



Jonas Antonio Vieira Junior

Análise comparativa dos métodos de  
classificação de imagem de alta  
resolução para mapeamento da  
cobertura do solo

XIII Curso de Especialização em  
Geoprocessamento  
2011



UFMG  
Instituto de Geociências  
Departamento de Cartografia  
Av. Antônio Carlos, 6627 – Pampulha  
Belo Horizonte  
cartog@igc.ufmg.br

**JONAS ANTONIO VIEIRA JUNIOR**

**ANÁLISE COMPARATIVA DOS MÉTODOS DE CLASSIFICAÇÃO  
DE IMAGENS DE ALTA RESOLUÇÃO PARA MAPEAMENTO  
DA COBERTURA DO SOLO**

Monografia apresentada como requisito parcial à obtenção do grau de Especialista em Geoprocessamento. Curso de Especialização em Geoprocessamento. Departamento de Cartografia. Instituto de Geociências. Universidade Federal de Minas Gerais.

Orientador: Prof.. Marcos Antonio Timbó Elmiro

**BELO HORIZONTE**

**2011**

V657a Vieira Junior, Jonas Antonio.  
2011 Análise comparativa dos métodos de classificação de imagem de alta resolução para mapeamento da cobertura do solo [manuscrito] / Jonas Antonio Vieira Junior. – 2011.  
ix, 32 f. : il. (color.)

Monografia (especialização em Geoprocessamento) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2011.

Orientador: Marcos Antonio Timbó Elmiro.

Bibliografia: f. 31.

Inclui anexo.

1. Sistemas de informação geográfica. 2. Solos. 3. Sensoriamento remoto. I. Elmiro, Marcos Antonio Timbó. II. Universidade Federal de Minas Gerais, Instituto de Geociências. III. Título.

CDU: 528.8

Aluno Jonas Antonio Vieira Junior

Monografia defendida e aprovada em cumprimento ao requisito exigido para obtenção do título de Especialista em Geoprocessamento, em 16 de dezembro de 2011, pela Banca Examinadora constituída pelos professores:

---

Prof. Dr. Marcos Antonio Timbó Elmiro

---

Prof. Bráulio Magalhães Fonseca

## RESUMO

O uso de imagens de satélites de sensoriamento remoto tem sido amplamente aplicado em projetos de mapeamento de uso do solo. Apontada como uma das alternativas viáveis para este tipo de trabalho, a classificação de imagens tem se apresentado como uma técnica de grande contribuição no que diz respeito à otimização de tempo na produção e ao ganho de qualidade dos produtos cartográficos. Nesse contexto, o objetivo desse trabalho é comparar os resultados da classificação supervisionada de imagens do satélite SPOT 5 com resolução espacial de 2,5 metros, da região de São Félix do Xingu/PA a partir de três métodos de classificação: Máxima Verossimilhança (MaxVer), Distância de Bhattacharya e Orientada a Objetos. Após realizado o pré-processamento, as correções geométricas e correções radiométricas na imagem, passou-se à coleta de amostras das classes de mapeamento do uso do solo, tais como: solo exposto/uso agropecuário, formação florestal, áreas de pousio, corpos d'água e afloramento rochoso. Nas etapas seguintes, realizou-se a avaliação da amostragem das classes utilizando o coeficiente Kappa, calculado manualmente para cada resultado da classificação. Deste modo, a classificação proveniente do algoritmo de Máxima Verossimilhança alcançou 0,636 no índice Kappa, seguido pela Distância de Bhattacharyya com 0,717 e Orientada a Objetos em torno de 0,741. Observou-se que o método MaxVer apresentou uma série de ruídos em todas as classes e confusão entre classes afloramento e solo exposto. O resultado obtido com o classificador Distância de Bhattacharyya manteve melhor consistência nas áreas próximas das amostras de treinamento, porém superestimou a existência de classes em regiões não amostradas. Finalmente, o algoritmo de classificação Orientada a Objetos representou melhor a informação extraída, visto a baixa confusão e a facilidade de correção na etapa pós-classificação.

## SUMÁRIO

	<u>Pág.</u>
LISTA DE FIGURAS .....	vii
LISTA DE TABELAS .....	viii
LISTA DE SIGLAS E ABREVIATURAS .....	ix
1- INTRODUÇÃO .....	10
1.1 - Apresentação.....	10
1.2 – Objetivos .....	11
2 – FUNDAMENTAÇÃO TEÓRICA .....	11
2.1 – Sensoriamento Remoto .....	12
2.2 – Processamento Digital de Imagens .....	14
2.3 – Métodos de classificação de imagens de satélite .....	15
2.3.1 – Máxima Verossimilhança.....	17
2.3.2 – Distância de Bhattacharyya .....	18
2.3.3 – Orientada a Objetos.....	19
2.4 – Índice Kappa .....	20
3 – MATERIAIS E MÉTODOS .....	21
3.1 – Caracterização da área de estudo .....	22
3.2 – Aquisição e tratamento dos dados.....	23
3.3 – Elaboração da chave de interpretação e aplicação dos métodos de classificação .....	24
4 – RESULTADOS E DISCUSSÕES .....	25
4.1 – Comparação dos resultados obtidos dos diferentes métodos .....	26
4.2 – O índice Kappa na avaliação do desempenho dos classificadores.....	29
5 – CONCLUSÕES E CONSIDERAÇÕES FINAIS .....	30
REFERÊNCIAS BIBLIOGRÁFICAS .....	31
ANEXO 1 – CHAVE DE INTERPRETAÇÃO .....	32

## LISTA DE FIGURAS

	<u>Pág.</u>
1 – Diagrama metodológico .....	22
2 – Mapa de localização da área de estudos.....	23
3 – Mapa de referência de cobertura do solo .....	26
4 – Classificação da cobertura do solo: Máxima Verossimilhança.....	27
5 – Classificação da cobertura do solo: Distância de Bhattacharya.....	28
6 – Classificação da cobertura do solo: Orientada a Objetos.....	29

## LISTA DE TABELAS

	<u>Pág.</u>
1 - Características do satélite SPOT 5.....	14
2 - Avaliação pelo índice Kappa .....	21
3 - Chave de interpretação sintetizada.....	24
4 - Desempenho dos classificadores no índice Kappa .....	29



## LISTA DE SIGLAS E ABREVIATURAS

PDI	- Processamento Digital de Imagens
SERE	- Sensoriamento Remoto
REM	- Radiação eletromagnética
MaxVer	- Algoritmo de classificação de Máxima Verossimilhança
SPRING	- Sistema de Processamento de Informações Georreferenciadas
SPOT	- Système Probatoire d'Observation de la Terre
ONR	- Office Naval Research
DN	- Digital Number
MTF	- Função de transferência de modulação
IFOV	- Campo de visada instantâneo
Pixel	- Picture element
UTM	- Universal Transversa de Mercator
WGS84	- World Geodetic System 1984 (Sistema Geodésico Mundial de 1984)
SIG	- Sistema de Informação Geográfico
INPE	- Instituto Nacional de Pesquisas Espaciais

# **1 - INTRODUÇÃO**

## **1.1 Apresentação**

Desde sua origem, o homem interfere de várias maneiras no espaço geográfico. Sua atuação nesse meio se deu de diferentes formas ao longo de sua história. Entretanto, o conhecimento do território sempre foi um diferencial na tomada de decisão, de modo a potencializar ao máximo o uso das características e recursos de cada região.

Nessa perspectiva, pode-se inferir que o conhecimento do território está assentado na qualidade e diversidade de informações que se tem acerca do mesmo. Conseqüentemente, faz-se necessário assegurar a veracidade e consistência de tais informações. Igualmente importante, deve-se verificar a representatividade das informações na realidade de intervenção, avaliando a variação temporal entre o dado que se tem em mãos e a realidade a ser analisada.

Atualmente, os avanços tecnológicos favoreceram o surgimento e o aperfeiçoamento de diversas técnicas de coleta de dados. Dentre os vários métodos de obtenção de dados e informações acerca do espaço geográfico, o Sensoriamento Remoto (SERE) tem apresentado elevado potencial na aquisição de grandes volumes de dados georreferenciados em diferentes escalas através de imagens.

Além disso, as características dos produtos em SERE – dados atuais, contínuos e em grande escala sobre a superfície terrestre em formato matricial – impulsionaram seu uso e difusão em vários estudos, tais como no monitoramento dos processos da hidrosfera, no planejamento e gestão urbana, na cartografia, nos estudos florestais, na geologia e na agricultura (NOVO, 2008).

Todavia, estes dados carecem de várias etapas de processamento e manipulação inerentes aos métodos de extração de informações. Se tratando de imagens de satélites, as etapas pertinentes ao tratamento e manipulação estão incluídas no Processamento Digital de Imagens (PDI). O principal método para extração de informações em imagens de satélites é a classificação.

Considerando as características das informações necessárias ao processo de tomada de decisões, atualmente o SERE disponibiliza imagens com alto nível de detalhamento (alta

resolução espacial) capazes de atender diferentes demandas. Em função das características dessas imagens, seu processamento é composto por várias fases e merece atenção especial. As técnicas de classificação de imagens de satélite possuem grande potencial para extração de informações, portanto é importante analisar a confiabilidade da informação obtida via diferentes métodos de classificação em imagens de alta resolução.

Nesse contexto, o vínculo profissional à empresa TerraVision Geotecnologia e Geoinformação possibilitou a oportunidade de desenvolvimento deste trabalho, tendo em vista a similaridade do estudo com outros projetos realizados pela empresa. Assim, foram analisados os métodos de classificação por Máxima Verossimilhança (MaxVer), Distância de Bhattacharya e Orientado a Objetos, disponíveis nos softwares SPRING e ENVI. A aplicação destes métodos foi validada em um recorte de uma cena do satélite SPOT 5 usando 3 bandas com resolução espacial de 2,5m.

## **1.2 Objetivos**

O objetivo geral deste estudo é analisar a confiabilidade da informação extraída de imagens do satélite SPOT 5 bandas 3, 2 e 1 de resolução 2,5m para mapeamento de uso e cobertura do solo por meio da comparação de três métodos de classificação: Máxima Verossimilhança (MaxVer), Distância de Bhattacharya e Orientado a Objetos.

Os objetivos específicos são:

- Delimitar a área de estudos com as classes de interesse;
- Realizar as etapas de Processamento Digital de imagens na área escolhida;
- Aplicar os métodos de classificação na cena definida;
- Comparar os resultados obtidos em cada método por meio de métodos estatísticos e validação de campo.

## **2 - FUNDAMENTAÇÃO TEÓRICA**

Nesta seção é feita uma breve descrição da base teórica e dos conceitos gerais relacionados ao Sensoriamento Remoto, Processamento Digital de Imagens e os Métodos de Classificação empregados nesta pesquisa.

## 2.1 – Sensoriamento Remoto

Os primeiros indícios que marcam o surgimento do Sensoriamento Remoto apontam para o desenvolvimento da fotografia e à pesquisa espacial (NOVO, 2008). De modo simultâneo ao desenvolvimento da aviação, os avanços nos estudos da ótica impulsionaram o uso e difusão das fotografias aéreas. Posteriormente, os esforços empregados nas duas grandes guerras mundiais surtiram em investimentos nessa área. Logo, foram desenvolvidos estudos sobre o comportamento dos alvos na região do infravermelho, de modo a detectar inimigos camuflados (NOVO, 2008).

Com o fim da guerra, essa tecnologia ficou disponível para uso civil e seu uso foi direcionado aos recursos naturais. Assim, o aporte tecnológico permitiu a expansão dos sistemas de sensoriamento remoto baseados em satélites e não mais somente em aviões. Tais características induziram um conjunto de avanços nos diversos campos do conhecimento (NOVO, 2008).

Atualmente, existe uma grande variedade de sistemas de satélites com sensores que permitem analisar alvos em diferentes escalas e características, direcionados aos estudos em áreas urbanas, agrícolas, geológicas, ecológicas, florestais, cartográficas, oceanográficas, hidrológicas e muitas outras (NOVO, 2008).

Apesar da variedade de aplicações e uso consolidado em diversos campos da ciência, existem várias definições para o termo Sensoriamento Remoto. O conceito apresentado por Lillesand et. al (2008) definem Sensoriamento Remoto como:

Sensoriamento Remoto é a ciência e arte de obter informação sobre um objeto, área ou fenômeno através de dados adquiridos por um sensor que não está em contato com o objeto, área ou fenômeno estudado” (LILLESAND, KIEFER, & CHIPMAN, 2008)

Sensores são equipamentos que possuem a características de captar variações no que diz respeito à quantidade ou propriedade da Radiação Eletromagnética (REM) em diferentes faixas do espectro eletromagnético (bandas dos satélites ou resolução espectral). Como observa Jensen (2009), outros tipos de campos de força podem substituir a REM. Porém, a maioria dos dados de SERE advém de sensores que registram a REM, visto sua velocidade de deslocamento e sensibilidade para os recursos naturais. Assim, o SERE multiespectral somente é possível em função da interação da REM com os alvos na superfície terrestre.

Com isso, pode-se ressaltar que existem erros intrínsecos a trajetória da energia, ao posicionamento do satélite e ao próprio sensor (RICHARDS & JIA, 2005). Além disso, ao se trabalhar com dados de SERE deve-se ter em mente que a REM é utilizada “como um substituto da propriedade real sob investigação” (JENSEN, 2009).

Além disso, a sensibilidade que a REM apresenta ao interagir com alvos de diferentes composições (vegetação, solo, água, edificações, entre outros) torna possível o registro da variação da reflectância de cada objeto para as faixas do espectro eletromagnético. Tal processo configura a criação de “assinaturas espectrais” dos alvos, observado também como “comportamento espectral dos alvos” (JENSEN, 2009; NOVO, 2008).

Após captar a energia refletida, emitida ou retroespalhada pelos alvos contidos no campo de varredura do satélite, o sensor a registra como um sinal elétrico e o armazena como valor digital numa matriz, constituindo assim uma imagem. Durante essa conversão analógico-digital o sensor cria valores digitais entre 8 e 12 bits, chamado de nível de quantização do dado ou resolução radiométrica. Cada valor digital contido na imagem está associado a um pixel (*picture element*) que pode ser definido como “(...) um elemento de cena bidimensional que constitui o menor elemento não-divisível de uma imagem digital” (JENSEN, 2009). Deste modo, cada pixel possui um valor de brilho, também conhecido como número digital (DN, *digital number*). Este valor, por sua vez, varia segundo a quantização do dado, seja de 0 a 255 (8 bits,  $2^8$ ) ou de 0 a 1023 (10 bits,  $2^{10}$ ).

Nessa perspectiva, o pixel representa uma porção da superfície terrestre que sofreu varredura pelo sensor. Logo, pode-se afirmar que “há uma relação entre o tamanho de um objeto ou área a ser identificada e a resolução espacial de um sistema de sensoriamento remoto” (JENSEN, 2009). Deste modo, acredita-se que o sensor possua resolução espacial. A imagem, produto dos processos de coleta de dados do sensor, somente pode ter sua resolução espacial através do cálculo da sua função de transferência de modulação (MTF). Entretanto, muitos sistemas em SERE possuem um campo de visada instantâneo (IFOV) constante. Assim, para estes casos, “a resolução espacial nominal é definida como a dimensão em metros do IFOV projetado no terreno” (JENSEN, 2009).

Concebido como sistema de fornecimento de imagens para fins comerciais, o sistema de sensores SPOT está em sua quinta geração de satélites. Lançado em maio de 2002, o satélite SPOT 5 possui as seguintes características, observadas na Tabela 1

**Tabela 1 - Características do satélite SPOT 5**

<b>Bandas</b>	<b>Resolução espectral (<math>\mu\text{m}</math>)</b>	<b>Resolução radiométrica (bits)</b>	<b>Resolução espacial (m)</b>
Pancromática	0,48 – 0,71	8	2,5 / 5
B1: Verde	0,50 – 0,59	8	10
B2: Vermelho	0,61 – 0,68	8	10
B3: Infravermelho próximo (NIR)	0,78 – 0,89	8	10
B4: Infravermelho médio (MIR)	1,58 – 1,75	8	20

*Adaptado de NOVO, 2008.*

Devido a tais características é possível gerar cenas de alta resolução espacial (2,5m) coloridas e com período de revisita de 26 dias (resolução temporal). Deste modo, o sensor consegue cenas de 60 a 80 km de faixa imageada.

## **2.2 – Processamento Digital de Imagens**

As cenas originais coletadas pelos sensores possuem erros de diversas origens (NOVO, 2008). Tais erros interferem na identificação dos elementos presentes na região de coleta do satélite e, conseqüentemente, dificultam as atividades de interpretação da cobertura do solo.

De modo a mitigar a influência destes erros na cena coletada, são realizados alguns procedimentos de manipulação nas características das imagens. O conjunto de etapas e processos incluídos nesses procedimentos consiste no Processamento Digital de Imagens (PDI).

Jensen (2009) aponta que as técnicas de PDI “(...) buscam detectar e identificar fenômenos importantes em uma cena”, de modo a torna-la visualmente melhor. Assim, pode-se afirmar que, num primeiro momento, estas técnicas estão inseridas no conjunto de ferramentas de análise dos dados de SERE. Isso porque, ao melhorar possibilidade de interpretação destes dados, os mesmos serão medidos e a informação será usada na solução de problemas (JENSEN, 2009).

Em uma abordagem mais detalhada, Jensen (2009) define que os objetivos do PDI são:

- Melhorar a qualidade geométrica e radiométrica dos dados brutos;

- Melhorar a aparência visual das imagens para facilitar a interpretação visual, realçando as feições de interesse;
- Automatizar certos procedimentos de extração de informações;
- Permitir a integração de dados de diferentes fontes;
- Facilitar o desenvolvimento de modelos e a geração de produtos que representem a grandeza de interesse do usuário, a informação.

Para alcançar estes objetivos, são necessárias uma série de etapas características do PDI, tais como: pré-processamento (correção geométrica e radiométricas); técnicas de manipulação do histograma para melhorar a visualização dos alvos (realce, equalização, análise de componentes principais - ACP); reconhecimento de padrões usando estatísticas inferenciais; processamento fotogramétrico via estereoscopia, sistemas especialistas (árvore de decisão) e análise de imagens usando redes neurais; análise de dados hiperespectrais, detecção de mudanças e classificação de imagens (NOVO, 2008; LILLESAND, KIEFER, & CHIPMAN, 2008; JENSEN, 2009).

O PDI caracteriza-se pelo o uso de técnicas matemáticas complexas aliadas ao conhecimento do objeto de estudo. Porém, apesar de sua complexidade, o PDI também faz uso de algumas técnicas básicas e analógicas inerentes ao processo de interpretação de imagens. Logo, estes processos são empregados de modo complementar, o que otimiza o processo de extração de informações das imagens.

### **2.3 – Métodos de classificação de imagens de satélite**

Dentre as técnicas de extração de informações de dados orbitais, a classificação de imagens se apresenta como um diferencial. Isso porque, “(...) o principal objetivo dos procedimentos de classificação de imagens é classificar automaticamente todos os pixels de uma imagem em classes ou temas de cobertura do solo” (LILLESAND, KIEFER, & CHIPMAN, 2008). Neste sentido, o uso de métodos estatísticos vinculados à busca de padrões espaciais e outras técnicas favorecem a automação do processo de extração de informações, além do ganho de qualidade e precisão observado nos resultados.

A classificação de imagens pode ser definida em várias perspectivas, das quais apresentaremos apenas as utilizadas nessa pesquisa. A primeira abordagem busca o reconhecimento de padrões através do princípio de que “(...) diferentes feições manifestam diferentes combinações de DN baseados em sua reflectância espectral inerente e propriedades de emitância” (LILLESAND, KIEFER, & CHIPMAN, 2008). Assim, o fundamento deste processo refere-se a um conjunto de medições de radiância obtidas em diferentes faixas do espectro eletromagnético, ou seja, bandas dos satélites. A este processo denomina-se padrão de reconhecimento espectral, pois utiliza informações espectrais pixel-a-pixel baseado em técnicas automáticas para classificar a cobertura do solo. (LILLESAND, KIEFER, & CHIPMAN, 2008).

Outro procedimento de classificação de imagens encontrado na literatura diz respeito ao reconhecimento de padrões espaciais. Segundo Lillesand, Kiefer e Chipman (2008), essa metodologia agrega a classificação dos pixels da imagem baseado no relacionamento espacial com seus vizinhos. Nessa perspectiva, os classificadores com essa concepção devem considerar aspectos como textura, proximidade, tamanho, forma, direção, repetição (frequência) e contexto (LILLESAND, KIEFER, & CHIPMAN, 2008). Estes classificadores se aproximam da análise cognitiva realizada durante o processo de interpretação de imagens. Portanto, tendem a ser muito mais complexos e intensos em termos de processamento computacional que os procedimentos de reconhecimento de padrão espectral.

Uma terceira alternativa encontrada na bibliografia menciona o uso combinado dos dois métodos citados anteriormente, caracterizando a classificação orientada a objetos (LILLESAND, KIEFER, & CHIPMAN, 2008). Neste caso, os autores apontam para a dificuldade de limiares e modelos para classificação e ressaltam que, como neste caso, deve-se considerar cada caso como um evento particular, no qual o uso deste método caracteriza um estudo criterioso de todas as etapas do processo.

Apesar das peculiaridades de cada uma dessas linhas de classificação de imagens, deve-se ressaltar que a primeira etapa do procedimento de classificação consiste na fase de treinamento (SCHOWENGERDT, 1983). Deste modo, obtém-se duas vertentes de trabalho para o processo de classificação. Na primeira, denominada método de classificação supervisionada, “o analista utiliza seu conhecimento à priori derivado da pesquisa de



campo, fotointerpretação, e outras fontes, em pequenas regiões da imagem a ser classificada para identificar aqueles pixels que pertencem a classe de interesse” (SCHOWENGERDT, 1983). Deste modo, o analista coleta amostras que vão “treinar” o algoritmo de classificação a buscar em toda a imagem alvos semelhantes. Para o segundo caso, o treinamento não-supervisionado, o analista emprega a um algoritmo computacional a tarefa de localizar áreas heterogêneas na imagem. Feito isso, o próprio analista vai identificar e designar a qual classe pertence as regiões delimitadas pelo algoritmo.

### 2.3.1 – Máxima Verossimilhança

Dentre os algoritmos de classificação encontrados na literatura, pode-se afirmar que alguns tem sido utilizado com maior frequência. O classificador de Máxima Verossimilhança (MaxVer), como nos informa Schowengerdt (1983), também encontrado como *maximum-likelihood*, tem se mostrado eficiente em vários casos de classificação de imagens por método de padrão de reconhecimento espectral. A título de comparação entre os algoritmos de Paralelepípedo e MaxVer para classificação de pixels presente no limiar entre duas classes – exatamente onde ocorre maior confusão de classes e, como consequência, erros na classificação – o MaxVer demonstrou melhor desempenho, visto o ganho de tempo de processamento, a classificação de regiões ambíguas com o acréscimo de apenas dois ou três por cento de erro em cada classe. Apesar de o método Paralelepípedo apresentar o mesmo tempo de processamento, este não conseguiu resolver a questão da ambiguidade de classes para os pixels durante a classificação (SCHOWENGERDT, 1983).

Segundo Tso e Mather (2001), a equação reduzida do algoritmo de classificação MaxVer é dada por:

$$-\ln[P(x_i|w_i)] = \ln|C_i| + (x_i - \mu_i)^T \cdot C_i^{-1} \cdot (x_i - \mu_i), \quad (1)$$

Onde  $x$  e  $w$  são chamados “eventos”,  $P$  é a probabilidade de coexistência ou interseção destes eventos,  $C$  é a matriz de covariância da classe  $w_i$ ,  $\mu_i$  é o vetor médio para a classe  $w_i$  e  $\cdot$  é o determinante da equação (TSO, MATHER, 2001).

Alguns autores afirmam que este algoritmo “(...) avalia quantitativamente a variância e covariância dos padrões de resposta espectral de cada classe durante a classificação de um pixel desconhecido (LILLESAND, KIEFER, & CHIPMAN, 2008). Com base nisso, o

algoritmo MaxVer assume que o conjunto de amostras de treinamento de determinada categoria apresenta distribuição gaussiana (distribuição normal – geralmente comum em distribuições de respostas espectrais). Feito isso, a distribuição do padrão de resposta de uma classe pode ser completamente descrito pelo vetor médio e pela matriz de covariância. Deste modo, pode-se calcular a probabilidade de um dado pixel pertencer a uma classe de cobertura do solo. Tal função é denominada função de densidade probabilística, a qual “(...) é utilizada para classificar um pixel não identificados através cálculo de probabilidade do valor do pixel pertencente a cada classe” (LILLESAND, KIEFER, & CHIPMAN, 2008).

De modo geral, o computador vai calcular o valor de determinado pixel e avaliar suas características para determinar sua classe, com base na distribuição da mesma. Todavia, após este procedimento inicial, o algoritmo de máxima verossimilhança vai analisar o contexto espacial em que este pixel está inserido, ou seja, seus vizinhos. A partir disso, é realizado o cálculo de probabilidade e o pixel pode ser classificado como outra classe adjacente ou não classificado. Existem ainda outras adaptações deste classificador, como o algoritmo Bayesiano de Máxima Verossimilhança. Porém, não são foco desta pesquisa.

### **2.3.2 – Distância de Bhattacharyya**

O algoritmo de classificação Distância de Bhattacharyya é utilizado para “(...) medir a separabilidade estatística de um par de classes espectrais” (SPRING, 2011). O princípio de aplicação deste método é análogo ao Isoseg, no qual são classificadas regiões de uma imagem segmentada.

Tal algoritmo é caracterizado por efetuar o agrupamento de dados não-supervisionado, aplicado sobre regiões descritas através de parâmetros estatísticos (média, matriz de covariância e área). Nestes casos, o analista define o limiar de aceitação para o agrupamento, “(...) de forma que todas regiões pertencentes a uma dada classe estão distantes da classe por uma distância inferior a esta” (SPRING, 2011). Assim, pode-se deduzir que o limiar e a distância entre as classes são inversamente proporcionais ao número de classes agrupadas.

Entretanto, o algoritmo de Distância de Bhattacharyya, diferente do Isoseg, demanda intervenção do analista na tarefa de treinamento por regiões. O processo realizado consiste

na definição de regiões por meio da segmentação de imagens e as regiões oriundas desta técnica são utilizadas como amostras no processo de treinamento do algoritmo.

Num estudo comparativo com enfoque no algoritmo de Distância Mínima, Wacker e Landgrebe (1972) demonstram que dentre os algoritmos de distância baseados em probabilidade, o de Distância de Bhattacharyya se destaca. Assim, afirmam que “(...) a principal razão para isso é, aparentemente, a estreita relação entre a probabilidade de erro e a Distância de Bhattacharyya, bem como o cálculo relativamente fácil da Distância de Bhattacharyya em problemas teóricos” (WACKER, LANDGREBE, 1972).

Conceitualmente, a formulação matemática para o algoritmo de Distância de Bhattacharyya é dada por:

$$B(P_i, P_j) = \frac{1}{2} (m_1 - m_2)^T \sum (m_i - m_j) + \frac{1}{2} \ln \frac{|\sum (m_i - m_j)|}{|\sum i|^{\frac{1}{2}} |\sum j|^{\frac{1}{2}}}, \quad (2)$$

Onde B é a distância de Bhattacharyya; Pi e Pj são pixels nas classes i e j; mi e mj são as médias das classes i e j, T é a matriz transposta, ln é o logaritmo neperiano, e i e j são classes dentro do contexto (MOREIRA et al., 2009).

Atualmente, assim como ocorrem adaptações no método MaxVer, alguns autores desenvolveram trabalhos de aprimoramento do algoritmo de Distância de Bhattacharyya. Chulhee Lee (2003) empregou a equação deste algoritmo para mitigar os erros de estimação recorrentes durante o processo de classificação.

### 2.3.3 – Orientada a Objetos

Ao contrário dos algoritmos apresentados anteriormente, a classificação Orientada a Objetos utiliza padrões de reconhecimento espectral e espacial.

A premissa deste método tem como fundamento duas etapas. Na primeira, a imagem é segmentada em objetos discretos. Na segunda, é realizada a classificação destes objetos. Este método parte do princípio de que a imagem é composta por manchas homogêneas (objetos) que são maiores que um único pixel. Embora apresente duas etapas, essa alternativa de classificação assemelha-se a interpretação visual de imagens digitais, pois trabalha com múltiplas escalas de trabalho, utiliza cores, forma, tamanho, textura, padrão e

informação de contexto para agrupar pixels em objetos com alguma representatividade (LILLESAND, KIEFER, & CHIPMAN, 2008).

Deste modo, a escala dos objetos gerados através da imagem é fundamental para o mapeamento. Isso porque todos os demais processos dependem desta etapa. Logo, se a segmentação atende o pressuposto para o mapeamento, acredita-se que os demais procedimentos serão menos onerosos em termos de tempo e qualidade da informação. Todavia, não existe modelo ideal para a segmentação. Esta, por sua vez, depende claramente de uma série de fatores, tais como a resolução do sensor que capturou a imagem e a escala aproximada das feições reconhecidas na paisagem que o analista busca identificar (LILLESAND, KIEFER, & CHIPMAN, 2008).

Uma vez que a imagem tenha sido segmentada, são oferecidas algumas características que podem ser utilizadas para classificar os objetos. Estas informações podem ser divididas em dois grupos: aquele relacionado intrinsecamente a um único objeto e outras que buscam descrever o relacionamento entre os objetos. Acerca de um único objeto, pode-se obter as propriedades espectrais, sua textura, forma e outros parâmetros. Ao analisar seu relacionamento com os demais objetos, observa-se algumas propriedades espaciais, tais como conectividade, proximidade a objetos semelhantes ou de diferentes características, e outros mais (LILLESAND, KIEFER, & CHIPMAN, 2008).

Além disso, a análise orientada a objetos pode servir de aporte para o mapeamento da mudança da cobertura terrestre, visto a relação espacial que mantém entre objetos. Por exemplo, um objeto que representa cobertura vegetal natural numa determinada época pode ser desmembrado num outro período em caso de intervenção (desmatamento) nessa mesma área. Logo, poder-se-ia observar a variação de classes da região em função da mudança na paisagem.

#### **2.4 – Índice Kappa**

Ao comparar diferentes métodos de classificação de imagens de alta resolução, torna-se necessário avaliar de modo científico o desempenho de cada um. Deste modo, deve-se obter um dado referência e, a partir deste, analisar os resultados obtidos por meio destes métodos para cada mapa (JENSEN, 1996).

De posse do dado de referência, neste caso o mapa de referência, faz-se necessário escolher um método para comparar os resultados. Assim, o índice de exatidão Kappa tem sido utilizado por vários autores em diferentes áreas do conhecimento. Congalton (1991) citado por MOREIRA et. al (2009), aponta que:

“(...) o uso do coeficiente kappa (K) é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, por exemplo, que utiliza somente os elementos diagonais (concordância real).”

Deste modo, obtém-se a exatidão global a partir da divisão da soma dos elementos da diagonal da matriz pelo universo de amostragem. O cálculo é dado pela seguinte fórmula:

$$K = \frac{X \sum_{i=1}^r X_{ii} - \sum_{i=1}^r X_i + X + i}{X^2 - \sum_{i=1}^r X_i + X + i} \quad (3)$$

Onde x é o elemento da matriz de erros; R é o número de categorias presentes na matriz de erros; Xii é o elemento da diagonal principal; Xi é o total da linha para uma dada categoria informacional; e X + i é o total da coluna para uma dada categoria informacional (MOREIRA et. al, 2009).

Finalmente, Congalton e Green (1998) citados por Moreira et. al (2009) indicam que as classificações em SERE podem ser avaliadas conforme a Tabela 2.

**Tabela 2 - Avaliação pelo índice Kappa**

ÍNDICE KAPPA (K)	AVALIAÇÃO DA CLASSIFICAÇÃO
$K \leq 0,4$	Pobre
$0,4 < K \leq 0,8$	Razoável
$K \geq 0,8$	Excelente

### 3 - MATERIAIS E MÉTODOS

A Figura 1 apresenta a estrutura geral das etapas de trabalho proposta para esta pesquisa. Cada tópico observado no diagrama será brevemente abordado nesta seção, de modo a esclarecer e justificar sua implementação.

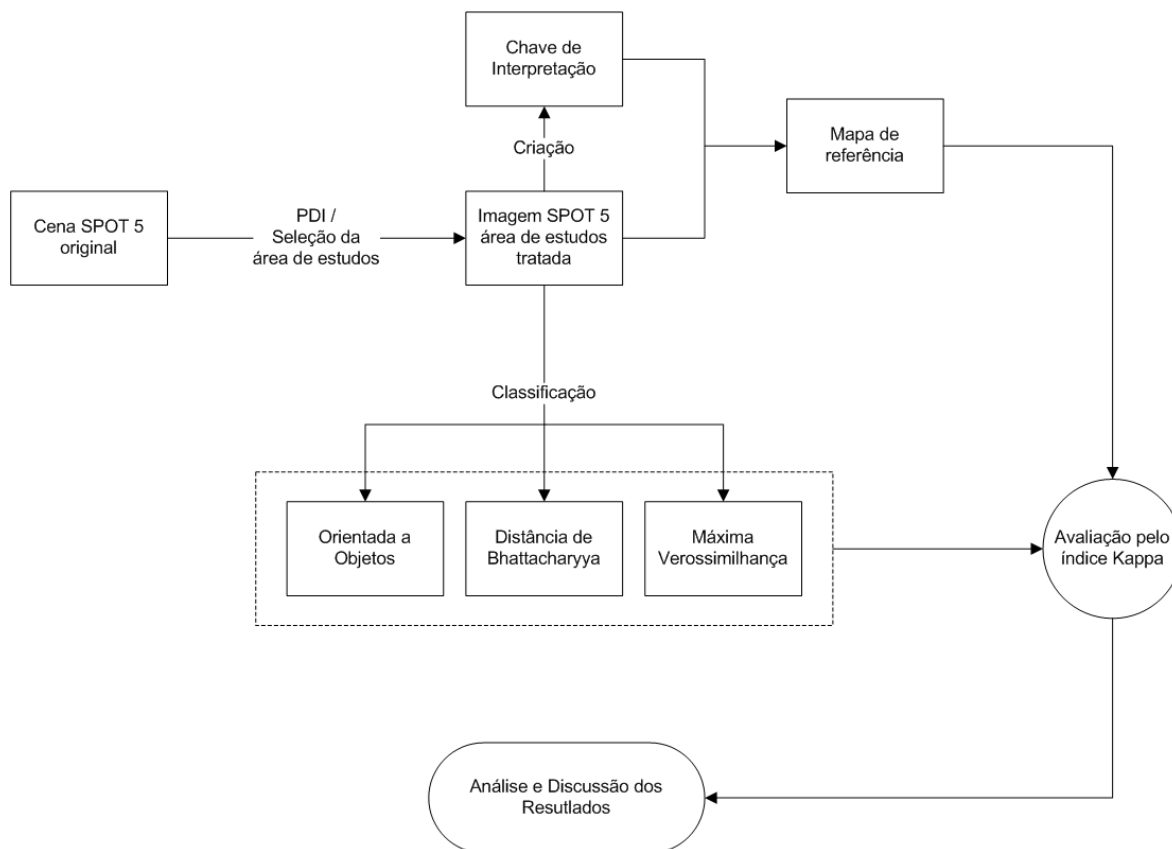


Figura 1 – Diagrama metodológico

### 3.1 Caracterização da área de estudo

A área de estudos compreende parte de uma cena do satélite SPOT 5, situada próxima a sede do município de São Félix do Xingu no estado do Pará (Figura 2). O principal critério para escolha deste recorte se deu em função da ocorrência das classes de interesse para mapeamento da cobertura do solo.

Embora tal região seja considerada favorável para o estudo em questão, sua escolha foi favorecida, também, pela intensa dinâmica de uso da terra. Como se pode observar, o próprio contexto regional influencia tal dinamismo.

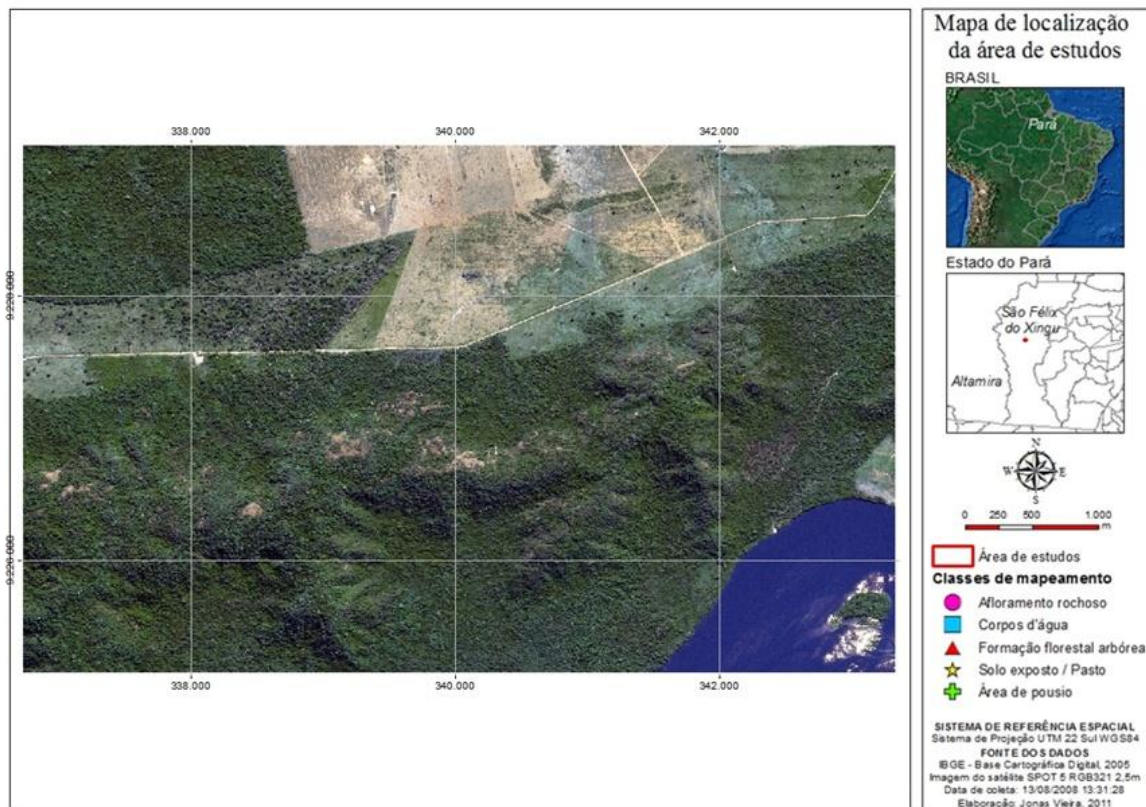


Figura 2: Mapa de localização da área de estudos

### 3.2 – Aquisição e tratamento dos dados

Para o desenvolvimento desta pesquisa foram necessários os seguintes dados:

- Cena 697-364 do satélite SPOT 5, composição RGB321, 2,5m de resolução espacial do sensor, coletada em 13 de julho de 2008, cedida pela empresa TerraVision Geotecnologia e Geoinformação;
- Limite municipal obtido juntamente ao IBGE;
- Chave de interpretação, elaborada no desenvolvimento desta pesquisa e baseada em alguns conceitos do manual de uso da terra, publicado pelo IBGE;
- Mapa de referência, construído com base na chave de interpretação, também desenvolvido ao longo da pesquisa;
- Pontos de coleta de amostras registradas por meio de fotografias em campo, observando a realidade de cada classe mapeada; e
- Mapa de uso e cobertura do solo, realizada anteriormente ao período de aquisição da cena para verificar o padrão das classes de mapeamento.

Todos estes dados foram reprojatados para o sistema de projeção UTM (Universal Transversa de Mercator), fuso 22, hemisfério sul e datum WGS84 (World Geodetic System 1984 – Sistema Geodésico Mundial de 1984).

Inicialmente, o tratamento dos dados consistiu nas etapas de PDI, as quais permitiram atenuar os erros encontrados nas imagens. De posse da imagem, observou-se ser necessário realizar reprojeção, de modo a padronizar o sistema de referência espacial adotado na pesquisa; recorte da área de estudos; e emprego de técnicas de manipulação do histograma das bandas da imagem, possibilitando melhor contraste dos elementos pertinentes a cada classe de mapeamento.

Cabe ressaltar que, visto os objetivos desta pesquisa, não foram aplicadas técnicas de suavização e melhorias no que diz respeito à visualização das informações obtidas por meio dos algoritmos de classificação. Deste modo, obtém-se o produto bruto dos diferentes classificadores empregados na mesma área e com mesmo padrão de amostras na etapa de treinamento.

### **3.3 – Elaboração da chave de interpretação e aplicação dos métodos de classificação**

Após um estudo interpretativo da cena mencionada anteriormente, foram definidas as seguintes classes de mapeamento de cobertura do solo (Tabela 3):

**Tabela 3 - Chave de interpretação sintetizada**

<b>CLASSE</b>	<b>DESCRIÇÃO</b>
Formação florestal arbórea	Caracterizada por florestas e fragmentos florestais arbóreos naturais ou regenerados após intervenção antrópica.
Corpos d'água	Caracterizado por rios, lagos e demais corpos d'água encontrados na imagem.
Afloramento Rochoso	Caracterizado pela presença de rochas em ambiente natural e antropizado, observado em amostras de campo.
Áreas de pousio	Também consideradas áreas de regeneração, são áreas caracterizadas pelo desenvolvimento da vegetação natural em locais cuja intervenção antrópica ocorreu por meio do desmate.
Solo exposto	Caracterizado por regiões em que observa-se solo exposto, áreas desmatadas, bancos de areia ao longo dos rios, pasto sujo e uso possivelmente agropecuário.



A versão completa desta chave de interpretação pode ser observada no Anexo 1. De posse da chave, tornou-se possível a elaboração do mapa de referência. Tal mapa foi criado a partir da vetorização das classes observadas na área de estudos e teve como propósito servir de referência para avaliação do desempenho dos classificadores.

A aplicação dos métodos de classificação escolhidos se deu em diferentes softwares. Para o mapeamento da cobertura do solo através do método de Máxima Verossimilhança foi utilizado o software ENVI 4.8. O produto obtido por meio do algoritmo de Distância de Bhattacharyya foi desenvolvido no SIG (Sistema de Informação Geográfica) SPRING 5.1.8, produzido pelo INPE (Instituto Nacional de Pesquisas Espaciais). Finalmente, a classificação por meio da técnica Orientada a Objeto foi realizada no software eCognition 8.

Cabe ressaltar que a etapa de treinamento, inerente a qualquer processo de classificação supervisionada, se deu em áreas semelhantes respeitando as características de cada método abordado.

O processo de avaliação destes produtos se deu em função do uso do índice Kappa para as classes resultantes e as classes observadas no mapa de referência. Logo, obtém-se um valor global de precisão para cada resultado. Assim, torna-se possível realizar uma análise comparativa entre tais produtos.

#### **4 - RESULTADOS E DISCUSSÕES**

Nesta seção são apresentados os resultados obtidos por meio da aplicação dos métodos abordados. Para isso, foram elaborados três mapas para a área escolhida, a discussão e análise a respeito dos métodos de classificação e, finalmente, a avaliação de desempenho global através do índice Kappa.

Deste modo, o primeiro resultado desta pesquisa pode ser observado na Figura 3, a qual apresenta o mapa de referência da cobertura do solo elaborado para a área de estudos. Assim, este mapa corrobora para análise e discussão dos resultados através da aplicação do índice Kappa e comparação visual dos resultados obtidos por meio dos classificadores.

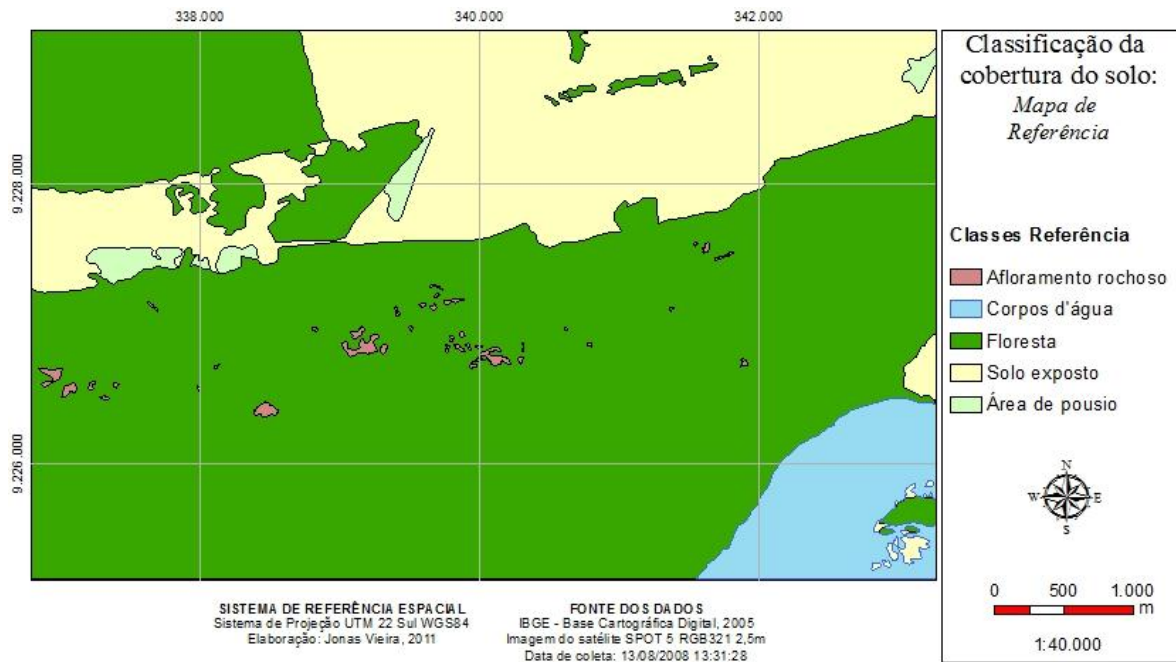


Figura 3: Mapa de referências de cobertura do solo

#### 4.1. Comparação dos resultados obtidos dos diferentes métodos

O resultado obtido por meio do método Máxima Verossimilhança apresentou as características esperadas para a classificação pixel a pixel em imagens de alta resolução, como se pode constatar na Figura 4. Isso pode ser observado ao constatar a presença de um pequeno número de pixels classificados e agrupados em classes opostas a maioria em sua volta, efeito denominado “sal e pimenta”. Neste caso, foram encontradas áreas de pousio em meio à formação florestal arbórea, dado que não corresponde à realidade. Todavia, a justificativa para este resultado assenta na alta variabilidade dos níveis de cinza encontrados em imagens de alta resolução e, em especial, a baixa separabilidade espectral entre as classes áreas de pousio e formação florestal arbórea.

De modo semelhante, foi constatada grande quantidade de pixels classificados como afloramento rochoso em áreas que, na realidade, são caracterizadas como solo exposto. Tal confusão é justificada quando analisamos a elevada variabilidade da classe solo exposto, possivelmente composto por áreas características de solos hidromórficos, pasto sujo ou áreas que sofreram supressão da cobertura vegetal pouco antes a data de coleta da cena.

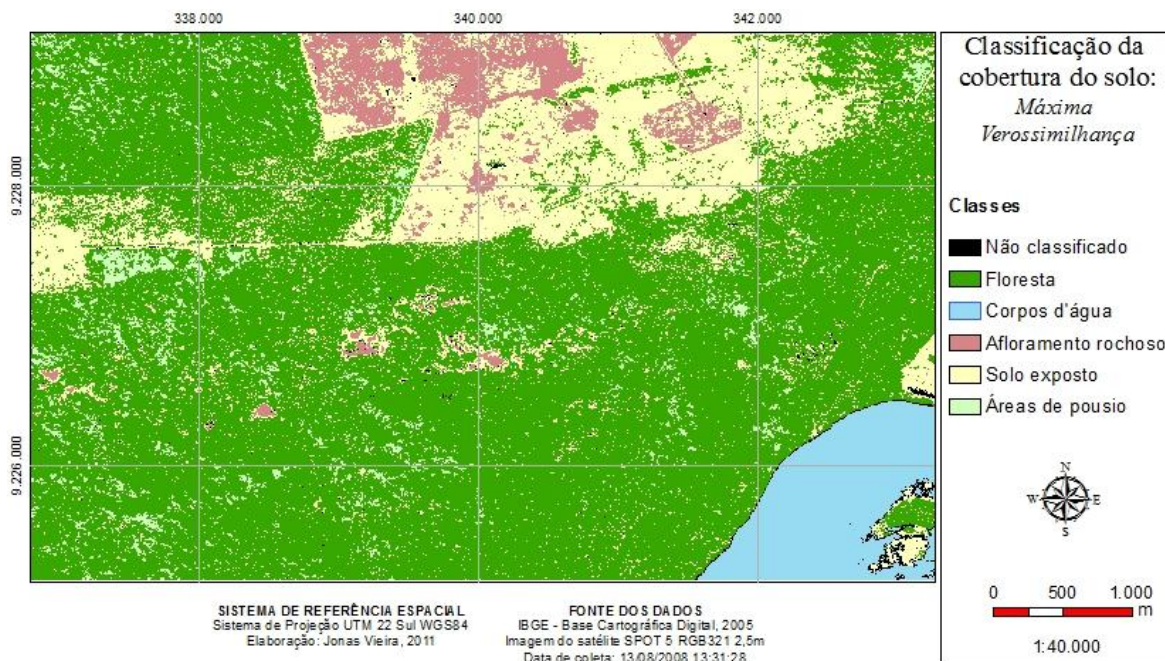


Figura 4: Classificação da cobertura do solo: Máxima Verossimilhança

Embora não tenha alcançado o resultado ideal, o método MaxVer apresentou resultado aceitável na identificação de alvos adjacentes a outros alvos cujo padrão de assinatura espectral apresenta ampla diferença. Isso aponta para regiões de contato entre classes de natureza notavelmente distinta, tais como afloramento rochoso e formação florestal arbórea, corpos d'água e formação florestal arbórea, solo exposto e corpos d'água. O mesmo não pode ser afirmado em relação a classe solo exposto adjacente a classe formação florestal arbórea, visto a elevada variação dos ND para ambas as classes.

No mapeamento obtido pelo classificador Distância de Bhattacharyya pode-se destacar algumas variações no que diz respeito à veracidade do mapeamento (Figura 5). Inicialmente, destaca-se o ganho ao delimitar os limites entre elementos de diferentes classes, como observado na relação solo exposto e floresta. Entretanto, observa-se que o mesmo não obteve tal sucesso em toda a cena, visto a confusão de alvos nas porções norte e oeste. Diferente do método de classificação MaxVer, este apresentou maior confusão na classe afloramento rochoso inserido no contexto florestal, na porção central da cena. Outro ponto divergente diz respeito à redução do efeito "sal e pimenta", o qual apresenta maior agrupamento de pixels no classificador Distância de Bhattacharyya. Finalmente, outro fator notável aponta para a elevada confusão nas áreas de pousio situadas à oeste da cena. Tal área foi considerada de elevada confusão para ambos os classificadores. Tal fenômeno

pode ser explicado não somente pela variabilidade dos ND, como também a baixa distância espectral desta classe em relação a formação florestal arbórea.

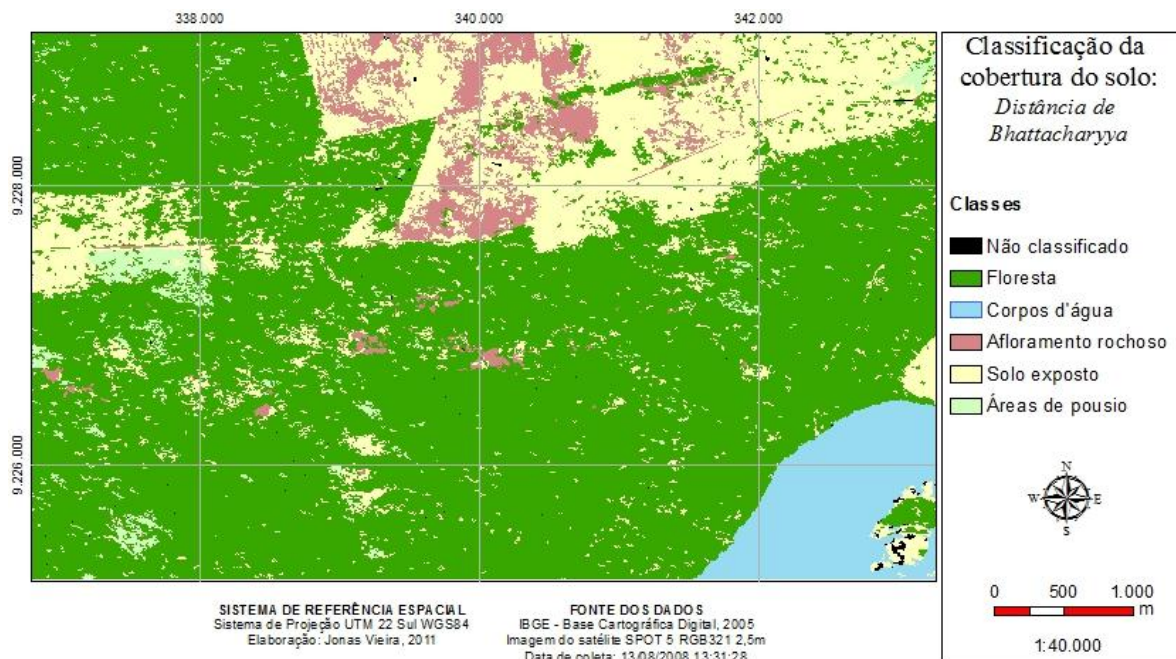


Figura 5: Classificação da cobertura do solo: Distância de Bhattacharyya

Ao contrário dos resultados apresentados anteriormente, o mapeamento da cobertura do solo através do método de classificação orientada a objetos apresentou ganhos na representação da informação (Figura 6). Num primeiro momento, pode-se observar a presença de padrão espacial concentrado para a confusão entre classes, principalmente para afloramento rochoso e áreas de pousio.

Outra característica positiva diz respeito à delimitação das feições. Isso pode ser constatado na maioria dos casos para a área de estudos, tais como os limites entre florestas e solo exposto, corpos d'água e demais outras classes.

Apesar dos avanços observados na representação da informação espacial, este método ainda apresentou elevada confusão, como observaremos na validação pelo índice Kappa. O classificador não obteve sucesso ao distinguir as classes afloramento rochoso e solo exposto. Todavia, deve-se ressaltar que foram aplicadas técnicas básicas deste método. Isso configura a não utilização de restrições espaciais e demais variáveis na classificação, o que potencializa os ganhos para o mapeamento.

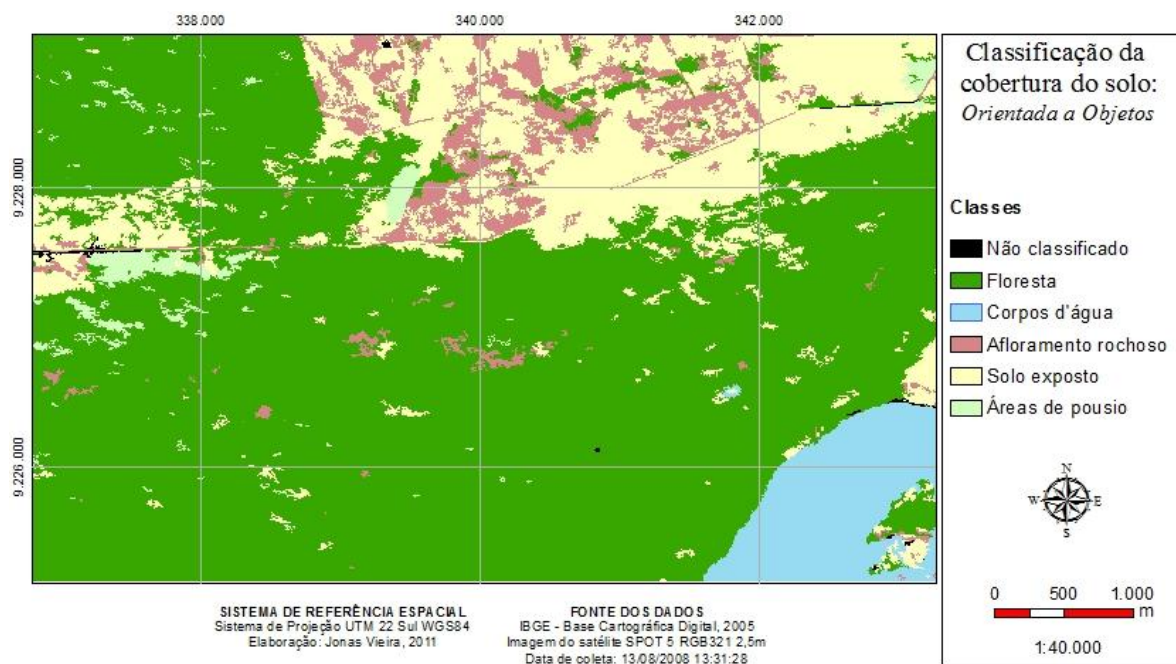


Figura 6: Classificação da cobertura do solo: Orientada a Objetos

#### 4.2. O índice Kappa na avaliação do desempenho dos classificadores

Para validar os resultados obtidos, foi calculado o índice Kappa. Este processo consistiu no cruzamento das informações de cada classe dos resultados obtidos em diferentes métodos com o mapa de referência. Assim, a Tabela 4 mostra o desempenho obtido pelos classificadores.

Tabela 4 - Desempenho dos classificadores no índice Kappa

Método	Desempenho no índice Kappa
Máxima Verossimilhança	0,636
Distância de Bhattacharyya	0,717
Orientada a Objetos	0,741

Tais resultados apontam para o melhor desempenho do método de classificação Orientada a Objetos, o qual pode ser confirmado ao analisar a Figura 6. O classificador Distância de Bhattacharyya alcançou 0,717 e o classificador de MaxVer 0,636. Isso aponta para melhor desempenho dos métodos que utilizam a técnica de segmentação de imagens e análise por padrão espacial em imagens de alta resolução.

Todavia, deve-se mencionar a pequena distância no desempenho dos classificadores Distância de Bhattacharyya e Orientada a Objetos. Isso pode ser explicado pelo fato de não utilizarmos toda a potencialidade dos métodos inseridos na classificação Orientada a Objetos. Assim, acredita-se que ao modelar todo o processo de classificação para este método, seria obtido valores superiores ao constatado neste estudo.

## **5 - CONCLUSÕES E CONSIDERAÇÕES FINAIS**

A utilização de métodos de classificação de imagens de satélite tem sido abordada em diversos estudos. Para este caso, adotamos como foco três métodos aplicados em imagens de alta resolução para classificação da cobertura do solo. O desenvolvimento do trabalho consistiu em aplicar tais métodos em softwares diferentes, visto a inexistência destes métodos num único software. De modo semelhante, foi adotado mesmo padrão espacial para a etapa de treinamento, a qual consistiu na coleta de amostras para as classes mapeadas.



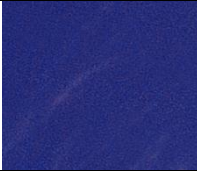





O desempenho dos classificadores testados neste trabalho correspondeu às premissas formuladas ao longo do estudo. Assim como encontrado na literatura, não é recomendado o uso de métodos de classificação pixel a pixel para extração de informações a partir de imagens de alta resolução espacial. As características de detalhamento destas imagens dificultam a extração automática de informações. Apesar de visualmente favoráveis a identificação de alvos, faz-se necessário um estudo mais adequado de suas características e aplicações para o objetivo dos trabalhos. Além disso, o uso de bibliotecas espectrais e imagens constituídas por diversas faixas do espectro eletromagnético é indicado para trabalhos dessa natureza. Os métodos que apresentaram melhor resultado fizeram uso da técnica de segmentação. Tal processo facilita a coleta de amostras, como também a pré-visualização do resultado final do mapeamento. Outro fator relevante na aplicação destes métodos aponta para a otimização no processo de correção. Além de não apresentar ruídos por toda a cena, tais métodos apresentaram padrão espacial semelhante para a confusão de classes, o que facilita o processo de correção manual

Finalmente, destaca-se a necessidade de planejamento e modelagem dos processos aplicados, assim como conhecimento das técnicas empregadas, o que nem sempre é considerado em projetos que fazem uso destes métodos.

## REFERÊNCIAS BIBLIOGRÁFICAS

- CHULHEE LEE, E. C. Feature extraction based on the Bhattacharyya distance. **Pattern Recognition**, New York. v36. 1703-1709p. 2003.
- JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2. ed. New Jersey: Prentice Hall, 1996. 316 p.
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos, SP: Parêntese, 2009. 4-29p.
- LILLESAND, Thomas M; KIEFER, Ralph W; CHIPMAN, Jonathan W. **Remote sensing and image interpretation**. 6th ed. Hoboken, NJ: John Wiley & Sons, c2008. xii, 441-587p.
- MOREIRA, A. de A.; SOARES, V. P.; GLERIANI, J. M.; RIBEIRO, C. A. A. S. Utilização de algoritmos de classificação para o mapeamento do uso e cobertura do solo da terra na bacia hidrográfica do ribeirão São Bartolomeu, Viçosa-MG, a partir de uma imagem do sensor IKONOS II. **XIII Simpósio Brasileiro de Geografia Física Aplicada**. Viçosa. Eixo 1. 2009.
- NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 3. ed., rev. e ampl. São Paulo: Edgard Blucher, 2008. 1-10;256-289p.
- RICHARDS, J. A; JIA, Xiuping. **Remote sensing digital image analysis: an introduction**. 3th ed. Berlin; New York: Springer-Verlag, 2005. xxiv, 4-25p.
- SCHOWENGERDT, Robert A. **Techniques for image processing and classification in remote sensing**. New York: Academic Press, c1983. 142-180p.
- SO, B.; MATHER, P. M. **Classification methods for remotely sensed data**. London; New York: Taylor & Francis, 2001. 77-78p.
- SPRING. **Tópicos de ajuda**. 2011. São José dos Campos, SP. 2011.
- US ARMY CORPS OF ENGINEERS. **Remote Sensing**. Washington, DC: 2003. 217p.
- WACKER, A.G; LANDGREBE, D.A. **Minimum Distance Classification in Remote Sensing**. LARS Technical Reports. Indiana. v25. Disponível em: <http://docs.lib.purdue.edu/larstech/25/> Acesso em: 12/novembro/2011.

## ANEXO 1 – CHAVE DE INTERPRETAÇÃO

CLASSE	ELEMENTO DE TEXTURA	TONALIDADE			TEXTURA			FORMA		EXEMPLO IMAGEM SPOT 5	EXEMPLO FOTOGRAFIA EM CAMPO
		-	-+	+	Fina	Média	Grossa	Regular	Irregular		
Formação florestal arbórea	Árvore	-	-+	+	Fina	Média	Grossa	Regular	Irregular		
Corpos d'água	Indefinido	-	-+	+	Fina	Média	Grossa	Regular	Irregular		
Afloramento Rochoso	Rocha	-	-+	+	Fina	Média	Grossa	Regular	Irregular		
Áreas de pousio	Arbustos	-	-+	+	Fina	Média	Grossa	Regular	Irregular		
Solo exposto	Solo	-	-+	+	Fina	Média	Grossa	Regular	Irregular	