CLASSES QUE MOSTRA A FORMAÇÃO DE UM CÓDIGO BINÁRIO BASEADO EM UM LIMIAIR

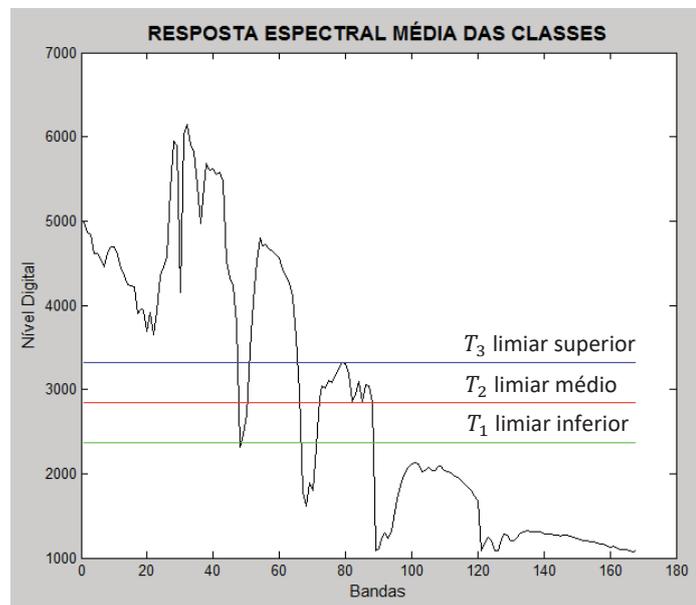


FONTE: ELABORAÇÃO DO AUTOR

Outra forma da codificação binária envolve o uso de três limiares. Para escolher os limiares determina-se o brilho médio (limiar médio) como descrito acima e, a partir deste, obtém-se os limiares inferior e superior. Dessa forma, consegue-se três limiares (inferior, médio e superior) e conseqüentemente 4 regiões (ver Figura 13). Esta codificação divide os possíveis valores em quatro regiões e por isso utiliza dois bits (00, 01, 10, 11). Assim cada pixel será representado mediante a expressão 6:

$$\begin{aligned}
 h(n) &= 00 \text{ se } x(n) \leq T_1 \\
 &= 01 \text{ se } T_1 < x(n) \leq T_2 \\
 &= 10 \text{ se } T_2 < x(n) \leq T_3 \\
 &= 11 \text{ se } x(n) > T_3
 \end{aligned}
 \tag{6}$$

FIGURA 13 - RESPOSTA ESPECTRAL MÉDIA DAS CLASSES QUE MOSTRA A FORMAÇÃO DE UM CÓDIGO BINÁRIO BASEADO EM TRÊS LIMIARES (INFERIOR, MÉDIO E SUPERIOR)



FONTE: ELABORAÇÃO DO AUTOR

2.6 VALIDAÇÃO DA QUALIDADE

Após a classificação de qualquer imagem se faz necessário a avaliação dos resultados obtidos, a fim de verificar se os objetivos da análise das imagens foram alcançados.

Desta forma, a avaliação consiste em conhecer a confiabilidade e a qualidade da classificação de imagens ou mapas temáticos. A avaliação da acurácia da classificação de imagens é um procedimento complexo e recebe uma atenção significativa na área de sensoriamento remoto. As dificuldades em avaliar a acurácia da classificação surgem devido ao efeito significativo de fatores como: número de classes, complexidade do terreno, as resoluções espaciais e espectrais do sistema sensor, o próprio algoritmo de classificação, a legenda utilizada no processo de classificação, o conjunto de dados que representa a verdade terrestre e as classes que podem ser confundidas uma com a outra (Meneses e Almeida, 2012).

2.6.1 Matriz de Erros

A acurácia é normalmente expressa em termos de índices que são calculados mediante as matrizes de confusão ou matrizes de erros. Elas determinam a concordância entre a imagem classificada e os dados de referência (verdade do campo). A tabela 3 representa um exemplo de matriz de confusão para um problema de classificação de cinco classes. O termo C_i representa a classe i (dados de referência) e o termo C_{ij} refere-se à quantidade de pixels da classe i que são designados erroneamente à classe j (dados classificados); N_c representa a quantidade de pixels das classes dos dados de referência; N representa a quantidade total de pixels (colunas ou linhas) distribuídos em todas as classes. Em um cenário ideal, onde todos os pixels são classificados corretamente, apenas a diagonal da matriz apresentará valores diferentes de zero. Para uma classificação ruim, os termos fora da diagonal serão maiores, indicando que o classificador teve problemas para classificar os pixels corretamente a partir dos dados de referência.

TABELA 3 - MATRIZ DE CONFUSÃO PARA UM PROBLEMA DE CLASSIFICAÇÃO DE 5 CLASSES

		Dados Classificados (j)					
Dados de referência (i)	Tipo de Classe	C_1	C_2	C_3	C_4	C_5	Soma parcial linha (i)
	C_1	C_{11}	C_{12}	C_{13}	C_{14}	C_{15}	$\sum_j^{N_c} C_{1j}$
	C_2	C_{21}	C_{22}	C_{23}	C_{24}	C_{25}	$\sum_j^{N_c} C_{2j}$
	C_3	C_{31}	C_{32}	C_{33}	C_{34}	C_{35}	$\sum_j^{N_c} C_{3j}$
	C_4	C_{41}	C_{42}	C_{43}	C_{44}	C_{45}	$\sum_j^{N_c} C_{4j}$
	C_5	C_{51}	C_{52}	C_{53}	C_{54}	C_{55}	$\sum_j^{N_c} C_{5j}$
	Soma parcial coluna (j)	$\sum_i^{N_c} C_{i1}$	$\sum_i^{N_c} C_{i2}$	$\sum_i^{N_c} C_{i3}$	$\sum_i^{N_c} C_{i4}$	$\sum_i^{N_c} C_{i5}$	N

FONTE: ADAPTADO DE BENEDIKTSSON E GHAMISI (2015).

Como resultado da classificação apresentam-se dois tipos de erros: de omissão (exclusão) e de comissão (inclusão) de cada classe. Os erros de omissão correspondem aos pixels pertencentes a uma determinada classe que o classificador não conseguiu reconhecer, ou seja, foram omitidos da classe. Estes erros podem ser avaliados para cada classe através da expressão 7:

$$E_{\text{omissão}(i)} = \frac{\sum_j^{N_c} C_{ij} - C_{ii}}{\sum_j^{N_c} C_{ij}} \quad (7)$$

onde $\sum_j^{N_c} C_{ij}$ é a soma parcial da linha (i); C_{ii} é o número de pixels corretos em uma classe.

Os erros de omissão estão referidos à acurácia do ponto de vista do produtor (dados de classificação). Quanto maior o valor do erro de omissão tanto

menor será a acurácia do produto. A acurácia do produtor é considerada como a percentagem de pixels corretamente classificados em cada classe. Este valor demonstra quão bem uma determinada classe foi classificada. Quanto maior for esta percentagem, maior será o êxito alcançado pelo produtor na classificação. Esta métrica é calculada dividindo o número de pixels corretos em uma classe pelo número total de pixels como dados de referência derivados da seguinte forma:

$$E_{\text{produtor}(i)} = \frac{C_{ii}}{\sum_j^{N_c} C_{ij}} * 100 \quad (8)$$

Os erros de comissão correspondem aos pixels que, sendo na realidade de uma classe, o classificador inclui em outra classe que não a correta. Estes erros podem ser calculados através da seguinte expressão:

$$E_{\text{comissão}(j)} = \frac{\sum_i^{N_c} C_{ji} - C_{ii}}{\sum_i^{N_c} C_{ji}} \quad (9)$$

onde $\sum_i^{N_c} C_{ji}$ é a soma parcial da coluna (j); C_{ii} é o número de pixels corretos em uma classe.

Quando um usuário está interessado em saber se um produto é confiável e se o total de pixels representados como uma determinada classe, em uma classificação, realmente corresponde a essa classe, é necessário determinar a acurácia do ponto de vista do usuário. Este conceito está relacionado com os erros de comissão; se os erros de comissão são poucos, então a classificação é confiável e pode ser calculado através da seguinte expressão:

$$E_{\text{usuário}(j)} = \frac{C_{ii}}{\sum_i^{N_c} C_{ji}} * 100 \quad (10)$$

2.6.2 O Coeficiente Kappa

O Coeficiente Kappa é uma medida estatística que se refere à concordância entre a classificação final e os dados de referência. A vantagem de kappa é que no cálculo do seu coeficiente incluem-se todos os elementos da matriz de erro (erros de comissão e omissão) e não somente os elementos da diagonal principal. Este coeficiente é bastante utilizado na avaliação dos resultados de classificação e varia

entre 0 (concordância nula) a 1 (concordância perfeita). O coeficiente kappa pode ser calculado pela seguinte expressão:

$$\kappa = \frac{N * \sum_i^{N_c} C_{ii} - \sum_{i,j}^{N_c} C_{ij} * C_{ji}}{N^2 * \sum_{i,j}^{N_c} C_{ij} * C_{ji}} \quad (11)$$

onde N representa a quantidade total de pixels em todas as classes, $\sum_j^{N_c} C_{ij}$ é a soma parcial da linha (i); C_{ii} é o número de pixels corretos em uma classe, $\sum_i^{N_c} C_{ji}$ é a soma parcial da coluna (i). Quanto maior seja o valor do coeficiente kappa, o resultado será considerado de melhor qualidade. Através da Tabela 4 mostra a relação entre o coeficiente kappa e o desempenho da classificação.

TABELA 4 - RELAÇÃO ENTRE O COEFICIENTE KAPPA E O DESEMPENHO DA CLASSIFICAÇÃO

Coeficiente kappa	Desempenho da classificação
< 0,00	péssimo
0,00 < κ ≤ 0,20	mau
0,20 < κ ≤ 0,40	razoável
0,40 < κ ≤ 0,60	bom
0,60 < κ ≤ 0,80	muito bom
0,80 < κ ≤ 1,00	excelente

FONTE: MOREIRA (2001).

3 MATERIAL E MÉTODOS

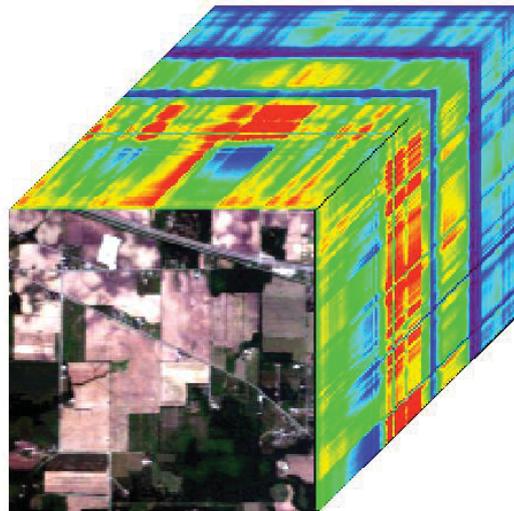
Para o desenvolvimento da metodologia foram utilizados os seguintes softwares: MATLAB, utilizado para desenvolver rotinas de programação para extração de atributos dos dados hiperespectrais, análise espectral, binarização, redução de dimensão baseado na codificação binária; MULTISPEC para Windows (disponibilizado pela Universidade Purdue e de acesso livre), para análise de separabilidade por divergência transformada e a classificação por máxima verossimilhança; ENVI, para visualização espectral da imagem hiperespectral AVIRIS.

3.1 DADOS EXPERIMENTAIS

Para a implementação da metodologia de redução de dimensionalidade, baseado na codificação binária para dados hiperespectrais, utilizou-se uma imagem do sensor AVIRIS (Airborne Visible/Infrared Imaging Spectrometer), obtidos no site do repositório de pesquisa da Universidade de Purdue. Esta imagem, denominada Indian Pines, cobre uma área agrícola localizada ao noroeste do Estado de Indiana nos Estados Unidos. (ver Figura 14). A região da área de estudo inclui campos agrícolas com características espectrais muito semelhantes entre si, fato que acarreta maior dificuldade à discriminação a partir de dados tradicionais em média ou baixa dimensionalidade. As dimensões espaciais desta imagem são 145 x 145 pixels e sua resolução espacial é de 20m por pixel. A imagem Indian Pines tem 224 bandas espectrais abrangendo a região do espectro eletromagnético entre 0.4 μm e 2.5 μm de comprimento de onda, isto é, desde a região do visível até o infravermelho. Além da imagem hiperespectral, se conta com informação da verdade de campo que pode ser vista na Figura 15. Esta informação permite uma análise acurada dos resultados obtidos dos processos de classificação.

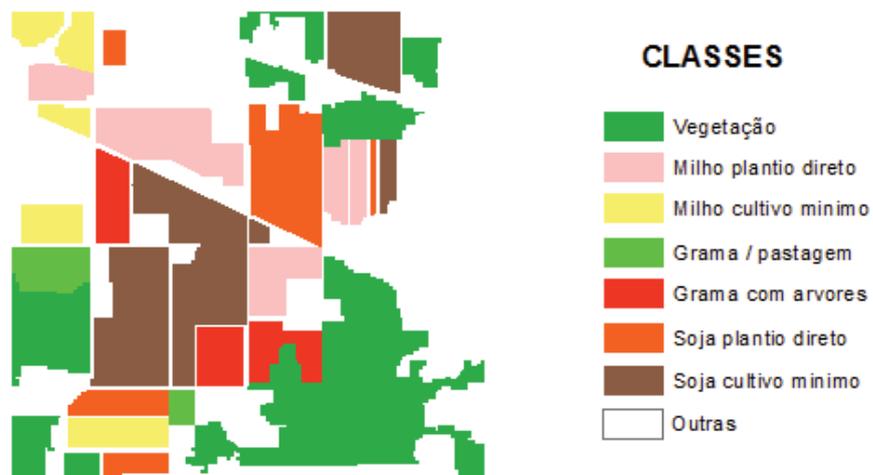
As quantidades de amostras utilizadas para a classificação e análise da qualidade podem ser vistas na Tabela 5. As amostras para cada classe foram extraídas mediante uma amostragem aleatória simples. Todas as amostras encontram-se bem distribuídas e cobrem toda a imagem AVIRIS utilizada neste trabalho.

FIGURA 14 - CUBO HIPERESPECTRAL DA IMAGEM INDIAN PINES DO SENSOR AVIRIS



FONTE: UNIVERSIDADE DE PURDUE

FIGURA 15 - VERDADE DE CAMPO DA IMAGEM INDIAN PINES



FONTE: UNIVERSIDADE DE PURDUE

TABELA 5 - NÚMERO DE PIXELS DE TREINAMENTO E TESTE PARA AS CLASSES DE ESTUDO

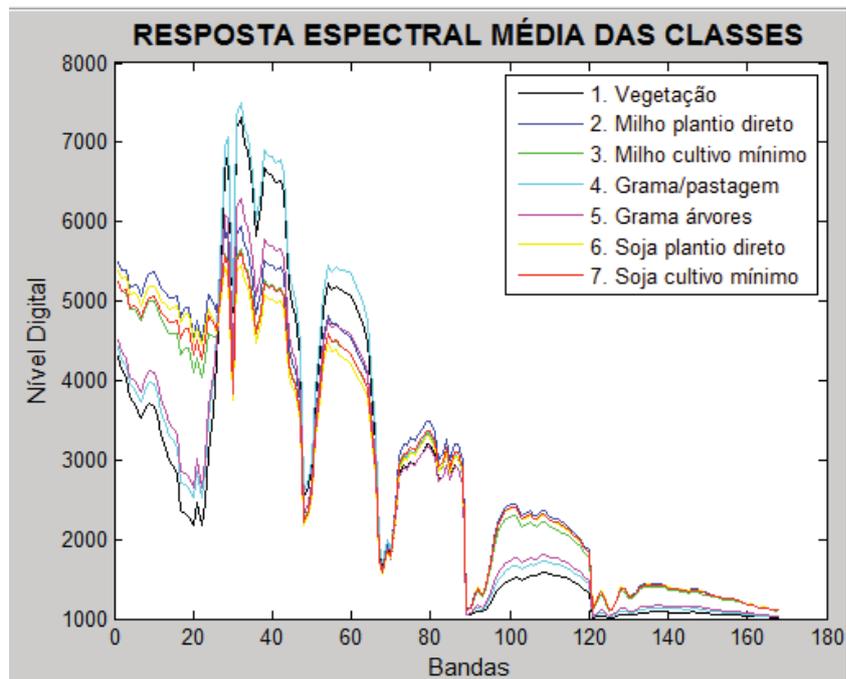
Classe	Treinamento	Verificação	Total
Vegetação	819	310	1129
Milho plantio direto	852	129	981
Milho cultivado mínimo	163	18	181
Grama / pastagem	447	42	489
Grama com arvores	751	61	812
Soja plantio direto	801	26	827
Soja cultivado mínimo	1796	167	1963

FONTE: ELABORAÇÃO DO AUTOR

Para este trabalho, as classes temáticas escolhidas foram baseadas nas características espectrais. Estas classes tem um comportamento espectral muito similar entre si, devido a que a área de estudo está em uma zona agrícola. Por essa razão, para sua identificação é preciso trabalhar com dados em alta dimensionalidade com os sensores hiperespectrais. As classes utilizadas para esta zona de estudo são: 1. Vegetação (VEG), 2. Milho plantio direto (MPD) (técnica de que não utiliza o revolvimento do solo para a plantação da cultura milho), 3. Milho cultivo mínimo (MCM) (técnica que revolve minimamente o solo para a plantação da cultura milho), 4. Grama/pastagem (GP), 5. Grama árvores (GA), 6. Soja plantio direto (SPD), 7. Soja cultivo mínimo (SCM).

A fim de visualizar o comportamento espectral de cada uma das classes de interesse foi elaborado um gráfico (ver Figura 16) que representa os valores digitais médios para todas as bandas utilizadas.

FIGURA 16 - REPRESENTAÇÃO ESPECTRAL DAS CLASSES

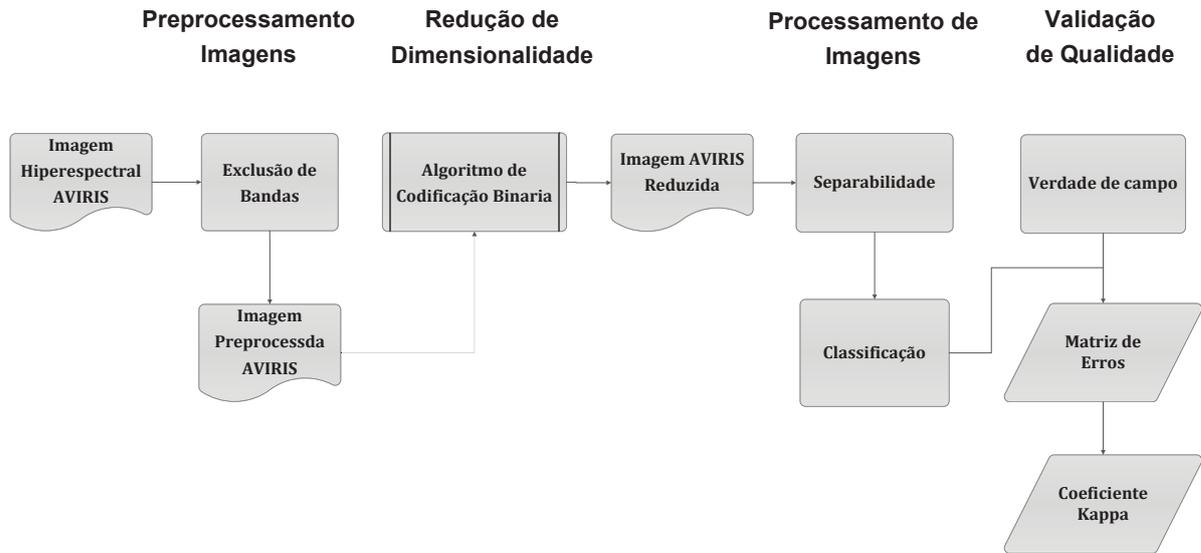


FONTE: ELABORAÇÃO DO AUTOR

3.2 METODOLOGIA

A Figura 17 resume as etapas de desenvolvimento da metodologia.

FIGURA 17 - ESQUEMA METODOLÓGICO DESTA TRABALHO



FONTE: ELABORAÇÃO DO AUTOR

A primeira etapa refere-se à exclusão de bandas da imagem hiperespectral AVIRIS. Nessa etapa excluem-se as bandas que têm forte interferência do vapor de água. Em seguida, executam-se os processamentos para a codificação binária para um e três limiares aplicados nas imagens hiperespectrais para a redução de dimensionalidade. Após, se realiza a análise de separabilidade e classificação das imagens e para finalizar tem-se a validação de qualidade conferida com a verdade de campo através da matriz de erros e o coeficiente kappa.

3.2.1 Exclusão de bandas

A imagem AVIRIS é composta por 224 bandas espectrais, mas inclui regiões do espectro com ruídos existentes em função da interferência do vapor de água da atmosfera. Este ruído pode causar inconvenientes no momento da análise e processamento dos dados. Por esse motivo, é necessário realizar uma fase preliminar de exclusão e eliminação das bandas ruidosas. A eliminação das bandas foi feita baseado na absorção dos constituintes atmosféricos, sendo assim, identificadas as bandas com ruído e aquelas menos perturbadas. As bandas que serão excluídas das análises são apresentadas na Tabela 6. Neste contexto, das 224 bandas que tem o sensor AVIRIS apenas 190 serão utilizadas para posteriores análises.

TABELA 6 - BANDAS RUIDOSAS ELIMINADAS SENSOR AVIRIS

Região	Intervalo espectral (μm)	Número bandas eliminadas	Identificação de bandas eliminadas
Visível	0,45 - 0,72	2	1, 2
Infravermelho Próximo	0,72 - 1,30	0	
Infravermelho Médio	1,38 - 2,45	32	103 - 110, 149 - 165, 218 - 224

FONTE: ELABORAÇÃO DO AUTOR

Nas Figuras 18 e 19 pode-se visualizar uma banda ruidosa pela interferência do vapor de água e uma imagem sem ruído, respectivamente.

FIGURA 18 - BANDA RUIDOSA SENSOR AVIRIS (BANDA 103)



FONTE: UNIVERSIDADE DE PURDUE

FIGURA 19 - BANDAS SEM RUÍDO SENSOR AVIRIS (BANDA 120)

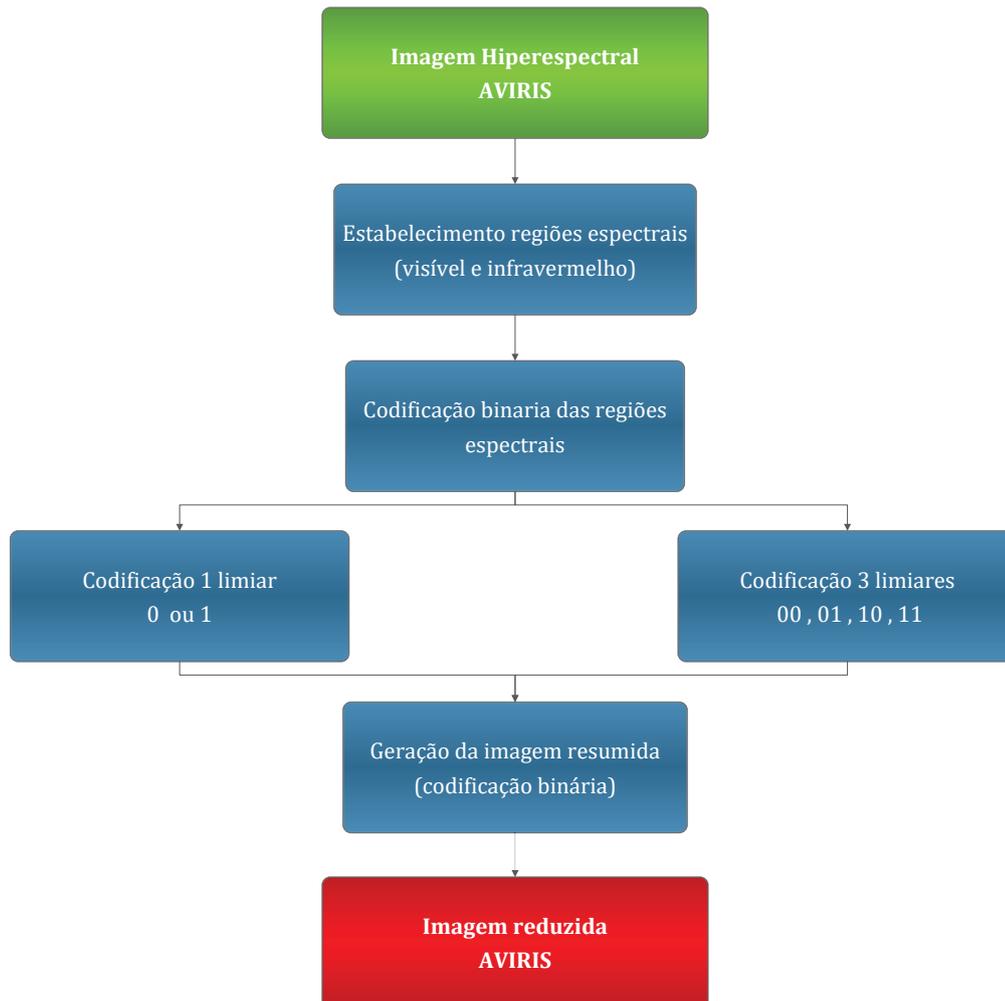


FONTE: UNIVERSIDADE DE PURDUE

3.2.2 Redução de dimensionalidade

Na Figura 20 pode-se visualizar a metodologia desenvolvida para reduzir a dimensionalidade dos dados hiperespectrais AVIRIS pelo algoritmo de Codificação Binária.

FIGURA 20 - ESQUEMA DE REDUÇÃO DE DIMENSIONALIDADE POR CODIFICAÇÃO BINÁRIA



FONTE: ELABORAÇÃO DO AUTOR

3.2.2.1 Estabelecimento de regiões espectrais

Esta abordagem consiste em agrupar todo o intervalo espectral segundo regiões, com a finalidade de envolver bandas vizinhas (comportamento similar). Todas as regiões empregaram a mesma quantidade de bandas: oito. Em seguida, fez-se a codificação binária de cada região separadamente baseado em um limiar médio ou três limiares (inferior, médio, superior).

Para realizar este procedimento utilizaram-se 168 bandas das 190 bandas obtidas no processo de exclusão de bandas. Para a seleção das 168 bandas analisou-se a sobreposição do visível (azul, verde e vermelho), infravermelho próximo e infravermelho médio.

No intervalo de comprimento de ondas referentes à cor azul dispunha-se de 12 bandas. Eliminou-se as 4 primeiras e compôs-se a primeira região. Para a cor verde procedeu-se de forma similar à da primeira região. Desta forma, das 12 bandas disponibilizadas na cor verde, apenas 8 bandas formaram a segunda região. No intervalo da cor vermelha havia apenas 8 bandas, com as quais formou-se a terceira região. Como existe um número maior de bandas na região do infravermelho médio e próximo, a agregação de bandas nestas regiões resultou em uma quantidade maior de imagens.

Na Tabela 7 são mostradas as 21 ($21 \times 8 = 168$ bandas) regiões espectrais obtidas a partir do espectro eletromagnético sensoriado pelo AVIRIS.

TABELA 7 - CRIAÇÃO DE IMAGENS AGREGADAS POR REGIÕES ESPECTRAIS

Região	Bandas	Imagens obtidas
Azul	8	1
Verde	8	1
Vermelho	8	1
Infravermelho próximo	8 x 8	8
Infravermelho médio	10 x 8	10

FONTE: ELABORAÇÃO DO AUTOR

3.2.2.2 Codificação Binária das regiões

Como resultado desta codificação binária, detalhada a seguir, obtém-se 21 regiões com um ou dois bits por pixel para cada banda da região, conforme o emprego de um ou três limiares respectivamente. Portanto, as bandas de cada região foram combinadas para gerar imagens de 8 ou 16 bits.

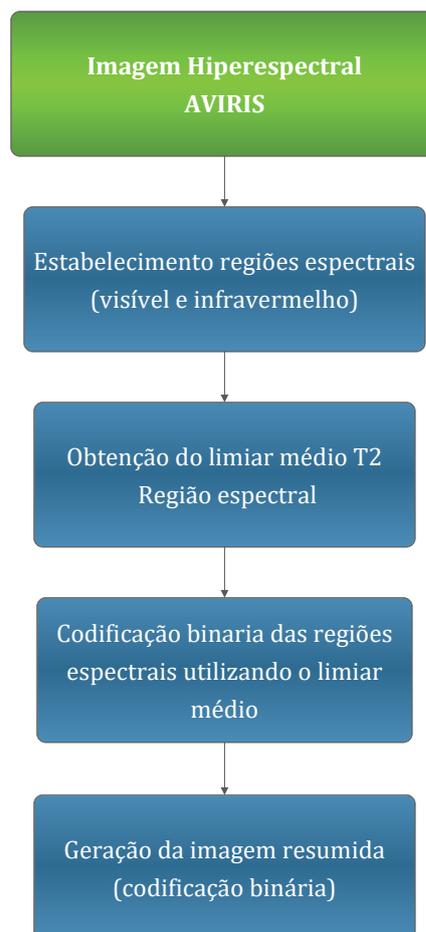
a) Codificação binária com um limiar

Uma das alternativas que utiliza a codificação binária na redução de dimensionalidade está baseada na codificação com um limiar. A metodologia para

esse experimento (ver Figura 21) seguiu os procedimentos que são detalhados a seguir:

- Obtenção do limiar médio T_2 baseado nas médias dos NDs originais de todas as classes de estudo (pixels de treinamento) para cada região espectral. Desta forma, ressalta-se que o limiar médio T_2 vai ser diferente para cada região espectral.
- Codificação binária, baseado no limiar médio T_2 , de cada banda da região espectral.
- Geração das imagens obtidas por codificação binária.

FIGURA 21 - ESQUEMA PARA CODIFICAÇÃO BINÁRIA (1 LIMIAR)



FONTE: ELABORAÇÃO DO AUTOR

b) Codificação binária com vários limiares

Baseado na metodologia utilizada por Jia e Richards (1993) determinou-se os valores do percentual do limiar P para a imagem hiperespectral do sensor AVIRIS. Desta forma, a seguir se apresenta os procedimentos para determinar os valores dos limiares: em primeiro lugar, escolhe-se T_2 como limiar médio dentro de uma região espectral especificada (procedimento idêntico à codificação binária com um limiar). Depois, analisam-se os NDs das respostas espectrais das classes de cobertura (amostras de treinamento). Com isto, obtém-se o valor médio para cada classe V_i , levando em consideração todos os pixels empregados no treinamento (por classe). Em seguida, determina-se a diferença absoluta entre a média de cada classe (V_i) e o limiar médio T_2 , e calcula-se a média da diferença absoluta de todas as classes. A transformação deste número em percentual P (único para todas as classes) dá-se pela divisão do mesmo pelo limiar T_2 (variável para cada classe).

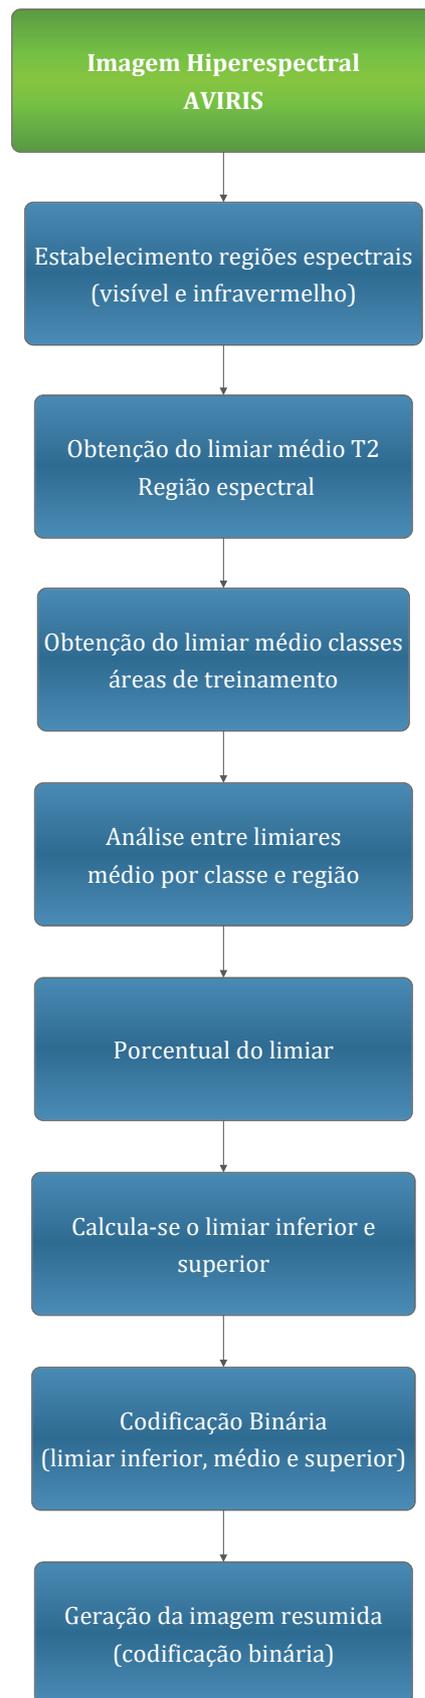
Depois de obter o percentual do limiar P , procede-se ao cálculo dos demais limiares T_1 e T_3 (variáveis para cada classe). Estes limiares são calculados mediante o decréscimo e acréscimo, respectivamente, do percentual P aplicado sobre o limiar T_2 . Em outras palavras, tomando-se como exemplo o cálculo de T_1 , deve-se subtrair de T_2 o valor obtido no cálculo do percentual P aplicado sobre T_2 . No caso de T_3 soma-se em vez de se subtrair.

Para este trabalho se utilizou sete classes (as mesmas da codificação binária com um limiar), resultando como percentual do limiar P o valor de três centésimos e, assim, T_1 e T_3 receberam os valores de 97% e 103% do limiar médio (T_2). Os limiares inferior e superior dependeram do limiar médio T_2 em cada região espectral.

Em seguida à obtenção dos limiares (inferior, médio e superior) realizou-se a binarização, em função destes limiares, de cada imagem componente de uma região espectral. Finalmente, efetuou-se a geração das imagens obtidas por codificação binária para cada região, com a finalidade de obter novas imagens que sintetizam toda a informação disponibilizada na imagem hiperespectral.

A Figura 22 mostra o procedimento para a codificação binária para três limiares.

FIGURA 22 - ESQUEMA PARA CODIFICAÇÃO BINÁRIA (3 LIMIARES)



FONTE: ELABORAÇÃO DO AUTOR

3.2.2.3 Geração de imagens das regiões

Após a binarização das imagens de cada região, por meio de um ou três limiares, faz-se a geração de novas imagens que resumem toda a informação contida na região espectral. Através das equações 12 e 13 pode-se determinar o novo valor de pixel codificado, a partir das binarizações das imagens componentes de uma região espectral, para um limiar e três limiares, respectivamente.

$$B_{i,j} = \sum_{t=1}^8 V(t) * 2^{(t-1)} \quad (12)$$

onde, $B_{i,j}$ é o novo valor do pixel, t é o índice que idêntica a banda dentro da região e V é o valor binário (obtido pela binarização com um limiar) proveniente do pixel na imagem t , e

$$B_{i,j} = \sum_{t=1}^8 V_e(t) * 2^{(2t-1)} + V_d(t) * 2^{(2t-2)} \quad (13)$$

onde, $B_{i,j}$ é o novo valor do pixel, t é o índice que idêntica a banda dentro da região, V_e é o valor do bit mais significativo (esquerdo) e V_d é o valor do bit menos significativo (direito), ambos provenientes do pixel de quatro estados na imagem t (00, 01, 10 ou 11).

3.2.3 Processamento de Imagens

3.2.3.1 Separabilidade pela medida de Divergência Transformada

Com a redução de dimensionalidade, feita através do agrupamento em regiões espectrais e binarização, gerou-se 21 imagens de 8 bits (um limiar) e 21 imagens de 16 bits (três limiares).

Com a finalidade de avaliar se uma banda (uma imagem) é importante na diferenciação entre pares de classes presentes em um conjunto de imagens, é necessário analisar a medida de sobreposição de tais classes entre si. Assim, a partir da identificação da assinatura espectral de cada classe e a medida de

sobreposição com outras classes, pode-se realizar a análise da separabilidade entre as mesmas, para um conjunto de bandas espectrais.

Neste contexto, após a redução de dimensionalidade na imagem hiperespectral AVIRIS, foi analisada a separabilidade entre as classes com a finalidade de verificar se o conjunto de imagens resultantes da redução de dimensionalidade foi adequado. Neste trabalho, a análise da separabilidade foi realizada através da determinação do índice de divergência transformada pelo software MULTISPEC.

Na Figura 23 pode-se mostrar o procedimento para determinar a separabilidade por divergência transformada.

FIGURA 23 - ESQUEMA DIVERGENCIA TRANSFORMADA



FONTE: ELABORAÇÃO DO AUTOR

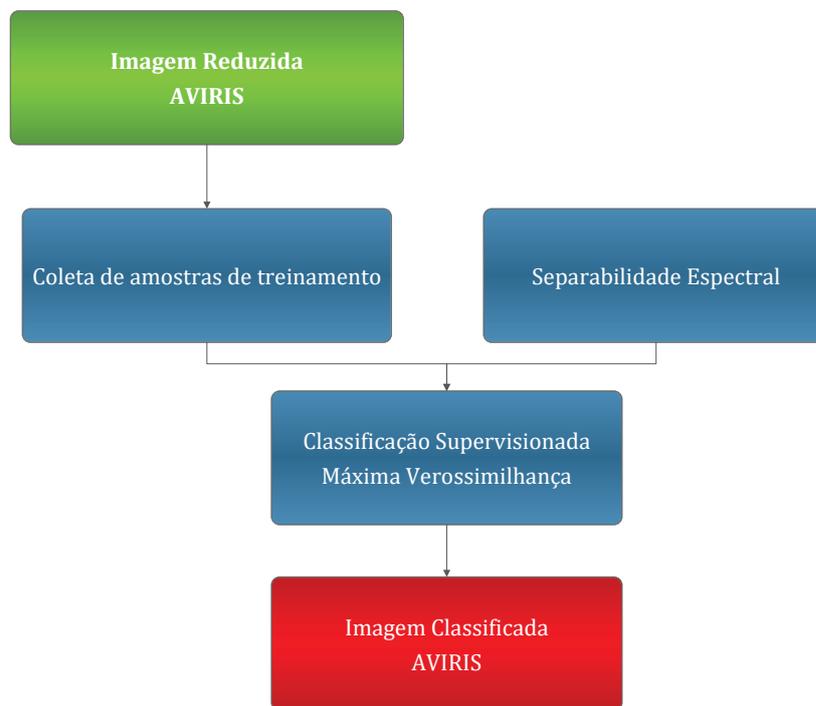
3.2.3.2 Classificação Máxima Verossimilhança

Depois da análise da separabilidade entre as classes tem-se que realizar a classificação digital da imagem com o objetivo de associar cada pixel da imagem às classes da cobertura da terra. Para realizar este processo foi utilizada a técnica de classificação supervisionada de Máxima Verossimilhança. Nessa abordagem, assume-se que os níveis digitais (ND) de cada classe se ajustam a uma distribuição

normal. Isto permite descrever essa classe por uma função de probabilidade, a partir de seu vetor de médias e matriz de variância-covariância. O cálculo é realizado para todos os pixels, atribuindo cada pixel para a classe que maximize a função de probabilidade. Esta abordagem foi executada no software MULTISPEC.

A figura 24 mostra o procedimento para realizar a classificação por máxima verossimilhança.

FIGURA 24 - ESQUEMA DE CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA



FONTE: ELABORAÇÃO DO AUTOR

3.2.4 Validação de Qualidade

Após a classificação de uma imagem, é importante avaliar a qualidade dos resultados do mapa de classificação de saída, derivados de dados de sensoriamento remoto. Segundo Richards (2013) a avaliação permite indicar a confiança nos resultados e se os objetivos de análise foram alcançados. Neste contexto, toda classificação implica certa margem de erros.

Para a avaliação da classificação da cobertura da terra da imagem AVIRIS, foi construída a matriz de erros (citado na seção 4.7.1), com a finalidade de mostrar

a concordância entre a classificação e a informação de referência. Para a informação de referência neste trabalho foi utilizada a verdade de campo disponibilizada pela Universidade de Purdue. Como ponto final, para quantificar e representar a acurácia da classificação foi utilizado o coeficiente kappa, obtido a partir da matriz de erros.

3.2.5 Experimentação

Para a realização da redução de dimensionalidade baseado na codificação binária de dados hiperespectrais do sensor AVIRIS foram feitos vários experimentos. Todos os experimentos se basearam na metodologia de Jia e Richards (1993), ora com um limiar, ora com três limiares. O percentual de limiar P igual a $1/6$ obtido nos experimentos destes autores também foi empregado. Além disso, como os dados empregados neste trabalho são diferentes dos de Jia e Richards (1993), resolveu-se utilizar a mesma sistemática, e assim obteve-se um novo percentual do limiar P .

Ao se realizar a codificação binária de três limiares verificou-se que nem sempre os limiares T_1 e T_3 ajudavam na distinção das respostas espectrais. Para superar esta deficiência criou-se uma nova codificação binária com três limiares. Nesta codificação T_1 e T_3 assumem, respectivamente, o valor médio compreendido entre os valores mínimos ou máximos, das respostas espectrais de cada região, e o limiar T_2 . A partir da obtenção destes novos limiares, gerou-se mais uma estratégia de redução de dimensionalidade automatizada.

Tendo em vista o propósito de distinguir as sete classes (referidas na seção 3.1) entre si, empregou-se o software MULTISPEC que oferece a ferramenta de divergência transformada. Usando-se todas as imagens e analisando-se os valores de divergências transformadas obtidas, incluindo aí a quantidade de imagens empregadas, verificou-se que não é necessário utilizar todas as imagens para a obtenção da melhor classificação. Constatou-se que a partir de 15 imagens não ocorria melhora na diferenciação entre classes. Destarte acabou-se usando 15 imagens. Frise-se que o software MULTISPEC fornece esta informação automaticamente.

4 ANÁLISE DE RESULTADOS

4.1 EXPERIMENTOS

No primeiro experimento, a codificação binária para redução de dimensionalidade foi realizada baseada em um limiar utilizando regiões espectrais.

O segundo experimento foi desenvolvido baseado no uso de três limiares (inferior, médio e superior), utilizando regiões espectrais para a codificação binária e aplicando o percentual do limiar de 1/6 (idêntico ao empregado por Jia e Richards, 1993).

O terceiro experimento, visando codificação binária de regiões espectrais na redução de dimensionalidade (novamente com três limiares), aplicou um percentual do limiar modificado (3/100) obtido para a cena de estudo deste trabalho e para as classes espectrais registradas na imagem (vegetação, milho plantio direto, milho cultivo mínimo, grama / pastagem, grama com arvores, soja plantio direto e soja cultivo mínimo).

O quarto experimento foi desenvolvido através da modificação de limiares. Esse experimento consiste em determinar os valores mínimo e máximo de cada região espectral e depois obter o valor médio compreendido entre estes valores e o limiar médio. Assim podem ser determinados os limiares T_1 e T_3 para cada região espectral. Observe-se que a alteração dos limiares T_1 ou T_3 só ocorreu quando: ou T_1 estava abaixo do mínimo da resposta espectral, ou T_3 estava acima do máximo da resposta espectral.

O quinto experimento foi realizado baseado nos resultados obtidos nos experimentos anteriores. Esse experimento consistiu na unificação das classes milho plantio direto e milho cultivo mínimo para formar a classe milho de forma geral. Com esta variação, neste experimento utilizaram-se três limiares para a codificação binária na redução de dimensionalidade aplicando o percentual do limiar equivalente a 1/6 (similar ao segundo experimento).

O sexto experimento empregou a mesma variação de agrupamento da classe milho e usou três limiares para a codificação binária na redução de dimensionalidade aplicando o percentual do limiar automatizado (similar ao quarto experimento).

4.1.1 Experimento 1: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com um limiar

Para este experimento realizou-se a codificação binária baseada em um limiar médio dentro de uma região espectral especificada. A partir do limiar médio se binarizou cada pixel da imagem (0/1) e depois se realizou a codificação com a finalidade de obter uma nova imagem com o novo valor do pixel compreendido entre 0 e 255 para cada região espectral composta por 8 bandas. Desta forma obteve-se 21 imagens (agregações realizadas) com pixel de 8 bits.

TABELA 8 - ÍNDICES DE SEPARABILIDADE DAS CLASSES POR DIVERGENCIA TRANSFORMADA PARA 1 LIMIAR

Pares de classes comparados	Divergência Transformada
Vegetação X Milho plantio direto	2000
Vegetação X Milho cultivo mínimo	2000
Vegetação X Grama / pastagem	2000
Vegetação X Grama com arvores	2000
Vegetação X Soja plantio direto	2000
Vegetação X Soja cultivo mínimo	2000
Milho plantio direto X Milho cultivo mínimo	1730
Milho plantio direto X Grama / pastagem	2000
Milho plantio direto X Grama com arvores	2000
Milho plantio direto X Soja plantio direto	2000
Milho plantio direto X Soja cultivo mínimo	1673
Milho cultivo mínimo X Grama / pastagem	2000
Milho cultivo mínimo X Grama com arvores	2000
Milho cultivo mínimo X Soja plantio direto	2000
Milho cultivo mínimo X Soja cultivo mínimo	1621
Grama / pastagem X Grama com arvores	2000
Grama / pastagem X Soja plantio direto	2000
Grama / pastagem X Soja cultivo mínimo	2000
Grama com arvores X Soja plantio direto	2000
Grama com arvores X Soja cultivo mínimo	2000
Soja plantio direto X Soja cultivo mínimo	1766

FONTE: ELABORAÇÃO DO AUTOR

Após a codificação utilizou-se as 21 imagens e as amostras de treinamento das classes para estimar a separabilidade entre elas. Assim, baseado no algoritmo de divergência transformada identificou-se sobreposição entre várias classes. As

principais sobreposições surgiram entre as classes: milho plantio direto e milho cultivado mínimo com valor de 1730, milho plantio direto e soja cultivado mínimo com valor de 1673, milho cultivado mínimo e soja cultivado mínimo com valor 1621 e soja plantio direto e soja cultivado mínimo com valor de 1766. Estes valores são baixos em comparação com as demais classes que tem valores iguais a 2000, o que indica que estas últimas classes não tem problemas de separabilidade. O resultado da análise da separabilidade das classes pode ser visualizado através da Tabela 8.

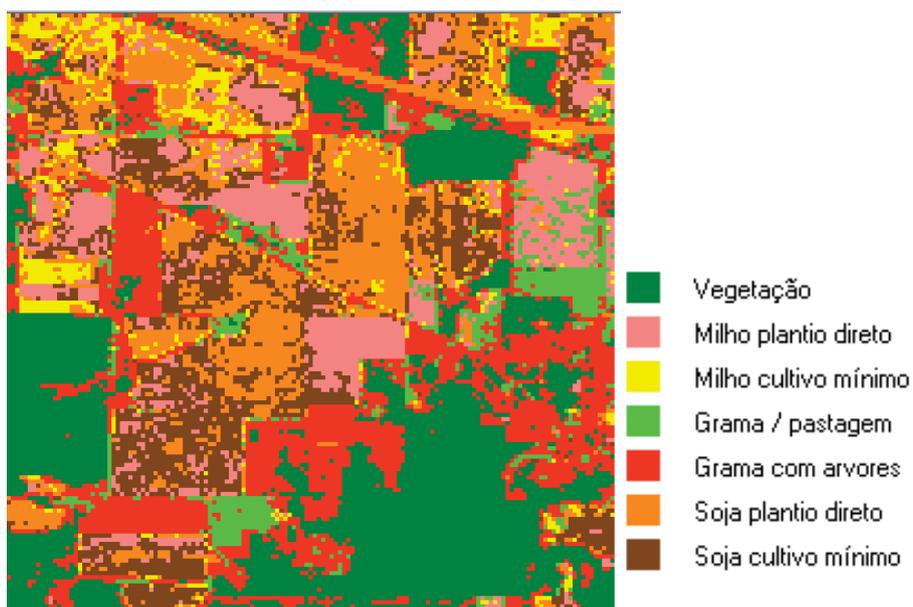
Após a análise de separabilidade entre classes realizou-se a classificação temática destas imagens. A classificação foi desenvolvida considerando somente as imagens que tiveram os valores mais altos no índice de separabilidade (15 imagens). As imagens de entrada para a classificação neste experimento se apresentam na Tabela 9. Mediante a Figura 25 pode-se visualizar o resultado da classificação.

TABELA 9 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO (1 LIMAR)

Região	verde	vermelho	infravermelho próximo	infravermelho médio
Imagens	2	3	4, 5, 6, 7, 8, 10, 11	12, 13, 14, 16, 18, 20

FONTE: ELABORAÇÃO DO AUTOR

FIGURA 25 - CLASSIFICAÇÃO PARA 1 LIMAR



FONTE: ELABORAÇÃO DO AUTOR

Em seguida, se construiu a matriz de confusão (ver Tabela 10) baseada nas amostras de verificação. Isto permitiu avaliar a qualidade temática obtida neste experimento. Observa-se que a maior confusão encontrou-se na discriminação entre as classes milho cultivado mínimo e soja (plantio direto e cultivo mínimo), com valor do erro de omissão igual a 0,6. Além disso, com base no valor do erro de omissão, deve-se mencionar que existe confusão entre as classes de soja cultivo mínimo e soja plantio direto, muito embora a porcentagem da exatidão do produtor seja aceitável. A explicação, para este último caso, é que a divergência transformada apresentou um valor baixo (1766).

TABELA 10 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 1 LIMAR

Classes		DADOS CLASSIFICAÇÃO								Exatidão produtor (%)	Erros de omissão
		VEG	MPD	MCM	GP	GA	SPD	SCM	TOTAL		
DADOS DE REFERÊNCIA	VEG	298	0	0	0	12	0	0	310	96,1	0,0
	MPD	0	80	8	2	0	22	20	132	60,6	0,4
	MCM	0	24	60	1	0	43	34	162	37,0	0,6
	GP	21	0	0	13	8	0	0	42	31,0	0,7
	GA	3	0	0	0	58	0	0	61	95,1	0,0
	SPD	0	3	0	0	0	23	0	26	88,5	0,1
	SCM	0	24	8	1	1	66	105	285	51,2	0,6
	TOTAL	322	131	76	17	79	154	159	938		
	Exatidão usuário (%)	92,5	61,1	78,9	76,5	73,4	14,9	66,0			
	Erros de comissão	0,1	0,4	0,2	0,2	0,3	0,9	0,3			

FONTE: ELABORAÇÃO DO AUTOR

4.1.2 Experimento 2: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares (porcentual baseado em 1/6)

A variação desse experimento em relação ao anterior consistiu em utilizar três limiares (inferior, médio e superior) para um percentual do limiar de 1/6 na codificação binária para reduzir a dimensionalidade. Este experimento utilizou 21 regiões espectrais (agrupadas de 8 em 8 bandas) na codificação de cada pixel da imagem hiperespectral AVIRIS. Os valores binarizados para cada pixel estão

compreendidos em 00, 01, 10 ou 11. Após este processo realizou-se a codificação com a finalidade de obter 21 imagens de 16 bits

Após a codificação realizou-se a análise da separabilidade em função das 21 imagens obtidas no procedimento anterior e as amostras de treinamento das classes. Através da Tabela 11 pode-se visualizar os índices de separabilidade por divergência transformada das classes para este experimento.

TABELA 11 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES (PORCENTUAL DO LIMIAR 1/6)

Pares de classes comparados	Divergência Transformada
Vegetação X Milho plantio direto	2000
Vegetação X Milho cultivo mínimo	2000
Vegetação X Grama / pastagem	2000
Vegetação X Grama com arvores	2000
Vegetação X Soja plantio direto	2000
Vegetação X Soja cultivo mínimo	2000
Milho plantio direto X Milho cultivo mínimo	1844
Milho plantio direto X Grama / pastagem	2000
Milho plantio direto X Grama com arvores	2000
Milho plantio direto X Soja plantio direto	2000
Milho plantio direto X Soja cultivo mínimo	2000
Milho cultivo mínimo X Grama / pastagem	2000
Milho cultivo mínimo X Grama com arvores	2000
Milho cultivo mínimo X Soja plantio direto	1983
Milho cultivo mínimo X Soja cultivo mínimo	1993
Grama / pastagem X Grama com arvores	2000
Grama / pastagem X Soja plantio direto	2000
Grama / pastagem X Soja cultivo mínimo	2000
Grama com arvores X Soja plantio direto	2000
Grama com arvores X Soja cultivo mínimo	2000
Soja plantio direto X Soja cultivo mínimo	1845

FONTE: ELABORAÇÃO DO AUTOR

Os resultados permitiram identificar as mesmas confusões entre classes mostradas no experimento 1. A diferença pode ser percebida nos valores do algoritmo da divergência transformada, por exemplo: a separabilidade de milho plantio direto e milho cultivo mínimo aumentou de 1730 para 1894, milho plantio direto e soja cultivo mínimo mudou de 1673 para 2000, milho cultivo mínimo e soja

cultivo mínimo modificou-se de 1621 para 1993, e soja plantio direto e soja cultivo mínimo variou de 1766 para 1845. Estes resultados permitem concluir que a separabilidade aumentou nestes itens apresentados. Além disso, houve uma mudança nas classes de milho cultivo mínimo e soja plantio direto. O valor da separabilidade entre estas classes diminuiu de 2000 para 1983.

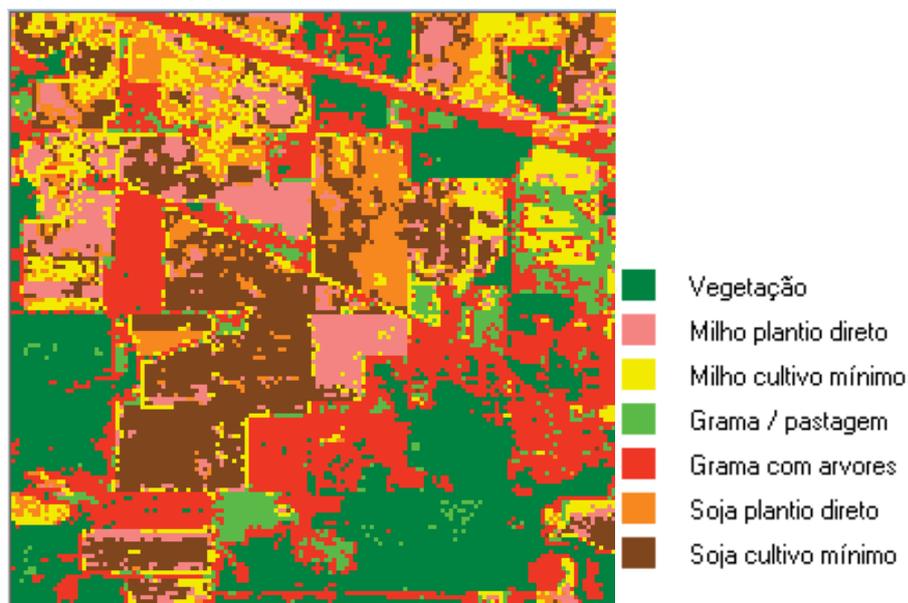
Após a análise de separabilidade realizou-se a classificação temática destas imagens. A classificação foi desenvolvida analisando-se somente as imagens que apresentaram os valores mais altos no índice de separabilidade. As imagens consideradas para a classificação temática podem ser visualizadas por meio da Tabela 12. Através da Figura 26 pode-se visualizar o resultado da classificação.

TABELA 12 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO (3 LIMIARES E PORCENTUAL DO LIMIAIR 1/6)

Região	azul	verde	vermelho	infravermelho próximo	infravermelho médio
Imagens	1	2	3	4, 5, 6, 8, 9, 10	12, 14, 15, 17,18, 20

FONTE: ELABORAÇÃO DO AUTOR

FIGURA 26 - CLASSIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMIAIR 1/6)



FONTE: ELABORAÇÃO DO AUTOR

Avaliou-se a informação obtida neste experimento através da matriz de confusão para as amostras de verificação. Na Tabela 13 pode-se visualizar que a

maior confusão ocorreu entre as classes de milho cultivo mínimo e soja cultivo mínimo. O valor do erro de omissão para estas classes é de 0,6, significando que o desempenho não é aceitável no momento de discriminar estas classes. Além disso, pode-se observar que existe uma confusão entre grama/pastagem e vegetação porque a porcentagem da exatidão do produtor está no valor de 38,1 %. Este valor é baixo em comparação com as demais porcentagens.

TABELA 13 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMIAIR 1/6)

		DADOS CLASSIFICAÇÃO									Exatidão produtor (%)	Erros de omissão
Classes		VEG	MPD	MCM	GP	GA	SPD	SCM	TOTAL			
DADOS DE REFERÊNCIA	VEG	307	0	0	0	3	0	0	310	99,0	0,0	
	MPD	0	73	15	1	0	6	34	129	56,6	0,4	
	MCM	0	0	7	0	0	2	9	18	38,9	0,6	
	GP	22	0	0	16	4	0	0	42	38,1	0,6	
	GA	0	0	0	1	60	0	0	61	98,4	0,0	
	SPD	0	0	4	0	0	21	1	26	80,8	0,2	
	SCM	0	33	14	0	2	14	104	167	62,3	0,4	
	TOTAL	329	106	40	18	69	43	148	753			
	Exatidão usuário (%)	93.3	68.9	17.5	88.9	87.0	48.8	70.3				
	Erros de comissão	0,1	0,3	0,8	0,1	0,1	0,5	0,3				

FONTE: ELABORAÇÃO DO AUTOR

4.1.3 Experimento 3: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares (porcentual baseado em 3/100).

Jia e Richards (1993) calcularam o porcentual do limiar de um sexto baseado nas respostas espectrais correspondentes a seis diferentes tipos de cobertura (classes) em uma imagem diferente da utilizada para este trabalho. Para este experimento, foi realizado o mesmo procedimento utilizado por estes autores para a obtenção do porcentual do limiar da imagem, obtendo-se como resultado o valor de 3/100. A partir do cálculo do porcentual do limiar codificou-se os pixels da

imagem com os valores de 00, 01, 10 ou 11. Depois deste processo, realizou-se a codificação tendo como objetivo produzir 21 imagens de 16 bits.

Depois da codificação efetuou-se a análise de separabilidade utilizando as 21 imagens e as amostras de treinamento das classes temáticas. Na tabela 14 apresentam-se os índices de separabilidade que permitem identificar a sobreposição entre classes para três limiares (porcentual do limiar com valor de 3/100).

TABELA 14 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES (PORCENTUAL DO LIMIAR 3/100)

Pares de classes comparados	Divergência Transformada
Vegetação X Milho plantio direto	2000
Vegetação X Milho cultivo mínimo	2000
Vegetação X Grama / pastagem	2000
Vegetação X Grama com arvores	2000
Vegetação X Soja plantio direto	2000
Vegetação X Soja cultivo mínimo	2000
Milho plantio direto X Milho cultivo mínimo	1885
Milho plantio direto X Grama / pastagem	2000
Milho plantio direto X Grama com arvores	2000
Milho plantio direto X Soja plantio direto	2000
Milho plantio direto X Soja cultivo mínimo	1997
Milho cultivo mínimo X Grama / pastagem	2000
Milho cultivo mínimo X Grama com arvores	2000
Milho cultivo mínimo X Soja plantio direto	2000
Milho cultivo mínimo X Soja cultivo mínimo	2000
Grama / pastagem X Grama com arvores	2000
Grama / pastagem X Soja plantio direto	2000
Grama / pastagem X Soja cultivo mínimo	2000
Grama com arvores X Soja plantio direto	2000
Grama com arvores X Soja cultivo mínimo	2000
Soja plantio direto X Soja cultivo mínimo	2000

FONTE: ELABORAÇÃO DO AUTOR

Após a análise da separabilidade deste experimento pode-se identificar que, de modo geral, aumentaram os valores comparados com os valores do experimento 2. Assim, a separabilidade de milho plantio direto e milho cultivo mínimo variou de 1844 para 1885, milho cultivo mínimo e soja plantio direto modificou-se de 1983 para

2000, milho cultivo mínimo e soja cultivo mínimo modificou-se de 1993 para 2000, e soja plantio direto e soja cultivo mínimo variou de 1845 para 2000.

As classes de milho plantio direto e soja cultivo mínimo tiveram a sua divergência transformada alterada de 2000 para 1997, o que indica que houve um ligeiro decréscimo. Estes resultados confirmam, de forma geral, que a separabilidade melhorou e as classes podem ser identificadas na classificação.

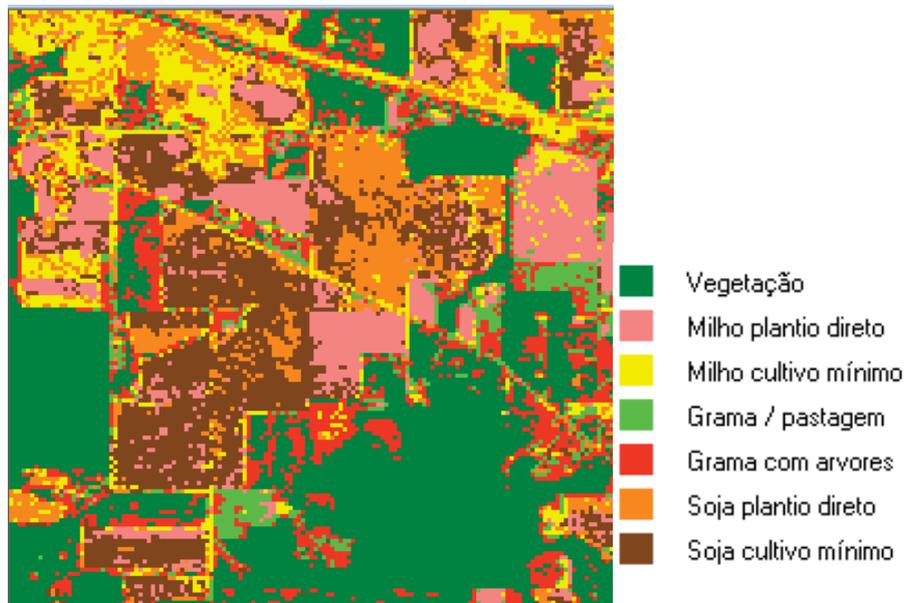
Considerando somente as imagens que tiveram os valores mais altos no índice de separabilidade realizou-se a classificação. As imagens usadas para a classificação temática podem ser observadas na Tabela 15. A classificação por máxima verossimilhança deste experimento se apresenta na Figura 27.

TABELA 15 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO (3 LIMIARES E PORCENTUAL DO LIMIAR 3/100)

Região	azul	vermelho	infravermelho próximo	infravermelho médio
Imagens	1	3	4, 7, 8, 11	13,14, 15, 16, 17, 18, 19, 20, 21

FONTE: ELABORAÇÃO DO AUTOR

FIGURA 27 - CLASSIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMIAR 3/100)



FONTE: ELABORAÇÃO DO AUTOR

Após a classificação temática fez-se necessário a avaliação dos resultados obtidos. Assim, determinou-se a confiabilidade e a qualidade da classificação desta

imagem por meio da construção da matriz de confusão. A Tabela 16 apresenta a matriz de confusão deste experimento baseado nas amostras de verificação, além dos valores dos erros do usuário, produtor, omissão e comissão. Nesta tabela pode-se visualizar que a maior confusão está representada nas classes de grama (pastagem e arvores) e vegetação, tendo como valores dos erros de omissão 0,7 e 0,5, respectivamente. O valor da porcentagem de exatidão do produtor ficou em 26,2% entre as classes de grama/pastagem e vegetação, sendo o pior em comparação com todos os demais percentuais.

TABELA 16 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES (PORCENTUAL DO LIMIAIR 3/100)

		DADOS CLASSIFICAÇÃO								Exatidão produtor (%)	Erros de omissão
Classes	VEG	MPD	MCM	GP	GA	SPD	SCM	TOTAL			
DADOS DE REFERÊNCIA	VEG	308	0	0	0	2	0	0	310	99,4	0,0
	MPD	0	71	5	0	0	17	36	129	55,0	0,4
	MCM	0	0	13	0	0	4	1	18	72,2	0,3
	GP	22	0	0	11	9	0	0	42	26,2	0,7
	GA	30	0	0	0	31	0	0	61	50,8	0,5
	SPD	0	0	3	0	0	23	0	26	88,5	0,1
	SCM	0	33	9	0	0	16	109	167	65,3	0,3
	TOTAL	360	104	30	11	42	60	146	753		
	Exatidão usuário (%)	85.6	68.3	43.3	100.0	73.8	38.3	74.7			
	Erros de comissão	0,1	0,3	0,6	0,0	0,3	0,6	0,3			

FONTE: ELABORAÇÃO DO AUTOR

4.1.4 Experimento 4: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares modificados

Neste experimento realizou-se uma análise do comportamento espectral por região, utilizando regiões espectrais com três limiares. Assim, após a determinação dos valores mínimo e máximo de cada região espectral, calculou-se o valor médio compreendido entre estes valores e o limiar médio, obtendo-se novos valores para os limiares T_1 e T_3 . Os valores binarizados para cada pixel estão compreendidos em

00, 01, 10 ou 11, o que gera, após a codificação, 21 novas imagens, sendo que cada uma resume 8 bandas componentes de cada região espectral.

A partir do processo de codificação, realizou-se a análise da separabilidade utilizando as 21 imagens. A separabilidade foi analisada baseada nos índices obtidos pelo método de divergência transformada. A Tabela 17 permite-se visualizar os índices de separabilidade das classes para este experimento.

TABELA 17 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES MODIFICADOS

Pares de classes comparados	Divergência Transformada
Vegetação X Milho plantio direto	2000
Vegetação X Milho cultivado mínimo	2000
Vegetação X Grama / pastagem	2000
Vegetação X Grama com árvores	2000
Vegetação X Soja plantio direto	2000
Vegetação X Soja cultivado mínimo	2000
Milho plantio direto X Milho cultivado mínimo	1615
Milho plantio direto X Grama / pastagem	2000
Milho plantio direto X Grama com árvores	2000
Milho plantio direto X Soja plantio direto	2000
Milho plantio direto X Soja cultivado mínimo	2000
Milho cultivado mínimo X Grama / pastagem	2000
Milho cultivado mínimo X Grama com árvores	2000
Milho cultivado mínimo X Soja plantio direto	2000
Milho cultivado mínimo X Soja cultivado mínimo	1997
Grama / pastagem X Grama com árvores	2000
Grama / pastagem X Soja plantio direto	2000
Grama / pastagem X Soja cultivado mínimo	2000
Grama com árvores X Soja plantio direto	2000
Grama com árvores X Soja cultivado mínimo	2000
Soja plantio direto X Soja cultivado mínimo	1783

FONTE: ELABORAÇÃO DO AUTOR

Baseado nas amostras de treinamento das classes pode-se identificar os índices de separabilidade entre as classes. Neste contexto, identificou-se a sobreposição existente entre várias classes. Os índices com maior problema são apresentados a seguir: milho plantio direto e milho cultivado mínimo com valor de 1615, diminuído em relação aos demais experimentos; milho cultivado mínimo e soja

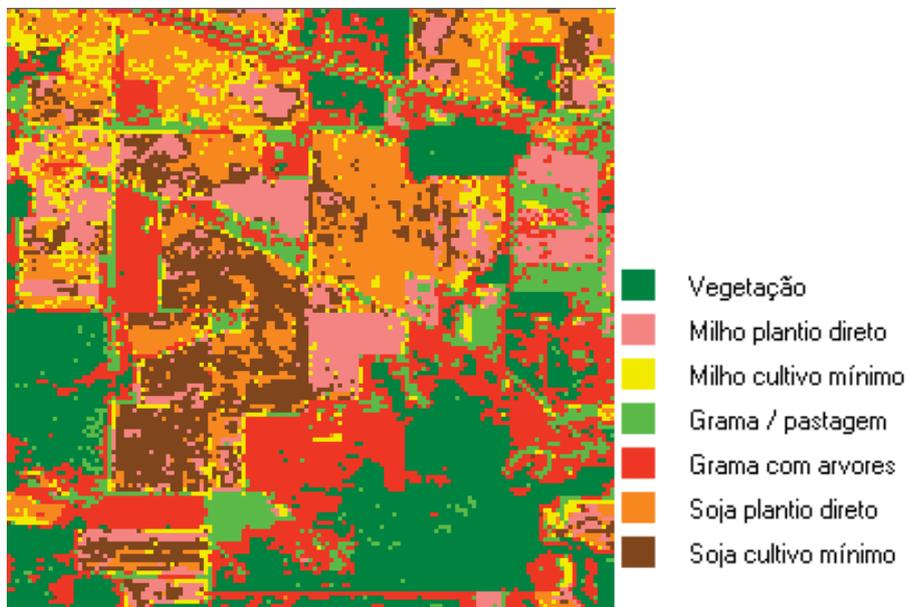
cultivo mínimo com valor de 1997, soja plantio direto e soja cultivo mínimo com valor de 1783, ambos diminuídos em relação ao terceiro experimento. As demais classes não apresentaram problemas (valores iguais a 2000). Após a análise de separabilidade realizou-se a classificação baseada nas 21 imagens obtidas da redução de dimensionalidade. A classificação foi desenvolvida considerando as bandas que tiveram os valores mais altos no índice de separabilidade, resultando 15 imagens. As imagens utilizadas para realizar a classificação temática podem ser visualizadas na Tabela 18. Na Figura 28 mostra-se a classificação do experimento 4 utilizando o limiar modificado com três limiares.

TABELA 18 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO PARA 3 LIMIARES MODIFICADOS

Região	verde	vermelho	infravermelho próximo	infravermelho médio
Imagens	2	3	5, 8, 9, 10, 11	12, 13, 14, 15, 16, 17, 18, 20

FONTE: ELABORAÇÃO DO AUTOR

FIGURA 28 - CLASSIFICAÇÃO PARA 3 LIMIARES MODIFICADOS



FONTE: ELABORAÇÃO DO AUTOR

Depois da classificação temática determinou-se a matriz de confusão (Tabela 19), a qual permitiu avaliar a qualidade. Pode-se observar que existe confusão de discriminação entre as classes milho plantio direto e soja (plantio direto

e cultivo mínimo), cujo valor do erro de omissão para estas classes é de 0,5. Outra confusão existente nesta matriz se apresenta entre as classes de grama/pastagem e vegetação e entre as classes de soja cultivo mínimo e soja plantio direto, ambas com valor do erro de omissão de 0,6.

TABELA 19 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO COM 3 LIMIARES MODIFICADOS

		DADOS CLASSIFICAÇÃO										
Classes		VEG	MPD	MCM	GP	GA	SPD	SCM	TOTAL	Exatidão produtor (%)	Erros de omissão	
DADOS DE REFERÊNCIA	VEG	300	0	0	0	10	0	0	310	96,8	0,0	
	MPD	0	70	5	1	0	36	17	129	54,3	0,5	
	MCM	0	0	13	0	0	3	2	18	72,2	0,3	
	GP	20	0	0	18	4	0	0	42	42,9	0,6	
	GA	1	0	0	1	59	0	0	61	96,7	0,0	
	SPD	0	0	5	0	0	21	0	26	80,8	0,2	
	SCM	0	42	15	2	0	33	75	167	44,9	0,6	
	TOTAL	321	112	38	22	73	93	94	753			
	Exatidão usuário (%)	93.5	62.5	34.2	81.8	80.8	22.6	79.8				
	Erros de comissão	0,1	0,4	0,7	0,2	0,2	0,8	0,2				

FONTE: ELABORAÇÃO DO AUTOR

4.1.5 Experimento 5: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares e com classe única de milho (porcentual do limiar 1/6)

Considerando que um dos problemas que se apresentou nos quatro experimentos anteriores foi com a classe milho cultivo mínimo, decidiu-se realizar uma variação nas classes escolhidas. A variação consistiu em unificar as classes milho plantio direto e milho cultivo mínimo para a classe milho de forma geral. Assim, realizaram-se dois experimentos adicionais para determinar a qualidade dos resultados da classificação baseados nas amostras de treinamento e verificação.

A partir dessa variação, este experimento consistiu na utilização de porcentual do limiar de 1/6 na codificação binária para reduzir a dimensionalidade da imagem hiperespectral AVIRIS. Desta forma obteve-se 21 imagens com pixels de 16 bits.

Após a codificação, utilizou-se as 21 imagens e as amostras de treinamento das classes para estimar a separabilidade entre elas. Os resultados obtidos dos índices de separabilidade são apresentados na Tabela 20.

TABELA 20 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMIAR 1/6)

Pares de classes comparados	Divergência Transformada
Vegetação X Milho	2000
Vegetação X Grama / pastagem	2000
Vegetação X Grama com arvores	2000
Vegetação X Soja plantio direto	2000
Vegetação X Soja cultivo mínimo	2000
Milho X Grama / pastagem	2000
Milho X Grama com arvores	2000
Milho X Soja plantio direto	2000
Milho X Soja cultivo mínimo	1999
Grama / pastagem X Grama com arvores	2000
Grama / pastagem X Soja plantio direto	2000
Grama / pastagem X Soja cultivo mínimo	2000
Grama com arvores X Soja plantio direto	2000
Grama com arvores X Soja cultivo mínimo	2000
Soja plantio direto X Soja cultivo mínimo	1919

FONTE: ELABORAÇÃO DO AUTOR

Depois da análise da separabilidade, pode-se identificar que os índices aumentaram na maioria de par de classes comparados com os valores dos experimentos anteriores. Assim, a separabilidade de milho e soja cultivo mínimo tem o valor de 1999 e soja plantio direto e soja cultivo mínimo está no valor de 1919. Os demais índices de separabilidade entre classes têm valores iguais a 2000.

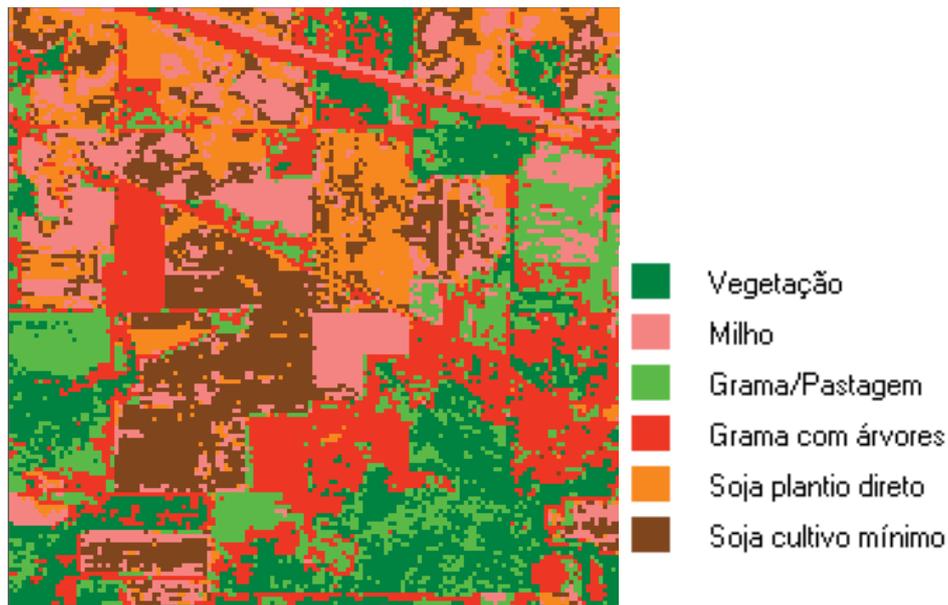
Após a análise de separabilidade realizou-se a classificação temática das imagens obtidas por codificação binária. As imagens consideradas para a classificação temática podem ser visualizadas por meio da Tabela 21. Na Figura 29 mostra-se o resultado da classificação por máxima verossimilhança.

TABELA 21 - IMAGENS UTILIZADAS PARA 3 LIMIARES PARA A CLASSIFICAÇÃO E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMIAIR 1/6)

Região	azul	verde	vermelho	infravermelho próximo	Infravermelho médio
Imagens	1	2	3	5, 6, 7, 8, 9, 10, 11	12, 13, 15, 18, 19

FONTE: ELABORAÇÃO DO AUTOR

FIGURA 29 - CLASSIFICAÇÃO PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMIAIR 1/6)



FONTE: ELABORAÇÃO DO AUTOR

Depois da classificação, avaliou-se a informação através da matriz de confusão para as amostras de verificação. Na Tabela 22 apresenta-se a matriz de confusão, na qual se pode visualizar que a maior confusão ocorreu entre as classes de milho e soja cultivo mínimo. O valor de erro de omissão para estas classes é de 0,4. Assim, pode-se mencionar que a unificação das classes milho contribuiu para melhorar a acurácia na classificação, já que o valor da porcentagem da exatidão de produtor está em 62,8. Este valor é alto em comparação com as porcentagens obtidas nos experimentos anteriores.

TABELA 22 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (PORCENTUAL DO LIMIAR 1/6)

		DADOS CLASSIFICAÇÃO								
Classes		VEG	M	GP	GA	SPD	SCM	TOTAL	Exatidão produtor (%)	Erros de omissão
DADOS DE REFERÊNCIA	VEG	265	0	41	4	0	0	310	85,5	0,1
	M	0	81	2	0	19	27	129	62,8	0,4
	GP	10	0	28	4	0	0	42	66,7	0,3
	GA	0	0	1	60	0	0	61	98,4	0,0
	SPD	0	0	0	0	25	1	26	96,2	0,0
	SCM	0	32	0	4	21	110	167	65,9	0,3
	TOTAL	275	113	72	72	65	138	735		
	Exatidão usuário (%)	96.4	71.7	38.9	83.3	38.5	79.7			
	Erros de comissão	0,0	0,3	0,6	0,2	0,6	0,2			

FONTE: ELABORAÇÃO DO AUTOR

4.1.6 Experimento 6: Redução da dimensionalidade baseado na codificação binária utilizando regiões espectrais com três limiares modificados

Este experimento também contou com a unificação da classe milho, derivada das classes milho plantio direto e milho cultivo mínimo. Além disso, empregou-se a codificação binária com três limiares modificados. Desta forma obteve-se 21 imagens com pixels de 16 bits.

Após a codificação, realizou-se a análise de separabilidade pelo método de divergência transformada em função das amostras de treinamento das classes. Os resultados obtidos para os índices de separabilidade são apresentados na Tabela 23.

Após a obtenção dos índices de separabilidade pode-se observar a ocorrência de um único valor diferente de 2000. O valor de 1831 ocorreu nas classes de soja plantio direto e soja cultivo mínimo.

Após a análise de separabilidade realizou-se a classificação temática. As imagens consideradas para esta classificação podem ser visualizadas por meio da Tabela 24. Na Figura 30 mostra-se a classificação por máxima verossimilhança.

TABELA 23 - ÍNDICES DE SEPARABILIDADE DAS CLASSES DIVERGENCIA TRANSFORMADA PARA 3 LIMIARES MODIFICADOS E COM CLASSE ÚNICA DE MILHO

Pares de classes comparados	Divergência Transformada
Vegetação X Milho	2000
Vegetação X Grama / pastagem	2000
Vegetação X Grama com arvores	2000
Vegetação X Soja plantio direto	2000
Vegetação X Soja cultivo mínimo	2000
Milho X Grama / pastagem	2000
Milho X Grama com arvores	2000
Milho X Soja plantio direto	2000
Milho X Soja cultivo mínimo	2000
Grama / pastagem X Grama com arvores	2000
Grama / pastagem X Soja plantio direto	2000
Grama / pastagem X Soja cultivo mínimo	2000
Grama com arvores X Soja plantio direto	2000
Grama com arvores X Soja cultivo mínimo	2000
Soja plantio direto X Soja cultivo mínimo	1831

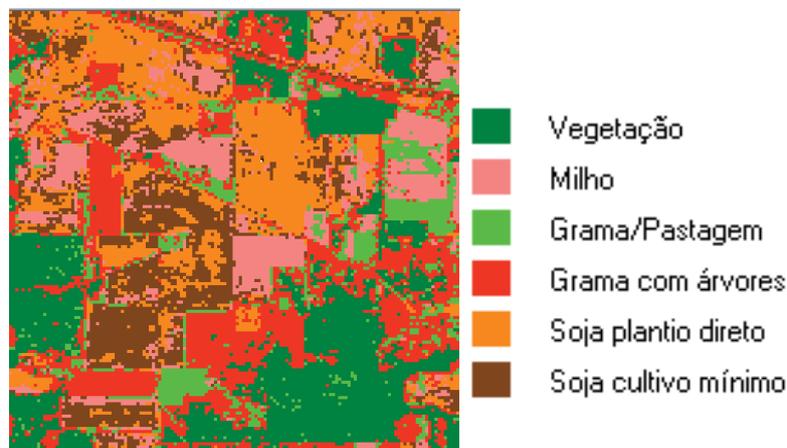
FONTE: ELABORAÇÃO DO AUTOR

TABELA 24 - IMAGENS UTILIZADAS PARA A CLASSIFICAÇÃO COM 3 LIMIARES MODIFICADOS

Região	azul	verde	vermelho	infravermelho próximo	Infravermelho médio
Imagens	1	2	3	4, 5, 6, 8, 9, 11	12, 14, 15, 16, 17, 18

FONTE: ELABORAÇÃO DO AUTOR

FIGURA 30 - CLASSIFICAÇÃO PARA 3 LIMIARES MODIFICADOS E COM CLASSE ÚNICA DE MILHO



FONTE: ELABORAÇÃO DO AUTOR

Depois da classificação temática realizou-se a avaliação dos resultados obtidos. Assim calculou-se a matriz de confusão baseado nas amostras de verificação. A Tabela 25 apresenta a matriz de confusão, onde se pode observar conflito entre: as classes de milho e soja plantio direto, grama/pastagem e vegetação, e soja cultivo mínimo e milho. Os erros de omissão para estes problemas resultam 0,4, 0,6 e 0,4 respectivamente, sendo os mais representativos em comparação com os demais erros.

TABELA 25 - MATRIZ DE CONFUSÃO PARA VERIFICAÇÃO PARA 3 LIMIARES E COM CLASSE ÚNICA DE MILHO (LIMIAR MODIFICADO)

		DADOS CLASSIFICAÇÃO								Exatidão produtor (%)	Erros de omissão
		Classes	VEG	M	GP	GA	SPD	SCM	TOTAL		
DADOS DE REFERÊNCIA	VEG	302	0	1	7	0	0	310	97,4	0,0	
	M	0	73	2	1	35	18	129	56,6	0,4	
	GP	22	0	17	3	0	0	42	40,5	0,6	
	GA	1	0	2	58	0	0	61	95,1	0,0	
	SPD	0	0	0	0	26	0	26	100	0,0	
	SCM	0	35	1	1	38	92	167	55,1	0,4	
	TOTAL	325	108	23	70	99	110	735			
	Exatidão usuário (%)	92.9	67.6	73.9	82.9	26.3	83.6				
	Erros de comissão	0,1	0,3	0,3	0,2	0,7	0,2				

FONTE: ELABORAÇÃO DO AUTOR

4.2 COEFICIENTE KAPPA

Para se avaliar a qualidade da cartografia temática gerada pelos experimentos anteriores empregou-se o coeficiente kappa para as amostras de verificação. Os valores apresentados na Tabela 26 foram calculados com base nas matrizes de confusão.

TABELA 26 - VALORES DOS COEFICIENTES KAPPA PARA AMOSTRAS DE VERIFICAÇÃO

Experimento	1	2	3	4	5	6
Índice kappa (verificação) %	60,1	70,4	65,9	65,4	70,1	69,3

FONTE: ELABORAÇÃO DO AUTOR

Como se pode perceber, todos os coeficientes kappa recaíram na faixa de 0,6 a 0,8 indicando desempenho de classificação “muito bom”.

5 CONCLUSÕES E RECOMENDAÇÕES

A metodologia proposta neste trabalho é promissora porque resume as características de bandas vizinhas, reduz a complexidade computacional, e melhora o desempenho da análise de dados.

A utilização de regiões espectrais para a redução de dimensionalidade apresentou resultados confiáveis, porque permite analisar as classes separadamente por região, obtendo desta forma representatividade no processo de classificação.

O agrupamento de bandas vizinhas para formar as regiões espectrais possibilitou a discriminação das classes através da análise do seu comportamento espectral.

O coeficiente kappa demonstrou que o uso de três limiares foi melhor que o uso de um limiar. A utilização de três limiares comprovou ser eficaz e eficiente para a análise da separabilidade das classes espectrais para fins de classificação da cobertura da terra.

Realizados os experimentos, identificou-se que a metodologia proposta por Jia e Richards (1993), com porcentual do limiar de $1/6$, foi a que possibilitou os melhores resultados. Tendo em vista que o coeficiente kappa apresentou resultados semelhantes para o porcentual do limiar de $3/100$, obtido a partir das classes identificadas para a imagem AVIRIS, não se deve deixar de calcular o porcentual do limiar para cada zona de estudo, já que os valores calculados por Jia e Richards (1993) podem não se adaptar para as classes pretendidas em diferentes imagens hiperespectrais.

Os resultados obtidos nos experimentos referidos ao método de redução de dimensionalidade por codificação binária foram satisfatórios. Esses resultados atingiram a qualidade temática baseados na matriz de confusão e coeficiente kappa para as amostras de verificação.

Como alternativa para melhorar a proposta de três limiares de Jia e Richards (1993), apresentou-se um percentual de limiar modificado (baseado no cálculo do valor médio entre os valores mínimo e máximo de cada região e o limiar médio T_2). Este percentual modificado permitiu obter o coeficiente kappa semelhante ao obtido por estes autores (65,4 vs 70,4), devendo, portanto, ser levado em consideração.

Os índices de separabilidade, considerando o método de divergência transformada, mostraram que as principais sobreposições surgiram entre as classes: milho plantio direto e milho cultivo mínimo; milho plantio direto e soja cultivo mínimo; milho cultivo mínimo e soja cultivo mínimo; e soja plantio direto e soja cultivo mínimo. Estas sobreposições apresentaram-se porque as assinaturas espectrais das classes são muito semelhantes na mesma região espectral e não se podem separar de forma fiável, o que provocou confusões e erros nos resultados da classificação.

Ao se unificar as classes de milho, verificou-se que os índices de separabilidade por divergência transformada aumentaram, indicando melhoria na classificação. Entretanto, o que se observou foi apenas uma ligeira melhora na discriminação destas classes.

Os experimentos realizados mostraram que, com a metodologia proposta baseada em extração de atributos, foi possível diminuir os efeitos do fenômeno de Hughes das imagens hiperespectrais, conservando a geometria dos dados originais. Segue-se que esta metodologia pode-se constituir como uma alternativa de redução de dimensionalidade.

A escolha das amostras de treinamento e verificação para cada classe na imagem torna-se importante, já que estas devem ser homogêneas, representativas e compostas por pixels com características similares, com a finalidade de obter uma boa separabilidade espectral para fins de classificação.

Recomenda-se aplicar esta metodologia em outras imagens hiperespectrais com a finalidade de avaliar as diferentes assinaturas espectrais das classes presentes nas imagens.

Como sugestão para desenvolvimentos futuros focados na redução de dimensionalidade, sugere-se que sejam pesquisadas abordagens relacionadas à integração da informação espectral e espacial das imagens hiperespectrais (p. ex. *mean-shift*).

REFERÊNCIAS

- ALAVIPANAH, S. K.; GHAZANFARI, K.; & KHAKBAZ, B. **Remote sensing and image understanding as reflected in poetical literature of Iran**. In Proceedings of remote sensing for science, education, and natural and cultural heritage, 30th symposium of european association of remote sensing laboratories, 31st May–3rd June, UNESCO Headquarters, Paris, France, 2010.
- ASHRAF, M. A.; MAAH, M. J.; YUSOFF, I. **Introduction to Remote Sensing of Biomass**, Universidade de Malásia, 2011.
- ASL, M. G.; MOBASHERI, M. R.; MOJARADI, B. **Unsupervised feature selection using geometrical measures in prototype space for hyperspectral imagery**. IEEE transactions on geoscience and remote sensing, 52(7), 3774-3787, 2014.
- BENEDIKTSSON, J. A.; GHAMISI P. **Spectral-Spatial Classification of Hyperspectral Remote Sensing Images**, First Edition, Artech House, 258p, 2015.
- BEN-DOR.; E., TAYLOR, R.G.; HILL, J.; DEMATT, J.A.M.; WHITING, M.L.; CHABRILLAT, S.; SOMMER, S. **Imaging spectrometry for soil applications**. *Advances in Agronomy*, 97, 321–392, 2008.
- CENTENO, J. A. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Departamento de Geomática, Universidade Federal do Paraná. Curitiba, 2010.
- CHUVIECO, E. **Fundamentos de Teledetección Espacial**, Segunda Edição, Edições Rialp S.A, Madrid - España. 452p, 1990.
- CHUVIECO, E. **Teledeteccion Ambiental**, Tomo 1, Terceira Edição, Editorial Ariel, S. A, Barcelona –Espanha, 2007.
- CHUVIECO, E. **Fundamentals of satellite remote sensing an environmental approach**, Second Edition, CRC Press Taylor & Francis Group, 457p, 2016.
- CIZNICKI, M.; KUROWSKI K.; PLAZA, A. **Graphics processing unit implementation of JPEG2000 for hyperspectral image compression**, 2012.
- DOBHAL, S. **Performance analysis of high-resolution and hyperspectral data fusion for classification and linear feature extraction**, 2008.
- FAUVEL, M.; DECHESNE, C.; ZULLO, A.; FERRATY, F. **Fast Forward Feature Selection of Hyperspectral Images for Classification With Gaussian Mixture Models**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(6), 2824-2831, 2015.
- FOSTER J. R.; TOWNSEND P. A. **Linking hyperspectral imagery and forest inventories for forest Assessment in the central Appalachians**. Proceedings. 14th Central Hardwood Forest Conference. p. 76-86, 2004.

GHAMISI, P. **Spectral and Spatial Classification of Hyperspectral Data.** (Doctoral dissertation, University of Iceland), 2015.

GRIFFIN, M. K.; HSU, S. M.; BURKE, H. K.; ORLOFF, S. M.; IUPHAM, C. A. **Examples of EO-1 Hyperion data analysis.** Massachusetts Institute of Tech Lexington Lincoln Lab, 2005.

HAACK, B.; BRYANT, N.; ADAMS, S. **An assessment of Landsat MSS and TM data for urban and near-urban land-cover digital classification.** Remote Sensing of Environment, 21(2), 201-213, 1987.

HUGHES, G.F. **On the mean accuracy of statistical pattern recognizers.** IEEE Trans. Inform. Theory IT 14, 55–63, 1968.

JIA, X.; RICHARDS, J. A. **Binary coding of imaging spectrometer data for fast spectral matching and classification.** Remote Sensing of Environment, 43(1), 47-53, 1993.

JOLLIFFE, I. T. **Principal Component Analysis,** Springer Series in Statistics. Springer, 2002.

LANDGREBE, D. A. **Hyperspectral Image Data Analysis as a High Dimensional Signal Processing Problem,** Reprinted from Special Issue of the IEEE Signal Processing Magazine, v. 19, n. 1 p. 17-28, January, 2002.

LANDGREBE, D. A. **Signal Theory Methods in Multispectral Remote Sensing,** Hoboken, NJ: Wiley, 2003.

LIANG, S.; LI, X.; WANG, J. (Eds.). **Advanced remote sensing: terrestrial information extraction and applications.** Academic Press, 2012.

LIAO, W.; PIZURICA, A.; SCHEUNDERS, P.; PHILIPS, W.; PI, Y. **Semi-supervised local discriminant analysis for feature extraction in hyperspectral images.** IEEE Transactions on Geoscience and Remote Sensing, 51(1), 184-198, 2013.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and image interpretation.** 6. Ed. New York; John Wiley & Sons, 763p, 2007.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation,** New York John Wiley & Sons, 2004

LINN, R. M. **Avaliação do modelo de Mistura Espectral com Múltiplos Membros de Referência (MESMA) aplicado aos dados hiperespectrais Hyperion/EO-1 da Planície Costeira do Rio Grande do Sul,** Mestrado Dissertação, 2008.

LIU, W. T. **Aplicações de Sensoriamento Remoto,** Campo Grande: Ed. UNIDERP, 2007.

LOISEL, H., VANTREPOTTE V., JAMET C., DAT N. G. **Challenges and New Advances in Ocean Color Remote Sensing of Coastal Waters**, 2013.

LUSCH, R. **Spectral characteristics of land surfaces**. In M.D. Nellis, R. Lougeay, and K. Lulla (Eds.), *Current Trends in Remote Sensing Education* (pp. 81-86). Hong Kong, China: Geocarto International Centre, 1989.

MATHER, P.M. **Computer Processing of Remotely Sensed Images**. Chichester, U.K.: John Wiley & Sons, 1998.

MAZER, A. S.; MARTIN, M.; LEE, M.; SOLOMON, J. E. **Image processing software for imaging spectrometry data analysis**, *Remote Sensing of Environment*, 24:201-210, 1988.

MENESES, P. R.; ALMEIDA, T. D. **Introdução ao Processamento de Imagens de Sensoriamento Remoto, Brasília, UNB/CNPq**, 2012.

MOREIRA, M. A. **Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação**. 2. ed. Viçosa: UFV, 307p, 2003.

MULDERS, M. A. **Remote Sensing in Soil Science**. Amsterdam, the Netherlands, Elsevier, 1987.

NOVO, E. M. **Sensoriamento Remoto Princípios e Aplicações**. Blucher, 4, ed. revista, 2010, 387 p.

REN, J.; ZABALZA, J.; MARSHALL, S.; ZHENG, J. **Effective feature extraction and data reduction in remote sensing using hyperspectral imaging** [Applications Corner]. *IEEE Signal Processing Magazine*, 31(4), 149-154, 2014.

RICHARDS, J. A. **Remote sensing digital image analysis An Introduction** Fifth Edition, Springer, 2013.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**, Academic press, Third Edition, 2007.

SERPICO, S. B.; D'INCA, M.; MELGANI, F.; MOSER, G. **Comparison of feature reduction techniques for classification of hyperspectral remote sensing data**, *International Symposium on Remote Sensing*, 4885, pp. 347-358, 2003.

SOUZA, E. M., SANCHEZ, R. V., CRUZ, C. B. **Reflectância da vegetação em Imagem Hiperespectral**, 2008.

SU, H.; YONG, B.; DU, Q. **Hyperspectral Band Selection Using Improved Firefly Algorithm**. *IEEE Geoscience and Remote Sensing Letters*, 13(1), 68-72, 2016.

SWAIN, P.; DAVIS, S. **Remote Sensing: The Quantitative Approach**, Mc.Graw-Hill, New York, 1978.

VANE, G.; GREEN, R. O.; CHRIEN, T. G.; ENMARK, H. T.; HANSEN, E. G.; PORTER, W. M. **The airborne visible/infrared imaging spectrometer (AVIRIS). Remote sensing of environment**, 44(2-3), 127-143, 1993

VOROVENCII, I. **The Hyperspectral Sensors used in Satellite and Aerial Remote Sensing**. Bulletin of the Transilvania University of Braşov• Vol, 2, 51, 2009.

XIE, H.; HEIPKE, C.; LOHMANN, P.; SOERGEL, U.; TONG, X; SHI, W. **A New Binary Encoding Algorithm for the Simultaneous Region-based Classification of Hyperspectral Data and Digital Surface Models**, Photogrammetrie - Fernerkundung - Geoinformation, (1), pp. 17–33, 2011.

YANG, H.; DU, Q.; CHEN, G. **Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 5(2), 544-554, 2012.

YUAN, Y.; ZHU, G.; WANG, Q. **Hyperspectral band selection by multitask sparsity pursuit**. IEEE Transactions on Geoscience and Remote Sensing, 53(2), 631-644, 2015

ZHANG, L.; ZHANG, L.; TAO, D.; HUANG, X. **Tensor discriminative locality alignment for hyperspectral image spectral–spatial feature extraction**. IEEE Transactions on Geoscience and Remote Sensing, 51(1), 242-256, 2013.

ZHONG, Z.; FAN, B.; DUAN, J.; WANG, L.; DING, K.; XIANG, S.; PAN, C. **Discriminant tensor spectral–spatial feature extraction for hyperspectral image classification**. IEEE Geoscience and Remote Sensing Letters, 12(5), 1028-1032, 2015.