

CENTRO UNIVERSITÁRIO DE ANÁPOLIS - UNIEVANGÉLICA
PROGRAMA DE PÓS-GRADUAÇÃO EM SOCIEDADE,
TECNOLOGIA E MEIO AMBIENTE

Caio Marcelo Nunes

**Análise e classificação de *pixels* em imagens de
satélite empregando agrupamento difuso**

Anápolis - GO

2014

Caio Marcelo Nunes

Análise e classificação de *pixels* em imagens de satélite empregando agrupamento difuso

Dissertação apresentada como parte dos requisitos do Programa de Pós-Graduação *Stricto Sensu* do Centro Universitário de Anápolis, para obtenção do título de Mestre em Ciências Ambientais.

Área de concentração: Sociedade, Tecnologia e Meio Ambiente.

Linha de pesquisa: Tecnologias e Meio Ambiente.

Centro Universitário de Anápolis – UniEVANGÉLICA

Programa de Pós-Graduação em Sociedade, Tecnologia e Meio Ambiente

Orientador: Prof. Dr. Clarimar José Coelho

Coorientador: Prof. Dr. Gustavo Teodoro Laureano

Anápolis - GO

2014

N972

Nunes, Caio Marcelo.

Análise e classificação de *pixels* em imagens de satélite empregando agrupamento difuso / Caio Marcelo Nunes. – Anápolis: Centro Universitário de Anápolis – UniEvangélica, 2014. 109 p.; il.

Orientador: Prof. Dr. Clarimar José Coelho.

Dissertação (mestrado) – Programa de pós-graduação em Sociedade, Tecnologia e Meio Ambiente – Centro Universitário de Anápolis – UniEvangélica, 2014.

1. Sensoriamento remoto 2. Classificação de imagens 3. CBERS 4. Land-sat 5. Segmentação de imagens 6. *Fuzzy* I. Coelho, Clarimar José. II. Laureano, Gustavo Teodoro. III. Título.

CDU 504

Caio Marcelo Nunes

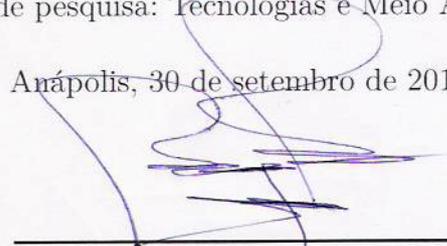
Análise e classificação de *pixels* em imagens de satélite empregando agrupamento difuso

Dissertação apresentada como parte dos requisitos do Programa de Pós-Graduação *Stricto Sensu* do Centro Universitário de Anápolis, para obtenção do título de Mestre em Ciências Ambientais.

Área de concentração: Sociedade, Tecnologia e Meio Ambiente.

Linha de pesquisa: Tecnologias e Meio Ambiente.

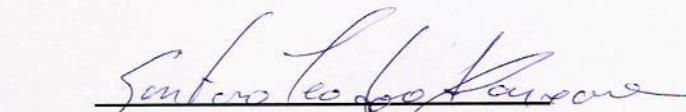
Trabalho aprovado. Anápolis, 30 de setembro de 2014:



Prof. Dr. Clarimar José Coelho

Centro Universitário de Anápolis (UniEVANGÉLICA)

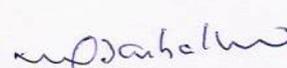
Orientador



Prof. Dr. Gustavo Teodoro Laureano

Instituto de Informática / Universidade Federal de Goiás (INF/UFG)

Coorientador



Prof.ª Dr.ª Maria Gonçalves da Silva Barbalho

Centro Universitário de Anápolis (UniEVANGÉLICA)

Professora Convidada



Prof. Dr. Anderson da Silva Soares

Instituto de Informática / Universidade Federal de Goiás (INF/UFG)

Professor Convidado

Prof. Dr. Francisco Leonardo Tejerina Garro
Centro Universitário de Anápolis (UniEVANGÉLICA)

Professor Suplente

Anápolis

2014

À minha doce mãezinha Luzia Maria (in memoriam), que plantou essa semente enquanto me ajudava nas lições de casa durante o ensino primário.

Agradecimentos

Muitas pessoas contribuíram para a realização deste trabalho. Agradeço primeiramente a Deus pela oportunidade da vida.

Um agradecimento especial aos professores e colegas do curso de mestrado do Centro Universitário de Anápolis, pelas preciosas trocas de informações e experiências, além das agradáveis e divertidas conversas.

Ao Orientador Prof. Dr. Clarimar José Coelho e ao Coorientador Prof. Dr. Gustavo Teodoro Laureano, pelo apoio, pela paciência, pelo conhecimento compartilhado e, principalmente, pelo incentivo e exemplo.

Aos colegas do Grupo de Pesquisa Computação Científica da Pontifícia Universidade Católica de Goiás (PUC Goiás)¹, pelas valiosas contribuições durante as apresentações em seminários.

Ao Prof. Me. Wagner Oliveira de Araujo, pelas preciosas orientações sobre o \LaTeX e a formatação dos trabalhos.

Ao Prof. Dr. Mauricio José Nardini, pela disponibilização de imagens de satélite utilizadas neste trabalho para os testes do protótipo de *software*.

À colega Marilyn Rocha Silva Nardini, pela amizade, pelo carinho e pelos momentos de descontração durante todo o mestrado.

Aos familiares e amigos, pelos momentos de ausência por motivo de dedicação a este trabalho.

À Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG)² e à Fundação Nacional de Desenvolvimento do Ensino Superior Particular (Funadesp)³ pelo apoio ao desenvolvimento da pesquisa.

E por fim à minha querida esposa Shirlei Nunes, que me alimentou, que me vestiu e que zelou pelos momentos de recolhimento para realizar meus estudos.

¹ Disponível em: <http://dgp.cnpq.br/dgp/espelhogrupo/3608548132333131>. Acesso em: 07 set. 2014, 12:24:30.

² Disponível em: <http://www.fapeg.go.gov.br/>. Acesso em: 15 abr. 2014, 15:18:57.

³ Disponível em: <http://www.funadesp.org.br>. Acesso em; 15 abr. 2014, 15:19:15.

*"Veja o mundo num grão de areia,
veja o céu em um campo florido,
guarde o infinito na palma da mão,
e a eternidade em uma hora de vida!"
(William Blake)*

Resumo

Esta dissertação tem como objetivo construir um protótipo de *software* que implementa o algoritmo de agrupamento difuso (*Fuzzy c-Means*, FCM) para análise e classificação dos *pixels* de imagens de satélite. O FCM é implementado como uma alternativa para o reconhecimento de áreas considerando incertezas e imprecisões existentes nas imagens. Técnicas tradicionais de agrupamento fixo são utilizadas para classificação de imagens multiespectrais da superfície terrestre. Essas técnicas reconhecem fenômenos que apresentam limites bem definidos e que podem ser facilmente discretizados. Entretanto, no mundo real existem áreas de incertezas e imprecisões, as quais podem ser mapeadas por meio de algoritmos de agrupamento que utilizam a lógica difusa. O algoritmo *c*-médias difuso é amplamente utilizado na segmentação de imagens médicas, devido à sua robustez para tratamento de ambiguidades e à sua capacidade de preservar informações da imagem original em relação aos métodos de agrupamento fixo. A metodologia apresentada neste trabalho aplica-se a imagens multiespectrais, provenientes dos sensores CBERS-2B/CCD e Landsat-5/TM, e a uma fotografia digital obtida por câmera fotográfica. Os pixels são agrupados usando FCM e, em seguida, um processo de classificação identifica os tipos de cobertura terrestre de acordo com padrões de resposta espectral da imagem de solo exposto, solo úmido, vegetação, água turva e água limpa. Os resultados obtidos indicam que o agrupamento difuso colabora na identificação de tipos de cobertura terrestre.

Palavras-chaves: sensoriamento remoto. classificação de imagens. CBERS. Landsat. segmentação de imagens. *fuzzy*.

Abstract

This paper aims to build a software prototype that implements the fuzzy clustering algorithm (Fuzzy *c*-Means, FCM) for analysis and classification of satellite images pixels. The FCM is implemented as an alternative to the recognition of areas considering uncertainties and inaccuracies in images. Traditional fixed clustering techniques are used for classification of multispectral images of the Earth's surface. These techniques recognize phenomena that have well-defined boundaries and can be easily discretized. However, in the real world there are areas of uncertainty and inaccuracy, which can be mapped by means of clustering algorithms utilizing fuzzy logic. The algorithm fuzzy *c*-means is widely used in medical image segmentation because of its robustness to treatment ambiguities and its ability to preserve the original image information with respect to a fixed grouping methods. The methodology presented in this paper applies to multispectral images, from the CBERS-2B/CCD and Landsat-5/TM sensors, and a digital photograph produced by camera. The pixels are grouped by using FCM, and then a classification process identifies the terrestrial coverage types according spectral response patterns of the image of exposed soil, moist soil, vegetation, turbid water and clean water. The results indicate that the fuzzy clustering assists in identifying types of terrestrial coverage.

Key-words: remote sensing. images classification. CBERS. Landsat. image segmentation. fuzzy.

Lista de ilustrações

Figura 1 – Curvas do comportamento espectral típico da água, vegetação e do solo exposto.	25
Figura 2 – Exemplo hipotético de <i>pixel</i> mistura em áreas de fronteiras.	33
Figura 3 – Representação digital de uma imagem multiespectral com 5 bandas espectrais.	34
Figura 4 – Identificação de órbitas/pontos das imagens captadas pelo sensor CBERS-2B/CCD no estado de Goiás.	36
Figura 5 – Metodologia para análise e classificação de <i>pixels</i> empregando agrupamento difuso.	38
Figura 6 – Imagem captada pelo sensor CBERS-2B/CCD referente à órbita 159, ponto 117, evidenciando a área recortada (em verde).	39
Figura 7 – Imagens em níveis de cinza recortadas nas bandas espectrais 1, 2, 3 e 4 do sensor CEBERS-2B/CCD.	40
Figura 8 – Imagens em níveis de cinza recortadas nas bandas espectrais 1, 2, 3 e 4 do sensor Landsat-5/TM.	41
Figura 9 – Etapas de um sistema de agrupamento difuso.	42
Figura 10 – Exemplo hipotético para funcionamento do algoritmo FCM.	46
Figura 11 – Assinaturas espectrais de alvos terrestres e sua relação com as bandas dos sensores dos satélites CBERS-2B e Landsat-5.	48
Figura 12 – Mapa de Grupos resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.	56
Figura 13 – Estatística de <i>Pixels</i> Agrupados resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.	57
Figura 14 – Variação das Diferenças Entre as Matrizes de Pertinência resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.	57
Figura 15 – Pertinência de Grupos às Classes de Alvos Terrestres resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.	58
Figura 16 – Composição RGB/342 dos recortes da Figura 7.	58
Figura 17 – Composição RGB/342 categorizada com chave de interpretação.	59
Figura 18 – Mapa de Grupos resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.	62
Figura 19 – Estatística de <i>Pixels</i> Agrupados resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.	63
Figura 20 – Variação das Diferenças Entre as Matrizes de Pertinência resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.	63

Figura 21 –Pertinência de Grupos às Classes de Alvos Terrestres resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM. .	64
Figura 22 –Imagem obtida a partir da ferramenta <i>Google Maps</i> , categorizada por alvos terrestres, correspondente geograficamente à cena obtida pelo sensor Landsat-5/TM.	65
Figura 23 –Fotografia digital submetida ao protótipo.	67
Figura 24 –Mapa de Grupos resultante da execução do protótipo sobre a fotografia digital.	67
Figura 25 –Estatística de <i>Pixels</i> Agrupados resultante da execução do protótipo sobre a fotografia digital.	68
Figura 26 –Variação das Diferenças Entre as Matrizes de Pertinência resultante da execução do protótipo sobre a fotografia digital.	68

Lista de tabelas

Tabela 1	– Características do sensor CCD do satélite CBERS-2B.	35
Tabela 2	– Características do sensor TM do satélite Landsat-5.	37
Tabela 3	– Valores difusos dos <i>pixels</i> \mathbf{x}_1 , \mathbf{x}_2 e \mathbf{x}_3 , conforme Figura 10.	47
Tabela 4	– Valores médios de reflectância de alvos terrestres nas diferentes bandas espectrais do sensor CBERS-2B/CCD.	49
Tabela 5	– Valores médios de reflectância de alvos terrestres nas diferentes bandas espectrais do sensor Landsat-5/TM.	49
Tabela 6	– Chave de interpretação para composição colorida RGB/342 de imagem do sensor CBERS-2B/CCD.	52
Tabela 7	– Áreas ocupadas pelos objetos solo exposto, solo úmido, vegetação, água turva e água limpa na cena obtida pelo sensor CBERS-2B/CCD. . . .	60
Tabela 8	– Áreas ocupadas pelos objetos reconhecidos pelo protótipo na cena obtida pelo sensor CBERS-2B/CCD.	61
Tabela 9	– Áreas ocupadas pelos objetos solo exposto, solo úmido, vegetação, água turva e água limpa na cena obtida pelo sensor Landsat-5/TM.	66
Tabela 10	– Áreas ocupadas pelos objetos reconhecidos pelo protótipo na cena obtida pelo sensor Landsat-5/TM.	66

Lista de siglas

AEE	Agência Espacial Europeia
AdFCM	Algoritmo de agrupamento FCM adaptável modificado (<i>Modified Adaptive Fuzzy c-Means Clustering Algorithm</i>)
ApFCM	FCM aproximado (<i>Approximate Fuzzy c-Means</i>)
CBERS-2B	Satélite Sino-Brasileiro de Recursos Terrestres - 2B (<i>China-Brazil Earth Resources Satellite - 2B</i>)
CCD	Sensor dispositivo de carga acoplada (<i>Charge Coupled Device</i>)
DN	Número Digital (<i>Digital Number</i>)
FAPEG	Fundação de Amparo à Pesquisa do Estado de Goiás
FCM	Algoritmo <i>c</i> -médias difuso (<i>Fuzzy c-Means algorithm</i>)
FLICM	Algoritmo de agrupamento <i>c</i> -médias com informação lógica difusa (<i>Fuzzy Logic Information c-Means Clustering</i>)
Funadesp	Fundação Nacional de Desenvolvimento do Ensino Superior Particular
GK	Algoritmo Gustafson-Kessel
GSFCM	FCM espacial generalizado (<i>Generalized Spatial Fuzzy c-Means</i>)
HFCM	FCM baseado em histograma (<i>Histogram Based Fuzzy c-Means</i>)
INPE	Instituto Nacional de Pesquisas Espaciais
ISFCM	Algoritmo FCM espacial aperfeiçoado (<i>Improved Spatial Fuzzy c-Means Algorithm</i>)
Landsat-5	Satélite de Sensoriamento Remoto Terrestre 5 (<i>Land Remote Sensing Satellite 5</i>)
MRI	Imagem de ressonância magnética (<i>Magnetic Resonance Image</i>)
MP-GO	Ministério Público do Estado de Goiás
NFCM	Novo algoritmo <i>c</i> -médias de agrupamento difuso (<i>Novel Fuzzy Clustering c-Means Algorithm</i>)
PCM	<i>c</i> -médias possibilístico (<i>Possibilistic c-Means</i>)

PDI	Processamento Digital de Imagens
PeFCM	FCM penalizado (<i>Penalized Fuzzy c-Means</i>)
PoFCM	FCM possibilístico (<i>Possibilistic Fuzzy c-Means</i>)
PUC Goiás	Pontifícia Universidade Católica de Goiás
ONU	Organização das Nações Unidas
RGB	Vermelho, verde, azul (<i>Red, Green, Blue</i>)
SFCM	FCM suprimido (<i>Suppressed Fuzzy c-Means</i>)
SOM	Mapa auto-organizável (<i>Self Organizing Map</i>)
TM	Mapeador temático (<i>Thematic Mapper</i>)

Lista de símbolos

Escalares são representados em itálico; vetores e sequências em minúsculo e negrito; e matrizes, em maiúsculo e negrito.

A	matriz de pertinência
<i>c</i>	número de grupos (<i>clusters</i>)
<i>d(a, b)</i>	função de distância que associa às tuplas (a, b) de $U \times U$ um valor numérico do conjunto \mathfrak{R}_0^+
<i>f(a, b)</i>	função bidimensional que representa a imagem digital
<i>h</i>	altura da imagem digital
<i>l</i>	largura da imagem digital
<i>k</i>	<i>k</i> -ésimo grupo
<i>m</i>	índice de difusividade ou expoente de ponderação
<i>n</i>	quantidade de pontos de dados ou <i>pixels</i> nas bandas espectrais
<i>p</i>	número de bandas espectrais
<i>t</i>	tempo ou passo do algoritmo
U	conjunto de todos os pontos de \mathfrak{R}^n
\mathbf{v}_k	centroide do <i>k</i> -ésimo grupo
X	conjunto de dados reproduzido por <i>c</i> subconjuntos (<i>clusters</i>) disjuntos via operação de união de conjuntos
(a, b)	coordenadas espaciais e inteiras de um ponto ou <i>pixel</i>
\mathbf{x}_i	vetor de valores digitais do <i>i</i> -ésimo <i>pixel</i> em <i>p</i> bandas espectrais
ε	tolerância de mudanças para cálculo de A
μ	grau de pertinência
ρ	reflectância
ϕ_i	radiação incidente
ϕ_r	radiação refletida

Neste trabalho, adota-se a terminologia sugerida por Sivanandini e Raj (2013): o termo classe vem de classificação (*classification*), onde os objetos são alocados a classes pré-definidas; e grupo vem de agrupamento (*clustering*), onde os agrupamentos são gerados sem conhecimento prévio. Assim o algoritmo de agrupamento FCM produzirá grupos a nível de *pixels* que depois serão classificados conforme o tipo de cobertura terrestre.

Sumário

1	Introdução	23
2	Pressupostos Teóricos e Metodológicos	33
2.1	Imagem Multiespectral do Sensor CBERS-2B/CCD	35
2.2	Imagem Multiespectral do Sensor Landsat-5/TM	36
2.3	Representação Matemática da Imagem Digital	37
2.4	Seleção da Área de Pesquisa	38
2.5	Agrupamento Difuso	41
2.6	Classificação da Imagem	47
2.7	Validação do Protótipo	50
3	Resultados e Discussão	53
3.1	Descrição do Protótipo	53
3.2	Experimento Sobre Imagem do Sensor CBERS-2B/CCD	55
3.3	Experimento Sobre Imagem do Sensor Landsat-5/TM	60
3.4	Experimento Sobre Fotografia Digital	66
	Conclusão	69
	Referências	73
	Apêndices	85
	APÊNDICE A Código Fonte do Protótipo	87
A.1	fAnotaClas.m	87
A.2	fAnotaGrupo.m	88
A.3	fCalcCentroides.m	89
A.4	fDDmaxPert.m	89
A.5	fDEcentCasos.m	90
A.6	fFCM.m	90
A.7	fFrequencia.m	93
A.8	fNovaPertinencia.m	93
A.9	fPertInicial.m	94
A.10	sAgrupamento.m	95
A.11	sClassificacao.m	100
A.12	sExibeCompRGB.m	103

Índice 105

1 Introdução

A análise e a classificação de imagens multiespectrais empregando o Algoritmo *c*-médias difuso (*Fuzzy c-Means algorithm*) (FCM) (HÖPPNER et al., 1999; LODWICK, 2008) tem como objetivo identificar os tipos de cobertura e uso do solo ao nível de *pixel* a partir dos padrões de resposta espectral do solo, água, área urbana, floresta, entre outros objetos que podem ser identificados nas imagens de sensores remotos orbitais (RICHARDS; JIA, 2006; SCHOWENGERDT, 2006).

Sensoriamento remoto é definido e/ou concebido como ciência ou arte de obter informações sobre objetos sem tocá-los. É a aquisição de dados físicos de um objeto sem toque ou contato. É a observação de um alvo por um dispositivo separado dele por alguma distância (CAMPBELL; WYNNE, 2008). Abriga tecnologia e conhecimentos complexos derivados de diferentes áreas como a física, botânica, engenharia eletrônica e cartografia (PAL; PETERS, 2010).

Uma imagem digital é formada por um arranjo de elementos (dígitos) organizados sob a forma de malha ou grade regular. O menor elemento da grade é chamado de *picture element* (*pixel*) (GONZALEZ; WOODS, 2000). Cada *pixel* representa uma área da superfície terrestre e é associado a um valor numérico que indica a intensidade da radiação eletromagnética refletida nessa superfície. Essa intensidade é o Número Digital (*Digital Number*) (DN).

A análise e classificação de imagens digitais de satélite consiste em identificar diferentes feições que apresentam padrões espectrais similares e que são atribuídos a uma determinada classe (RICHARDS; JIA, 2006). O processo de reconhecimento de objetos gera características dimensionais como área e comprimento dos objetos ou atributos como padrões de cores, texturas e medidas usando métodos de contagem ou frequência de *pixels* (JONG, 2008). A classificação de imagens multiespectrais associa os *pixels* da imagem a um número finito de classes que representam os objetos do mundo real com base nos seus valores digitais. Se o *pixel* satisfaz determinado conjunto de critérios, normalmente avaliados por medidas estatísticas, o *pixel* é atribuído à classe que melhor satisfaz os critérios estabelecidos (MENESES; ALMEIDA, 2012; NAVALUR, 2008).

A análise de agrupamento (*clustering*) refere-se a um grande conjunto de métodos que têm como princípio subdividir um conjunto de dados \mathbf{X} em n subconjuntos (*clusters*) disjuntos que reproduzem o conjunto \mathbf{X} via operação de união de conjuntos $\mathbf{X} = \{c_1 \cup c_2 \cup, \dots, \cup c_n\}$ (DUDA; HART, 2006). É interessante ressaltar que os dados \mathbf{X} usados neste trabalho são imagens multiespectrais. Os grupos (*clusters*) partição- c_i do conjunto \mathbf{X} , onde $i = 1, 2, \dots, n$, são denominados não *fuzzy*. O termo *fuzzy* ou difuso é

definido no contexto de uma lógica que admite valores lógicos entre o falso (0) e o verdadeiro (1) (NGUYEN; WALKER, 2006). Cada algoritmo *fuzzy* possui seu próprio critério de agrupamento para identificar o agrupamento ótimo. O algoritmo de agrupamento FCM assume que os elementos da imagem pertencem a todos os grupos com graus de pertinência diferentes e são obtidos a partir da distância entre o elemento e os centroides dos grupos (BEZDEK et al., 1982; KLAWONN; KRUSE; RUNKLER, 2010; JONG, 2008). O termo pertinência refere-se ao grau de extensão com que um elemento faz parte de um grupo (HÖPPNER et al., 1999; MIRANDA, 2011). Um elemento pode pertencer totalmente a um grupo (pertinência 1,0) ou parcialmente (por exemplo, pertinência 0,6) ou não pertencer (pertinência 0,0). Assim, um elemento pode pertencer a mais de um grupo, com graus de pertinência que variam no intervalo entre 0,0 e 1,0.

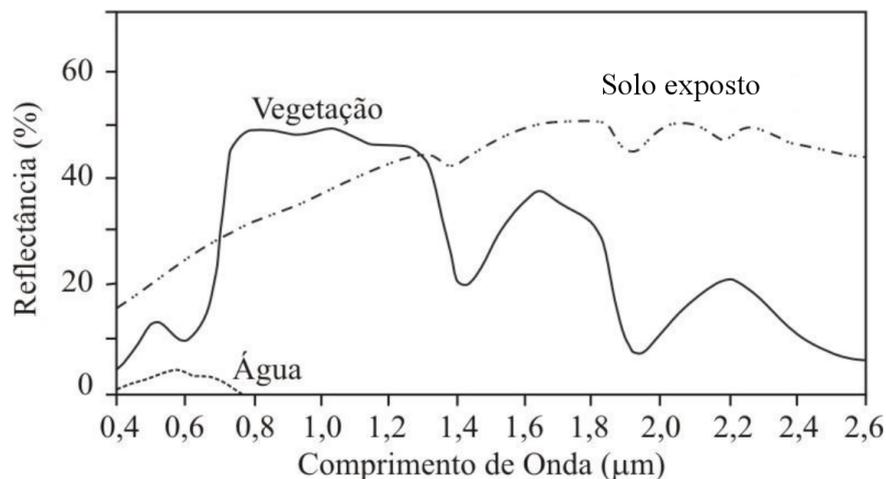
A identificação de tipos de cobertura em imagens multiespectrais empregando métodos computacionais em sensoriamento remoto é feita a partir do princípio que diferentes materiais são caracterizados por reflectâncias espectrais próprias em cada banda do espectro (MATHER; KOCH, 2011). A reflectância é definida pela proporção entre o fluxo de radiação eletromagnética incidente numa superfície e o fluxo refletido. A reflectância ou fator de reflexão ρ é proporcional à razão da radiação refletida ϕ_r pela radiação incidente ϕ_i , calculada pela expressão $\rho = \phi_r / \phi_i$ (CAMPBELL; WYNNE, 2008). Quando respostas espectrais de vários materiais são conhecidas, as propriedades de objetos desconhecidos podem ser determinadas pela comparação das respostas espectrais destes objetos com dados de referência (JENSEN, 2006; LILLESAND; KIEFER; CHIPMAN, 2007; WANG et al., 2006).

Cada objeto possui uma assinatura espectral ou intensidade relativa que cada corpo reflete ou emite nos diversos comprimentos de onda. A diferenciação e classificação dos objetos nas imagens de satélite ocorre pela caracterização dos respectivos comportamentos espectrais. Por exemplo, na Figura 1 a diferenciação da vegetação em relação a outros objetos é mais eficaz na faixa espectral do infravermelho próximo, entre 0,7 e 1,3 μm . É nesse comprimento de onda que se registram níveis máximos de reflectância para a vegetação. Ou seja, se na faixa espectral do visível, entre 0,4 e 0,7 μm , apenas se distinguem diferentes tonalidades de verde, já no infravermelho próximo as estruturas internas da vegetação contribuem para que a curva média apresentada no gráfico se eleve significativamente. O comportamento da água mostra que a maior parte da energia é absorvida; os níveis de reflectância são mais baixos entre 0,4 e 0,8 μm , o valor a partir do qual a reflectância é praticamente nula.

A coleta e o tratamento de informações geográficas sobre vegetações, cursos d'água, propriedades rurais, estradas e densidade populacional constituem atividades fundamentais para o gerenciamento dos problemas ambientais. Há bem pouco tempo essas atividades eram realizadas em documentos e mapas em papel, dificultando ou mesmo impossibili-

tando qualquer análise que envolvesse grandes volumes de dados. Essa realidade começou a mudar na segunda metade do século passado, quando a Tecnologia da Informação possibilitou o armazenamento e a representação dessas informações em meio computacional (CÂMARA et al., 2001).

Figura 1 – Curvas do comportamento espectral típico da água, vegetação e do solo exposto.



Fonte: Lillesand, Kiefer e Chipman (2007).

As imagens de satélite possibilitam o estudo e o monitoramento de fenômenos como erosões do solo, inundações, vulcanismos, desmatamentos e queimadas, sejam eles naturais ou provocados/intensificados/agravados pela ação do homem (FLORENZANO, 2002). A análise de imagens que identificam o tipo de cobertura de solo possibilita o monitoramento e o planejamento do uso sustentável dos recursos naturais. A análise pode contribuir também para o reconhecimento de áreas com atividades ilícitas, como o desmatamento ilegal ou a plantação de maconha em meio a outras culturas que dificultam sua identificação visual. Outro tema que motiva este trabalho é a identificação e o monitoramento de áreas úmidas, que são ecossistemas complexos e variados tais como lagos, manguezais, pântanos, áreas irrigadas para agricultura e reservatórios de hidrelétricas. O assunto é prioritário para a Organização das Nações Unidas (ONU), pois envolve as poucas reservas de água potável existentes, uma vez que, em todo o planeta, existe apenas 0,3 % de água doce distribuída em rios e lagos (WWF, 2011; BRASIL, 2014).

Nos métodos tradicionais para a classificação de imagens, como o *k*-médias (*k-means*) proposto primeiramente por MacQueen (1967), considera-se o *pixel* puro ou homogêneo. O *pixel* é associado a uma única classe o que pode levar à perda de detalhes e consequente geração de uma imagem classificada incorretamente. O *pixel* pode representar um padrão de cobertura complexo, ou seja, uma mistura de classes.

Já os métodos baseados em lógica *fuzzy* ou difusa são usados no processamento de imagens como uma boa ferramenta para a representação de incertezas provenientes do

processo de classificação. Por intermédio da lógica difusa é possível modelar a atividade de percepção dos seres humanos, representando informações como alto, médio, baixo, quente, pouco quente, frio, por exemplo (RICHTER, 2004; SIVANANDAM; SUMATHI; DEEPA, 2006).

Algoritmos de agrupamento difuso combinam lógica *fuzzy* e análise de agrupamento e apresentam vantagens sobre os algoritmos tradicionais de agrupamento fixo baseados no raciocínio clássico e permitem que os objetos sejam atribuídos a um ou mais grupos/conjuntos a partir da análise de uma probabilidade de pertinência (GAN; MA; WU, 2007). Em muitas situações reais como na classificação de objetos em imagens, restringir a pertinência de um objeto a um único grupo constitui uma tarefa difícil e sujeita a erros (MESAKAR; CHAUDHART, 2013). Essa situação prática motiva o emprego do agrupamento difuso onde cada objeto da imagem pertence a mais de um grupo e a pertinência a um ou outro grupo varia de forma contínua entre falso (0) e verdadeiro (1) (MIRANDA, 2011).

Algoritmos de agrupamento difuso são amplamente estudados e aplicados em diversas áreas como: medicina (LIEW; YAN, 2003; CHUANG et al., 2006; TRIPOLITI; FOTIADIS; ARGYROPOULOU, 2007; LUNG; KIM, 2009; BEEVI; SATHIK, 2010; BEGUM; DEVI, 2011), geologia (MOREIRA; FILHO; CÂMARA, 2002; NOLASCO-CARVALHO; FRANCA-ROCHA; UCHA, 2009; AN; MOON; RENCZ, 1991), negócios (BORBA; MURCIA; MAIOR, 2007; GANGA; CARPINETTI; POLITANO, 2011; BOJADZIEV; BOJADZIEV, 2007), sistemas de engenharia (OLIVEIRA; AMENDOLA; NÄÄS, 2005; RAO et al., 1992; ROSS, 2004), taxonomia (BEZDEK, 1974; WEI; CHEN, 1999; HERRERA, 2008) e processamento de imagens (PAL; PAL, 1993; KELLER; KRISNAPURAM; PAL, 2005; SONKA et al., 2008), convertendo-se nas principais técnicas em análise de agrupamento.

O FCM é um dos algoritmos de agrupamento difuso mais populares e amplamente utilizado em vários trabalhos de reconhecimento de padrões, mineração de dados (*data mining*) e processamento de imagens (YAMBAL; GUPTA, 2013). O FCM apresenta resultados significativos na segmentação de imagens médicas devido a sua robustez para tratamento de ambiguidades e a sua capacidade de preservar informação sobre a imagem original em relação aos métodos de agrupamento fixo (BEZDEK; HALL; CLARKE, 1993; PHAM; PRINCE, 1999; CHEN; GIGER; BICK, 2006; NAZ; MAJEED; IRSHAD, 2010; BEGUM; DEVI, 2011). As vantagens do FCM incluem implementação clara, robustez, aplicabilidade a dados multiespectrais e capacidade de modelar incertezas (SHAMSI; SEYEDARABI, 2012). Nas últimas décadas, o sucesso do FCM na segmentação de imagens é devido à introdução da difusividade na pertinência de cada *pixel* da imagem (GANESH; PALANISAMY, 2012).

As primeiras noções de lógica *fuzzy* (ou multivalorada) foram introduzidas em

1920 pelo filósofo e lógico polonês Lukasiewicz (1878-1956), que propôs a utilização do intervalo de valores $[0, 1]$ para indicar a possibilidade de uma declaração ser falsa ou verdadeira (LUKASIEWICZ; TARSKI, 1930).

Em 1965, Zadeh publicou o artigo *Fuzzy Sets*, quando a lógica *fuzzy* recebeu este nome. Zadeh redescobriu a ideia de difusividade (*fuzzification*), identificou e combinou os conceitos da lógica clássica e dos conjuntos de Lukasiewicz e Tarski, definindo os graus de pertinência. Zadeh observou que recursos tecnológicos, baseados na lógica booleana, não são suficientes para automatizar atividades relacionadas a problemas de natureza industrial, biológica ou química, por compreenderem situações ambíguas e imprecisas (ZADEH, 1965). Isso acontece com classes de objetos no mundo real que não possuem um critério preciso de pertinência. É o caso, por exemplo, da classe animais que claramente inclui membros como cães, gatos, peixes. Entretanto, objetos como estrela-do-mar, bactéria possuem uma ambiguidade na classe animais. Desde então o agrupamento difuso tem sido amplamente discutido, estudado e aplicado em diversas áreas (GAN; MA; WU, 2007).

Os primeiros trabalhos aplicando a teoria de conjuntos difusos na análise de agrupamento foram propostos por Bellman, Kalaba e Zadeh (1966) e por Ruspini (1969). O agrupamento difuso (*fuzzy clustering*) baseado em relações difusas (*fuzzy relations*) foi proposto primeiramente por Tamura, Higuchi e Tanaka (1971). Relações difusas são relações que exprimem o grau de intensidade da associação entre os elementos de dois ou mais conjuntos difusos (TANSCHKEIT, 2004; YAGUINUMA, 2013).

O algoritmo *k*-médias (*k-means*) é um dos mais utilizados para fazer agrupamento de objetos inclusive em Processamento Digital de Imagens (PDI) aplicado ao sensoriamento remoto (GAN; MA; WU, 2007; MIRANDA, 2011). Também chamado de *hard c-means* (YANG, 1993), o algoritmo *k-means* foi concebido para agrupar dados numéricos e atribuir cada objeto ao grupo *k* com média (*mean*) ou centroide mais próximo.

Höppner et al. (1999) dedica um livro inteiro à análise de agrupamento difuso e classifica os algoritmos em dois grupos: i) Clássico e ii) Baseado-em-forma (*shape-based*). Existem muitos algoritmos clássicos de agrupamento difuso, dentre os quais se destacam: i) FCM (BEZDEK; EHRLICH; FULL, 1984), ii) FCM suprimido (*Suppressed Fuzzy c-Means*) (SFCM) (FAN; ZHEN; XIE, 2003), iii) *c*-médias possibilístico (*Possibilistic c-Means*) (PCM) (KRISHNAPURAM; KELLER, 1993), e iv) Algoritmo Gustafson-Kessel (GK) (GUSTAFSON; KESSEL, 1978). Os algoritmos de agrupamento difuso baseado-em-forma incluem: i) Baseado-em-forma circular (MAN; GATH, 1994), ii) Baseado-em-forma elíptica (GATH; HOORY, 1995), e iii) Baseado-em-forma genérica (ALI; DOOLEY; KARMAKAR, 2006).

O algoritmo FCM foi descrito pela primeira vez na literatura por Dunn (1974). Dunn apresenta o método *c-means* convencional (*hard*), popularmente conhecido como *k*-

means, combinando com a ideia das partições-*c* difusas de Ruspini (1969). Uma partição-*c* difusa (*fuzzy c-partition*) de um conjunto de dados \mathbf{X} descreve a pertinência de cada elemento em todos os grupos por meio de uma função de pertinência que varia no intervalo $[0, 1]$ (BEZDEK; EHRLICH; FULL, 1984). O trabalho de Dunn define um grau de difusividade $m = 2$, mas o caso geral para um grau de difusividade $m > 1$ foi desenvolvido por Bezdek (1973) em sua tese de doutorado na Universidade de Cornell. O grau de difusividade m controla o processo de difusividade das partições resultantes da aplicação do método. Posteriormente outras generalizações foram apresentadas por Gustafson e Kessel (1978) e Bezdek et al. (1981).

Huntsberger e Descalzi (1985) apresentam trabalhos que usam o FCM para a detecção de bordas no contexto da análise e classificação de imagens coloridas. Detecção de borda é uma operação que detecta descontinuidade significativa na intensidade dos níveis de cinza dos *pixels* de imagens (SILVA et al., 2009).

Cannon et al. (1986) publicam trabalhos onde mostram a aplicação do algoritmo FCM para segmentação de imagem do sensor Mapeador temático (*Thematic Mapper*) (TM), que é um dos sensores do Satélite de Sensoriamento Remoto Terrestre 5 (*Land Remote Sensing Satellite 5*) (Landsat-5) (QUARTAROLI; BATISTELLA, 2005). Segmentação de imagem é o processo de particionar uma imagem digital em múltiplos segmentos formados por conjuntos de *pixels* (BEGUM; DEVI, 2011). Trivedi e Bezdek (1986) desenvolvem uma metodologia para segmentação de baixo nível utilizando agrupamento difuso. Os resultados mostram que o FCM pode ser usado para separar regiões de mistura de classes em regiões menores e homogêneas. Cannon, Dave e Bezdek (1986) propõem a implementação do FCM aproximado (*Approximate Fuzzy c-Means*) (ApFCM) para reduzir a carga de processamento do algoritmo original, sobretudo para processar grandes conjuntos de dados. A nova abordagem se baseia na substituição de cálculos iterativos presentes no FCM original por tabelas internas com valores aproximados (*lookup tables*). Embora os resultados indiquem que o ApFCM tem melhor desempenho, o trabalho sugere estudos mais aprofundados para comprovar a superioridade em relação ao FCM original.

Pal et al. (2005) apresentam uma versão do FCM possibilístico (*Possibilistic Fuzzy c-Means*) (PoFCM) que combina as funções objetivo do PCM e do FCM, reduzindo efetivamente a influência de ruídos e de *outliers* nos resultados do agrupamento. Ruídos são variações aleatórias de intensidade no sinal da imagem, que contribuem para reduzir a visualização de detalhes, principalmente de objetos pequenos e de baixo contraste (OLIVEIRA et al., 2007). *Outlier* é um objeto que está isolado, suficientemente diferente dos demais objetos (JAIN; DUBES, 1988).

Mingoti e Lima (2006) apresentam uma comparação entre os algoritmos de rede neural Mapa auto-organizável (*Self Organizing Map*) (SOM), FCM, *k-means* e métodos tradicionais de agrupamento hierárquico. A comparação demonstrou que o algoritmo

FCM obteve melhor desempenho em relação aos demais, mesmo na presença de *outliers* e de sobreposição de grupos. A sobreposição de grupos é conhecida como *overlapping*, que é a situação em que grupos de objetos possuem algum grau de sobreposição, apesar de apresentarem distribuições estatísticas distintas e possivelmente bem definidas (VENDRAMIN, 2012). Algoritmos de agrupamento *fuzzy* de dados lidam com esse tipo de problema, pois buscam encontrar grupos difusos (*fuzzy clusters*) onde cada objeto possui graus de pertinência em relação a todos os grupos (HÖPPNER et al., 1999).

Yang e Huang (2007) apresentam o algoritmo FCM penalizado (*Penalized Fuzzy c-Means*) (PeFCM), que incorpora informações da vizinhança espacial do *pixel* ao algoritmo FCM original por meio de um fator de penalidade. O fator de penalidade atua como um regulador no algoritmo FCM original, levando em conta a influência dos *pixels* vizinhos sobre os *pixels* centrais. Apesar dos resultados mostrarem que o PeFCM é efetivo e mais robusto que o FCM original, os autores sugerem a necessidade de maiores estudos para adaptar o parâmetro de penalidade do algoritmo, que é determinado de forma experimental. Tripoliti, Fotiadis e Argyropoulou (2007) propõe um método automatizado composto de quatro estágios e baseado na segmentação de Imagem de ressonância magnética (*Magnetic Resonance Image*) (MRI) utilizando o algoritmo FCM. O método foi aplicado com sucesso em um conjunto de 504 imagens referentes a 25 pacientes com artrite reumatoide, colaborando para a redução de falsos diagnósticos e a detecção de inflamações que não eram percebidas.

Zhou et al. (2008) apresentam o método FCM baseado em deslocamento médio (*Mean Shift Based FCM*) para extração de lesões da pele. Nesse trabalho, uma expressão com a área média é incorporada à função objetivo do FCM original. Resultados experimentais mostram que esse algoritmo é hábil na extração das delimitações de lesões da pele, mas não há testes sobre imagens de satélite.

Sudhavani e Sathyaprasad (2009) apresentam uma modificação do FCM para segmentação de imagens labiais. Também Kannan, Ramathilagam e Sathya (2009) propõem um aperfeiçoamento do FCM para a segmentação de MRI do tórax. Lung e Kim (2009) desenvolveram um algoritmo de agrupamento FCM espacial generalizado (*Generalized Spatial Fuzzy c-Means*) (GSFCM) para segmentação de MRI do cérebro. O GSFCM utiliza atributos do *pixel* e informações espaciais locais baseadas em seus atributos de distância. Os resultados mostram que o GSFCM supera o FCM convencional na segmentação desse tipo de imagem.

Kannan et al. (2010) propõem um Novo algoritmo *c*-médias de agrupamento difuso (*Novel Fuzzy Clustering c-Means Algorithm*) (NFCM) voltado para a estimativa de intensidades não homogêneas ou tendências ponderadas e a segmentação de MRI também do cérebro. A vantagem do NFCM é que ele pode ser aplicado em uma fase inicial da análise de dados automatizada. O NFCM é útil para lidar com intensidades não homogêneas e

ruídos presentes na imagem.

Beevi e Sathik (2010) apresentam uma técnica de agrupamento que explora o algoritmo FCM baseado em histograma (*Histogram Based Fuzzy c-Means*) (HFCM) para a segmentação de imagens médicas. O HFCM converge mais rapidamente ao agrupar o histograma da imagem em vez de agrupar toda a imagem. O algoritmo primeiro remove ruídos das imagens e depois realiza a segmentação. Os ruídos são removidos por intermédio da filtragem colaborativa domínio-transformado 3D esparsa (*sparse 3D transform-domain collaborative filtering*) (DABOV et al., 2007). O histograma da imagem é usado para inicializar os parâmetros do FCM e evitar a convergência para valores mínimos. Uma probabilidade espacial é incorporada na função objetivo para intensificar a robustez do algoritmo contra ruídos. Essa abordagem converge mais rápido do que o FCM convencional e obtém uma segmentação confiável isenta de níveis de ruído na aplicação em imagens médicas.

Em outro trabalho semelhante, Beevi, Sathik e Senthamaraikannan (2010) propõem um Algoritmo FCM espacial aperfeiçoado (*Improved Spatial Fuzzy c-Means Algorithm*) (ISFCM). O HFCM novamente é utilizado para inicializar os parâmetros de entrada do ISFCM. A informação espacial é incorporada ao FCM convencional utilizando-se uma probabilidade *a priori*. A probabilidade *a priori* mostra a influência espacial dos *pixels* vizinhos sobre o *pixel* central, que é automaticamente decidida no algoritmo de pertinência difusa. Ao incorporar a informação espacial, o ISFCM pode superar a sensibilidade a ruído apresentada pelo FCM convencional. A principal vantagem do ISFCM é a sua simplicidade e a possibilidade de ser aplicado sobre grandes conjuntos de dados, que no caso desse trabalho são imagens médicas.

Krinidis e Chatzis (2010) apresentam o Algoritmo de agrupamento *c*-médias com informação lógica difusa (*Fuzzy Logic Information c-Means Clustering*) (FLICM) para superar as desvantagens do FCM convencional, embora nesse trabalho sejam utilizadas imagens sintéticas e fotos do mundo real. No FLICM é introduzido um novo fator na função objetivo do FCM, conferindo mais robustez ao agrupamento, além das seguintes características: insensibilidade a ruídos; preservação de detalhes da imagem original; liberdade para seleção de parâmetros; e pode ser aplicado diretamente sobre a imagem de entrada, sem exigir qualquer pré-processamento. Na ausência de qualquer conhecimento prévio de ruídos, o FLICM é uma ótima estratégia para agrupamento em imagens (NAZ; MAJEED; IRSHAD, 2010).

Begum e Devi (2011) publicam um estudo que destaca o algoritmo FCM dentre vários métodos baseados na lógica *fuzzy* para o reconhecimento de padrões em imagens de ressonância magnética e a colaboração em diagnósticos e prognósticos médicos.

Shamsi e Seyedarabi (2012) propõem uma modificação do FCM para utilização de informações espaciais aplicadas em MRI do cérebro. Outro trabalho publicado por

Ganesh e Palanisamy (2012) apresenta o Algoritmo de agrupamento FCM adaptável modificado (*Modified Adaptive Fuzzy c-Means Clustering Algorithm*) (AdFCM) também para segmentação de MRI do cérebro, considerando a intensidade luminosa global da imagem para realização do agrupamento.

Diante do que foi exposto, o objetivo geral deste trabalho é construir um protótipo de *software* empregando ferramentas livres¹, que possam ser utilizadas por outros pesquisadores independentemente de licenças de *software* proprietário². Os objetivos específicos são:

- Desenvolver uma metodologia para análise e classificação de *pixels* em imagens de satélite empregando o algoritmo de agrupamento difuso FCM, considerando que o processo de classificação é realizado por meio de conhecimento do comportamento espectral de objetos na superfície terrestre.
- Identificar nas imagens de satélite os seguintes objetos: solo exposto, solo úmido, vegetação, água turva e água limpa.
- Estimar a área ocupada pelos objetos identificados.

É utilizada no teste do protótipo uma imagem digital multiespectral adquirida pelo sensor Satélite Sino-Brasileiro de Recursos Terrestres - 2B (*China-Brazil Earth Resources Satellite - 2B*) (CBERS-2B)/Sensor dispositivo de carga acoplada (*Charge Coupled Device*) (CCD), que possui resolução espacial moderada de 20 m e que foi disponibilizada diretamente pelo Instituto Nacional de Pesquisas Espaciais (INPE)³. Outra imagem utilizada foi adquirida pelo sensor Landsat-5/TM, que possui uma resolução espacial de 30 m, disponibilizada também pelo INPE por intermédio do Ministério Público do Estado de Goiás (MP-GO)⁴. Também foi submetida ao protótipo uma fotografia digital para verificar a aplicação do método de agrupamento difuso nesse tipo de imagem. Resultados preliminares indicam a boa capacidade do FCM para distinguir grupos de objetos na superfície terrestre.

O protótipo de software desenvolvido para a análise e classificação de imagens multiespectrais empregando agrupamento difuso é implementado no ambiente GNU/Octave⁵ e será disponibilizado no Laboratório de Geoprocessamento do Programa de Pós-Graduação em Sociedade, Tecnologia e Meio Ambiente da UniEVANGÉLICA⁶.

¹ *Software* livre: programa de computador que pode ser copiado, usado e distribuído livremente.

² *Software* proprietário: programa de computador que requer o pagamento de licença para ser usado. Não pode ser copiado e nem distribuído sem a autorização do desenvolvedor/proprietário.

³ Disponível em: <http://www.inpe.br/>. Acesso em: 22 abr. 2014, 15:13:07.

⁴ Disponível em: <http://www.mpggo.mp.br/>. Acesso em: 26 ago. 2014, 20:38:15.

⁵ Disponível em: <https://www.gnu.org/software/octave/>. Acesso em: 15 abr. 2014, 16:42:35.

⁶ Disponível em: <http://www.unievangelica.edu.br/mestradostm/>. Acesso em: 22 abr. 2014, 15:15:37.

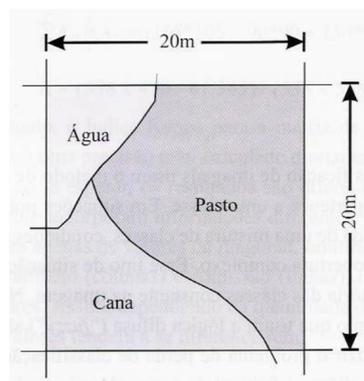
Esta dissertação é dividida em 3 capítulos, sendo o primeiro a Introdução, onde é apresentado o tema e os objetivos da pesquisa. No segundo capítulo são discutidas as limitações dos métodos tradicionais de agrupamento fixo, os dados disponíveis para análise e classificação de imagens, propõe uma forma adequada de tratar os *pixels* não homogêneos, apresenta o método FCM original e os procedimentos de agrupamento e classificação de *pixels* a partir do comportamento espectral dos objetos de interesse para este trabalho. É apresentado também o método de interpretação visual para validação de resultados do protótipo. No terceiro capítulo são apresentados os resultados obtidos e a discussão dos resultados. Por fim, a Conclusão evidencia as vantagens e limitações do FCM, além de apresentar sugestões para trabalhos futuros.

2 Pressupostos Teóricos e Metodológicos

Algoritmos de classificação de imagens costumam utilizar métodos de agrupamento fixo onde cada *pixel* pertence a uma única classe. No entanto, o *pixel* pode representar uma única classe ou uma mistura de classes. Essa situação conduz a uma classificação inadequada das classes de objetos como água, vegetação e solo exposto, presentes na imagem. Uma classe de cobertura de solo possui características espectrais que dependem do processo de interação entre a radiação eletromagnética e as propriedades físico-químicas do material daquela classe de cobertura. Quando o *pixel* contém apenas uma classe de cobertura, como pasto por exemplo, então armazenam-se somente as características espectrais dessa classe. Por outro lado, quando o *pixel* contém uma mistura de classes de cobertura, como pasto e cana-de-açúcar por exemplo, então o valor do *pixel* é resultante da reflectância da mistura dos componentes dessas classes (MIRANDA, 2011).

A mistura ocorre sempre que a área no terreno coberta por um único *pixel* inclui duas ou mais classes espectrais. A Figura 2 ilustra um exemplo hipotético, mas possível, de *pixel* mistura contendo áreas de água, cana-de-açúcar e pasto. Nessa situação, o *pixel* armazena valores de mais de uma classe e ocorre principalmente em áreas de fronteiras entre diferentes alvos terrestres (FISHER; PATHIRANA, 1993).

Figura 2 – Exemplo hipotético de *pixel* mistura em áreas de fronteiras.



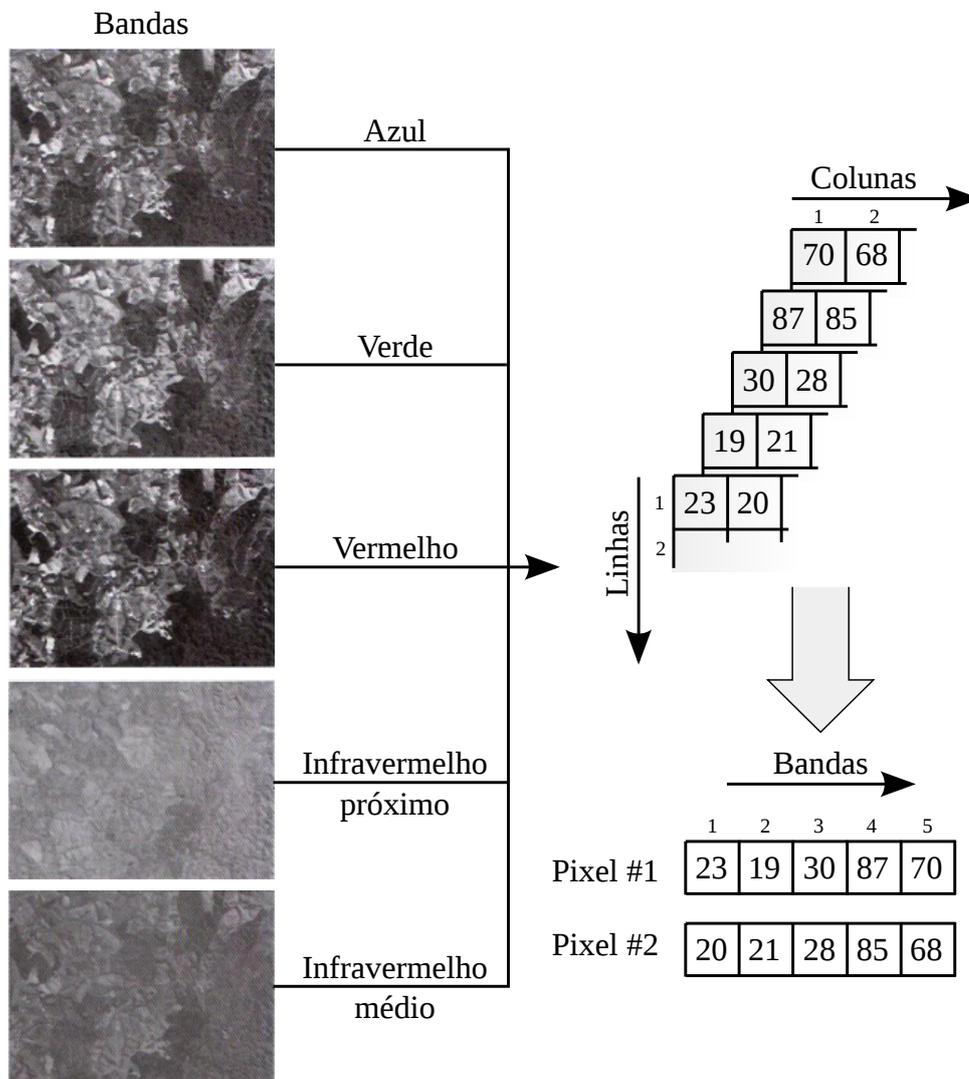
Fonte: Miranda (2011).

O problema do *pixel* mistura, decorrente da resolução espacial do sensor do satélite, aumenta de acordo com o próprio tamanho do *pixel* da imagem. Quanto maior for o tamanho do *pixel*, maior também será a ocorrência de *pixels* mistura em imagens com padrão de cobertura complexo. Essas imagens apresentam uma resolução espacial de média (20 até 80 m) a grande (maior que 80 m) (MIRANDA, 2011). É o caso das imagens do sensor CBERS-2B/CCD que possuem uma resolução espacial de 20 m, e também do sensor Landsat-5/TM que fornece imagens com resolução espacial de 30 m, tamanho

suficiente para apresentar situações como a que foi descrita na Figura 2.

O presente trabalho baseia-se em técnicas de PDI para manipulação de imagens digitais no sentido de facilitar a extração de informações. Realiza-se o processamento digital para agrupar e classificar *pixels* em imagens, manipulando tanto os dados de imagem pancromática, que representa as feições em uma única faixa do espectro solar, como também de imagem multiespectral (Figura 3), que representa as feições em várias faixas do espectro solar (PETROU; PETROU, 2010). A imagem multiespectral consiste em imagens de um mesmo objeto, tomadas com diferentes comprimentos de ondas eletromagnéticas (NAVULUR, 2006).

Figura 3 – Representação digital de uma imagem multiespectral com 5 bandas espectrais.



Fonte: Miranda (2011).

2.1 Imagem Multiespectral do Sensor CBERS-2B/CCD

As imagens do satélite CBERS-2B fornecidas pelo INPE são processadas em 5 níveis diferentes de correção, numerados de 0 a 4. O nível 0 representa a imagem em dados brutos sem qualquer alteração no valor dos *pixels*. Ela é recebida diretamente pela estação de recepção do INPE. Contém dados não calibrados e informação adicional sobre atitude e efemérides do satélite, ou seja, o posicionamento, a velocidade e a orientação espacial. Essa imagem é arquivada pelo INPE em formato específico para uso interno. No nível 1, a imagem resulta de processo de correção radiométrica. Esse processo inclui basicamente calibração relativa e correção de *pixels* defeituosos. A imagem de nível 2 é corrigida geometricamente usando os parâmetros do satélite e sem o uso de pontos de controle. Trata-se da imagem básica disseminada pelo INPE, em formato GeoTIFF e que é utilizada neste trabalho para o teste do protótipo. No nível 3, a imagem passa por procedimentos adicionais de correção geométrica com o uso de pontos de controle. Isso permite a localização dos elementos lineares na imagem, em um terreno plano, com precisão compatível com o padrão de exatidão cartográfica. A imagem de nível 4 é ortorretificada. Isso significa que é refinada pelo uso de modelo digital de elevação, e compatível com aplicações que requerem uma modelagem cartográfica acurada em qualquer tipo de terreno (INPE, 2005).

A Tabela 1 descreve as principais características do sensor CBERS-2B/CCD. São utilizadas as bandas espectrais 1, 2, 3 e 4, cujos intervalos distintos de comprimento de onda influenciam na diferenciação das respostas espectrais dos objetos. A resolução espacial de 20 x 20 m expressa o tamanho do *pixel* e possibilita o cálculo das áreas classificadas. A largura da faixa imageada de 113 km indica a extensão total de cada imagem obtida pelo sensor do satélite.

Tabela 1 – Características do sensor CCD do satélite CBERS-2B.

Característica	Descrição
Bandas espectrais	(1) 0,45 - 0,52 μm (azul) (2) 0,52 - 0,59 μm (verde) (3) 0,63 - 0,69 μm (vermelho) (4) 0,77 - 0,89 μm (infravermelho próximo)
Resolução espacial	20 x 20 m
Largura da faixa imageada	113 km

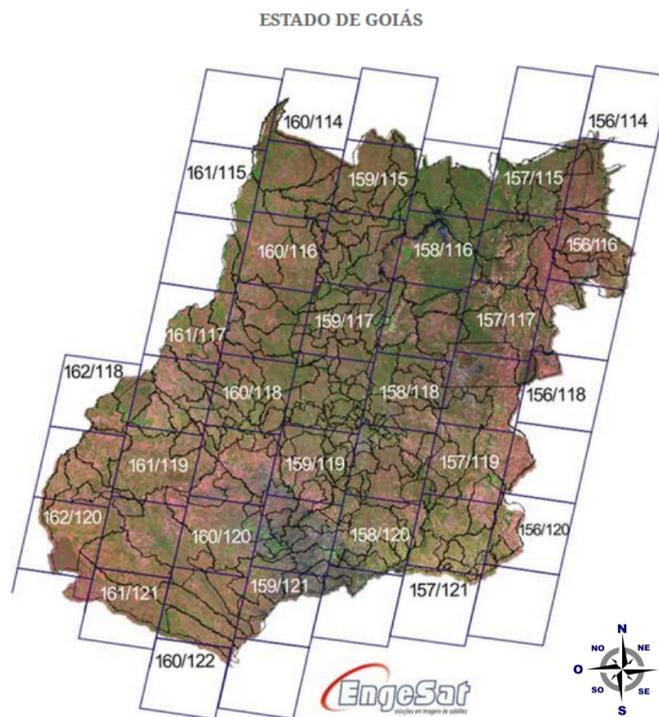
Fonte: INPE (2011).

A Figura 4 mostra um mosaico das cenas (quadriláteros numerados) identificadas pelo binômio órbita/ponto no Estado de Goiás.

A primeira cena utilizada para teste do protótipo localiza-se na órbita 159, ponto 117 (região do Vale do São Patrício, compreendendo os municípios de São Luiz do Norte, Itapaci, Nova Glória, Santa Isabel, Ceres, Goianésia, Uruana e Itapuranga, todos loca-

lizados no estado de Goiás), na data de 25/06/2008, com 0% de cobertura de nuvens, faixa espectral das bandas 1, 2, 3 e 4 (azul, verde, vermelho e infravermelho próximo) e resolução espacial nominal de 20 m. A imagem possui uma área de 113 x 113 km, totalizando 12.769 km² (INPE, 2009). Essa região foi escolhida porque reúne municípios de interesse para pesquisas do Programa de Pós-Graduação em Sociedade, Tecnologia e Meio Ambiente do Centro Universitário de Anápolis.

Figura 4 – Identificação de órbitas/pontos das imagens captadas pelo sensor CBERS-2B/CCD no estado de Goiás.



Fonte: ENGESAT (2006).

2.2 Imagem Multiespectral do Sensor Landsat-5/TM

A segunda cena utilizada para teste do protótipo é obtida pelo sensor Landsat-5/TM e localiza-se na órbita 222, ponto 71, região da represa do Ribeirão João Leite, entre os municípios de Goiânia e Anápolis no estado de Goiás, na data de 20/10/2011, com 0% de cobertura de nuvens, faixa espectral das bandas 1, 2, 3 e 4 (azul, verde, vermelho e infravermelho próximo) e resolução espacial nominal de 30 m. A imagem possui uma área de 185 x 185 km, totalizando 34.225 km² (INPE, 2008). Essa região foi escolhida porque apresenta corpos d'água que podem ser visualizados por meio da ferramenta *Google Maps* e comparados com os resultados do protótipo.

A Tabela 2 descreve as principais características do sensor Landsat-5/TM e todas as suas bandas espectrais. A imagem obtida para este trabalho contém somente as bandas

1, 2, 3 e 4.

Tabela 2 – Características do sensor TM do satélite Landsat-5.

Característica	Descrição
Bandas espectrais	(1) 0,45 - 0,52 μm (azul) (2) 0,52 - 0,60 μm (verde) (3) 0,63 - 0,69 μm (vermelho) (4) 0,76 - 0,90 μm (infravermelho próximo) (5) 1,55 - 1,75 μm (infravermelho médio) (6) 10,4 - 12,5 μm (infravermelho termal) (7) 2,08 - 2,35 μm (infravermelho distante)
Resolução espacial	30 x 30 m (bandas 1, 2, 3, 4, 5 e 7) 120 x 120 m (banda 6)
Largura da faixa imageada	185 km

Fonte: INPE (2008).

2.3 Representação Matemática da Imagem Digital

Do ponto de vista matemático, a imagem digital é representada por uma função bidimensional $f(a, b)$, onde (a, b) são coordenadas espaciais e inteiras, definidas por convenção como $a = [1, 2, 3, \dots, l]$ e $b = [1, 2, 3, \dots, h]$. Os limites l e h representam a largura e a altura da imagem, respectivamente. A amplitude de f em qualquer par de coordenadas a e b é proporcional à intensidade da radiação eletromagnética (ou nível de cinza) da imagem naquele ponto. A imagem digital é caracterizada pelo fato dos valores de a , b e da amplitude de f serem quantidades finitas e discretas (GONZALEZ; WOODS, 2000).

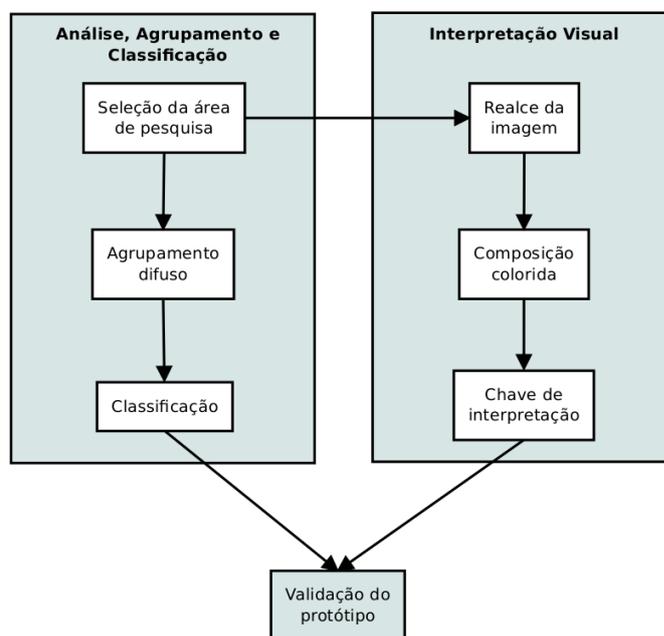
As imagens digitais podem passar por tratamentos estatísticos e algébricos. É possível calcular, por exemplo, o valor médio e o desvio padrão dos *pixels* presentes em cada banda; assim como se pode somar, subtrair, dividir ou multiplicar os valores dos *pixels*. De uma forma geral, o tratamento estatístico nos *pixels* das bandas pode ser: univariado, bivariado e multivariado. O primeiro se aplica a cada banda isoladamente. O segundo estuda as bandas de par-em-par. Já o tratamento multivariado, que é a abordagem deste trabalho, utiliza-se de métodos estatísticos e algébricos para analisar simultaneamente múltiplas (maior ou igual a duas) medidas ou variáveis, em cada observação sob investigação (MIRANDA, 2011).

A metodologia proposta neste trabalho inclui as seguintes fases: análise, agrupamento de *pixels* e classificação; interpretação visual e validação do protótipo. A Figura 5 ilustra os passos metodológicos deste trabalho, que são detalhados nas seções seguintes.

2.4 Seleção da Área de Pesquisa

Com relação à primeira cena submetida ao protótipo, na imagem de satélite mostrada na Figura 6 é selecionada e recortada uma área que se localiza entre as coordenadas geográficas de latitude $15^{\circ} 01' 12'' S$ e longitude $49^{\circ} 37' 30'' O$ (canto superior esquerdo), latitude $15^{\circ} 05' 16'' S$ e longitude $49^{\circ} 33' 33'' O$ (canto inferior direito), datum WGS84. Essa área selecionada está representada pelo quadrado em tom de verde. A imagem resultante possui 352×378 *pixels*, totalizando uma área de $53,22 \text{ km}^2$.

Figura 5 – Metodologia para análise e classificação de *pixels* empregando agrupamento difuso.



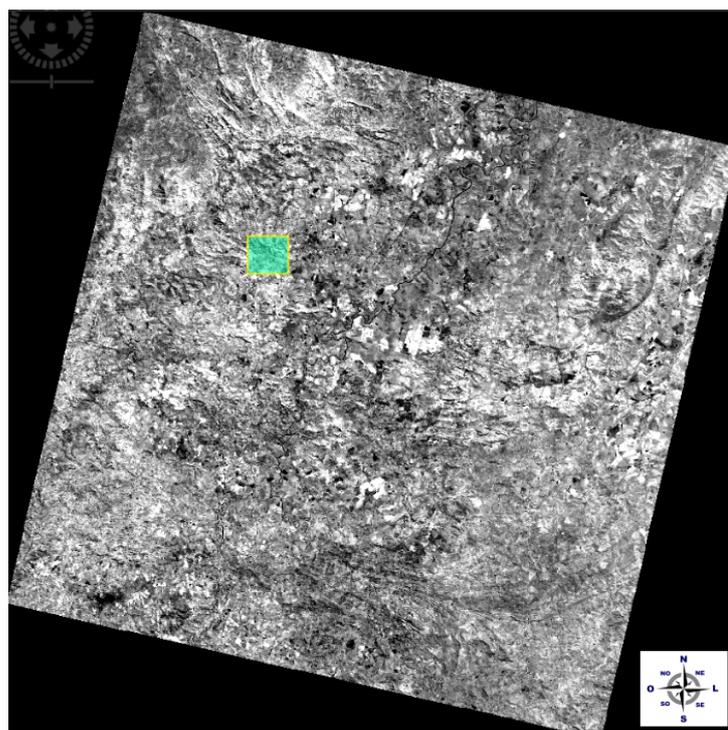
Fonte: elaborado pelo autor.

A Figura 7 mostra as imagens resultantes do recorte efetuado sobre a imagem multiespectral da Figura 6. Essas imagens estão em níveis de cinza com resolução radiométrica de 8 *bits*, ou seja, o valor digital de cada *pixel* pode variar de 0 a 255. Cada imagem da Figura 7 representa uma banda da imagem multiespectral recortada. A imagem a) corresponde à banda 1 e representa a reflectância dos objetos na faixa espectral do azul ($0,45 - 0,52 \mu\text{m}$). A imagem b) corresponde à banda 2 e representa a reflectância dos objetos na faixa espectral do verde ($0,52 - 0,59 \mu\text{m}$). A imagem c) corresponde à banda 3 e representa a reflectância dos objetos na faixa espectral do vermelho ($0,63 - 0,69 \mu\text{m}$). A imagem d) corresponde à banda 4 e representa a reflectância dos objetos na faixa espectral do infravermelho próximo ($0,77 - 0,89 \mu\text{m}$).

Com relação à segunda cena submetida ao protótipo, na imagem de satélite é selecionada e recortada uma área que se localiza entre as coordenadas geográficas de latitude $16^{\circ} 32' 45'' S$ e longitude $49^{\circ} 13' 15'' O$ (canto superior esquerdo), latitude

16° 34' 15" S e longitude 49° 11' 20" O (canto inferior direito), datum WGS84. A imagem resultante possui 1.736 x 1.364 *pixels*, totalizando uma área de 2.131,11 km², ou seja, uma cena com área cerca de 40 vezes maior do que a área da primeira cena submetida ao protótipo.

Figura 6 – Imagem captada pelo sensor CBERS-2B/CCD referente à órbita 159, ponto 117, evidenciando a área recortada (em verde).



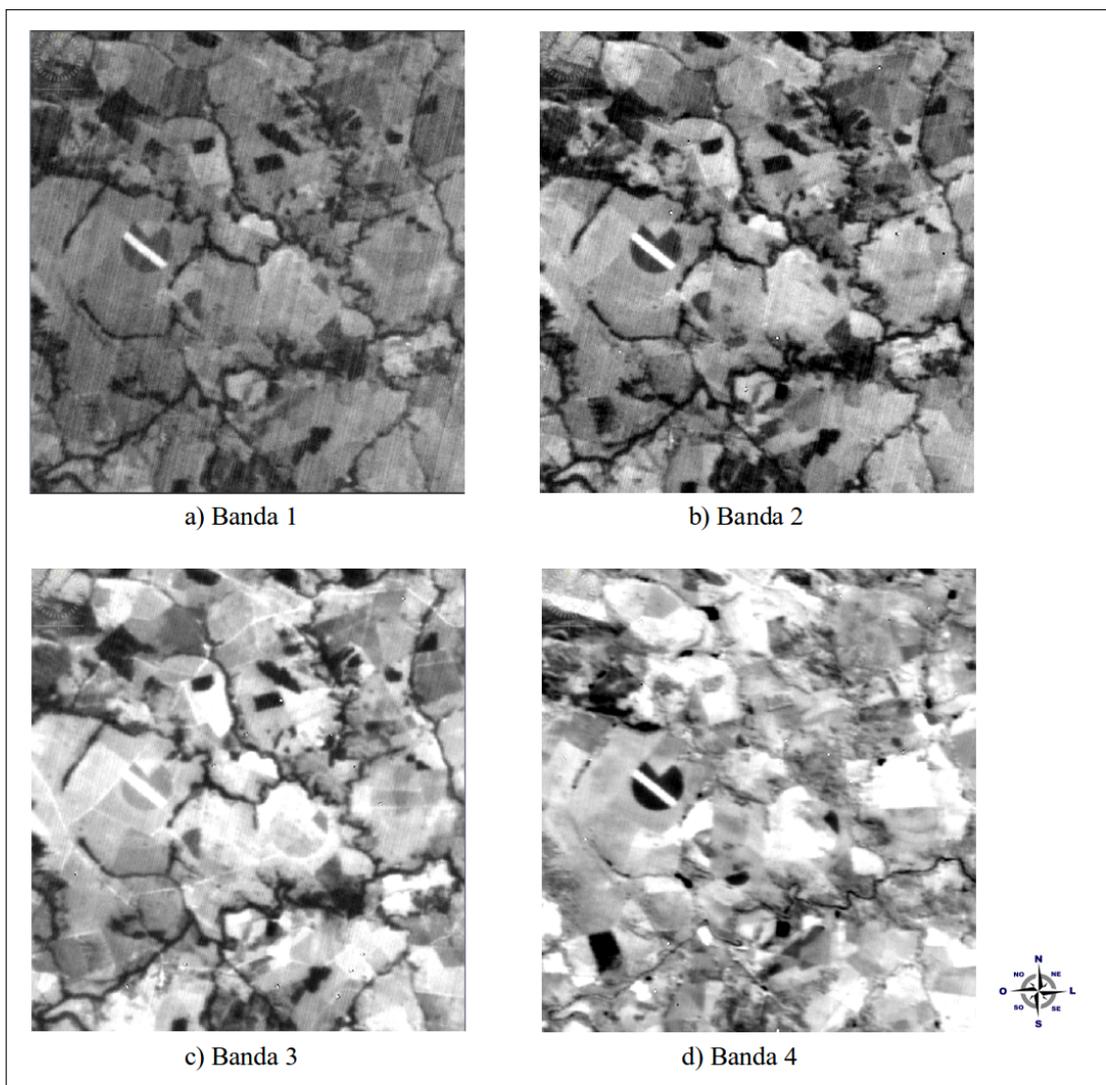
Fonte: INPE (2009).

A Figura 8 mostra as imagens resultantes do recorte efetuado sobre a imagem multiespectral do sensor Landsat-5/TM. Essas imagens também estão em níveis de cinza com resolução radiométrica de 8 *bits*. Cada imagem da Figura 8 representa uma banda da imagem multiespectral recortada. A imagem a) corresponde à banda 1 e representa a reflectância dos objetos na faixa espectral do azul (0,45 - 0,52 μm). A imagem b) corresponde à banda 2 e representa a reflectância dos objetos na faixa espectral do verde (0,52 - 0,60 μm). A imagem c) corresponde à banda 3 e representa a reflectância dos objetos na faixa espectral do vermelho (0,63 - 0,69 μm). A imagem d) corresponde à banda 4 e representa a reflectância dos objetos na faixa espectral do infravermelho próximo (0,76 - 0,90 μm). É importante notar que as bandas espectrais 2 e 4 do sensor Landsat-5/TM apresentam intervalos de comprimento de onda ligeiramente diferentes das bandas espectrais correspondentes do sensor CBERS-2B/CCD. Essa diferença implica na determinação de diferentes valores digitais médios para *pixels* dos alvos nas diferentes bandas espectrais, de acordo com cada sensor, conforme será detalhado na seção 2.6.

Com relação à imagem adquirida pelo sensor Landsat-5/TM para utilização no

protótipo, são utilizadas somente as bandas 3 e 4, porque apresentam melhores resultados na avaliação da separabilidade de assinaturas de classes de uso e cobertura do solo. A separabilidade é uma medida estatística da distância espectral entre duas assinaturas. Quanto mais significativa for a distância espectral entre duas assinaturas, maior é a chance de fazer uma boa distinção entre as duas classes que elas representam (QUARTAROLI; BATISTELLA, 2005).

Figura 7 – Imagens em níveis de cinza recortadas nas bandas espectrais 1, 2, 3 e 4 do sensor CEBERS-2B/CCD.



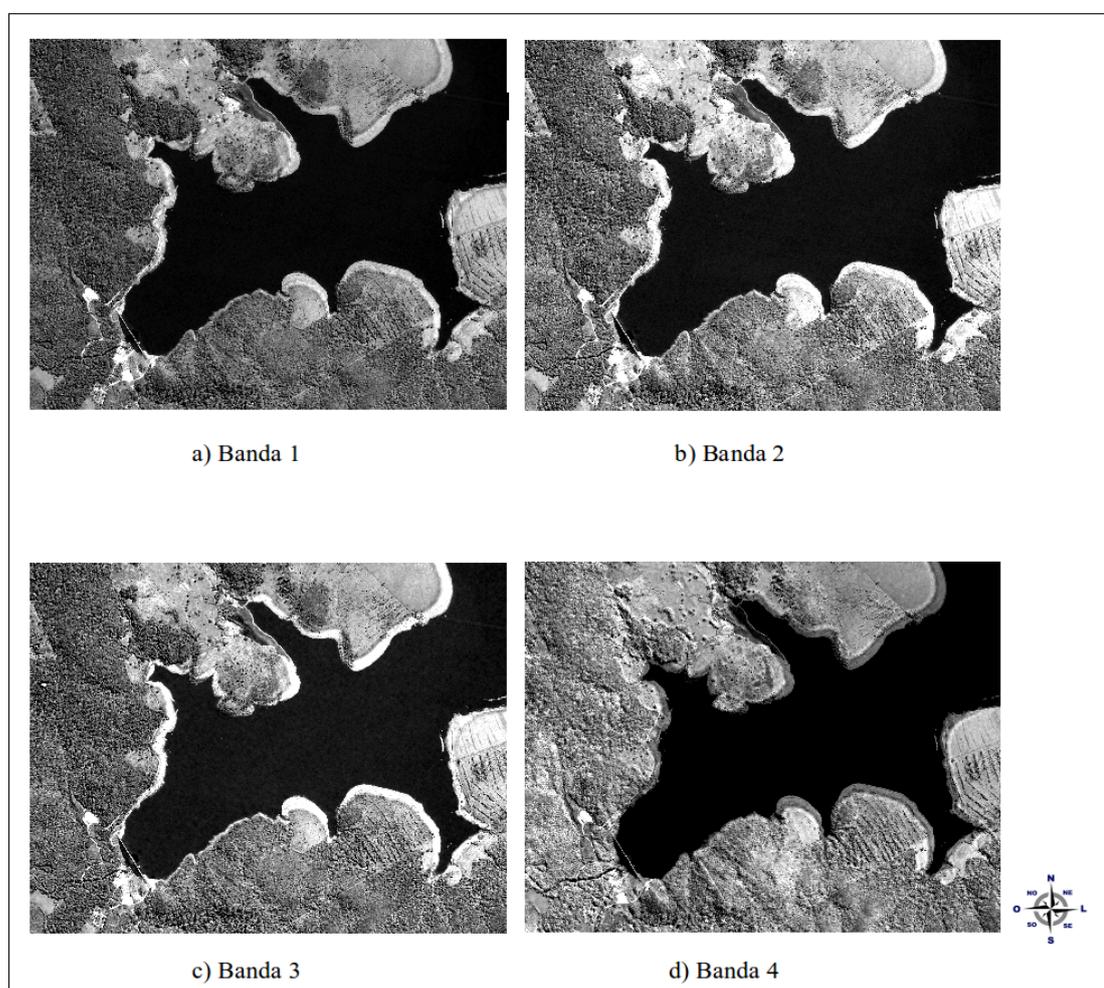
Fonte: INPE (2009).

Para recortar as imagens e identificar as coordenadas geográficas utiliza-se o programa GNU/BEAM VISAT, disponibilizado pela Agência Espacial Europeia (AEE) gratuitamente (ESA, 2013).

2.5 Agrupamento Difuso

Métodos de agrupamento têm como objetivo separar objetos em grupos, baseando-se nas características que estes objetos apresentam. Consistem em colocar em um mesmo grupo objetos que sejam similares de acordo com algum critério pré-determinado (LINDEN, 2009). Neste trabalho, os objetos são *pixels* e o agrupamento é realizado baseando-se nas suas características espectrais.

Figura 8 – Imagens em níveis de cinza recortadas nas bandas espectrais 1, 2, 3 e 4 do sensor Landsat-5/TM.



Fonte: INPE (2008).

Nesse sentido, a similaridade é fundamental para a definição de grupos. Uma forma de expressar similaridade é por intermédio de um conjunto de distâncias entre pares de objetos (MIRANDA, 2011). Seja \mathbf{U} o conjunto de todos os pontos de \mathbb{R}^n . Uma medida de distância é uma função $d(a, b): \mathbf{U} \times \mathbf{U} \rightarrow \mathbb{R}_0^+$ que associa às tuplas (a, b) de $\mathbf{U} \times \mathbf{U}$ um valor numérico do conjunto dos reais positivos (inclusive zero) e, por meio disso, satisfaz os seguintes axiomas (WANGENHEIM; WANGENHEIM, 2003):

$$d(a, a) = 0 \quad \text{reflexividade}$$

$$d(a, b) = d(b, a) \quad \text{simetria}$$

As medidas de distância podem possuir as propriedades de uma métrica. Seja d uma medida de distância sobre o universo \mathbf{U} . Se:

$$d(a, b) = 0 \Rightarrow (a = b) \quad \text{nula para pontos coincidentes}$$

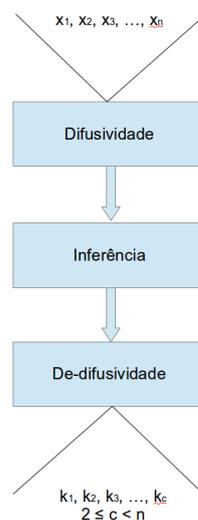
$$d(a, b) + d(b, d) \geq d(a, d) \quad \text{desigualdade triangular}$$

então d é uma métrica e (\mathbf{U}, d) um espaço métrico. A desigualdade triangular basicamente especifica que a menor distância entre dois pontos é uma reta.

De um modo geral, o objetivo da métrica é medir distâncias entre os pontos do espaço de atributos. No caso deste trabalho, são distâncias entre os *pixels* no espaço espectral.

Um sistema de agrupamento difuso, ilustrado na Figura 9, é composto basicamente de 3 etapas: i) difusividade, que é a entrada de valores da matriz de imagem e a divisão desse espaço de atributos em subespaços difusos, cada um especificado por uma função de pertinência. É o processo de obter uma quantidade difusa a partir de uma quantidade fixa, considerando o fato de que a quantidade fixa possui incertezas intrinsecamente; ii) inferência, realização do cálculo do peso de cada regra difusa para atribuição dos graus de pertinência; e iii) de-difusividade (*defuzzification*) ou conversão difusa para fixa, consiste em obter a melhor representação da saída *fuzzy* como quantidades exatas. Nesta etapa, os valores difusos são traduzidos em valores discretos (ROSS, 2004; TSO; MATHER, 2009; MIRANDA, 2011; ANDRADE; SILVA, 2011).

Figura 9 – Etapas de um sistema de agrupamento difuso.



Fonte: Miranda (2011).

Considere $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_n\}$ uma imagem com n *pixels* a ser agrupada em c agrupamentos difusos com $2 \leq c < n$. \mathbf{x}_i é um vetor de valores digitais do i -ésimo *pixel* em p bandas espectrais. Vários métodos de agrupamento têm sido propostos para identificar as c partições ótimas em \mathbf{X} . O método mais popular e mais estudado utiliza a função que minimiza a soma generalizada dos erros quadráticos intragrupos (BEZDEK; EHRLICH; FULL, 1984). Esse método procura formar partições em que as associações são fortes dentro dos grupos (intragrupo) e fracas entre grupos (intergrupo). O método é definido em função dos centroides dos grupos e do grau de difusividade m , gerando um índice de desempenho J que mede, para todos os elementos, a soma das distâncias ponderadas de cada elemento a cada um dos centroides dos grupos (MIRANDA, 2011). Trata-se do método FCM, que neste trabalho associa os *pixels* a cada grupo por meio de uma função de pertinência difusa. Quanto menor o valor de J , melhor é a partição difusa. Assim, o objetivo do método FCM é encontrar uma partição que minimize o índice de desempenho J . Portanto, o problema de agrupamento pode ser equacionado como um problema de otimização (YONAMINE et al., 2002).

O método FCM é a minimização iterativa do índice de desempenho J dado por uma função objetivo, que consiste na especificação matemática que mede a eficiência do sistema para cada solução proposta, expressa pela seguinte equação (BEZDEK; EHRLICH; FULL, 1984; FISHER; PATHIRANA, 1990; NAZ; MAJEED; IRSHAD, 2010):

$$J = \sum_{i=1}^n \sum_{k=1}^c \mu_{ik}^m \|\mathbf{x}_i - \mathbf{v}_k\|^2 \quad (2.1)$$

onde: μ_{ik} é a pertinência do *pixel* \mathbf{x}_i no k -ésimo grupo; \mathbf{v}_k é o centroide do k -ésimo grupo; m é o fator de difusividade ou expoente de ponderação e encontra-se no intervalo $1 < m \leq \infty$; $\|\cdot\|$ é uma métrica, representada neste trabalho por esse símbolo. A distância Euclidiana entre o *pixel* \mathbf{x}_i e o centroide \mathbf{v}_k é usada como métrica (BEZDEK; EHRLICH; FULL, 1984; CANNON; DAVE; BEZDEK, 1986; MIRANDA, 2011).

A função de pertinência é definida por:

$$\mu_{ik} = \frac{1}{\sum_{k=1}^c \left(\frac{\|\mathbf{x}_i - \mathbf{v}_k\|}{\|\mathbf{x}_i - \mathbf{v}_j\|} \right)^{\frac{2}{m-1}}}, \text{ para } i = 1, 2, \dots, n \text{ e } j = 1, 2, \dots, c, \text{ sendo } j \neq k. \quad (2.2)$$

e os centroides dos grupos são atualizados da seguinte forma:

$$\mathbf{v}_k = \frac{\sum_{i=1}^n [\mu_{ik}^m] \mathbf{x}_i}{\sum_{i=1}^n [\mu_{ik}^m]} \quad (2.3)$$

A Equação 2.2 significa que a distância de cada *pixel* \mathbf{x}_i ao centroide do grupo \mathbf{v}_k da k -ésima partição é comparada com a distância do mesmo *pixel* ao centroide do grupo

\mathbf{v}_j de todas as demais partições difusas ($j \neq k$). É atribuído um grau de pertinência ao *pixel* \mathbf{x}_i no k -ésimo grupo, que seja proporcional ao seu grau de pertinência aos demais j -ésimos grupos.

Se $\|\mathbf{x}_i - \mathbf{v}_k\| = 0$, então o ponto de dado \mathbf{x}_i coincide com o centroide do grupo \mathbf{v}_k e a pertinência total é $\mu_{ik} = 1$. O grau de pertinência mínimo em relação aos demais grupos é $\mu_{ik} = 0$. O valor μ_{ik} define o grau de pertinência difusa e de acordo com a Equação 2.2 é inversamente proporcional à distância espectral calculada com $\|\cdot\|$. Dessa forma, *pixels* mais próximos do centroide recebem valores difusos maiores e *pixels* mais distantes do centroide recebem valores menores de pertinência difusa.

O fator de difusividade m é usado para definir a distância permitida entre os pontos e o centroide que está sendo calculado. À medida que $m \rightarrow 1$, as partições que minimizam J (Equação 2.1) tornam-se crescentemente fixas. Por outro lado, à medida que $m \rightarrow \infty$, aumenta a degradação das pertinências para um estado mais difuso. Degradar as pertinências significa desfocar, borrar, considerar mais elementos do conjunto como pertencentes a uma pseudo partição, ou seja, uma partição que não é verdadeira (MIRANDA, 2011). Nenhuma evidência teórica ou computacional define um valor ótimo para m . O intervalo de valores úteis mais usado é $[1, 30]$. Para a maioria dos dados, um valor de m no intervalo $[1,5; 3,0]$ produz bons resultados (BEZDEK; EHRlich; FULL, 1984).

O método *fuzzy c-means* descrito a seguir tem a finalidade de minimizar o índice de desempenho J na função objetivo descrita na Equação 2.1 e encontrar a melhor partição difusa. Conforme as anotações e definições de Bezdek, Ehrlich e Full (1984), Fisher e Pathirana (1990), Miranda (2011), Cannon, Dave e Bezdek (1986) e Dave (1992), o método FCM é implementado a partir do seguinte algoritmo:

1. Considere um conjunto de n pontos de dados (*pixels* das bandas) a ser agrupado, $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_n\}$.
2. Defina o número de grupos, c , tal que $2 \leq c < n$.
3. Escolha um nível apropriado de difusividade para os grupos, $m \in \mathfrak{R}_{>1}$.
4. Inicialize a matriz \mathbf{A} de pertinências, de dimensão $n \times c$, com valores aleatórios tal que:
 $\mu_{ik} \in [0, 1]$ e $\sum_{k=1}^c \mu_{ik} = 1$, para $i = 1, \dots, n$ e $k = 1, \dots, c$.
5. Calcule (com $t = 0$) ou atualize (com $t > 0$) o centroide dos grupos \mathbf{v}_k usando:

$$\mathbf{v}_k^{(t+1)} = \frac{\sum_{i=1}^n [\mathbf{A}_k(\mathbf{x}_i^{(t+1)})]^m \mathbf{x}_i}{\sum_{i=1}^n [\mathbf{A}_k(\mathbf{x}_i^{(t+1)})]^m}, \text{ para } k = 1, 2, \dots, c. \quad (2.4)$$

6. Calcule as métricas de distância d_{ik} e d_{ij} :

$$d_{ik} = \|\mathbf{x}_i - \mathbf{v}_k^{(t)}\|^2 \text{ e } d_{ij} = \|\mathbf{x}_i - \mathbf{v}_j^{(t)}\|^2 \quad (2.5)$$

para todos os grupos $k, j = 1, 2, \dots, c$ e pontos de dados $i = 1, 2, \dots, n$.

7. Calcule (com $t = 0$) ou atualize (com $t > 0$) a matriz de pertinência difusa \mathbf{A} de acordo com d_{ik} . Se $d_{ik} > 0$, calcule o grau de pertinência do elemento \mathbf{x}_i ao grupo \mathbf{A}_k , μ_{ik} , pela seguinte fórmula:

$$\mathbf{A}_k^{(t+1)}(\mathbf{x}_i) = \mu_{ik}^{(t+1)} = \left[\sum_{k=1}^c \left(\frac{d_{ik}^{(t)}}{d_{ij}^{(t)}} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (2.6)$$

8. Repita a partir de (5) até que mudanças em \mathbf{A} sejam menores que uma dada tolerância, previamente definida, $\varepsilon \in (0, 1]$:

$$\|\mathbf{A}_k^{(t-1)}(\mathbf{x}_i) - \mathbf{A}_k^{(t)}(\mathbf{x}_i)\| < \varepsilon \quad (2.7)$$

A geração das partições difusas é feita em um processo iterativo onde os centroides definidos inicialmente no Passo 5 do algoritmo vão sendo ajustados de modo a formar os agrupamentos e definir a pertinência de cada *pixel* aos grupos.

O vetor \mathbf{v}_k , calculado pela Equação 2.4 no Passo 5 do algoritmo, centroide do grupo \mathbf{A}_k , é descrito por p atributos (p bandas espectrais), e é a média ponderada dos dados em \mathbf{A}_k . A média ponderada é calculada por meio do somatório das multiplicações entre valores e pesos do *pixel* \mathbf{x}_i , divididos pelo somatório dos pesos. O peso do vetor \mathbf{x}_i é a m -ésima potência do seu grau de pertinência ao conjunto difuso \mathbf{A}_k .

A Equação 2.6, definida no Passo 7 do algoritmo, expressa a função de pertinência e significa que a distância de cada elemento \mathbf{x}_i ao centroide do grupo \mathbf{v}_k da partição atual \mathbf{A}_k é comparada com a distância do mesmo elemento ao centroide do grupo \mathbf{v}_j de todas as demais partições difusas ($j \neq k$), atribuindo um grau de pertinência ao elemento \mathbf{x}_i no grupo \mathbf{A}_k , que seja proporcional ao seu grau de pertinência aos demais grupos \mathbf{A}_j .

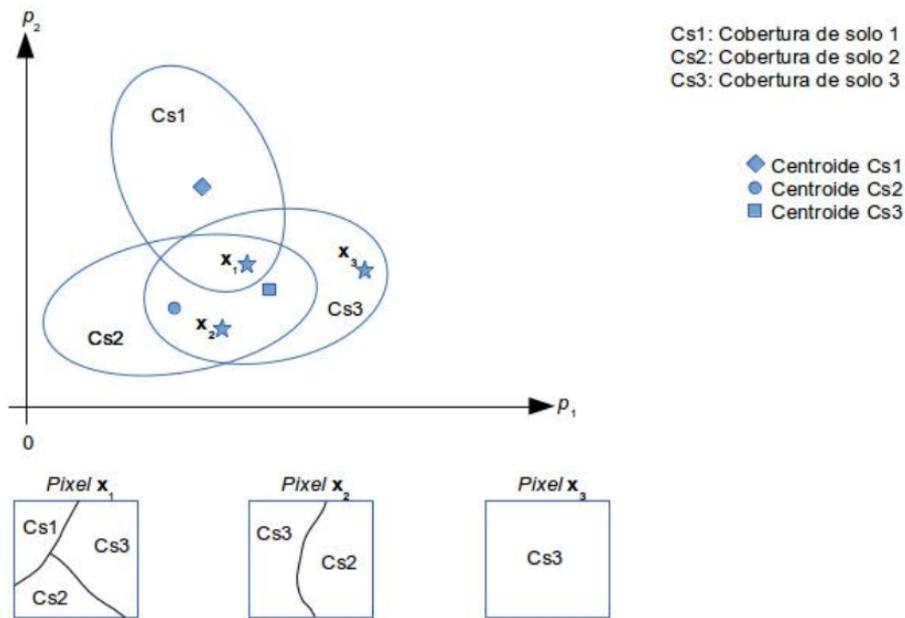
Se $d_{ik} = 0$, então o ponto de dado \mathbf{x}_i coincide com o centroide do grupo \mathbf{v}_k , a pertinência total pode ser atribuída $\mathbf{A}_k(\mathbf{x}_i) = 1$ e o grau de pertinência mínimo (0) é atribuído aos demais grupos. É importante observar aqui que o valor $\mathbf{A}_k(\mathbf{x}_i)$ define o grau de pertinência difusa, sendo inversamente proporcional à distância espectral calculada com d .

O algoritmo para quando é alcançado um número limite de iterações informado como parâmetro ou quando a matriz de pertinência \mathbf{A} deixa de apresentar mudanças significativas.

A Figura 10 ilustra um exemplo hipotético para o funcionamento do algoritmo FCM com 3 agrupamentos de diferentes coberturas de solo, 2 casos de *pixel* mistura e 1

caso de *pixel* puro. A parte superior da figura mostra o espaço de atributos espectrais de 2 bandas p_1 e p_2 . As 3 elipses representam os 3 agrupamentos de diferentes coberturas de solo: Cs1, Cs2 e Cs3. Os 3 centroides dos agrupamentos estão representados por um losango, um círculo e um quadrado, respectivamente. Os 3 *pixels* \mathbf{x}_1 , \mathbf{x}_2 e \mathbf{x}_3 representam possíveis situações reais. A parte inferior da figura mostra um diagrama de composição dos 3 *pixels* com relação aos componentes de mistura espectral.

Figura 10 – Exemplo hipotético para funcionamento do algoritmo FCM.



Fonte: Miranda (2011).

Na Figura 10 o *pixel* \mathbf{x}_1 apresenta informações espectrais das 3 diferentes coberturas de solo, sendo que a área de Cs3 é maior que a área de Cs2, que por sua vez é maior que a área de Cs1. As distâncias de \mathbf{x}_1 para os centroides dos grupos decrescem na sequência Cs1, Cs2 e Cs3. A Tabela 3 representa hipoteticamente valores difusos atribuídos pela Equação 2.6 definida no Passo 7 do algoritmo. Com relação ao *pixel* \mathbf{x}_2 , apenas 2 coberturas de solo estão presentes, sendo que área de Cs2 é ligeiramente maior que a de Cs3. No espaço de atributos, a distância de \mathbf{x}_2 para o centroide de Cs2 é menor do que para o centroide de Cs3. Por isso, na Tabela 3 o valor difuso de \mathbf{x}_2 é 0,0 em relação ao agrupamento da cobertura de solo Cs1. Já o *pixel* \mathbf{x}_3 é puro e apresenta um único valor espectral da cobertura de solo Cs3, conforme o diagrama de composição. Por isso, na Tabela 3 o *pixel* \mathbf{x}_3 possui valor difuso 0,0 para os agrupamentos das coberturas de solo Cs1 e Cs2, enquanto que para a cobertura Cs3 o valor difuso é 1,0.

Depois da execução do algoritmo FCM, segue-se a etapa de de-difusividade, na qual os valores difusos são convertidos para números precisos, visto que os problemas do mundo real requerem um resultado preciso. Existem muitos métodos para realizar a

de-difusividade. Dentre os mais comuns estão: cortes lambda (*lambda-cuts*); centro de massa ou centro de gravidade; médias dos máximos; pertinência máxima; e centroide mais próximo. Nas referências estudadas neste trabalho não há evidências que indiquem o melhor método para casos gerais e nem para o caso específico de imagens de satélite. Assim como muitas questões em lógica *fuzzy*, a escolha do método de de-difusividade deve ser feita com base no contexto dos dados disponíveis (ROSS, 2004). Em imagens no padrão Vermelho, verde, azul (*Red, Green, Blue*) (RGB), geralmente o método de de-difusividade mais utilizado é o da pertinência máxima (RAHIMI et al., 2004; TOWFIK, 2010). Por este motivo e também pela sua simplicidade de implementação, o método da pertinência máxima é utilizado no presente trabalho.

Tabela 3 – Valores difusos dos *pixels* \mathbf{x}_1 , \mathbf{x}_2 e \mathbf{x}_3 , conforme Figura 10.

<i>Pixel/Agrupamento</i>	Cs1	Cs2	Cs3
\mathbf{x}_1	0,2	0,3	0,5
\mathbf{x}_2	0,0	0,6	0,4
\mathbf{x}_3	0,0	0,0	1,0

No método da pertinência máxima, o elemento com maior valor em cada linha da matriz de valores difusos recebe o valor de pertinência 1,0, enquanto todos os outros elementos na mesma linha recebem o valor 0,0. Considerando que o valor de pertinência máxima na i -ésima linha seja $\max\{\mu_{ij}\}$, então a regra para decidir se o *pixel* \mathbf{x}_i pertence ao grupo j é (ROSS, 2004; MIRANDA, 2011):

Se $\mu_{ij} = \max\{\mu_{ij}\}$ então

$$\mu_{ij} = 1,0;$$

senão

$$\mu_{ik} = 0,0 \quad \forall k \neq j; k, j = 1, 2, \dots, c \text{ e } i = 1, 2, \dots, n$$

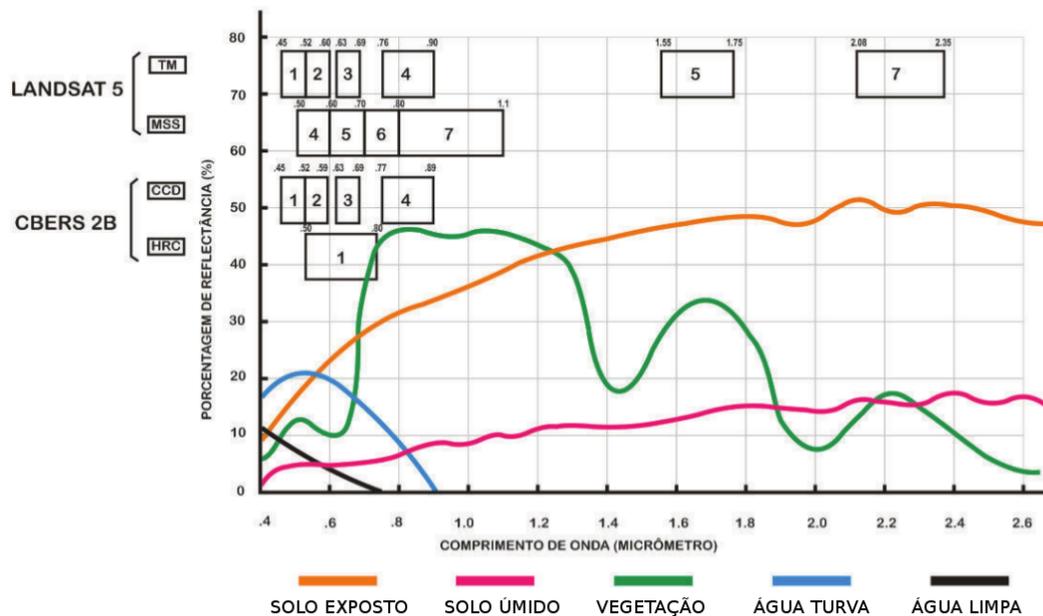
2.6 Classificação da Imagem

Depois que os *pixels* são alocados aos grupos, o conhecimento necessário para designar os seus significados (classificação) pode ser teórico (conhecimento do comportamento espectral dos alvos) ou prático (adquirido por intermédio de visitas a campo, mapas, fotografias aéreas ou imagens de alta resolução) (SCHOWENGERDT, 2006; RICHARDS; JIA, 2006; NOVO, 1992). Para a identificação de tipos de cobertura da Terra nas imagens multiespectrais é utilizado o princípio de que diferentes materiais são caracterizados por reflectâncias espectrais próprias em cada banda do espectro (MATHER; KOCH, 2011).

A Figura 11 mostra as assinaturas espectrais dos alvos terrestres analisados neste trabalho e a relação com as bandas dos sensores dos satélites CBERS-2B e Landsat-5.

Essas assinaturas indicam características dos diferentes objetos que permitem mapear os diversos temas a partir da imagem de satélite (LILLESAND; KIEFER, 1994).

Figura 11 – Assinaturas espectrais de alvos terrestres e sua relação com as bandas dos sensores dos satélites CBERS-2B e Landsat-5.



Fonte: Lillesand e Kiefer (1994) e Lima e Morato (2010).

A partir do estudo das assinaturas espectrais da Figura 11 é possível determinar os valores digitais médios para *pixels* desses alvos nas diferentes faixas espectrais. Considerando uma resolução radiométrica de 8 *bits*, os valores digitais podem variar no intervalo de 0 a 255 (256 níveis de cinza). Considerando também os valores percentuais médios de reflectância no gráfico da Figura 11 e efetuando o cálculo dos valores digitais correspondentes, obtêm-se as tabelas 4 e 5 para os alvos solo exposto, solo úmido, vegetação, água turva e água limpa, referentes aos sensores CBERS-2B/CCD e Landsat-5/TM, respectivamente.

Os valores digitais médios levantados por Lillesand e Kiefer (1994) e Chaves et al. (2009) nas diferentes faixas espectrais são comparados com os centroides dos grupos calculados anteriormente na etapa do agrupamento difuso. A proximidade dos valores comparados entre um agrupamento e uma cobertura indica a possibilidade de identificação do alvo terrestre na imagem.

Para verificar a proximidade das características espectrais entre os agrupamentos e os alvos de interesse neste estudo, emprega-se novamente o algoritmo FCM. A utilização do FCM nessa etapa permite assumir que os centroides dos grupos pertencem a todos os alvos com graus de pertinência diferentes. Dessa forma são gerados gráficos que ilustram a pertinência de cada grupo a cada uma das classes que representam os objetos da superfície

terrestre. Os graus de pertinência são obtidos a partir da distância Euclidiana entre os centroides dos grupos e os valores digitais médios dos alvos terrestres.

Tabela 4 – Valores médios de reflectância de alvos terrestres nas diferentes bandas espectrais do sensor CBERS-2B/CCD.

Alvo terrestre	Banda espectral	Comprimento de onda médio (μm)	Reflectância média (%)	Valor digital médio
Solo exposto	1	0,48	18	46
	2	0,55	20	51
	3	0,66	26	67
	4	0,83	32	82
Solo úmido	1	0,48	14	36
	2	0,55	14	36
	3	0,66	15	38
	4	0,83	18	46
Vegetação	1	0,48	12	31
	2	0,55	11	28
	3	0,66	10	26
	4	0,83	46	118
Água turva	1	0,48	21	54
	2	0,55	21,5	55
	3	0,66	18,5	47
	4	0,83	17	44
Água limpa	1	0,48	16,5	42
	2	0,55	15	38
	3	0,66	13	33
	4	0,83	0	0

Tabela 5 – Valores médios de reflectância de alvos terrestres nas diferentes bandas espectrais do sensor Landsat-5/TM.

Alvo terrestre	Banda espectral	Comprimento de onda médio (μm)	Reflectância média (%)	Valor digital médio
Solo exposto	3	0,66	26,25	67
	4	0,83	32	82
Solo úmido	3	0,66	5,25	13
	4	0,83	7	18
Vegetação	3	0,66	22,5	58
	4	0,83	45,75	117
Água turva	3	0,66	17,25	44
	4	0,83	7,5	19
Água limpa	3	0,66	2,75	7
	4	0,83	0	0

2.7 Validação do Protótipo

Neste trabalho, a validação do protótipo de *software* é feita por meio de conhecimento teórico para a cena obtida pelo sensor CBERS-2B/CCD. Já a validação do protótipo para a cena obtida pelo sensor Landsat-5/TM é feita por meio de conhecimento prático, utilizando-se mapas fornecidos pela ferramenta *Google Maps*.

Com relação à imagem obtida pelo sensor CBERS-2B/CCD, os resultados de classificação por *pixel* gerados na etapa de agrupamento difuso são validados pelo processo de interpretação visual das imagens, que é o processo pelo qual o analista humano é capaz de extrair informações diretamente das imagens obtidas por sensores remotos orbitais, apresentados sob a forma de uma imagem pancromática ou colorida. Para a interpretação visual de imagens normalmente são utilizados alguns elementos como: padrão, cor ou tonalidade, textura, sombreamento, localização, forma e tamanho (LUIZ et al., 2002).

A interpretação visual é um trabalho relativamente complexo no sensoriamento remoto e as técnicas visuais fazem uso da habilidade humana para avaliar quantitativamente os padrões espectrais em uma imagem (LILLESAND; KIEFER, 1994). Neste trabalho, a interpretação visual consiste nas etapas de realce da imagem, geração de composição colorida e de chave de interpretação.

O realce tem a finalidade de melhorar a qualidade visual da imagem e facilitar o trabalho de interpretação. Uma técnica simples e eficiente para detectar feições, que é utilizada neste trabalho, é a ampliação linear de contraste (*contrast stretch*). A ampliação linear de contraste consiste na expansão da distribuição linear de dados originais para todo o intervalo possível de 256 níveis de cinza em imagens com resolução radiométrica de 8 *bits*.

As composições coloridas são obtidas da associação de cores primárias, mais conhecidas como RGB, às informações espectrais contidas em três bandas quaisquer dos sistemas sensores. Esse procedimento aumenta a acuidade do sistema visual humano em discernir diferentes feições nas imagens durante a fase de interpretação (MOREIRA, 2003).

A chave de interpretação consiste na criação de um conjunto de elementos que caracterizam determinados objetos e que auxiliam na interpretação de imagens com composição colorida. Cada intérprete pode criar suas próprias chaves, que sistematizam e orientam o processo de análise e interpretação de imagens (CUNHA, 2009). Vários elementos de reconhecimento podem interagir para descrever a chave de interpretação: tonalidade, cor, tamanho, forma, textura, padrão, sombreamento, altura e localização (LIMA; MORATO, 2010; IWAI, 2003).

A tonalidade é a resposta da quantidade relativa da luz refletida ou da radiação emitida registrada pelo sensor, resultante das propriedades físicas e químicas do alvo. Quanto mais luz ou energia um objeto refletir ou emitir, mais a sua representação na

imagem vai tender ao branco. Por outro lado, quanto menos energia o objeto refletir ou emitir, mais a sua representação tenderá ao preto.

A cor é um elemento utilizado na interpretação de imagens coloridas. A cor do objeto depende da quantidade de energia que ele reflete no canal correspondente à imagem e da mistura entre as cores. Interpretar imagens coloridas é mais fácil do que interpretar imagens em preto e branco, porque o olho humano distingue cem vezes mais cores do que níveis de cinza.

O tamanho é uma função da escala em relação aos objetos da imagem. Em função do tamanho, pode-se por exemplo distinguir uma residência de uma indústria, uma área residencial de uma industrial, um sulco de erosão de uma voçoroca, uma agricultura de subsistência de uma agricultura comercial.

A forma é um elemento que por si só já possibilita a identificação de alguns objetos, feições ou superfícies. Assim, estradas e rios são facilmente identificados pela sua forma linear e curvilínea, as áreas de cultivo pela sua forma geométrica retangular ou em faixas, e as áreas de culturas irrigadas por sistemas de pivô central apresentam formas circulares. Geralmente, as formas regulares indicam objetos artificiais ou culturais, construídos pelo Homem (indústrias, áreas de reflorestamento, áreas agrícolas, represas etc.), enquanto que as formas irregulares indicam aspectos naturais (matas, lagos, rios, pântanos etc.) e ocorrem na ausência de formas geométricas definidas.

A textura refere-se ao aspecto liso e uniforme ou rugoso dos objetos em uma imagem. Normalmente é produzida pela agregação de unidades muito pequenas para serem identificadas individualmente, passando a ser analisadas em conjunto. A textura apresenta informações sobre as variações de tons ou níveis de cinza/cor de uma imagem. Trata-se de um elemento muito importante na identificação de unidades de relevo: a textura lisa indica áreas de relevo plano, e a textura rugosa corresponde a áreas de relevo acidentado e dissecado pela drenagem.

O padrão é um elemento que se refere ao arranjo espacial ou à organização dos objetos em uma superfície. A repetição de certas formas e seus relacionamentos estabelece padrões que ajudam no processo de interpretação de imagens. Em imagens de alta resolução espacial um padrão de linhas sucessivas pode ser associado a culturas plantadas em fileiras, por exemplo.

O sombreamento é resultante da iluminação oblíqua da superfície pelo Sol, no momento da aquisição da imagem pelo sensor. A sombra permite que outros elementos como a forma e o tamanho possam ser inferidos para colaborar na interpretação da imagem. A sombra é um elemento que pode ajudar na identificação de objetos como pontes, charminés, postes, árvores e feições de relevo, mas pode também ocultar a visualização dos objetos por ela encobertos.

Com relação à altura, é importante considerar que a forma de um objeto observado sob a perspectiva vertical é diferente da forma sob a perspectiva horizontal. Assim, as árvores de um pomar se transformam em pequenos círculos, edifícios se transformam em retângulos, um vulcão é visto como um círculo menor (o cume) dentro de um círculo maior (a base), por exemplo. Em imagens bidimensionais a altura de objetos como árvores, edifícios e relevo pode ser estimada por meio do sombreamento.

A localização é um elemento que se refere à posição geográfica de um objeto. É um elemento de reconhecimento que auxilia a interpretação à medida que se reconhece, por exemplo, o clima e o tipo de vegetação. As áreas urbanas, por exemplo, podem ser identificadas por sua proximidade de rodovias, rios e litorais.

Apesar do conhecimento prévio da área de estudo facilitar o processo de interpretação e aumentar o potencial de leitura da imagem, este trabalho não conta com visitas a campo para identificação dos objetos presentes na cena imageada. A Tabela 6 descreve a chave de interpretação para uma composição colorida RGB/342 da cena obtida pelo sensor CBERS-2B/CCD, a partir das informações de Florenzano (2002), Spring (2005) e Lima e Morato (2010).

Tabela 6 – Chave de interpretação para composição colorida RGB/342 de imagem do sensor CBERS-2B/CCD.

	Categoria	Subcategoria	Cor	Textura	Forma
a	Vegetação	Área agrícola em estágio inicial	Verde clara	Lisa	Regular/geométrica
		Área agrícola (cultura sadia e madura)	Verde escura	Lisa	Regular/geométrica
		Pastagem plantada	Verde	Lisa	Irregular
		Pastagem suja	Verde	Ligeiramente rugosa	Irregular
		Mata e capoeira	Verde escura	Rugosa	Irregular
b	Solo	Exposto ou área desmatada	Vermelha tendendo à branca	Lisa	Regular
		Preparado para cultivo ou pós-colheita	Vermelha escura	Lisa	Regular/geométrica
c	Água e áreas úmidas	Água limpa	Preta	Lisa	Irregular, curvilínea para rios
		Água turva	Violeta	Lisa	Irregular, curvilínea para rios

Para a segunda cena submetida ao protótipo, obtida pelo sensor Landsat-5/TM, é possível extrair coordenadas geográficas da imagem e comparar o resultado gerado pelo protótipo com a consulta em ferramentas de localização como o *Google Maps*, por exemplo.

3 Resultados e Discussão

3.1 Descrição do Protótipo

Para realização da pesquisa, todos os programas utilizados foram executados em sistema operacional GNU/Linux, distro Ubuntu 12.04 LTS 64 *bits*¹, que possuem versões disponíveis também para outros sistemas operacionais.

Os métodos de agrupamento e classificação foram implementados no ambiente GNU/Octave versão 3.2.4 32 *bits*, que é um *software* livre voltado para a construção de modelos algébricos e matriciais. Dessa forma, outros pesquisadores podem acessar o protótipo independentemente de licenças de *software* proprietário.

O algoritmo FCM descrito no Capítulo Pressupostos Teóricos e Metodológicos foi implementado no ambiente GNU/Octave sob a forma de uma função (*function*), conforme descrito no Apêndice A.6. A função *fFCM.m* recebe os seguintes parâmetros:

***I*:** matriz $n \times p$ de n casos por p variáveis. Cada linha da matriz representa um *pixel* e cada coluna representa o seu valor digital na banda espectral da imagem.

***MuInicial*:** matriz de graus de pertinência inicial para atender ao Passo 4 do algoritmo. Se desejar que a função calcule a 1ª matriz de pertinência com valores aleatórios, então deixar esse parâmetro como [].

***CentInicial*:** matriz inicial $c \times p$ de c centroides por p bandas espectrais. Se desejar que a função calcule a 1ª matriz de centroides, então deixar esse parâmetro como [].

***numGrupos*:** quantidade de grupos a serem gerados.

***maxIteracoes*:** quantidade limite de iterações.

***epsilon*:** valor limite para a diferença entre as matrizes de pertinência que estão sendo geradas.

***expPonderacao*:** expoente de ponderação ou fator de difusividade.

A função *fFCM.m* retorna os seguintes parâmetros:

¹ Disponível em: <http://releases.ubuntu.com/12.04/>. Acesso em: 15 abr. 2014, 18:18:20.

- CP:** matriz $n \times c$ contendo os graus de pertinência de cada um dos n *pixels* para cada um dos c grupos.
- MuInicialNovo:** matriz $n \times c$ contendo os graus de pertinência atribuídos aleatoriamente pela 1ª vez a cada um dos n *pixels* para cada um dos c grupos.
- CentFinal:** matriz $c \times p$ contendo os c centroides gerados no final do processamento para cada uma das p bandas espectrais.
- E:** matriz coluna com os valores das diferenças entre as matrizes de pertinência calculados durante o processamento.
- qtdeIteracoes:** quantidade de iterações efetivamente realizadas no processamento.
- epsilonSaida:** último épsilon calculado antes de encerrar o processamento.

Na etapa de agrupamento, a função *fFCM.m* é chamada pelo programa *sAgrupamento.m* listado no Apêndice A.10. Esse programa define diretórios de trabalho, formata a imagem multiespectral como o parâmetro I de entrada para a função *fFCM.m*, efetua o processo de de-difusividade e gera gráficos a partir dos resultados.

O protótipo é executado sobre a mesma imagem a partir de combinações dos parâmetros de entrada: quantidade de grupos e fator de difusividade. Conforme a análise dos resultados, outras execuções são realizadas informando-se parâmetros limitantes do processamento: quantidade limite de iterações e valor limite para a diferença entre as matrizes de pertinência que estão sendo geradas. A análise dos resultados das execuções é feita com base na interpretação visual da composição colorida da imagem multiespectral, no caso da imagem obtida pelo sensor CBERS-2B/CCD. Para a imagem obtida pelo sensor Landsat-5/TM, a análise é feita comparando-se os resultados das execuções com uma consulta por meio da ferramenta *Google Maps*. Essa análise leva à seleção do melhor agrupamento difuso realizado, segundo os diferentes parâmetros de entrada para o protótipo, para em seguida proceder à etapa de classificação.

Na etapa de classificação executa-se o programa *sClassificacao.m* listado no Apêndice A.11. Além de definir os diretórios de trabalho, o programa *sClassificacao.m* utiliza os grupos e seus centroides calculados na etapa anterior para comparar com as assinaturas espectrais dos objetos de interesse do presente trabalho: solo exposto, solo úmido, vegetação, água turva e água limpa. Essas assinaturas espectrais foram definidas anteriormente nas tabelas 4 e 5, para os sensores CBERS-2B/CCD e Landsat-5/TM respectivamente. A comparação é realizada para verificar a proximidade das características espectrais entre os agrupamentos e os alvos de interesse neste estudo, utilizando-se novamente o algoritmo FCM por intermédio de chamada à função *fFCM.m*.

Na etapa de interpretação visual, para a cena obtida pelo sensor CBERS-2B/CCD, o processo de realce e a geração de composição colorida são efetuados pelo programa *sExibeCompRGB.m* listado no Apêndice A.12. Inicialmente, esse programa define o diretório e as bandas espectrais para serem realçadas e utilizadas na composição. Em seguida, realiza a ampliação linear de contraste e gera a composição com uma qualidade visual melhor para facilitar o trabalho de interpretação.

3.2 Experimento Sobre Imagem do Sensor CBERS-2B/CCD

Sobre a imagem recortada nas bandas 1, 2, 3 e 4, mostrada anteriormente na Figura 7, foi executado o programa *sAgrupamento.m* com os seguintes parâmetros de entrada para a função *fFCM.m*:

- I:** matriz de dimensão 133.056 x 4 contendo os valores digitais de 133.056 *pixels* nas bandas espectrais 1, 2, 3 e 4.
- MuInicial:** [], para que uma matriz de graus de pertinência inicial seja gerada.
- CentInicial:** [], para que uma matriz de centroides inicial seja gerada.
- numGrupos:** 5.
- maxIteracoes:** 100.
- epsilon:** 0,01.
- expPonderacao:** 1,5.

Como resultado desse processamento, obteve-se o Mapa de Grupos apresentado na Figura 12, a Estatística de *Pixels* Agrupados na Figura 13 e a Variação das Diferenças Entre as Matrizes de Pertinência na Figura 14. Os parâmetros de saída *qtdeIteracoes* e *epsilonSaida* retornaram os valores 40 e 0,00978, respectivamente.

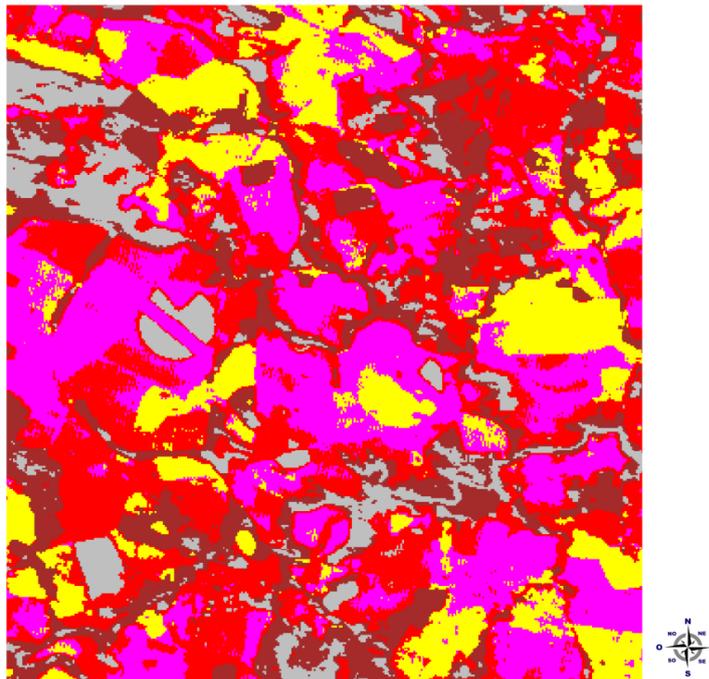
As Figuras 12 e 13 indicam que todos os *pixels* foram agrupados. E não poderia ser diferente, visto que o método da pertinência máxima empregado na etapa de defusividade associa todos os *pixels* a algum grupo, independentemente de situações em que ocorrem valores baixos de pertinência.

Para essa execução, a Figura 14 mostra que a diferença entre as matrizes de pertinência começa a decrescer efetivamente a partir da 6^a iteração e atinge um valor ε abaixo de 0,01 na 40^a iteração.

Depois de gerados os grupos, a etapa seguinte de classificação foi executada por meio do programa *sClassificacao.m*, utilizando-se novamente o algoritmo FCM ao chamar a função *fFCM.m* com os seguintes parâmetros de entrada:

- I:** matriz de dimensão 5 x 4 contendo os 5 centroides de cada grupo em cada uma das bandas espectrais 1, 2, 3 e 4.
- MuInicial:** [], para que uma matriz de graus de pertinência inicial seja gerada.
- CentInicial:** valores digitais médios dos *pixels* para os alvos terrestres de interesse nas bandas 1, 2, 3 e 4, conforme a Tabela 4.
- numGrupos:** 5.
- maxIteracoes:** 1.
- epsilon:** 0,01.
- expPonderacao:** 1,5.

Figura 12 – Mapa de Grupos resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.



Como resultado da classificação, obteve-se o Gráfico de Pertinência de Grupos às Classes de Alvos Terrestres apresentado na Figura 15. Nesse gráfico é possível constatar que: o grupo 1 apresenta a maior pertinência de 0,52 à classe solo exposto; o grupo 2 apresenta a maior pertinência de 0,68 à classe vegetação; o grupo 3 apresenta a maior pertinência de 0,37 à classe solo exposto; o grupo 4 apresenta a maior pertinência de 0,80 à classe vegetação; e o grupo 5 apresenta a maior pertinência de 0,65 também à classe solo exposto. Não houve nenhuma pertinência máxima associada às classes solo úmido, água turva e água limpa, mas houve pertinências parciais a essas classes, principalmente no grupo 3.

Figura 13 – Estatística de *Pixels* Agrupados resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.

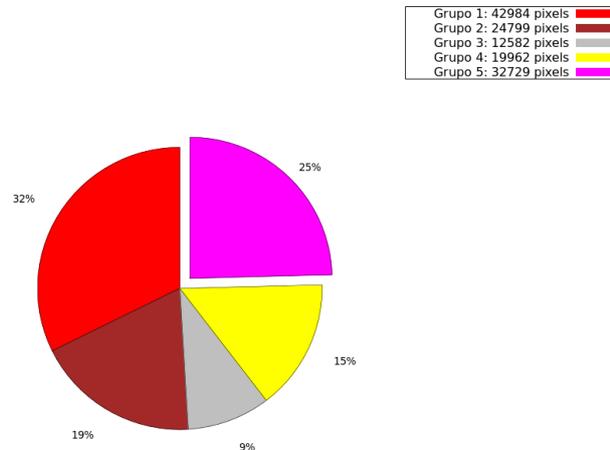
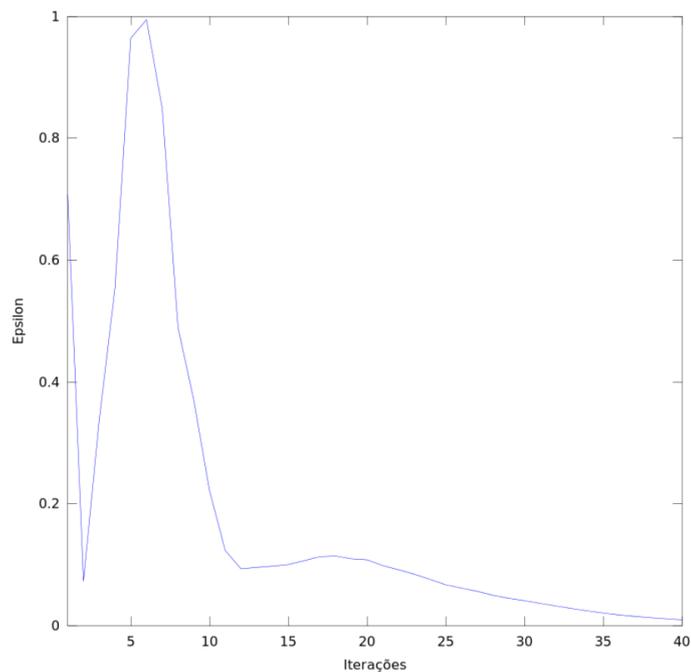


Figura 14 – Variação das Diferenças Entre as Matrizes de Pertinência resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.

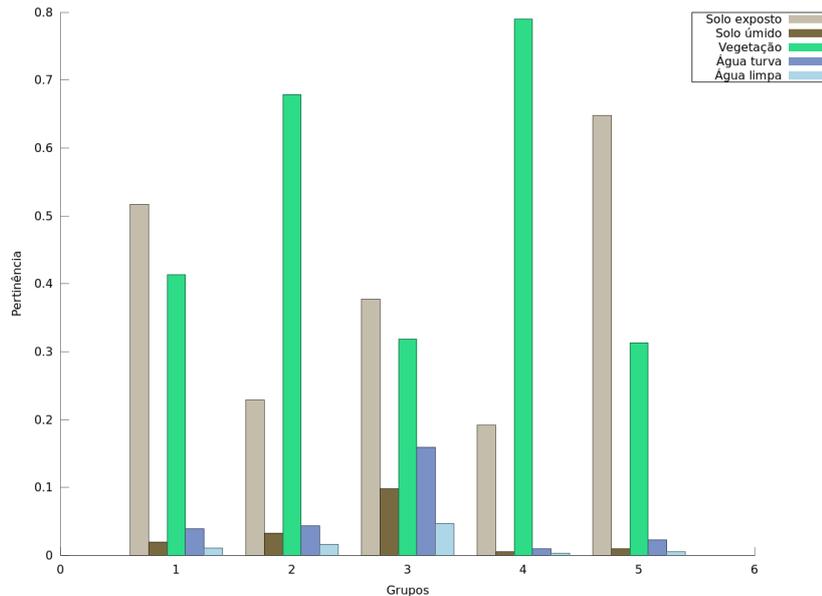


Para validar os resultados da classificação, as bandas 1, 2, 3 e 4 recortadas na seção 2.4 foram realçadas e submetidas ao modelo de cores RGB, que associa cores primárias às informações espectrais. A Figura 16 ilustra o processo de realce sobre uma composição RGB/342 utilizada neste trabalho para a interpretação visual. É possível notar que em relação à Figura 16a, sem realce, a Figura 16b realça diferentes feições de cobertura terrestre.

A composição RGB/342 foi associada à chave de interpretação descrita na Tabela 6, dando origem à Figura 17. De acordo com a chave de interpretação, na composição

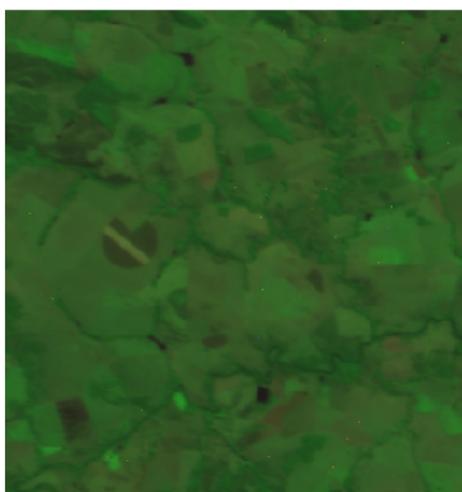
RGB/342 a vegetação aparece em tons de verde, como as áreas que foram assinalados com as indicações a1, a2, a3 e a4. O solo exposto aparece em tons de vermelho, conforme as áreas assinaladas com as indicações b1, b2, b3 e b4. A água e as áreas úmidas aparecem em tons de marrom, conforme as áreas assinaladas com as indicações c1, c2 e c3.

Figura 15 – Pertinência de Grupos às Classes de Alvos Terrestres resultante da execução do protótipo sobre a cena obtida pelo sensor CBERS-2B/CCD.

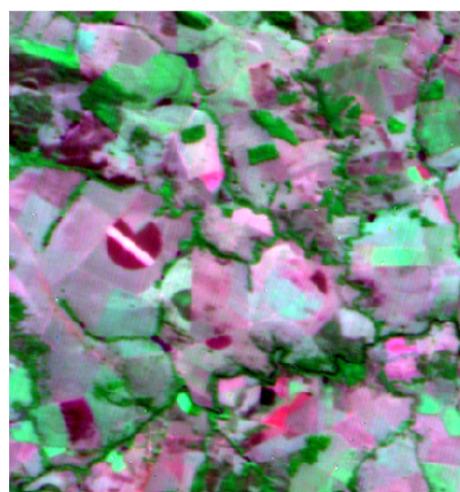


As ilustrações geradas pelo protótipo podem ser analisadas de 2 formas: partindo da composição colorida RGB/342 em direção ao Gráfico de Pertinência de Grupos às Classes de Alvos Terrestres ou o caminho inverso, partindo do gráfico resultante do processo de classificação em direção à composição colorida gerada na interpretação visual.

Figura 16 – Composição RGB/342 dos recortes da Figura 7.



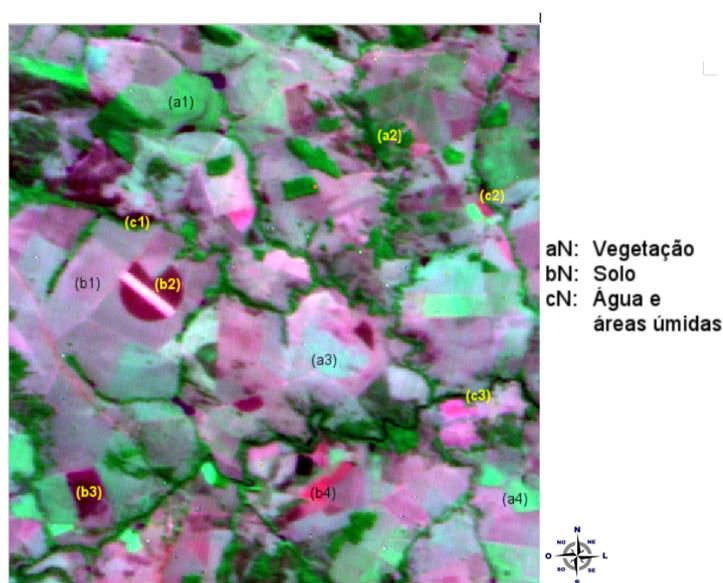
(a) Sem realce



(b) Com realce

Assumindo a primeira forma de análise, para saber a quais classes o protótipo associou as áreas assinaladas na composição colorida, a Figura 17 mostra áreas exemplificadas por a1, a3 e a4, em tom verde claro, representadas na Figura 12 pela cor amarela. Essa cor representa o grupo 4, de acordo com a Figura 13. A Figura 15 indica que o grupo 4 apresenta alta pertinência à classe vegetação, o que condiz com a interpretação visual da composição colorida apresentada na Figura 17. Já as áreas exemplificadas por a2, em tom verde escuro, representadas na Figura 12 pela cor marrom, correspondem ao grupo 2, de acordo com a Figura 13. O grupo 2, conforme a Figura 15, apresenta alta pertinência também à classe vegetação, condizente com a interpretação visual.

Figura 17 – Composição RGB/342 categorizada com chave de interpretação.



As áreas exemplificadas por b1 na Figura 17, em tom vermelho claro, são representadas na Figura 12 pela cor lilás. De acordo com a Figura 13, essa cor corresponde ao grupo 5 e a Figura 15 indica uma alta pertinência à classe solo exposto. Já as áreas exemplificadas por b2 e b3, em tons de vermelho escuro, são representadas na Figura 12 pela cor cinza. Conforme a Figura 13, essa cor representa o grupo 3, que na Figura 15 indica máxima pertinência à classe solo exposto. Entretanto, a Figura 15 indica também para o grupo 3 pertinências consideráveis às classes vegetação, água turva e solo úmido, indicando se tratar de áreas agricultáveis, que recebem alguma irrigação e que portanto tratam-se de um solo úmido. Ressalta-se ainda que a área b2 apresenta a forma geométrica de um pivô de irrigação, tanto na Figura 17 como na Figura 12, reforçando a classificação como solo úmido. Com relação às áreas exemplificadas por b4, representada na Figura 17 por um tom vermelho intermediário, corresponde na Figura 12 à cor vermelha. Essa cor, de acordo com a Figura 13 representa o grupo 1 e possui alta pertinência à classe solo exposto, conforme mostra a Figura 15. É possível notar também que esse grupo 1 apresenta considerável pertinência à classe vegetação, indicando que as áreas exemplificadas

por b4 podem se tratar de pastagens ou regiões degradadas com pouca vegetação. As áreas exemplificadas por b1, b2, b3 e b4 foram classificadas de forma condizente com a interpretação visual.

As áreas exemplificadas por c1, c2 e c3 na Figura 17, em tons mais escuros, são representadas na Figura 12 pela cor cinza. De acordo com a Figura 13, essa cor corresponde ao grupo 3 e a Figura 15 indica uma alta pertinência à classe solo exposto. Esse grupo também apresenta considerável pertinência às classes vegetação, água turva e solo úmido, além de uma pertinência à classe água limpa maior em relação aos demais grupos. Apesar disso, os tons escuros e a forma geométrica depreendidos da interpretação visual da Figura 17 indicam tratar-se de cursos d'água, represas ou lagos, mas podem representar também áreas de queimadas. Dessa forma, embora o processo de agrupamento tenha delimitado satisfatoriamente as áreas exemplificadas por c1, c2 e c3, conforme a Figura 12, o processo de classificação apenas identificou essas regiões como solo úmido.

Considerando que cada *pixel* das imagens do sensor CBERS-2B/CCD abrange uma área de 20 x 20 m, ou 400 m², é possível calcular o tamanho das áreas ocupadas por cada objeto analisando as Figuras 13 e 15. O resultado é apresentado na Tabela 7.

Tabela 7 – Áreas ocupadas pelos objetos solo exposto, solo úmido, vegetação, água turva e água limpa na cena obtida pelo sensor CBERS-2B/CCD.

Classe	Quantidade de <i>Pixels</i>	Área Total (km ²)
Solo exposto	88.295	35,32
Solo úmido	0	0
Vegetação	44.761	17,90
Água turva	0	0
Água limpa	0	0
TOTAL	133.056	53,22

Por outro lado, se for considerado que a mistura dos objetos solo exposto, solo úmido, vegetação, água turva e água limpa pode originar outros objetos como solo úmido, vegetação arbórea e vegetação rasteira, então a Tabela 8 ilustra um novo cálculo para essas áreas.

3.3 Experimento Sobre Imagem do Sensor Landsat-5/TM

Sobre a imagem recortada nas bandas 3 e 4, mostrada anteriormente na Figura 8, foi executado o programa *sAgrupamento.m* com os seguintes parâmetros de entrada para a função *fFCM.m*:

I: matriz de dimensão 2.367.904 x 2 contendo os valores digitais de 2.367.904 *pixels* nas bandas espectrais 3 e 4.

MuInicial: [], para que uma matriz de graus de pertinência inicial seja gerada.

CentInicial: [], para que uma matriz de centroides inicial seja gerada.

numGrupos: 5.

maxIteracoes: 100.

epsilon: 0,0001.

expPonderacao: 1,5.

Tabela 8 – Áreas ocupadas pelos objetos reconhecidos pelo protótipo na cena obtida pelo sensor CBERS-2B/CCD.

Classe	Quantidade de <i>Pixels</i>	Área Total (km ²)
Vegetação rasteira	42.984	17,19
Vegetação arbórea	44.761	17,90
Solo úmido	12.582	5,03
Solo exposto	32.729	13,09
TOTAL	133.056	53,22

Como resultado desse processamento, obteve-se o Mapa de Grupos apresentado na Figura 18, a Estatística de *Pixels* Agrupados na Figura 19 e a Variação das Diferenças Entre as Matrizes de Pertinência na Figura 20. Os parâmetros de saída *qtdeIteracoes* e *epsilonSaida* retornaram os valores 96 e 0,00010, respectivamente.

As Figuras 18 e 19 indicam que todos os *pixels* foram agrupados. E também não poderia ser diferente, visto que o método da pertinência máxima empregado na etapa de de-difusividade associa todos os *pixels* a algum grupo, independentemente de situações em que ocorrem valores baixos de pertinência.

Para essa execução, a Figura 20 mostra que a diferença entre as matrizes de pertinência começa a decrescer efetivamente a partir da 8^a iteração e atinge um valor ε abaixo de 0,0001 na 96^a iteração.

Depois de gerados os grupos, a etapa seguinte de classificação foi executada por meio do programa *sClassificacao.m*, utilizando-se novamente o algoritmo FCM ao chamar a função *fFCM.m* com os seguintes parâmetros de entrada:

I: matriz de dimensão 5 x 2 contendo os 5 centroides de cada grupo em cada uma das bandas espectrais 3 e 4.

MuInicial: [], para que uma matriz de graus de pertinência inicial seja gerada.

CentInicial: valores digitais médios dos *pixels* para os alvos terrestres de interesse nas bandas 3 e 4, conforme a Tabela 5.

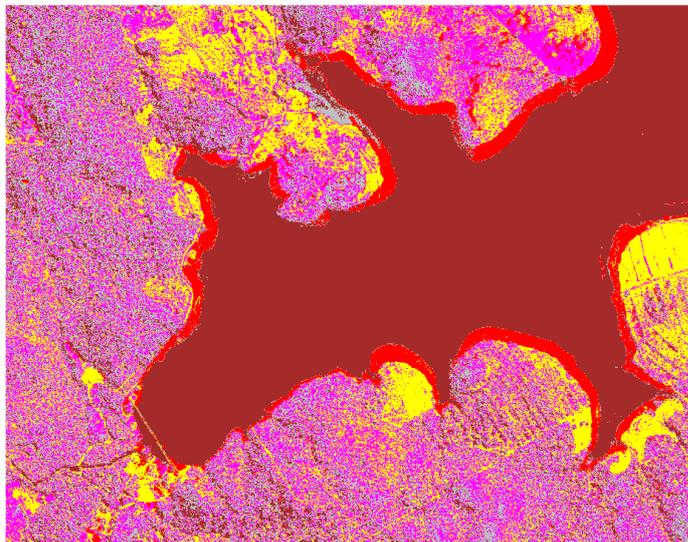
numGrupos: 5.

maxIteracoes: 1.

epsilon: 0,0001.

expPonderacao: 1,5.

Figura 18 – Mapa de Grupos resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.



Como resultado da classificação, obteve-se o Gráfico de Pertinência de Grupos às Classes de Alvos Terrestres apresentado na Figura 21. Nesse gráfico é possível constatar que: o grupo 1 apresenta a maior pertinência de 0,37 à classe solo exposto; o grupo 2 apresenta a maior pertinência de 0,54 à classe água limpa; o grupo 3 apresenta a maior pertinência de 0,87 à classe solo exposto; o grupo 4 apresenta a maior pertinência de 0,45 à classe vegetação; e o grupo 5 apresenta a maior pertinência de 0,60 também à classe vegetação. Não houve nenhuma pertinência máxima associada às classes solo úmido e água turva, mas houve pertinências parciais a essas classes nos grupos 1, 2, 4 e 5.

Para validar os resultados da classificação, obteve-se por meio da ferramenta *Google Maps*² uma imagem que corresponde às coordenadas geográficas extraídas da cena georreferenciada do sensor Landsat-5/TM. A Figura 22 mostra a imagem obtida e categorizada visualmente de acordo com os seguintes alvos: vegetação (indicações a1, a2 e a3); solo exposto (b1); água e áreas úmidas (c1, c2 e c3).

² Disponível em: <https://www.google.com.br/maps/place/16%C2%B032%2745.6%22S+49%C2%B013%2715.6%22W/@-16.5557493,-49.201495,4350m/data=!3m1!1e3!4m2!3m1!1s0x0:0x0?hl=pt-BR>. Acesso em: 10 ago. 2014, 16:27:58.

Figura 19 – Estatística de *Pixels* Agrupados resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.

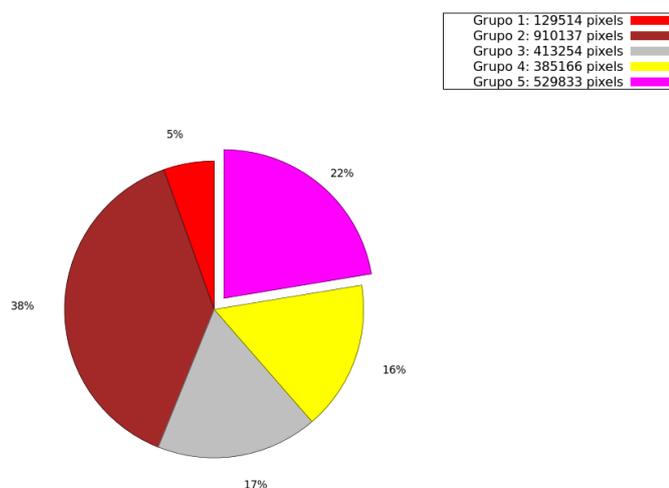
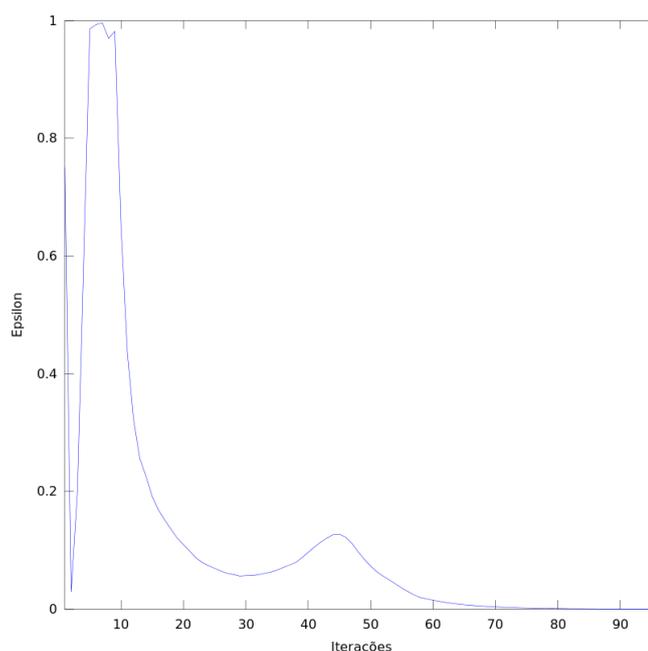


Figura 20 – Variação das Diferenças Entre as Matrizes de Pertinência resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.

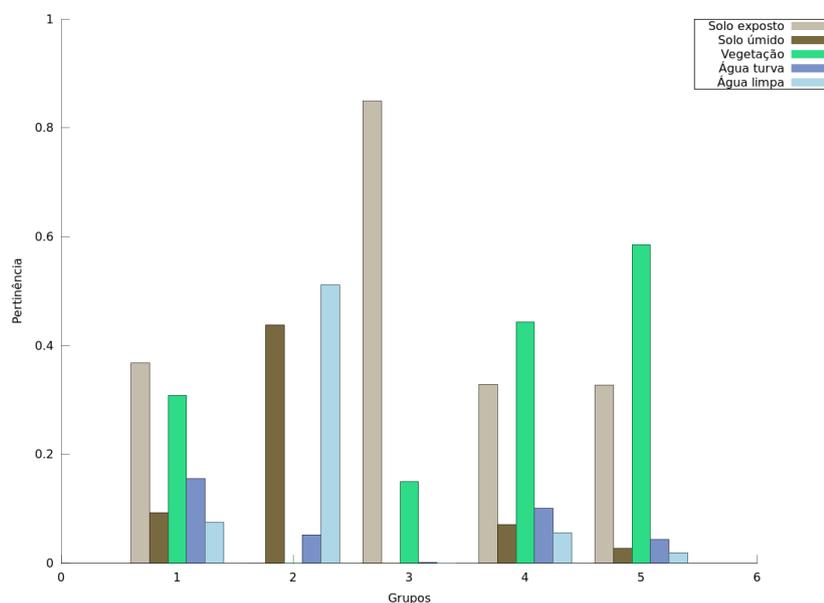


A análise das ilustrações geradas pelo protótipo é feita partindo-se da Figura 22 em direção ao Gráfico de Pertinência de Grupos às Classes de Alvos Terrestres ilustrado na Figura 21, para se reconhecer a quais classes o protótipo associou as áreas assinaladas na Figura 22.

Percebe-se que as áreas exemplificadas por a1 são representadas na Figura 18 pela cor lilás, que representa o grupo 5, de acordo com a Figura 19. A Figura 21 indica que o grupo 5 apresenta alta pertinência à classe vegetação, o que condiz com a visualização da Figura 22. Já as áreas exemplificadas por a2 e a3, representadas na Figura 18 pela cor

amarela, correspondem ao grupo 4, de acordo com a Figura 19. O grupo 4, conforme a Figura 21, apresenta alta pertinência também à classe vegetação. É possível notar também que esse grupo 4 apresenta considerável pertinência à classe solo exposto, indicando que as áreas exemplificadas por a2 e a3 podem se tratar de pastagens ou regiões degradadas com pouca vegetação, diferentemente do grupo 5 mencionado anteriormente, que apresenta pertinência bem maior à classe vegetação e cujas áreas exemplificadas por a1 podem se tratar de florestas ou vegetação arbórea. As áreas exemplificadas por a1, a2 e a3 foram classificadas de forma condizente com a visualização da Figura 22.

Figura 21 – Pertinência de Grupos às Classes de Alvos Terrestres resultante da execução do protótipo sobre a cena obtida pelo sensor Landsat-5/TM.

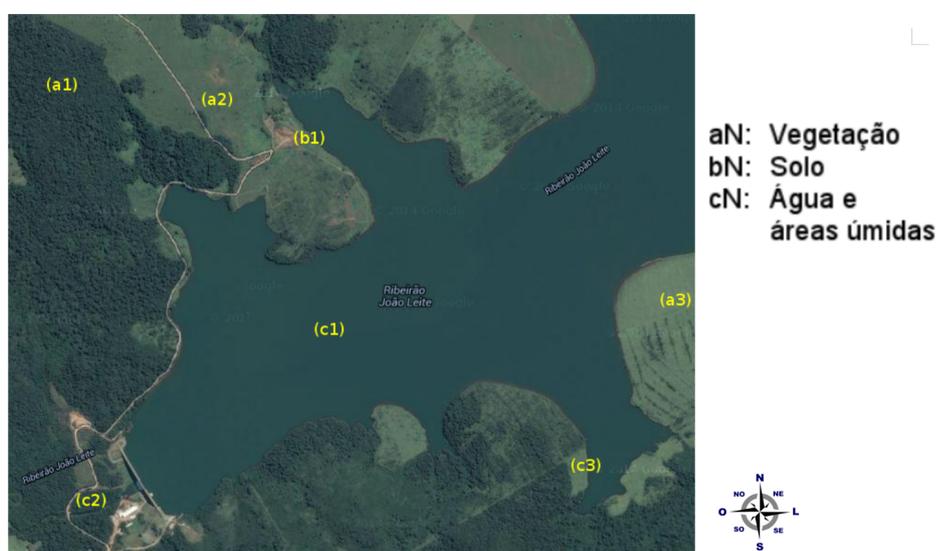


As áreas exemplificadas por b1, que estão distribuídas de forma esparsa de acordo com a Figura 22, são representadas na Figura 18 pela cor cinza. De acordo com a Figura 19, essa cor corresponde ao grupo 3 e a Figura 21 indica uma alta pertinência à classe solo exposto, com uma pertinência razoavelmente menor à classe vegetação. Trata-se portanto de uma indicação de áreas com pouca vegetação, mas predominantemente solo exposto, também condizente com a visualização da Figura 22.

A área exemplificada por c1, que visualmente identifica parte da represa do Ribeirão João Leite na Figura 22, é representada na Figura 18 pela cor marrom. De acordo com a Figura 19, essa cor corresponde ao grupo 2 e a Figura 21 indica uma alta pertinência à classe água limpa, uma considerável pertinência à classe solo úmido e uma pertinência razoavelmente menor à classe água turva. A classificação como água limpa indica a grande extensão da superfície aquática, enquanto que a classificação como solo úmido pode indicar o fundo da represa. A área exemplificada por c2, que também é representada pela cor marrom na Figura 18, apresenta as mesmas características da área c1, ou seja, alta pertinência à classe água limpa, considerável pertinência à classe solo

úmido e uma pertinência menor à classe água turva. Contudo, trata-se de curso d'água do Ribeirão João Leite, depois de passar pela barragem para captação de água, conforme é mostrado nas Figuras 22 e 18, evidenciando a capacidade do protótipo para identificar cursos d'água sob a forma de represas ou de ribeirões. As áreas exemplificadas por c3 na Figura 22 são representadas na Figura 18 pela cor vermelha. De acordo com a Figura 19, essa cor corresponde ao grupo 1 e a Figura 21 indica uma alta pertinência à classe solo exposto. Esse grupo também apresenta considerável pertinência a todas as demais classes, ou seja, vegetação, água turva, solo úmido e água limpa. Trata-se ainda do grupo que evidencia a maior pertinência à classe água turva, em relação aos demais grupos. Por essas características, o grupo 1 representa áreas que se diferenciam das demais pela sua alta umidade, ou seja, não são propriamente cursos d'água mas sim áreas úmidas, áreas de solo e/ou vegetação que possuem alta umidade. Na Figura 18 as áreas úmidas estão ao redor da represa do Ribeirão João Leite e alguns pontos esparsos da cena imageada. Também as áreas exemplificadas por c1, c2 e c3 foram classificadas de forma condizente com a visualização da Figura 22.

Figura 22 – Imagem obtida a partir da ferramenta *Google Maps*, categorizada por alvos terrestres, correspondente geograficamente à cena obtida pelo sensor Landsat-5/TM.



Considerando que cada *pixel* das imagens do sensor Landsat-5/TM abrange uma área de 30 x 30 m, ou 900 m², é possível calcular o tamanho das áreas ocupadas por cada objeto analisando as Figuras 19 e 21. O resultado é apresentado na Tabela 9.

Por outro lado, se for considerado que a mistura dos objetos solo exposto, solo úmido, vegetação, água turva e água limpa pode originar outros objetos como vegetação densa e vegetação rala, então a Tabela 10 ilustra um novo cálculo para essas áreas.

Tabela 9 – Áreas ocupadas pelos objetos solo exposto, solo úmido, vegetação, água turva e água limpa na cena obtida pelo sensor Landsat-5/TM.

Classe	Quantidade de <i>Pixels</i>	Área Total (km ²)
Solo exposto	542.768	488,49
Solo úmido	0	0
Vegetação	914.999	823,50
Água turva	0	0
Água limpa	910.137	819,12
TOTAL	2.367.904	2.131,11

Tabela 10 – Áreas ocupadas pelos objetos reconhecidos pelo protótipo na cena obtida pelo sensor Landsat-5/TM.

Classe	Quantidade de <i>Pixels</i>	Área Total (km ²)
Vegetação arbórea	529.833	476,85
Vegetação rasteira	385.166	346,65
Solo úmido	129.514	116,56
Solo exposto	413.254	371,93
Cursos d'água	910.137	819,12
TOTAL	2.367.904	2.131,11

3.4 Experimento Sobre Fotografia Digital

Para testar a utilização do algoritmo FCM sobre fotografias digitais, foi submetida ao protótipo a imagem da Figura 23.

O protótipo foi executado com os seguintes parâmetros de entrada:

I: matriz de dimensão 1.080.299 x 3 contendo os valores digitais de 1.080.299 *pixels* nas bandas espectrais 1, 2 e 3.

MuInicial: [], para que uma matriz de graus de pertinência inicial seja gerada.

CentInicial: [], para que uma matriz de centroides inicial seja gerada.

numGrupos: 3.

maxIteracoes: 100.

epsilon: 0,01.

expPonderacao: 3.0.

Como resultado desse processamento, obteve-se o Mapa de Grupos apresentado na Figura 24, a Estatística de *Pixels* Agrupados na Figura 25 e a Variação das Diferenças

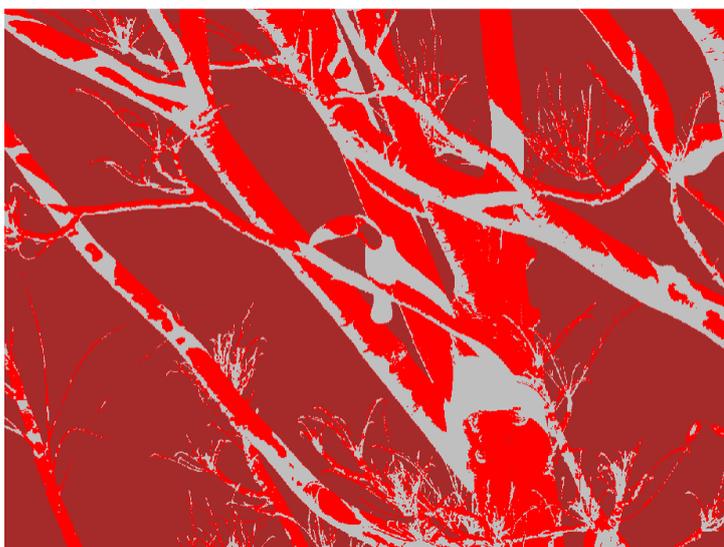
Figura 23 – Fotografia digital submetida ao protótipo.



Fonte: elaborado pelo autor.

Entre as Matrizes de Pertinência na Figura 26. Os parâmetros de saída *qtdeIteracoes* e *epsilonSaida* retornaram os valores 18 e 0,00774, respectivamente.

Figura 24 – Mapa de Grupos resultante da execução do protótipo sobre a fotografia digital.



As figuras mostram uma capacidade satisfatória do protótipo para delimitar as áreas que representam o céu, o tucano, a árvore e ainda as sombras projetadas na árvore.

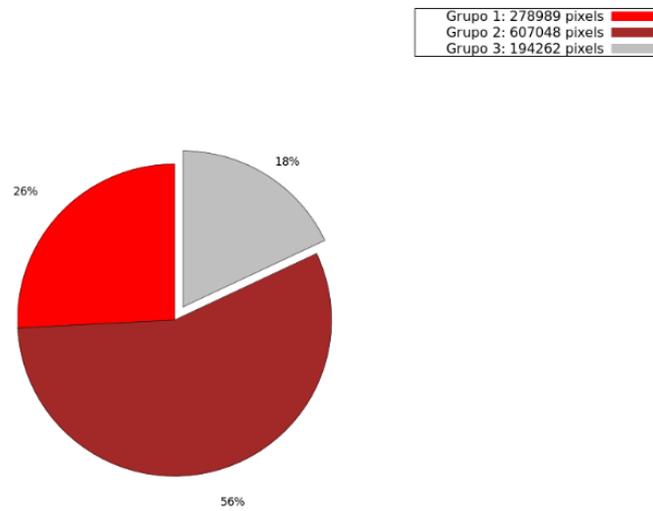
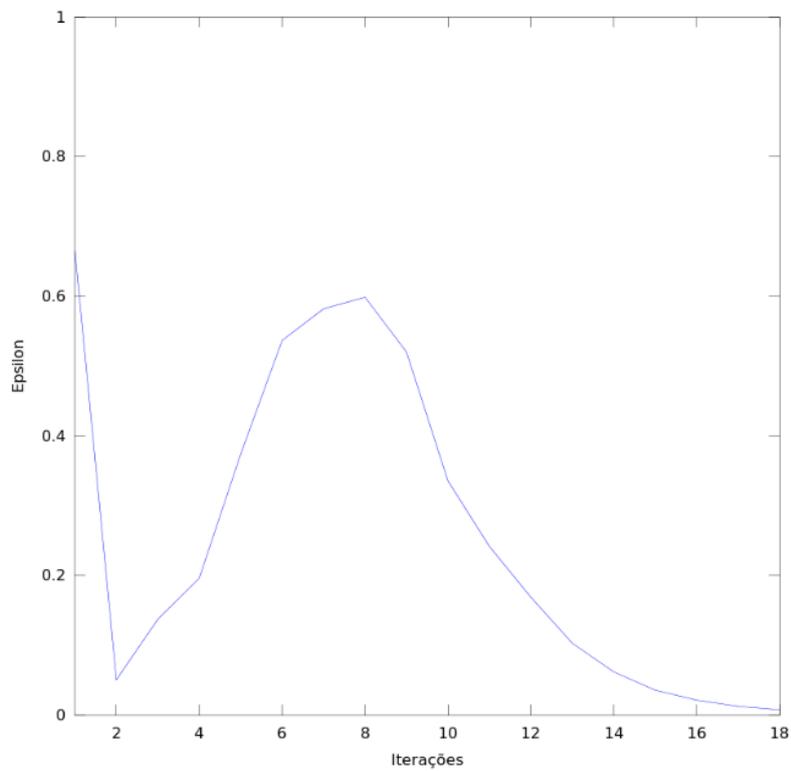
Figura 25 – Estatística de *Pixels* Agrupados resultante da execução do protótipo sobre a fotografia digital.

Figura 26 – Variação das Diferenças Entre as Matrizes de Pertinência resultante da execução do protótipo sobre a fotografia digital.



Conclusão

Este trabalho propôs a construção de um protótipo de *software* empregando ferramentas livres para realização da análise e classificação de *pixels* em imagens de satélite, que está à disposição de outros pesquisadores independentemente de licenças de *software* proprietário. Foi desenvolvida uma metodologia para análise e classificação de *pixels* empregando o algoritmo de agrupamento difuso FCM, utilizando no processo de classificação o conhecimento do comportamento espectral de objetos na superfície terrestre. Nas imagens de satélite foram identificados os seguintes objetos: solo exposto, solo úmido, vegetação, água turva e água limpa. Os tamanhos das áreas ocupadas pelos objetos identificados foram estimados com base na resolução espacial das imagens.

A utilização da lógica *fuzzy* foi fundamentada no problema do *pixel* mistura, situação em que um *pixel* da imagem possui mais de uma categoria de cobertura de solo. Nessa condição, métodos de agrupamento fixo falham por reconhecerem apenas fenômenos que apresentam limites bem definidos e que podem ser facilmente discretizados. Neste trabalho foi implementado o FCM como uma alternativa para o reconhecimento de áreas de incertezas e imprecisões existentes no mundo real, em uma plataforma livre GNU/Octave. O protótipo de *software* recebeu 3 imagens digitais sob a forma de matrizes numéricas e realizou o agrupamento difuso de acordo com parâmetros de entrada como a quantidade de grupos e o fator de difusividade. Posteriormente, o protótipo também realizou a classificação das imagens de satélite com base no comportamento espectral dos alvos de superfície terrestre.

A primeira imagem, adquirida pelo sensor CBERS-2B/CCD, submetida ao protótipo teve a validação realizada por intermédio da comparação dos resultados com a identificação visual da própria imagem utilizada. A segunda imagem, adquirida pelo sensor Landsat-5/TM, oferece a possibilidade de extração de coordenadas geográficas e os resultados do protótipo foram validados pela comparação com outra imagem de satélite que possibilita a identificação visual dos alvos terrestres. Finalmente o protótipo recebeu uma terceira imagem na forma de fotografia digital, cujos resultados do processo de agrupamento difuso também foram validados pela identificação visual.

Vantagens e Limitações

O mérito de usar o agrupamento difuso na análise e classificação de *pixels* em imagens de satélite está na agregação de informação normalmente difusa existente nos objetos do mundo real. Enquanto métodos de agrupamento fixo oferecem uma solução única do problema, o método difuso apresenta várias soluções, cabendo ao analista das

imagens determinar a quantidade de soluções e escolher aquela(s) que mais se revela(m) viável(is) para a solução do problema sob análise. A familiaridade com o domínio do problema é o principal elemento na análise dos resultados encontrados.

O protótipo apresentou resultados satisfatórios para uma imagem adquirida pelo sensor CBERS-2B/CCD. Apesar disso, dependendo do tipo de utilização da imagem, é importante que ela passe por um processo externo de georreferenciamento para que o erro de posicionamento seja eliminado e o erro interno possa ser refinado. Não faz parte do escopo do presente trabalho, mas as pesquisas de Mello et al. (2005), Schowengerdt (2006) e Alves, Meloni e Brito (2011) podem ser consultadas com esse objetivo.

Na etapa de de-difusividade utilizou-se o método da pertinência máxima, onde o elemento com maior valor em cada linha da matriz de valores difusos recebe o valor de pertinência 1,0, enquanto todos os outros elementos na mesma linha recebem o valor 0,0. Assim como muitas questões em lógica *fuzzy*, a escolha do método de de-difusividade deve ser feita com base no contexto dos dados disponíveis. Por isso é interessante comparar outros métodos para a etapa de de-difusividade no contexto das imagens de satélite.

Os resultados obtidos no processo de agrupamento difuso foram satisfatórios para todas as áreas exemplificadas na Figura 17, cuja imagem foi obtida pelo sensor CCD do satélite CBERS-2B. O mesmo não se pode dizer do processo de classificação, que gerou resultados condizentes para os alvos terrestres vegetação e solo, mas não para água, embora esse último tenha sido classificado como solo úmido. Vale a pena, nesse caso, rever as assinaturas espectrais dos objetos água turva e água limpa definidas na seção 2.6, inclusive com visitas a campo para conferir a resposta espectral desses materiais.

Para as áreas exemplificadas na Figura 22, cuja imagem submetida ao protótipo foi obtida do sensor Landsat-5/TM, os resultados obtidos nos processos de agrupamento difuso e de classificação foram satisfatórios, inclusive com relação às áreas úmidas. Para essa imagem especificamente foram utilizadas apenas as bandas espectrais 3 e 4, por estarem disponíveis dentre as bandas que apresentam boa separabilidade espectral. Contudo, havendo disponibilidade, as bandas 5 e 7 também apresentam boa separabilidade espectral e poderiam ser testadas na utilização no protótipo.

Com relação à fotografia digital mostrada na Figura 23, o protótipo gerou resultados satisfatórios para o agrupamento de *pixels*, demonstrando a aplicabilidade do algoritmo FCM também para este tipo de imagem.

A presença de ruído é um problema comum em imagens adquiridas por satélites de sensoriamento remoto. Os ruídos afetam a qualidade e o potencial de interpretação da imagem. Em sistemas de varredura eletrônica, como é o caso do sensor CBERS-2B/CCD, o ruído aparece na forma de listras verticais na direção da trajetória do satélite, variando sua intensidade e periodicidade conforme a banda. O algoritmo FCM original utilizado

neste trabalho tem a desvantagem de desconsiderar qualquer informação sobre o contexto espacial, tornando-se sensível a ruídos. Além disso, o agrupamento pelo método FCM é baseado exclusivamente na intensidade dos *pixels*, tornando-se sensível às variações de intensidade decorrentes da iluminação e da geometria do objeto.

Trabalhos Futuros

O algoritmo FCM original é executado de forma sequencial. É relativamente lento quando aplicado sobre imagens completas de satélite que se constituem em grandes conjuntos de dados. Essa lentidão decorre da necessidade de grande quantidade de memória, que implica no aumento da frequência de acesso a disco. Paralelizar o algoritmo FCM pode ser uma forma de melhorar a performance e a eficiência da tarefa de agrupamento, dividindo os cálculos entre vários processadores e minimizando a necessidade de acesso a disco. Rahimi et al. (2004) apresentam um algoritmo FCM paralelo com esse objetivo.

Outra possibilidade de melhorar a performance é reduzindo a carga de processamento do algoritmo FCM original, mais especificamente os cálculos efetuados nas Equações 2.4 e 2.6 do algoritmo, por meio da substituição de variáveis exatas por estimativas. Cannon, Dave e Bezdek (1986) apresentam um trabalho com essa modificação do algoritmo original.

O algoritmo FCM original tende a encontrar grupos cuja forma é esférica, e não pode ser usado diretamente para detectar formas lineares ou planas na imagem (DAVE, 1992). Trata-se de um problema de agrupamento que pode ser minimizado aplicando técnicas para detecção de bordas. Os trabalhos de Gustafson e Kessel (1978), Bezdek et al. (1981), Anderson, Bezdek e Dave (1982), Dave (1990), Dave (1992), e Dave e Bhaswan (1992) apresentam variações do FCM para detecção de grupos em outras formas.

Há trabalhos sobre imagens multiespectrais de satélite como Stefanos e Filho (2009) que descartam as bandas espectrais com ruídos significativos, porém existe o risco de descartar também informações relevantes para o processo de análise e classificação.

Outros trabalhos utilizam variações do método FCM para reduzir o ruído da imagem: FCM com informação espacial adaptável (PHAM, 2001; LIEW; YAN, 2003; CHUANG et al., 2006) e FCM suprimido para segmentação MRI (HUNG; YANG; CHEN, 2006).

Referências

- ALI, M. A.; DOOLEY, L. S.; KARMAKAR, G. C. Object based image segmentation using fuzzy clustering. In: IEEE. *Acoustics, Speech and Signal Processing*. [S.l.], 2006. v. 2, p. II–II. Citado na página 27.
- ALVES, A. O.; MELONI, R. B. da S.; BRITO, J. L. N. e S. Registro semi-automático de imagens cbers utilizando coeficiente de correlação de pearson. In: *Simpósio Brasileiro de Sensoriamento Remoto, 15, Curitiba*. São José dos Campos: INPE, 2011. p. 2546–2552. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0563.pdf>>. Acesso em: 16 abr. 2014, 16:27:32. Citado na página 70.
- AN, P.; MOON, W. M.; RENCZ, A. Application of fuzzy set theory for integration of geological, geophysical and remote sensing data. *Canadian Journal of Exploration Geophysics*, v. 27, n. 1, p. 1–11, 1991. Citado na página 26.
- ANDERSON, I. A.; BEZDEK, J. C.; DAVE, R. Polygonal shape description of plane boundaries. *Systems science and science*, v. 1, p. 295–301, 1982. Citado na página 71.
- ANDRADE, E. L. de; SILVA, U. M. da. Avaliação da classificação não-supervisionada em imagens de alta resolução, utilizando a lógica fuzzy. In: *Simpósio Brasileiro de Sensoriamento Remoto, 15, Curitiba*. São José dos Campos: INPE, 2011. p. 7418–7425. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0623.pdf>>. Acesso em: 16 abr. 2014, 16:41:27. Citado na página 42.
- BEEVI, S. Z.; SATHIK, M. M.; SENTHAMARAIKANNAN, K. A robust fuzzy clustering technique with spatial neighborhood information for effective medical image segmentation. *arXiv preprint arXiv:1004.1679*, 2010. Citado na página 30.
- BEEVI, Z.; SATHIK, M. A robust segmentation approach for noisy medical images using fuzzy clustering with spatial probability. *International Arab Journal of Information Technology (IAJIT)*, v. 9, n. 1, 2010. Citado 2 vezes nas páginas 26 e 30.
- BEGUM, S. A.; DEVI, O. M. Fuzzy algorithms for pattern recognition in medical diagnosis. *Assam University Journal of Science and Technology*, v. 7, n. 2, p. 1–12, 2011. Citado 3 vezes nas páginas 26, 28 e 30.
- BELLMAN, R.; KALABA, R.; ZADEH, L. A. Abstraction and pattern classification. *Journal of Mathematical Analysis and Applications*, Academic Press, v. 13, n. 1, p. 1–7, 1966. Citado na página 27.
- BEZDEK, J. C. *Fuzzy mathematics in pattern classification*. Tese (Doutorado) — Applied Math. Center, Cornell University, Ithaca, 1973. Citado na página 28.
- BEZDEK, J. C. Numerical taxonomy with fuzzy sets. *Journal of Mathematical Biology*, Springer, v. 1, n. 1, p. 57–71, 1974. Citado na página 26.
- BEZDEK, J. C. et al. Detection and characterization of cluster substructure i. linear structure: fuzzy c-lines. *SIAM Journal on Applied Mathematics*, SIAM, v. 40, n. 2, p. 339–357, 1981. Citado 2 vezes nas páginas 28 e 71.

- BEZDEK, J. C.; EHRLICH, R.; FULL, W. Fcm: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, Elsevier, v. 10, n. 2, p. 191–203, 1984. Citado 4 vezes nas páginas 27, 28, 43 e 44.
- BEZDEK, J. C.; HALL, L. O.; CLARKE, L. P. Review of MR image segmentation techniques using pattern recognition. *MEDICAL PHYSICS-LANCASTER PA-*, American Institute of Physics, v. 20, p. 1033–1033, 1993. Citado na página 26.
- BEZDEK, J. C. et al. Fuzzy clustering: a new approach for geostatistical analysis. *Int. Jour. Sys., Measurement and Decision*, v. 1/2, p. 13–24, 1982. Citado na página 24.
- BOJADZIEV, G.; BOJADZIEV, M. *Fuzzy logic for business, finance, and management*. [S.l.]: World Scientific Publishing Co., Inc., 2007. Citado na página 26.
- BORBA, J. A.; MURCIA, F. D. R.; MAIOR, C. D. S. Fuzzy abc: Modelando a incerteza na alocação dos custos ambientais. *Revista Brasileira de Gestão de Negócios*, v. 9, n. 24, 2007. Citado na página 26.
- BORKOWSKI, L. *Jan Lukasiewicz: selected works*. [S.l.]: North-Holland, 1970. Citado na página 78.
- BRASIL. Ministério do Meio Ambiente. 2014. *Dia mundial das zonas úmidas*. Disponível em: <<http://www.mma.gov.br/biodiversidade/biodiversidade-aquatica/zonas-umidas-convencao-de-ramsar/conven%C3%A7%C3%A3o-de-ramsar>>. Acesso em: 06 set. 2014, 20:30:05. Citado na página 25.
- CÂMARA, G. et al. *Introdução à ciência da geoinformação*. São José dos Campos: INPE, 2001. Citado na página 25.
- CAMPBELL, J. B.; WYNNE, R. H. *Introduction to Remote Sensing*. [S.l.]: CRC, 2008. ISBN 9780849363955. Citado 2 vezes nas páginas 23 e 24.
- CANNON, R. L.; DAVE, J. V.; BEZDEK, J. C. Efficient implementation of the fuzzy c-means clustering algorithms. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, n. 2, p. 248–255, 1986. Citado 4 vezes nas páginas 28, 43, 44 e 71.
- CANNON, R. L. et al. Segmentation of a thematic mapper image using the fuzzy c-means clustering algorithm. *Geoscience and Remote Sensing, IEEE Transactions on*, IEEE, n. 3, p. 400–408, 1986. Citado na página 28.
- CHAVES, M. B. et al. Classificação de imagens cbers para mapeamento de áreas de recarga de mananciais subterrâneos. In: *Simpósio Brasileiro de Sensoriamento Remoto, 14, Natal*. São José dos Campos: INPE, 2009. p. 4679–4686. Citado na página 48.
- CHEN, W.; GIGER, M. L.; BICK, U. A fuzzy c-means (fcm)-based approach for computerized segmentation of breast lesions in dynamic contrast-enhanced mr images. *Academic radiology*, Elsevier, v. 13, n. 1, p. 63–72, 2006. Citado na página 26.
- CHUANG, K.-S. et al. Fuzzy c-means clustering with spatial information for image segmentation. *Computerized Medical Imaging and Graphics*, Elsevier, v. 30, n. 1, p. 9–15, 2006. Citado 2 vezes nas páginas 26 e 71.

- CUNHA, K. L. *Uso de imagens Landsat e CBERS no mapeamento da suscetibilidade à erosão na região de Primavera do Leste – MT*. Dissertação (Mestrado em Física Ambiental) — Universidade Federal de Mato Grosso, Cuiabá, 2009. Citado na página 50.
- DABOV, K. et al. Image denoising by sparse 3-d transform-domain collaborative filtering. *Image Processing, IEEE Transactions on*, IEEE, v. 16, n. 8, p. 2080–2095, 2007. Citado na página 30.
- DAVE, R. N. Fuzzy shell-clustering and applications to circle detection in digital images. *International Journal Of General System*, Taylor & Francis, v. 16, n. 4, p. 343–355, 1990. Citado na página 71.
- DAVE, R. N. Boundary detection through fuzzy clustering. In: *Proc. IEEE Int. Conference on Fuzzy Systems*. [S.l.: s.n.], 1992. p. 8–12. Citado 2 vezes nas páginas 44 e 71.
- DAVE, R. N.; BHASWAN, K. Adaptive fuzzy c-shells clustering and detection of ellipses. *Neural Networks, IEEE Transactions on*, IEEE, v. 3, n. 5, p. 643–662, 1992. Citado na página 71.
- DUDA, R. O.; HART, P. E. *Pattern classification and scene analysis*. [S.l.]: CRC-Press, 2006. ISBN 9780849363955. Citado na página 23.
- DUNN, J. C. A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, v. 3, n. 3, p. 32–57, 1974. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01969727308546046>>. Acesso em: 17 abr. 2014, 17:28:31. Citado 2 vezes nas páginas 27 e 28.
- ENGESAT. *Consulta gráfica das melhores cenas CBERS disponíveis, selecionadas pela EngeSat*. Curitiba: [s.n.], 2006. Disponível em: <http://www.engesat.com.br/produtos-/grade_cbers/go_tm.htm>. Acesso em: 28 ago. 2013, 09:06:45. Citado na página 36.
- ESA. European Space Agency. 2013. *The BEAM project*. Disponível em: <<http://www-.brockmann-consult.de/cms/web/beam/welcome>>. Acesso em: 12 out. 2013, 14:51:13. Citado na página 40.
- FAN, J.-L.; ZHEN, W.-Z.; XIE, W.-X. Suppressed fuzzy c-means clustering algorithm. *Pattern Recognition Letters*, v. 24, n. 9-10, p. 1607 – 1612, 2003. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865502004014>>. Acesso em: 17 abr. 2014, 17:31:40. Citado na página 27.
- FISHER, P. F.; PATHIRANA, S. The evaluation of fuzzy membership of land cover classes in the suburban zone. *Remote Sensing of Environment*, Elsevier, v. 34, n. 2, p. 121–132, 1990. Citado 2 vezes nas páginas 43 e 44.
- FISHER, P. F.; PATHIRANA, S. The ordering of multitemporal fuzzy landcover information derived from landsat mss data. *Geocarto International*, v. 8, n. 3, p. 5–14, 1993. Citado na página 33.

- FLORENZANO, T. G. *Imagens de satélite para estudos ambientais*. São Paulo: Oficina de Textos, 2002. ISBN 9788586238215. Disponível em: <<http://books.google.com.br/books?id=RFLcAAAACAAJ>>. Acesso em: 15 abr. 2014, 11:58:20. Citado 2 vezes nas páginas 25 e 52.
- GAN, G.; MA, C.; WU, J. *Data clustering: theory, algorithms, and applications*. Society for Industrial and Applied Mathematics, 2007. (ASA-SIAM Series on Statistics and Applied Probability). ISBN 9780898716238. Disponível em: <<http://books.google.com.br/books?id=ZXLSPV1X1sC>>. Acesso em: 17 abr. 2014, 17:34:11. Citado 2 vezes nas páginas 26 e 27.
- GANESH, M.; PALANISAMY, V. A modified adaptive fuzzy c-means clustering algorithm for brain mr image segmentation. *International Journal of Engineering Research & Technology (IJERT)*, v. 1, 2012. Citado 2 vezes nas páginas 26 e 31.
- GANGA, G. M. D.; CARPINETTI, L. C. R.; POLITANO, P. R. Gestão do desempenho em cadeias de suprimentos usando lógica fuzzy. *Gestão & Produção*, scielo, v. 18, p. 755–774, 2011. ISSN 0104-530X. Citado na página 26.
- GATH, I.; HOORY, D. Fuzzy clustering of elliptic ring-shaped clusters. *Pattern recognition letters*, Elsevier, v. 16, n. 7, p. 727–741, 1995. Citado na página 27.
- GONZALEZ, R.; WOODS, R. *Processamento de imagens digitais*. São Paulo: Edgard Blucher, 2000. ISBN 9788521202646. Disponível em: <<http://books.google.com.br/books?id=d3MnAgAACAAJ>>. Acesso em: 17 abr. 2014, 17:37:41. Citado 2 vezes nas páginas 23 e 37.
- GUSTAFSON, D. E.; KESSEL, W. C. Fuzzy clustering with a fuzzy covariance matrix. In: IEEE. *Decision and Control including the 17th Symposium on Adaptive Processes, 1978 IEEE Conference on*. [S.l.], 1978. v. 17, p. 761–766. Citado 3 vezes nas páginas 27, 28 e 71.
- HERRERA, F. Genetic fuzzy systems: taxonomy, current research trends and prospects. *Evolutionary Intelligence*, Springer, v. 1, n. 1, p. 27–46, 2008. Citado na página 26.
- HÖPPNER, F. et al. *Fuzzy Cluster Analysis: Methods for Classification, Data Analysis and Image Recognition*. Chichester: Wiley, 1999. (Wiley IBM PC Series). ISBN 9780471988649. Disponível em: <<http://books.google.com.br/books?id=ZWaREPjUVeMC>>. Acesso em: 17 abr. 2014, 17:39:17. Citado 4 vezes nas páginas 23, 24, 27 e 29.
- HUNG, W.-L.; YANG, M.-S.; CHEN, D.-H. Parameter selection for suppressed fuzzy c-means with an application to MRI segmentation. *Pattern Recognition Letters*, Elsevier, v. 27, n. 5, p. 424–438, 2006. Citado na página 71.
- HUNTSBERGER, T. L.; DESCALZI, M. F. Color edge detection. *Pattern Recognition Letters*, Elsevier, v. 3, n. 3, p. 205–209, 1985. Citado na página 28.
- INPE. Instituto Nacional de Pesquisas Espaciais. Coordenação-Geral de Observação da Terra. Divisão de Geração de Imagens. 2005. *Licença de uso das imagens CBERS para usuários brasileiros*. Disponível em: <http://www.dgi.inpe.br/pedidos_CBERS/licenca-CBERS.htm>. Acesso em: 02 out. 2013, 11:55:10. Citado na página 35.

- INPE. Instituto Nacional de Pesquisas Espaciais. Coordenação-Geral de Observação da Terra. Divisão de Geração de Imagens. 2008. *As imagens Landsat TM*. Disponível em: <http://www.dgi.inpe.br/pedidos_Landsat/>. Acesso em: 01 set. 2014, 12:52:30. Citado 3 vezes nas páginas 36, 37 e 41.
- INPE. Instituto Nacional de Pesquisas Espaciais. Coordenação-Geral de Observação da Terra. Divisão de Geração de Imagens. 2009. *Imagens CBERS*. Disponível em: <<http://www.dgi.inpe.br/siteDgi/CBERS.php>>. Acesso em: 28 ago. 2013, 10:35:21. Citado 3 vezes nas páginas 36, 39 e 40.
- INPE. Instituto Nacional de Pesquisas Espaciais. Coordenação-Geral de Observação da Terra. 2011. *Câmeras imageadoras CBERS-1, 2 e 2B*. Disponível em: <http://www.cbers.inpe.br/sobre_satelite/cameras_imageadoras_cbers1e2e2b.php>. Acesso em: 05 out. 2013, 16:05:30. Citado na página 35.
- IWAI, O. K. *Mapeamento do uso do solo urbano do município de São Bernardo do Campo, através de imagens de satélites*. Dissertação (Mestrado em Engenharia de Transportes) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2003. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3138/tde-03022004-152010/>>. Acesso em: 20 abr. 2014, 11:45:30. Citado na página 50.
- JAIN, A. K.; DUBES, R. C. *Algorithms for clustering data*. [S.l.]: Prentice-Hall, Inc., 1988. Citado na página 28.
- JENSEN, J. R. *Remote sensing of the environment: an earth resource perspective*. New Jersey: Pearson Prentice Hall, 2006. ISBN 9780849363955. Citado na página 24.
- JONG, F. v. d. M. Steven M. de. *Remote sensing image analysis: including the spatial domain*. [S.l.]: Springer, 2008. Citado 2 vezes nas páginas 23 e 24.
- KANNAN, S. R. et al. Fuzzy clustering approach in segmentation of t1-t2 brain mri. *International Journal on Signal & Image Processing*, v. 1, n. 2, 2010. Citado na página 29.
- KANNAN, S. R.; RAMATHILAGAM, S.; SATHYA, A. Robust fuzzy c-means in classifying breast tissue regions. In: IEEE. *Advances in Recent Technologies in Communication and Computing, 2009. ARTCom'09. International Conference on*. [S.l.], 2009. p. 543–545. Citado na página 29.
- KELLER, J.; KRISNAPURAM, R.; PAL, N. R. *Fuzzy models and algorithms for pattern recognition and image processing*. [S.l.]: Springer, 2005. Citado na página 26.
- KLAWONN, F.; KRUSE, R.; RUNKLER, T. *Fuzzy cluster analysis: methods for classification, data analysis and image recognition*. [S.l.]: CRC-Press, 2010. (Wiley IBM PC Series). ISBN 9780849363955. Citado na página 24.
- KRINIDIS, S.; CHATZIS, V. A robust fuzzy local information c-means clustering algorithm. *Image Processing, IEEE Transactions on*, IEEE, v. 19, n. 5, p. 1328–1337, 2010. Citado na página 30.
- KRISHNAPURAM, R.; KELLER, J. M. A possibilistic approach to clustering. *Fuzzy Systems, IEEE Transactions on*, IEEE, v. 1, n. 2, p. 98–110, 1993. Citado na página 27.

- LIEW, A.-C.; YAN, H. An adaptive spatial fuzzy clustering algorithm for 3-d mr image segmentation. *Medical Imaging, IEEE Transactions on*, IEEE, v. 22, n. 9, p. 1063–1075, 2003. Citado 2 vezes nas páginas 26 e 71.
- LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. *Remote Sensing and Image Interpretation*. [S.l.]: Willey, 2007. ISBN 9780849363955. Citado 2 vezes nas páginas 24 e 25.
- LILLESAND, T. M.; KIEFER, R. W. *Remote sensing and image interpretation*. Wiley & Sons, 1994. ISBN 9780471577836. Disponível em: <<http://books.google.com.br/books?id=BU3uAAAAMAAJ>>. Acesso em: 01 set. 2013, 22:41:12. Citado 2 vezes nas páginas 48 e 50.
- LIMA, B. F.; MORATO, R. G. Mapeamento do uso da terra e da expansão urbana em alfenas, sul de minas gerais. *Anais... XVI Encontro Nacional De Geógrafos. Porto Alegre*, 2010. Citado 3 vezes nas páginas 48, 50 e 52.
- LINDEN, R. Técnicas de agrupamento. *Revista de Sistemas de Informação da FSMA*, n. 4, p. 18–36, 2009. Citado na página 41.
- LODWICK, W. *Surfaces in GIS and Geographical Analysis: Theory, Analytical Methods, Algorithms and Applications*. [S.l.]: The Gilford Press, 2008. Citado na página 23.
- LUIZ, A. J. B. et al. Auxílio das imagens de satélite aos levantamentos por amostragem em agricultura. *Agricultura em São Paulo*, v. 49, n. 1, p. 41–54, 2002. Citado na página 50.
- LUKASIEWICZ, J.; TARSKI, A. Untersuchungen über den aussagenkalkül. *Comptes Rendus des Séances de la Société des Sciences et des Lettres de Varsovie*, v. 23, 1930. Reprinted and translated in Borkowski (1970). Citado na página 27.
- LUNG, H. V.; KIM, J.-M. A generalized spatial fuzzy c-means algorithm for medical image segmentation. In: IEEE. *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on*. [S.l.], 2009. p. 409–414. Citado 2 vezes nas páginas 26 e 29.
- MACQUEEN, J. B. Some methods for classification and analysis of multivariate observations. In: CAM, L. M. L.; NEYMAN, J. (Ed.). *Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability*. [S.l.]: University of California Press, 1967. v. 1, p. 281–297. Citado na página 25.
- MAN, Y. H.; GATH, I. Detection and separation of ring-shaped clusters using fuzzy clustering. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 16, n. 8, p. 855–861, 1994. Citado na página 27.
- MATHER, P.; KOCH, M. *Computer Processing of Remotely-Sensed Images: An Introduction*. [S.l.]: Willey-Blacwell, 2011. ISBN 9780849363955. Citado 2 vezes nas páginas 24 e 47.
- MELLO, E. M. K. et al. O uso de imagens cbers no monitoramento do desflorestamento da amazônia brasileira. In: *Simpósio Brasileiro de Sensoriamento Remoto, 12, Goiânia*. São José dos Campos: INPE, 2005. p. 1313–1320. Disponível em: <<http://marte.sid.inpe.br/col/ltid.inpe.br/sbsr/2004/11.12.16.06/doc/1313.pdf>>. Acesso em: 16 abr. 2014, 15:55:30. Citado na página 70.

- MENESES, P. R.; ALMEIDA, T. (Org.). *Introdução ao processamento de imagens de sensoriamento remoto*. Brasília: UnB/CNPq, 2012. Disponível em: <<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 15 abr. 2014, 11:58:20. Citado na página 23.
- MESAKAR, S. S.; CHAUDHART, M. S. Image segmentation by fuzzy clustering algorithm for brain tumor detection. In: *Proceedings of IRAJ International Conference, 21st*. Pune, Índia: [s.n.], 2013. p. 41–44. Citado na página 26.
- MINGOTI, S. A.; LIMA, J. O. Comparing som neural network with fuzzy c-means, k-means and traditional hierarchical clustering algorithms. *European Journal of Operational Research*, Elsevier, v. 174, n. 3, p. 1742–1759, 2006. Citado na página 28.
- MIRANDA, J. I. *Processamento de imagens digitais: métodos multivariados em java*. Campinas, SP: Embrapa Informática Agropecuária, 2011. Citado 12 vezes nas páginas 24, 26, 27, 33, 34, 37, 41, 42, 43, 44, 46 e 47.
- MOREIRA, F. R. d. S.; FILHO, R. d. A.; CÂMARA, G. Aplicação da abordagem de importação semântica (is) para caracterização de contatos litológicos em modelos de inferência espacial. *Rem: Revista Escola de Minas, SciELO Brasil*, v. 55, n. 4, p. 301–306, 2002. Citado na página 26.
- MOREIRA, M. *Fundamentos do sensoriamento remoto e metodologias de aplicação*. UFV, 2003. ISBN 9788572691581. Disponível em: <<http://books.google.com.br/books?id=pue3twAACAAJ>>. Citado na página 50.
- NAVALUR, K. *Multispectral Image Analysis Using the Object-Oriented Paradigm*. [S.l.]: CRC, 2008. Citado na página 23.
- NAVULUR, K. *Multispectral image analysis using the object-oriented paradigm*. [S.l.]: CRC press, 2006. Citado na página 34.
- NAZ, S.; MAJEED, H.; IRSHAD, H. Image segmentation using fuzzy clustering: A survey. In: IEEE. *Emerging Technologies (ICET), 2010 6th International Conference on*. [S.l.], 2010. p. 181–186. Citado 3 vezes nas páginas 26, 30 e 43.
- NGUYEN, H. T.; WALKER, E. A. *A First Course in Fuzzy Logic*. [S.l.]: CRC-Press, 2006. ISBN 9780849363955. Citado na página 24.
- NOLASCO-CARVALHO, C. C.; FRANCA-ROCHA, W.; UCHA, J. M. Mapa digital de solos: uma proposta metodológica usando inferência fuzzy. *Revista Brasileira de Engenharia Agrícola e Ambiental, SciELO Brasil*, v. 13, n. 1, p. 46–55, 2009. Citado na página 26.
- NOVO, E. M. L. de M. *Sensoriamento remoto: princípios e aplicações*. Edgard Blücher, 1992. ISBN 9788521200574. Disponível em: <<http://books.google.com.br/books?id=03y-AAAACAAJ>>. Acesso em: 05 out. 2013, 20:55:30. Citado na página 47.
- OLIVEIRA, D. F. et al. Avaliação da qualidade de imagem em sistemas de radiografia computadorizada e image plates. In: *IV Conferencia Panamericana de END, Buenos Aires*. [S.l.: s.n.], 2007. Citado na página 28.

- OLIVEIRA, H. L. d.; AMENDOLA, M.; NÄÄS, I. d. A. Estimativa das condições de conforto térmico para avicultura de postura usando a teoria dos conjuntos fuzzy. *Engenharia Agrícola*, Associação Brasileira de Engenharia Agrícola, v. 25, 2005. Citado na página 26.
- PAL, N. R. et al. A possibilistic fuzzy c-means clustering algorithm. *Fuzzy Systems, IEEE Transactions on*, IEEE, v. 13, n. 4, p. 517–530, 2005. Citado na página 28.
- PAL, N. R.; PAL, S. K. A review on image segmentation techniques. *Pattern recognition*, Elsevier, v. 26, n. 9, p. 1277–1294, 1993. Citado na página 26.
- PAL, S. K.; PETERS, J. F. *Rough Fuzzy Image Analysis: Foundations and Methodologies*. [S.l.]: CRC-Press, 2010. ISBN 9780849363955. Citado na página 23.
- PETROU, M.; PETROU, C. *Image processing: the fundamentals*. [S.l.]: John Wiley & Sons, 2010. Citado na página 34.
- PHAM, D. L. Spatial models for fuzzy clustering. *Computer vision and image understanding*, Elsevier, v. 84, n. 2, p. 285–297, 2001. Citado na página 71.
- PHAM, D. L.; PRINCE, J. L. An adaptive fuzzy c-means algorithm for image segmentation in the presence of intensity inhomogeneities. *Pattern Recognition Letters*, Elsevier, v. 20, n. 1, p. 57–68, 1999. Citado na página 26.
- QUARTAROLI, C. F.; BATISTELLA, M. Processamento de imagens de sensoriamento remoto: tutorial básico. In: *Documentos 44*. 1ª. ed. Campinas-SP: Embrapa Monitoramento por Satélite, 2005. p. 146. Disponível em: <http://www.cnpm.embrapa.br/publica/download/doc44_proximagens.pdf>. Acesso em: 15 abr. 2014, 11:58:20. Citado 2 vezes nas páginas 28 e 40.
- RAHIMI, S. et al. A parallel fuzzy c-mean algorithm for image segmentation. In: *IEEE. Fuzzy Information, 2004. Processing NAFIPS'04. IEEE Annual Meeting of the*. [S.l.], 2004. v. 1, p. 234–237. Citado 2 vezes nas páginas 47 e 71.
- RAO, S. S. et al. Multiobjective fuzzy optimization techniques for engineering design. *Computers & structures*, Elsevier, v. 42, n. 1, p. 37–44, 1992. Citado na página 26.
- RICHARDS, J. A.; JIA, X. *Remote sensing digital image analysis: an introduction*. 4ª. ed. Berlin: Springer, 2006. ISBN 978-3-540-25128-6. Disponível em: <<http://books.google.com.br/books?id=ETfwQnBMP4UC>>. Acesso em: 04 set. 2013, 09:37:41. Citado 2 vezes nas páginas 23 e 47.
- RICHTER, M. M. Logic and approximation in knowledge based systems. In: *Logic versus Approximation*. [S.l.]: Springer, 2004. p. 184–203. Citado na página 26.
- ROSS, T. J. *Fuzzy logic with engineering applications*. 2. ed. New Mexico: John Wiley & Sons, 2004. Citado 3 vezes nas páginas 26, 42 e 47.
- RUSPINI, E. H. A new approach to clustering. *Information and Control*, v. 15, n. 1, p. 22 – 32, 1969. ISSN 0019-9958. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0019995869905919>>. Acesso em: 27 nov. 2013, 09:41:24. Citado 2 vezes nas páginas 27 e 28.

- SCHOWENGERDT, R. A. *Remote Sensing: Models and Methods for Image Processing*. Elsevier Science, 2006. ISBN 9780080480589. Disponível em: <<http://books.google.com.br/books?id=KQXNaDH0X-IC>>. Acesso em: 01 set. 2013, 09:43:35. Citado 3 vezes nas páginas 23, 47 e 70.
- SHAMSI, H.; SEYEDARABI, H. A modified fuzzy c-means clustering with spatial information for image segmentation. *International Journal of Computer Theory & Engineering*, v. 4, n. 5, Out. 2012. Citado 2 vezes nas páginas 26 e 30.
- SILVA, J. F. C. da et al. Avaliação da qualidade da detecção de bordas em uma seqüência de imagens de ruas e rodovias. *Revista Brasileira de Cartografia*, v. 2, n. 56, 2009. Citado na página 28.
- SIVANANDAM, S. N.; SUMATHI, S.; DEEPA, S. N. *Introduction to Fuzzy Logic using MATLAB*. Springer, 2006. ISBN 9783540357810. Disponível em: <http://books.google.com.br/books?id=a_J2P3FT9sgC>. Acesso em: 29 mar. 2014, 09:45:10. Citado na página 26.
- SIVANANDINI, L. D.; RAJ, M. M. A survey on data clustering algorithms based on fuzzy techniques. *International Journal of Science and Research (IJSR), India Online*, v. 2, Abr. 2013. ISSN 2319-7064. Citado na página 20.
- SONKA, M. et al. *Image processing, analysis, and machine vision*. [S.l.]: Thomson Toronto, 2008. Citado na página 26.
- SPRING. *Composição CBERS*. 2005. Disponível em: <<http://phorum.dpi.inpe.br/read.php?10,2342>>. Acesso em: 20 abr. 2014, 18:07:30. Citado na página 52.
- STEFANES, M.; FILHO, A. C. P. Contribuição ao uso do sensor ccd/cbers-2 para a caracterização da cobertura do solo: um estudo de caso no cerrado. *Revista de Estudos Ambientais (REA)*, v. 11, n. 2, p. 71–87, jul./dez. 2009. Citado na página 71.
- SUDHAVANI, G.; SATHYAPRASAD, K. Segmentation of lip images by modified fuzzy c-means clustering algorithm. *International Journal of Computer Science and Network Security IJCSNS*, v. 9, n. 4, p. 187–191, 2009. Citado na página 29.
- TAMURA, S.; HIGUCHI, S.; TANAKA, K. Pattern classification based on fuzzy relations. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-1, n. 1, p. 61–66, 1971. ISSN 0018-9472. Citado na página 27.
- TANSCHKEIT, R. Sistemas fuzzy. *Inteligência computacional: aplicada a administração, economia e engenharia em Matlab*, p. 229–264, 2004. Citado na página 27.
- TOWFIK, Z. S. Comparison between fuzzy c-means clustering (FCM) and geometrically guided condition fuzzy c-means clustering (ggc FCM). *Diyala Journal For Pure Science*, Baghdad, v. 6, n. 2, p. 32–49, 2010. Citado na página 47.
- TRIPOLITI, E. E.; FOTIADIS, D. I.; ARGYROPOULOU, M. Automated segmentation and quantification of inflammatory tissue of the hand in rheumatoid arthritis patients using magnetic resonance imaging data. *Artificial intelligence in medicine*, Elsevier, v. 40, n. 2, p. 65–85, 2007. Citado 2 vezes nas páginas 26 e 29.

- TRIVEDI, M. M.; BEZDEK, J. C. Low-level segmentation of aerial images with fuzzy clustering. *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, v. 16, n. 4, p. 589–598, 1986. Citado na página 28.
- TSO, B.; MATHER, P. *Classification Methods for Remotely Sensed Data*. CRC Press, 2009. (Environmental engineering). ISBN 9781420090727. Disponível em: <<http://books.google.com.br/books?id=P6YsAQAAMAAJ>>. Acesso em: 18 abr. 2014, 10:09:30. Citado na página 42.
- VENDRAMIN, L. *Estudo e desenvolvimento de algoritmos para agrupamento fuzzy de dados em cenários centralizados e distribuídos*. Dissertação (Mestrado) — Universidade de São Paulo, São Paulo, Ago. 2012. Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC-USP, como parte dos requisitos para obtenção do título de Mestre em Ciências - Ciências de Computação e Matemática Computacional. VERSÃO REVISADA. Citado na página 29.
- WANG, L. et al. *Fuzzy systems and knowledge discovery*. [S.l.]: Springer, 2006. ISBN 9780849363955. Citado na página 24.
- WANGENHEIM, C. G. von; WANGENHEIM, A. von. *Raciocínio baseado em casos*. Manole, 2003. ISBN 9788520414590. Disponível em: <<http://books.google.com.br/books?id=cIMwqPOdPTMC>>. Acesso em: 08 mai. 2014, 22:40:17. Citado na página 41.
- WEI, Q.; CHEN, G. Mining generalized association rules with fuzzy taxonomic structures. *Fuzzy Information Processing Society, 1999. NAFIPS. 18th International Conference of the North American*, p. 477–481, 1999. Citado na página 26.
- WWF. World Wildlife Fund. 2011. *Dia mundial das áreas úmidas*. Disponível em: <<http://www.wwf.org.br/?uNewsID=27482>>. Acesso em: 06 set. 2014, 20:24:43. Citado na página 25.
- YAGUINUMA, C. A. *Sistema FOQuE para Expansão Semântica de Consultas baseada em Ontologias Difusas*. Dissertação (Mestrado) — UNIVERSIDADE FEDERAL DE SÃO CARLOS, São Carlos, 2013. Citado na página 27.
- YAMBAL, M.; GUPTA, H. Image segmentation using fuzzy c means clustering: a survey. *Image*, v. 2, n. 7, 2013. Citado na página 26.
- YANG, M.-S. A survey of fuzzy clustering. *Mathl. Comput. Modelling*, v. 18, n. 11, p. 1–16, 1993. Citado na página 27.
- YANG, Y.; HUANG, S. Image segmentation by fuzzy c-means clustering algorithm with a novel penalty term. *Computing and Informatics*, v. 26, p. 17–31, 2007. Citado na página 29.
- YONAMINE, F. et al. Aprendizado não supervisionado em domínios fuzzy algoritmo fuzzy c-means. *São Carlos: UFSCAR*, 2002. Citado na página 43.
- ZADEH, L. A. Fuzzy sets. *Information and Control*, v. 8, n. 3, p. 338–353, 1965. ISSN 0019-9958. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S001999586590241X>>. Acesso em: 27 nov. 2013, 10:12:47. Citado na página 27.

ZHOU, H. et al. Anisotropic mean shift based fuzzy c-means segmentation of skin lesions. In: ACM. *Proceedings of the 5th international conference on Soft computing as transdisciplinary science and technology*. [S.l.], 2008. p. 438–443. Citado na página 29.

Apêndices

APÊNDICE A – Código Fonte do Protótipo

A.1 fAnotaClas.m

```

%— Função fAnotaClas(arqSaida, numExecucao, tempoInicial, tempoFinal,
%—             qtdeGrupos, qtdeClasses, m, qtdeIterEntrada,
%—             qtdeIterSaida, epEntrada, epSaida, Mpert)
%— Grava no arquivo arqSaida as informações de processamento recebidas
%— como parâmetro.
%—
%— Recebe os seguintes parâmetros:
%— arqSaida           — caminho e nome do arquivo onde serão
%—                   gravadas as informações.
%— numExecucao       — número da pasta de execução.
%— tempoInicial      — vetor resultante do comando clock() contendo
%—                   data e hora inicial.
%— tempoFinal        — vetor resultante do comando clock() contendo
%—                   data e hora final.
%— qtdeGrupos        — quantidade de grupos a serem classificados.
%— qtdeClasses       — quantidade de classes a serem geradas.
%— m                 — expoente de ponderação.
%— qtdeIterEntrada   — quantidade de iterações de entrada.
%— qtdeIterSaida     — quantidade de iterações de saída.
%— epEntrada         — epsolon de entrada.
%— epSaida           — epsolon de saída.
%— Mpert             — matriz 5 x 2 contendo, para cada classe, o
%—                   grupo de maior pertinência e o respectivo
%—                   grau de pertinência.
%—
%— Não retorna parâmetros
%—
%— Autor: Wagner Oliveira de Araujo
%— Adaptado por: Caio Marcelo Nunes
%— Data: 24/02/2014
%— ÚLTIMA REVISÃO: 21/04/2014.

function fAnotaClas(arqSaida, numExecucao, tempoInicial, tempoFinal, qtdeGrupos, ...
    qtdeClasses, m, qtdeIterEntrada, qtdeIterSaida, epEntrada, epSaida, Mpert)
    % Calcula tempo de execução
    tExecucao = etime(tempoFinal, tempoInicial)/60;

    % Formata data e hora
    dthInicial = strcat(num2str(tempoInicial(3)), '/', num2str(tempoInicial(2)), '/', ...
        num2str(tempoInicial(1)), ' ', num2str(tempoInicial(4)), ':', ...
        num2str(tempoInicial(5)), ':', num2str(tempoInicial(6)));
    dthFinal = strcat(num2str(tempoFinal(3)), '/', num2str(tempoFinal(2)), '/', ...
        num2str(tempoFinal(1)), ' ', num2str(tempoFinal(4)), ':', num2str(tempoFinal(5)), ...
        ':', num2str(tempoFinal(6)));

    fid = fopen(arqSaida, 'a');

```

```

% Anotação para 5 classes
fprintf(fid, '%s \t %s \t %s \t %3.2f \t %u \t %u \t %1.3f \t %u \t %u \t %1.5f \t ...
    %1.5f \t %u \t %3.2f ...
    \t %s \t %s\n', numExecucao, dthInicial, dthFinal, tExecucao, qtdeGrupos, ...
    qtdeClasses, m, qtdeIterEntrada, qtdeIterSaida, epEntrada, epSaida, Mpert(1,1), ...
    (Mpert(1,2)*100), Mpert(2,1), (Mpert(2,2)*100), Mpert(3,1), (Mpert(3,2)*100), ...
    Mpert(4,1), (Mpert(4,2)*100), Mpert(5,1), (Mpert(5,2)*100), version, computer);
fclose(fid);
end

```

A.2 fAnotaGrupo.m

```

%— Função fAnotaGrupo(arqSaida, numExecucao, tempoInicial, tempoFinal,
%—         imagem, qtdePixels, qtdeBandas, qtdeGruposEntrada,
%—         qtdeGruposSaida, m, qtdeIterEntrada, qtdeIterSaida,
%—         epEntrada, epSaida, perAgrupa)
%— Grava no arquivo arqSaida as informações de processamento recebidas
%— como parâmetro.
%—
%— Recebe os seguintes parâmetros:
%— arqSaida         - caminho e nome do arquivo onde serão gravadas as informações.
%— numExecucao     - número da pasta de execução.
%— tempoInicial    - vetor resultante do comando clock() contendo data e hora inicial.
%— tempoFinal      - vetor resultante do comando clock() contendo data e hora final.
%— imagem          - nome da imagem de entrada no processamento.
%— qtdePixels      - quantidade de pixels da imagem de entrada.
%— qtdeBandas      - quantidade de bandas da imagem de entrada.
%— qtdeGruposEntrada - quantidade de grupos de entrada.
%— qtdeGruposSaida - quantidade de grupos de saída.
%— m               - expoente de ponderação.
%— qtdeIterEntrada - quantidade de iterações de entrada.
%— qtdeIterSaida   - quantidade de iterações de saída.
%— epEntrada       - epsolon de entrada.
%— epSaida         - epsolon de saída.
%— perAgrupa       - percentual de pixels agrupados.
%—
%— Não retorna parâmetros.
%—
%— Autor: Wagner Oliveira de Araujo
%— Adaptado por: Caio Marcelo Nunes
%— ÚLTIMA REVISÃO: 21/04/2014.

function fAnotaGrupo(arqSaida, numExecucao, tempoInicial, tempoFinal, imagem, qtdePixels, ...
    qtdeBandas, qtdeGruposEntrada, qtdeGruposSaida, m, qtdeIterEntrada, qtdeIterSaida, ...
    epEntrada, epSaida, perAgrupa)
% Calcula tempo de execução
tExecucao = etime(tempoFinal, tempoInicial)/60;

% Formata data e hora
dthInicial = strcat(num2str(tempoInicial(3)), '/', num2str(tempoInicial(2)), '/', ...
    num2str(tempoInicial(1)), ' ', num2str(tempoInicial(4)), ':', ...
    num2str(tempoInicial(5)), ':', num2str(tempoInicial(6)));
dthFinal = strcat(num2str(tempoFinal(3)), '/', num2str(tempoFinal(2)), '/', ...
    num2str(tempoFinal(1)), ' ', num2str(tempoFinal(4)), ':', num2str(tempoFinal(5)), ...
    ':', num2str(tempoFinal(6)));

```

```

fid = fopen(arqSaida,'a');
fprintf(fid, '%s \t %s \t %s \t %s \t %u \t %u \t %u \t %u \t %1.3f \t %u \t %u \t ...
          %1.5f \t %1.5f \t %3.2f \t %3.2f \t %s \t %s\n', numExecucao, dthInicial, ...
          dthFinal, imagem, qtdePixels, qtdeBandas, qtdeGruposEntrada,qtdeGruposSaida, m, ...
          qtdeIterEntrada, qtdeIterSaida, epEntrada, epSaida, perAgrupa, tExecucao, version, ...
          computer);
fclose(fid);
end

```

A.3 fCalcCentroides.m

```

%— Função [Centroides] = fCalcCentroides(Casos, Mu, exp)
%— Retorna uma matriz Centroides c x v contendo os centroides de
%— c grupos nas v variáveis.
%—
%— Recebe os seguintes parâmetros:
%— Casos      -   matriz i x v contendo os valores de i casos em v
%—              variáveis.
%— Mu         -   matriz i x c contendo graus de pertinência dos
%—              i casos em c grupos.
%— exp        -   expoente de ponderação usado para calcular os
%—              centroides.
%—
%— Retorna o seguinte parâmetro:
%— Centroides -   matriz c x v contendo os centroides de c grupos em
%—              v variáveis.
%— Autor: Caio Marcelo Nunes
%— Data: 22/05/2013
%— ÚLTIMA REVISÃO: 21/04/2014.

function [Centroides] = fCalcCentroides(Casos, Mu, exp)
    % Eleva cada elemento da matriz de graus de pertinência ao
    % expoente de ponderação recebido como parâmetro
    MuExp = Mu .^ exp;

    MuExpLinha = MuExp';
    Centroides = MuExpLinha * Casos ./ ((ones(size(Casos, 2), 1)+sum(MuExp))');
    % Fonte: stepfcm (JANG, 1994)
end

```

A.4 fDDmaxPert.m

```

%— Função [C] = fDDmaxPert(M)
%— Realiza o processo de de-difusividade sobre um conjunto de grupos
%— difusos M, utilizando o método da pertinência máxima.
%— Retorna uma matriz C n x 1 contendo o grupo atribuído a cada caso da
%— matriz M n x c.
%—
%— Recebe os seguintes parâmetros:
%— M          -   matriz n x c contendo graus de pertinência para
%—              n casos em c grupos.
%—
%— Retorna o seguinte parâmetro:
%— G          -   matriz n x 1 contendo os grupos atribuídos a

```

```

%—          cada caso da matriz M.
%— Autor: Caio Marcelo Nunes
%— Data: 24/03/2014
%— ÚLTIMA REVISÃO: 21/04/2014.

function [G] = fDDmaxPert(M)
    [qtdeLinhas, qtdeColunas] = size(M);
    G = zeros(qtdeLinhas, 1, 'uint8');
    for i = 1:qtdeLinhas
        [pMax, ind] = max(M(i, :));
        G(i) = ind;
    end
end

```

A.5 fDEcentCasos.m

```

%— Função [D] = fDEcentCasos(Centroides, Casos)
%— Retorna uma matriz D c x i contendo a distância euclidiana entre a
%— matriz Centroides c x v e a matriz Casos i x v.
%—
%— Recebe os seguintes parâmetros:
%— Centroides - matriz c x v contendo os centróides de c classes em
%—              v variáveis.
%— Casos      - matriz i x v contendo os valores de i casos em v
%—              variáveis.
%—
%— Retorna o seguinte parâmetro:
%— D          - matriz c x i contendo os valores de distância
%—              euclidiana entre os centróides e os casos.
%— Autor: Caio Marcelo Nunes
%— Data: 22/05/2013
%— ÚLTIMA REVISÃO: 21/04/2014.

function [D] = fDEcentCasos(Centroides, Casos)
    % Pré-aloca matriz de distâncias entre os centróides e os casos
    qtdeClasses = size(Centroides, 1);
    qtdeCasos = size(Casos, 1);
    qtdeVariaveis = size(Casos, 2);
    D = zeros(qtdeClasses, qtdeCasos, 'double');

    if qtdeVariaveis > 1,
        for c = 1:qtdeClasses
            D(c, :) = sqrt(sum(((Casos - ones(qtdeCasos, 1) * Centroides(c, :)) .^2)'));
        end
    else
        for c = 1:qtdeClasses
            D(c, :) = abs(Centroides(c) - Casos)';
        end
    end
    % Fonte: distfcm (JANG, 1994)
end

```

A.6 fFCM.m

```

%— Função [CP, MuInicialNovo, E, qtdeIteracoes, epsilonSaida] =
%—   fFCM(I, MuInicial, CentInicial, numGrupos, maxIteracoes,
%—   epsilon, expPonderacao)
%— Retorna uma matriz CP n x c contendo os graus de pertinências dos n
%— casos em c grupos segundo o método Fuzzy C-Means (FCM) aplicado sobre
%— a matriz I n x p de n casos e p variáveis.
%—
%— Recebe os seguintes parâmetros:
%— I           - matriz n x p de n casos por p variáveis.
%— MuInicial   - Matriz n x c de graus de
%—              pertinência inicial. Se desejar
%—              utilizar uma nova matriz gerada aleatoriamente,
%—              então deixar esse parâmetro como [].
%— CentInicial - Matriz c x p de centroides inicial. Se desejar
%—              que a função calcule a 1ª matriz de centroides,
%—              então deixar esse parâmetro como [].
%— numGrupos   - quantidade de grupos.
%— maxIteracoes - quantidade máxima de iterações.
%— epsilon     - valor de parada requerido pelo algoritmo.
%— expPonderacao - expoente de ponderação. Bezdek et al. (1984)
%—              sugere um valor no intervalo [1.5, 3].
%—
%— Retorna os seguintes parâmetros:
%— CP          - matriz n x c contendo os graus de pertinência a
%—              cada um dos c grupos para cada um dos n casos.
%— MuInicialNovo - matriz n x c contendo os graus de pertinência
%—              gerados pela 1ª vez de forma aleatória.
%— CentFinal    - matriz c x p contendo os centroides gerados no
%—              final do processamento.
%— E           - matriz coluna com os valores de epsilon
%—              calculados durante o processamento.
%— qtdeIteracoes - quantidade de iterações realizadas no
%—              processamento.
%— epsilonSaida - último epsilon calculado.
%— Autor: Caio Marcelo Nunes
%— ÚLTIMA REVISÃO: 21/04/2014.

function [CP, MuInicialNovo, CentFinal, E, qtdeIteracoes, epsilonSaida] = fFCM(I, ...
    MuInicial, CentInicial, numGrupos, maxIteracoes, epsilon, expPonderacao)
% Definição dos parâmetros de saída
CP = []; E = [];

% Consiste parâmetros de entrada
if numGrupos < 2
    error('Parâmetro incorreto! numGrupos deve ser >= 2.');
```

```
end;
if expPonderacao <= 1.0
    error('Parâmetro incorreto! expPonderacao deve ser > 1.');
```

```
end;

% Determina n° de casos e n° de variáveis
[numCasos, numVariaveis] = size(I);
disp ('PARÂMETROS DE ENTRADA:');
fprintf ('Número de casos: %i\n', numCasos);
fprintf ('Número de variáveis: %i\n', numVariaveis);
fprintf ('Número de grupos: %i\n', numGrupos);
fprintf ('Número máximo de iterações: %i\n', maxIteracoes);
fprintf ('Diferença entre matrizes de pertinência p/ parada do algoritmo: %f\n', epsilon);
fprintf ('Expoente de ponderação: %f\n', expPonderacao);
fflush(stdout);
```

```

% —
% Determina matriz de graus de pertinência inicial
if (isempty(MuInicial))
    disp(' ');
    disp('Gerando 1ª matriz de pertinência (aleatória) ...');
    fflush(stdout);
    Mu = fPertInicial(numCasos, numGrupos);
    MuInicialNovo = Mu;
else
    disp(' ');
    disp('Aproveitando 1ª matriz de pertinência recebida como parâmetro ...');
    fflush(stdout);
    Mu = MuInicial;
    MuInicialNovo = MuInicial;
end;
% —

% —
% Laço principal do agrupamento difuso
paradaPorEpsilon = false;
iteracao = 1;

while (~paradaPorEpsilon) && (iteracao <= maxIteracoes)
    disp(' ');
    fprintf ('%iª iteração ...\n', iteracao);

    % —
    % Calcula centroides
    if (isempty(CentInicial)) || (iteracao > 1)
        disp('Calculando centroides ...');
        fflush(stdout);
        Centroides = fCalcCentroides(I, Mu, expPonderacao);
    else
        disp('Aproveitando 1ª matriz de centroides recebida como parâmetro ...');
        fflush(stdout);
        Centroides = CentInicial;
    end;
    % —

    % —
    % Calcula distâncias dos centroides para os casos utilizando
    % como métrica a distância Euclidiana
    disp('Calculando distâncias entre centroides e casos ...');
    fflush(stdout);
    Distancias = fDEcentCasos(Centroides, I);
    % —

    % —
    % Calcula novos valores de Mu
    disp('Calculando novos valores para a matriz de pertinência ...');
    fflush(stdout);
    MuNovo = fNovaPertinencia(Distancias, expPonderacao);
    MuNovo = MuNovo;
    % —

```

```

% —
% Compara novos valores calculados para Mu em relação à
% tolerância recebida como parâmetro
difMaxima = max(max(abs(Mu - MuNovo)));
fprintf('Diferença máxima entre as matrizes de pertinência: %f\n', difMaxima);
fflush(stdout);
E(iteracao) = difMaxima;
paradaPorEpsilon = (difMaxima < epsilon);
% —

qtdeIteracoes = iteracao;
epsilonSaida = difMaxima;
iteracao++;
disp(' ');
disp('Limpendo variáveis de memória ...');
fflush(stdout);
Mu = MuNovo;
clear MuNovo;

end;
% —

% Retorna parâmetros
CP = Mu;
CentFinal = Centroides;

end

```

A.7 fFrequencia.m

```

%— Função M = fFrequencia(v)
%— Recebe um vetor v e retorna a matriz M com os elementos distintos na
%— 1ª coluna e frequência de cada elemento na 2ª coluna.
%— Autor: Caio Marcelo Nunes
%— Data: 21/03/2013
%— ÚLTIMA REVISÃO: 21/04/2014.

function M = fFrequencia(v)
    % Determina os elementos discretos do vetor e preenche a 1ª coluna
    M(:, 1) = uint32(unique(v));

    % Determina a frequência de cada elemento no vetor e coloca na
    % 2ª coluna
    Z = histc(v, min(v):max(v));

    % Desconsidera as frequências zeradas
    j = 1;
    for i = 1:length(Z)
        if Z(i) != 0
            M(j,2) = Z(i);
            j++;
        end
    end
end
end

```

A.8 fNovaPertinencia.m

```

%— Função [MuNovo] = fNovaPertinencia(D, exp)
%— Retorna uma matriz MuNovo c x i contendo novos valores de graus de
%— pertinência calculados a partir da matriz de distâncias D c x i e do
%— expoente de ponderação exp.
%—
%— Recebe os seguintes parâmetros:
%— D      -   matriz c x i contendo as distâncias entre os i casos e
%—          as c classes.
%— exp    -   expoente de ponderação usado para calcular novos valores
%—          de MuNovo.
%—
%— Retorna o seguinte parâmetro:
%— MuNovo -   matriz c x i contendo novos valores de graus de
%—          pertinência.
%— Autor: Caio Marcelo Nunes
%— Data: 22/05/2013

function [MuNovo] = fNovaPertinencia(D, exp)
    % Determina expoente de ponderação usado para calcular novos
    % valores de Mu.
    % Equação 11b de BEZDEK et al. (1984)
    e = 2/(exp - 1);

    Temp = D .^ (-e);
    MuNovo = Temp ./ (ones(size(D, 1), 1) * sum(Temp));
    % Fonte: stepfcm (JANG, 1994)
end

```

A.9 fPertInicial.m

```

%— Função [Mu] = fPertInicial(i, c)
%— Retorna uma matriz Mu i x c contendo os graus de pertinência dos i
%— casos em c classes.
%—
%— Recebe os seguintes parâmetros:
%— i      -   quantidade de casos.
%— c      -   quantidade de classes.
%—
%— Retorna o seguinte parâmetro:
%— Mu     -   matriz i x c contendo os graus de pertinência dos i casos em c
%—          classes.
%— Autor: Caio Marcelo Nunes
%— Data: 22/05/2013

function [Mu] = fPertInicial(i, c)
    % —
    % Inicializa aleatoriamente a matriz de graus de pertinência de modo
    % que:
    % (1) 0 < SOMA Mu(i, c) < numCasos, para i = 1,...,numCasos e
    %     c = 1,...,numClasses.
    %     Onde:
    %     SOMA = somatório de todos os mu's (graus de pertinência) de
    %           todos os casos de uma família de partições (soma nas
    %           colunas). É um valor positivo e menor que o número de
    %           casos existentes.
    % (2) SOMA Mu(i, c) = 1, para i = 1,...,numCasos e
    %     c = 1,...,numClasses.

```

```

%     Ou seja, a soma dos mu's de cada caso (soma nas linhas) deve
%     ser igual a 1.
%     ———

Mu = rand(i, c);    % Números aleatórios entre 0 e 1

% Normaliza resultados para que a soma dos graus de pertinência em cada linha
% seja igual a 1
SomaLinhas = sum(Mu, 2);
Mu = Mu ./ SomaLinhas(:, ones(1, c));
end

```

A.10 sAgrupamento.m

```

% PROGRAMA:      sAgrupamento.m
% DESCRIÇÃO:    Define pastas de trabalho, lê e formata imagens para
%              submissão à função FCM. Em seguida gera os gráficos
%              e relatórios referentes ao processo de agrupamento de
%              pixels.
% AUTOR:       Caio Marcelo Nunes.
% ÚLTIMA REVISÃO: 21/04/2014.

% ———

% Define parâmetros para montagem de pastas.
% Quando se tratar de uma nova bateria, a pasta correspondente deve ser
% criada através do Gerenciador de Janelas.
numBateria      = '32';
numExecucaoGrupo = '076';
% ———

% ———
% Parâmetros para a função FCM
qtdeGrupos      = 5;    % Definir até 7 grupos.
                  % Para definir mais que 7 grupos, as
                  % matrizes de cores "Combinacoes" e "MC"
                  % definidas no código do programa devem
                  % ser redimensionadas.

qtdeIteracoesEntrada = 100;
m                    = 1.5;
epsilonEntrada      = 0.0001;
% ———

% ———
% Define diretórios de trabalho
dirCadermeta = '/home/caio/Mestrado/Bibliografia/Minha dissertação/Resultados do ...
               processamento/';

% Imagem multiespectral de satélite — CBERS-2B/CCD
%dirImagem = '/home/caio/Mestrado/Bibliografia/Minha dissertação/Imagens de ...
              satélite/159-117 - 2008-06-25 - nível 2/Sessao Beam/Imagens TIF recortadas/';
%nomeImagem = '159-117 - 2008-06-25 - nível 2 - recorte';

% Imagem multiespectral de satélite — Landsat/TM — João Leite
dirImagem = '/home/caio/Mestrado/Bibliografia/Minha dissertação/Imagens de ...
             satélite/Represa do Ribeirão João Leite/Recorte 1/';
nomeImagem = 'Represa do Ribeirão João Leite - R1';

```

```

% Imagem padrão RGB
%dirImagem = '/home/caio/Mestrado/Bibliografia/Figuras JPG/';
%nomeImagem = 'tucano.jpg';

dirExecucaoBateria = strcat('/home/caio/Mestrado/Bibliografia/Minha ...
    dissertação/Resultados do processamento/Bateria ', numBateria, '/');
dirExecucaoGrupo = strcat(dirExecucaoBateria, 'Execução ', numExecucaoGrupo, '/');
% —

% —
% Definir o aproveitamento ou a geração de um Mu inicial
% Mudanças na imagem de entrada ou no n° de grupos de entrada implicam
% na geração de um novo Mu inicial.
%cargaInicial = strcat(dirExecucaoBateria, 'MuInicial.mat');
%load(cargaInicial);
%MuInicial = MuInicialNovo;
%if size(MuInicial,2) != qtdeGrupos
    %disp('Erro: deve ser gerado um Mu inicial novo!');
    %return;
%end
MuInicial = [];
% —

% —
% Verifica se o diretório de execução do grupo já existe
if exist(dirExecucaoGrupo, 'dir')
    do
        resposta = input(sprintf('O diretório de execução (' , dirExecucaoGrupo, ') já ...
            existe. Prosseguir (s/n)? '), 's');
        until resposta == 's' | resposta == 'n';
        if resposta == 'n'
            return
        end;
    else
        mkdir(dirExecucaoGrupo);
    end;
% —

% —
% Lê bandas de uma imagem multiespectral
% Considera 4 bandas espectrais
%qtdeColunas = 4;

% Considera 2 bandas espectrais
qtdeColunas = 2;

% Bandas 1, 2, 3 e 4 – CBERS-2B/CCD
%caminhoImagem = strcat(dirImagem,'Recorte 2 – banda 1.tif');
%[I, Map] = imread(caminhoImagem);
%qtdeLinhas = numel(I);
%PB = zeros(qtdeLinhas, qtdeColunas, 'single');
%PB(:,1)=reshape(I,qtdeLinhas,1);
%caminhoImagem = strcat(dirImagem,'Recorte 2 – banda 2.tif');
%[I, Map] = imread(caminhoImagem);
%PB(:,2)=reshape(I,qtdeLinhas,1);
%caminhoImagem = strcat(dirImagem,'Recorte 2 – banda 3.tif');
%[I, Map] = imread(caminhoImagem);
%PB(:,3)=reshape(I,qtdeLinhas,1);
%caminhoImagem = strcat(dirImagem,'Recorte 2 – banda 4.tif');
%[I, Map] = imread(caminhoImagem);

```

```

%PB(:,4)=reshape(I,qtdeLinhas,1);
%[qtdeLinhasOrig, qtdeColunasOrig] = size(I);

% Bandas 3 e 4 – Ribeirão João Leite
caminhoImagem = strcat(dirImagem, 'b3.tif');
[I, Map] = imread(caminhoImagem);
qtdeLinhas = size(I,1) * size(I,2);
PB = zeros(qtdeLinhas, qtdeColunas, 'single');
PB(:,1)=reshape(I(:, :, 1), qtdeLinhas, 1);
caminhoImagem = strcat(dirImagem, 'b4.tif');
[I, Map] = imread(caminhoImagem);
PB(:,2)=reshape(I(:, :, 1), qtdeLinhas, 1);

[qtdeLinhasOrig, qtdeColunasOrig, qtde3dim] = size(I);
% —

% —
% Lê imagem padrão RGB
%caminhoImagem = strcat(dirImagem, nomeImagem);
%[I, Map] = imread(caminhoImagem);
%qtdeLinhas = size(I, 1) * size(I, 2);
%PB=zeros(qtdeLinhas, 3, 'single');
%PB(:,1)=reshape(I(:, :, 1), qtdeLinhas, 1);
%PB(:,2)=reshape(I(:, :, 2), qtdeLinhas, 1);
%PB(:,3)=reshape(I(:, :, 3), qtdeLinhas, 1);
%qtdeLinhasOrig = size(I, 1);
%qtdeColunasOrig = size(I, 2);
%qtdeColunas = size(I, 3);
% —

% —
% Limpa variáveis utilizadas na leitura da imagem
clear Map;
clear qtdeLinhas;
clear I;
% —

% —
% Inicia contagem de tempo
tIni = clock();
% —

% —
% Chama a função que implementa o algoritmo FCM
[PixelsGrupos, MuInicial, [], qtdeGrupos, qtdeIteracoesEntrada, epsilonEntrada, m] = ...
    fFCM(PB, MuInicial, [], qtdeGrupos, qtdeIteracoesEntrada, epsilonEntrada, m);
% —

% —
% Efetua o processo de de-difusividade
disp(' ');
disp('Efetuando processo de de-difusividade ...');
fflush(stdout);

% De-difusividade utilizando o método da pertinência máxima
GruposFinal = fDDmaxPert(PixelsGrupos);
% —

% —
% Complementa tabela resultante da de-difusividade com grupos que não

```

```

% receberam valores difusos
F = fFrequencia(GruposFinal);
qtdeLinhasF = size(F, 1);
Fcomp = zeros((qtdeGrupos + 1), 2);
qtdeGruposNaoIden = 0;
k = 1;
for n = 1:qtdeLinhasF
    while F(n,1) > k
        Fcomp(k,:) = [k,0];
        qtdeGruposNaoIden++;
        k++;
    end
    Fcomp(k,:) = F(n,:);
    k++;
end;
% ———

% ———
% Calcula percentual de agrupamento
qtdePixels = qtdeLinhasOrig * qtdeColunasOrig;
if qtdeGrupos == length(Fcomp)
    perAgrupa = 100.00;
else
    perAgrupa = ((qtdePixels - double(Fcomp(qtdeGrupos+1, 2)))/qtdePixels) * 100;
end
qtdeGruposIden = qtdeGrupos - qtdeGruposNaoIden;
% ———

% ———
% Mostra tabela com grupos e quantidade de pixels agrupados
disp(' ');
disp('Frequência de grupos final:');
disp(Fcomp);
fflush(stdout);
% ———

% ———
% Monta mapa de grupos
disp(' ');
disp('Gerando mapa de grupos ...');
fflush(stdout);
MC = reshape(GruposFinal, qtdeLinhasOrig, qtdeColunasOrig);
Composicao = zeros(qtdeLinhasOrig, qtdeColunasOrig, 3, 'uint8');
Combinacoes = uint8([255, 0, 0;
                    165, 42, 42;
                    191, 191, 191;
                    255, 255, 0;
                    255, 0, 255;
                    255, 179, 0;
                    127, 127, 127]);

p = 1;
for k = 1:(qtdeGrupos + 1)
    Posicoes = (MC == k);
    [Lin, Col] = find(Posicoes);
    for i = 1:length(Lin)
        Composicao(Lin(i), Col(i), :) = Combinacoes(p, :);
    end
    if length(Lin) > 0
        p = p + 1;
    end
end

```

```

end
clear MC Combinacoes Posicoes Lin Col i;
% —

% —
% Mostra mapa de grupos
figure;
imshow(Composicao);
title('Mapa de Grupos');
caminhoFigura = strcat(dirExecucaoGrupo, 'MG.png');
print(caminhoFigura, '-dpng');
clear Composicao
% —

% —
% Mostra estatística de pixels agrupados
P = double(F(:, 2)) / 10000;
E = zeros(1, length(P));
E(length(E)) = 1;
figure;
H = pie(P, E);
CM = colormap([1,0,0; 0.64,0.16,0.16; 0.75,0.75,0.75; 1,1,0;1,0,1; 1,0.7,0; 0.5,0.5,0.5]);
j = 1;
for i = 1:2:length(H)
    set(H(i), 'facecolor', CM(j, :));
    j++;
end
Legenda = cell(1, length(P));
for k = 1:length(P)
    if k < length(P)
        Legenda(k) = strcat('Grupo ', num2str(k), ': ', int2str(F(k, 2)), ' pixels');
    elseif perAgrupacao == 100.00
        Legenda(k) = strcat('Grupo ', num2str(k), ': ', int2str(F(k, 2)), ' pixels');
    else
        Legenda(k) = strcat('Não agrupados: ', int2str(F(k, 2)), ' pixels');
    end
end
title('Estatística de pixels agrupados');
axis([-2, 2, -2, 2]);
axis("off");
legend(Legenda,-1);
legend left;
legend boxon;
caminhoFigura = strcat(dirExecucaoGrupo, 'Estatística.png');
print(caminhoFigura, '-dpng');
clear P H CM j i Legenda k;
% —

% —
% Mostra gráfico de epsilons
figure;
plot(Epsilons);
title('Evolução das diferenças entre as matrizes de pertinência');
xlabel('Iterações');
ylabel('Epsilon');
axis([1 qtdeIteracoesSaida 0 1], 'square');
caminhoFigura = strcat(dirExecucaoGrupo, 'Epsilon.png');
print(caminhoFigura, '-dpng');
% —

```

```

% —
% Salva estruturas para utilização em futuros processamentos

% Mu inicial
save(cstrcat(dirExecucaoBateria, 'MuInicial.mat'), 'MuInicialNovo');

% Matriz de grupos
save(cstrcat(dirExecucaoGrupo, 'GruposFinal.mat'), 'GruposFinal');

% Matriz final de centróides
save(cstrcat(dirExecucaoGrupo, 'CentFinal.mat'), 'CentFinal');
% —

% —
% Finaliza contagem de tempo
disp('CONCLUÍDO COM SUCESSO!');
tFin = clock();
% —

% —
% Efetua anotações na caderneta de laboratório
caminhoCaderneta = cstrcat(dirCaderneta, 'caderneta.txt');
numExecucao = cstrcat(numBateria, '-', numExecucaoGrupo);
fAnotaGrupo(caminhoCaderneta, numExecucao, tIni, tFin, nomeImagem, qtdePixels, ...
    qtdeColunas, qtdeGrupos, qtdeGruposIden, m, qtdeIteracoesEntrada, qtdeIteracoesSaida, ...
    epsilonEntrada, epsilonSaida, perAgrupa);
% —

```

A.11 sClassificacao.m

```

% PROGRAMA:      sClassificacao.m
% DESCRIÇÃO:     Define pastas de trabalho, lê resultados da etapa de
%                agrupamento e formata parâmetros de entrada para
%                submissão à função FCM. Em seguida gera os gráficos
%                e relatórios referentes ao processo de classificação.
% AUTOR:        Caio Marcelo Nunes.
% ÚLTIMA REVISÃO: 21/04/2014.

% —
% Parâmetros para montagem de pastas
numBateria      = '32';
numExecucaoGrupo = '076';
numExecucaoClasse = '04';
% —

% —
% Parâmetros para a função FCM
qtdeClasses      = 5;
qtdeIteracoesEntrada = 1;
m                = 1.5;
epsilonEntrada   = 0.0001;
% —

% —
% Define diretórios de trabalho
dirCaderneta = '/home/caio/Mestrado/Bibliografia/Minha dissertação/Resultados do ...
    processamento/';

```

```

dirExecucaoGrupo = strcat('/home/caio/Mestrado/Bibliografia/Minha dissertação/Resultados ...
    do processamento/Bateria ', numBateria, '/Execução ', numExecucaoGrupo, '/');
dirExecucaoClasse = strcat('/home/caio/Mestrado/Bibliografia/Minha dissertação/Resultados ...
    do processamento/Bateria ', numBateria, '/Execução ', numExecucaoGrupo, '/Execução ', ...
    numExecucaoGrupo, '.', numExecucaoClasse, '/');
% —

% —
% Define o aproveitamento ou a geração de um Mu inicial
%cargaInicial = strcat(dirExecucaoGrupo, 'MuInicialClas.mat');
%load(cargaInicial);
%MuInicialClas = MuInicialClasNovo;
MuInicialClas = [];
% —

% —
% Define valores digitais médios dos pixels para alvos terrestres nas
% bandas 1, 2, 3 e 4 do sensor CBERS-2B/CCD
%SoloExposto      = [72 54 64 83];
%SoloUmido       = [12 13 14 17];
%Vegetacao       = [33 31 27 118];
%AguaTurva       = [54 54 47 17];
%AguaLimpa       = [22 13 8 0];

% Define valores digitais médios dos pixels para alvos terrestres nas
% bandas 3 e 4 do sensor landsat/TM
SoloExposto      = [67 82];
SoloUmido       = [13 18];
Vegetacao       = [58 117];
AguaTurva       = [44 19];
AguaLimpa       = [7 0];
% —

% —
% Monta matriz com centroides das classes

% Bandas 1, 2, 3 e 4 – Sensor CBERS-2B/CCD
CentroidesClasses = zeros(qtdeClasses, 4);

% Bandas 3 e 4 – Sensor Landsat/TM
CentroidesClasses = zeros(qtdeClasses, 2);

CentroidesClasses(1,:) = SoloExposto;
CentroidesClasses(2,:) = SoloUmido;
CentroidesClasses(3,:) = Vegetacao;
CentroidesClasses(4,:) = AguaTurva;
CentroidesClasses(5,:) = AguaLimpa;
% —

% —
% Verifica se o diretório de execução do grupo existe
if ~exist(dirExecucaoGrupo, 'dir')
    error(strcat('O diretório de execução (', dirExecucaoGrupo, ') não existe. '));
end;
% —

% —
% Verifica se o diretório de execução da classe já existe
if exist(dirExecucaoClasse, 'dir')
    do

```

```

        resposta = input(cstrcat('O diretório de execução (' , dirExecucaoClasse, ') já ...
            existe. Prosseguir (s/n)? '), 's');
    until resposta == 's' | resposta == 'n';
    if resposta == 'n'
        return
    end;
else
    mkdir(dirExecucaoClasse);
end;
% —

% —
% Carregar centroides dos grupos
cargaCentroidesGrupos = cstrcat(dirExecucaoGrupo, 'CentFinal.mat');
load(cargaCentroidesGrupos);
[qtdeLinhasOrig, qtdeColunasOrig] = size(CentFinal);
% —

% Inicia contagem de tempo
tIni = clock();

% Chama função que implementa o algoritmo FCM
[GruposClasses, MuInicialClasNovo, CentFinal2, Epsilons, qtdeIteracoesSaida, epsilonSaida] ...
    = fFCM(CentFinal, MuInicialClas, CentroidesClasses, qtdeClasses, qtdeIteracoesEntrada, ...
        epsilonEntrada, m);

% —
% Mostra gráfico
figure(1);
H = bar(GruposClasses);
CM = colormap([0.77,0.74,0.67;0.47,0.41,0.25;0.18,0.86,0.53;0.48,0.57,0.78;0.68,0.84,0.90]);
j = 1;
for i = 1:length(H)
    set(H(i), 'facecolor', CM(j, :));
    j++;
end
Legenda = cell(1, length(H));
Legenda(1) = 'Solo exposto';
Legenda(2) = 'Solo úmido';
Legenda(3) = 'Vegetação';
Legenda(4) = 'Água turva';
Legenda(5) = 'Água limpa';
title('Pertinência de Grupos às Classes de Alvos Terrestres');
xlabel('Grupos'); ylabel('Pertinência');
box off;
legend(Legenda,-1); legend left; legend boxon;
caminhoFigura = cstrcat(dirExecucaoClasse, 'PertClasses.png');
print(caminhoFigura, '-dpng');
% —

% —
% Determina maiores pertinências de cada classe
Mpert = zeros(qtdeClasses, 2);
for i=1:qtdeClasses
    [mx,ind] = max(GruposClasses(:,i));
    Mpert(i,:) = [ind,mx];
end
% —

% —

```

```

% Salva estruturas para futuros processamentos

% Mu inicial
save(cstrcat(dirExecucaoGrupo, 'MuInicialClas.mat'), 'MuInicialClasNovo');

% Matriz de pertinência dos grupos às classes
save(cstrcat(dirExecucaoClasse, 'GruposClasses.mat'), 'GruposClasses');
% —

% Encerra contagem de tempo
disp('CONCLUÍDO COM SUCESSO!');
tFin = clock();

% —
% Efetua anotações na caderneta de laboratório
caminhoCaderneta = cstrcat(dirCaderneta, 'caderneta.txt');
numExecucao = cstrcat(numBateria, '-', numExecucaoGrupo, '-', numExecucaoClasse);
fAnotaClas(caminhoCaderneta, numExecucao, tIni, tFin, qtdeLinhasOrig, qtdeClasses, m, ...
    qtdeIteracoesEntrada, qtdeIteracoesSaida, epsilonEntrada, epsilonSaida, Mpert);
% —

```

A.12 sExibeCompRGB.m

```

% PROGRAMA: sExibeCompRGB.m
% Exibe composição RGB sem e com realce através da ampliação linear de
% contraste (contrast stretch).
% Autor: Caio Marcelo Nunes
% Data: 20/06/2013
% ÚLTIMA REVISÃO: 26/04/2014

% —
% Lê bandas 1, 2, 3, 4 e 5 de uma imagem multiespectral

dirImagem = '/home/caio/Mestrado/Bibliografia/Minha dissertação/Imagens de ...
    satélite/159-117 - 2008-06-25 - nível 2/Sessao Beam/Imagens TIF recortadas/';
caminhoImagem1 = cstrcat(dirImagem, 'Recorte da banda 1.tif');
caminhoImagem2 = cstrcat(dirImagem, 'Recorte da banda 2.tif');
caminhoImagem3 = cstrcat(dirImagem, 'Recorte da banda 3.tif');
caminhoImagem4 = cstrcat(dirImagem, 'Recorte da banda 4.tif');
caminhoImagem5 = cstrcat(dirImagem, 'Recorte da banda 5.tif');

[I, Map] = imread(caminhoImagem3);
ImagemRGB = zeros(size(I,1), size(I,2), 3, 'uint8');
ImagemRGB(:,:,1) = I;

[I, Map] = imread(caminhoImagem2);
ImagemRGB(:,:,2) = I;
;
[I, Map] = imread(caminhoImagem1);
ImagemRGB(:,:,3) = I;
% —

% Exibe a composição original
figure; imshow(ImagemRGB, []); title('Composição colorida RGB/321 original');

% —
% Exibe a composição realçada

```

```
% Converte DN da imagem no intervalo 0-255 para o intervalo 0-1, para
% utilização do comando "imadjust"
ImagemRGBd = double(ImagemRGB)/255;

% Efetua o realce
ImagemRGBr = imadjust(ImagemRGBd, stretchlim(ImagemRGBd), []);

% Exibe a imagem realçada
figure; imshow(ImagemRGBr, []); title('Composicao colorida RGB/321 com realce');
```

Índice

- agrupamento
 - difuso, 26, 31, 69
 - difuso - algoritmos clássicos, 27
 - difuso - aplicações, 26
 - difuso - histórico, 27
 - difuso - sistema, 42
 - fixo, 26, 32, 33, 69
- algoritmo k -médias (*k-means*), 27
- análise de agrupamento (*clustering*), 23
- áreas úmidas, 25
- assinatura espectral, 24
- atitude e efemérides do satélite, 35
- chave de interpretação, 50
- composição colorida, 50
- de-difusividade, 42, 46
- detecção de borda, 28
- difusividade, 27, 42
- fator de penalidade, 29
- função objetivo, 43
- graus de pertinência, 24, 27
- imagem
 - altura, 52
 - cor, 51
 - digital, 23, 37
 - forma, 51
 - localização, 52
 - multiespectral, 31, 34, 54
 - ortorretificada, 35
 - padrão, 51
 - pancromática, 34, 50
 - realce, 50
 - segmentação, 28
 - sombreamento, 51
 - tamanho, 51
 - textura, 51
 - tonalidade, 50
- imagens CBERS-2B/CCD
 - níveis de correção, 35
- imagens Landsat-5/TM, 36
- inferência, 42
- lógica
 - difusa (*fuzzy*), 23, 25, 26, 30, 47
- método da pertinência máxima, 47
- métrica, 42
- medida de distância, 41
- órbitas e pontos do satélite CBERS-2B
 - em Goiás, 35
- outlier*, 28
- overlapping*, 29
- partição- c difusa (*fuzzy c-partition*), 28
- pixel*
 - mistura, 33, 45, 69
 - puro, 25
- reflectância, 24
- relações difusas, 27
- ruído, 28, 30, 70
- sensoriamento remoto, 23
- separabilidade de assinaturas, 40
- similaridade, 41
- tratamento univariado, bivariado e multivariado dos *pixels*, 37