

Resumo

O programa CBERS (*China-Brazil Earth-Resources Satellite*) nasceu do acordo realizado entre Brasil e China, no qual o Brasil foi inserido num grupo restrito de países que tem acesso a tecnologia de sensoriamento remoto. O INPE (Instituto Nacional de Pesquisas Espaciais) foi um dos mediadores dessa parceria e responsável pela criação um programa de georreferenciamento de imagens de sensoriamento remoto, onde uma de suas características é classificar essas imagens baseado em algoritmo de reconhecimento de padrões. Estas técnicas de reconhecimento de padrões são usadas para classificar ou descrever padrões (entidade a qual se pode dar um nome), através de um conjunto de características ou propriedades. Com o crescente desenvolvimento tecnológico presente na área de sensoriamento remoto e reconhecimento de padrões, este trabalho tem como objetivo fazer um estudo comparativo entre o uso dos algoritmos de classificação supervisionados (Máxima Verossimilhança e Distância Euclidiana) e não-supervisionados (K-Médias) aplicados a imagens digitais de sensoriamento remoto, obtidas pelo o sensor CCD (*Couple Changed Device*).

Abstract

The CBERS (China-Brazil Earth-Resources Satellite) program was born as an agreement between Brazil and China, in which Brazil has been inserted in a restricted group of countries who have access to remote sensing technology. The Instituto Nacional de Pesquisas Espaciais (INPE) was one of the mediators of this partnership and responsible for creating a program of georeferencing for remote sensing images, one of its features is classifying these images based on Pattern Recognition algorithms. These algorithms are used to classify or describe standards (entity which can be labeled) through a set of patterns or proprieties. As the technology in Remote Sensing and Pattern Recognition is constantly increasing, this work has the meaning of making a comparing study between the use algorithms for classification supervised (Maximum Likelihood and Euclidian Distance) and non-supervised (K-means) applied to images from remote sensing, collected by CCD (Couple Changed Device) sensor.

Sumário

Índice de Figuras	v
Índice de Tabelas	vi
Tabela de Símbolos e Siglas	viii
1 Introdução	10
1.1 Organização do Trabalho	11
2 Princípios de Sensoriamento Remoto	12
2.1 Radiação Eletromagnética	12
2.1.1 Espectro Eletromagnético	13
2.2 Sistemas Sensores	14
2.2.1 Fontes de Energia	15
2.2.2 Princípio de Funcionamento	16
2.2.3 Tipos de produtos	16
3 Programa CBERS	18
3.1 Programa CBERS	18
3.2 Características técnicas da tecnologia CBERS	19
3.2.1 Módulo de carga útil	19
3.2.2 Módulo Serviço	22
3.3 Sistema de Coleta de dados	23
4 Reconhecimento de Padrões Aplicado a Sensoriamento Remoto	25
4.1 Algoritmos de Agrupamento	25
4.1.1 Mapas Auto-Organizáveis	26
4.1.2 K-Means	28
4.2 Algoritmos de Classificação Supervisionados	30
4.2.1 Máxima Verossimilhança	30
4.2.2 Distância Euclidiana	31
5 Estudo de caso: Classificação de Imagens do Município de Floresta	33
5.1 Introdução	33
5.2 Materiais e Métodos	33
5.2.1 O Ambiente SPRING	33
5.2.2 Área Imageada	34
Aspectos Socioeconômicos	34
Aspectos Fisiográficos	35
5.2.3 Registro de Imagens	36
5.2.4 Métodos de Classificação	38
5.3 Resultados e Discussões	39
5.4 Conclusões	44
5.5 Dificuldades Encontradas	44

6 Conclusões e Trabalhos Futuros

45

6.1 Contribuições e Trabalhos Futuros

45

Índice de Figuras

Figura 1.	Relação entre E (campo elétrico), M (campo magnético) e C (velocidade da luz).	12
Figura 2.	Comprimento de onda	13
Figura 3.	Espectro eletromagnético	13
Figura 4.	Reflectância do alvo “árvore”	14
Figura 5.	Sistema sensor	15
Figura 6.	Sensor Passivo (a) e Sensor Ativo(b).....	15
Figura 7.	Sensores presente no CBERS-1 e 2.....	19
Figura 8.	Intervalos espectrais das 5 bandas do sensor CCD [6]	21
Figura 9.	Imagem do sensor WFI banda 1	21
Figura 10.	Imagem do sensor IRMSS banda 1	21
Figura 11.	Imagem do Rio São Francisco na cidade de Petrolina com o sensor HRC	22
Figura 12.	Imagem do satélite CBERS-2B	22
Figura 13.	Transmissão de dados entre PCDs e Satélite	23
Figura 14.	Transmissão de dados entre satélite e antena de recepção.....	23
Figura 15.	Transmissão de dados entre antenas de recepção e centro de missão de coleta	24
Figura 16.	Imagem de uma plataforma de coleta de dados	24
Figura 17.	Processo de separação de classes usando o Algoritmo de <i>Clustering</i>	26
Figura 18.	Arquitetura tipo de uma rede de Kohonen para arquitetura bidirecional.....	26
Figura 19.	Passos da classificação das redes de Kohonen	27
Figura 20.	Passos da classificação das redes de Kohonen	27
Figura 21.	Passos da classificação das redes de Kohonen	28
Figura 22.	Passos da classificação das redes de Kohonen	28
Figura 23.	Passos da classificação das redes de K-Médias	29
Figura 24.	Passos da classificação das redes de K-Médias	29
Figura 25.	Passos da classificação das redes de K-Médias	30
Figura 26.	Classificação Máxima Verossimilhança	30
Figura 27.	Classificação do algoritmo Máxima Verossimilhança	31
Figura 28.	Localização da área de estudo [15].....	34
Figura 29.	Imagem CBERS-2B banda 1	35
Figura 30.	Imagem CBERS-2B banda 2	35
Figura 31.	Imagem CBERS-2B banda 3	35
Figura 32.	Imagem CBERS-2B banda 4	35
Figura 33.	Imagem CBERS-2B banda 5	36
Figura 34.	Transformações polinomiais.....	37
Figura 35.	Imagem de uma imagem registrada no SPRING	38
Figura 36.	Imagem CCD/CBERS-2B em composição colorida (R1B3G4)	39
Figura 37.	Imagem CCD/CBERS-2B em composição colorida (R1G3B4)	39
Figura 38.	Imagem CCD/CBERS-2B em composição colorida (R4G3B1)	40
Figura 39.	Classificação K-Médias sobre as composições R1B3G4 e R4B1G3	41
Figura 40.	Classificação K-Médias sobre as composições R1B3G4 e R4B1G3	41
Figura 41.	Classificação Distância Euclidiana sobre as composições R1B3G4 e R4B1G3	42

Figura 42. Classificação do MAXVER sobre as composições R1B3G4 e R4B1G343

Índice de Tabelas

Tabela 1.	Classes definidas no projeto.....	39
Tabela 2.	Matriz de confusão do algoritmo baseado na distância Euclidiana	42
Tabela 3.	Matriz de confusão do algoritmo MAXVER.....	43

Tabela de Símbolos e Siglas

(Dispostos por ordem de aparição no texto)

CBERS – China-Brazil Earth-Resources Satellite (Satélite Sino-Brasileiro de Recursos Terrestres)

INPE – Instituto Nacional de Pesquisas Espaciais

CCD – Couple Changed Device

IRMSS – InfraRed MultiSpectral Scanner

WFI – Wide Field Imager

HRC – High Resolution Camera

GPS – Global Positioning System (Sistema de Posicionamento Global)

PCD – Plataforma de Coleta de Dados

SOM – Self Organized Maps (Mapas Auto-Organizáveis)

SPRING – Sistema de Processamento de Informações Georreferenciadas

IBGE – Instituto Brasileiro de Geografia e Estatística

Agradecimentos

Dedico a conclusão deste trabalho aos meus pais, pois eles me deram todo o apoio durante a minha vida acadêmica. Agradeço também ao meu orientador Wellington Pinheiro dos Santos, pessoal a qual tenho muita admiração. Sem sua orientação o término deste trabalho não seria possível.

Aos meus amigos Rodolfo, George e Pedro que também tiveram uma importância fundamental na conclusão do projeto, pois me deram uma grande ajuda nas horas mais difíceis.

Ao meu irmão, que teve participação como avaliador de desempenho do projeto.

A minha avó, que apesar de não está mais entre nós, me mostrou a simplicidade da vida, ensinando-me valores muito importantes para eu trilhar meu caminho com dignidade.

Capítulo 1

Introdução

Análises realizadas sobre expansão urbana são reconhecidamente importantes, pois têm o papel de fornecer dados a respeito dos impactos ambientais gerados ao meio físico com a troca de cobertura vegetal por vias de acesso, edificações e pisos, gerando uma impermeabilização da superfície. “As técnicas de sensoriamento remoto, com suas características sinópticas, multiespectrais e temporais, é uma importante ferramenta no mapeamento, identificação e monitoramento de feições terrestres. Possibilitando obter informações sobre a cobertura de áreas extensas, de maneira relativamente rápida, precisa e econômica” (Matsukuma, 2002). Portanto, a partir o uso desses sistemas é possível se ter um melhor planejamento e minimização dos impactos negativos causados ao meio ambiente. Com o crescente desenvolvimento de novas gerações de sistemas sensores de alta resolução, fica cada vez mais fácil coletar um maior número de informações sobre uma determinada área analisada.

Pesquisadores defendem a utilização desses sistemas no processo de identificação do uso do solo, devido à facilidade de reconhecimento visual de padrões e formas. No entanto, os métodos convencionais de processamento de imagens possuem um baixo desempenho na classificação de imagem digital.

O processo de classificação de imagem pode ser apresentado de duas formas: supervisionada ou não-supervisionada. Na classificação supervisionada as classes presentes na imagem são definidas através das amostras de treinamento. É dessa forma o algoritmo classifica os *pixels* de cada classe, já que as amostras de treinamento deve ser um número satisfatório e uniforme. Na classificação não-supervisionada, as amostras de treinamento e uso do número de classes não são necessárias, pois o algoritmo classifica os *pixels* e o intérprete identifica as classes geradas.

No projeto foram utilizados os algoritmos de classificação (Máxima Verossimilhança, K-Médias) e a medida Distância Euclidiana. Como o desempenho classificação depende da experiência do intérprete e da capacidade de reconhecimento da área de estudo, os métodos de classificação estão sujeitos a erros, já que apenas características espectrais são levadas em conta, sendo esquecidas as características da textura.

O presente trabalho tem como objetivo avaliar o desempenho dos três algoritmos propostos. Estes são usados na classificação de imagem de sensoriamento remoto do sensor CCD (*Couple Changed Device*) referentes ao município de Floresta.

1.1 Organização do Trabalho

O trabalho está dividido em 6 Capítulos. O Capítulo 1 introduz o trabalho apresentando o objetivo e motivações para o seu desenvolvimento.

O Capítulo 2 mostra as características dos sistemas de sensoriamento remoto presentes nos satélites de onde as imagens foram coletadas.

O Capítulo 3 descreve o programa CBERS (*China-Brasil Earth Resources Satellite*) onde houve uma parceria entre China e Brasil no desenvolvimento de satélites de sensoriamento remoto, mostrando as características técnicas presentes nestes tipos de satélites.

O Capítulo 4 explica os tipos de algoritmos supervisionados e não-supervisionados de reconhecimento de padrões aplicado às imagens de sensoriamento remoto.

O Capítulo 5 mostra o processo de desenvolvimento do projeto que vai desde a metodologia usada até os resultados obtidos. O Capítulo 6 conclui o trabalho e visa tecer a aplicabilidade do projeto a trabalhos futuros

Capítulo 2

Princípios de Sensoriamento Remoto

Um dos principais objetivos do sensoriamento remoto é a expansão da percepção da sensorial do ser humano, seja através da visão panorâmica oferecida pela visão espacial ou aérea, seja pela possibilidade de coletar informações mostradas pelo espectro eletromagnético que não são visíveis à visão do homem. Assim, os sistemas sensores fazem uso da radiação eletromagnética para coletar características intrínsecas a cada objeto.

O comportamento espectral da radiação emitida e/ou refletida pode ser medido de acordo com a intensidade da interação entre esta radiação e a superfície terrestre. Logo, conhecendo o comportamento espectral, é possível identificar alvos semelhantes em outros locais. Como por exemplo, a energia refletida por uma planta, apresenta uma característica espectral e uma mesma planta apresentando um déficit nutricional apresenta outro tipo de característica. Entendendo isso, este Capítulo tem o objetivo de mostrar as características presentes nos sistemas sensores.

2.1 Radiação Eletromagnética

O princípio de sensoriamento remoto usa a radiação eletromagnética como principal fonte de energia usada pra iluminar um objeto (a menos que a energia detectada não seja emitida pelo objeto).

Os fundamentos da teoria de onda são usados para mostrar o comportamento da radiação eletromagnética. Como pode ser visto na Figura 1, o campo eletromagnético (M) varia em magnitude em direção perpendicular ao campo elétrico (E) e ambos os campos viajam na velocidade da luz.

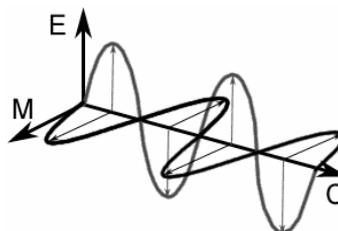


Figura 1. Relação entre E (campo elétrico), M (campo magnético) e C (velocidade da luz)

Duas características importantes no entendimento de sensoriamento remoto são os conceitos de frequência (f) e comprimento de onda (λ), onde a relação entre eles é dada por:

$$c = \lambda f \quad (1)$$

Através da fórmula apresentada é possível chegar a conclusão de que o comprimento de onda (distância entre valores repetidos num mesmo padrão de onda) e a frequência são grandezas inversamente proporcionais, o que significa dizer que, quanto maior o comprimento de onda (Figura 2), menor a frequência obtida [1]. A velocidade de uma onda eletromagnética no vácuo é representada por c e f é o número de ciclos de uma onda que passa por um ponto fixo no espaço por unidade de tempo, o que equivale a ciclos por segundo, normalmente medida em *hertz* (Hz). A relação f e λ é muito importante, pois estes conceitos surgiram a partir da observação de do espectro eletromagnético, que será dissertado a seguir.

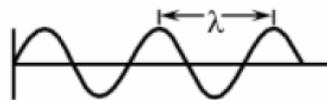


Figura 2. Comprimento de onda

2.1.1 Espectro Eletromagnético

A palavra espectro (do latim “*spectrum*” que significa, aparição ou fantasma), segundo a literatura, foi dita por *Isaac Newton*, no século XVII, para descrever uma faixa de cores que surgiu em sua experiência quando a luz do Sol atravessou um prisma de vidro. Nesse experimento, Newton observou que esse raio luminoso, ao atravessar o prisma, se desdobrava em um feixe colorido, denominado espectro de cores [2]. Logo depois, foi descoberto que esse espectro de cores possuía faixas de frequências com seus respectivos comprimentos de ondas; isso caracterizou os diversos tipos de ondas eletromagnéticas, vindo a ser denominado espectro eletromagnético. O infravermelho próximo, visível e emissivo são algumas das principais faixas do espectro eletromagnético e podem ser vistas na Figura 3 [2].

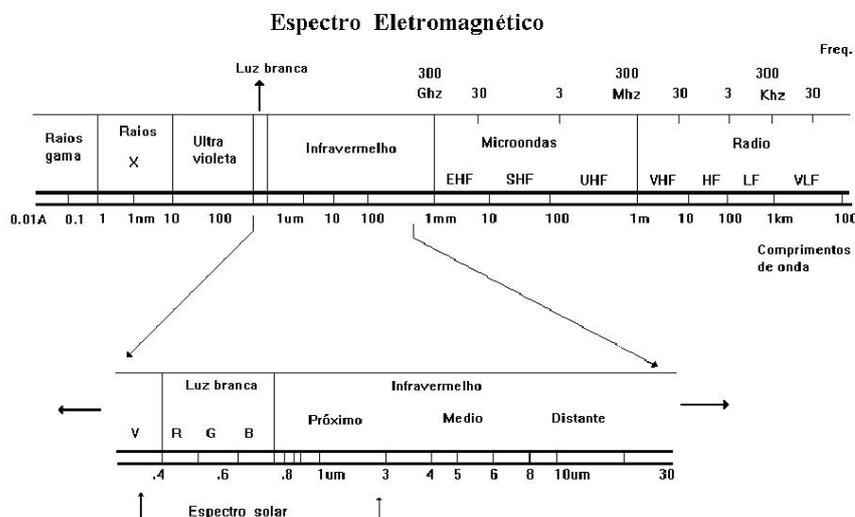


Figura 3. Espectro eletromagnético

Em sensoriamento remoto é comum definir quais faixas do espectro eletromagnético vão operar em cada sensor. Estas são denominadas bandas espectrais. Quanto maior for o número de bandas presentes num sistema sensor, melhor será a resolução espectral. Assim o sistema vai possuir um maior número de informações sobre a distribuição de energia refletida na cena.

A resolução espectral de um sistema sensor está relacionada com o número de bandas espectrais e a largura individual de cada banda [2]. Um sistema com alta resolução espectral contém um número elevado de bandas espectrais, onde cada banda individualmente abrange um intervalo estreito de comprimento de onda. Como os objetos analisados pelos sistemas sensores absorvem, transmitem, emitem e refletem radiação eletromagnética, é possível discriminar espectralmente alvos distintos, quando há interação desses alvos com a radiação. A Figura 4 mostra que, após a radiação solar incidir numa vegetação, a radiação refletida com mais intensidade foram a verde e, o infravermelho, e com menos intensidade, a componente azul e vermelha, pois foram absorvidas no processo de fotossíntese da clorofila [2].

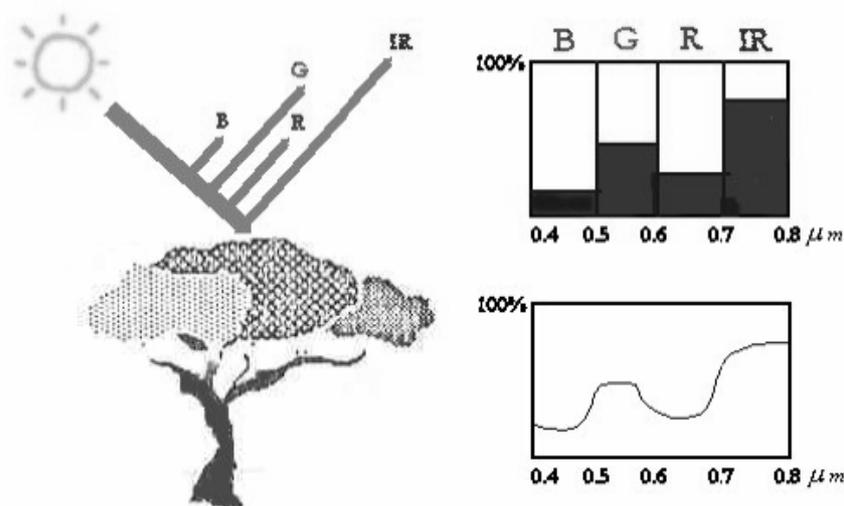


Figura 4. Reflectância do alvo “árvore”

2.2 Sistemas Sensores

Um sensor é um dispositivo capaz de detectar e registrar a radiação eletromagnética existente num objeto, já sensoriamento remoto é o processo de se obter informações sobre um objeto ou fenômenos, através de sensores, sem que haja contato direto com eles [3].

Entre os tipos de sensores presentes estão os multiespectrais e hiperespectrais. A diferença entre eles é que o sensor hiperespectral apresenta sua curva de resposta espectral, em nível de informação obtida, muito mais acentuada que nos sensores multiespectrais.

Um sistema sensor, mostrado na Figura 5, é composto basicamente por:

1. Coletor: pode ser composto por conjuntos lentes, espelhos ou antena;
2. Sistema de Registro (detector): filmes;
3. Processador.

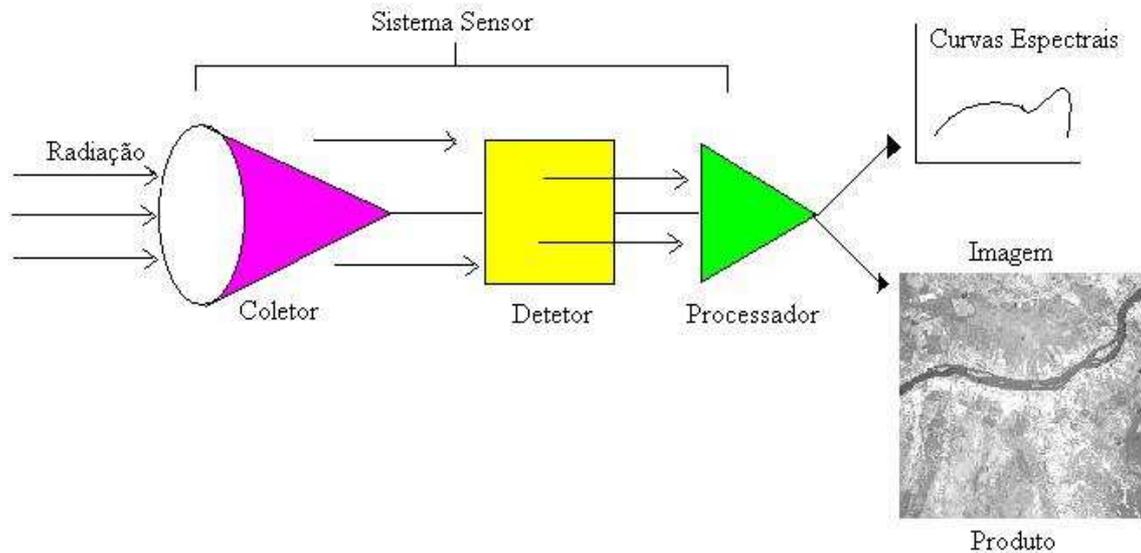


Figura 5. Sistema sensor

O coletor recebe energia, por exemplo, através de lentes, o detector capta a energia coletada de uma determinada faixa do espectro; o sinal registrado é processado (exemplo: amplificado). Através do processamento obtém-se o produto que contém as informações necessárias requeridas pelo usuário.

Os sistemas sensores podem ser classificados em função:

- Da fonte de energia
- Princípio de funcionamento
- Tipo de produto gerado que o sensor produz.

2.2.1 Fontes de Energia

Quanto à fonte de radiação, os sensores podem ser classificados como passivos (Figura 6.a) ou ativos (Figura 6.b) [3].

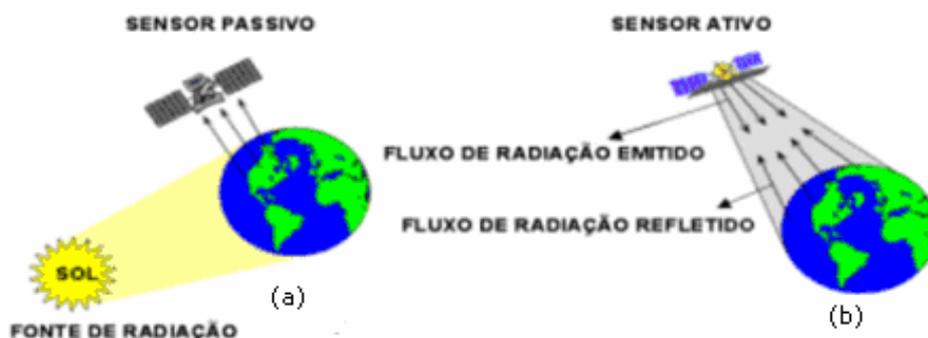


Figura 6. Sensor Passivo (a) e Sensor Ativo(b)

Quando os sensores não possuem sua própria fonte de radiação e são capazes de medir a radiação refletida ou emitida pelos alvos, são chamados de sensores passivos. Como os sensores passivos dependem de uma fonte de iluminação externa, a radiação ao interagir com o objeto é refletida indo atingir o detector do sistema sensor [4].

Já o sistema sensor ativo possui sua própria fonte de radiação eletromagnética e não depende de uma fonte externa para irradiar o alvo. No sistema sensor ativo, o sensor emite um fluxo de radiação numa determinada faixa espectral, quando a radiação atinge o alvo, parte dessa radiação é refletida e captada pelo sensor.

2.2.2 Princípio de Funcionamento

Quanto ao princípio de funcionamento os sensores ativos e passivos estão agrupados em duas categorias:

- Varredura (*Scanning*)

A imagem da cena é formada pela aquisição seqüencial de imagens elementares do terreno. O sensor CCD é um exemplo de sensores de varredura.

- Não-Varredura (*Non-Scanning*)

Registra a radiação refletida da superfície observada em sua totalidade no mesmo instante.

2.2.3 Tipos de produtos

Quanto aos tipos de produtos os sistemas sensores são classificados como:

- Fotográficos

Nos produtos fotográficos, o registro da radiação é representado de forma analógica. Eles registram, através de sistemas ópticos, a energia refletida de objeto. Os detectores dessas imagens registram essa energia em uma película fotossensível chamadas de filmes fotográficos. Os sistemas fotográficos atualmente são os aerotransportados.

- Não-Fotográficos:

Nos produtos não-fotográficos o registro da radiação é representado de forma discreta e medem a radiação eletromagnética presente nos objetos em determinadas faixas espectrais. Os radiômetros possuem sistemas de sensores não-fotográficos e são classificados como:

- Imageadores

Os radiômetros imageadores medem a radiância do objeto e fornecem o resultado dessa medida em forma de gráficos ou números.

- Não-imageadores

O resultado final é expresso na forma de imagem da cena de um terreno.

Uma das características presentes nos imageadores não-fotográficos em geral é a presença de quatro domínios de resolução:

a. Espectral: Nível de resolução do sensor para discriminar diferentes tipos de objetos. Quanto maior a resolução, mais rica em detalhes será as informações dadas a respeito de um objeto.

b. Espacial: refere-se ao campo de visada instantâneo do sensor.

c. Temporal: Nos sensores de sensoriamento remoto que operam a nível orbital, a resolução temporal se refere ao tempo em que o sensor leva pra recobrir a área em estudo.

d. Radiométrica: Está relacionado ao nível de radiação emitida e/ou refletida dos objetos localizados na superfície terrestre.

Ao final deste Capítulo é possível compreender o princípio de funcionamento de um sistema sensor e algumas aplicabilidades destes sistemas.

No próximo Capítulo são abordados estudos dos algoritmos de reconhecimento de padrões, usados na classificação de imagens de sensoriamento remoto.

Capítulo 3

Programa CBERS

A utilização de satélites é uma das maneiras mais eficazes e econômicas de se obter dados sobre a superfície da terra, visando o monitoramento e a modelagem de fenômenos terrestres. Vários países possuem satélites de alta tecnologia onde diversas missões são feitas para a obtenção de coletas de dados.

Portanto, este Capítulo, visa descrever uma visão global da tecnologia CBERS (*China-Brazil Earth-Resources Satellite*) que vai desde o início do acordo do programa, realizado entre China e Brasil, até a apresentação das características presentes no satélite.

Como as imagens que são analisadas no trabalho, pertencem a cidade de Floresta, localizada no sertão do nordeste brasileiro, as imagens do sensor CCD do satélite CBERS-2B são mais citadas no trabalho, já que este foi o sensor usado na classificação das imagens da área.

3.1 Programa CBERS

O programa CBERS foi criado entre uma parceria de Brasil e China no setor técnico-científico espacial, onde ambos os países assinaram em julho de 1988 um acordo de parceria. Neste acordo estariam presentes o INPE (Instituto Nacional de Pesquisas Espaciais) e a CAST (Academia Chinesa de Tecnologia Espacial) que teve como objetivo o desenvolvimento de dois satélites avançados de sensoriamento remoto, denominado Programa CBERS.

Este programa fez com que o Brasil entrasse num seleto grupo de países que faz uso da tecnologia de sensoriamento remoto. Um dos principais objetivos do uso dessa tecnologia para o Brasil é o monitoramento áreas extensas do território brasileiro, buscando cada vez mais consolidar a utilização desse satélite.

O primeiro acordo assinado entre Brasil e China contemplou o lançamento dos satélites de sensoriamento remoto CBERS 1 e 2. O CBERS-1 foi lançado em 14 de outubro de 1999, pelo lançador chinês *Long-March 4B*, a partir de *Tayuan Launch Center*, na República Popular da China, tendo seu tempo vida útil estimado em 2 anos, mas devido ao sucesso, ficou operante até agosto de 2003. Já o satélite CBERS-2, apesar de possuir características muito semelhantes ao CBERS-1, apresenta melhoramentos tanto na estação de processamento de imagens quanto no desempenho de instrumentos. O CBERS-2 foi lançado em outubro de 2003 e estava previsto a ficar em órbita até 2006 [4].

Com o sucesso do lançamento de CBERS-1 e 2, os governos da China e Brasil assinaram mais um acordo onde seriam desenvolvidos mais três novos satélites de sensoriamento remoto, o

CBERS-2B, CBERS-3 e CBERS-4, com características mais robustas. Em 19 de setembro de 2007, o satélite CBERS-2B foi lançado a partir de *Tayuan Launch Center* pelo *Long-March 4B*, mesmo foguete que realizou o lançamento do CBERS 1 e 2.

Pela primeira vez, o Brasil terá participação de 50% no projeto do lançamento do CBERS-3 e 4 e estes lançamentos estão previstos para 2009 e 2011 respectivamente. No próximo tópico são abordadas algumas características importantes presentes no satélite CBERS.

3.2 Características técnicas da tecnologia dos Satélites CBERS

Neste tópico são descritas algumas das características presentes nos satélites CBERS-1, 2 e 2B (Figura 7), que são basicamente compostos por dois módulos:

- Módulo de carga útil;
- Módulo Serviço.

3.2.1 Módulo de carga útil

O módulo de carga útil é responsável por acomodar os sistemas ópticos:

- CCD (*Couple Charged Device*) – Câmera Imageadora de Alta Resolução
- IRMSS (*InfraRed MultiSpectral Scanner*) – Imageador de Varredura de Média Resolução
- WFI (*Wide Field Imager*) - Câmera Imageadora de Amplo Campo de Visada

Com a criação do CBERS-2B, a câmera IRMSS do CBERS-2 foi substituída pelo sensor HRC (*High Resolution Camera*), também chamada de Câmera Pancromática de Alta Resolução [5].

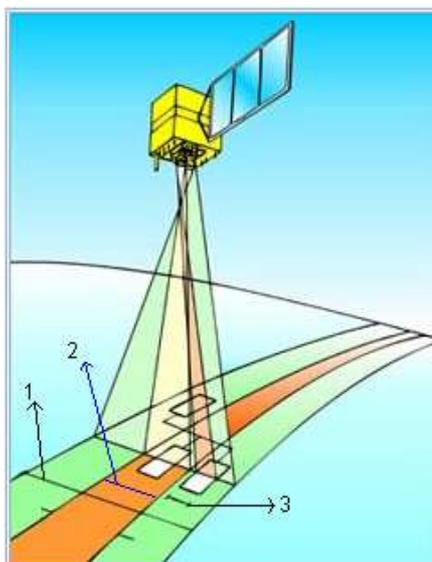


Figura 7. Sensores presente no CBERS-1 e 2

As legendas **1**, **2** e **3** da Figura 7 mostram a área de varredura dos sensores WFI, IRMSS e CCD respectivamente:

- WFI: 890 km;
- IRMSS: 120 km;
- CCD: 113 km.

As variadas câmeras presentes no CBERS-1, 2 e 2B é uma de suas mais importantes características, pois elas possuem diferentes resoluções espaciais (campo de visada instantâneo do sensor, por exemplo, um sensor com resolução espacial de vinte metros registra imagens entre dois objetos que estejam separados até uma distância de 20 m).

Os tipos de sensores presentes nos satélites CBERS-1, 2 e 2B são descritos no decorrer deste Capítulo.

O sensor WFI possui um campo de visada de sessenta graus fazendo com que a largura da faixa imageada chegue a 890 km, permitindo que a resolução espacial seja 260 m x 260 m. Num período de cinco dias, podem ser obtidas imagens de todo o globo terrestre. Outra característica importante no sensor é poder operar com duas bandas espectrais: O vermelho, com comprimento de onda de 0,63-0,69 μm e o infra-vermelho com 0,77-0,89 μm .

O sensor IRMSS, apesar de não estar presente no CBERS-2B, trabalha com quatro faixas espectrais, estendendo seu espectro de observação até o infra-vermelho termal. Sua resolução espacial é de 80 m x 80 m para a banda pancromática (0,50-1,10 μm), infravermelho médio (1,55-1,75 μm), infravermelho médio (2,08-2,35 μm) e resolução de 160 m x 160 m para a banda infravermelho termal (10,40-12,50 μm).

A câmera HRC pertence somente ao CBERS-2B e opera somente em uma faixa espectral pancromática (0,50 - 0,80 μm), produzindo imagens numa faixa imageada de 27 km de largura, com resolução de 2,7 m. Essa resolução permite que a imagem estudada seja observada de forma mais detalhada que os sensores CCD, IMRSS e WFI. O período de resolução temporal (período que o sensor leva para recobrir uma mesma área imageada) do sensor HRC é de 130 dias na operação proposta, ou seja, são necessários 130 dias para se ter uma cobertura total do globo terrestre.

Como as imagens usadas no projeto pertencem ao sensor CCD/CBERS-2B, esse sensor foi o foco deste trabalho. A imagem formada pelo sensor CCD apresenta 6000 linhas, onde cada linha possui 6000 *pixels*. Com um *pixel* possuindo vinte metros de resolução espacial, cada linha formada apresenta uma faixa de 20 m por 120 km. O processo de formação das imagens é realizado de acordo com sua trajetória orbital. Assim, cada linha leva cerca de 0,00289s para ser formada, correspondendo a uma velocidade orbital de 7 km/s. O processo de formação de uma imagem é de aproximadamente 17,24 segundos .

Com o tempo de resolução temporal de 26 dias e largura da faixa imageadora de 113 km, seu campo de visada lateral pode chegar a 32° , diminuindo sua resolução temporal para 3 dias. Outras características do sensor CCD é a formação de pares de imagens estereoscópicas. Suas faixas espectrais são divididas em cinco bandas, sendo o intervalo de (0,51-0,73 μm) para a banda pancromática, (0,45-0,52 μm) para a banda azul, (0,52-0,59 μm) para a banda verde, (0,63-0,69 μm) para a banda vermelha e (0,52-0,59 μm) para o infravermelho próximo, os intervalos espectrais do sensor CCD podem ser vistos na Figura 8.

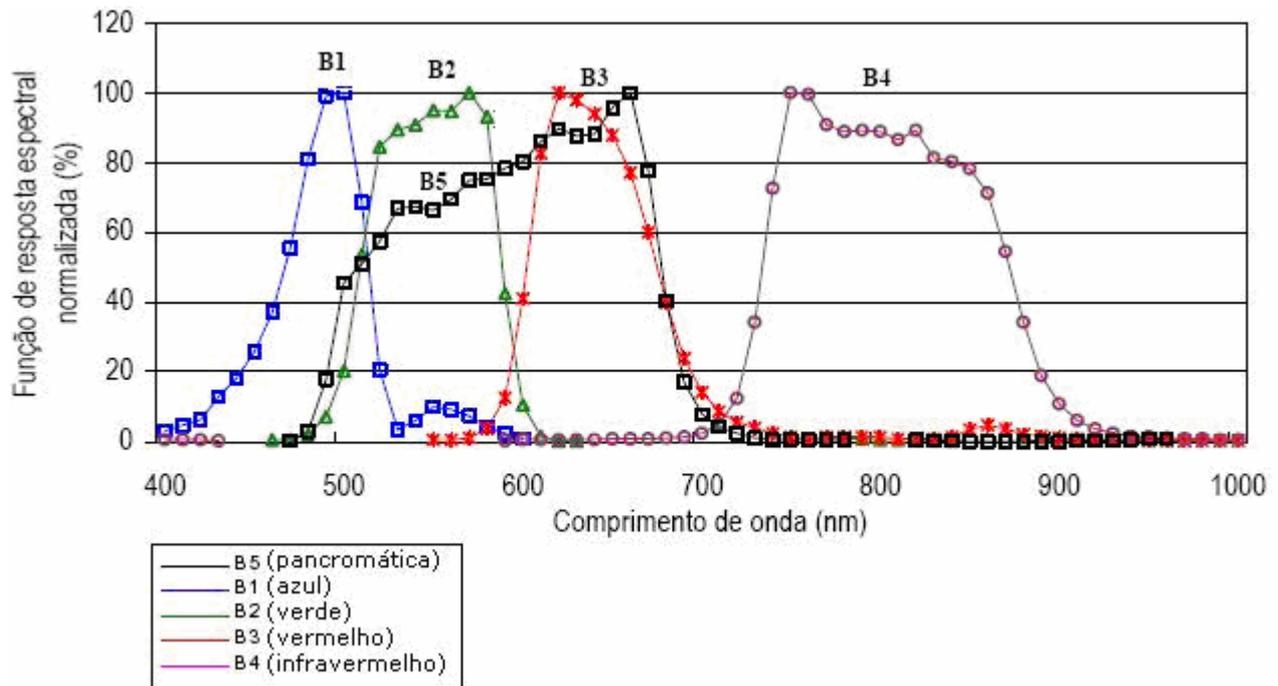


Figura 8. Intervalos espectrais das 5 bandas do sensor CCD [6]

As Figuras 9, 10 e 11 mostram as imagens produzidas pelos sensores WFI, IRMSS e HRC respectivamente.



Figura 9. Imagem do sensor WFI banda 1

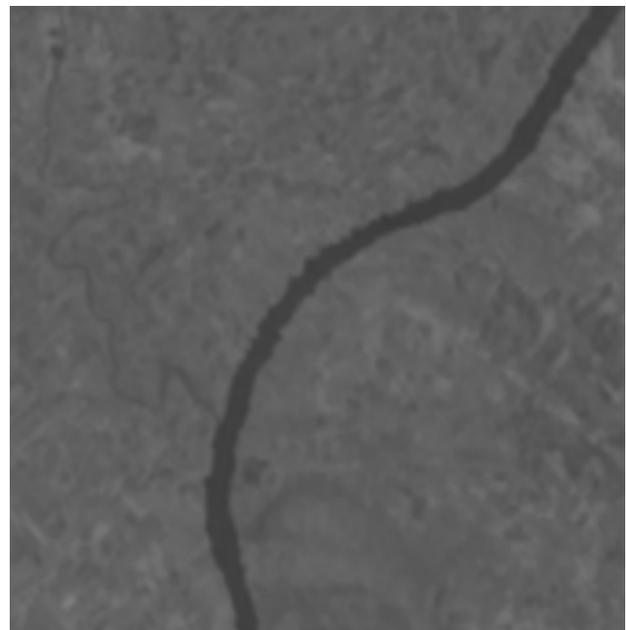


Figura 10. Imagem do sensor IRMSS banda 1



Figura 11. Imagem do Rio São Francisco na cidade de Petrolina com o sensor HRC

3.2.2 Módulo Serviço

O módulo serviço contém equipamentos que têm a função de fornecer energia ao satélite, são também responsáveis pelas funções ligadas às operações no satélite. Para manter o funcionamento do CBERS-2B são necessários 1000 watts de potência, onde esta energia é obtida através do posicionamento dos painéis solares, ficando orientados na mesma direção do sol por controle automático.

O satélite CBERS-2B apresenta uma melhoria em relação CBERS 1 e 2, pois houve a implantação de um receptor GPS (*Global Positioning System*) e a instalação de um sensor de estrelas para dar assistência aos mecanismos de controle de altitude. O auxílio nas eventuais manobras correções da órbita nominal do satélite é realizada com a ajuda de um conjunto de propulsores a hidrazina (composto químico, com fórmula química H_2H_4 , usado como combustível mono-propelente para foguetes usado também como propelente para satélites artificiais).

O satélite (Figura 12) encontra-se numa órbita heliossíncrona (órbita cujo plano guarda uma orientação constante em relação ao Sol, ou seja, o ângulo Sol-Terra-Satélite permanece constante, garantindo condições semelhantes de iluminação ao longo do ano na área imageada). O CBERS-2B está localizado a 778km de altitude em relação a superfície terrestre, chegando a realizar cerca de 14 revoluções por dia, cruzando o equador às dez horas e trinta minutos, sempre com as mesmas condições de iluminação solar comparadas imagens tomadas em dias diferentes [5].



Figura 12. Imagem do satélite CBERS-2B

As imagens enviadas dos satélites de sensoriamento remoto possuem distorções sistemáticas que ocorrem no processo de formação das imagens. Essas distorções são relacionadas a diferentes fatores, tais como:

- Rotação da Terra durante a formação da imagem
- Distorções panorâmicas
- Variações de altitude, velocidade e posicionamento da plataforma

Um exemplo dessa distorção ocorreu em 23/03/2005, quando os pesquisadores notaram uma variação geométrica das imagens CCD/CBERS-2. Após esse problema, foi realizado um experimento no qual seria verificada a acurácia posicional do satélite em datas próxima a transferência de controle, realizadas entre China e Brasil. Logo foi detectado um erro no algoritmo chinês, responsável pelo controle da altitude do satélite. Esse erro ocorreu devido a diferença do tempo sideral que fazia com que o computador de bordo transmitisse os dados errados sobre a altitude do satélite, fazendo com que houvesse distorções nas imagens.

3.3 Sistema de Coleta de dados

Neste tópico é abordada a forma como os dados são coletados pelas plataformas de coleta de dados e a maneira como esses dados são transmitidos até chegar ao centro de missão localizado em Cachoeira Paulista-SP. O satélites SCD-1, SCD-2, CBERS-2, CBERS-2B junto com as plataformas de coletas de dados (PCDs), estações de recepção de dados de Cuiabá e Alcântara e pelo centro de missão coleta formam o sistema brasileiro de coleta de dados.

Os PCDs são plataformas de coletas de dados que possuem sensores responsáveis por coletar informações em locais remotos. Algumas das informações obtidas pelos PCDs são: cálculo da temperatura do ambiente, velocidade do vento e umidade do ar no local, onde está localizada a plataforma. A comunicação feita entre as plataformas e estações de recepção é estabelecida pelos satélites, que funcionam como retransmissores de dados, onde as plataformas geralmente enviam cerca de 32 bytes dados úteis a cada 200 segundos para os satélites.

A coleta de dados é feita inicialmente quando uma PCD estabelece conexão com o satélite, depois de estabelecida a conexão, dados são enviados das PCDs para o satélite, visualizado na Figura 13, o satélite retransmite a informação enviada pela PCD para a estações de recepção localizadas em Alcântara no Maranhão e em Cuiabá no Mato Grosso (Figura 14). Os dados recebidos pelas estações de recepção são enviados ao centro de missão de coletas localizado em Cachoeira Paulista, na cidade de São Paulo, para serem então processados (Figura 15) [5].



Figura 13. Transmissão de dados entre PCDs e Satélite



Figura 14. Transmissão de dados entre satélite e antena de recepção



Figura 15. Transmissão de dados entre antenas de recepção e centro de missão de coleta

A Figura 16 mostra os sensores presentes numa PCD. O sensor 1 é responsável pela medição da velocidade do vento na localidade. O sensor 2 mede a temperatura do local. O sensor 3 avalia o nível de radiação solar. O sensor 4, 5, 6, 7 e 8 são respectivamente responsáveis por medição do índice pluviométrico, pressão atmosférica, radiação solar líquida, temperatura e fluxo de calor no solo.



Figura 16. Imagem de uma plataforma de coleta de dados

Com o término deste Capítulo foi possível entender o surgimento do programa CBERS, algumas características importantes presentes no satélite, nos seus sensores e o funcionamento das PCDs. O próximo Capítulo tem como objetivo mostrar a importância dos algoritmos de reconhecimento de padrões aplicada às imagens de sensoriamento remoto.

Capítulo 4

Reconhecimento de Padrões Aplicado a Sensoriamento Remoto

O desenvolvimento de sistemas baseado em reconhecimento de padrões ou tomada de decisões é uma área da ciência com amplo campo de pesquisa e desenvolvimento, já que estes sistemas são bastante usados atualmente. Cartões magnéticos, leitores de código de barras são exemplos de aplicações desses sistemas, que tem como objetivo classificar objetos de interesse em uma determinada classe ou categoria, pois, em sensoriamento remoto, um *pixel* pode ser definido como uma classe criada pelo analista. O objetivo desse Capítulo é mostrar o uso de algoritmo de reconhecimento de padrões aplicado a imagens digitais de sensoriamento remoto, usando algoritmos de classificação supervisionados ou não-supervisionados.

4.1 Algoritmos de Agrupamento

Os algoritmos de agrupamentos, também chamados de *Clustering*, particionam objetos em conjuntos (*clusters*) baseando-se na similaridade entre eles. Os elementos de um conjunto são mais similares entre si do que os elementos pertencentes a outros conjuntos.

“Um agrupamento pode ser visto como uma partição sobre um espaço de atributos, definidos sobre algum critério”(Bailey,1995).

A principal função da clusterização é particionar conjuntos de objetos em grupos homogêneos de modo que haja uma maximização das semelhanças dos objetos dentro de cada cluster e uma minimização da homogeneidade entre os objetos que pertencem a clusters distintos.

Com o crescente número de dados disponíveis atualmente é necessário que haja classificações ou agrupamentos desses dados em conjuntos ou categorias para uma melhoria de acessibilidade dessas informações. Os clusters usam o método de aprendizagem não supervisionada (não faz uso de um “supervisor” para indicar o que cada padrão representa) e os conjuntos nos quais os objetos vão ser inseridos são definidos pelo algoritmo de agrupamento.

Uma melhor forma de compreender o funcionamento do algoritmo de *Clustering* é apresentada na Figura 17.

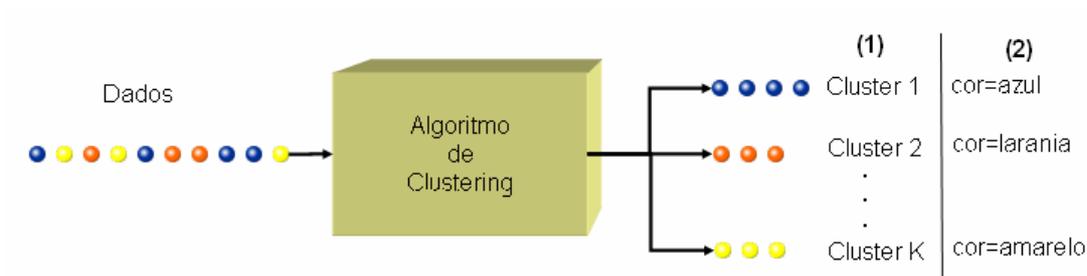


Figura 17. Processo de separação de classes usando o Algoritmo de *Clustering*

No algoritmo, os dados são agrupados em *clusters* e classificados em classes de acordo com o grau de similaridade existente entre eles.

4.1.1 Mapas Auto-Organizáveis

Os mapas auto-organizáveis de *Kohonen*, também chamados de redes SOM, [7] (*Self Organized-Maps*) são redes neurais com auto-capacidade de organização. Utilizando o paradigma de aprendizado não-supervisionado, busca encontrar similaridade baseando-se nos padrões de entrada. O principal objeto do uso dos mapas auto-organizados é agrupar os dados de entrada semelhantes formando os *Clusters*.

As redes SOM foram criadas baseando-se no mapa topológico que existe no córtex cerebral. Sua arquitetura é composta por uma malha onde cada neurônio está conectado às componentes de entrada através de um vetor de pesos com mesma dimensão do vetor de entrada, mostrada na Figura 18 [8].

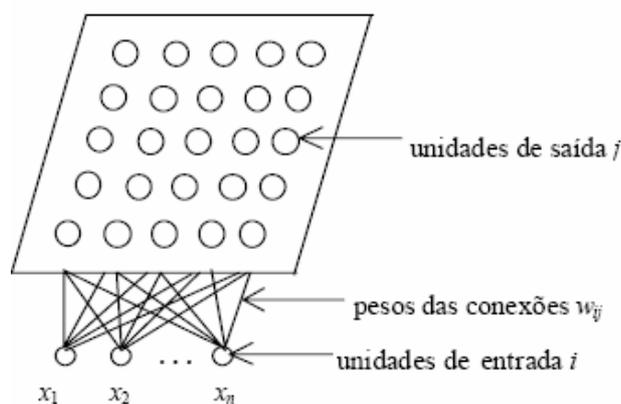


Figura 18. Arquitetura tipo de uma rede de Kohonen para arquitetura bidirecional

O conceito de vizinhança local (o comportamento de uma unidade é diretamente afetado pelo comportamento das unidades vizinhas) foi implementado nesse tipo de rede, podendo também alocar em um mesmo neurônio ou neurônio vizinhos entradas que estão de alguma forma próxima no espaço original.

No processo de aprendizagem os neurônios competem pelo privilégio de aprender, calculando sua proximidade do vetor de pesos ao vetor de entrada. Uma característica que deve ser considerada nas redes de Kohonen é que o tamanho do vetor de entrada deve ser igual ao do vetor de pesos e a distância entre os vetores de peso e de entrada de cada neurônio da rede pode

ser feita usando várias métricas, por exemplo, a distância euclidiana. Depois de calculada as medidas entre os vetores, o que possuir a menor distância será o neurônio vencedor, sendo o único a gerar um sinal de saída. Este neurônio e seus vizinhos são os únicos que podem modificar seus pesos e aprenderem com a apresentação de um determinado padrão. Após o treinamento da rede, cada neurônio está associado a um vetor de pesos podendo ser um representante deste grupo. O passo final é apresentar os padrões de entrada à rede para que eles sejam ajustados “automaticamente” e os vetores de entrada, com características semelhantes, fiquem agrupados em *clusters* ou nos *clusters* vizinhos [9].

Uma maneira didática para explicar o funcionamento dos mapas auto-organizáveis de Kohonen é representada a seguir.

No primeiro passo, mostrado na Figura 19, o número de aglomerados devem ser definidos antecipadamente. No passo 2 foi definido uma grade com 6 nodos.

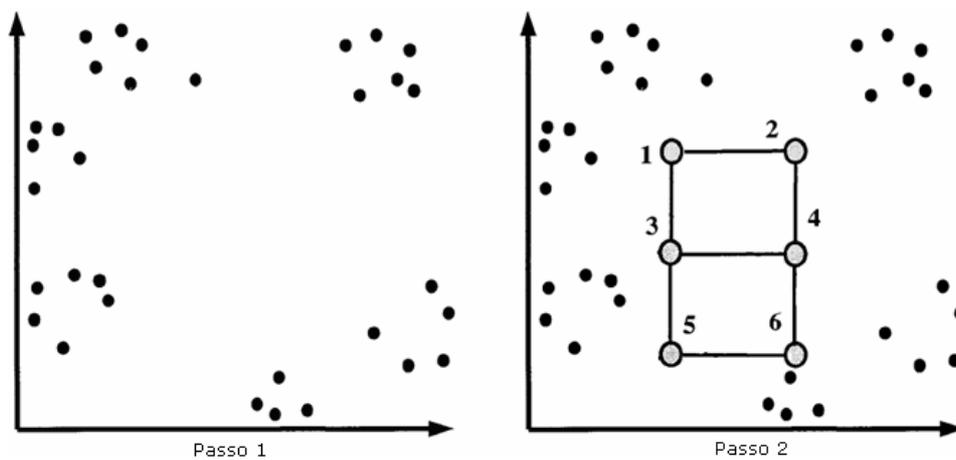


Figura 19. Passos da classificação das redes de Kohonen

No passo 3, na Figura 20, um padrão P foi escolhido aleatoriamente e passo 4 foram calculadas as distâncias de todos os nodos da grade em relação a padrão P escolhido.

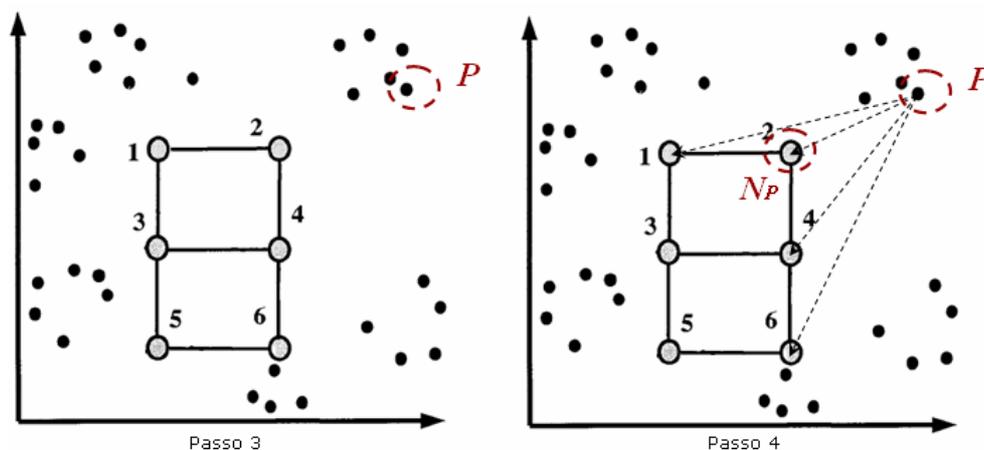


Figura 20. Passos da classificação das redes de Kohonen

Como o nodo 2 (N_p) é o nodo mais próximo do aglomerado onde o padrão P pertence, a posição de N_p é ajustada. No passo 5 um novo padrão Q é selecionado aleatoriamente. No passo 6 são novamente calculadas as distâncias do padrão Q em relação aos nodos da grade e a posição

do nodo N_q é ajustada, visualizado na Figura 21. O processo é repetido até que o critério de parada seja satisfeito, como mostrado no passo 8 (Figura 22).

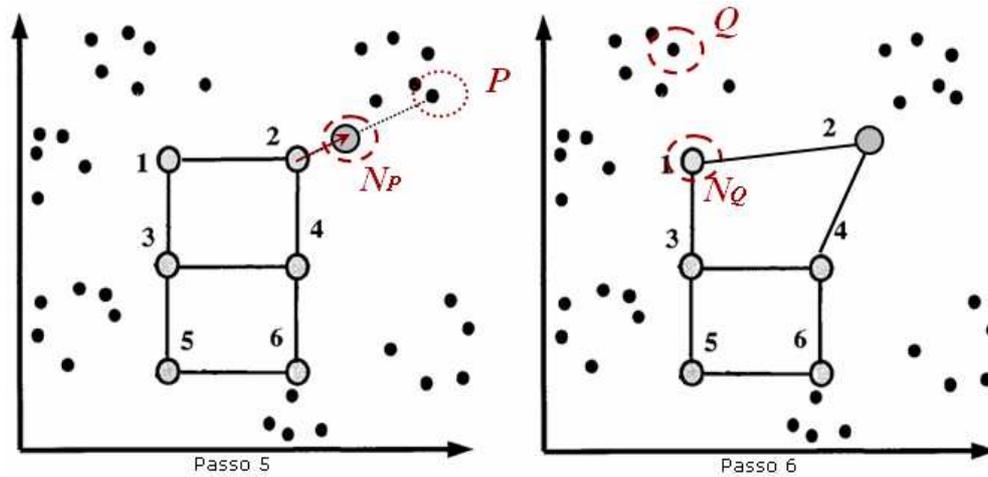


Figura 21. Passos da classificação das redes de Kohonen

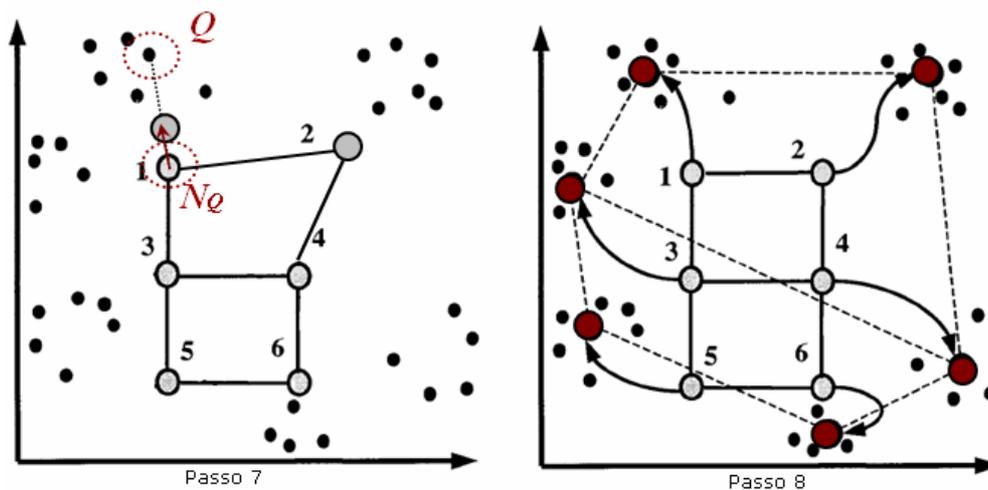


Figura 22. Passos da classificação das redes de Kohonen

A dependência de muitos parâmetros tais como: número de interações, inicialização dos pesos e taxa de aprendizagem, são algumas das dificuldades apresentadas por esse algoritmo.

4.1.2 K-Médias

O *K-Means*, também chamado de K-Médias, é um algoritmo de agrupamento não-supervisionado que pertence a classes dos algoritmos de partição, onde os dados são divididos em um conjunto de *clusters*. Usando o critério de distância mínima o algoritmo aglomera classe por classe em um processo iterativo. O algoritmo chega ao fim quando o número de interações, definida pelo usuário finalizar ou se o número de espectros que mudam de classes alcance um determinado valor. Duas interações consecutivas são usadas para calcular a diferença média dos espectros com relação aos respectivos centróides [10].

O algoritmo K-Médias pode ser descrito de maneira simplificada como:

Dado uma entrada E , representado por um conjunto de dados com X objetos e NG como o número de grupos. Os passos do algoritmo são:

- (1). Escolher arbitrariamente NG objetos de E como centros iniciais dos grupos;
- (2). Repita:
 - (2.1). Colocar cada X objeto em cada NG centro mais próximo desse objeto;
 - (2.2). Calcular novos centros para cada grupo, onde cada centro novo é igual ao valor médio dos objetos;
- (5) até que: não haja mais mudança nos centros;

O exemplo da Figura 23.a mostra padrões posicionados num espaço bi-dimensional onde K clusters são definidos pelo usuário, nesse exemplo $k = 3$ (Figura 23.b), são distribuídos aleatoriamente.

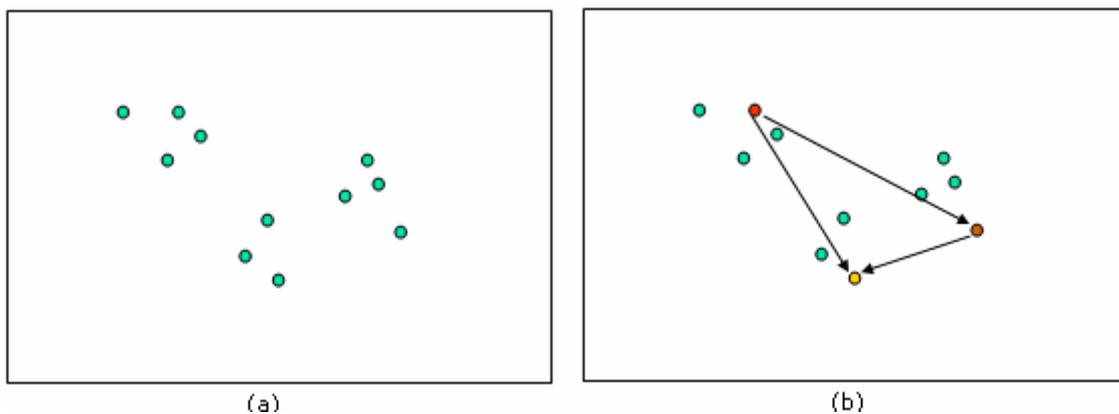


Figura 23. Passos da classificação das redes de K-Médias

No terceiro passo, Figura 24.a, são calculadas as distâncias de cada ponto aos K centros e a cada centro são associados os pontos mais próximos. Se mais de um ponto pertence a uma determinada classe, o valor de um novo centróide é calculado fazendo-se a média de cada atributo de todos os pontos que pertencem a essa classe, como mostrado na Figura 24.b.

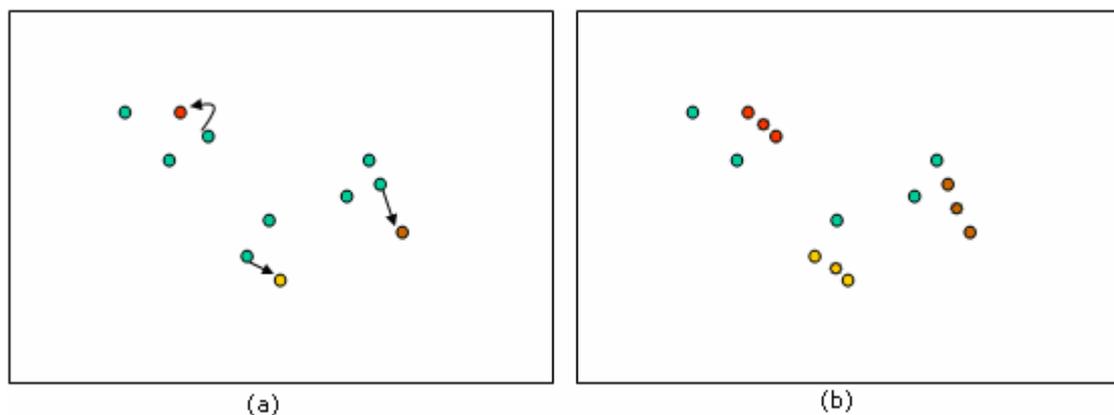


Figura 24. Passos da classificação das redes de K-Médias

No próximo passo, Figura 25.a, os dois passos anteriores são repetidos com os novos centróides. Esses passos são executados até que não seja necessária uma mudança do centróide (Figura 25.b).

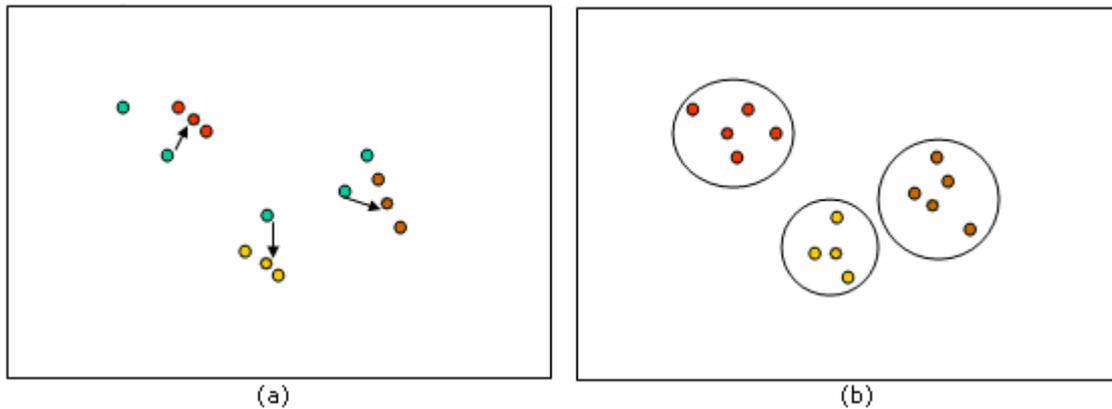


Figura 25. Passos da classificação das redes de K-Médias

Uma das maiores dificuldades apresentadas pelo algoritmo do K-Médias é a definição inicial dos K *clusters*, pois não se sabe se eles serão suficientes para representar os dados.

4.2 Algoritmos de Classificação Supervisionados

4.2.1 Máxima Verossimilhança

Máxima Verossimilhança, conhecido como MAXVER, é um método de classificação supervisionado (o usuário definirá as classes que aos quais os dados pertencerão) muito usado na classificação de imagens digitais de sensoriamento remoto. O algoritmo de classificação da Máxima Verossimilhança utiliza-se de parâmetros estatísticos para considerar a ponderação das distâncias entre médias dos níveis digitais das classes.

É necessário que um elevado número de *pixels* faça parte das amostras do conjunto de treinamento para uma melhor precisão no processo de classificação de imagens digitais utilizando o algoritmo MAXVER. Através do conjunto de treinamento são definidos diagramas de dispersão das classes e suas respectivas distribuições de probabilidades.

Na classificação realizada pelo MAXVER (Figura 26) são apresentadas duas classes de com distribuição de probabilidades distintas, onde esta distribuição representa a probabilidade de um *pixel* pertencer a uma classe ou a outra qualquer.

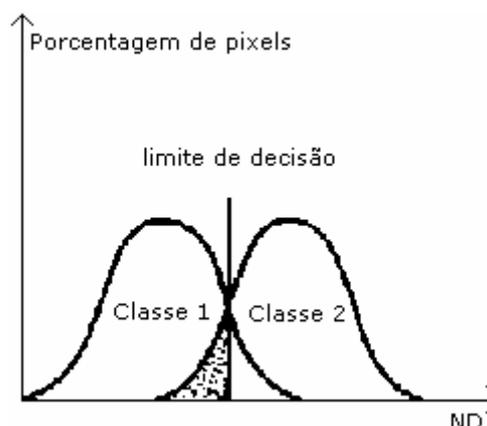


Figura 26. Classificação Máxima Verossimilhança

Como pode ser observado, a região onde as duas curvas sobrepõem indica que um determinado *pixel* tem igual probabilidade de pertencer a ambas as classes. Para solucionar este problema de classificação, para *pixels* com igual probabilidade de pertencer a uma mesma classe, foi criado um critério de decisão a partir da definição de limiares.

Através desse limite de decisão, um *pixel* que esteja localizado na região sombreada, apesar de pertencer a classe 2, será classificado com classe 1 por um limite de aceitação estabelecido. O limite de aceitação nada mais é que a porcentagem de *pixel* da distribuição de probabilidade de uma classe que será classificada como pertencente a esta classe. Por exemplo, um limite de aceitação de 99%, engloba a classificação de 99% dos *pixels*, e 1% dos *pixels* são ignorados (os *pixels* de menor probabilidade). A vantagem do uso do limiar é compensar a probabilidade de alguns *pixels* terem sido introduzidos no treinamento por engano, nesta classe, ou estarem no limite entre as duas classes [12].

Outro exemplo usado para exemplificar a forma como algoritmo de MAXVER faz a classificação imagens digitais é mostrado na Figura 27.

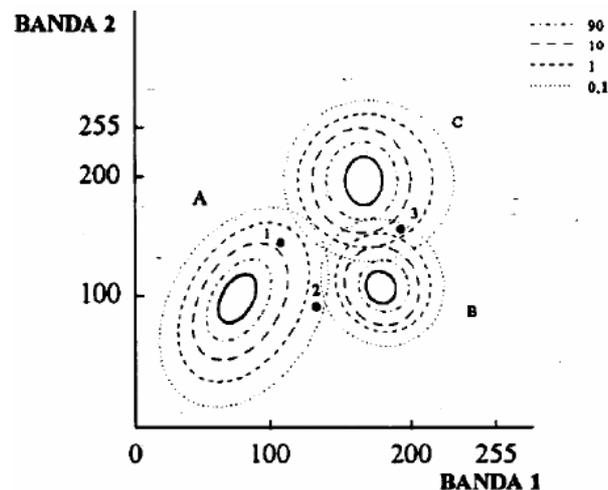


Figura 27. Classificação do algoritmo Máxima Verossimilhança

No processo de classificação de imagens digitais são vistas as curvas de probabilidade para as classes A, B e C, no espaço de atributos de duas bandas espectrais, usadas na classificação da máxima verossimilhança. Como pode ser visto, os valores dos níveis de cinza de três *pixels* da imagem são representados pelos pontos 1, 2 e 3.

Para a aplicação desse método de classificação, parte-se do pressuposto que os níveis de cinza do *pixel* de cada classe apresentam distribuição normal, onde o algoritmo MAXVER avalia a probabilidade de cada *pixel* pertencer às classes já definidas, ou seja, um *pixel* x será inserido a classe A se a probabilidade dele pertencer as outras classes forem menores.

Por exemplo, ao se escolher o *pixel* 2, o algoritmo classificá-lo-á como sendo da classe A, pois apesar de se encontrar mais próximo ao valor central da banda B, ele encontra-se inserido numa faixa de maior probabilidade para pertencer a classe A.

4.2.2 Distância Euclidiana

A medida da distância Euclidiana pode ser usada na classificação supervisionada usando a distância entre dois objetos para associar um *pixel* a uma determinada classe. O cálculo da distância entre objetos é um dos métodos mais simples de classificação, pois quanto maior o

valor, menor será o grau de similaridade e, quanto menor o valor, maior a similaridade ou menor dissimilaridade entre os objetos. Seja $d(s,q)$ a distância entre dois objetos s e q pertencentes ao mesmo domínio. Se as dimensões dos vetores de características de s e q forem iguais, a distância $d()$ é a distância euclidiana entre eles e é dado por:

$$d(s, q) \equiv \sqrt{\sum_{i=1}^n (s[i] - q[i])^2} \quad (2)$$

Onde $s[i]$ e $q[i]$ representam o valor da i -ésima dimensão de s e q .

Na classificação de imagens de sensoriamento remoto, as amostras são coletadas e são definidos os agrupamentos que representam as classes [13]. Na análise feita pela distância Euclidiana, cada *pixel* faz parte de um agrupamento.

Essa análise é feita através de:

$$d(x, m) = \sqrt{(x^2 - m^2)} \quad (3)$$

onde:

x = *pixel* que está sendo testado;

m = média de agrupamento.

A equação (3) compara a distância Euclidiana do *pixel* com a média de cada agrupamento, onde o *pixel* é inserido ao agrupamento que apresenta menor distância. Este procedimento é repetido até que toda a imagem digital seja classificada.

Aprendizagem baseada em instâncias, redes neurais, estatísticas, reconhecimento de padrões e psicologia cognitiva são algumas das áreas em que a classificação, utilizando a Distância Euclidiana está presente, pois muitos sistemas inteligentes dependem da eficiência de uma função para cálculo de distância entre dois vetores.

Capítulo 5

Estudo de caso: Classificação de Imagens do Município de Floresta

5.1 Introdução

Neste Capítulo é apresentado o estudo de caso que consiste na classificação de imagens de sensoriamento remoto do município de Floresta, utilizando os algoritmos de classificação supervisionados (distância Euclidiana e Máxima Verossimilhança) e não-supervisionados (K-Médias). Na Seção 5.2 são apresentados os materiais e métodos usados no projeto, onde serão mostradas características do ambiente SPRING, da área de estudo imageadas pelo satélite, o conceito de registro de imagens, a forma em que este registro foi abordado no projeto e por fim os métodos de classificação disponíveis na ferramenta. Na Seção 5.3 são mostrados os resultados obtidos no trabalho e para finalizar o tópico da seção 5.4 são apresentados comentários e algumas conclusões a respeito dos resultados obtidos.

5.2 Materiais e Métodos

5.2.1 O Ambiente SPRING

O SPRING (Sistemas para Processamentos de Informações Georreferenciadas) foi o programa usado no projeto para a obtenção dos resultados. Este sistema foi desenvolvido pelo INPE (Instituto Nacional de Pesquisas Espaciais) e suas funcionalidades são utilizadas no processamento de imagens, análise espacial e consultas a banco de dados espaciais. Algoritmos especiais usados na segmentação de imagens realizam indexação espacial baseando-se no modelo orientado a objeto e garantindo ótimo desempenho em várias aplicações [14]. O SPRING é baseado em três módulos:

1. IMPIMA: tem a função de ler as imagens capturadas pelos sensores;

2. Spring: principal módulo de entrada de dados. Nele os dados podem ser manipulados e processados.

3. SCARTA: através dos resultados gerados no SPRING, pode-se editar cartas e arquivos de impressão.

5.2.2 Área Imageada

Floresta é um município do estado de Pernambuco com 3.664,9 km² de área e está localizado a 433 km da capital pernambucana (Recife), as coordenadas geográficas do município são 08°36'04" latitude Sul e 38°34'07" longitude Oeste. Sua população possui cerca de 28.000 habitantes. Através da Figura 28 é possível ter uma idéia de como a cidade está inserida no estado de Pernambuco.

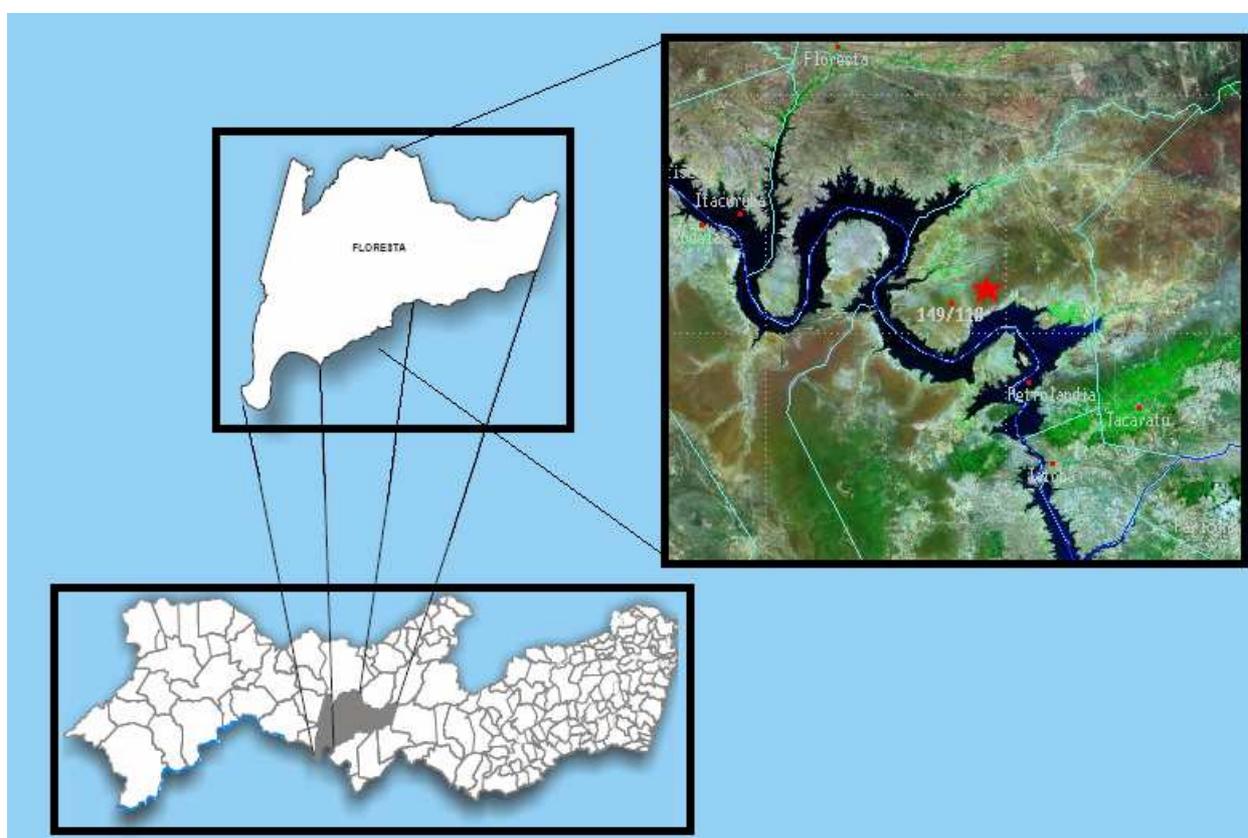


Figura 28. Localização da área de estudo [15]

Aspectos Socioeconômicos

O município de Floresta é constituído pelo município de Airi, Carnaubeira e Olho D'água do Padre, Nazaré do Pico, Carqueija e dos povoados: Varjota, Gravata de São Francisco, Juazeiro de São Francisco, Jaburu, Massapê e Santa. Dados do censo divulgados pelo IBGE (Instituto Brasileiro de Geografia e Estatística) mostram uma taxa de urbanização de 64%, enquanto a rural é 36%.

Aspectos Fisiográficos

A cidade de Floresta está inserida na unidade geoambiental da Depressão Sertaneja, que representa a paisagem típica do semi-árido nordestino, caracterizada por uma superfície de pediplanação bastante monótona. Sua vegetação é basicamente composta por Caatinga Hiperxerófila com trechos de Floresta Caducifólia. O clima é do tipo Tropical Semi-Árido, com chuvas de verão.

As imagens da região foram obtidas pelo sensor CCD em suas 5 bandas espectrais: banda1 (Figura 29), banda2 (Figura 30), banda3 (Figura 31), banda4 (Figura 32) e banda5 (Figura 33).

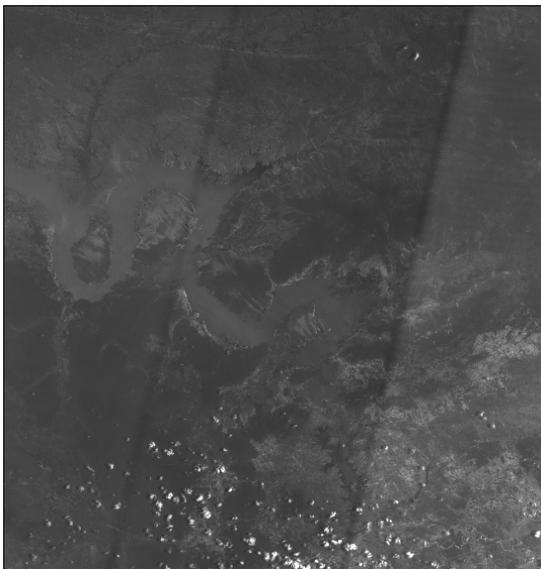


Figura 29. Imagem CBERS-2B banda 1

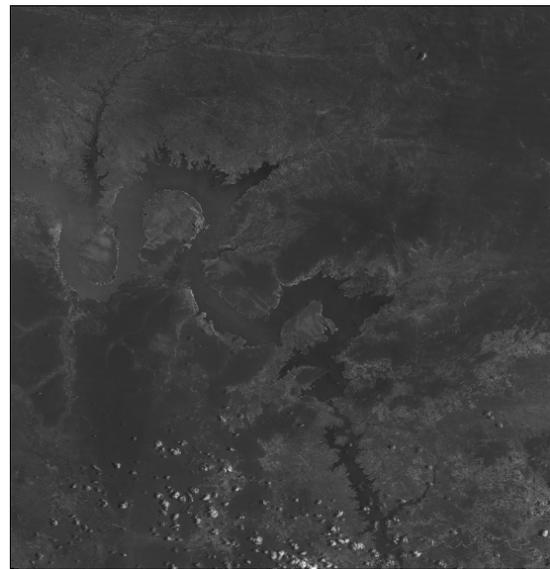


Figura 30. Imagem CBERS-2B banda 2

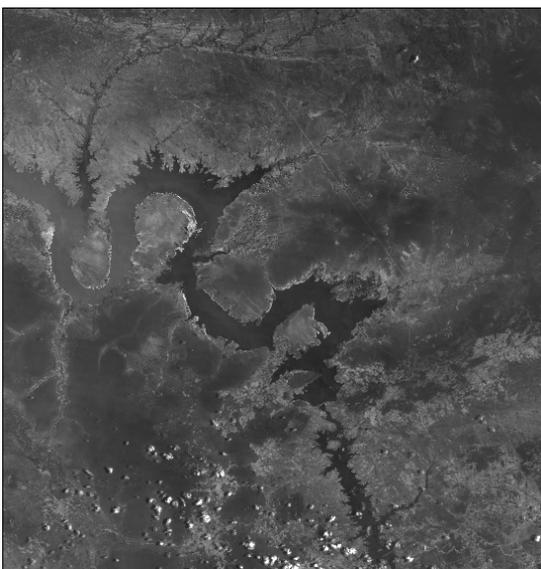


Figura 31. Imagem CBERS-2B banda 3

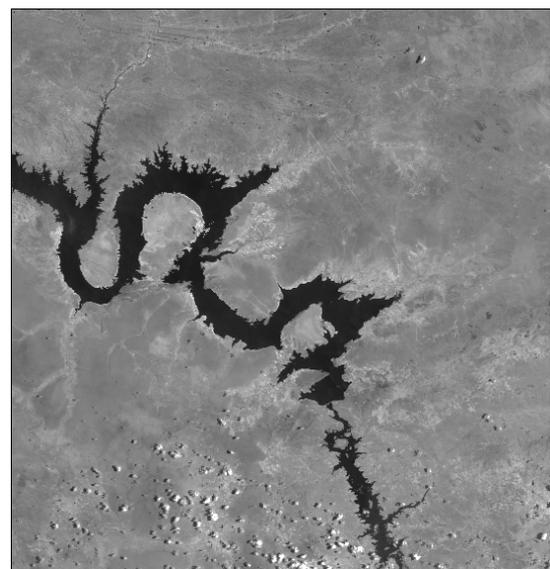


Figura 32. Imagem CBERS-2B banda 4



Figura 33. Imagem CBERS-2B banda 5

As imagens das 5 bandas espectrais foram requisitadas ao INPE (Instituto Nacional de Pesquisas Espaciais) e enviadas no formato .tiff (*Tagged Image File Format*). A leitura das imagens são feitas no IMPIMA e salvas no formato .grb (formato aceito pelo SPRING para o registro de imagem).

Uma das motivações para se usar a cidade de Floresta no projeto foi desta encontrar-se inserida nos domínios da Macro Bacia do Rio S ao Francisco, Bacia Hidrográfica do Rio Pajeú e do Grupo de Bacias de Pequenos Rios Interiores, o que leva a cidade a possuir uma grande diversidade natural, permitindo que haja mais regiões a serem analisadas no projeto.

As imagens relacionadas às cinco bandas que foram mostradas, precisam ser registradas. O próximo tópico mostra o processo de registro de uma imagem, realizado pela ferramenta SPRING.

5.2.3 Registro de Imagens

Para que haja o registro de uma imagem é necessário que ela seja georreferenciada. O georreferenciamento é o processo de tornar conhecida as coordenadas de uma imagem num dado sistema de referência. Algumas coordenadas de pontos da imagem devem ser obtidas no georreferenciamento. Essas coordenadas são chamadas de pontos de controle. Um ponto de controle é considerado como o local com boa nitidez da imagem, como por exemplo, imagem de um rio.

O registro de uma imagem é a transformação geométrica desta, onde as coordenadas da imagem são relacionadas com as coordenadas de um sistema de referência, mostrado na Figura 34. No SPRING, esse sistema de referência, é o sistema de coordenadas planas. Essa transformação geométrica tem o objetivo de eliminar as distorções existentes na imagem causadas em seu processo de formação, pois o sistema sensor do satélite não se encontra em posição precisa no momento do imageamento da área. Como o registro relaciona as coordenadas da imagem com as coordenadas geográficas, esse processo envolve superposição de uma mesma cena que aparece em duas ou mais imagens distintas, de forma que os pontos correspondentes nas imagens coincidam espacialmente [16].

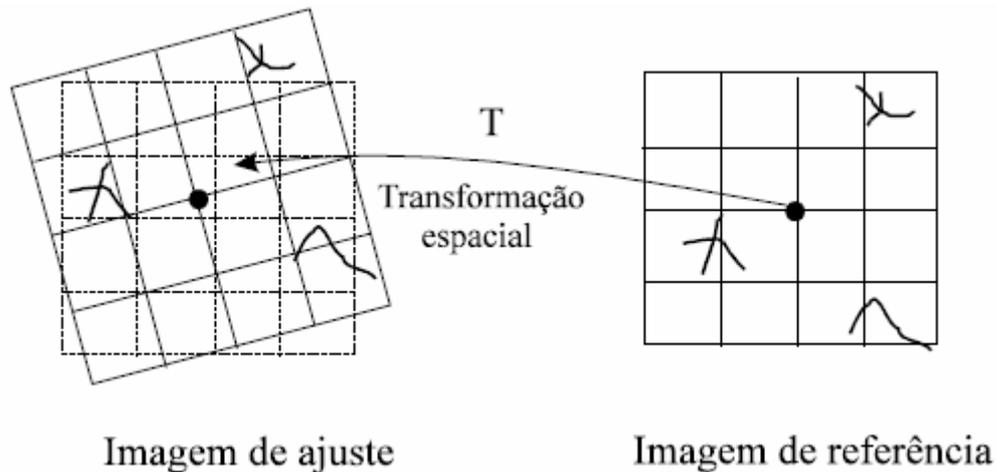


Figura 34. Transformações polinomiais

Os procedimentos usados no processo de registro das imagens foram, primeiramente, escolher se as transformações polinomiais seriam do primeiro ou segundo grau. Essa transformação é bastante comum durante o registro, pois elas criam um vínculo entre as coordenadas da imagem e o sistema de coordenadas de referência, através dos pontos de controle. A obtenção das coordenadas dos pontos de controle pode ser realizada a partir de levantamentos topográficos, GPS (*Global Positioning System*), por meio de mesas digitalizadoras ou mapas georreferenciados. No projeto, foi utilizado o modo teclado (GPS) e o número mínimo de pontos de controle obtidos foi calculado, tomando como base o grau da equação usada na transformação polinomial. O número mínimo de pontos de controle pode ser encontrado pela equação:

$$N_{pc} = \frac{(N+1)(N+2)}{2} \quad (4)$$

onde:

N é o grau do polinômio

N_{pc} : número de pontos de controle

Caso a equação seja do primeiro grau ($N=1$) o número mínimo de pontos de controle é:

$$N_{pc} = \frac{(1+1)(1+2)}{2} = 3 \text{ pontos de controle}$$

A transformação polinomial do primeiro grau é dada por:

$$\begin{aligned} x_r &= a_1x + b_1y + d_1 \\ y_r &= a_2x + b_2y + d_2 \end{aligned} \quad (5)$$

onde:

x_r e y_r : são coordenadas planas

x e y : são coordenadas da imagem

a_1, a_2, b_1, b_2, d_1 e d_2 : parâmetros responsáveis pela relação dos dois sistemas

No projeto foram usadas transformações polinomiais do segundo grau. Logo, o número mínimo de pontos de controle a serem adquiridos é seis.

O último procedimento usado no registro da imagem foi a escolha do interpolador: vizinho mais próximo. Sua função é fazer com que o sistema não gere níveis de cinza intermediário iguais aos da imagem de entrada.

A Figura 35 mostra uma imagem da banda 1 do sensor CCD registrada no programa SPRING.

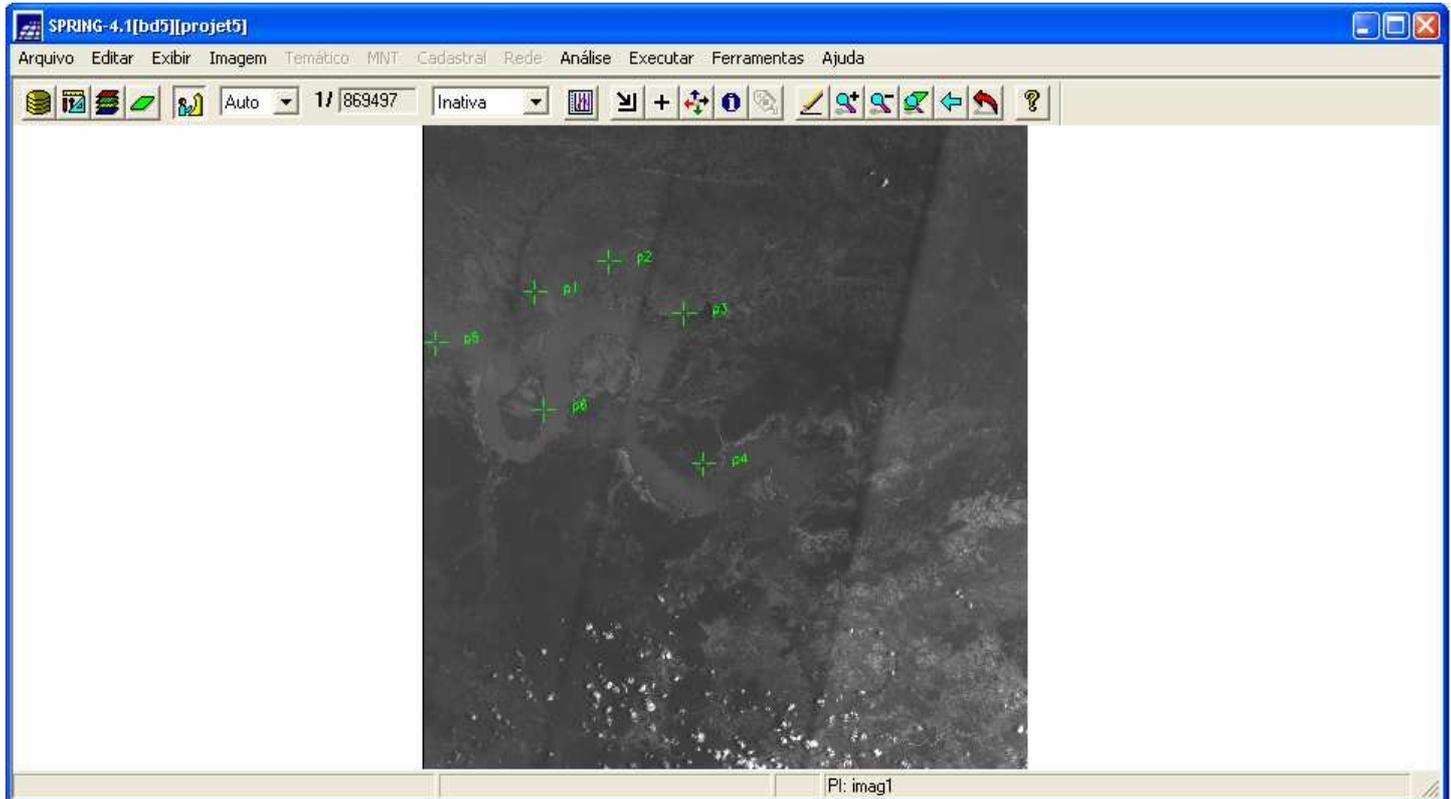


Figura 35. Imagem de uma imagem registrada no SPRING

5.2.4 Métodos de Classificação

Os algoritmos usados na classificação das imagens registradas no SPRING foram: Máxima Verossimilhança, o baseado na distância Euclidiana e o K-Médias. No processo de classificação das imagens no ambiente SPRING foi necessária a criação de um arquivo de contexto contendo informações sobre o tipo de classificador, assim o escolhido no projeto foi o “*pixel a pixel*”.

Antes da fase de treinamento dos algoritmos, foram definidas as classes (Tabela 1), através da interpretação visual da imagem do sensor CCD. Para a classificação das duas imagens multiespectrais, utilizando o algoritmo MAXVER, foram utilizadas 14 amostras do tipo aquisição e 7 amostras do tipo teste, com limiar de aceitação de 100%, o que significa que todos os *pixels* previamente determinados para suas respectivas classes foram 100% classificados. Na classificação das mesmas duas imagens multiespectrais usando algoritmo baseado na distância Euclidiana, foram utilizadas 14 amostras de aquisição e 7 amostras de teste. Já na classificação usando o algoritmo K-Médias foram usados, como parâmetros de entrada do classificador, 8 temas com 10 iterações e 7 temas com 10 iterações.

Tabela 1. Classes definidas no projeto

Classe	Descrição	Legenda
Águas Profundas	Águas profundas do rio.	
Águas Rasas	Águas rasas do rio.	
Vegetação 2	Vegetação Caatinga Hiperxerófila.	
Vegetação 1	Vegetação Floresta Caducifolia.	
Vegetação 3	Outros tipos de vegetação presentes.	
Nuvem	Nuvens presentes no local.	
Solo	Área com mínima cobertura.	

Por fim, realizou-se uma análise quantitativa dos resultados obtidos nas classificações da imagem em estudo. Esta análise teve como base as amostras de aquisição e teste, onde foi gerada a matriz de confusão das amostras de teste dos algoritmos de classificação MAXVER e o baseado na distância Euclidiana. No Tópico de resultados são discutidos os desempenhos das matrizes de confusão a fim de avaliar a eficiência dos algoritmos.

5.3 Resultados e Discussões

O resultado obtido no projeto foi gerado a partir de amostras da imagem multiespectral formada a partir das cinco bandas espectrais presentes no sensor CCD. A imagem com composição colorida R1B3G4 (as bandas 1, 3 e 4 do sensor CCD estão associadas as cores vermelho, azul e verde respectivamente) e composição R4B3G1 foram escolhidas para análise e são representadas nas figuras 36 e 38 respectivamente. A outra imagem multiespectral gerada é mostrada na Figura 37.



Figura 36. Imagem CCD/CBERS-2B em composição colorida (R1B3G4)



Figura 37. Imagem CCD/CBERS-2B em composição colorida (R1G3B4)



Figura 38. Imagem CCD/CBERS-2B em composição colorida (R4G3B1)

A imagem de composição colorida (R1B3G4) foi escolhida na primeira análise, pois ela apresenta uma melhor nitidez na representação da cobertura vegetal, facilitando assim a separação das classes das diferentes variedades de vegetação. Como uma das características mais presentes do município de Floresta é presença de vários tipos de vegetação, a classificação realizada sobre essa composição foi utilizada porque as classes predominantes na imagem são compostas por diferentes vegetações. Todavia, a composição colorida (R4G3B1) também foi usada no processo de classificação da imagem multiespectral na segunda análise, já que esta composição mostrou-se eficiente na visualização entre diferentes tipos de solos. No entanto, a presença da classe do tipo solo não predomina sobre área imageada.

O algoritmo K-Médias foi usado na classificação das imagens multiespectrais de composição colorida (R1B3G4) e (R4G3B1), onde a composição (R1B3G4) foi usada na primeira análise e a de composição (R4G3B1) foi usada na segunda análise. Como parâmetros de entrada foram atribuídos 8 temas com 10 iterações, onde o conjunto de treinamento e de teste das composições coloridas foram os mesmos.

Em relação a classificação do algoritmo K-Médias, mostrada na Figura 39, nota-se através de uma análise qualitativa que o algoritmo obteve um desempenho razoável para ambas as composições, pois classificou corretamente a maioria das nuvens presentes na imagem, do solo e distinguiu bem a diferença entre águas profundas e águas rasas. No entanto, no quesito, tipo de vegetação, o algoritmo não obteve um bom resultado, pois como podem ser visto no resultado da classificação, os diferentes tipos de vegetação presente na área são homogeneizando. O resultado também não foi satisfatório no processo de classificação das nuvens e do solo, pois é possível notar que diferentes tipos de solo foram classificados como nuvens.

Na análise realizada nos dois experimentos sobre as duas composições, não foi possível gerar a matriz de confusão do algoritmo K-Médias, pois o ambiente SPRING só dá suporte a geração das matrizes de confusão dos algoritmos da Máxima Verossimilhança e o baseado na distância Euclidiana.

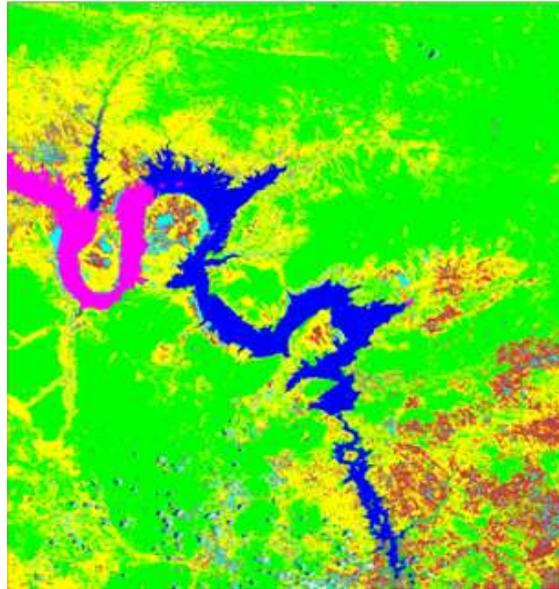


Figura 39.Classificação K-Médias sobre as composições R1B3G4 e R4B1G3

Foi observado também que, com os parâmetros de entrada de 7 temas com 10 iterações, usados no classificador, tanto para a composição R1B3G4 quanto para a R4B1G3, o algoritmo apresentou o mesmo problema em classificar tipos de solo como nuvens, homogeneizou os diferentes tipos de vegetação e o aspecto mais importante é não diferenciação entre águas profundas e águas rasas. Isso mostra a importância na escolha do valor de K clusters, no caso, K igual a 7 temas, usado no processo de classificação.

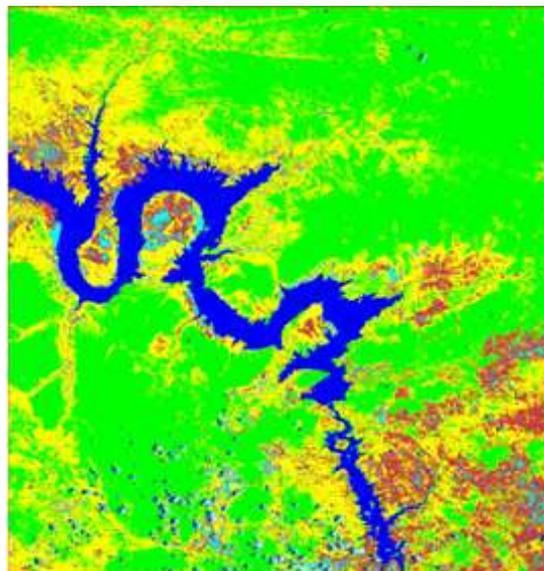


Figura 40.Classificação K-Médias sobre as composições R1B3G4 e R4B1G3

A classificação obtida pelo algoritmo baseado na distância Euclidiana (Figura 41), realizada sobre as composições R1B3G4 e R4B1G3 mostrou-se eficaz, pois foram diferenciadas as classes águas profundas das águas rasas. Houve também uma diferenciação das três classes dos tipos de vegetação. Já a classe solo apresentou muitos *pixels* classificados erroneamente e estes erros são discutidos através da matriz de confusão da distância Euclidiana.

5.4 Conclusões

Dos dois algoritmos supervisionados (Distância Euclidiana e Máxima Verossimilhança) usados na classificação, a Distância Euclidiana apresentou melhor desempenho geral (99,86%) que o algoritmo MAXVER. No entanto o algoritmo Distância Euclidiana apresentou limitações, apresentando uma pior classificação que o MAXVER relacionada às classes Solo e Vegetação 2, já que 75,29% dos *pixels* da classe solo foram classificados erroneamente como vegetação 2. Devido a essa limitação o algoritmo baseado na distância Euclidiana pode apresentar um resultado ruim, apesar de, em média, ter sido melhor resultado que o obtido com a Máxima Verossimilhança.

O desempenho geral do algoritmo MAXVER foi inferior ao da Distância Euclidiana por ser um método de classificação *pixel a pixel*. E como métodos estatísticos precisam de uma grande quantidade de amostras de teste para representar uma classe, isso pode ter influenciado no desempenho do algoritmo MAXVER. No entanto, não foi possível gerar a matriz de confusão do algoritmo de classificação K-Médias, pois o ambiente SPRING não possui essa avaliação de desempenho.

Uma forma importante de análise quantitativa usada na avaliação desempenho dos algoritmos supervisionados foi os estudos de suas respectivas matrizes de confusão, pois a partir dela, foi possível avaliar a exatidão de cada mapeamento.

Para a classificação de áreas mais robustas como: diferentes tipos de solo ou locais urbanos dever ser utilizadas melhores técnicas de aperfeiçoamento e métodos de classificações mais apropriados. Um exemplo de técnicas de aperfeiçoamento seria trabalhar com imagens bem ampliadas de forma a coletar amostras *pixel por pixel*.

5.5 Dificuldades Encontradas

O processo de registro de imagem no ambiente SPRING foi o principal problema, pois uma das imagens (banda 5) do sensor CCD fornecidas pelo INPE (Instituto Nacional de Pesquisas Espaciais) apresentava-se com um erro de deslocamento em relação às demais (quatro bandas restantes). Esse deslocamento ocorre devido à velocidade orbital do satélite ou através do erro do posicionamento do satélite. A solução encontrada foi registrar uma imagem recortada, a partir do programa IMPIMA.

Outra dificuldade deve-se à obtenção das coordenadas geográficas da imagem que vai ser registrada, pois no processo de registro, o programa SPRING faz uso do retângulo envolvente. Nesse retângulo envolvente são inseridas duas coordenadas de referência da imagem. As coordenadas de referências são pontos na superfície da terra mapeados na imagem que será registrada. A solução encontrada foi obter as coordenadas do retângulo envolvente a partir do *homepage* do INPE, pois lá são encontrados os parâmetros das imagens que foram analisadas. No entanto, as coordenadas encontradas no banco de dados do INPE não foram suficientes, já que havia um erro de deslocamento entre a coordenada real e a coordenada inserida no sistema. A solução foi realizar diversos testes, onde vários pontos foram extraídos e testados de forma que as coordenadas do sistema (SPRING) fossem correspondentes às coordenadas dos pontos na superfície.

Capítulo 6

Conclusões e Trabalhos Futuros

O sistema SPRING foi utilizado no processo de classificação das imagens de sensoriamento remoto do município de Floresta. Os algoritmos propostos foram o Máxima Verossimilhança e o baseado na distância Euclidiana, onde as matrizes de confusão de cada um deles foram usadas como parâmetro na avaliação de desempenho. Através dos resultados obtidos nesse processo, conclui-se que apesar do sistema apresentar bons resultados (cerca de 98% de acertos na classificação dos *pixels* de cada classe), o desempenho dos algoritmos poderia ser melhor, já que muitos *pixels* foram classificados de forma errada nas áreas onde não haviam cobertura vegetal. Em relação ao desempenho do K-Médias notou-se que, na medida em que houve um aumento no número de temas de 7 para 8, a classificação dada pelo analista tornou-se mais eficiente porque passou a mostrar as diferenças de profundidade na classe rio.

6.1 Contribuições e Trabalhos Futuros

As ferramentas utilizadas no processamento de imagens estão em constante crescimento. Com isso, os sistemas tornaram-se mais robustos e capazes de processar um maior volume de dados em menos tempo. Um exemplo disso é o uso de sistemas classificadores de imagens de satélites. Seu uso possui extrema importância no controle do desmatamento florestal e do assoreamento dos rios e lagoas, já que foi possível identificar diferentes profundidades. Essa foi principal motivação atribuída para desenvolvimento do projeto. A partir do que foi concluído no trabalho, espera-se que ele tenha contribuído para o desenvolvimento de novos estudos. Um deles poderia ser a implantação de uma técnica de aprimoramento da ferramenta SPRING no processo de obtenção de amostras de testes e aquisição através de uma grande ampliação da imagem em estudo. Isso melhoraria tanto o resultado da classificação, quando facilitaria o manejo de amostras mais precisas pelo usuário. Outra forma de aprimoramento do sistema poderia estar na inserção de um novo algoritmo no SPRING com a tarefa de avaliar o desempenho das classificações obtidas pelos algoritmos já implantados no ambiente.

Bibliografia

- [1] *Introdução ao Sensoriamento Remoto e processamento de Imagens*, Disponível em<
http://www.ufsm.br/petagonomia/apostilas/v1_inpe.pdf> Acesso em: 20 de outubro de 2008.
- [2] ERBERT, M. *Introdução ao Sensoriamento Remoto*. Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul.
- [3] MOREIRA, M. A. *Sistemas Sensores*. Disponível em:
<<http://www.ltid.inpe.br/dsr/mauricio/sensores.pdf> > Acesso em: 20 de agosto de 2008.
- [4] ANJOS, C. S. *Análises de Características Radiométricas e Geométricas de dados CCD/CBERS-2*. Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, INPE - São José dos Campos.
- [5] *INPE (Instituto Nacional de Pesquisas Espaciais)*, Disponível em: <<http://www.inpe.br>> Acesso em: 21 de agosto de 2008.
- [6] ESPOSITO, E. S. C. e KRUG, T. e GREEN, R. O. *Simulação de bandas espectrais das câmaras CCD e WFI (CBRES) geradas a partir das imagens do sensor hiperspectral A VIRIS*, Centro Técnico Espacial.
- [7] KOHONEN, T. The Self-Organizing Map. *Proceeding of the IEEE*, vol. 78, n.9, p 1464-1480. 1990.
- [8] *Mapas Auto-Organizáveis de Kohonen*, Disponível em<ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/lnunes_mest/cap8.pdf> Acesso em: 3 de setembro de 2008.
- [9] *Redes Neurais e Lógica Fuzzy*, Disponível em: <http://www.maxwell.lambda.ele.puc-rio.br/cgi-bin/PRG_0599.EXE/7629_4.pdf > Acesso em: 3 de setembro de 2008.
- [10] KOLOSSOSKI, G. *Segmentação de imagens e algoritmo K-Means*. Trabalho de graduação do curso de Engenharia Elétrica, Universidade Federal do Paraná.

- [11] CROS, A., P. (1992): *Processamento digital de imagens de Sensoriamento Remoto* Campinas, SP, IG/UNICAMP.
- [12] RIBEIRO, S. R. e CENTENO, J. S. *Classificação do Uso do Solo Utilizando Redes Neurais e o algoritmo MAXVER*, Universidade Federal do Paraná.
- [13] BORGES, R. O. e SILVA, R. A. A. e CASTRO, S. S. *Utilização da classificação por Distância Euclidiana no mapeamento de focos de arenização do Setor Sul da alta bacia do Rio Araguaia*, Universidade Federal de Goiás.
- [14] BATISTA, R. E. C. e NEVES, M. F. *SPRING – Sistema de Processamento de Informações Georreferenciada*.
- [15] *Diagnóstico do Município de Floresta*, Disponível em: <www.cprm.gov.br/rehi/atlas/pernambuco/relatorios/FLOR061.pdf> Acesso em: 3 de setembro de 2008.
- [16] *Registro de Imagem*. Disponível em: <<http://www.dpi.inpe.br/SPRING/teoria/aula3.pdf>> Acesso em: 30 de agosto de 2008.