

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS  
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E  
METEOROLOGIA - CEPSRM  
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**DADOS DO SENSOR HYPERION / EO-1 PARA ANÁLISE DAS ÁREAS DE MATA  
ATLÂNTICA E DE BANANAIS NO NORDESTE DO RIO GRANDE DO SUL**

**Alan Bernardo Arruda Bisso**

Porto Alegre, RS  
2010

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

**DADOS DO SENSOR HYPERION / EO-1 PARA ANÁLISE DAS ÁREAS DE MATA  
ATLÂNTICA E DE BANANAIS NO NORDESTE DO RIO GRANDE DO SUL**

**Alan Bernardo Arruda Bisso**

Orientadora: Dra. Dejanira Luderitz Saldanha

**Banca Examinadora:**      **Dr. Lênio Soares Galvão (PPGSR – INPE)**  
   **Dr. Laurindo Antonio Guasselli (PPGGEA –UFRGS)**  
   **Dra. Denise Fontana (PPGSR – UFRGS)**

Dissertação submetida ao Programa de Pós-graduação em Sensoriamento Remoto do Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia – UFRGS, como requisito parcial para obtenção do grau de Mestre em Sensoriamento Remoto, área de concentração em Sensoriamento Remoto e Geoprocessamento Aplicados – Recursos Naturais e Meio Ambiente.

Porto Alegre, RS  
Agosto, 2010

*Aos meus pais*  
*Napoleão Nunes Bisso*  
&  
*Alda Arruda Bisso*

## AGRADECIMENTOS

À Universidade Federal do Rio Grande do Sul (UFRGS) e ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPSRM), pelo ensino de qualidade, pelo auxílio no trabalho de campo e pela estrutura disponibilizada, sem a qual não seria possível a realização desta pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela oportunidade de bolsa de pós-graduação, auxílio financeiro indispensável para o meu aperfeiçoamento e conclusão da Pós-Graduação.

À professora Dejanira, minha orientadora e ao professor Laurindo pelo apoio no momento mais difícil que tive durante o mestrado e por todo auxílio na execução do trabalho.

Aos colegas de curso, principalmente, o Mestre Guilherme Garcia de Oliveira por todo apoio no decorrer do curso e na elaboração da dissertação.

Ao meu pai, mãe e irmãos pelo incentivo na continuidade dos estudos além da graduação.

À minha namorada, Luana Caye, pela ajuda, paciência, incentivo e cobranças, que sem elas não teria finalizado o trabalho.

Aos meus amigos Bruno Lopes e Roberto Antunes pelo incentivo e apoio nos momentos difíceis curriculares e extra curriculares.

## RESUMO

A região do litoral norte do estado do Rio Grande do Sul abriga conjuntos florestais do Bioma Mata Atlântica que se encontram extremamente fragmentados e com reduzida parcela de vegetação nativa. A ocupação humana e as atividades econômicas agrícolas da região vêm ocasionando forte pressão nestes remanescentes florestais. O plantio de banana ocupa a maior área nesta região, gerando um enorme impacto sobre as áreas de Mata Atlântica que vem cedendo lugar para as áreas de bananais. O presente trabalho tem como objetivo avaliar o uso de dados hiperespectrais para a diferenciação das áreas de Mata Atlântica e de bananais no município de Três Cachoeiras, o maior produtor de banana do Estado. Classificadores bayesianos foram utilizados para a determinação das classes, Mata Atlântica e Bananais, com dados extraídos de uma imagem de alta resolução espectral do município de Três Cachoeiras. Verificou-se que os valores de acurácia com índice Kappa e Exatidão Global diminuíram conforme a simplificação do classificador de Bayes. Desta forma, os maiores valores de acurácia foram os dos métodos de Máxima Verossimilhança, Fisher e Distância Euclidiana, respectivamente. Os dois primeiros métodos aumentam os valores de acurácia se forem implementados com um limiar de exclusão. Foi verificado que a variável ambiental de orientação de vertentes não influencia na forma da curva espectral das áreas ocupadas por bananais, influenciando somente na intensidade da mesma. Destaca-se que a utilização de dados hiperespectrais representam uma nova abordagem do sensoriamento remoto, complementando a análise do meio ambiente realizada pelos métodos multispectrais.

## ABSTRACT

The North Coast region of Rio Grande do Sul is home to sets of Atlantic Forest in the state; however they are extremely fragmented, with small portion of native vegetation. Human occupation and agricultural economic activities in the region have caused great pressure on these forest remnants. Banana plantation in this region is takes the biggest part of this area, and the features of this planting generates a huge impact on the areas of Atlantic Forest, since that it is giving way to the areas of plantations. This assignment aims to evaluate the use of hyperspectral data for differentiation between the Atlantic Forest and banana's areas in the town of Três Cachoeiras, the state's largest producer of banana. Bayesian classifiers and data extracted from a town's high spatial resolution image have been used in order to verify the accuracy of the classifiers. It was found that the values of accuracy with an index Kappa and Global Accuracy have decreased by the simplification of the Bayes classifier. Thus the highest values of accuracy were the Method of Maximum Likelihood, Linear Fisher and Euclidean Distance, respectively. The first two methods increase the accuracy values if they are implemented with a threshold of exclusion. It was verified that the strands' environmental orientation variable does not influence the shape of spectral curve of the areas of banana plantations, but only influences its intensity. It is noteworthy that the use of hyperspectral data represent a new way of approach to remote sensing, complementing the environmental analysis performed by the multispectral methods.

## SUMÁRIO

LISTA DE FIGURAS .....	07
LISTA DE TABELAS .....	09
ESTRUTURA DA DISSERTAÇÃO .....	11
1 - INTRODUÇÃO E JUSTIFICATIVA.....	12
2 - FUNDAMENTAÇÃO TEÓRICA .....	16
2.1 A Mata Atlântica .....	16
2.2 O Litoral Norte Gaúcho .....	19
2.3 Bananicultura .....	20
2.4 Sensoriamento Remoto .....	23
2.5 O Sensor Hyperion/EO-1 .....	25
2.6 Comportamento Espectral da Vegetação.....	26
2.7 Condicionantes Topográficos da Paisagem.....	30
2.8 Classificação Digital de Imagens .....	31
2.9 Separabilidade entre Classes de Vegetação.....	36
3 - MATERIAIS E MÉTODOS .....	38
3.1 Materiais .....	38
3.2 Métodos .....	39
4 - RESULTADOS E DISCUSSÕES .....	47
4.1 Pré-processamento.....	47
4.2 Comportamento Espectral da Mata Atlântica e dos Bananais.....	50
4.3 Bhattacharya .....	56
4.4 Resultado das Classificações da Imagem .....	58
5 - CONCLUSÃO .....	79
6 - BIBLIOGRAFIA.....	81

## LISTA DE FIGURAS

Figura 1 - Extensão do domínio da Mata Atlântica conforme o Decreto 750/93. ....	17
Figura 2 - Remanescentes florestais e ecossistemas associados à Mata Atlântica no RS.....	18
Figura 3 – Mapa do Rio Grande do Sul com os três municípios com maior produção de banana .....	22
Figura 4 - Cubo hiperespectral de dados de imagem, como registrado por um espectrômetro de imagem.....	24
Figura 5 - Curva teórica do comportamento espectral da vegetação e os fatores que controlam a sua reflectância. ....	28
Figura 6 - Representação das classes de informação por subconjuntos de classes espectrais .....	37
Figura 7 - Fluxograma das etapas desenvolvidas ao longo do trabalho. ....	39
Figura 8 - Mapa de localização da região da área de estudo. ....	40
Figura 9 - Imagem Hyperion, composição RGB 37, 27, 17 e as bandas 37, 27 e 17 respectivamente. ....	41
Quadro 1 - Parâmetros utilizados na correção atmosférica .....	43
Figura 10 - Recorte da imagem Hyperion .....	44
Figura 11: Imagem Hyperion, banda 13, (A) com correção dos <i>stripes</i> e (B) imagem original no nível L1R.....	47
Figura 12: Exemplo do processamento no software ENVI contendo a imagem original e a imagem com correção atmosférica, com seus respectivos gráficos de comportamento espectral de um alvo de vegetação. ....	48
Figura 13: Distribuição das amostras na área de estudo, imagem do sensor Hyperion, data 02/05/2004. ....	50
Figura 14: Resposta espectral dos alvos Bananais e Mata Atlântica, imagem do sensor Hyperion, data 02/05/2004.....	51
Figura 15: Diferença das respostas espectrais dos alvos de Bananais com relação às áreas de Mata Atlântica.....	52
Figura 16: Comportamento espectral das áreas de Bananais e Mata Atlântica com detalhes ao longo da faixa utilizada, imagem do sensor Hyperion, data 02/05/2004 .....	53

Figura 17: Comportamento espectral das áreas de Bananais nas diferentes orientações de vertentes da área de estudo, com detalhes ao longo da faixa utilizada, imagem do sensor Hyperion, data 02/05/2004 .....	54
Figura 18: Diferença entre a resposta espectral das áreas de Bananais nas vertentes orientadas para o Norte com relação às orientadas para o Sul, imagem do sensor Hyperion, data 02/05/2004.....	55
Figura 19: Histograma de distribuição dos pixels, no comprimento de onda de 689nm, das classes Sombra em azul claro, Mata em azul escuro, Banana em verde e Campo em vermelho, na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004 .....	57
Figura 20: Imagem classificada pelo método Máxima Verossimilhança, sensor Hyperion, data 02/05/2004.....	60
Figura 21: Imagem classificada pelo método de Fisher, sensor Hyperion, data 02/05/2004 ..	62
Figura 22: Imagem classificada pelo método da Distância Euclidiana Mínima, sensor Hyperion, data 02/05/2004 .....	64
Figura 23: Imagem classificada pelo método da Máxima Verossimilhança com <i>Threshold</i> de 2%, sensor Hyperion, data 02/05/2004 .....	66
Figura 24: Imagem classificada pelo método Fisher com <i>Threshold</i> de 2%, sensor Hyperion, data 02/05/2004.....	69

## LISTA DE TABELAS

Tabela 1. Número de pixel nas amostras das classes de uso do solo. ....	45
Tabela 2: Distâncias mínimas e médias dos 20 melhores canais para separar as classes Mata, Banana, Campo e Sombra na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004..	56
Tabela 3: Distâncias mínimas e médias dos 20 melhores conjuntos de 5 canais para separar as classes Mata, Banana, Campo e Sombra na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004. ....	58
Tabela 4: Matriz de confusão da classificação Máxima Verossimilhança confeccionada pelo método de Re-substituição, no software Multispec. ....	60
Tabela 5: Matriz de Confusão da classificação Máxima Verossimilhança confeccionada pelo método de Leave-One-Out, no software Multispec. ....	61
Tabela 6: Distribuição das áreas das classes na imagem classificada pelo método da Máxima Verossimilhança sem <i>Threshold</i> .....	61
Tabela 7: Matriz de Confusão da classificação Fisher confeccionada pelo método de Re-substituição, no software Multispec .....	62
Tabela 8: Distribuição das áreas das classes na imagem classificada pelo método de Fisher, sem <i>Threshold</i> .....	63
Tabela 9: Matriz de confusão da classificação Distância Euclidiana Mínima confeccionada pelo método de Re-substituição, no software Multispec .....	64
Tabela 10: Matriz de confusão da classificação Distância Euclidiana Mínima confeccionada pela método de Leave-One-Out, no software Multispec .....	65
Tabela 11: Distribuição das áreas das classes na imagem classificada pelo método da Distância Euclidiana Mínima.....	65
Tabela 12: Matriz de confusão da classificação Máxima Verossimilhança com <i>Threshold</i> de 2%, confeccionada pelo método de Re-substituição, no software Multispec. ....	67
Tabela 13: Matriz de confusão da classificação Máxima Verossimilhança com <i>Threshold</i> de 2% confeccionada pelo método Leave-One-Out, no software Multispec.....	67
Tabela 14: Distribuição das áreas das classes na imagem classificada pelo método da Máxima Verossimilhança com <i>Threshold</i> de 2%.....	68
Tabela 15: Matriz de confusão da classificação Fisher com <i>Threshold</i> de 2%, confeccionada pelo método de Re-substituição, no software Multispec.....	69
Tabela 16: Distribuição das áreas das classes na imagem classificada pelo método de Fisher com <i>Threshold</i> de 2%.....	70

Tabela 17: Matriz de confusão da classificação pelo método da Distância Euclidiana .....	71
Tabela 18: índices de acurácia Kappa e Exatidão Global do método Distância Euclidiana .....	71
Tabela 19: Matriz de confusão da classificação pelo método de Fisher .....	72
Tabela 20: Índices de acurácia Kappa e Exatidão Global do método Fisher .....	72
Tabela 21: Matriz de confusão da classificação pelo método de Fisher com <i>Threshold</i> de 2% .....	73
Tabela 22: Índices de acurácia Kappa e Exatidão Global do método Fisher com <i>Threshold</i> de 2% .....	73
Tabela 23: Matriz de confusão da classificação pelo método Máxima Verossimilhança .....	74
Tabela 24: Índices de acurácia Kappa e Exatidão Global do método Máxima Verossimilhança .....	74
Tabela 25: Matriz de confusão da classificação pelo método Máxima Verossimilhança com <i>Threshold</i> de 2% .....	75
Tabela 26: Índices de acurácia Kappa e Exatidão Global do método Máxima Verossimilhança com <i>Threshold</i> de 2% .....	75
Tabela 27: Índices de acurácia de todos os métodos de classificação implementados calculados a partir dos dados vetoriais extraídos da imagem de alta resolução espacial .....	76
Tabela 28: Tabela dos índices Kappa e Exatidão Global dos classificadores utilizados por Oliveira (2009) com dados HRG – SPOT 5 para o município de Três Cachoeiras .....	77

## **ESTRUTURA DA DISSERTAÇÃO**

Este trabalho está organizado em cinco capítulos sendo aqui, apresentada uma breve descrição dos mesmos. O capítulo I apresenta a introdução dos temas que serão discriminados ao longo da dissertação, destacando a temática da Mata Atlântica, o plantio de bananas nesta região, o uso do Sensoriamento Hiperespectral e a possibilidade de discriminação dos diversos alvos aí contidos. Neste capítulo também são apresentados os objetivos e uma breve justificativa sobre as motivações que levaram à escolha do tema e que tornaram a realização desta dissertação relevante.

No capítulo 2 é relatada a fundamentação teórica sobre os temas referentes ao trabalho, visando facilitar a compreensão da metodologia desenvolvida e dos resultados alcançados. Neste capítulo é feita uma revisão ampla sobre a temática da Mata Atlântica, sua integração com o plantio de bananas e o Sensoriamento Remoto Hiperespectral aplicado a estudos da vegetação. Estes estudos referem-se à utilização de sistemas de classificação para diferenciar diferentes culturas, ponderando e quantificando suas áreas.

No capítulo 3 apresentam-se os materiais e os métodos utilizados para a execução dos objetivos propostos, bem como a metodologia empregada na realização da dissertação. A seqüência dos procedimentos metodológicos e os parâmetros utilizados no desenvolvimento da pesquisa são representados como imagens ilustrativas das várias etapas do processo.

Resultados e discussões obtidos pelo desenvolvimento dos procedimentos metodológicos propostos são apresentados no capítulo 4, além de algumas discussões baseadas nos resultados encontrados.

O capítulo 5 apresenta as conclusões dessa pesquisa. Na seqüência, são relacionadas as referências bibliográficas da dissertação e os anexos.

## 1 - INTRODUÇÃO E JUSTIFICATIVA

Ao longo do período de colonização e ocupação do território brasileiro a população, proveniente do território europeu, instalou-se ao longo da costa brasileira. Região esta ocupada pela vegetação que constitui o Bioma da Mata Atlântica. Em decorrência dessa ocupação grande parte das florestas nativas da faixa litorânea foi sendo substituída por áreas agrícolas e centros urbanos fazendo com que a vegetação do Bioma Mata Atlântica ficasse cada vez mais escassa e fragmentada.

O Bioma Mata Atlântica, Patrimônio Nacional<sup>1</sup>, contém uma alta diversidade de espécies e é caracterizado por alto nível de endemismo (Morellato & Haddad, 2000). A biodiversidade existente neste bioma é reconhecida tanto nacional como internacionalmente pela comunidade científica. Entretanto é um dos biomas mais ameaçados no mundo, registrando-se um alto grau de intervenção antrópica nos diversos ecossistemas que o compõem. Sendo o segundo maior complexo florestal tropical do Brasil, a Mata Atlântica é considerada um dos mais importantes repositórios de biodiversidade do planeta e um hotspost para a conservação (Tabarelli *et al.*, 2005).

A ocorrência da Mata Atlântica, principalmente ao longo do litoral brasileiro, originalmente ocupava 17 estados brasileiros, (PI, CE, RN, PE, PB, SE, AL, BA, ES, MG, GO, RJ, MS, SP, PR, SC e RS), possuindo uma área de 1.315.460 km<sup>2</sup>. Atualmente a sua vegetação nativa ocupa pouco mais de 6% da área original. Apesar do grande grau de desmatamento e fragmentação, este bioma apresenta uma grande biodiversidade de fauna e flora, sendo considerada a região de mata com maior biodiversidade do mundo (Fundação SOS Mata Atlântica & INPE, 2009).

Tendo em vista a elevada extensão de ocorrência da Mata Atlântica, a utilização do sensoriamento remoto torna-se uma ferramenta importante para o monitoramento do meio ambiente, por causa das suas características que permitem acompanhar a vegetação, monitorar os desmatamentos das áreas e as condições ambientais locais. As imagens de satélites, utilizadas para este monitoramento, são uma grande fonte de dados que possibilitam a análise espacial e temporal do uso e ocupação da superfície terrestre.

---

<sup>1</sup> Definido pela Constituição da República Federativa do Brasil de 1988, no parágrafo 4 do artigo 225.

Atualmente, o avanço das resoluções dos sensores orbitais, dos computadores e das técnicas de processamento de imagens, vem permitindo o progresso de estudos de imagens hiperespectrais em uma maior escala de abrangência – acontecimento que até pouco tempo atrás não era possível devido às limitações técnicas dos computadores.

Com as imagens hiperespectrais podemos avaliar os alvos da superfície terrestre através de outra perspectiva. Não só a partir de uma análise espacial, mas também por meio de uma análise da resposta espectral ao longo de um intervalo do espectro eletromagnético gerando curvas espectrais definidas por esses sensores.

Na região do litoral norte do Estado do Rio Grande do Sul estão presentes os maiores remanescentes florestais da Mata Atlântica deste estado, vinculados ao relevo acidentado da faixa de transição de dois compartimentos geomorfológicos: a Planície Costeira e o Planalto Meridional no Rio Grande do Sul. A Mata Atlântica ocupa principalmente as áreas de morros e encostas ao longo da borda do planalto, e está parcialmente preservada, especialmente, nas áreas de relevo mais acidentado. Nessas encostas a atividade agrícola é dificultada pela declividade apresentada no local. Essas características impedem a mecanização da agricultura e a fixação e desenvolvimentos de outras culturas agrícolas, pois em regiões com alto grau de declividade, a fixação do solo é dificultada em períodos chuvosos.

A produção de banana constitui-se em uma das poucas culturas agrícolas que se desenvolve bem neste tipo de situação geomorfológica. Por serem perenes, os bananais, no litoral norte gaúcho, vem sendo cultivados nos locais originalmente ocupados pela Mata Atlântica. Esta atividade permite a sobrevivência econômica de várias famílias da região, já que em suas propriedades rurais as características do relevo dificultam outra atividade econômica vinculada ao uso direto da terra.

Uma grande parte desta área de morros e de encostas do planalto é considerada de Preservação Permanente (APP), conforme o Código Florestal Brasileiro, Lei 4771/65, tendo suas áreas reservadas para a preservação dos recursos hídricos, do solo e da biodiversidade.

No atual contexto de preservação ambiental, este trabalho se justifica, pois apresenta uma nova abordagem de análise da vegetação, utilizando dados de sensoriamento remoto através de imagens hiperespectrais pelas quais é possível detalhar melhor as curvas espectrais dos alvos imageados. Tornam-se assim, uma nova ferramenta de estudos. As respostas mais

detalhadas da reflectância dos alvos são diretamente influenciadas pelas características físico-químicas e estruturais dos objetos observados. Desta maneira a utilização de dados hiperespectrais permite uma análise do comportamento espectral da vegetação de forma mais precisa.

Essa análise mais completa auxilia nos estudos de desmatamento, principalmente quando o desmatamento da mata nativa dá lugar a uma vegetação estruturalmente muito semelhante – neste caso, Mata Atlântica e bananais, ambas de porte arbóreo. Esta característica dificulta a sua análise e diferenciação quando utiliza-se os sensores tradicionais, que tem uma baixa resolução espectral e média resolução espacial.

Os sensores multiespectrais não permitem a diferenciação das diversas formações vegetais arbóreas com base em critérios espectrais, já que as pequenas diferenças ao longo do espectro são imperceptíveis em função das poucas bandas espectrais. Estas bandas abrangem intervalos amplos ao longo do espectro eletromagnético, não sendo possível identificar feições espectrais mais estreitas, que diferenciam os alvos semelhantes. Além disso, as diferenciações texturais dos alvos são dificultadas, já que na grande maioria dos sensores multiespectrais, as resoluções espaciais são pouco refinadas, tornando difícil a caracterização das pequenas variações existentes, como: o espaçamento entre as plantas dos bananais e os diferentes arranjos das áreas de mata nativa e de plantio de bananas.

A região nordeste do Rio Grande do Sul apresenta uma grande área de remanescentes da vegetação do bioma Mata Atlântica. Também é uma região onde o plantio de bananas é muito intenso, tanto na forma de grandes bananais, como também em áreas menores entremeadas com as áreas de vegetação nativa dificultando o seu monitoramento e conseqüentemente a sua fiscalização.

Richards e Jia (1998) enfatizam, ao analisar as mudanças tecnológicas na área de sensoriamento remoto e geoprocessamento, que “...talvez a mais significativa seja a disponibilidade generalizada de dados hiperespectrais e os especiais desafios apresentados por esse tipo de dados para extração de informações.” Assim, os esforços empreendidos para a realização deste trabalho visam contribuir como uma nova abordagem metodológica de monitoramento e quantificação do uso e ocupação de áreas, através da utilização de sensoriamento remoto hiperespectral e análise dos fatores que contribuem para a variabilidade espectral das plantas de bananeiras no nordeste do estado do Rio Grande do Sul.

Desta maneira, a presente dissertação vê como objetivo analisar as áreas de Mata Atlântica e de cultivo de bananas no Litoral Norte gaúcho, através de dados hiperespectrais coletados pelo sensor Hyperion. Portanto, este estudo envolve a análise de espectros de referência e a análise da quantificação destas áreas, através de métodos e técnicas de classificação, assim como a verificação da influência do relevo nos perfis espectrais das classes da vegetação estudada. Com a hipótese de que a utilização de dados hiperespectrais fornecem um ganho na acurácia do processo de classificação, mesmo utilizando-se de classificadores tradicionais como os bayesianos.

Neste contexto, é necessário alcançar alguns objetivos específicos como: 1) testar métodos de classificação Bayesianos com base em critérios de seleção de feições espectrais que aperfeiçoam a separação destes dois tipos de alvo; 2) verificar a variação espectral das duas classes de vegetação destacando as semelhanças e as diferenças.

## 2 - FUNDAMENTAÇÃO TEÓRICA

### 2.1 A Mata Atlântica

A Mata Atlântica é um complexo e exuberante conjunto de ecossistemas de grande importância, por abrigar uma parcela significativa da diversidade biológica do Brasil, reconhecida nacional e internacionalmente no meio científico. Lamentavelmente, é também um dos biomas mais ameaçados do mundo, devido às constantes agressões ou ameaças de destruição dos habitats nas suas variadas tipologias e ecossistemas associados (SOS Mata Atlântica & INPE, 2009).

A Mata Atlântica pode ser vista como um mosaico diversificado de ecossistemas, apresentando estruturas e composições florísticas diferenciadas, em função de diferenças de solo, relevo e características climáticas existentes na ampla área de ocorrência desse bioma no Brasil (IBAMA, 2010).

A Mata Atlântica abrangia originalmente 1.315.460 km<sup>2</sup>, o que correspondia a aproximadamente 15% do território brasileiro. Seus limites originais contemplavam áreas em 17 Estados, (PI, CE, RN, PE, PB, SE, AL, BA, ES, MG, GO, RJ, MS, SP, PR, SC e RS) (SOS Mata Atlântica & INPE, 2009).

Atualmente, restam cerca de 7,3% de sua cobertura florestal original, tendo sido inclusive identificada como a quinta área mais ameaçada e rica em espécies endêmicas do mundo. Na Mata Atlântica existem 1.361 espécies da fauna brasileira, com 261 espécies de mamíferos, 620 de aves, 200 de répteis e 280 de anfíbios, sendo que 567 espécies só ocorrem nesse bioma. Possui, ainda, cerca de 20 mil espécies de plantas vasculares, das quais 8 mil delas também só ocorrem na Mata Atlântica. Várias espécies da fauna são bem conhecidas pela população, tais como os mico-leões e muriquis, espécies de primatas dos gêneros *Leontopithecus* e *Brachyteles*, respectivamente. Vale lembrar que, no sul da Bahia, foi identificada, recentemente, a maior diversidade botânica do mundo para plantas lenhosas, ou seja, foram registradas 454 espécies em um único hectare (IBAMA, 2010).

O Bioma Mata Atlântica, que ocupa toda a faixa continental atlântica leste brasileira e se estende para o interior no Sudeste e Sul do País, é definido pela vegetação florestal predominante e relevo diversificado. Na Mata Atlântica, predominam as florestas estacionais semidecíduais (em que 20 a 50 % das árvores perdem as folhas no período seco do ano), e as florestas ombrófilas densas e mistas (com araucária). Em ambos os conjuntos florestais ocorrem, em menor proporção, as florestas estacionais decíduais (em que mais de 50% das árvores perdem folhas no período seco) (IBGE, 2004).

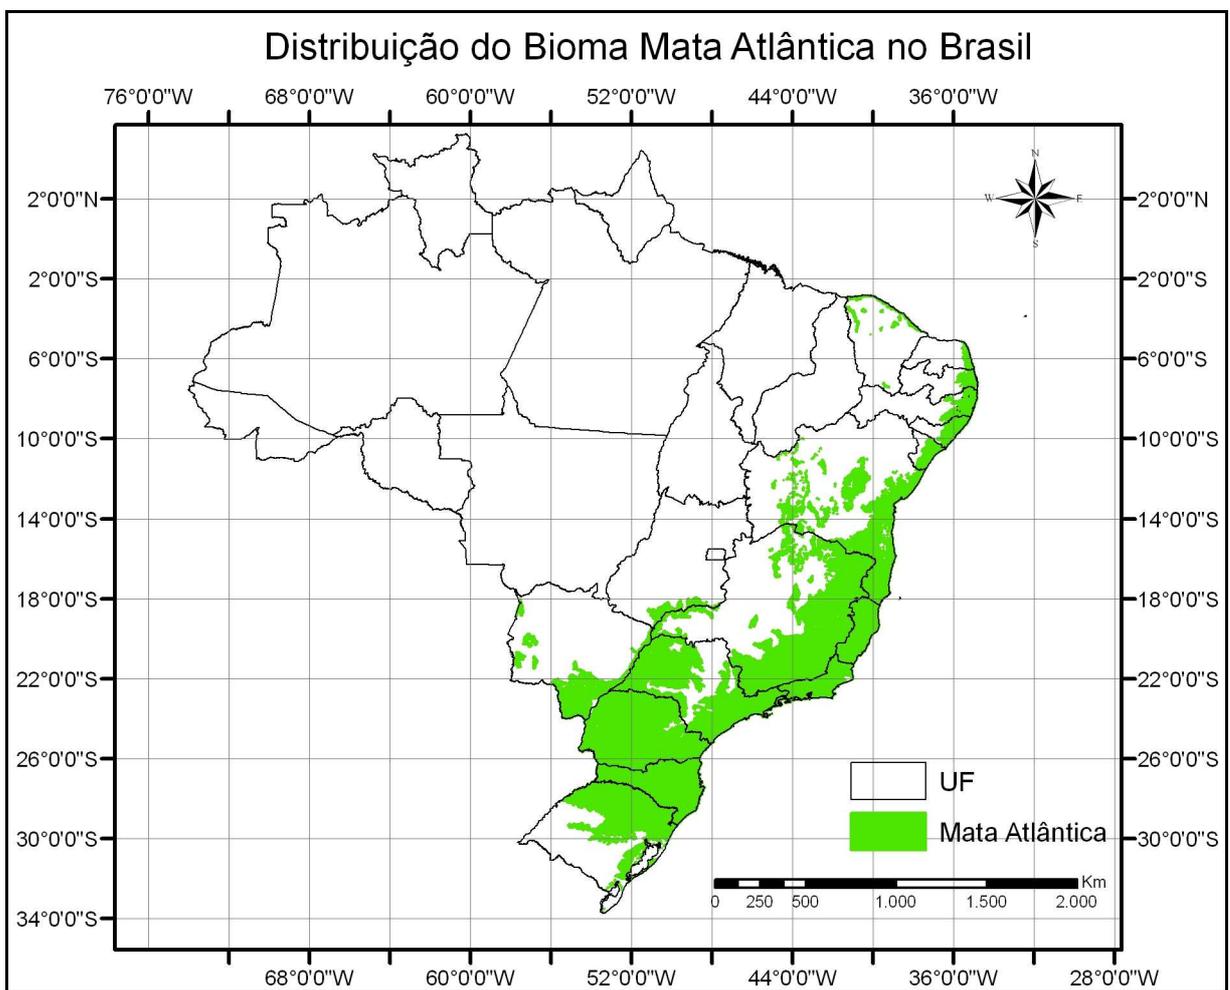


Figura 1. Extensão do domínio da Mata Atlântica conforme o Decreto 750/93.

Fonte: Relatório SOS Mata Atlântica & INPE (2008).

### 2.1.1 A Mata Atlântica no Rio Grande do Sul

No Rio Grande do Sul, a Floresta Atlântica (Mata Atlântica *stricto sensu*, Oliveira-Filho & Fontes, 2000) ocupa as encostas leste e os vales do Planalto Sul-Brasileiro, desde o nordeste do RS até a planície costeira e as encostas do planalto de Santa Catarina e Paraná, adentrando também em direção ao centro do estado ao longo da encosta do planalto médio (MMA, 2009).

No Estado do Rio Grande do Sul, a Reserva da Biosfera da Mata Atlântica corresponde a 17,2% da área do Estado (48.695 km<sup>2</sup>), abrangendo os remanescentes florestais que abrigam nossos recursos florísticos e faunísticos mais expressivos e seu potencial genético, bem como nossa história de colonização e de culturas indígenas dos caingangues e guaranis. (FEPAM, 2010).

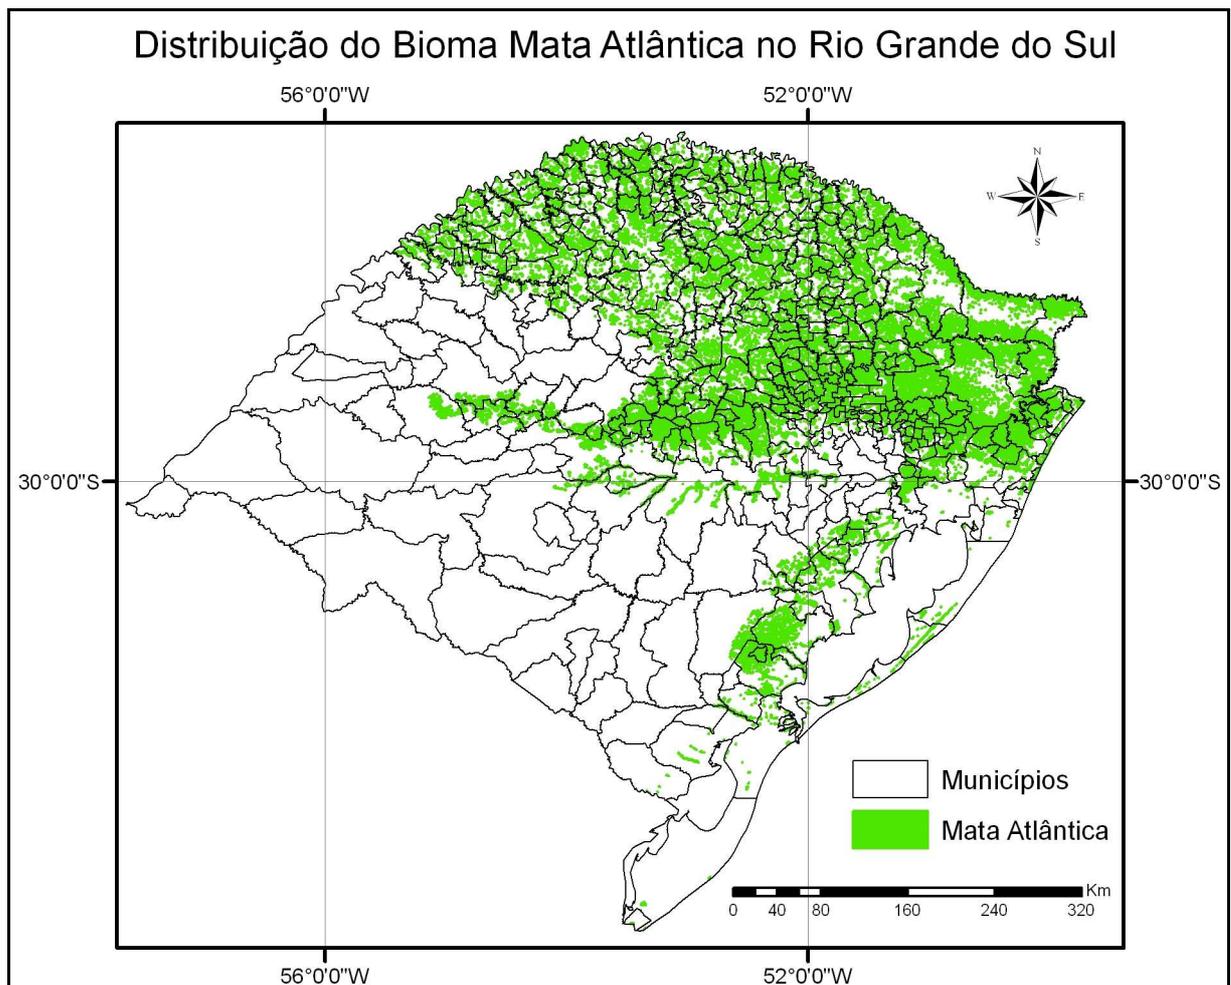


Figura 2. Remanescentes florestais e ecossistemas associados à Mata Atlântica no RS.  
 Fonte: Relatório SOS Mata Atlântica & INPE (2008).

## 2.2 O Litoral Norte Gaúcho

Rambo (2000), ao falar sobre a parte mais setentrional da Planície Costeira do Rio Grande do Sul, destaca três fatores diferenciadores desta região em relação ao resto da planície:

“o primeiro são as numerosas lagoas marginais ao norte de Tramandaí e de Osório que se concordam com as do sul pelo paralelismo geral e sua disposição atrás das dunas móveis e, delas diferem por sua forma, apresentando o lado mais curto ao oceano, também as duas primeiras lagoas maiores internas, a dos Barros e a dos Quadros, de circunferência mais arredondada, não deixam de participar deste fenômeno; só a Lagoa Itapeva conserva a forma das lagoas internas do sul. O segundo é a vegetação fortemente desenvolvida em mata seca, ou paludosa, devido a presença abundante de água estagnada, ao maior índice pluviométrico, à imigração de muitas espécies serranas e a proximidade das sociedades tropicais do litoral catarinense. O terceiro fator, o mais importante de todos, é o talude do planalto: começando nas elevações areníticas ao sudoeste da Lagoa dos Barros, logo se recobre, em possança sempre crescente da capa eruptiva melafírica, com seus tabuleiros, chapadões, contrafortes, vales profundos, peraus de rocha cinzenta e paredões revestidos de flora rupestre”. (p. 44-45)

O litoral norte gaúcho apresenta uma heterogeneidade de paisagens, Neto & Basso (2005), dividem a região do litoral norte em 4 zonas agroecológicas:

“Zona 1 (lagoas): região com relevo suavemente ondulado próximo as encostas e plano nas margens das lagoas. O solo é arenoso e várias áreas são alagadas. A cobertura vegetal compõe-se de arbustos, pastagens e plantas aquáticas. Esta região está ocupada com pequenos sítios de lazer e comunidades de pescadores que realizam pesca artesanal nas lagoas. Culturas de subsistência (milho, mandioca e feijão) e uma pecuária mista (leite e corte) são as atividades mais presentes nas propriedades.

Zona 2 (encostas): a topografia é declivosa na encosta dos morros e ondulada no limite da zona 1. A rodovia BR 101 divide a encosta da região de relevo ondulado. O solo é litológico com bastante presença de pedras dificultando a mecanização. A cobertura vegetal é típica da Mata Atlântica (quaresmeiras, figueiras, juçaras, bromélias, e samambaias), a principal cultura presente é a bananeira, que se encontra implantada na meia encosta dos morros.

Zona 3 (morros): a topografia nesta região íngreme é de difícil acesso. O solo apesar de possuir uma coloração escura devido à matéria orgânica, tem um aspecto arenoso e em algumas parcelas possui menor teor de areia. As principais atividades são as de subsistência associada à fruticultura e/ou exploração de samambaias. A fruticultura é composta basicamente pela produção de laranjas e alguma produção de uva. Ainda que em menor proporção observa-se outras culturas como figo, pêssego e banana. O número de propriedades é pequeno e em sua maioria muito pobres. A área útil das propriedades normalmente é pequena e o restante da

área permanece coberto pela vegetação típica da Mata Atlântica e em muitos casos em estado de regeneração.

Zona 4 (várzeas do rio Maquiné e seus afluentes): a topografia nesta região é plana e o solo é mais argiloso. O número de propriedades é maior e estas são mais capitalizadas em relação às outras zonas. O rio Maquiné e seus afluentes são fornecedores de água para a irrigação das hortaliças, as quais constituem em um das principais atividades agrícolas produzidas nessa microrregião. a produção de mudas é feitas em estufas e o cultivo das hortaliças é realizado no campo.”(p.207-208)

A pesquisa será desenvolvida nas zonas da encosta (2) e dos morros (3), onde se localiza a maior concentração dos plantios de banana.

### **2.2.1 Aspectos Geobotânicos da Escarpa Atlântica e Litoral Norte**

O Inventário Florestal Contínuo do Rio Grande do Sul (Rio grande Do Sul, 2002), ao abordar os aspectos geobotânicos no seu resultando, traz a seguinte caracterização da região da Escarpa Atlântica e Litoral Norte do Rio Grande do Sul:

A ocorrência de rochas vulcânicas, que podem atingir altitudes superiores a 1.000 metros, afetadas por eventos tectônicos de grande envergadura, controla a presença de uma expressiva escarpa, com marcante contraste com os depósitos de sedimentos costeiros do litoral.

O terço inferior dessa escarpa evidencia a presença de arenitos da Formação Botucatu, sempre cobertos por rocha basáltica, caracterizando o caso de Torres como um testemunho da envergadura regional dos falhamentos que influenciaram nos processos geomorfológicos.

Existe significativa contribuição de água subterrânea, a partir de áreas do planalto, que se manifestam nas lagoas costeiras, em função da presença de lineamentos tectônicos aquíferos.

O meio físico, condicionado pelas feições acima mencionadas, proporciona a presença de uma floresta subtropical (Mata Atlântica), muito rica em biodiversidade, que ocupa parte da planície sedimentar e se distribui de forma irregular ao longo da parte inferior da escarpa.

Na borda superior da escarpa se manifestam ocorrências de matas nebulares sob influência das baixas temperaturas e persistência de altíssimos teores de umidade na atmosfera e no solo.

## **2.3 Bananicultura**

A maior parte das pesquisas históricas indica a origem das espécies comestíveis de banana predominantemente no sudeste asiático, nas regiões que hoje compreendem Filipinas, Malásia e Indonésia. Há evidências do cultivo da fruta em Papua Nova Guiné entre 5.000 e 10.000 a.C., o que caracterizaria sua população como a pioneira na plantação de bananeiras. Por meio do comércio estabelecido principalmente por árabes e persas entre a Índia e o norte da Austrália no decorrer dos séculos V e VI, a banana se espalhou significativamente pelo sul do continente asiático e chegou a diversas ilhas do Pacífico, incluindo o Havaí, junto com o deslocamento da população polinésia. A África Ocidental recebeu suas primeiras mudas cultivadas há mais de três mil anos, apesar de ainda não haver consenso com relação aos responsáveis por esse transporte (Langhe, 1995).

As navegações portuguesas e espanholas no século XV foram as responsáveis pela rápida disseminação da bananeira na América, onde encontrou condições climáticas notáveis para seu desenvolvimento (Morton, 1987).

Embora a grande maioria dos autores considere que a banana foi introduzida nas Américas pelos portugueses, Moreira (1987) apud Lima (2005) afirma que, apesar de os primeiros registros escritos a respeito da fruta no território brasileiro datarem de 1570, existiriam fortes evidências de que os índios já a cultivavam mesmo antes da chegada dos portugueses. Entretanto, foi somente com a vinda dos europeus que os plantios se estenderam desde as frias encostas rio-grandenses até a foz do Amazonas. A primeira coleção de bananeiras no Brasil data de 1925, quando o agrônomo Felisberto Cardoso de Camargo a inicia com 12 Variedades, no Instituto Agrônomo de Campinas (IAC). Em 1931 ocorrem os primeiros experimentos de fertilizantes em bananeiras, e em 1948 surge o primeiro híbrido de bananeiras no país.

### **2.3.1 Bananas no Rio Grande do Sul**

O Rio Grande do Sul possui apenas 1,6% da produção nacional de banana. No Estado, a produção é de 107.234 toneladas e concentra-se na região do Litoral do Estado com 89,2% do total. Os municípios de Três Cachoeiras, com 37.277 toneladas, Morrinhos do Sul, com

22.770 toneladas e Mampituba, com 16.082 toneladas, são os maiores produtores, contribuindo com 71% da produção gaúcha. (SEPLAG / RS, 2008).

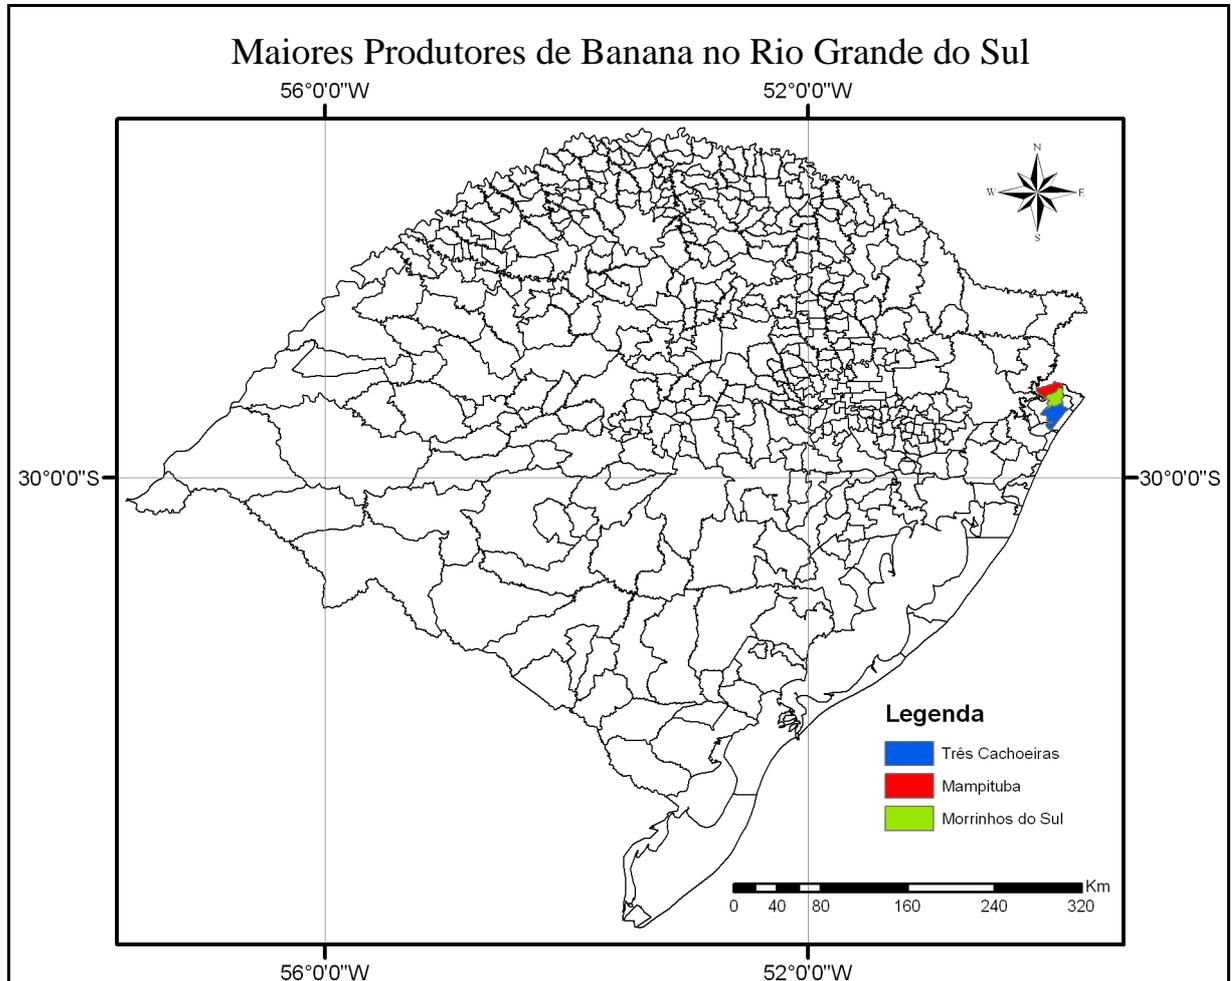


Figura 3. Mapa do Rio Grande do Sul com os três municípios com maior produção de banana. Fonte: Atlas socioeconômico do Rio Grande do Sul (2007).

Neto & Basso (2005) destacam que o cultivo da banana foi introduzido no período entre 1870 e 1950 no Rio Grande do Sul. Durante a década de 50 com a construção da BR-101, a região de Maquiné (no Litoral Norte Gaúcho) passa por um período de expansão das atividades agrícolas. A banana prata, produto de maior valor comercial é introduzida na região. No período de 1960 a 1980 há um incremento da produção de banana prata na região da encosta. Durante os anos 80, a cultura da banana se expande na zona da encosta, ocupando terras que eram até então utilizadas para o plantio da cana e que originalmente tinham sido de Mata Atlântica.

O cultivo da banana ocupa predominantemente as vertentes da formação Serra Geral, num enclave limítrofe à Planície Costeira. O relevo apresenta-se muito irregular, como resultado da dissecação e da drenagem que geraram encostas, vales, pequenas várzeas e altas declividades, ocupadas originalmente por florestas de Mata Atlântica. Os solos submontanos são argilosos, provenientes da decomposição do basalto. Todas essas características convergem em condições favoráveis ao cultivo da banana (Wives, 2008).

## **2.4 Sensoriamento Remoto**

Sensoriamento remoto é a arte e a ciência de obter informações sobre um objeto sem estar em contato físico direto com o mesmo. O sensoriamento remoto pode ser usado para medir e monitorar importantes características biofísicas e atividades humanas na Terra (Jensen, 2009).

Para Florenzano (2002) o sensoriamento remoto é a tecnologia que permite obter imagens e outros tipos de dados, da superfície terrestre, através da captação e do registro da energia refletida ou emitida pela superfície. O termo sensoriamento refere-se à obtenção dos dados e, remoto, que significa distante, é utilizado para a obtenção que é feita à distância, ou seja, sem o contato físico entre o sensor e a superfície terrestre.

### **2.4.1 Sensoriamento Remoto Hiperespectral**

O processo de aquisição de imagens em centenas de bandas registradas e contíguas, de forma a possibilitar que para cada pixel das mesmas seja possível derivar uma curva de reflectância espectral completa, recebe as denominações de ‘espectroscopia de imageamento’ (*imaging spectroscopy*) ou ‘sensoriamento remoto hiperespectral’ (*hyperspectral remote sensing*). O objetivo do sensoriamento remoto hiperespectral é medir, quantitativamente, a assinatura espectral dos componentes do sistema Terra, a partir de espectros calibrados,

adquiridos na forma de imagens, para uso em aplicações de sensoriamento remoto. (INFOGEO, 2004).

Os dados produzidos pelos espectrômetros são diferentes dos gerados pelos instrumentos multiespectrais, devido ao enorme número de bandas registradas – orientado para o termo Hiperespectral. Para uma dada área geográfica imageada, os dados produzidos podem ser vistos como um cubo, como mostrado na Figura 4, tendo duas dimensões que representam a posição espacial e uma que representa a reflectância em determinado intervalo de comprimento de onda (Richard & Jia, 1998).

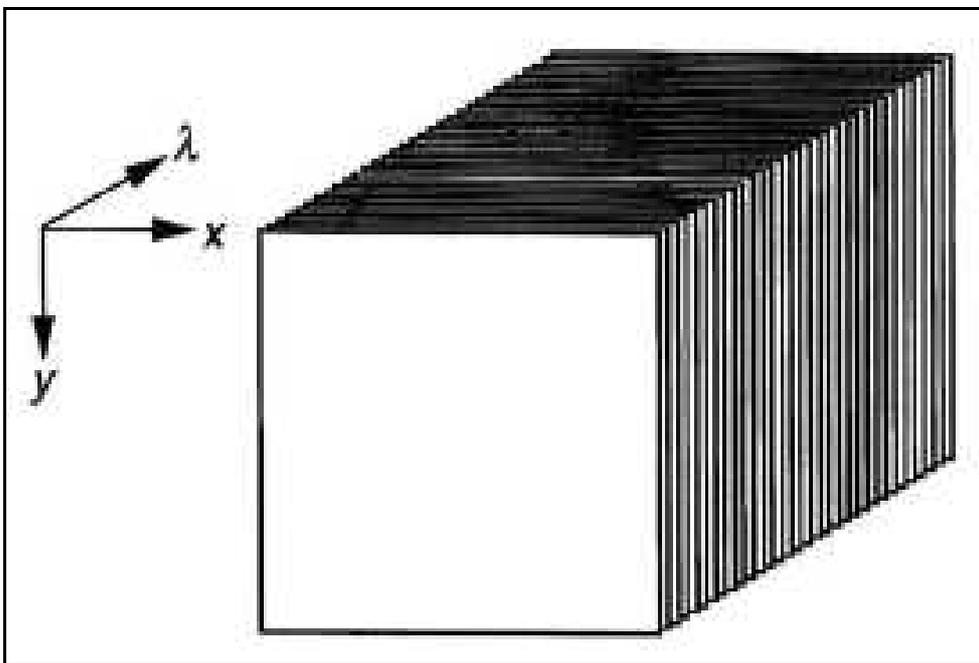


Figura 4. Cubo hiperespectral de dados de imagem, como registrado por um espectrômetro de imagem. Fonte: Richards & Jia (1998).

A aquisição de imagens em diversos comprimentos de onda permite a confecção de espectros de reflectâncias quase que contínuas para a caracterização dos elementos que formam a paisagem. Desta maneira, o sensoriamento remoto hiperespectral, também denominado espectroscopia de imageamento, consiste na aquisição simultânea de imagens em centenas de bandas (com intervalos na ordem de 10 nm) contíguas, permitindo a extração de um espectro detalhado para cada elemento de cena (pixel) da imagem, com base em características de reflectância (Goetz et al., 1985, apud Linn, 2008).

O *United States Geological Survey* (USGS) destaca que as imagens hiperespectrais possuem várias aplicações. Podem ser utilizadas em mineração, geologia, silvicultura,

agricultura e gestão ambiental. A detalhada classificação dos bens da Terra através do sensor hiperespectral denominado Hyperion permite a exploração mineral mais precisa, melhores previsões e avaliações de rendimento das culturas e melhor controle de mapeamento (USGS, 2010).

A espectroscopia de reflectância é uma técnica analítica, que usa energia eletromagnética refletida pelos materiais nas regiões espectrais do visível-infravermelho próximo (VNIR) e infravermelho de ondas curtas (SWIR), com o objetivo de obter informações sobre a composição mineralógica e química dos materiais (Clark, 1999). Certos átomos ou moléculas absorvem energia em função de suas estruturas atômicas, manifestando-se na forma de feições de absorção nos espectros de reflectância, também chamados de curvas de reflectância espectral (Ducart, 2004).

Conforme Curran et al. (2001), a partir de meados da década de 1980, o sensoriamento remoto hiperespectral (sensores com bandas espectrais estreitas localizadas em posições específicas do espectro) obteve expressivo avanço tecnológico, aumentando a habilidade humana de mapear atributos de vegetação. O uso destes instrumentos possibilita a aquisição de dados com resolução espectral suficiente para reconstituir bandas de absorção, as quais apresentam o potencial de fornecer informações sobre os conteúdos de componentes bioquímicos de dosséis vegetais (Tisot, 2009).

## **2.5 O Sensor Hyperion/EO-1**

O sensor Hyperion está a bordo do satélite *Earth Observing One* (EO-1), que foi lançado em 21 de novembro de 2000. Ele representa uma nova geração de sensores que fornece uma nova classe de dados de observação, para a melhor caracterização da superfície terrestre (USGS, 2010).

O Hyperion/EO-1 é o primeiro sensor hiperespectral em nível orbital, adquirindo dados de 400 a 2500 nm em bandas estreitas e contíguas de 10 nm de resolução espectral e 30 m de resolução espacial. O sistema opera por varredura “*pushbroom*” e contém um único telescópio e dois espectrorradiômetros imageadores (um operando no visível e infravermelho próximo (VNIR), e o outro no infravermelho de ondas curtas SWIR). Um filtro dicróico

direciona as bandas de 400 a 1000 nm para um espectrorradiômetro e as bandas de 900 a 2500 nm, para o outro. Os espectrorradiômetros se sobrepõem de 900 a 1000 nm, permitindo a intercalibração entre eles. A largura da faixa imageada é de 7,7 Km. Cada cena possui 242 bandas, das quais 196 são radiometricamente calibradas. Os dados são quantificados em 16 bits (Ungar et al., 2003).

Segundo Galvão et al. (2005):

O uso do sensor Hyperion possibilita a aquisição de dados com resolução espectral suficiente para reconstruir bandas de absorção nos espectros dos pixels relacionadas com o conteúdo de clorofila, teor de água nas folhas e feições de lignina e celulose, as quais podem ser parâmetros importantes na diferenciação de tipologias vegetais. Por outro lado, a pobre relação sinal-ruído (SNR) do sensor, especialmente no SWIR, é um obstáculo para a medição adequada dessas feições sem a interferência de ruídos.

Existem diversos estudos com a utilização dos dados hiperespectrais do Hyperion, por exemplo, para a diferenciação de tipos de cana-de-açúcar e a estimativa de produtividade de soja. Destacamos aqui os trabalhos de Galvão, Formaggio, Tisot (2005) e Galvão, Formaggio, Breunig (2009).

## **2.6 Comportamento Espectral da Vegetação**

Conforme destaca Novo (1992), para que possamos extrair informações a partir de dados de sensoriamento remoto, é fundamental o conhecimento do comportamento espectral dos objetos da superfície terrestre e dos fatores que interferem neste comportamento.

O termo comportamento espectral da vegetação é freqüentemente utilizado para representar as características de reflectância da radiação eletromagnética pelas folhas, plantas individuais e conjunto de plantas, embora a caracterização do comportamento espectral de um alvo esteja associada aos processos de reflexão, transmissão e absorção (Ponzoni, 2001).

A curva espectral da vegetação no caso da vegetação verde sadia se caracteriza pela intensa absorção da radiação eletromagnética nas regiões do azul e do vermelho (devido à clorofila) e pela intensa reflexão na faixa do infravermelho (IV) próximo (causada pela

estrutura foliar) (Linn, 2008). Esta intensa refletância decresce em direção ao infravermelho médio, conforme o aumento do comprimento de onda, e apresenta dois grandes picos de absorção nos comprimentos de onda do 1,9 e 2,5 micrometros, devido ao conteúdo de água, conforme Figura 5.

Como a folha é o principal elemento de interação da energia eletromagnética com a vegetação, o exame do comportamento espectral de uma folha sadia auxiliará o entendimento dos fatores que influenciam no comportamento espectral dos alvos de vegetação, em imagens hiperespectrais. Segundo Gates et al. (1965), apud Moreira (2003), são três os principais fatores que influenciam a quantidade de energia eletromagnética refletida pelas folhas: pigmentos, espaços ocupados pela água e pelo ar, e estrutura celular com dimensões de comprimento de onda da região incidente (grãos de amido, mitocôndrias, ribossomos, núcleo e outros plastídios). Além desses três fatores, existem outros que afetam a energia refletida pelas folhas, como conteúdo de água, maturação ou idade da folha, posição nodal, condições de iluminação, pubescência e senescência.

Segundo Moreira (2003), uma pequena quantidade de luz é refletida pelas células da camada superficial; a maior parte é transmitida para o mesófilo esponjoso onde os raios incidem frequentemente nas paredes celulares, sendo refletidos se os ângulos de incidência da radiação forem suficientemente grandes. Dado o grande número de paredes celulares dentro da folha, alguns raios são refletidos de volta na direção da fonte de energias incidente, enquanto outros são transmitidos através da folha.

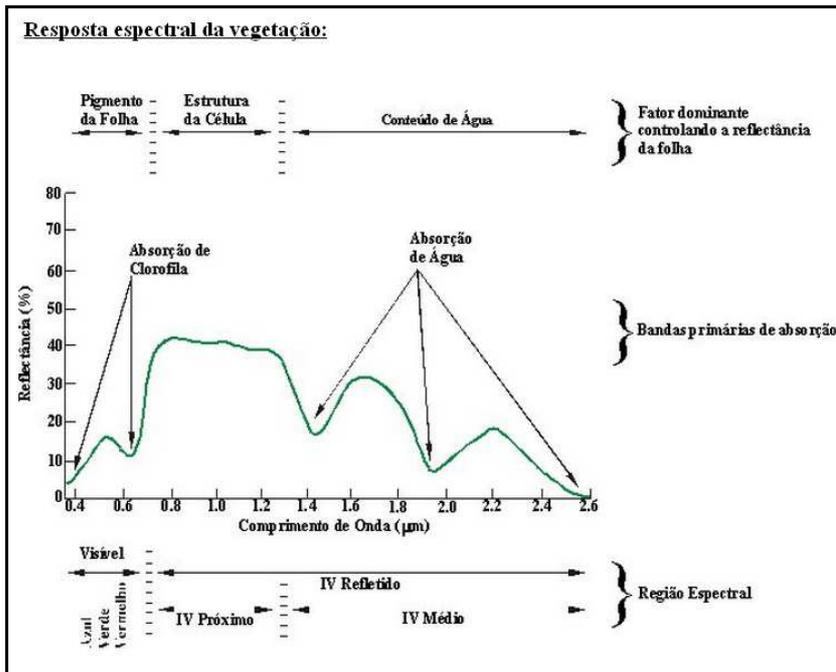


Figura 5. Curva teórica do comportamento espectral da vegetação e os fatores que controlam a sua reflectância.

Fonte: [http://www.fgel.uerj.br/labgis/gis\\_atualizada/sensoriamento/espectro.html](http://www.fgel.uerj.br/labgis/gis_atualizada/sensoriamento/espectro.html)

A resposta espectral da vegetação à incidência da radiação eletromagnética, na faixa espectral compreendida entre o comprimento de onda de 400 a 2600 nm, demonstra uma curva bastante característica, conforme mostrado na Figura 5. Este intervalo de comprimento de onda foi dividido por Ponzoni & Shimabukuro (2007) em três partes, descritas como:

a) Região do visível (0,4 - 0,72 µm): neste intervalo os pigmentos existentes na folha dominam a reflectância, sendo, portanto, responsáveis pela forma da curva nessa região espectral. Estes pigmentos geralmente encontrados nos cloroplastos são: clorofila (65%), caroteno (6%) e xantofilas (29%). Os valores percentuais destes pigmentos existentes podem variar intensamente de espécies para espécies. A energia radiante interage com a estrutura foliar por absorção e por espalhamento. A energia é absorvida seletivamente pela clorofila e convertida em calor ou fluorescência, e também, convertida fotoquimicamente em energia armazenada na forma de componentes orgânicos através de fotossíntese. Os pigmentos predominantes absorvem radiação na região do azul (próximo a 0,445µm), mas somente a clorofila absorve na região do vermelho (0,645 µm). A maioria das plantas são moderadamente transparentes na região do verde (0,540 µm);

b) Região do infravermelho próximo (0,725-1,10 µm): neste intervalo ocorre pequena radiação e considerável espalhamento interno da radiação da folha. A absorção da água é geralmente baixa, enquanto que a reflectância é quase constante;

c) Região do infravermelho médio (1,10-3,20µm): a absorção devido à água líquida intrafoliar afeta a reflectância das folhas na região do infravermelho médio. Considerando a água líquida, esta apresenta na região

em torno de 2,0  $\mu\text{m}$ , fatores de reflectância geralmente pequenos. A água absorve consideravelmente a radiação incidente na região espectral compreendida entre 1,3 $\mu\text{m}$  a 2,0 $\mu\text{m}$ . Mais precisamente, nos comprimentos de onda de 1,45  $\mu\text{m}$ , 1,95 e 2,7 $\mu\text{m}$ , bandas de absorção podem ser observadas.(p.)

Analisando-se ainda a Figura 5, podemos identificar a região de inflexão na faixa de transição dos comprimentos de onda do visível para o infravermelho. Esta faixa é denominada de borda vermelha (*red edge*). A borda vermelha é talvez a feição espectral mais estudada na curva da resposta espectral da vegetação e com maior sensibilidade ao estresse. Ela é o ponto de máxima inflexão entre a baixa reflectância no vermelho, devido à absorção pela clorofila, e a alta reflectância em torno de 800 nm, associada com a estrutura interna das folhas e teor de água (Kumar et al., 2001).

Na região do visível, a reflectância diminui com o aumento da camada de folhas, e na região do infravermelho próximo, a reflectância aumenta com o aumento do número de camadas. Mas essas dinâmicas não apresentam variações lineares, ou seja, a diminuição da reflectância na região do visível, com a adição da segunda camada de folhas, não apresentará a mesma dimensão quando for acrescida uma terceira camada, e o mesmo acontecerá com o acréscimo de uma quarta camada, e assim por diante. Na região do infravermelho, analogamente, o aumento da reflectância com a adição de camadas também não será linear e apresentará acréscimos sempre menores à medida que forem adicionadas camadas adicionais de folhas. Esse fenômeno comprova o caráter assintótico da reflectância de dosséis, também conhecido como reflectância infinita (Ponzoni & Shimabukuro, 2007).

Os estudos envolvendo a reflectância espectral de dosséis têm se desenvolvido, na sua maioria, motivados pela necessidade de se relacionar os níveis de cinza das imagens às diferentes tipologias vegetais e seus parâmetros biofísicos e bioquímicos. Isto pode ser feito desde que a natureza da alteração da radiação por parâmetros da vegetação e fatores ambientais seja entendida e especificada (GOEL, 1988).

O destino da radiação eletromagnética que incide num dossel vegetativo depende de suas características, como comprimento de onda e ângulo de incidência, além das características do dossel e, em última análise, das folhas que o compõem.

Em se tratando de culturas agrícolas, Richardson et al. (1975); Kollenkark et al. (1982) apud Linn (2008), comentaram que os dosséis de cultura exibem, no campo de visada

do sensor, quatro componentes com diferentes propriedades de reflectância óptica: vegetação iluminada, solo iluminado, vegetação sombreada e solo sombreado. A magnitude de cada um desses componentes varia com a cobertura vegetal, orientação e espaçamento das fileiras, morfologia do dossel, estrutura interna dos elementos que compõem o dossel, diâmetro da copa da planta, altura, teor de água na planta e no solo, condição fitossanitária, ângulo zenital e azimute do sol, latitude e tamanho do elemento de resolução do equipamento utilizado.

Goel (1988) mencionou que a radiação solar incidente sobre um dossel é espalhada e refletida, tendo sua direção e composição espectral alteradas de maneira bastante complexa. Essa alteração é causada tanto por parâmetros inerentes ao próprio dossel quanto por fatores ambientais.

## **2.7 Condicionantes Topográficos da Paisagem**

A topografia ao lado de outras variáveis ambientais é fundamental na caracterização da paisagem local e regional. Diversos estudos têm relacionado variáveis topográficas com o estabelecimento, distribuição e diversidades de espécies vegetais.

Um destes estudos foi realizado por Bispo (2007), que utilizou variáveis topográficas extraídas de Modelos Digitais de Elevação (MDE) para caracterização da paisagem. Em seu estudo foram utilizadas as seguintes variáveis topográficas:

- a) Elevação: corresponde a altitude do terreno. Está relacionada à distribuição vertical do solo e clima, condicionando diferentes padrões vegetativos na paisagem.
- b) Declividade: corresponde ao ângulo de inclinação da superfície local. Possui ação direta sobre o equilíbrio entre a infiltração de água no solo e escoamento superficial, além de controlar a intensidade dos fluxos de matéria e insolação. Esse conjunto de fatores resulta na formação de ambientes com diferentes características físicas e biológicas, as quais permitem o estabelecimento de diferentes tipos de vegetação.
- c) Orientação de vertentes: corresponde ao alinhamento do terreno em relação ao sol, é a medida do ângulo horizontal da direção esperada do escoamento superficial, geralmente expressa em azimute. Dentre os vários aspectos (relação com distribuição de diferentes substratos, refúgios ecológicos etc.), esta variável relaciona-se ao grau de sombreamento ou iluminação do terreno, selecionando ambientes mais propícios para o desenvolvimento de determinados tipos de vegetação em detrimento de outros. Assim, a orientação de vertentes controla a direção

dos fluxos de matéria e insolação, portanto, com efeitos locais sobre os regimes hídricos e de energia, definindo diferentes padrões vegetativos.

d) Curvatura vertical: refere-se ao caráter convexo/côncavo do terreno quando analisado em perfil.

e) Curvatura horizontal: refere-se ao caráter divergente/convergente dos fluxos de matéria sobre o terreno quando analisado em projeção horizontal.

As variáveis (d) e (e) estão relacionadas aos processos de migração e acúmulo de água, minerais e materiais orgânicos no solo através da superfície, proporcionados pela gravidade. Estas duas variáveis combinadas representam uma caracterização das formas do terreno, que se associam diretamente a propriedades hidrológicas e de transporte, exercendo influência indireta sobre a vegetação local.

São reconhecidos os efeitos principais da topografia no estabelecimento da vegetação, ao lado da ação do clima, da geologia, dos solos e da intervenção antrópica. A variabilidade topográfica induz a uma diversidade de fauna e flora significativa no ecossistema. O desenvolvimento deste é controlado, ainda, por fatores abióticos, tais como disponibilidade de água, temperatura e incidência de radiação (Bispo, 2007).

## **2.8. Classificação Digital de Imagens**

A classificação digital de imagens visa reconhecer padrões e alvos homogêneos com o objetivo de mapear os diferentes componentes da superfície terrestre. O resultado final da classificação de uma imagem é um mapa temático, no qual os pixels classificados são representados por cores. Cada cor é associada a uma classe (área urbana, tipo de vegetação, etc.) definida previamente pelo usuário (Câmara, 2001 apud Portillo, 2007).

As diferentes classes de cobertura terrestre têm propriedades de reflectância distintos, porém algumas destas classes possuem propriedades de reflectância que se assemelham ou se sobrepõem, dificultando a separação das mesmas. Dessa forma, a maioria dos métodos de classificação se propõe a avaliar a semelhança de padrões espectrais usando alguma medida da distância entre pixels do espaço espectral (Noguchi, 2004).

As técnicas em que o critério de decisão depende da distribuição de valores de pixel, em várias bandas espectrais, são definidas como técnicas de classificação multiespectral (Novo, 2008), sendo este o método mais frequentemente utilizado na extração de informações de imagens de sensoriamento remoto (Richards, 1998).

Na classificação multiespectral, os vetores de valores digitais para cada pixel são comparados, e os pixels com valores similares, segundo uma regra de decisão, tendem a ser associados a uma classe (Novo, 2008). Cada pixel da imagem original é classificado dentro de uma das diversas classes, mostrando a distribuição geográfica de um tema. As técnicas de classificação podem ser divididas em: classificação supervisionada e classificação não supervisionada.

Classificação supervisionada é um método de classificação de imagens que depende de informações provenientes do analista e permite analisar e identificar as diferenças de reflectância nas imagens, permitindo a identificação das feições (classes) presentes na cena. Na classificação supervisionada são utilizados algoritmos para nomear os pixels em uma imagem de forma a representar tipos específicos de cobertura terrestre, ou classes que são conhecidas a priori (Richards, 1998).

Usualmente, a classificação digital de imagens multiespectrais é realizada através de classificadores que se baseiam no Teorema de Bayes. Os classificadores Bayesianos são ditos ótimos no sentido de que minimizam a probabilidade de erro, quando as hipóteses sobre as distribuições de probabilidade são corretas para as diversas classes (alvos/feições) existentes na imagem.

### **2.8.1 Classificador de Bayes**

Os classificadores de Bayes baseiam-se nos histogramas das classes para aproximar funções de densidade de probabilidade que seguem o padrão normal de distribuição, também conhecido como distribuição gaussiana.

$$p(\omega_i | x) = \frac{p(x | \omega_i) \cdot P(\omega_i)}{p(X)}$$

Eq. 1

Onde:

$P(\omega_i | x)$  – *probabilidade a posteriori*, representa a probabilidade de um dado pixel X pertencer à classe  $\omega_i$ .

$p(x | \omega_i)$  – função densidade de probabilidade condicional à classe  $\omega_i$ . Representa a distribuição de probabilidades interna na classe  $\omega_i$ . Os parâmetros associados à esta função de probabilidade podem ser estimados através das amostras de treinamento.

$P(\omega_i)$  – denominada de *probabilidade a priori*, representa a probabilidade de ocorrência da classe  $\omega_i$ , na cena sendo analisada.

$p(X)$  – probabilidade de encontrar um pixel de qualquer classe na posição X.

O classificador de Bayes visa minimizar o risco de erro na tomada de decisão, considerando a probabilidade do pixel pertencer a uma das classes de treinamento, em função da probabilidade à priori daquela classe ocorrer na cena e também da covariância entre as bandas espectrais nas classes.

Do classificador de Bayes são derivados os classificadores de Máxima Verossimilhança, o Linear de Fisher e a Distância Euclidiana. Nestes classificadores são implementadas simplificações na regra de decisão.

### 2.8.1.1 Máxima Verossimilhança

Máxima Verossimilhança é o método mais comum de classificação supervisionada usado com dados de imagem de sensoriamento remoto, (Richards, 1998). Este método generaliza o classificador de Bayes, porque ele atribui que a probabilidade a priori de ocorrência de determinada classe é igual a de ocorrência em outras classes, resultando numa simplificação, já que o termo  $P(\omega_i)$  desaparece da fórmula do classificador.

O método de classificação de Máxima Verossimilhança considera a ponderação das distâncias entre médias dos níveis digitais das classes e o pixel, utilizando parâmetros estatísticos, ou seja, considerando a distribuição de probabilidade normal para cada classe.

Neste método é calculada a média dos níveis de cinza, a variância e a correlação de cada classe em cada banda, considerando que estes possuem normalmente distribuição gaussiana.

O classificador calcula estatisticamente a probabilidade de cada pixel pertencer a determinada classe no espaço de atributos, e é executado assumindo igual probabilidade de ocorrência para todas as classes. Porém, com o conhecimento a priori de que as probabilidades não são iguais para todas as classes, é possível especificar fatores de peso para classes particulares. Esta variante da regra de decisão é conhecida como regra de decisão Bayesiana.

A Máxima Verossimilhança iguala os pesos das probabilidades a priori das classes, devido ao fato de que na prática a função de probabilidade  $P(\omega_i / X)$  não é conhecida pelo analista. A função de decisão do classificador Máxima Verossimilhança está descrita na equação 2.

$$G_i(x) = P(x / \omega_i) \cdot P(\omega_i)$$

Eq. 2

Onde:

$G_i(X)$  = Função de decisão para a classe “i”;

$P(x/\omega_i)$  = Probabilidade de que o pixel pertença à classe “i” na gaussiana;

$P(\omega_i)$  = Probabilidade a priori.

### 2.8.1.2 Classificador Linear de Fisher

O classificador Linear de Fisher é um método estatístico utilizado para separar as classes de objetos (imagens) de um espaço original para um espaço transformado. A partir do espaço transformado, o classificador iguala as covariâncias entre as bandas espectrais, e aplica a função de decisão para a classificação. A proposta de classificador Linear de Fisher é separar amostras de grupos distintos através da transformação de seu espaço para outro que maximize a separação interclasses, enquanto minimiza as variâncias intraclasses. Então, o

objetivo do classificador é realizar a redução de dimensionalidade ao mesmo tempo em que preserva o máximo possível de informação discriminatória das classes.

O classificador Linear de Fisher, além de não considerar as probabilidades a priori de ocorrência das classes na cena, não considera as covariâncias das bandas espectrais, supondo que as matrizes de covariâncias são diagonais (covariâncias zeradas e iguais para todas as classes), omitindo a informação de quanto às bandas espectrais são correlacionadas entre si. A função de decisão do método de Fisher está descrito na equação 3.

$$G_{Fi}(X) \propto (X - \mu_i)^T \sum i^{-1} (X - \mu_i)$$

Eq. 3

### 2.8.1.3 Distância Euclidiana Mínima

O método de classificação por Distância Euclidiana baseia-se na distância em que o pixel “X” se encontra da média mais próxima de uma classe qualquer, no espaço original. Este classificador omite componentes como a probabilidade à priori de ocorrência do pixel “X” na cena, as informações de covariância entre as bandas espectrais e a correlação entre as classes.

O classificador Distância Euclidiana Mínima assume que as matrizes de covariância são iguais entre as diferentes bandas espectrais e também entre as classes amostradas, ponderando somente a média obtida para cada classe. Considera ainda as matrizes de covariância de todas as classes como diagonais e iguais, (Richards, 1998). A classificação de um novo pixel pelo método de Distância Mínima é obtida a partir da menor distância entre o pixel a ser classificado ( $X$ ) e os valores médios obtidos das amostras treinadas. Desta maneira, além das suposições realizadas pelos outros dois classificadores, este classificador utiliza variâncias iguais para todas as classes em qualquer banda multiespectral. Sendo assim, utiliza somente as médias das amostras (Distância Mínima Euclidiana em relação à média).

Na equação 4 está apresentada a função de decisão para a classificação por Distância Euclidiana Mínima, onde não são consideradas as componentes como probabilidade à priori

de ocorrência da classe, as covariâncias entre as bandas espectrais e a correlação entre as classes, apenas a distância do pixel “X” da média da classe é considerada.

$$G_{DEi}(X) \propto (X - \mu.i)^T . (X - \mu.i)$$

Eq. 4

## 2.9 Separabilidade entre Classes de Vegetação

A separação entre classes utilizando-se de classificadores digitais, como já visto anteriormente, necessita da seleção de amostras de treinamento para a caracterização espectral das classes. Nem sempre a amostra de uma classe de uso e ocupação do solo apresenta-se homogênea e com pouca variação espectral.

Richards (1998) destaca que na prática, os agrupamentos de classe informações não podem ser agregados isoladamente. Não é raro encontrar vários grupos para a mesma região de solo, para o mesmo tipo de vegetação aparente e assim sucessivamente para outros tipos de cobertura em uma cena. Estes não são somente resultados das diferenças específicas em vários tipos de cobertura, mas também resultados das diferenças no conteúdo de umidade, tipo dos solos, vegetação subjacente e influências topográficas. Por conseguinte, um espaço multi-espectral é mais provável que apareça como mostrado na Figura 6 em que cada classe de informação é visto como sendo composto de várias classes espectrais.

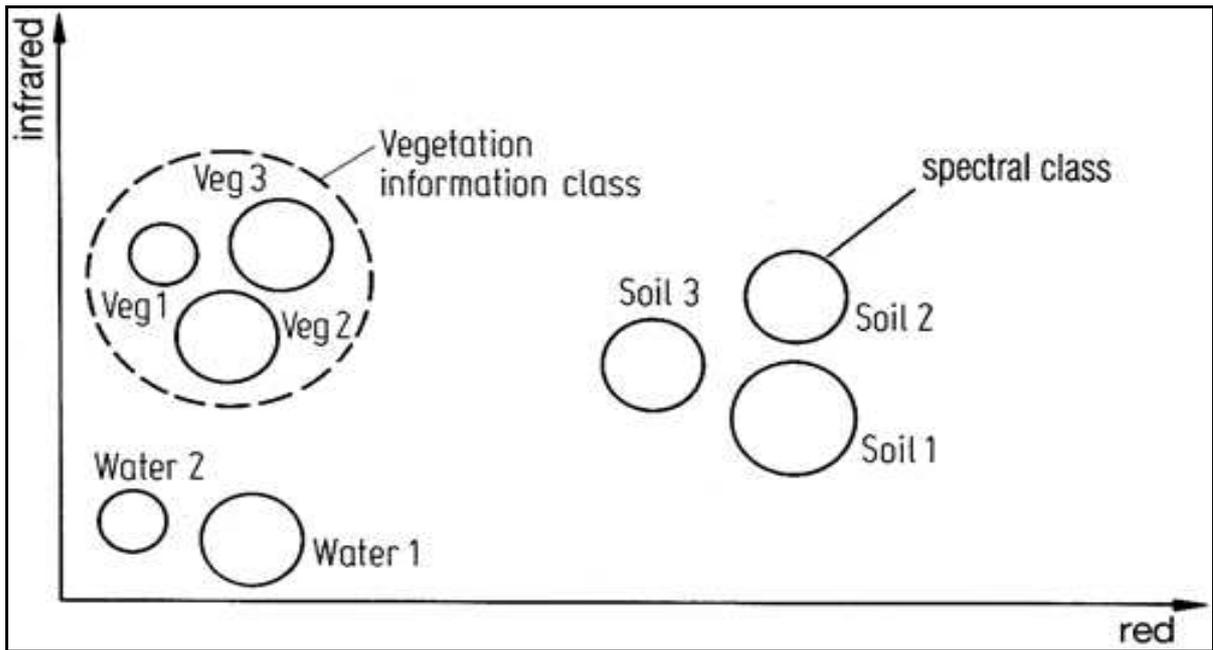


Figura 6: Representação das classes de informação por subconjuntos de classes espectrais.

Fonte: Richards, 1998

Porém, em muitos casos, as classes de informações de interesse não formam grupos distintos ou subgrupos, mas preferencialmente parte de um conjunto de dados contínuo no espaço multispectral. Isto acontece, por exemplo, quando existe um gradual fechamento do dossel, os sensores captam esta variação gradual da mistura entre o dossel e o sub-bosque. As classes de informação aqui poderão corresponder às misturas percentuais indicadas ao invés de conjuntos bem definidos de sub-classes, conforme ilustrado na figura. 3.6.

Ponzoni (2002) sobre comportamento espectral da vegetação ressalta que cada dossel, em particular, possui suas características próprias e desenvolve-se em diferentes tipos de solos sob diferentes condições ambientais. Não há como prever todas as possibilidades, tentar elencá-las, relacionando-as a possíveis padrões em imagens orbitais. Assim como acontece com qualquer outro objeto de estudo à luz das técnicas de sensoriamento remoto, são inerentes as chamadas ambigüidades nas quais efeitos de diferentes fatores/ parâmetros podem assumir valores iguais de radiância, o que implicará em uma “mesma” aparência nas imagens, mesmo em se tratando de diferentes coberturas vegetais. Cabe ao intérprete estar preparado para conviver com estas limitações e extrair dos produtos de sensoriamento remoto o máximo de informação confiável.

### 3 - MATERIAIS E MÉTODOS

Para alcançar os objetivos propostos neste trabalho foram utilizados os seguintes materiais e métodos:

#### 3.1 Materiais

Para análise do comportamento espectral das áreas de Mata Atlântica e de bananicultura foi utilizada uma imagem Hyperion, no nível de processamento L1R, imagem radiometricamente corrigida, mas sem correção geométrica. Os dados Hyperion utilizados, padrão HDF (*Hierarchical Data Format*), 16 bits, são compostos pelos valores inteiros de radiância. A data do imageamento utilizado foi 2 de maio de 2004. A imagem Hyperion apresenta 256 colunas por 3352 linhas, com resolução espacial nominal de 30 m, desta forma a largura e comprimento da imagem são de 7,68 km e 100,56 km respectivamente. Esta imagem possui 242 bandas, com amplitude variando, em média, de 10 nm entre os comprimentos de ondas.

Utilizou-se também no trabalho uma imagem do sensor IKONOS de alta resolução espacial (1 m). O dia da aquisição da imagem pelo sensor foi 07 de abril de 2004, a resolução radiométrica dos dados é de 8 bits e a imagem é composta pelas 3 bandas do visível.

Para o processamento digital da imagem foi utilizado o software *Environment For Visualizing Images*, - ENVI 4.5 - um sistema de processamento de imagem de sensoriamento remoto desenvolvido pela RSI (Research Systems Inc), distribuído pela SULSOFT. Outro software utilizado foi o MultiSpec, que é desenvolvido pela Universidade de Purdue.

Para o trabalho de campo foi utilizado um veículo da Universidade Federal do Rio Grande do Sul para visitar as áreas, assim como, receptores GPS de navegação da marca Garmin modelo 60 CS, cartas topográficas e um Laptop HP Pavilion dv2000.

### 3.2 Métodos

As etapas e a seqüência adotada na realização deste trabalho são apresentadas na Figura 7 e descritas na seqüência.

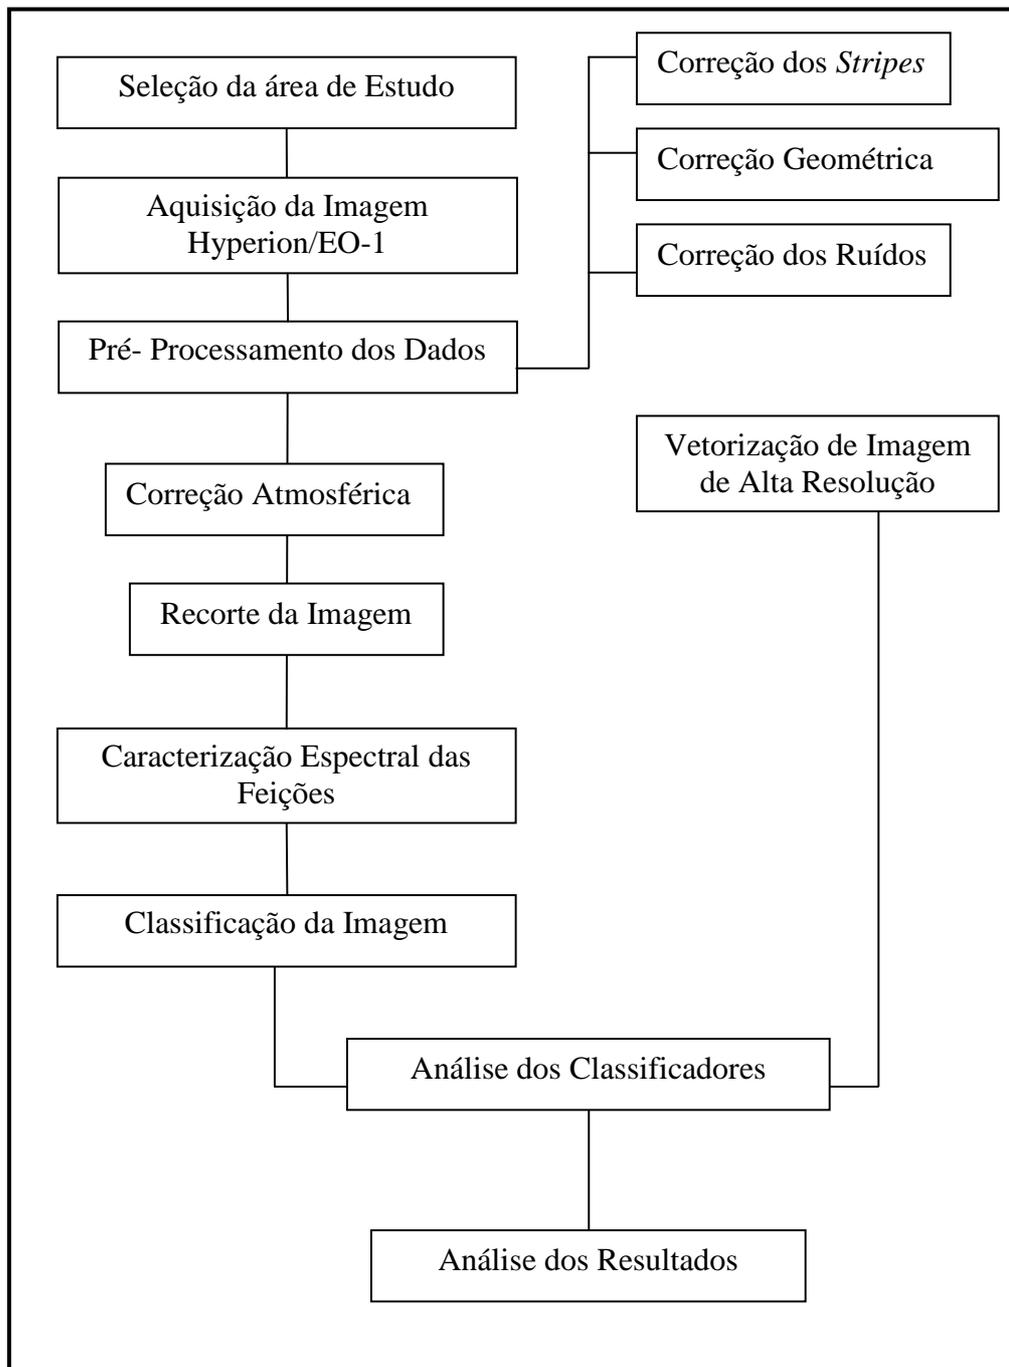


Figura 7: Fluxograma das etapas desenvolvidas ao longo do trabalho.

### 3.2.1 Seleção da Área de Estudo

A área de estudo foi selecionada com base na disponibilidade de imagens Hyperion / EO-1 em que houvesse o imageamento de áreas de Bananais e Mata Atlântica. Com base nesta característica foi selecionada a região do Litoral Norte do Rio Grande do Sul, mais precisamente a região Noroeste do Município de Três Cachoeiras, onde ocorre grande concentração de plantações de hortifrutigranjeiros, sendo a banana o cultivo predominante nas áreas das encostas dos morros da Serra Geral (Figura 8).

Desta forma o recorte espacial utilizado ficou definido entre as coordenadas  $50^{\circ} 01'$ ,  $29^{\circ} 29'$  e  $50^{\circ} 05'$ ,  $29^{\circ} 24'$  onde existe a predominância das características citados anteriormente para a realização deste estudo.

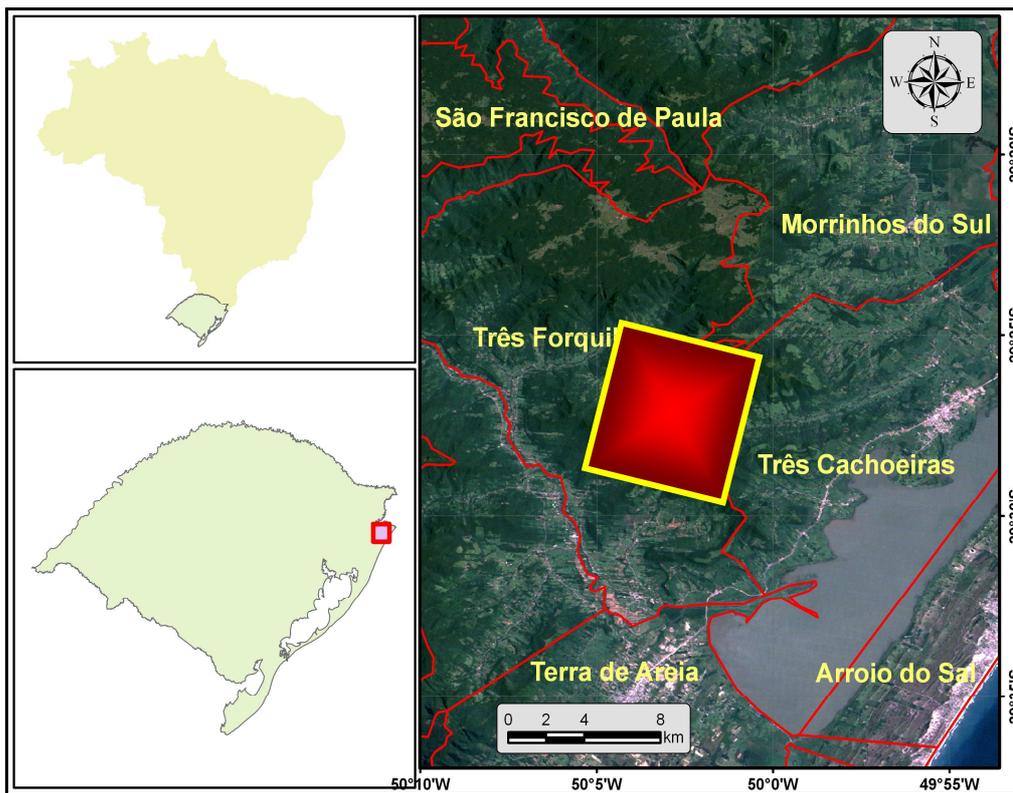


Figura 8: Mapa de localização da região da área de estudo.

### 3.2.2 Aquisição da Imagem Hyperion

A imagem hiperespectral do sensor Hyperion utilizada no trabalho estava disponibilizada no acervo de imagens do Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia da Universidade Federal do Rio Grande do Sul. Esta imagem está também disponível para download no site da USGS, através do GLOVIS (*Global Visualization Viewer*), (<http://glovis.usgs.gov>) ou pelo *EarthExplorer* (<http://edcsns17.cr.usgs.gov/EarthExplorer/>). O nome da imagem, disponível para download no site, utilizada neste trabalho foi: EO1H2200802004123110PZ.

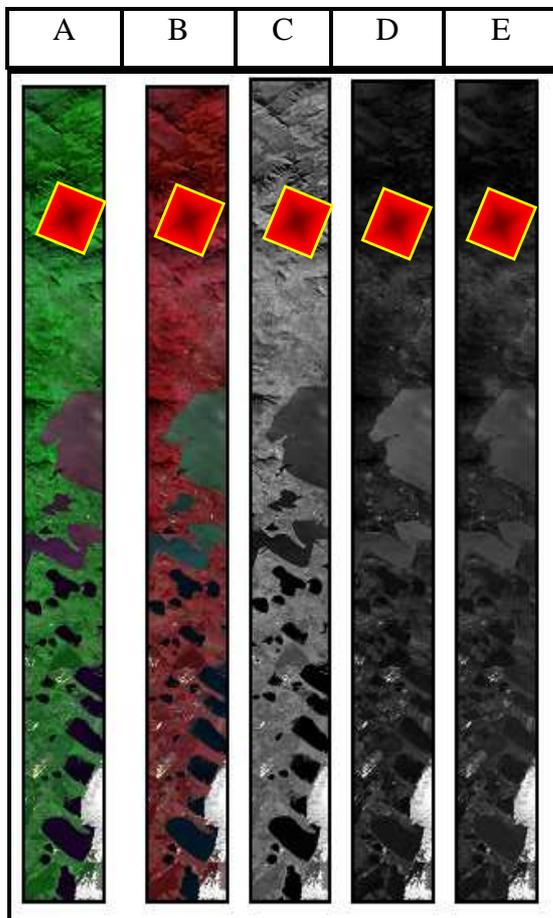


Figura. 9: Imagem Hyperion, composições (A) RGB 689nm, 791nm, 587nm e (B) RGB 791nm, 689nm, 587nm e as bandas separadas (C) 3791nm, (D) 689nm e (E) 587 respectivamente com a localização da área de estudo.

A figura 9 demonstra os diferentes aspectos da paisagem que a imagem selecionada recobre, desde as várias lagoas ao sul da imagem até a área de relevo mais acidentado, na parte norte, onde se localiza a área de estudo.

### 3.2.3 Trabalho de Campo

O trabalho de campo foi realizado para verificar as características ambientais da área, assim como para a identificação dos alvos a serem estudados no município de Três Cachoeiras. O trabalho de campo ocorreu entre os dias 27/08/2009 e 30/08/2009. A diferença entre as datas das imagens e o trabalho de campo se justifica, já que, a cultura da banana é perene e não ocorreram grandes modificações nas áreas plantadas no período. Este trabalho possibilitou compreender o desafio de diferenciar espectralmente as áreas de bananais das áreas ocupadas pela Mata Atlântica na região, considerando também as variáveis do relevo e a sua influência na resposta espectral dos alvos selecionados.

Na área de estudo ocorrem duas maneiras de plantio de banana. Uma com plantio de mudas em pequenas áreas entremeadas na mata nativa e outra como um monocultivo de banana em uma grande área.

Em decorrência da heterogeneidade vegetal nas pequenas áreas, ocorre o fenômeno conhecido como pixel mistura, que é a presença de mais de uma classe em um mesmo pixel. Este fenômeno influencia no valor de um pixel, pois é o resultado da integração da resposta espectral dos diversos alvos que o compõem.

O trabalho de campo também subsidiou a verificação do resultado da classificação, que foi realizada posteriormente, tendo em vista a extração de pontos de controle da ocorrência de mata nativa e bananais que auxiliaram na vetorização da imagem de alta resolução.

### 3.2.4. Pré-processamento da Imagem Hyperion

A imagem Hyperion foi pré-processada no software ENVI 4.5. Neste processamento foi realizada a conversão dos dados de L1R para o formato padrão do ENVI. Para isso foi utilizado um *plugin* disponibilizado no site da *ITT Visual Information Solutions*, ([www.ittvis.com](http://www.ittvis.com)), denominado de *Hyperion Tools*. Essa ferramenta tem as opções para o georreferenciamento da imagem a partir de um arquivo do tipo “.met”, correção dos *stripes*, que são linhas verticais onde os *pixels* apresentam valores errôneos, esta correção é feita por

meio da interpolação dos valores dos vizinhos horizontais. Também foi gerado um arquivo com os fatores de escala para utilização na correção atmosférica da mesma.

### 3.2.5 Correção Atmosférica

A correção atmosférica foi realizada no módulo *FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes)* do ENVI 4.5. Este módulo é baseado nos modelos de transferência radiativa MODTRAN-4 (*Moderate Resolution Transmittance Code*), (Felde et al., 2003). Desta maneira elimina-se os efeitos de espalhamento e absorção da radiação, ocasionados pela interação com a atmosfera. Os parâmetros utilizados para efetuar a correção atmosférica foram definidos com base nas informações da imagem e recomendações do distribuidor do software, SULSOFT ([http://www.envi.com.br/index.php?link=Atmospheric\\_Correction](http://www.envi.com.br/index.php?link=Atmospheric_Correction)), e estão descritos no Quadro 1.

<i>Input Radiance Image</i>	Imagem interpolada pelo Hyperion Tools
<i>Radiance Scale Factor</i>	Arquivo gerado a partir do Hyperion Tools
Latitude	-29.73329926
Longitude	-50.13330078
Sensor	Hyperion
Sensor altitude	705
<i>Ground Elevation</i>	0.3
Pixel	30
<i>DATA</i>	<i>May, 2, 2004</i>
<i>Flight Time GTM</i>	13:1:58
<i>Atmospheric model</i>	<i>Mid-Latitude Summer</i>
<i>Water retrieval</i>	<i>Yes</i>
<i>Water absorption Feature</i>	1135
<i>Aerosol models</i>	Rural

<i>Aerosol retrieval</i>	<i>None</i>
<i>Initial visibility</i>	40
<i>Spectral Polishing</i>	<i>No</i> (não temos um arquivo de definição espectrográfica)
<i>Wavelength recalibration</i>	<i>Yes</i>

Quadro 1. Parâmetros utilizados na correção atmosférica.

Após a correção atmosférica da imagem foi realizado um recorte da mesma priorizando as áreas com características mais acentuadas de plantio de bananas e Mata Atlântica Figura 10.

Desta maneira o recorte priorizou a região do vales a oeste do município de Três Cachoeiras, assim como uma parte do município limítrofe. A imagem resultante ficou com 60182 pixels.

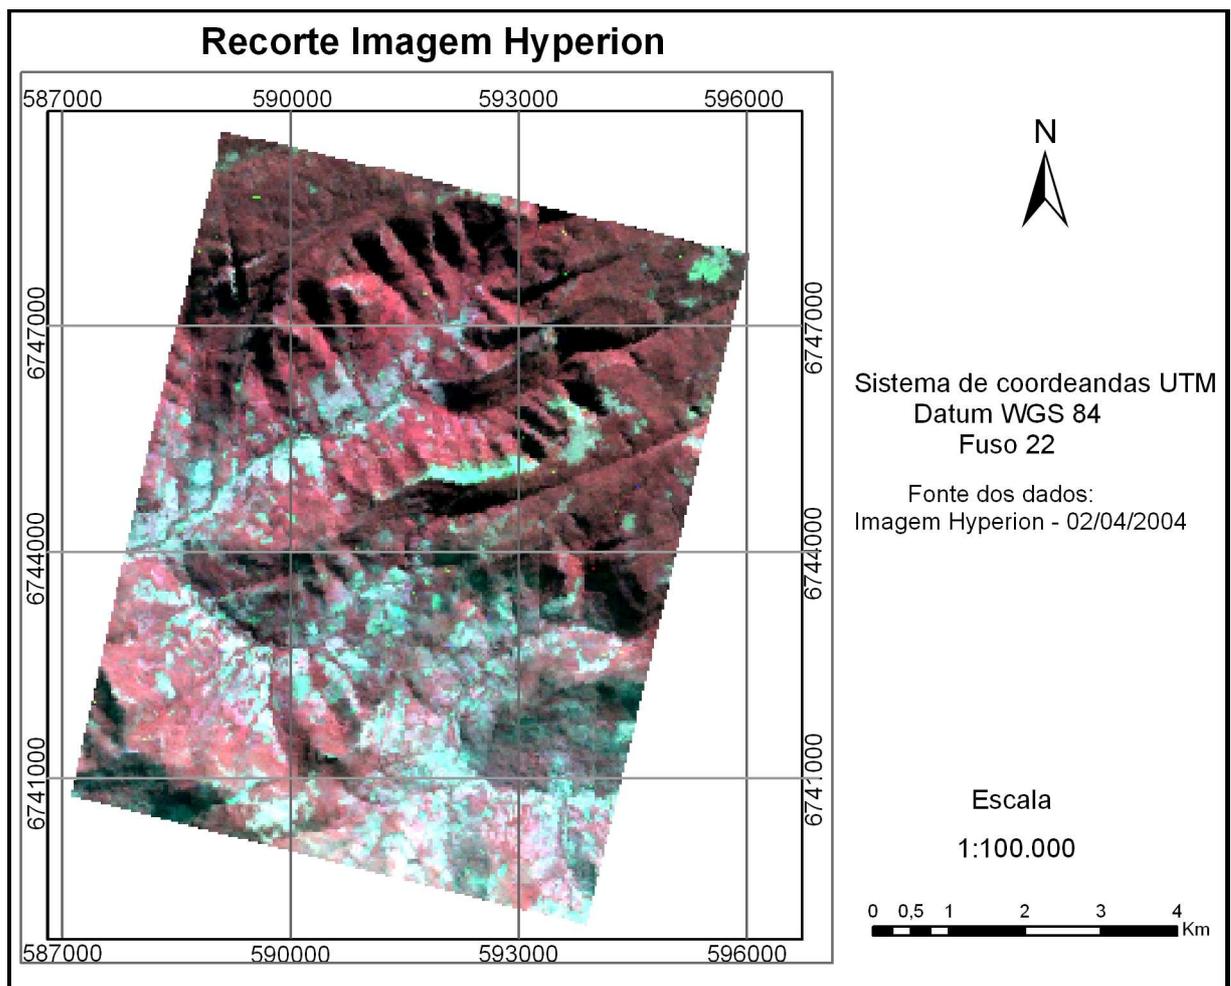


Figura. 10: Recorte da imagem Hyperion com correção atmosférica, composição colorida RGB 37, 27, 17, de 2 de Maio de 2004.

### 3.2.6 Caracterização Espectral das Feições

Para caracterização espectral foram definidas quatro classes de uso e ocupação do solo: Mata Atlântica, Banana, Campo e Sombra. As amostras selecionadas de cada classe foram utilizadas no treinamento dos classificadores para definição dos parâmetros de similaridade espectral. O total de pixels utilizados nos processos de classificação e seleção de feições foi de 511 pixels, com objetivo de caracterizar as quatro classes de usos e ocupação do solo presentes na área de estudo. O total de pixels em cada classe de uso do solo utilizado foi de acordo com o demonstrado na tabela 1.

Tabela 1: Número de pixels nas amostras das classes de uso do solo.

Classes de Uso e cobertura do Solo	Nº de pixels
Mata	129
Banana	135
Campo	51
Sombra	196

Este valor total de pixels é muito próximo ao total recomendado para a seleção de uma amostra representativa de uma população de 60182 (número de pixel da imagem), com base em um teste estatístico considerando um erro amostral de 4% e um nível de confiança de 95%. O teste estatístico de amostragem aleatória simples, com os parâmetros citados a cima, recomenda a seleção de 595 pixels para composição de uma amostra representativa que caracterize a área de estudo.

A seleção das amostras dos pixels foi realizada com base no reconhecimento feito no campo e também na verificação da mistura dos histogramas das classes, priorizando a menor sobreposição das áreas das classes, o que ocasionaria uma confusão no momento da classificação.

Também foi realizada uma amostragem das áreas de ocorrência de plantio de banana em diferentes orientações do relevo (Norte, Sul, Leste e Noroeste), para verificar se existem diferenças no comportamento espectral ao longo de toda a faixa do espectro eletromagnético, imageada pelo sensor Hyperion.

### **3.2.7 Classificações Bayesianas**

Foram utilizados os classificadores Bayesianos Máxima Verossimilhança, Fisher e Distância Euclidiana Mínima, todos esses processos de classificação foram implementados sem *Threshold* e com *Threshold* de 2%, no programa MultiSpec. Esta análise dos classificadores com *threshold* tem como objetivo excluir da classificação os pixels com probabilidade de classificação correta menor do que 2%, o que resulta em uma imagem classificada com maior acurácia. Para a confecção dos mapas da área de estudo foram utilizadas as quatro classes de uso e ocupação selecionadas para caracterização das feições existente na imagem.

### **3.2.8 Vetorização de Imagem de Alta Resolução Espacial**

A vetorização da imagem de alta resolução espacial IKONOS, foi realizada no software ARCGIS. Este processo foi realizado para validar os resultados obtidos pelos processos de classificação, a partir da comparação dos resultados classificados com as diversas áreas das classes de uso e ocupação do solo vetorizadas na área de estudo. A vetorização foi realizada a partir da interpretação visual do analista.

### **3.2.9 Análise dos Classificadores**

Os resultados dos processos de classificação foram comparados com os dados vetoriais extraídos da imagem de alta resolução espacial, a partir do processo de fotointerpretação juntamente com o conhecimento adquirido com o trabalho de reconhecimento da região. Os dados extraídos da imagem vetorizada foram utilizados para a construção das matrizes de confusão para a verificação das classes onde existe maior ou menor mistura de informações. Desta maneira utilizamos os dados vetoriais como uma forma de verdade de campo, já que neste tipo de dados podemos identificar melhor as feições existentes no terreno.

## 4 - RESULTADOS E DISCUSSÕES

### 4.1 Pré-processamento

Na etapa do pré-processamento foram realizados os procedimentos disponíveis na ferramenta *Hyperion\_tools* do ENVI. O produto resultante do processamento foi uma imagem com 158 bandas ao invés das 242 originais. Esta redução ocorre por que apenas 196 são radiometricamente calibradas e as outras estão posicionadas em regiões de grande influencia da atmosfera. Na Figura 11, observa-se o resultado do procedimento de correção dos *stripes*, na banda 13, realizado nesta etapa.



Figura 11: Imagem Hyperion, banda 13, (A) com correção dos *stripes* e (B) imagem original no nível L1R.

#### 4.1.1 Correção Atmosférica

A correção atmosférica dos dados elimina os efeitos indesejáveis, ocasionados pela interação da radiação eletromagnética com as partículas que compõem a atmosfera. Os dados corrigidos atmosféricamente são convertidos para reflectância de superfície na ferramenta FLAASH do ENVI. Na Figura 12 é demonstrada a interface do ENVI, com imagem antes e após a correção atmosférica, assim como, o gráfico gerado a partir da leitura de um mesmo pixel em ambas as imagens. Este gráfico demonstra o comportamento espectral de uma área com vegetação. A análise do espectro de reflectância gerado apresentou, conforme a literatura, valores esperados.

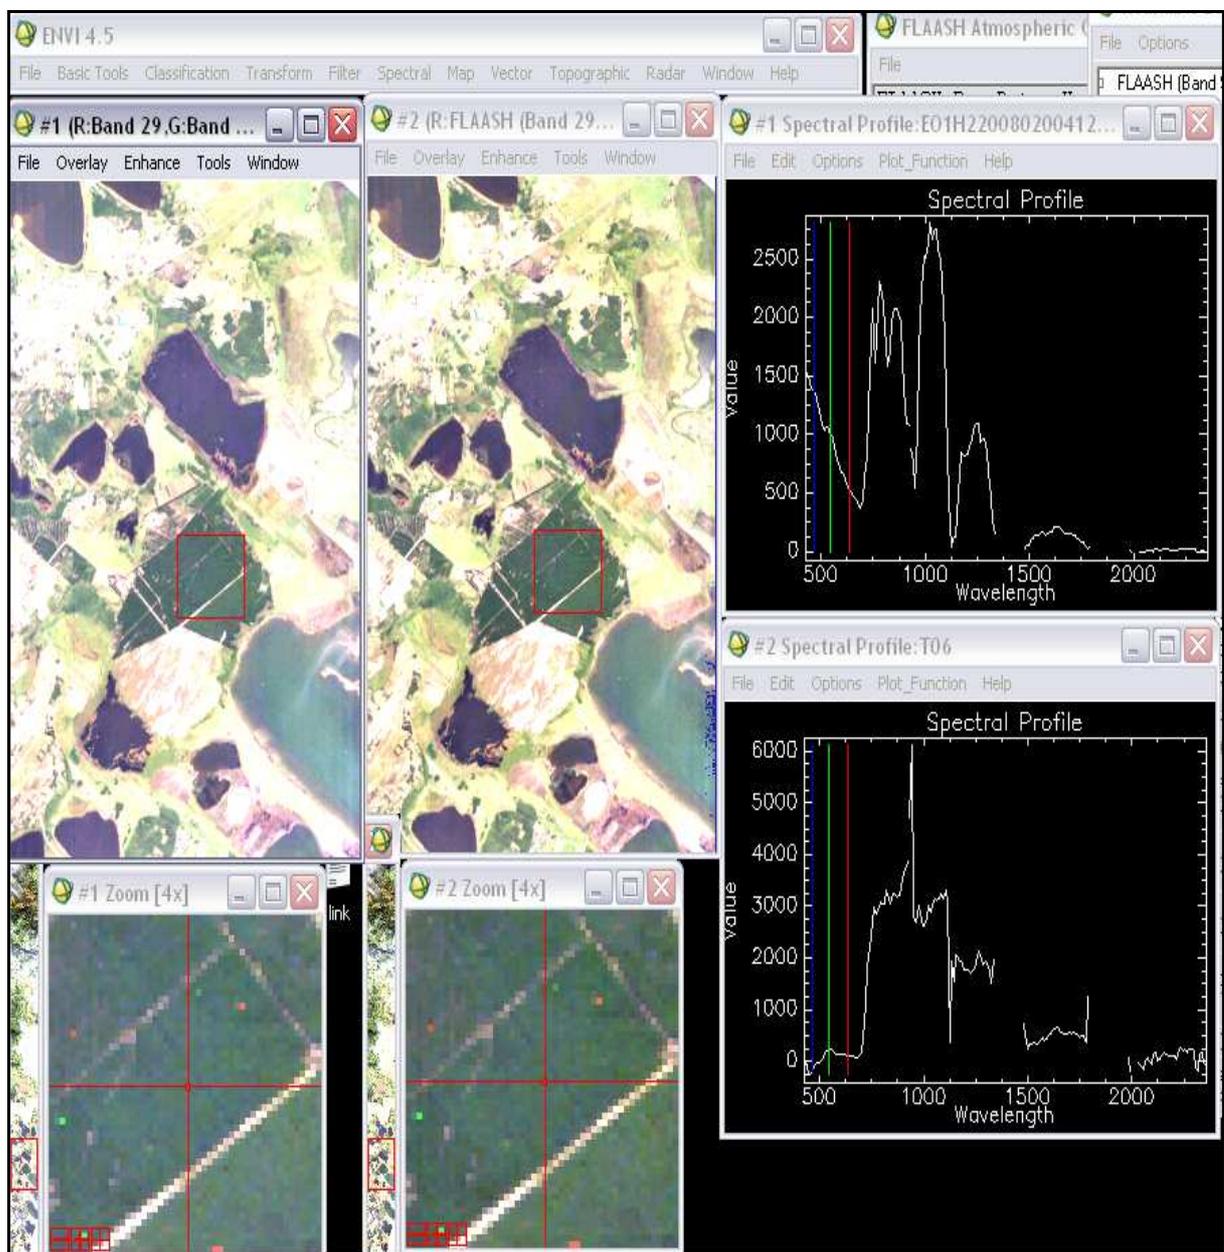


Figura 12: Exemplo do processamento no software ENVI contendo a imagem original e a imagem com correção atmosférica, com seus respectivos gráficos de comportamento espectral de um alvo de vegetação.

O pixel selecionado, no exemplo da Figura 12, representa uma área de vegetação sadia. O perfil apresenta feições bem características, com uma baixa refletância no azul e no vermelho e um aumento da refletância na região do infravermelho próximo decaindo em direção às regiões com comprimento de ondas maiores.

A acurácia e a confiabilidade da classificação digital de imagens dependem de vários fatores: da escolha de áreas de treinamento representativas, compostas por pixels com características similares, distribuídas, por sua vez em classes de boa separabilidade espectral (VIBRANS, 2003).

Após a correção atmosférica e o recorte da imagem, foram selecionadas as amostras para o treinamento dos classificadores. Com o intuito de aproximar o tamanho da amostra ao máximo recomendado pelo teste estatístico de amostragem realizado para a execução do trabalho, foram selecionados 511 pixels. Estes pixels foram divididos entre quatro classes de uso e ocupação do solo presentes na imagem, que são: Mata, Banana, Campo e Sombra.

A disposição das áreas selecionadas para a caracterização das classes utilizadas neste estudo está apresentada na Figura 13. Podemos verificar na imagem, em função do sombreamento, que o relevo na área é fortemente acentuado. O relevo nessa área de encosta apresenta alta declividade e significativa variação altimétrica, bem como vales encaixados ao longo da escarpa do Planalto Meridional. Na área analisada, o predomínio das áreas agrícolas ocorre nas áreas mais baixas, avançando em direção as áreas mais altas e declivosas, onde existia a preponderância da vegetação de Mata Atlântica.

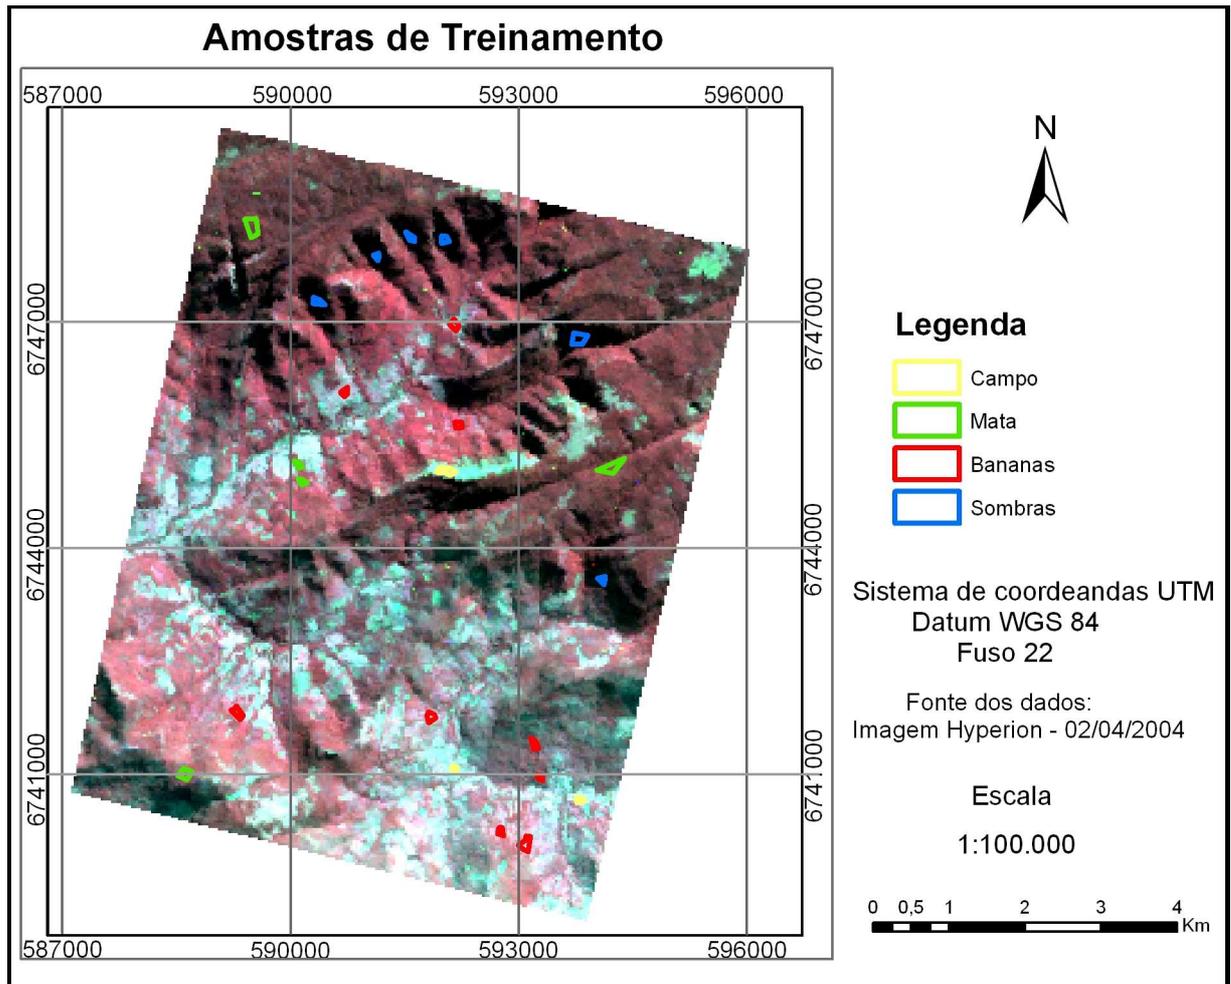


Figura 13: Distribuição das amostras na área de estudo, imagem do sensor Hyperion data 02/05/2004.

#### 4.2 Comportamento Espectral da Mata Atlântica e dos Bananais

A partir da análise do comportamento espectral dos dois tipos principais de cobertura vegetal existentes na área de estudo, Mata Atlântica e Bananais, verifica-se a semelhança dos alvos ao longo da faixa espectral trabalhada. Com base na média das amostras selecionadas, as espécies vegetais do Bioma Mata Atlântica apresentaram uma reflectância menor do que as dos Bananais (Figura 14). Na região do infravermelho próximo esta variação chega a ser de 15%, somente nos comprimentos de onda maiores que a diferença de reflectância diminui muito, chegando a alguns comprimentos em que a reflectância da classe Bananais seja menor do que a da Mata Atlântica.

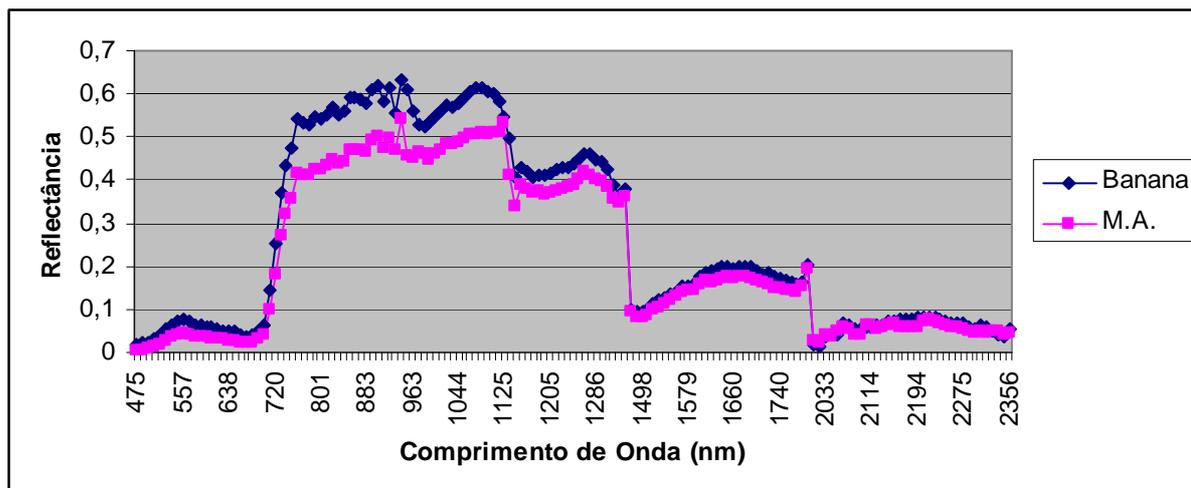


Figura 14: Resposta espectral dos alvos Bananais e Mata Atlântica, imagem do sensor Hyperion, data 02/05/2004.

Esta maior reflectância nas áreas com Bananais é ocasionada porque nestas áreas existe pouca variação de altura entre as plantas, visto que as espécies foram plantadas na mesma época fazendo com que elas tenham aproximadamente a mesma idade, o que possivelmente causa esta pouca variação de altura. Esta homogeneidade de altura diminui a probabilidade de uma planta fazer sombra sobre a outra.

Ponzoni (2002) ao comparar a reflectância no infravermelho próximo de uma área de floresta perenifólia com um plantio jovem de *Eucalyptus spp.*, destaca que a floresta perenifólia, bem densa, com um IAF (Índice de Área Foliar) muito elevado, poderá assumir um brilho mais escuro do que um plantio jovem de *Eucalyptus spp.*, que possuiria um IAF bem menos elevado. Em tal floresta, a existência de diferentes estratos (camadas) horizontais, com os indivíduos dominantes projetando suas copas acima de uma cota média do dossel, poderia acarretar o sombreamento daqueles que se posicionariam imediatamente abaixo. Isso implicaria na diminuição da irradiância nos estratos inferiores e, conseqüentemente, na diminuição da radiância medida pelo sensor orbital, o que, por sua vez, implicaria no “escurecimento” do dossel da floresta em relação ao de *Eucalyptus spp.*, que não possuiria estratos e, portanto, o sombreamento entre seus elementos constituintes seria bem menor. Evidentemente que esse efeito será tanto maior quanto maior for o ângulo de incidência solar, uma vez que o sombreamento é proporcional a esse ângulo.

Já nas áreas de Mata Atlântica, existe uma diversidade maior de espécies. Isso implica em uma maior variação de pigmentação, de absorção de clorofila, de algumas espécies com

floração em épocas diferentes e uma maior variabilidade dos estratos das espécies, o que também implica no sombreamento de algumas árvores de espécies menores, acentuando-se pela alta variação do relevo na área de estudo. Nas áreas com sombra, existe um menor fluxo de radiação de energia eletromagnética em direção ao sensor, por isso a curva espectral do alvo Mata Atlântica tem menor reflectância do que a dos Bananais, ao contrario do que era esperado, já que acreditávamos que a áreas de Mata Atlântica teriam maior reflectância do que as áreas de Bananais por causa do efeito da múltipla reflectância, que acontece quando existem vários estratos, camadas de folhas em um dossel. Mas este fenômeno não contribui suficientemente para que as áreas de Mata Atlântica tivessem maior reflectância do que as áreas de Bananais.

Na Figura 15 podemos verificar a variação da diferença de reflectância entre as áreas de plantio de Bananais e de Mata Atlântica, em cada comprimento de onda. Podemos verificar que as maiores diferenças estão na região do infravermelho próximo, entre 0,6 a 0,16 pontos percentuais, a diferença diminui em direção ao infravermelho médio, sendo o valor, em alguns comprimentos de onda, negativo, o que significa que nestes comprimentos de onda a amostra de vegetação da Mata Atlântica tem maior valor de reflectância, como por exemplo nos comprimentos de onda de 1982 e 2053 nanômetros. Na região do visível as menores diferenças são na faixa do azul e do vermelho e a maior na faixa do verde, região do visível que a vegetação tem maior reflectância.

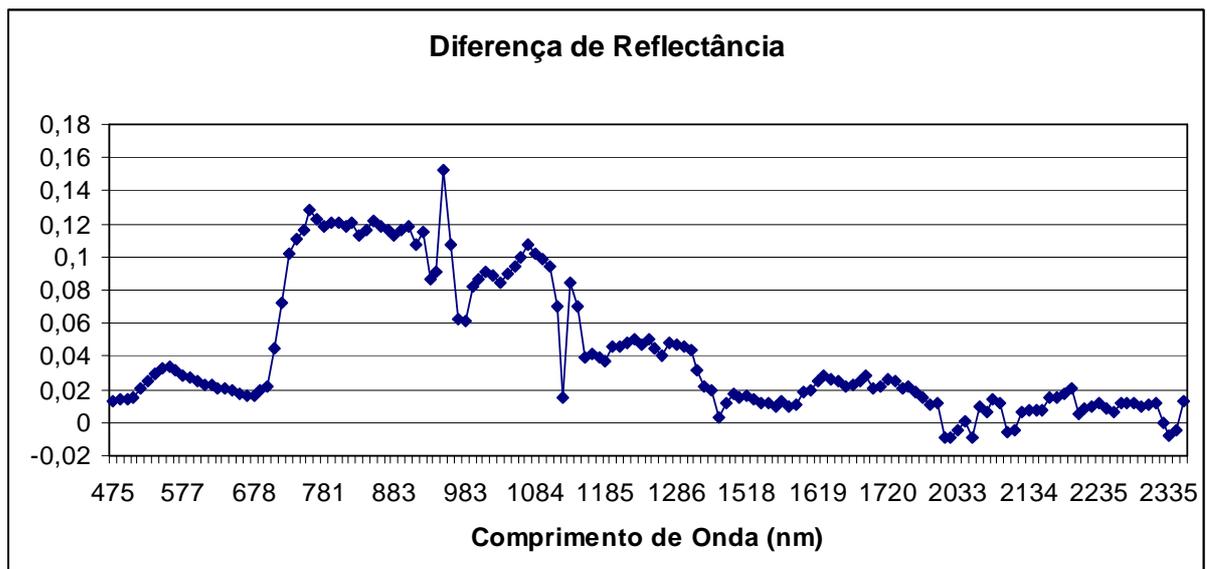


Figura 15: Diferença das respostas espectrais dos alvos de Bananais com relação às áreas de Mata Atlântica, imagem do sensor Hyperion, data 02/05/2004.

A Figura 16 mostra um conjunto de gráficos detalhando da Figura 14, que apresenta o comportamento espectral das áreas de Bananais e de Mata Atlântica, ao longo de todo o espectro eletromagnético. Podemos verificar que na faixa do visível, os comprimentos de onda que mais diferenciam os valores de reflectância entre as áreas de Bananais e de Mata Atlântica estão compreendido na região do verde. Esta diferença chega a 0,03 % no comprimento de onda 557 nm.

Na região do infravermelho próximo, no comprimento de onda 760 nm, a diferença de reflectância é de 0,12 pontos percentuais, chegando a 0,15 pontos percentuais no comprimento de onda 953 nm, mas como este valor é muito discrepante dos demais nesta faixa espectral, pode ter sido ocasionado por algum tipo de ruído na informação.

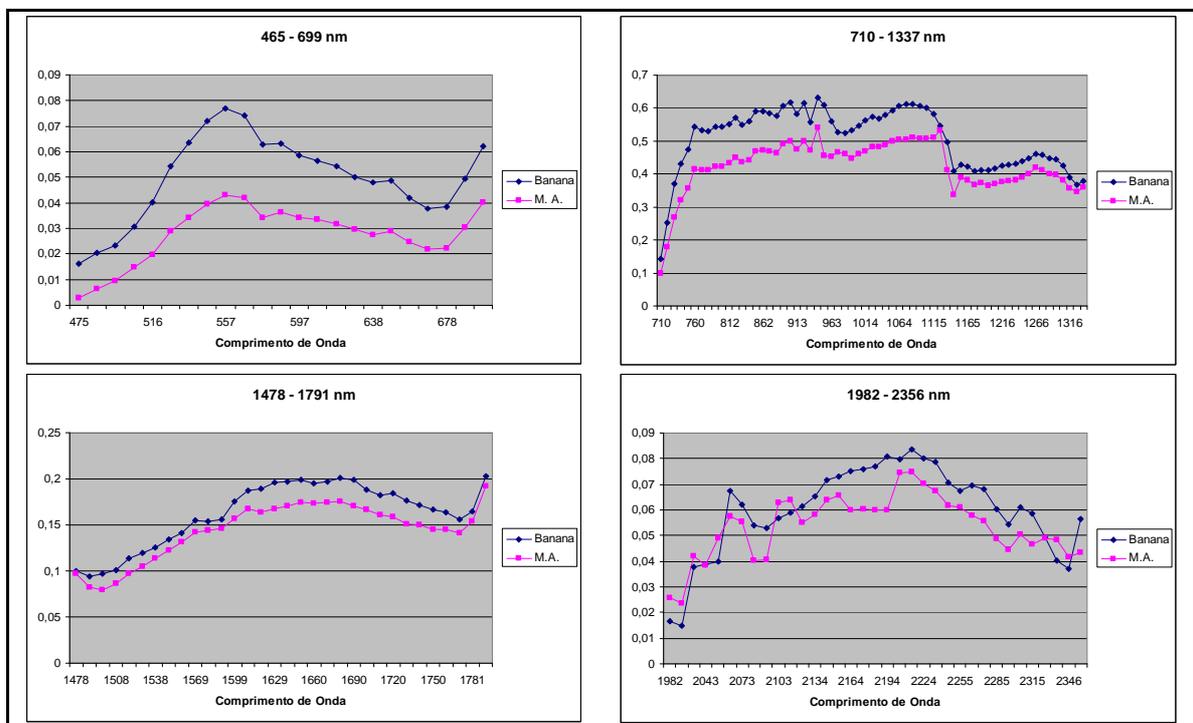


Figura 16: Comportamento espectral das áreas de Bananais e Mata Atlântica com detalhes ao longo da faixa espectral utilizada, imagem do sensor Hyperion, data 02/05/2004.

Analisando somente as áreas selecionadas contendo o plantio de banana, podemos verificar que as mesmas têm muita diferença de resposta na sua reflectância, conforme a orientação e a declividade da vertente onde estão plantadas. Sendo que as áreas orientadas para o Norte são as que têm maior reflectância, seguida pelas áreas voltadas para o Noroeste, Leste e Sul. A região que tem menor reflectância são as áreas voltadas para o Sul (Figura 17).

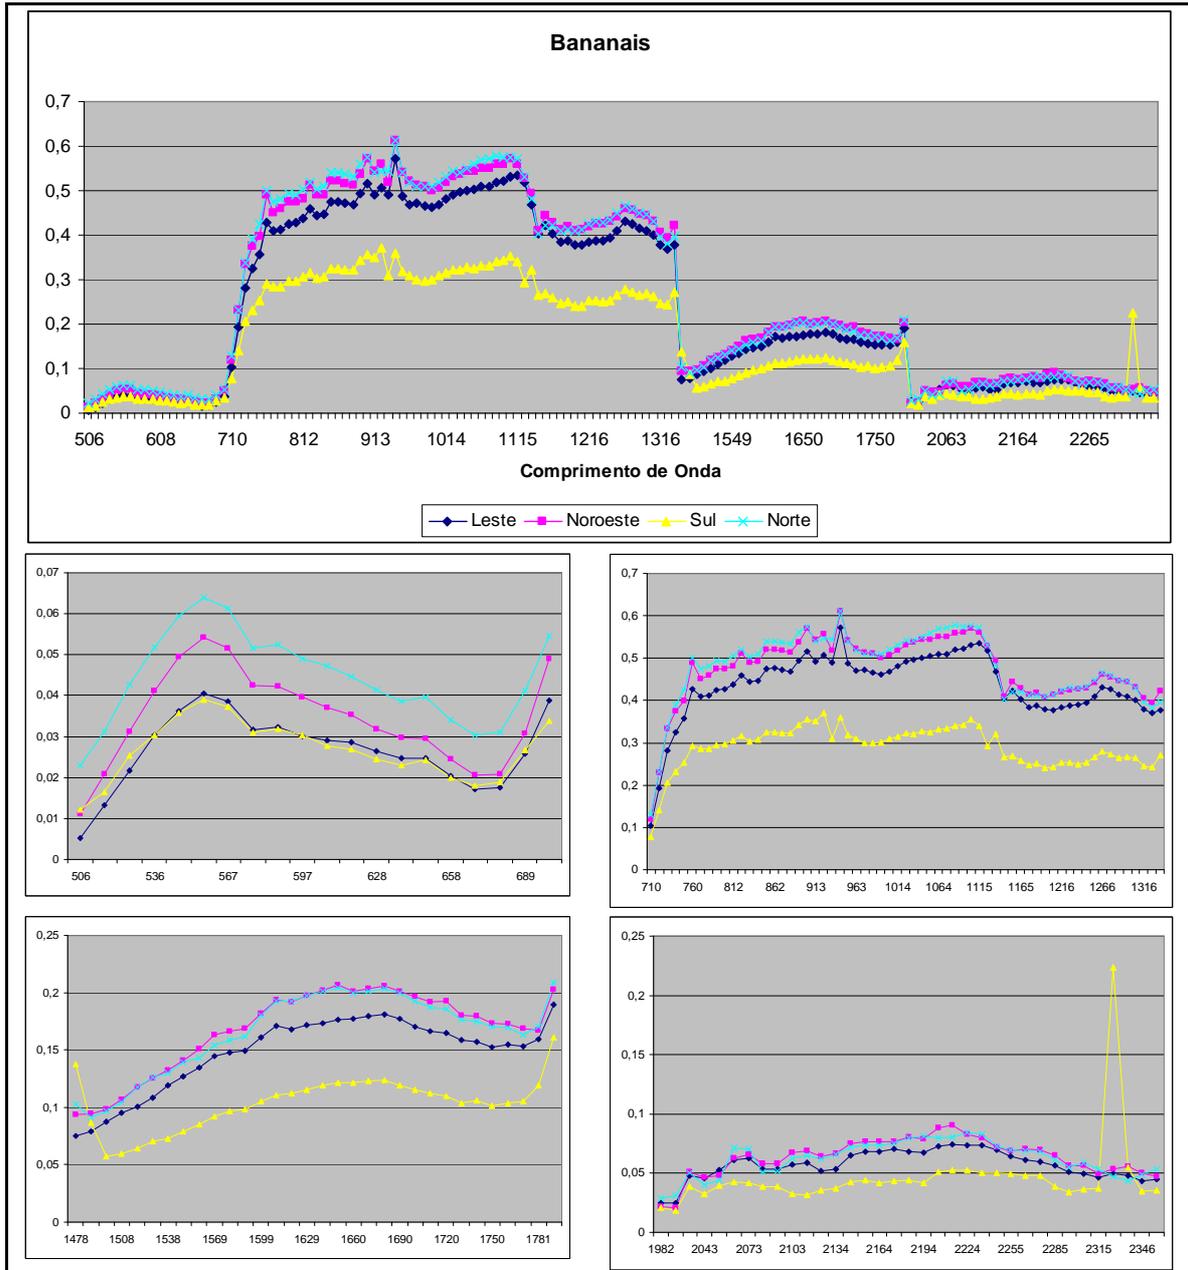


Figura 17: Comportamento espectral das áreas de Bananais nas diferentes orientações de vertentes da área de estudo, com detalhes ao longo da faixa espectral utilizada, imagem do sensor Hyperion, data 02/05/2004.

A diferença entre as áreas plantadas para o Norte e as áreas plantadas voltadas para o Sul, na região do visível, não é muito significativa, mas na região do infravermelho próximo, esta diferença pode chegar a até 0,25 pontos percentuais no comprimento de onda de 943 nm, (Figura 18). Em apenas dois comprimentos de onda a reflectância das áreas do Sul são maiores do que a do Norte, mas acredita-se que isso acontece mais por causa de algum tipo de ruído na imagem do que condicionado a fatores ambientais ou estruturais das plantas.

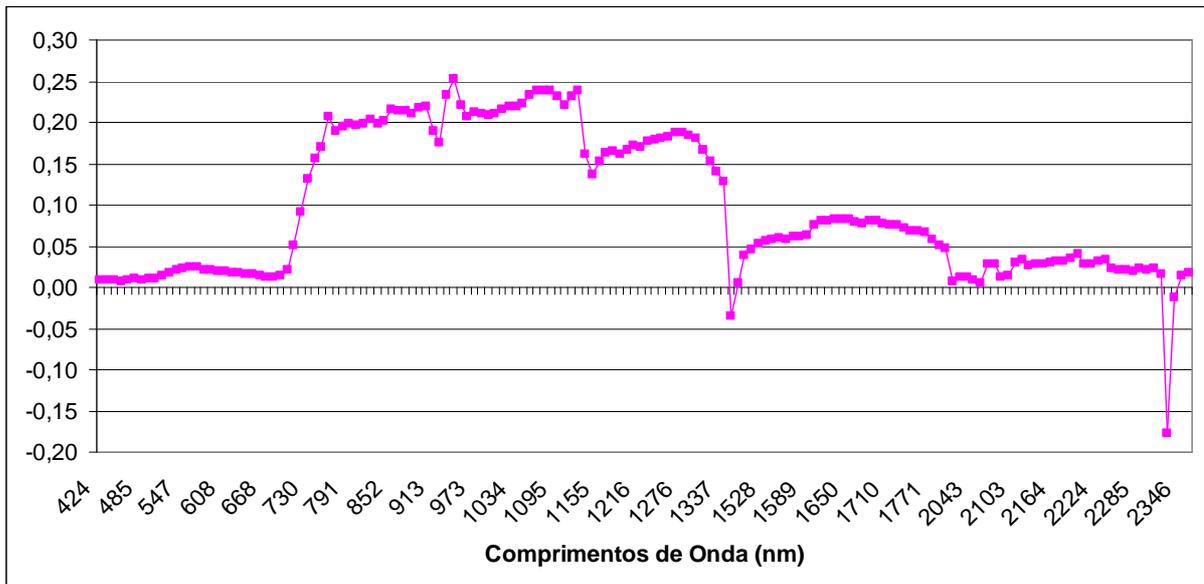


Figura 18: Diferença entre a resposta espectral das áreas de Bananais nas vertentes orientadas para o Norte com relação às orientadas para o Sul, imagem do sensor Hyperion, data 02/05/2004.

A diminuição da intensidade da reflectância está diretamente ligada à própria intensidade de radiação que chega a superfície terrestre, já que, na latitude da área de estudo, as áreas voltadas para o Norte recebem maior fluxo de radiação eletromagnética do que as áreas voltadas para o Sul. Esta diferença de fluxo de radiação explica a própria diminuição da intensidade da curva espectral das áreas plantadas nas vertentes voltadas para o Sul, com relação às áreas predominantemente voltadas para o quadrante Norte, já que a diferença de incidência de radiação reflete no desenvolvimento vegetativo das plantas. Bispo (2007) destaca que a variável orientação de vertentes define ambientes mais propícios para o desenvolvimento de determinados tipos de vegetação em detrimento de outros. Desta maneira, as plantas voltadas para o Norte, que recebem maior fluxo de radiação, se desenvolvem mais do que as plantas voltadas para o Sul, conforme verificado na Figura 18. Fonseca et. al. (2002) destacava que os aumentos na quantidade de biomassa diminuem a reflectância na porção visível do espectro e aumentam a reflectância na porção do infravermelho.

Destacamos aqui que a seleção das amostras também foi feita a partir da imagem hiperespectral, fazendo com que possa ocorrer a seleção de algumas áreas de outras classes. Isso tornaria a amostra “poluída”, fazendo com que ocorra o fenômeno pixel mistura, devido à baixa resolução espacial do sensor Hyperion. Assim, os pontos que destoam dos gráficos em alguns comprimentos de onda, podem ser associados a esta “poluição” da amostra, já que não

refletem o resultado esperado, que seria uma curva mais uniforme na região do infravermelho próximo, como apresentado na Figura 5 do ítem 2.6.

### 4.3 Bhattacharya

A distância de Bhattacharya foi executada para a verificação dos melhores conjuntos de canais, para separação das classes utilizadas. Esta distância estatística utiliza os dados amostrais para a verificação do canal ou conjunto de canais com a maior distância mínima entre as curvas dos dados amostrados

O canal que apresentou maior separabilidade entre as classes foi o de comprimento de onda igual a 678nm, Tabela 2. Neste canal a menor distância apresentada de separabilidade foi entre as classes de Mata e Banana, sendo a mesma de 5,01. A maior distância de separabilidade entre as classes ocorreu entre a classe de Sombra e a classe de Campo, a distância entre estas duas classes ficou sendo de 41,6. A média das distâncias entre as classes neste canal ficou sendo de 16,20. A partir da análise do histograma das amostras de treinamentos das 4 classes utilizadas para subsidiar as classificações supervisionadas, foi possível verificar esta separabilidade nas amostras coletadas no canal selecionada pela distância estatística de Bhattacharya, banda 27, Figura 19.

Tabela 2: Distâncias mínimas e médias dos 20 melhores canais para separar as classes Mata, Banana, Campo e Sombra na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004.

Símbolo dos pares de classes		12	13	14	23	24	34	
Fator de Ponderação		-10	-10	-10	-10	-10	-10	
$\lambda$ (nm)	Mínima	Média	Medidas Ponderadas de Distância Entre Classes					
678	5,01	16,20	5,66	21,7	41,6	5,01	17,4	5,72
689	4,91	16,22	5,31	20,1	42,3	4,91	19,0	5,52
668	4,63	14,26	4,63	17,8	35,0	4,97	17,9	5,20
658	4,45	15,66	4,45	18,6	39,7	5,38	20,3	5,35
699	3,40	18,81	3,40	17,6	50,3	5,60	27,6	8,14
648	2,90	12,84	2,90	13,2	27,2	5,92	21,8	5,84
638	2,67	13,52	2,67	13,1	28,3	6,47	24,9	5,54
628	2,21	12,21	2,21	10,9	26,7	5,35	24,0	3,93
618	1,73	12,25	1,73	10,5	24,2	6,23	24,7	5,93
1589	1,20	6,69	1,24	2,96	9,91	1,20	17,5	7,30
1730	1,15	6,80	1,15	3,33	12,2	1,18	15,4	7,40

Continuação Tabela 2: Distâncias mínimas e médias dos 20 melhores canais para separar as classes Mata, Banana, Campo e Sombra na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004

1569	1,15	6,38	1,20	2,84	9,41	1,15	16,6	7,07
608	1,14	11,16	1,14	7,93	18,2	6,61	26,8	6,16
1720	1,13	5,76	1,13	3,38	10,9	1,30	12,4	5,37
1599	1,13	7,16	1,13	3,05	10,6	1,40	18,8	7,90
1579	1,12	6,45	1,26	2,80	9,10	1,12	17,2	7,20
1639	1,12	7,46	1,12	3,47	14,5	1,18	16,6	7,72
1710	1,10	6,75	1,10	3,39	12,4	1,24	15,0	7,30
1650	1,09	7,63	1,09	3,52	14,9	1,23	17,0	7,98
1700	1,08	7,15	1,08	3,40	12,8	1,33	16,5	7,74

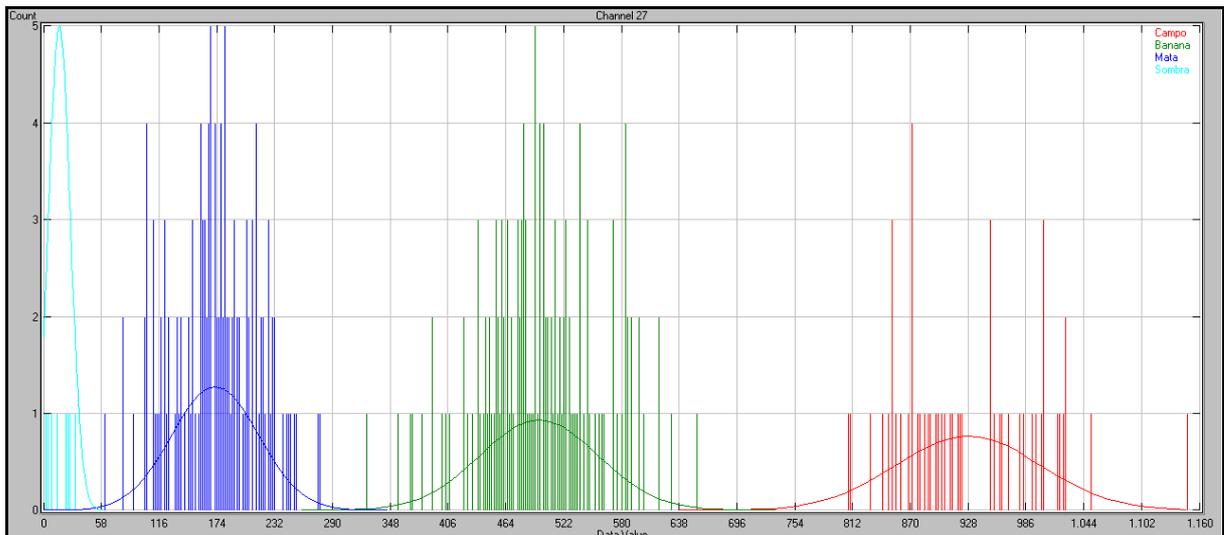


Figura 19: Histograma de distribuição dos pixels, no comprimento de onda de 689 nm, das classes Sombra em azul claro, Mata em azul escuro, Banana em verde, e Campo em vermelho, na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004.

A utilização da distância estatística permitiu um menor tempo de processamento dos dados na classificação, já que foi utilizado um número menor de bandas neste processo, visando otimizá-lo. O resultado da classificação não foi prejudicado, porque foi utilizado o melhor conjunto de 5 bandas possíveis, ou seja, o que permitiu maior separabilidade dos dados.

Analisando-se a separabilidade das classes através de um conjunto de canais, onde existe uma combinação entre canais, a separabilidade das classes aumentou. A melhor combinação dos canais, ou seja, a combinação que apresentou melhor separabilidade das classes, contendo 5 canais, foi a combinação dos comprimentos de ondas 547 nm, 628 nm, 730 nm, 1316 nm e 1720 nm. Os dois primeiros comprimentos de ondas se encontram na região do visível, 547 nm (verde), 628 nm (vermelho), o comprimento de onda de 730 nm na

região infravermelho próximo e os comprimentos de onda 1316 nm e 1730 nm na região infravermelho médio do espectro eletromagnético. Nesta combinação a menor distância mínima foi de 9,83, novamente entre as classes Campo e Banana, e a maior separabilidade foi de 101, entre as classes Campo e Sombra. A média das distâncias nesta combinação foi de 34,02, Tabela 3.

Tabela 3 - Distâncias mínimas e médias dos 20 melhores conjuntos de 5 canais para separar as classes Mata, Banana, Campo e Sombra na imagem do satélite EO-1, sensor Hyperion, data 02/05/2004.

Símbolo dos pares de classes		12	13	14	23	24	34	
Fator de Ponderação		-10	-10	-10	-10	-10	-10	
$\lambda$ (nm)	Mínima	Média	Medidas Ponderadas de Distância Entre Classes					
547 628 730 1316 1720	9,83	34,02	9,83	20,9	101,	9,97	52,1	9,97
547 628 720 1155 1720	9,74	32,23	9,74	21,0	90,9	9,95	50,6	10,9
547 628 730 1306 1720	9,73	34,78	9,83	21,4	104,	9,99	52,9	9,73
678 740 1306 1518 1720	9,71	34,53	9,71	25,4	89,6	9,89	62,1	10,3
547 628 740 1316 1720	9,71	33,12	10,0	22,2	95,1	9,77	51,8	9,71
547 628 720 1316 1720	9,71	33,82	9,71	21,2	99,6	10,1	51,1	11,1
678 710 1074 1276 1720	9,68	31,96	9,68	25,3	78,1	9,80	57,2	11,6
678 720 1064 1266 1720	9,68	35,51	9,75	32,0	94,5	9,68	55,7	11,3
547 628 710 1316 1720	9,68	33,33	9,68	21,1	96,6	9,76	51,9	10,7
567 628 740 1316 1720	9,67	32,64	9,70	22,4	92,3	9,74	51,9	9,67
547 628 710 1165 1720	9,66	32,91	9,71	22,2	93,4	9,66	51,6	10,7
547 628 710 1155 1720	9,66	30,22	9,66	21,0	78,2	9,87	51,9	10,5
557 628 740 1316 1720	9,65	33,26	9,88	22,4	95,4	9,87	52,3	9,65
547 628 720 1306 1720	9,64	34,71	9,64	21,7	104,	9,97	51,4	11,1
557 628 730 1306 1720	9,64	35,36	9,64	21,3	108,	9,97	53,0	9,79
557 628 1306 1549 1720	9,64	32,91	10,1	21,2	96,2	9,64	50,0	10,2
557 628 730 1155 1720	9,64	32,85	9,64	21,0	95,5	9,89	51,2	9,67
557 628 1306 1549 1720	9,63	33,69	10,1	21,7	100,	9,63	49,9	9,73
547 628 710 1306 1720	9,63	33,61	9,63	21,6	97,4	9,96	52,3	10,6
678 720 1054 1266 1720	9,62	34,17	9,73	31,2	86,6	9,62	56,3	11,4

#### 4.4 Resultados das Classificações da Imagem

Nos processos de classificação Bayesianos foi utilizado um conjunto com 5 canais selecionados pelo método da distância de Bhattacharyya, que foram os canais dos comprimentos de onda 547nm, 628nm, 730nm, 1316nm, 1720nm, conforme demonstra a Tabela 3, que contém a organização dos 20 melhores conjuntos de banda, com maiores

distâncias mínimas e maiores médias. As imagens foram classificadas através dos métodos da Distância Euclidiana, Fisher e Máxima Verossimilhança, com e sem *Threshold* de 2%.

A avaliação dos processos de classificação foi efetuada através da análise das matrizes de confusão elaboradas pelo programa Multispec através do método de Re-substituição e o Leave-One-Out. Também foram elaboradas matrizes de confusão a partir do cruzamento dos dados vetoriais extraídos da imagem de alta resolução espacial.

#### **4.4.1 Avaliação Multispec**

##### **4.4.1.1 Máxima Verossimilhança**

O resultado do processo de classificação pelo método da Máxima Verossimilhança é apresentado na Figura 20, e as Tabelas 4 e 5 apresentam as matrizes de confusão elaboradas pelo método de Re-substituição e Leave-One-Out, respectivamente. Os valores de Índice Kappa são de 100% e 99,7%. Apenas no método Leave-One-Out, ocorreu um erro na classificação de um pixel, sendo que este era para ser classificado como Sombra e foi classificando como Banana.

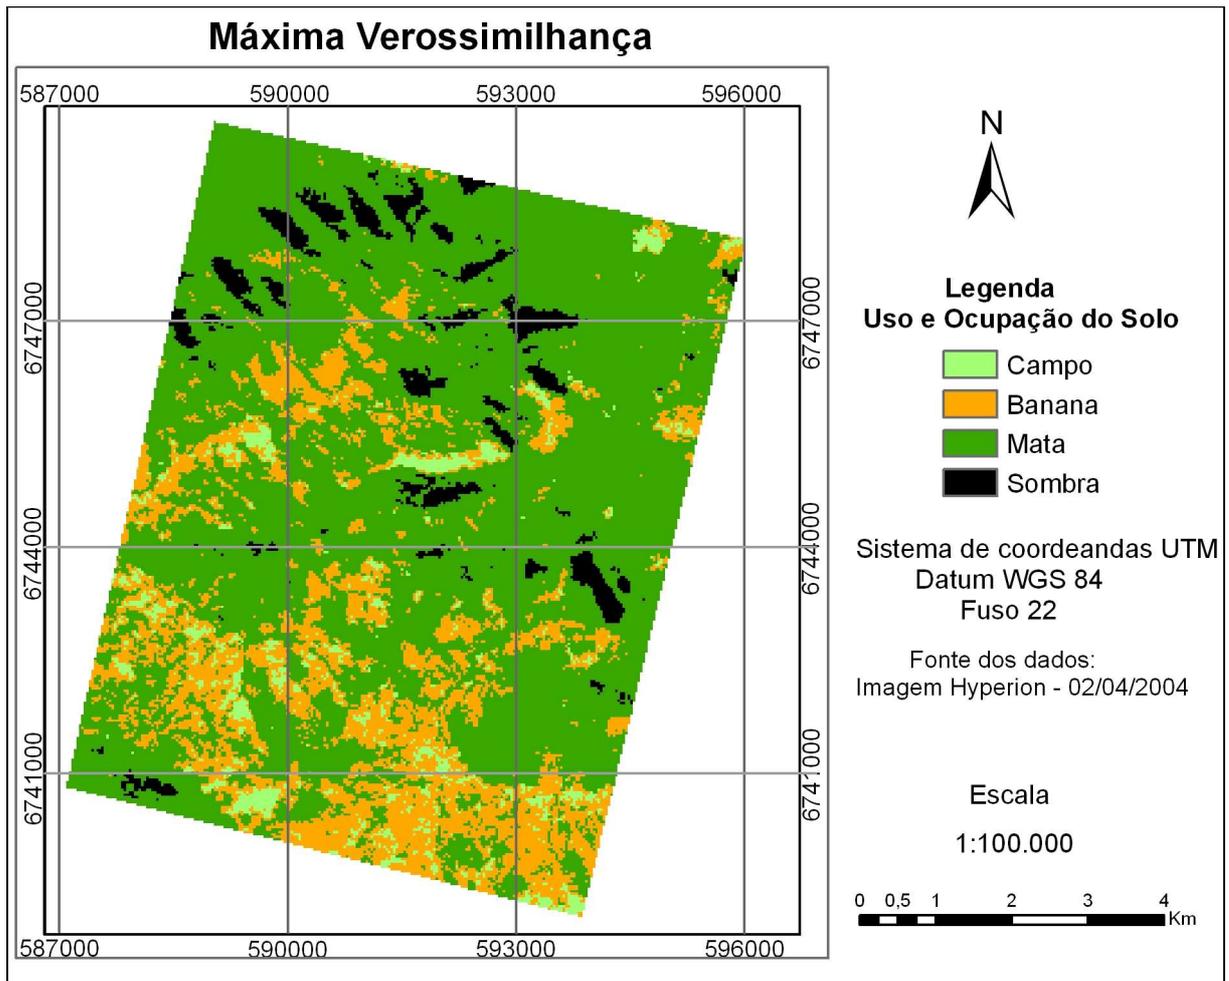


Figura 20: Imagem classificada pelo método Máxima Verossimilhança, sensor Hyperion, data 02/05/2004.

Tabela 4: Matriz de confusão da classificação Máxima Verossimilhança confeccionada pelo método de Re-substituição, no software Multispec.

Referência		Nº de amostras nas classes				
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra
Campo	100,0	51	51	0	0	0
Banana	100,0	135	0	135	0	0
Mata	100,0	129	0	0	129	0
Sombra	100,0	196	0	0	0	196
TOTAL		511	51	135	129	196
Exatidão de Comissão (%)			100	100	100	100
Exatidão Global (511/511) = 100,0%						
Índice Kappa (X100) = 100,0%. Variância = 0,00000.						

Tabela 5: Matriz de confusão da classificação Máxima Verossimilhança confeccionada pelo método de Leave-One-Out, no software Multispec.

Referência		N° de amostras nas Classes				
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra
Campo	100,0	51	51	0	0	0
Banana	100,0	135	0	135	0	0
Mata	100,0	129	0	0	129	0
Sombra	99,5	196	0	1	0	195
TOTAL		511	51	136	129	196
Exatidão de Comissão (%)			100	99,3	100	100
Exatidão Global (510/511) = 99,8%						
Índice Kappa (X100) = 99,7%. Variância = 0,000008.						

A média de probabilidade do método Máxima Verossimilhança foi de 12,7%, conforme a Tabela 6. A classe que mais ocorreu foi a Classe Mata, com 70,33%, o seu alto percentual ocorreu devido à área de Mata Atlântica preservada na porção Norte da imagem e nos morros da região, onde ocorrem as maiores declividades e altitudes da região, o que dificulta a intervenção antrópica. O percentual da classe Banana foi de 21,04% predominantemente na parte Sul, Sudeste e Noroeste da imagem, distribuída nas encostas dos vales dos rios da região.

Tabela 6: Distribuição das áreas das classes na imagem classificada pelo método da Máxima Verossimilhança sem *Threshold*.

Classes	Pixels	Porcentagem	Área (Hectares)
Campo	2418	4,02	259,99
Banana	12663	21,04	1361,56
Mata	42329	70,33	4551,34
Sombra	2772	4,61	298,05
Total	60182	100,0	6470,95
Probabilidade Média 12,7%.			

#### 4.4.1.2 Linear de Fisher

O resultado do processo de classificação pelo método Linear de Fisher é apresentado na Figura 21, e a Tabela 7 apresenta a matriz de confusão elaborada pelo método de re-substituição. O valor do Índice Kappa também foi de 100%, não sendo classificado nenhum pixel em uma classe errada.

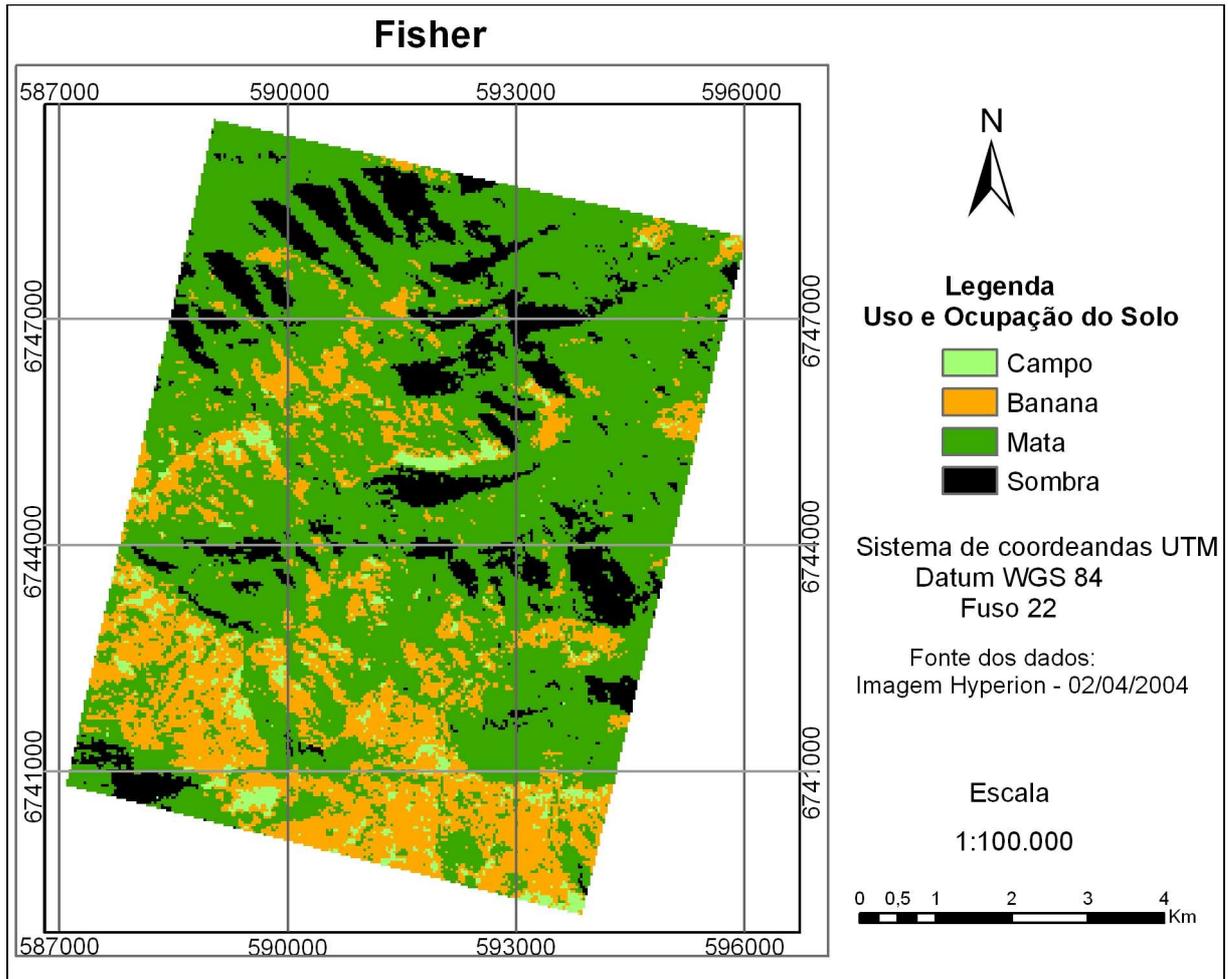


Figura 21: Imagem classificada pelo método de Fisher, sensor Hyperion, data 02/05/2004.

Tabela 7: Matriz de confusão da classificação Fisher confeccionada pelo método de Re-substituição, no software Multispec.

Referência		Nº de amostras nas Classes				
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra
Campo	100,0	51	51	0	0	0
Banana	100,0	135	0	135	0	0
Mata	100,0	129	0	0	129	0
Sombra	100,0	196	0	0	0	196
TOTAL		511	51	135	129	196
Exatidão de Comissão (%)			100	100	100	100
Exatidão Global (511/511) = 100,0%						
Índice Kappa (X100) = 100,0%. Variância = 0,000000.						

Assim como o método da Máxima Verossimilhança, o método de classificação Linear de Fisher apresentou como resultado da classe com maior porcentagem de área, a classe Mata,

com um total de 62,72% da área da imagem, Tabela 8. Na classe Sombra, teve um aumento de área em relação ao método anterior, e a área da classe foi de 13,21% do total. A área da classe Banana foi de 21,14% da área total, apenas 0,10 pontos percentuais maior do que o método anterior. Na classe Campo ocorreu uma diminuição da área em relação ao método anterior, de 4,02% para 2,93% da área total da imagem. A média de probabilidade do método do classificador de Fisher foi de 41,9%, sendo 29,2 pontos percentuais mais alta do que o método da Máxima Verossimilhança.

Tabela 8: Distribuição das áreas das classes na imagem classificada pelo método de Fisher, sem *Threshold*.

Classes	Pixels	Porcentagem	Área (Hectares)
Campo	1762	2,93	189,46
Banana	12724	21,14	1368,12
Mata	37745	62,72	4058,46
Sombra	7951	13,21	854,92
Total	60182	100,0	6470,95
Probabilidade Média 41,9%.			

#### 4.4.1.3 Distância Euclidiana Mínima

A classificação pelo método da Distância Euclidiana Mínima, apresentado na Figura 22, teve os valores mais baixos de Índices Kappa, 97,2% e 97,0%, para as matrizes de confusão construídas a partir do método de Re-substituição e de Leave-One-Out, Tabelas 9 e 10. No processo de Re-substituição, 11 pixels da classe Banana foram classificados como Campo, 1 pixel da classe Mata foi classificado como Banana e 1 pixel da classe Campo também foi erroneamente classificado como Banana. No processo Leave-One-Out os valores ficaram praticamente os mesmos, exceto por 1 pixel a mais da classe Campo que foi classificado como Banana.

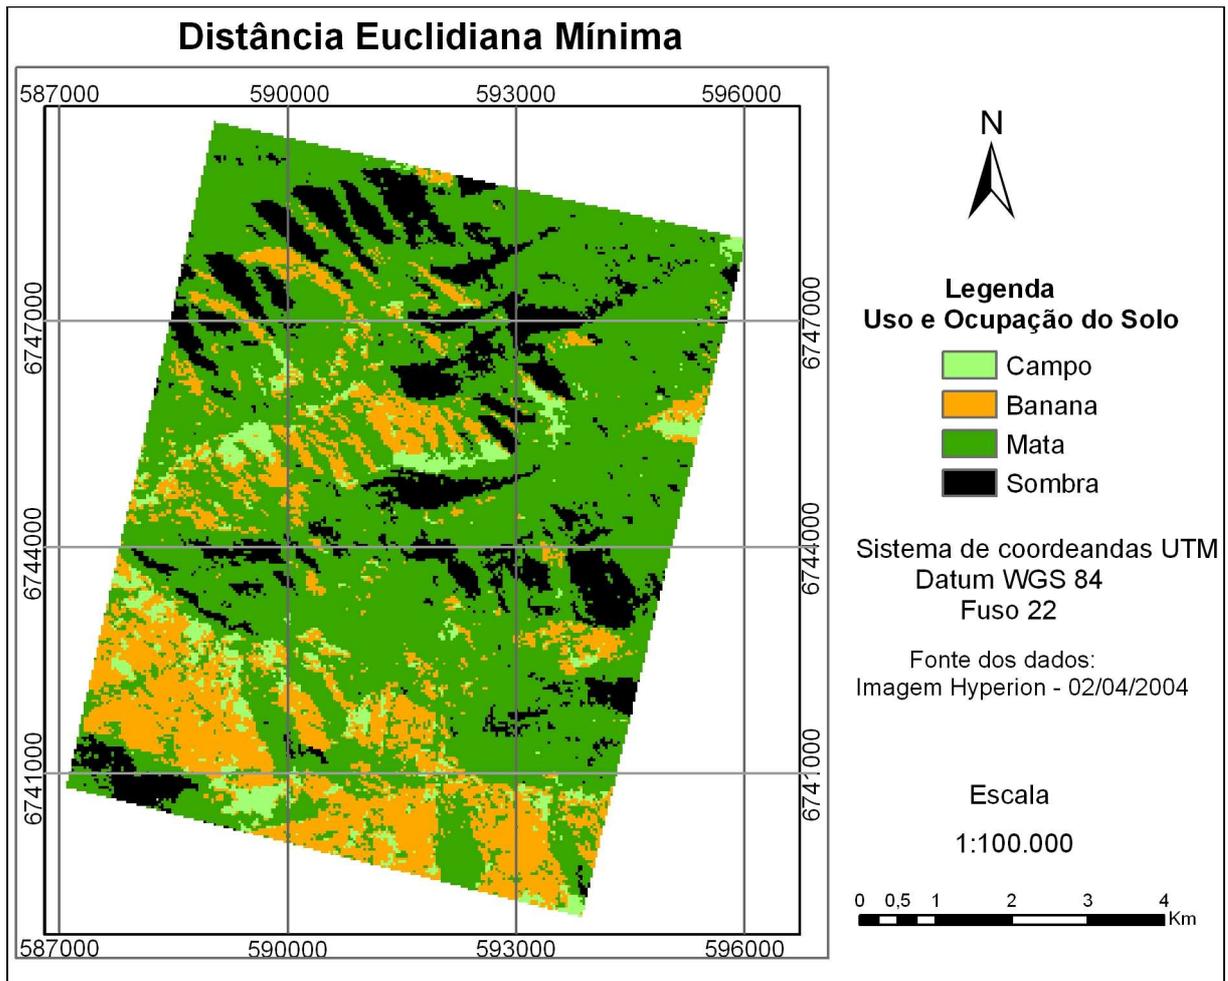


Figura 22: Imagem classificada pelo método da Distância Euclidiana Mínima, sensor Hyperion, data 02/05/2004

Tabela 9: Matriz de confusão da classificação Distância Euclidiana Mínima confeccionada pelo método de Re-substituição, no software Multispec.

Referência		Nº de amostras nas Classes				
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra
Campo	98,0	51	50	1	0	0
Banana	94,1	135	5	127	0	0
Mata	99,2	129	0	1	128	0
Sombra	100,0	196	0	0	0	196
TOTAL		511	55	129	131	196
Exatidão de Comissão (%)*			90,9	98,4	97,7	100
Exatidão Global (501/511) = 98,0%						
Índice Kappa (X100) = 97,2%. Variância = 0,000074.						

Tabela 10: Matriz de confusão da classificação Distância Euclidiana Mínima confeccionada pelo método de Leave-One-Out, no software Multispec.

Referência		N° de amostras nas Classes				
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra
Campo	96,1	51	49	2	0	0
Banana	94,1	135	5	127	3	0
Mata	99,2	129	0	1	128	0
Sombra	100,0	196	0	0	0	196
TOTAL		511	54	130	131	196
Exatidão de Comissão (%)*			90,7	97,7	97,7	100
Exatidão Global (500/511) = 97,8%						
Índice Kappa (X100) = 97,0%. Variância = 0,000081.						

A classe que mais ocorreu foi a de Mata com 62,77%. A classe Banana representou 18,02% da imagem, diminuindo a sua representatividade com relação aos dois métodos anteriores. A classe Campo representou 5,05%, sendo representada com maior área do que os outros métodos apresentados, assim com a classe Sombra que ficou representada em 14,15% da imagem (Tabela 11).

Tabela 11: Distribuição das áreas das classes na imagem classificada pelo método da Distância Euclidiana Mínima.

Classes	Pixels	Porcentagem	Área (Hectares)
Campo	3042	5,05	327,09
Banana	10847	18,02	1166,30
Mata	37777	62,77	4061,90
Sombra	8516	14,15	915,67
Total	60182	100,0	6470,95

Algumas áreas classificadas como Campo pelo método de Fisher foram classificadas como Banana pelo método da Distância Euclidiana Mínima e, outras áreas que foram classificadas como Banana, foram classificadas como Mata. Em relação a estas diferenças apresentadas verificou-se que as áreas classificadas pelo método de Fisher estão corretas.

#### 4.4.1.4 Máxima Verossimilhança com *Threshold* 2%

O resultado do processo de classificação pelo método da Máxima Verossimilhança com *Threshold* de 2% é apresentado na Figura 23, e as Tabelas 12 e 13 apresentam as matrizes de confusão elaboradas pelo método de Re-substituição e de Leave-One-Out, respectivamente. Os valores de Índice Kappa são de 94,6% e 93,5%. A imagem resultante tem uma menor área classificada neste processo porque são eliminadas as áreas classificadas com probabilidade menor de 2 % de representação correta, o que resulta numa imagem com maior precisão para o usuário.

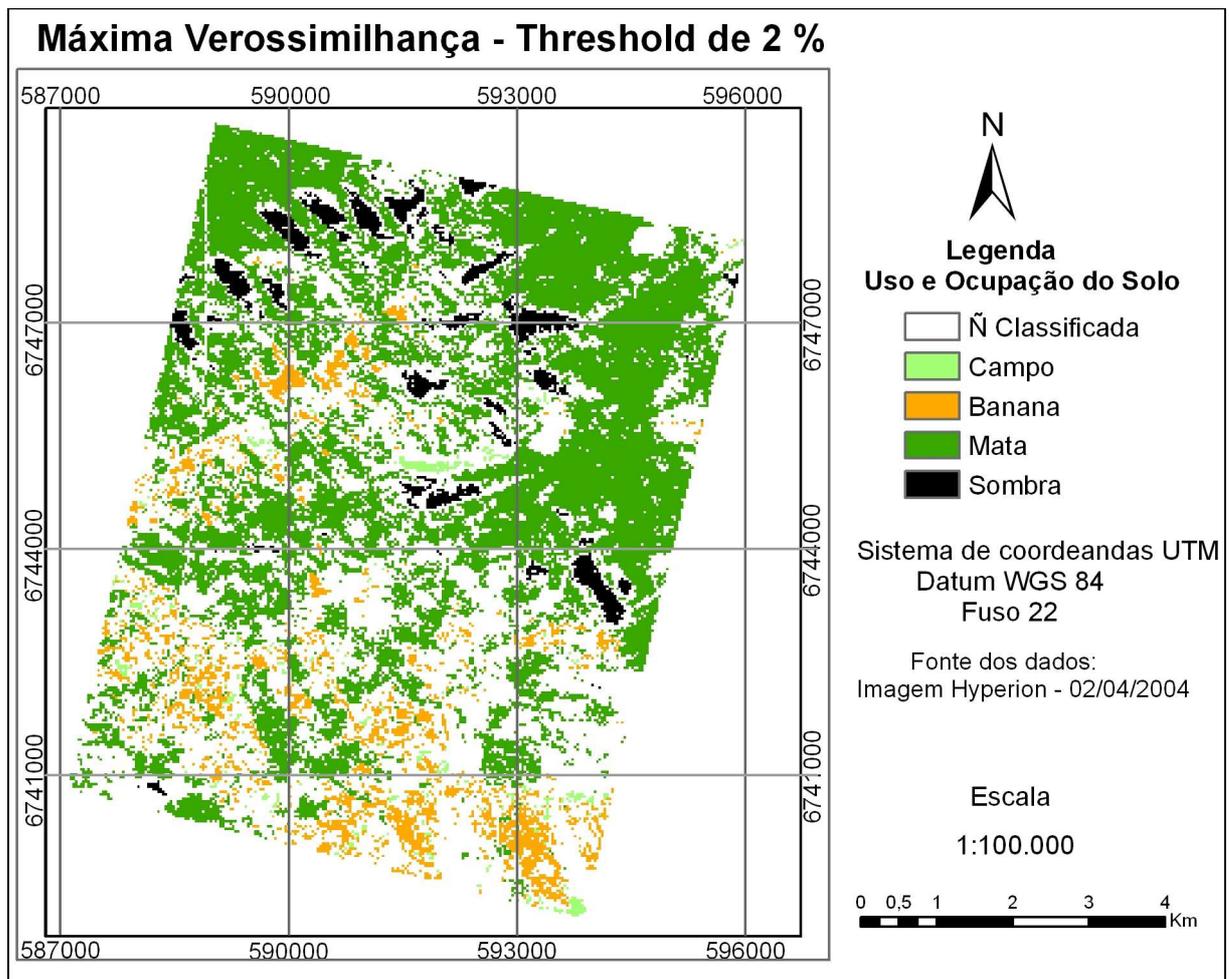


Figura 23: Imagem classificada pelo método da Máxima Verossimilhança com *Threshold* de 2 %, sensor Hyperion, data 02/05/2004

Na matriz de confusão confeccionada a partir do método de Re-substituição, nenhum pixel foi classificado em classe errônea, mas, 20 pixels dos 511 das amostras de teste entraram no limiar de exclusão pela baixa probabilidade de pertencer a classe que se destinavam, sendo 8 da classe Banana, 7 da classe Mata e 5 da classe Sombra. A classe Campo não teve nenhum pixel que se enquadrou no limiar de exclusão.

Tabela 12: Matriz de confusão da classificação Máxima Verossimilhança com *Threshold* de 2%, confeccionada pelo método de Re-substituição, no software Multispec.

Referência		N° de amostras nas Classes					
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra	<i>Threshold</i>
Campo	100,0	51	51	0	0	0	0
Banana	94,1	135	0	127	0	0	8
Mata	94,6	129	0	0	122	0	7
Sombra	97,4	196	0	0	0	191	5
TOTAL		511	51	127	122	191	20
Exatidão de Comissão (%)			100,0	100,0	100,0	100,0	
Exatidão Global (491 / 511 ) = 96,1%							
Índice Kappa (X100) = 94,6%. Variância = 0,000138.							

Com relação à matriz de confusão confeccionada pelo método Leave-One-Out, também não ocorreram pixels classificados em classes errôneas, mas o número de pixels que não foram classificados das amostras de teste aumentou de 20 para 24, sendo que em todas as classes houve pixels excluídos: na classe Campo, 5 pixels; na classe Banana, 8 pixels; na classe Mata, 8 pixels; na classe Sombra, 5 pixels. A classe Mata teve o aumento de 1 pixel com relação a matriz de confusão anterior.

Tabela 13: Matriz de confusão da classificação Máxima Verossimilhança com *Threshold* de 2%, confeccionada pelo método Leave-One-Out, no software Multispec.

Referência		N° de amostras nas Classes					
Classes	Acuracia (%)	Amostras	Campo	Banana	Mata	Sombra	<i>Threshold</i>
Campo	94,1	51	48	0	0	0	3
Banana	94,1	135	0	127	0	0	8
Mata	93,8	129	0	0	121	0	8
Sombra	97,4	196	0	0	0	191	5
TOTAL		511	48	127	121	191	24
Exatidão de Comissão (%)*			100,0	100,0	100,0	100,0	
Exatidão Global (487 / 511 ) = 95,3%							
Índice Kappa (X100) = 93,5%. Variância = 0,000162.							

A classe Mata foi a área mais representada na imagem, com 40,57 %, a classe Banana ficou com apenas 6,15 %. A classe Campo foi a menos representada com 0,91% e a classe Sombra representa 3,40 % da imagem. No total 48,98 % da imagem não foi classificada por causa *Threshold* de 2%, Tabela 14.

Tabela 14: Distribuição das áreas das classes na imagem classificada pelo método da Máxima Verossimilhança com *Threshold* de 2%.

Classes	Pixels	Porcentagem	Área (Hectares)
Campo	546	0,91	58,71
Banana	3699	6,15	397,73
Mata	24417	40,57	2625,39
Sombra	2044	3,40	219,78
<i>Não classificada</i>	29476	48,98	3169,35
Total	60182	100,00	6470,95

#### 4.4.1.5 Fisher com *Threshold* 2%

O resultado do processo de classificação pelo método de Fisher com *Threshold* de 2% é apresentado na Figura 24, e a Tabela 15 apresenta a matriz de confusão elaborada pelo método de Re-substituição. O valor de Índice Kappa é de 94,0% nesta classificação. Nenhum pixel foi substituído em classe errônea, entretanto 22 pixels das amostras de teste não foram classificados, sendo 4 na classe Campo, 11 na classe Banana, 6 na classe Mata e 1 na classe Sombra. As classes Mata e Banana tiveram um aumento na área classificada em relação ao método anterior e, na classe Campo, ocorreu uma diminuição, ficando cada classe com 48,59%, 7,80 % e 0,72 % respectivamente, Tabela 16.

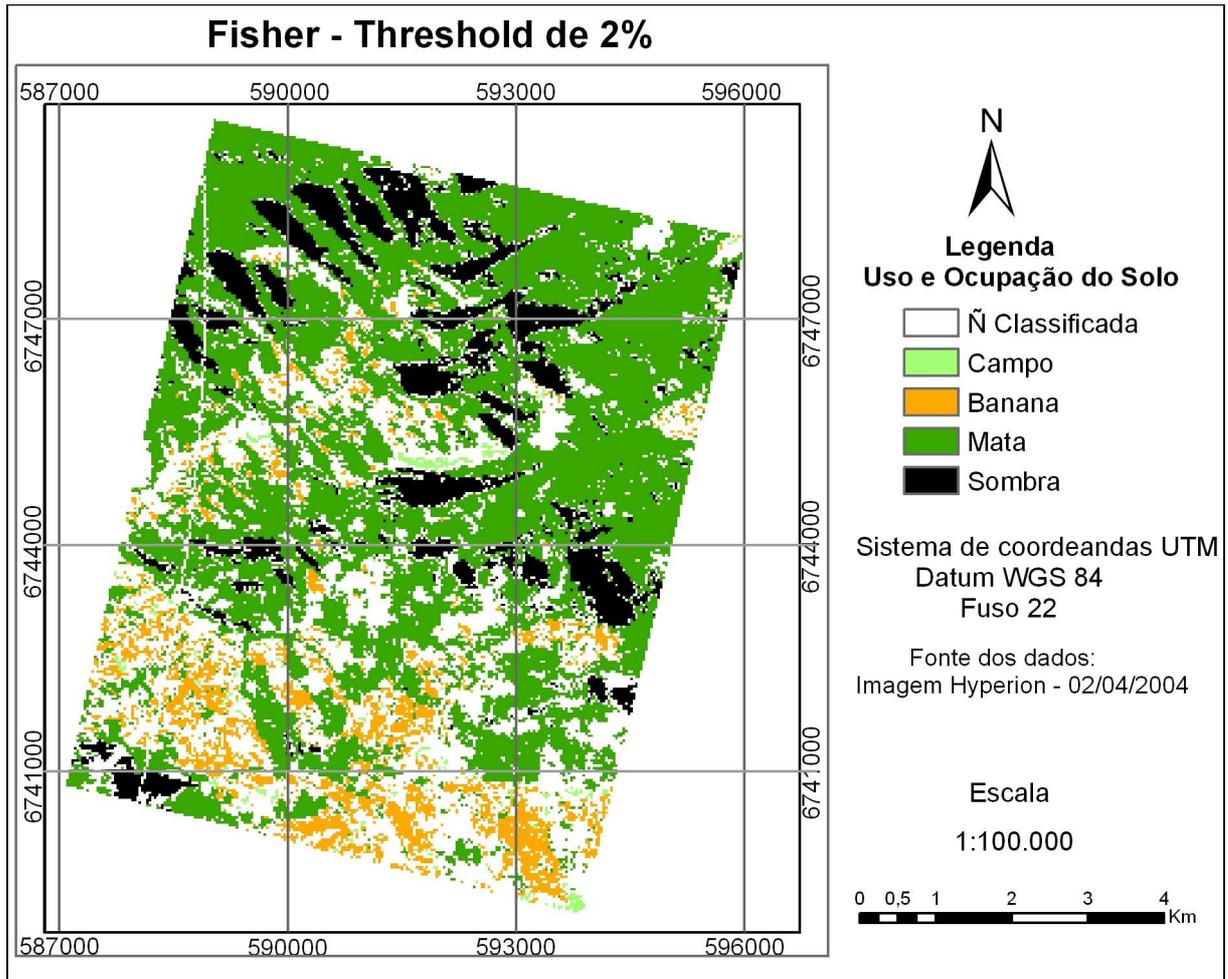


Figura 24: Imagem classificada pelo método Fisher com *Threshold* de 2%, sensor Hyperion, data 02/05/2004.

Tabela 15: Matriz de confusão da classificação Fisher com *Threshold* de 2%, confeccionada pelo método de Re-substituição, no software Multispec.

Referência		Nº de amostras nas classes						
Classes	Acurácia (%)	Amostras	Campo	Banana	Mata	Sombra	<i>Threshold</i>	
Campo	92,2	51	47	0	0	0	4	
Banana	91,9	135	0	124	0	0	11	
Mata	95,3	129	0	0	123	0	6	
Sombra	99,5	196	0	0	0	195	1	
TOTAL		511	47	124	123	195	22	
Reliability Accuracy (%)*			100.0	100.0	100.0	100.0		
Exatidão Global (489 / 511) = 95,7%								
Índice Kappa (X100) = 94,0%. Variância = 0,000150.								

Tabela 16: Distribuição das áreas das classes na imagem classificada pelo método de Fisher com *Threshold* de 2%.

Classes	Amostras	Porcentagem	Área (Hectares)
Campo	433	0,72	46,56
Banana	4697	7,80	505,04
Mata	29244	48,59	3144,41
Sombra	6622	11,00	712,02
<i>Não classificada</i>	19186	31,88	2062,94
Total	116.739	100,00	6470,95

Ocorreu um aumento da área classificada da imagem com relação ao método Máxima Verossimilhança. O classificador de Fisher, utilizando o mesmo limiar de 2 % para exclusão dos pixels, deixou de classificar 31,88%, desta forma o método de Fisher classificou 17,10% a mais da imagem do que o método Máxima Verossimilhança.

#### **4.4.2 Cruzamento entre as Imagens Classificadas e os Vetores Extraídos da Imagem de Alta Resolução Espacial**

As confecções das tabelas de confusão a partir dos dados vetoriais foram feitas com informações das áreas extraídas da imagem de alta resolução espacial. Desta maneira os valores das áreas dos vetores apresentados estão em metros quadrados (m<sup>2</sup>).

##### **4.4.2.1 Distância Euclidiana Mínima**

O valor do Índice Kappa, para o método de classificação da Distância Euclidiana Mínima, comparado com os dados extraídos da imagem de alta resolução espacial, foi de 0,2238 e a Exatidão Global foi de 0,5952, Tabela 18. Estes valores foram os mais baixos dentre os classificadores avaliados. O total de área que foi classificada corretamente foi de 1208,22 ha, dos 2033,34 ha classificados.

Tabela 17: Matriz de confusão da classificação pelo método da Distância Euclidiana.

Classificação	Referência( vetores)				Total Classificado	Erro comissão
	Campo	Banana	Mata	Sombra		
Campo	51,35	6,39	21,33	0,03	79,11	0,35
Banana	74,45	150,84	249,83	0,00	475,13	0,68
Mata	95,84	162,81	974,61	4,23	1237,49	0,21
Sombra	2,44	5,52	202,24	31,42	241,62	0,87
	224,08	325,56	1448,01	35,68	2033,34	
Erro Omissão	0,77	0,54	0,33	0,12		

Tabela 18: Índices de acurácia Kappa e Exatidão Global do método Distância Euclidiana.

Kappa	0,2238
Exat. Global	0,5942

O vetor da classe Banana representava 325,56ha, que seria equivalente a aproximadamente 3617 pixels da imagem Hyperion. Desta área total, 150,84ha foram classificados corretamente, o que corresponde a aproximadamente 1676 pixels. A classe Banana apresentou grande confusão na classificação com a classe Mata, já que mais da metade das áreas vetorizadas como Banana foram classificados como Mata, 162,81ha, o que corresponde a aproximadamente 1808 pixels (Tabela 17).

#### 4.4.2.2 Linear de Fisher

O valor do Índice Kappa para o método de classificação Linear de Fisher foi de 0,2612 e a Exatidão Global da classificação foi de 0,5970, Tabela 20. Estes valores são maiores do que os valores da classificação pelo método da Distância Euclidiana Mínima. O total da área classificada corretamente por este método foi de 1213,92 ha, dos 2033,34 ha classificados (Tabela 19).

Tabela 19: Matriz de confusão da classificação pelo método de Fisher.

Classificação	Referência( vetores)				Total Classificado	Erro comissão
	Campo	Banana	Mata	Sombra		
Campo	42,01	8,29	18,53	0,03	68,86	0,39
Banana	130,29	184,61	301,33	0,17	616,40	0,70
Mata	50,17	129,62	957,83	6,01	1143,63	0,16
Sombra	1,62	3,04	170,32	29,47	204,46	0,86
	224,08	325,56	1448,01	35,68	2033,34	
Erro Omissão	0,81	0,43	0,34	0,17		

Tabela 20: Índices de acurácia Kappa e Exatidão Global do método Fisher.

Kappa	0,2612
Exat. Global	0,5970

A classe Banana foi a única classe que teve um aumento de área classificada corretamente. As classes Campo, Mata e Sombra tiveram uma diminuição da sua área classificada corretamente. O aumento da área classificada corretamente da classe Banana foi de 33,77 ha. A diminuição das áreas classificadas corretamente de Campo, Mata e Sombra foram de 9,34 ha, 16,78 ha e 1,95 ha respectivamente (Tabela 19) .

#### 4.4.2.3 Fisher com Threshold 2%

O método de classificação de Fisher aplicado com um *Threshold* de 2% apresentou uma significativa melhora nos seus Índices de acurácia. Sendo que o valor de Kappa ficou 0,3456 e o valor da Exatidão Global foi de 0,6951, Tabela 22. O total de área que foi classificada corretamente foi de 858,28 ha, dos 1234,73 ha classificados, Tabela 21.

Tabela 21: Matriz de confusão da classificação pelo método de Fisher com *Threshold* de 2%.

Classificação	Referência( vetores)				Total Classificado	Erro comissão
	Campo	Banana	Mata	Sombra		
Campo	12,03	2,32	3,89	0,02	18,27	0,34
Banana	31,50	119,01	125,72	0,00	276,24	0,57
Mata	14,22	69,20	703,87	2,03	789,32	0,11
Sombra	0,95	2,17	124,42	23,37	150,90	0,85
	58,70	192,71	957,89	25,42	1234,73	
Erro Omissão	0,80	0,38	0,27	0,08		

Tabela 22: Índices de acurácia Kappa e Exatidão Global do método Fisher com *Threshold* de 2%.

Kappa	0,3456
Exat. Global	0,6951

A classe Banana teve 119,01 ha classificados corretamente, dos 192,71 ha classificados na imagem. A Classe Mata teve 703,87 ha corretamente classificados, dos 957,89 ha. Os erros de omissão e de comissão mais baixos foram os das classes Sombra e Mata. Isto significa que poucas áreas destas classes foram classificadas em outras classes, e que poucas áreas de outras classes foram classificadas nestas classes.

Analisando o erro de comissão mais baixo, que foi o da classe Mata, 0,11, significa que 11% da área desta classe deveria estar distribuído em outras classes e não na classe Mata. E analisando o erro da mesma classe, 0,27, significa que 27% de áreas que estão distribuídas nas outras classes deveriam ter sido classificadas como Mata.

#### 4.4.2.4 Máxima Verossimilhança

O método de classificação de Máxima Verossimilhança apresentou o mais alto resultado de Exatidão Global e também de Índice Kappa, entre os métodos sem *Threshold*. O valor de Kappa foi de 0,3218 e o valor da Exatidão Global foi de 0,6911, Tabela 24.

Conforme o Tabela 23 a classe que teve o menor erro de omissão e de comissão foi a classe Mata, tendo 0,25 de erro de omissão e 0,14 de comissão. A classe Banana teve o segundo menor erro de omissão, 0,42 e o maior erro de comissão, 0,70.

Tabela 23: Matriz de confusão da classificação pelo método Máxima Verossimilhança.

Classificação	Referência( vetores)				Total Classificado	Erro comissão
	Campo	Banana	Mata	Sombra		
Campo	49,25	12,00	24,29	0,03	85,57	0,42
Banana	139,51	188,48	293,18	0,50	621,68	0,70
Mata	35,32	124,81	1092,56	21,28	1273,96	0,14
Sombra	0,00	0,27	37,98	13,88	52,13	0,73
	224,08	325,56	1448,01	35,68	2033,34	
Erro Omissão	0,78	0,42	0,25	0,61		

Tabela 24: Índices de acurácia Kappa e Exatidão Global do método Máxima Verossimilhança.

Kappa	0,3218
Exat. Global	0,6611

#### 4.4.2.5 Máxima Verossimilhança com Threshold 2%

O método de classificação de Máxima Verossimilhança apresentou o melhor resultado de Exatidão Global e também de Índice Kappa, entre todos os métodos utilizados. O valor de Kappa foi de 0,4885 e o valor da Exatidão Global foi de 0,7755, Tabela 26. Entre todos os métodos de classificação analisados, este foi o que obteve os maiores valores de Índice Kappa e de Exatidão Global.

A classe que teve o menor erro de omissão e de comissão foi a classe Mata, tendo 0,17 de erro omissão e 0,07 de comissão. A classe Banana teve o terceiro menor erro de omissão, 0,26 e também o terceiro menor erro de comissão, 0,55. A classe Sombra teve o maior erro de comissão, 0,71 e o segundo menor erro de omissão, 0,20, conforme o Tabela 25.

Tabela 25: Matriz de confusão da classificação pelo método Máxima Verossimilhança com *Threshold* de 2%.

Classificação	Referência( vetores)				Total Classificado	Erro comissão
	Campo	Banana	Mata	Sombra		
Campo	15,04	3,38	5,85	0,02	24,29	0,38
Banana	36,65	97,39	83,35	0,00	217,39	0,55
Mata	6,37	30,71	547,66	2,49	587,24	0,07
Sombra	0,00	0,17	24,98	10,15	35,30	0,71
	58,06	131,65	661,84	12,67	864,22	
Erro Omissão	0,74	0,26	0,17	0,20		

Tabela 26: Índices de acurácia Kappa e Exatidão Global do método Máxima Verossimilhança com *Threshold* de 2%.

Kappa	0,4885
Exat. Global	0,7755

Analisando-se os resultados de todos os processos de classificação, verificamos uma melhora na acurácia quando trabalhamos com o limiar de exclusão (*Threshold* 2%), sendo que o índice Kappa aumentou 0,08, para o classificador de Fisher e 0,16 para o de Máxima Verossimilhança. A Exatidão Global também aumentou, sendo o aumento de 0,09 para Fisher e 0,11 para a Máxima Verossimilhança.

O processo de classificação Máxima Verossimilhança com o *Threshold* de 2% foi o método que classificou a menor quantidade de área das amostras vetorizadas, 864,22 ha, já o método Linear de Fisher com *Threshold* de 2% classificou 370,51 ha a mais, totalizando 1234,73 ha.

A grande diferença entre os valores de acurácia, principalmente nos Índices Kappa apresentados para a análise com os dados das próprias amostras de treinamento do classificador comparado com os dados extraídos da imagem de alta resolução espacial, deve-se principalmente pela diferença de resolução espacial das imagens, Hyperion 30 m e IKONOS 1 m.

Desta maneira, a maior precisão dos dados vetoriais permitiu identificar outras classes de uso do solo, que não foram contabilizadas no processo de classificação, mas, que foram identificadas no processo de vetorização, como solo exposto e outros cultivos. Como as

amostras de treinamento para os classificadores foram extraídas da imagem Hyperion, algumas amostras podem ter sido influenciadas por outras classes de uso do solo que não foram contabilizadas no processo de classificação.

Como os vetores destas outras áreas não foram utilizados na avaliação, presume-se que grande parte das áreas que foram classificadas erroneamente, pertençam a estas classes. Como o Índice Kappa é de avaliação mais criteriosa, e leva em consideração não somente os acertos, mas também os erros e a própria distribuição dos erros entre as classes, os baixos valores apresentados pelas classificações demonstram que existe um elevado grau de erro, e que este erro está distribuído em todas as classes.

Tabela 27: Índices de acurácia de todos os métodos de classificação implementados, calculados a partir dos dados vetoriais extraídos da imagem de alta resolução espacial.

Classificadores	Índices de acurácia	
	Kappa	Exatidão global
Máxima verossimilhança	0,3218	0,6611
Máxima verossimilhança c/ <i>Threshold</i> 2%	0,4885	0,7755
Distância euclidiana mínima	0,2238	0,5942
Fisher	0,2612	0,5970
Fisher c/ <i>Threshold</i> 2%	0,3456	0,6951

Conforme classificação sugerida por Vieira & Soares (2008), os valores admitidos de índice Kappa entre 0,2 e 0,4 são razoáveis e, os valores entre 0,4 e 0,6 são bons, em uma classificação que varia entre péssimo a excelente. Desta maneira somente o método da Máxima Verossimilhança com *Threshold* de 2% apresenta um bom resultado de Índice Kappa, todos os outros métodos utilizados são classificados como razoáveis conforme esta classificação.

Oliveira (2009) realizou um estudo similar a este com uma imagem HRG-SPOT 5. Ele trabalhou com os classificadores, Máxima Verossimilhança Gaussiana, Distância Euclidiana Mínima, Battacharya e Ioseg, para o município de Três Cachoeiras. Neste trabalho ele usou outras classes de uso e ocupação do solo como: Floresta Ombrófila Densa, Formação Florestal Secundária, Florestamento, Bananais, Solo Exposto, Campo e Sombra.

Os resultados da avaliação dos classificadores utilizados por Oliveira (2009) comparando com um fragmento vetorizado da mesma imagem utilizada nos processos de classificação são apresentados na Tabela 28. O resultado do classificador Máxima

Verossimilhança Gaussiana, foi de 0,5054 para o Índice Kappa e de 61,78 % para a Exatidão Global. Comparando este resultado com o encontrado na classificação Máxima Verossimilhança com *Threshold* de 2% para as 5 bandas selecionadas da imagem Hyperion utilizada neste trabalho, houve uma melhora na Exatidão Global de 15,77 pontos percentuais. Mesmo comparando com o melhor resultado de Oliveira (2009), que foi o do Bhattacharya, o valor da Exatidão Global encontrado na classificação Máxima Verossimilhança com *Threshold* de 2% foi 8,42 pontos percentuais superior.

Tabela 28: Tabela dos Índices Kappa e Exatidão Global dos classificadores utilizados por Oliveira (2009) com dados HRG – SPOT 5 para o município de Três Cachoeiras.

Fonte: Oliveira, 2009.

Classificadores	Índices de acurácia	
	Kappa- qualidade	Exatidão Global
Máxima Verossimilhança Gaussiana	0,5054	61,78%
Distancia Euclidiana Mínima	0,3647	50,11%
Bhattacharya	0,5753	69,13%
Isoseg	0,5194	64,33%

Estes melhores valores de Exatidão Global utilizando os mesmos classificadores que Oliveira (2009) utilizou para a diferenciação das classes é resultado da vantagem da utilização de dados hiperespectrais, que permite uma melhor análise dos alvos, visto que tem a capacidade de compor uma imagem com resolução espectral com um nível de detalhamento bem próximo dos verificados em espectrorradiômetros de campo ou laboratório. Como o procedimento de extração de feições pelo método de Bhattacharya selecionou as melhores bandas para separação destas classes, com base nas características das amostras de treinamento extraídas da imagem para serem utilizadas nos processos de classificação, otimizou-se o resultado da classificação. A eliminação das bandas, cujos comprimentos de ondas diferenciam menos as classes, auxilia no melhor resultado da exatidão da classificação, já que essas bandas fariam com que os resultado das funções de decisão dos classificadores fossem mais baixas, possibilitando uma maior confusão no processo de classificação.

Como já discutido anteriormente, devido à diferença de resolução espacial e espectral das imagens analisadas e, principalmente, pela existência de outras classes de uso do solo, identificadas na imagem de alta resolução, o Índice de Exatidão Global representa melhor a qualidade dos resultados das classificações, já que o mesmo verifica somente os valores das áreas corretamente classificadas. Desta maneira podemos dizer que o dado hiperespectral contribui para a melhoria da classificação, e que os baixos valores de Índice Kappa não representam de forma adequada este avanço. Provavelmente estes baixos valores do Índice

Kappa são ocasionados por pequenas áreas de outras classes de uso do solo, que se encontram inseridas em regiões com um predomínio diferente de uso e ocupação. Devido a baixa resolução espacial do sensor Hyperion, não se pode evidenciar esta diferença. Fazendo com que as pequenas áreas fossem erroneamente rotuladas no processo de classificação.

## 5 - CONCLUSÃO

Com base nos resultados obtidos neste estudo, podemos destacar as seguintes conclusões em relação a análise das áreas de Mata Atlântica e de cultivo de bananas no Litoral Norte gaúcho do estado do Rio Grande do Sul.

Em relação aos testes dos classificadores Bayesianos, verificou-se que o método Máxima Verossimilhança com *Threshold* de 2% apresentou o melhor resultado para a separabilidade entre as classes de Banana e Mata Atlântica. O mesmo apresentou os maiores valores de Índice Kappa e de Exatidão Global e também um dos menores erros de omissão e comissão para estas classes de uso e ocupação do solo, demonstrando o seu alto potencial de classificação. Uso do *Threshold* representou um ganho na acurácia do processo de classificação.

Os dados hiperespectrais demonstraram ser uma boa alternativa para análise ambiental, já que os mesmos trazem uma outra forma de abordagem e análise. Mesmo utilizando-se de métodos tradicionais de classificação, os dados trabalhados aqui atingiram um bom desempenho com a utilização do critério de seleção de feições, Bhattacharya. Conforme discutido e analisado no capítulo 4, através dos bons resultados comparados com os dados multiespectrais.

Em relação à variação espectral das classes de vegetação, foi destacado que elas apresentaram uma semelhança na forma da curva espectral, referente à configuração da curva teórica do comportamento espectral da vegetação, mas valores de refletância distintos. A refletância da classe Banana apresentou maiores valores do que a classe Mata.

A refletância da classe Banana apresentou diferentes valores de refletâncias condicionadas pelas variáveis geomorfológicas do terreno que condicionam o desenvolvimento vegetativo das plantas. Desta maneira, as áreas das classes de vegetação orientadas para o Norte apresentaram maior refletância do que as áreas voltadas para o Sul, esta diferença de refletância, conforme analisado, é ocasionado pelos diferentes graus de desenvolvimento das plantas, as áreas que recebem maior fluxo de radiação tendem a se desenvolverem mais do que as áreas que recebem menor fluxo de radiação. Conforme já

destacado, o aumento da biomassa aumenta a refletância na porção do infravermelho do espectro eletromagnético.

Pra validar ainda mais a hipótese que a utilização dos dados hiperespectrais representam um ganho na análise da diferenciação entre as áreas de Mata Atlântica e Bananais recomenda-se:

Verificar o poder de discriminação do classificador SAM, *Spectral Angle Mapper*, para realmente vermos todo potencial de separação de classes de uso e ocupação do solo dos dados hiperespectrais, e compará-los com os resultados encontrados nos classificadores tradicionais.

Em relação à variável ambiental analisada, foi verificado que a orientação da vertente das áreas de plantio de Banana tem influência no comportamento da intensidade da curva espectral, mas não na forma da curva. A declividade poderia influenciar nos resultados, mas essa variável não foi analisada. Pode ser realizado um estudo comparativo através de uma classificação com a utilização de classes de vegetação subdivididas com relação as orientações de vertentes para verificar se existe melhoria nos valores dos índices de acurácia.

Para melhoria em uma análise futura, sugere-se utilizar os próprios dados extraídos da imagem de alta resolução espacial, para efetuar o treinamento e avaliação dos classificadores, utilizando-se de 50% dos dados vetoriais para treinamento e os outros 50% para validação da classificação. Desta maneira diminuiríamos a probabilidade da ocorrência de amostras “poluídas” com outras classes de uso do solo, o que possivelmente aumentaria a acurácia dos classificadores, já que trabalharíamos com dados numa mesma escala de análise.

## 6 - BIBLIOGRAFIA

BISPO, P. da C. **Dados geomorfométricos como subsídio ao mapeamento da vegetação.** 2007. (mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais, curso de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007

CLARK R.N. 1999. **Spectroscopy of rocks and minerals, and principles of spectroscopy.** in: Rencz, A.N.(ed.) remote sensing for the earth sciences, manual of remote sensing, Ryerson, R.A.; (ed), 3 , John Wiley & Sons, INC., New York, pp.:3-58

CURRAN, P. J.; DUNGAN, J. L.; PETERSON. D. L. **Estimating the foliar biochemical concentration of leaves with reflectance spectrometry: testing the Kokaly and Clark methodologies.** Remote Sensing of Environment. v.76, p.349-359, 2001.

DUCART, D. F. **Caracterização da alteração hidrotermal associada às ocorrências auríferas de Los Menucos, Argentina, Por meio de Técnicas de sensoriamento remoto e espectroscopia de reflectância.** 2004. 86f. Dissertação (Mestrado em Geociências)- Instituto de Geociências, curso de Pós-Graduação em Geociências. Universidade Estadual de Campinas, Campinas, 2004.

FELDE, G.W.; ANDERSON, G.P.; COOLEY, T.W.; MATTHEW, M.W.; ADLERGOLDEN, S.M.; BERK, A.; LEE, J. **Analysis of Hyperion data with the FLAASH atmospheric correction algorithm.** In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, n.3, 21-25 jul. 2003, [S.l.]. Proceedings... v. 1, p.90-92. Disponível em: <<http://ieeexplore.ieee.org/iel5/9010/28601/01293688.pdf>>. Acesso em: 15 nov. 2007.

FLORENZANO, T. G. **Imagens de Satélites para Estudos Ambientais.** São Paulo: Oficina de Textos, 2002. 97p.

GALVÃO, L. S; FORMAGGIO, A. R; TISOT, D. A; **DISCRIMINAÇÃO DE VARIEDADES DE CANA-DE-AÇÚCAR COM DADOS HIPERESPECTRAIS DO SENSOR HYPERION/EO-1,** Revista Brasileira de Cartografia No 57/01, 2005.

GALVÃO, L. S; FORMAGGIO, A. R; BREUNIG, F. M, **Relações entre índices de vegetação e produtividade de soja com dados de visada fora do nadir do sensor Hyperion/EO-1** Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 1095-1102.

GOEL, N. S. **Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data.** Remote Sensing Reviews, v. 4 p. 1-21, 1988.

IBGE. **Mapa de Biomas e Vegetação.** Rio de Janeiro, 21 mai. 2004. Notícias. Disponível em: <[http://www.ibge.gov.br/home/presidencia/noticias/noticia\\_visualiza.php?id\\_noticia=169](http://www.ibge.gov.br/home/presidencia/noticias/noticia_visualiza.php?id_noticia=169)> Acesso em : 13 mai. 2010.

IBAMA. **Ecossistemas Brasileiros**. Brasília. Disponível em:  
<[http://www.ibama.gov.br/ecossistemas/mata\\_atlantica.htm](http://www.ibama.gov.br/ecossistemas/mata_atlantica.htm)> Acesso em: 13 mai. 2010

FEPAM. **Implantação da reserva da biosfera da Mata Atlântica do Rio Grande do Sul. Porto Alegre**, Disponível em: <<http://www.fepam.rs.gov.br/programas/kfw.asp>> Acesso em: 13 mai. 2010

FONSECA, E. L. da; Rosa, L. M. G ; Fontana, D. C. **Caracterização espectral de Paspalum notatum em diferentes níveis de adubação nitrogenada. Pesquisa Agropecuária Brasileira**, Brasília, v. 37, n. 3, p. 365-371, 2002.

FUNDAÇÃO SOS MATA ATLÂNTICA; INPE. **Atlas dos Remanescentes Florestais da Mata Atlântica – Período 2005 a 2008**. Disponível em: <[http://mapas.sosma.org.br/site\\_media/download/atlas%20mata%20atlantica-relatorio2005-2008.pdf](http://mapas.sosma.org.br/site_media/download/atlas%20mata%20atlantica-relatorio2005-2008.pdf)>. Acesso em 13 mai.2010

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspective em recursos terrestres/John R. Jensen; tradução José Carlos Neves Epiphanyo (cordenador)...[ET AL.] – São José dos Campos, SP: Parêntese, 2009.**

LIMA, D. C. **A bananicultura na área de proteção ambiental da serra de Maranguape-CE e suas implicações no ambiente físico, humano e na biodiversidade**. 2005 Dissertação (mestrado em Desenvolvimento e Meio Ambiente), curso de Pós-Graduação em Desenvolvimento e Meio Ambiente, Universidade Federal do Ceará, Fortaleza, 2005

LANGHE, E. de. **Banana and plantain: the earliest fruit crops?** In: INIBAP (International Network for the Improvement of Banana and Plantain). Networking banana and plantain: annual report 1995 – Focus paper 1. Montpellier (FR): INIBAP, 1996, p. 6-8. Disponível em: <[http://bananas.bioversityinternational.org/files/files/pdf/publications/an05\\_en.pdf](http://bananas.bioversityinternational.org/files/files/pdf/publications/an05_en.pdf)>. Acesso em: 15 mar. 2007.

LINN, R. de M. **Avaliação de modelos de mistura spectral MESMA e SMA aplicados aos dados hiperespectrais Hyperion/EO-1 adquiridos na planície costeira do estado do Rio Grande do Sul**. 2008. 140 f. Dissertação (Mestrado em Sensoriamento Remoto) Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, Curso de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

MMA. **Campos Sulinos: conservação e uso sustentável da biodiversidade / Valério De Patta Pillar et al. Editores. – Brasília: MMA, 2009. 403 p.**

MORTON, J. Banana. In: MORTON, J. F. **Fruits of warm climates**. Miami: Florida Flair Books, 1987, p. 29-46. Disponível em:  
<<http://www.hort.purdue.edu/newcrop/morton/banana.html>>. Acesso em: 13 mai. 2010.

MOREIRA, M. A. **Fundamentos Do Sensoriamento Remoto e metodologia de aplicação**. 2 ed. Viçosa: UFV, 2003. 307p.

MORELLATO, L. P. C.; Haddad, C. F. P. Introduction: **The Brazilian Atlantic forest**. *Biotropica*. v. 32, n. 4b, p. 786-792. 2000.

NETO, B. S; Basso, D. **Sistemas agrários do Rio grande do Sul: análise e recomendações de políticas**. Ijuí: Ed. Unijui, 2005. 312. p.

NOGUCHI, M. T. G. **Um Sistema Baseado em Regras Fuzzy para Classificação Supervisionada de Imagens Multiespectrais de Alta Resolução**. Dissertação de Mestrado. Universidade Federal do Paraná, 2004.

NOVO, E.M.L. de M. **Sensoriamento Remoto: princípios e aplicações**. 3 ed. São Paulo: Blucher, 2008. 362 p.

NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 2. ed. São Paulo: Edgard Blucher, 1992.

OLIVEIRA, G. de, **Integração de dados HRG-SPOT5 e SRTM para espacialização de bananais em área do bioma mata Atlântica no município de Três Cachoeiras, RS** 2009. 83 f. Monografia (graduação) Instituto de Geociências, Curso de Geografia bacharelado, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

PONZONI, F.J. Comportamento espectral da vegetação. In: Meneses, P.R.; Madeira Netto, J.S (Org). **Sensoriamento Remoto: Reflectância de alvos naturais**. Brasília: Universidade de Brasília, Embrapa Cerrados, 2001. 262 p.

PONZONI, F. J; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**, São José dos Campos, SP: A. Silva Vieira Ed. ; 2007

PORTILLO, J. E. **Sensoriamento remoto e SIG na análise da Cotonicultura nos municípios de Campo Verde e Primavera do Leste – MT**. 2007 Dissertação (Mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais, Curso de Pós-Graduação em Sensoriamento Remoto, São Jose dos Campos, 2007

RAMBO, B. **A Fisionomia Do Rio Grande Do Sul**. São Leopoldo: 3.ed. 2000. 473p.

INFOGEO. Curitiba: n.33, 2004.

RICHARDS, A. R. & JIA, X. **Remote sensing digital analysis: an introduction**. 3th. Berlin: Springer – Verlag 1998.

RIO GRANDE DO SUL. Governo do Estado. Secretaria Estadual do Meio Ambiente. **Inventário Florestal Contínuo do Rio Grande do Sul**. Porto Alegre, 2002. Disponível no site: <[www.ufsm.br/ifcrs](http://www.ufsm.br/ifcrs)> Acessado em: 20 jun 2010.

SEPLAG. **Atlas Socioeconômico do Rio Grande do Sul**. Disponível em: <<http://www.scp.rs.gov.br/atlas/atlas.asp?menu=496>> Acesso em maio. 2010.

TABARELLI, M. et al. **Challenges and opportunities for biodiversity conservation in the Brazilian Atlantic forest**. *Conservation Biology*, v. 19, n. 3, p. 695-700, 2005.

TISOT D. A. **Modelos de transferência radiativa no estudo da concentração de clorofila em cana-de-açúcar, utilizando dados hiperespectrais.** 2009. 112f. Tese (Doutorado em sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

UNGAR, S.G.; PEARLMAN, J.S.; MENDENHALL, J.A.; REUTER, D. **Overview of the Earth Observing One (EO-1) mission.** IEEE Transactions on Geoscience and Remote Sensing, v. 41, n.6, p. 1149-1159,2003.

USGS ,United States Geological Survey Disponível em:<<http://eo1.usgs.gov/hyperion.php>>  
Acessado em: 13 mai 2010.

VIBRANS, A. C. **A cobertura florestal da bacia do Rio Itajaí** – elementos para uma análise histórica. 2003. 240f. Tese (Doutorado em Geografia) - UFSC, Florianópolis, 2003.

VIEIRA, C. A. O; SOARES, V. P. **Projeto UFV Geocapacitar:** Processamento Digital de Imagens. 2008 UFV

WIVES. D.G. **Funcionamento e performance dos sistemas de produção da banana na microrregião do Litoral Norte do Rio Grande do Sul.** 2008. 164 p. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul, Porto Alegre. 2008.