

ALESSANDRA LOPES BRAGA

**IDENTIFICAÇÃO DE EXTENSAS ÁREAS DE CULTURAS AGRÍCOLAS
NUMA ABORDAGEM ESPECTRO-TEMPORAL UTILIZANDO IMAGENS
MODIS**

Dissertação apresentada
à Universidade Federal de
Viçosa, como parte das
exigências do Programa de
Pós-Graduação em Engenharia
Civil, para obtenção do título de
Magister Scientiae.

VIÇOSA
MINAS GERAIS - BRASIL
2007

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

B813i
2007

Braga, Alessandra Lopes, 1978-

Identificação de extensas áreas de culturas agrícolas
numa abordagem espectro-temporal utilizando imagens
MODIS / Alessandra Lopes Braga. – Viçosa, MG, 2007.
xv, 124f. : il. (algumas col.) ; 29cm.

Inclui anexo.

Orientador: Carlos Antônio Oliveira Vieira.

Dissertação (mestrado) - Universidade Federal de
Viçosa.

Referências bibliográficas: f. 90-98.

1. Sensoriamento remoto. 2. Imagens multiespectrais.
3. Cultivos agrícolas - Identificação. 4. Redes neurais
(Computação). 5. Máxima verossimilhança. I. Universidade
Federal de Viçosa. II. Título.

CDD 22.ed. 621.3678

ALESSANDRA LOPES BRAGA

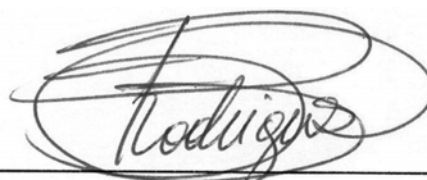
**IDENTIFICAÇÃO DE EXTENSAS ÁREAS DE CULTURAS AGRÍCOLAS
NUMA ABORDAGEM ESPECTRO-TEMPORAL UTILIZANDO IMAGENS
MODIS**

Dissertação apresentada
à Universidade Federal de
Viçosa, como parte das
exigências do Programa de
Pós-Graduação em Engenharia
Civil, para obtenção do título de
Magister Scientiae.

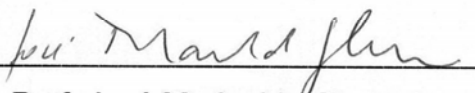
APROVADA: 06 de março de 2007.



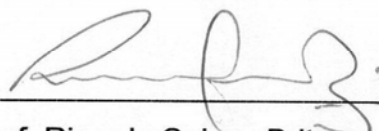
Prof. Antônio Simões Silva
Co-Orientador



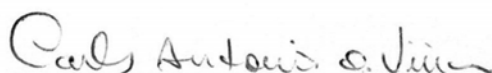
Prof. Dalto Domingos Rodrigues
Co-Orientador



Prof. José Marinaldo Gleriani



Prof. Ricardo Seixas Brites



Prof. Carlos Antônio Oliveira Vieira
(Orientador)

*A meus pais,
pela educação e pelo amor,
que me prepararam para a vida,
aos meus irmãos pelos bons
momentos compartilhados,
e ao Francisco, pelo amor e apoio,
eu dedico.*

AGRADECIMENTOS

Primeiramente a Deus, pela grande conquista.

Ao grande apoio da minha família.

Ao Francisco pelo carinho, amor, companheirismo e paciência.

Ao Professor e Orientador Carlos Vieira, pela paciência, por todo apoio e pela oportunidade de crescimento profissional e pessoal.

Aos colegas de curso: Flávio, Geíza, Márcio, Renan, Giuliano, Leonardo, Rafael e Rômulo. Em especial ao apoio da Geíza e do Leonardo, no decorrer dos experimentos.

Ao Márcio Puppín, pelo apoio dado na implementação da rotina para interpolação das superfícies analíticas de tendência.

Aos professores Antônio Simões Silva e Dalto Domingos Rodrigues, pelo apoio.

Aos professores José Marinaldo Gleriani e Ricardo Seixas Brites, pelas valiosas contribuições e sugestões dadas a este trabalho.

Ao professor Vicente Paulo Soares, do Departamento de Engenharia Florestal, pelo uso do *software* ERDAS Imagine 8.5.

Aos grandes amigos Selma e Mário, pela força e companheirismo em todos os momentos.

Às amigas da república Poli e Meire, pelo companheirismo.

Ao Núcleo de Geoprocessamento Professor Celestino Aspiazú - NUGEO, pela utilização do *software* Idrisi Kilimanjaro.

À CAPES, o fomento à pesquisa e subsídio financeiro na forma da bolsa de mestrado.

À Universidade Federal de Viçosa (UFV), em especial o Departamento de Engenharia Civil, pela oportunidade da realização do curso de mestrado.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

BIOGRAFIA

ALESSANDRA LOPES BRAGA, filha de João Geraldo Braga e Maria Helena Lopes Braga, nasceu em 2 de outubro de 1978, na cidade de Timóteo, Minas Gerais.

Em 2000, iniciou o Curso de Engenharia de Agrimensura na Universidade Federal de Viçosa, Viçosa-MG, graduando-se em 2005.

Em março de 2005, iniciou o Programa de Pós-Graduação em Engenharia Civil, em nível de mestrado, na Universidade Federal de Viçosa, submetendo-se à defesa de dissertação em 6 de março de 2007.

SUMÁRIO

RESUMO	viii
ABSTRACT	x
LISTA DE FIGURAS	xii
LISTA DE TABELAS.....	xiv
1 - INTRODUÇÃO	1
1.1 Justificativa e Hipóteses de Pesquisa.....	3
1.2 Objetivo	4
1.3 Organização da Dissertação	4
2 - FUNDAMENTOS TEÓRICOS	6
2.1 Previsão de Safras no Brasil	6
<i>2.1.1 Censos Agropecuários</i>	<i>7</i>
<i>2.1.2 Levantamentos por Amostragem</i>	<i>8</i>
2.1.2.1 Métodos Subjetivos.....	8
2.1.2.2 Métodos Probabilísticos.....	10
2.2 Uso do Sensoriamento Remoto nas Estimativas Agrícolas	14
<i>2.2.1 Sensor Orbital.....</i>	<i>18</i>
2.2.1.2 Sensor MODIS.....	19
<i>2.2.2 Classificação de Imagens.....</i>	<i>23</i>
2.2.2.1 Regra da Mínima Distância Euclidiana.....	24
2.2.2.2 Classificador Gaussiano da Máxima Verossimilhança.....	25
2.2.2.3 Classificador Redes Neurais Artificiais.....	27

2.2.3 Avaliação da Classificação	33
2.2.4 Abordagem Multitemporal	38
3 - MATERIAIS E MÉTODOS.....	41
3.1 Área de Estudo	41
3.2 Materiais	43
3.2.1 Dados Orbitais.....	43
3.2.1.1 Conversão Radiométrica	45
3.2.2 Ferramentas Computacionais	46
3.3 Modelagem Multitemporal-Multiespectral	47
3.3.1 Interpolação das Superfícies Analíticas	49
3.3.1.1 Análise de Tendência Polinomial da Superfície	50
3.3.1.2 Collocation	52
3.4 Experimento.....	56
3.4.1 Imagens de Referência	58
3.4.2 O Processo de Classificação.....	64
3.4.3 Seleção de Atributos Aditiva.....	70
4 - RESULTADOS E DISCUSSÃO	72
4.1 Classificação de uma única imagem	72
4.2 Classificações Multitemporais	75
4.3 Seleção de Atributos.....	81
5 -CONCLUSÕES	88
Referências Bibliográficas	90
ANEXO A	
Qualidade Cartográfica	99
ANEXO B	
MATRIZES DE CONFUSÃO OBTIDAS PELAS DIFERENTES	
METODOLOGIAS	105
ANEXO C	
IMAGENS TEMÁTICAS OBTIDAS PELAS DIFERENTES	
METODOLOGIAS	112

RESUMO

BRAGA, Alessandra Lopes, M.Sc., Universidade Federal de Viçosa, março de 2007. **Identificação de extensas áreas de culturas agrícolas empregando uma abordagem espectro-temporal utilizando imagens MODIS**. Orientador: Carlos Antonio Oliveira Vieira, Co-orientadores: Antônio Simões Silva e Dalto Domingos Rodrigues.

Imagens do sensoriamento remoto possuem características espaciais, espectrais, radiométricas e temporais, tornando-se assim uma importante ferramenta para aplicações agrícolas nos mais diversos aspectos. Neste sentido, esta dissertação descreve uma metodologia para a classificação de extensas áreas agrícolas, em escala regional, utilizando imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*). Fez-se uso de superfícies de resposta espectral-temporal, onde cada *pixel* da imagem é representado em um espaço tridimensional, onde os eixos são respectivamente: o tempo, o comprimento de onda e a refletância. A metodologia consiste na interpolação de uma superfície analítica passando por pontos de controle, usando dois tipos de interpoladores (*Collocation* e Análise de Tendência Polinomial). Através dessa interpolação obtiveram-se os coeficientes que descrevem a distribuição da superfície no espaço tridimensional, e os mesmos foram utilizados para a classificação das imagens digitais. Para a classificação foram utilizados dois algoritmos, o classificador Gaussiano da

Máxima verossimilhança e as Redes Neurais Artificiais. Uma das limitações, no processo de classificação supervisionada, é a aquisição da imagem de referência, assim para este trabalho foram usadas três metodologias distintas para sua obtenção: Reamostragem das imagens temáticas com resolução espacial de 30 para a resolução de 250 metros; Digitalização de polígonos homogêneos em tela; e Operação de vizinhança, que consiste na eliminação de *pixels* com vizinhança com alta variação no nível digital. Para a avaliação dos resultados obtidos foram utilizados testes e análises estatísticas. Os resultados mostram que as classificações pelas redes neurais apresentam os melhores resultados, até mesmo com poucas amostras de treinamento. Os resultados também mostram importância da alta qualidade na geração da imagem de referência.

ABSTRACT

BRAGA, Alessandra Lopes, M.Sc, Universidade Federal de Viçosa, march of 2007. **Identification of agricultural crop areas extensive using an approach spectro-temporal using MODIS images.** Adviser: Carlos Antonio Oliveira Vieira, Co-advisers: Antônio Simões Silva e Dalto Domingos Rodrigues.

Remote sensing images have spatial, spectral, radiometric and temporal characteristics, which become an important tool for agricultural applications, in several aspects. This thesis describes a methodology for classification of extensive agricultural areas, in regional scale, using MODIS (Moderate Resolution Imaging Spectro-radiometer) images. It was used a spectral-temporal surface response, where each pixel of the image is represented in a three-dimensional space and the axes are: time, wavelength and reflectance, respectively. The methodology consists of an interpolation of analytical surfaces, passing through control points, using two types of interpolators (Collocation and Polynomial Trend Surfaces). Through these interpolation methods, the surface coefficients were generated, which describe the distribution of the surface in the three-dimensional space. These coefficients were then used into the classification process. Two classification algorithms were used, the maxima likelihood and artificial neural network classifiers. One of the drawbacks, in supervised classification process, is the

acquisition of the reference image. For this work were used three distinct methodologies for its attainment: thematic image sampling from the spatial resolution of 30m to 250m; digitalization of homogeneous polygons on the screen; and neighborhood operation, which consists of the elimination of pixels with neighborhood with high variation on the digital level. Statistical analyses were used in order to validate the results. The results show that the classification using neural networks had the best resulted, even with small training sample size. The results also show the importance of high quality reference image generations.

LISTA DE FIGURAS

Figura 1: Varredura do sensor MODIS, mostrando o aumento no tamanho dos <i>pixels</i> com a variação do ângulo de visada.....	22
Figura 2: Esboço de um neurônio biológico.....	28
Figura 3: Modelo de Neurônio.....	28
Figura 4: Exemplo de uma rede neural.....	31
Figura 5: Localização da área de estudo.....	42
Figura 6: Localização dos municípios que compõe a EDR de Limeira.....	42
Figura 7: Imagens MODIS, na composição colorida R - Banda 6, G - Banda 1 e B - Banda 3.....	44
Figura 8: Um esboço da metodologia STRS.....	48
Figura 9: Superfícies Analíticas de Contorno para os dois interpoladores PTS e COL.....	54
Figura 10: Fluxograma das atividades desenvolvidas nesta dissertação. ...	57
Figura 11: Máscara de um filtro 3x3 é sobreposta à imagem na posição (i j).	60
Figura 12: Representação da operação de vizinhança para o cálculo do desvio padrão.....	61
Figura 13: Imagem classificada a partir da imagem de referência Refer_3, de acordo com o limite as EDR Limeira.....	75
Figura 14: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador COL e algoritmo RNA, de acordo com o limite as EDR Limeira.....	81
Figura 15: Seleção das Características, coeficientes PTS, para as metodologias Refer_1, Refer_2 e Refer_3.....	82
Figura 16: Seleção das Características, coeficientes COL, para as metodologias Refer_1, Refer_2 e Refer_3.....	83
Figura C1: Imagem classificada a partir da imagem de referência Refer_1, com a imagem MODIS na data 21/03/2004, de acordo com o limite as EDR Limeira.....	112

Figura C2: Imagem classificada a partir da imagem de referência Refer_2, com a imagem MODIS na data 21/03/2004, de acordo com o limite as EDR Limeira.	113
Figura C3: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador PTS e algoritmo MaxVer, de acordo com o limite as EDR Limeira.	114
Figura C4: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador COL e algoritmo MaxVer, de acordo com o limite as EDR Limeira.	115
Figura C5: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador PTS e algoritmo RNA, de acordo com o limite as EDR Limeira.	116
Figura C6: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador COL e algoritmo RNA, de acordo com o limite as EDR Limeira.	117
Figura C7: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador PTS e algoritmo MaxVer, de acordo com o limite as EDR Limeira.	118
Figura C8: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador COL e algoritmo MaxVer, de acordo com o limite da EDR Limeira.	119
Figura C9: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador PTS e algoritmo RNA, de acordo com o limite da EDR Limeira.	120
Figura C10: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador PTS e algoritmo MaxVer, de acordo com o limite da EDR Limeira.	121
Figura C11: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador COL e algoritmo MaxVer, de acordo com o limite da EDR Limeira.	122
Figura C12: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador PTS e algoritmo RNA, de acordo com o limite da EDR Limeira.	123
Figura C13: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador COL e algoritmo RNA, de acordo com o limite as EDR Limeira.	124

LISTA DE TABELAS

Tabela 1: Especificações do Sensor MODIS.....	21
Tabela 2: Representação da matriz de confusão.....	34
Tabela 3: Imagens MODIS.	44
Tabela 4: Exemplo ilustrativo da Operação de vizinhança.	62
Tabela 5: Números de pixel / classe para cada limiar do desvio padrão do nível de cinza do pixel e sua vizinhança.....	63
Tabela 6: Classes da imagem de referência.....	64
Tabela 7: Comparação entre o número de ciclos e a precisão da classificação com a imagem Refer_1.	69
Tabela 8: Comparação entre o número de ciclos e a precisão da classificação com a imagem Refer_2.	69
Tabela 9: Comparação entre o número de ciclos e a precisão da classificação Refer_3.....	70
Tabela 10: Matriz de Confusão da Classificação com imagem de referência Refer_3.....	73
Tabela 11: Índices derivados das matrizes de confusão.	73
Tabela 12: Avaliação do desempenho dos classificadores MaxVer por metodologia de obtenção da imagem de referência através dos resultados dos coeficientes Kappa, a um nível de confiança de 95% ($Z = 1,96$).	74
Tabela 13: Índices derivados da matriz de confusão.	78
Tabela 14: Avaliação do desempenho dos classificadores por interpolador e por metodologia de obtenção da imagem de referência através dos resultados dos coeficientes Kappa, onde: C (COL), P (PTS), A (RNA), M (MaxVer), R (Refer_1), D (Refer_2) e O (Refer_3) a um nível de confiança de 95% ($Z = 1,96$)......	79
Tabela 15: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador COL e algoritmo RNA.....	80

Tabela 16: Seleção de Atributos para metodologia Refer_1, para cada interpolador PTS e COL.....	85
Tabela 17: Seleção de Atributos para metodologia Refer_2, para cada interpolador PTS e COL.....	86
Tabela 18: Seleção de Atributos para metodologia Refer_3, para cada interpolador PTS e COL.....	87
Tabela A1: Pontos de controle homólogos referentes à abrangência da EDR – Limeira/SP.	102
Tabela A.2: Resultado do PEC, EP, σ_x e σ_y	103
Tabela A.3: Valores de $\chi^2_{x \alpha, n-1}$ e $\chi^2_{y \alpha, n-1}$	103
Tabela B1: Matriz de Confusão da Classificação com imagem de referência Refer_1, com a imagem MODIS na data 21/03/2004.	105
Tabela B2: Matriz de Confusão da Classificação com imagem de referência Refer_2, com a imagem MODIS na data 21/03/2004.	106
Tabela B3: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador PTS e algoritmo MaxVer.	106
Tabela B4: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador COL e algoritmo MaxVer.	107
Tabela B5: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador PTS e algoritmo RNA.	107
Tabela B6: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador COL e algoritmo RNA.	108
Tabela B7: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador PTS e algoritmo MaxVer.	108
Tabela B8: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador COL e algoritmo MaxVer.	109
Tabela B9: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador PTS e algoritmo RNA.	109
Tabela B10: Matriz de Confusão da Classificação com imagem de referência Refer_3, interpolador PTS e algoritmo MaxVer.	110
Tabela B11: Matriz de Confusão da Classificação com imagem de referência Refer_3, interpolador COL e algoritmo MaxVer.	110
Tabela B12: Matriz de Confusão da Classificação com imagem de referência Refer_3, interpolador PTS e algoritmo RNA.	111
Tabela B13: Matriz de Confusão da Classificação com imagem de referência por Operação de Vizinhança, interpolador COL e algoritmo RNA.	111

1 - INTRODUÇÃO

O sensoriamento remoto tem sido considerado uma importante ferramenta nos mais diversos aspectos relacionados a aplicações agrícolas, compreendendo desde o monitoramento até a estimativa da produção agrícola (Vieira, 2000). Para essas aplicações são necessárias informações precisas, em tempo hábil e com baixo custo. Desta forma, as novas tecnologias na área de sensoriamento remoto são capazes de gerar informações que podem aperfeiçoar a nível regional e nacional a estruturação de sistemas estimativas agrícolas mais eficientes e dinâmicos. Tais informações permitem um planejamento adequado da economia agrícola em um país, podendo contornar o problema de escassez ou de excesso de produtos (Motta, 2001).

Na produção agrícola é necessário fazer um acompanhamento periódico, visto que as culturas levam um determinado tempo para se desenvolver. O sensoriamento remoto através do uso de imagens de satélites, têm servido como fonte dados para acompanhar a dinâmica agrícola, principalmente em países de grandes dimensões como o Brasil, uma vez que as caracterizam de maneira global e com visão sinóptica, além do caráter multiespectral e repetitiva (Sanchez et al., 2005).

Segundo Picoli et al. (2005), no Brasil a estimativa da área plantada é realizada predominantemente de forma subjetiva, através de questionários

aplicados aos produtores e/ou às entidades relacionadas à atividade agrícola. Essa estimativa pode ser subestimada ou superestimada, e para contornar este problema, o sensoriamento remoto - através de imagens temáticas - tem um grande potencial na correta estimativa de área plantada.

No acompanhamento da dinâmica de áreas agrícolas torna-se necessário mapeá-las, para identificar e quantificar essas áreas. Esse processo de identificação para o sensoriamento remoto é conhecido como classificação.

A classificação, de acordo com Lillessand e Kiefer (1999), tem como objetivo categorizar, por meio de procedimentos computacionais, todos os *pixels* de uma determinada imagem, atribuindo a cada um deles um “rótulo” que os relaciona a um objeto do mundo real (Mather, 1999). Gerando assim o mapa temático, a partir do reconhecimento de padrões espectrais das imagens digitais.

Segundo Vieira (2000), tradicionalmente a maioria dos procedimentos de classificação de imagens fundamenta-se na simples investigação da característica radiométrica do *pixel* (análise multiespectral). Esse procedimento assume implicitamente que a cultura possui o mesmo estágio fenológico, o que de fato normalmente não ocorre, mesmo considerando uma área homogênea, devido às diferentes datas de plantio, diferentes tipos de solo e condições climáticas. Outro aspecto importante está relacionado à periodicidade de aquisição de imagens com pouca cobertura de nuvens, pois nas regiões tropicais, a época chuvosa é, em geral, também o período de desenvolvimento da maioria das culturas de maior importância produtiva e econômica (Formaggio et al., 2005).

A resposta espectral das vegetações (principalmente culturas agrícolas) muda com o desenvolvimento da planta, desta forma é apropriada à utilização da análise multitemporal considerando as características espectrais das imagens de satélite. Neste contexto, para esta pesquisa são determinadas a justificativa e as hipóteses, adotando-se assim o objetivo desta dissertação, descritos nas seções a seguir.

1.1 Justificativa e Hipóteses de Pesquisa

As imagens do sensoriamento remoto passaram a ser uma importante fonte de informações para o levantamento das atividades agrícolas. A resposta espectral de alvos agrícolas varia devido às diferentes tempos de plantio e manejo, diferentes tipos de solo e condições climáticas (Vieira, 2000). Vários métodos têm sido desenvolvidos para classificação multiespectral no monitoramento de culturas agrícolas, porém, pelo seu dinamismo, raramente as culturas podem ser bem caracterizadas numa única data (Murakami et al., 2001; Murthy et al., 2003).

Uma das questões básicas que limitam o uso de imagens de satélite no monitoramento de culturas agrícolas é a cobertura de nuvens durante o ciclo de crescimento das culturas que depende do período de aquisição (resolução temporal). Com as características dos sensores atualmente em uso, há um conflito entre uma redução expressiva na resolução espacial em favor da ampliação da resolução temporal. Assim sendo, coexistem sensores de alta resolução espacial, como o ETM+ do Landsat 7 (30 m x 30 m) e baixa frequência de aquisição (16 dias) com sensores de baixa resolução espacial como o MODIS - *Moderate Resolution Imaging Spectroradiometer* (250 m x 250 m, 500m x 500m e 1km x 1km) e alta frequência de revisita (1 dia). A utilização de imagens MODIS, para geração de imagens temáticas em escalas regionais e até globais, são oportunamente aceitáveis por se tratar da avaliação de classes informacionais representando extensas áreas agrícolas. Desta forma, serão utilizadas no escopo desta pesquisa as imagens MODIS.

Para qualquer esquema de classificação automático de culturas agrícolas, seria importante sempre considerar a componente temporal das imagens de satélite, como por exemplo, o método proposto Vieira (2000). O método proposto por este autor, explora o uso da Superfície de Resposta Espectral-Temporal (STRS – *Spectral-Temporal Response Surface*) para caracterizar o comportamento de cada *pixel* no tempo (tempo de re-visita do sensor em estudo) para cada comprimento de onda.

Neste contexto, a presente dissertação propõe a utilização e adaptação da técnica proposta por Vieira (2000), para identificação de

extensas culturas agrícolas em áreas tropicais. Para isso, adotou-se a seguinte hipótese básica: *uma abordagem multitemporal e multiespectral pode produzir resultados significativamente mais precisos do que a abordagem tradicional (multiespectral), para realizar a identificação (ou classificação) de culturas agrícolas em imagens de sensoriamento remoto.*

Para validar esta suposição, foram exploradas algumas perguntas específicas para pesquisa:

- 1) Seria possível explorar o aspecto multiespectral na classificação das imagens MODIS, em diferentes estádios fenológicos das culturas agrícolas (análise multitemporal), para melhorar a discriminação entre elas?
- 2) Áreas encobertas por nuvens, que exercem grande influência negativa no processo de classificação em áreas tropicais, podem ser reduzidas através do procedimento de parametrização das superfícies analíticas como proposto por Vieira (2000)?
- 3) Seria possível usar bandas espectrais do sensor MODIS com sua altíssima resolução temporal, para extrair características discriminantes das culturas agrícolas no processo de reconhecimento de padrões?

1.2 Objetivo

O objetivo desta dissertação é adaptar e utilizar a metodologia desenvolvida por Vieira (2000), que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS, para classificar extensas áreas de culturas agrícolas, com vistas à previsão de safras. Nessa metodologia utiliza-se a variação espectro-temporal, durante os estádios fenológicos das culturas agrícolas, com a finalidade de melhorar o desempenho do processo de classificação.

1.3 Organização da Dissertação

Esta dissertação, além do capítulo introdutório, apresenta-se dividida em outros quatro capítulos, conforme a descrição abaixo.

No capítulo 2, são descritos os fundamentos teóricos básicos deste trabalho. Esse capítulo fornece uma introdução aos conceitos de previsão de

safras com o uso de sensoriamento remoto nas estimativas agrícolas, além de uma breve teoria de classificação de padrões em imagens de satélites. As características e propriedades do sensor MODIS são apresentados. Também são descritos alguns trabalhos que dão suporte ao uso de imagens multitemporais na classificação.

Apresenta-se no capítulo 3, a área de estudo e os dados utilizados para o desenvolvimento desta dissertação. Além da metodologia a ser aplicada para a obtenção de imagens de referência, que permitirão a classificação multiespectral e multitemporal de imagens fazendo uso da STRS, compreendendo todos os passos necessários para a sua aplicação.

No capítulo 4, são apresentados e discutidos os resultados da metodologia que leva em consideração o caráter multiespectral e multitemporal das imagens MODIS para classificação extensas áreas agrícolas.

Finalmente o capítulo 5, expõe as conclusões a respeito dos resultados encontrados e recomendações para trabalhos futuros.

2 - FUNDAMENTOS TEÓRICOS

2.1 Previsão de Safras no Brasil

A previsão de safras agrícolas é uma importante informação no estabelecimento de instrumentos de políticas e negócios agrícolas, no sentido de contornar o problema de escassez ou de excesso de produtos. Estimativas confiáveis da safra agrícola são necessárias ao setor agropecuário para o abastecimento a níveis Municipal, Estadual e Federal (Apan e Potgieter, 2002). De acordo com Adami (2003), para qualquer integrante da cadeia agropecuária - quer seja produtor, consumidor, governo, entre outros - essas estimativas são necessárias, uma vez que visam reduzir as especulações e seus impactos nos preços finais dos produtos agrícolas.

A Constituição da República Federativa do Brasil, estabeleceu que compete à União “*organizar e manter os serviços oficiais de estatística, geografia, geologia e cartografia de âmbito nacional*” (Art. 21, inciso XV). O Instituto Brasileiro de Geografia e Estatística (IBGE) é o órgão oficial responsável pela organização e manutenção destes serviços e isso evidentemente aplica-se também às “estatísticas agrícolas”.

Pino (1999) define esta expressão “estatísticas agrícolas” como o “conjunto de estatísticas sobre variáveis referentes ao setor agropecuário”.

Segundo Rizzi (2005), dentre essas variáveis destacam-se a área plantada e a produtividade e, em decorrência destas, a produção de determinada cultura agrícola, gerando assim a estimativa da safra agrícola.

Atualmente, as previsões de safras são realizadas por dois métodos bem distintos: os censos agropecuários e os métodos de amostragem da população de culturas agrícolas plantadas (Moura, 2000).

Nos censos agropecuários, o levantamento dos dados para obter informações sobre determinadas variáveis agronômicas (área plantada, área colhida, variedade das culturas e entre outras) é realizado de modo a cobrir toda a população (Adami, 2003). Segundo Pino (1999), no Brasil, o censo agropecuário tem periodicidade decenal ou quinquenal, com informações através de questionários ao nível de estabelecimento rural. A frequência destes censos deixa a desejar, visto que o último censo foi realizado em 1996 e o próximo será realizado em 2007 (IBGE, 2006).

Os levantamentos agrícolas por amostragem dividem-se em probabilístico e não probabilístico; e, pela forma de medição das variáveis (como por exemplo, área plantada por determinada cultura) podem ser subjetivos, quando obtidas em levantamentos por entrevistas, ou objetivo, quando obtidas por meio de levantamento *in loco* (trena, teodolito, etc.) ou sensoriamento remoto (Luiz, 2002; Sanches, 2004). No Brasil, por exemplo, dividem-se os levantamentos agrícolas em subjetivos (Levantamento Sistemático de Produção Agrícola - LSPA) e objetivos (Pesquisa Objetiva de Previsão de Safras - PREVS). Maiores detalhes sobre os censos agrícolas e os levantamentos agrícolas serão mostrados nas próximas seções.

2.1.1 Censos Agropecuários

Os censos agropecuários têm como objetivo fornecer uma classificação detalhada da estrutura agrícola da Federação. O valor de cada variável, para a área total do levantamento, é obtido a partir dos valores das variáveis em todas as unidades federativas (Sanches, 2004).

No levantamento censitário as formas de se obterem os dados são de caráter descritivo, ou seja, o entrevistado fornece os valores das variáveis agrícolas (área plantada, colhida, variedade e muitos outros) para o

entrevistador, sem nenhum tipo de conferência no campo (Adami, 2003). Esse levantamento é expedito, e, portanto, menos eficiente para obtenção de dados anuais em extensas áreas plantadas de culturas agrícolas, como no caso do Brasil.

No Estado de São Paulo, como exemplo de censo agrícola, foi realizado o Levantamento Censitário de Unidades de Produção Agrícola (LUPA), referente ao período de 1995/1996, através de um convênio entre o Instituto de Economia Agrícola (IEA), a Coordenadoria de Assistência Técnica Integrada (CATI) e a Secretaria de Agricultura (SAA) (Pino, 1999).

A área Estadual no levantamento LUPA foi estratificada em Unidades de Produção Agropecuária (UPAs) com diversos tamanhos, as menores com 0,1 ha e as maiores com área superior a 10 mil ha (Moura, 2000). Devido ao volume de dados coletados em campo, a publicação dos resultados é de forma demorada, esses resultados não têm utilidade imediata pelos órgãos governamentais, a não ser para o acompanhamento da situação da agropecuária a nível Estadual (Adami, 2003).

2.1.2 Levantamentos por Amostragem

2.1.2.1 Métodos Subjetivos

O método de amostragem não probabilístico, também conhecido como método subjetivo, aplicado no LSPA, foi implementado pelo IBGE em novembro de 1972 e está sendo aplicado até os dias atuais. Esse levantamento tem como finalidade atender as demandas de usuários por informações estatísticas conjunturais, sobre as safras dos produtos agrícolas com maior importância econômica e social para o País (IBGE, 2002).

O LSPA é uma pesquisa mensal de previsão e acompanhamento das safras agrícolas, que fornece estimativas de área, produção e rendimento médio, desde a fase de intenção de plantio até o final da colheita, de cada cultura investigada (IBGE, 2002).

No LSPA pode-se estimar a área plantada por meio de questionários, como também através de entrevistas com agricultores, reuniões com

técnicos envolvidos com o setor agrícola, ou ainda através de levantamentos sobre venda de sementes e insumos, dentre outros (Moura, 2000; Adami, 2003). Para obter dados sobre a agropecuária utiliza-se o LSPA, devido à facilidade de realizarem entrevistas e de não existir a necessidade de delineamento estatístico (Adami, 2003).

Segundo Fontana et al. (2000), estes levantamentos são formas complexas de se obter dados confiáveis, além de serem demoradas, onerosas, subjetivas, o que pode causar imprecisões no processo de estimativa de produção agrícola e não permitem uma análise quantitativa dos erros envolvidos.

Outra pesquisa realizada pelo IBGE desde o ano 1972 é a da Produção Agrícola Municipal (PAM) com base nas informações coletadas para o LSPA (para produtos agrícolas em comum). A PAM é um tipo levantamento a nível municipal que fornece informações sobre áreas plantadas e colhidas, sobre a quantidade produzida, como também sobre o rendimento médio obtido e sobre preço médio pago ao produtor, relativo a 62 produtos agrícolas. A coleta de informações é realizada mediante um questionário preenchido para cada município do país, pelos agentes do IBGE (IBGE, 1991).

A CONAB (Companhia Nacional de Abastecimento) faz o levantamento de safra no país por meio de pesquisas de intenção de plantio e colheita realizados seis vezes durante o ano safra, também por meio de questionários com as entidades ligadas à produção agrícola. Esse levantamento é feito de forma diferente, pois utiliza uma amostragem pré-estabelecida nos municípios que sejam os mais representativos das culturas de cada região do país (CONAB, 2006).

Em São Paulo, o IEA é outra instituição que aplica o método subjetivo para previsão de safras. Essas pesquisas são realizadas nos meses de setembro e novembro, sendo que os dados obtidos em setembro são relacionados à quantidade de áreas destinadas às culturas de verão (cultura de ciclo curto) e, em novembro, os valores são ligados com a intenção de plantio dos agricultores por município. Posteriormente, são realizadas mais três visitas a campo pela equipe técnica da CATI, nos meses de dezembro,

fevereiro e abril, originando assim a estatística agrícola do Estado (Moura, 2000).

2.1.2.2 Métodos Probabilísticos

Em 1985, o INPE e o IBGE desenvolveram um projeto denominado Sistema de Informação Agropecuária (SIAG), que visava obter estatísticas agrícolas com base num painel amostral (Rudorff e Moreira, 2002). Esse método objetivo, atualmente denominado PREVS, foi implementado inicialmente nos seguintes Estados: Paraná, Santa Catarina, Distrito Federal e São Paulo, sendo que atualmente apenas o Estado do Paraná continua realizando esta pesquisa.

A PREVS tem como objetivo principal o levantamento anual de informações através de técnicas estatísticas, visando fornecer estimativas de área cultivada e rendimento das principais culturas. Na PREVS utiliza imagens de satélite para as estratificações das áreas de estudo a nível estadual em função da intensidade de uso agrícola, e fotografias aéreas para auxiliar na localização dos segmentos no campo (Yi, 2005).

Na estratificação da área de estudo emprega-se um sistema de construção do painel amostral, a nível estadual em função da intensidade de uso agrícola. Os estratos podem ser divididos em substratos e cada substrato é dividido em unidades menores, denominadas Unidades de Controle (UCs). Essas UCs são amostradas de forma aleatória e posteriormente divididas em segmentos. Realiza-se um novo sorteio para definir quais segmentos serão visitados no campo, e a seguir os segmentos são demarcados nas fotografias aéreas para serem visitados. Os produtos de sensoriamento utilizados são imagens TM/Landsat-5 nas escalas de 1/100.000 e 1/250.000, e fotografias aéreas na escala de 1/10.000 e 1/25.000, usadas para delimitação dos segmentos sorteados (Moura, 2000).

As metodologias amplamente utilizadas para a estimativa de área cultivada fazem uso de dois tipos de estimadores principais, o estimador por expansão direta e o estimador por regressão (González-Alonso et al., 1997).

Segundo Luiz (2002), o estimador por expansão direta baseia-se apenas nos dados amostrais, reproduzindo para toda a população as

proporções relativas encontradas nas amostras. Para obter estimativas de variáveis, tais como área plantada, colhida e rendimento médio esperado das principais culturas, esse método utiliza dados coletados no campo a partir do painel amostral (Ippoliti-Ramilo, 1999).

Na definição de um painel amostral com segmentos de áreas semelhantes utiliza-se imagens de satélite, e o detalhamento de cada segmento empregam-se fotografias aéreas (Epiphany et al. 2002). Esse estimador utiliza as equações da amostragem aleatória estratificada (Cochran, 1977), conforme apresentado na Equação 1:

$$T_{ed} = D \cdot \bar{Y} \quad (1)$$

onde,

T_{ed} - estimativa da área ocupada pela cultura de interesse;

ed - diz respeito ao método de expansão direta;

D - área total da região de estudo;

\bar{Y} - média amostral de Y_i (amostras selecionadas).

O estimador por regressão linear necessita de uma ou mais variáveis auxiliares, as quais devem ter seus valores disponíveis para todos os elementos da população (Luiz, 2002). Segundo González-Alonso et al. (1997) o estimador por regressão utiliza duas variáveis para as suas estimativas: informações de campo; e os dados obtidos das classificações das imagens de sensores remotos, essas informações são agrupadas através do modelo de regressão linear. Utilizam-se as Equações 2, 3, 4 e 5, conforme Cochran (1977) e González-Alonso et al. (1997), no estimador por regressão linear.

$$Y_i = \beta_0 + \beta_i \cdot X_i \quad (2)$$

onde,

Y_i - porcentagem da área ocupada com a cultura de interesse na unidade amostral i ;

β_0 e β_i - coeficientes de regressão;

X_i - porcentagem da área ocupada pela cultura de interesse, calculada pela classificação dos *pixels* correspondentes à unidade amostral i ;

$i = 1, 2, 3, \dots, n$.

Para a estimativa da superfície de interesse pelo método de regressão T_{reg} , é definida pela Equação 3:

$$T_{reg} = D \cdot \bar{Y}_{reg} \quad (3)$$

onde,

D - área total no $i^{\text{ésimo}}$ estrato;

\bar{Y}_{reg} - porcentagem de área amostrada por segmento no $i^{\text{ésimo}}$ estrato.

Sendo definido por:

$$\bar{Y}_{reg} = \bar{y}_i + b_i \cdot (m_x - \bar{x}_i) \quad (4)$$

onde,

\bar{y}_i - porcentagem de área ocupada por segmento no $i^{\text{ésimo}}$ estrato;

b_i - coeficiente do estimador de regressão no $i^{\text{ésimo}}$ estrato, dado por:

$$b_i = \frac{\sum_{j=1}^{n_i} [x_{i,j} - \bar{y}_i] \cdot [x_{i,j} - \bar{x}_i]}{\sum_{j=1}^{n_i} [x_{i,j} - \bar{x}_i]^2} \quad (5)$$

onde,

m_x - proporção de *pixel* classificado corretamente no $i^{\text{ésimo}}$ estrato;

\bar{x}_i - proporção verificada de *pixel* classificados corretamente por segmento no $i^{\text{ésimo}}$ estrato;

\bar{y}_i - porcentagem de área ocupada por segmento no $i^{\text{ésimo}}$ estrato;

$x_{i,j}$ - proporção de *pixels* classificados corretamente na $j^{\text{ésimo}}$ amostra unitária no $i^{\text{ésimo}}$ estrato.

Segundo Luiz (2002), os estimadores citados apresentam pressupostos estatísticos, a partir dos quais as estimativas estão sujeitas aos erros aleatórios, que são possíveis de serem estimados e permitem analisar a confiabilidade dos resultados obtidos. Gonzáles-Alonso et al. (1997) compararam o estimador de expansão direta com o de regressão para estimar áreas agrícolas e concluiu que o estimador por regressão obteve uma eficiência relativa em torno de nove vezes maior que a expansão direta.

O sensoriamento remoto, por meio de imagens de satélites, juntamente com progresso da informática podem possibilitar a obtenção dados a custo cada vez mais baixo, para esquemas amostrais das áreas de produção agrícola.

A CONAB em 2004 implantou o projeto GeoSafras, que emprega modelos estatísticos auxiliados pelo sensoriamento remoto, GPS, sistemas de informações geográficas e modelos agrometeorológicos, tecnologias que constituem método objetivo. A metodologia para a estimativa de área baseia-se em modelo amostral com expansão para estimativa da área cultivada por estado. No primeiro ano, o projeto foi aplicado nos Estados São Paulo, Minas Gerais, Espírito Santo, Paraná, Rio Grande do Sul e Mato Grosso, enfocando prioritariamente alguns produtos, tais como: café, cana-de-açúcar, soja, milho e laranja (Figueiredo, 2005).

No projeto GeoSafras, primeiramente há a estratificação do Estado em estudo, onde os municípios são classificados e agrupados em faixas de igual percentual da área cultivada (porcentagem em relação à área de plantio da cultura no estado). O passo seguinte consiste na estimativa de área com imagens de satélites.

Em 2004 foram utilizadas imagens do Landsat e em 2005 imagens do CBERS-2 (*China-Brazil Earth Resources Satellite*), no projeto GeoSafras. A partir das imagens processadas, são distribuídos aleatoriamente 100 pontos dentro dos limites dos municípios sorteados, com o objetivo de efetuar uma supervisão no campo sobre o uso do solo (soja, milho, mata, área urbana, pastagem, etc.) em cada um desses pontos. Esse método procura de forma menos subjetiva, calcular as áreas ocupadas por determinadas culturas (Figueiredo, 2005; Ganan, 2005).

2.2 Uso do Sensoriamento Remoto nas Estimativas Agrícolas

Sensoriamento Remoto é a ciência e a arte de se obter informações sobre determinado objeto sem que o sensor esteja em contato físico com esse objeto (Lillesand e Kiefer, 1999; Mather, 1999). O sensoriamento remoto foi também definido por Novo (1989), como sendo a utilização de modernos sensores, aeronaves, espaçonaves, com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a Radiação Eletromagnética (REM) e as feições existentes na superfície terrestre em suas mais diversas manifestações.

O uso do sensoriamento remoto com base na análise de imagens de satélites é utilizado para acelerar e/ou reduzir custos dos mapeamentos e detecção do uso e cobertura do solo. As imagens de satélite oferecem possibilidades de gerar informações precisas para a avaliação e evolução de diversas variações temáticas da superfície terrestre, aliado às novas técnicas de processamento e aos novos sensores.

Segundo Schowengerdt (1997), dentre as aplicações para os dados de sensoriamento remoto destacam-se: agricultura, meteorologia, mapeamento, segurança e monitoramento ambiental. Sendo a agricultura uma das áreas de aplicação com maior demanda de dados de sensores orbitais, por permitem extrair informações de áreas cultivadas em grandes extensões territoriais e possibilitar o monitoramento das culturas agrícolas ao longo do seu ciclo de crescimento e desenvolvimento. Além disso, as imagens orbitais possuem um custo relativamente baixo, quando comparados às fotografias aéreas.

O sensor remoto é um dispositivo inserido em uma plataforma (ex.: avião ou satélite) que registra a energia refletida e emitida pelo alvo, gerando informações que serão processadas para posterior análise e interpretação. Esta informação é representada pela resolução espectral, que indica o número e largura das bandas espectrais que o sensor pode discriminar. Uma alta resolução espectral é obtida quando as bandas de um sistema sensor são estreitas e/ou quando utiliza um maior número de faixas espectrais, aumentando a capacidade do sensor em registrar pequenas variações do

comportamento espectral e, conseqüentemente, melhorando a diferenciação dos vários tipos de cobertura do solo (Noguchi, 2004).

Determinadas fases da agricultura são caracterizadas por lentas mudanças espectrais, como por exemplo, o período que vai da primeira gradagem, após a colheita, até o plantio seguinte, ou mesmo o período que vai da fase de completa cobertura da terra até a fase de pré-amadurecimento. Essas fases são caracterizadas por suaves alterações de reflectância. Por outro lado, há fases no processo agrícola que alteram rapidamente o comportamento espectral, tais como as determinadas pelo aparecimento e desaparecimento da cultura numa determinada área (Formagio e Epiphano, 1990). Essa alteração do comportamento espectral de certas culturas pode ser detectada utilizando a variedade temporal das imagens.

Como uma tecnologia de aquisição de dados na previsão de safras, os dados de campo (Ippoliti-Ramilo, 1999) e de sensoriamento remoto são de grande potencial na estimativa da área ocupada por culturas (Apan e Potgieter, 2002; Ippoliti-Ramilo, 1999). As técnicas do sensoriamento remoto têm sido apontadas como instrumento eficaz para a obtenção de resultados com maior precisão, em menor tempo e custo, do que com o uso exclusivo das técnicas tradicionais (González-Alonso et al., 1997).

Na estimativa de área plantada, foram comparados os resultados obtidos pela utilização de imagens do satélite Landsat com o método subjetivo LSPA, em diferentes regiões do Brasil: Sudeste (Ippoliti-Ramilo, 1999) e Sul (Rizzi, 2005). Com os resultados obtidos, estes autores (Ippoliti-Ramilo, 1999; Rizzi, 2005) analisaram que os resultados têm sido bem discordantes. Ippoliti-Ramilo (1999) observou que as estimativas de cana-de-açúcar realizadas através do LSPA superaram (nos três municípios em São Paulo: Sumaré, Hortolândia e Nova Odessa), as obtidas pelo procedimento de classificação dos dados Landsat, em valores que variaram de 5,1% até 14,4% da superfície dos municípios. Enquanto que a estimativa de área plantada com soja em municípios do Rio Grande do Sul provocou uma superestimativa de 11,3% por parte do LSPA em relação às classificações das imagens Landsat, em nível estadual, para o ano-safra 2000/2001 (Rizzi, 2005). Apesar das diferenças marcantes encontradas nas

duas regiões, observa-se que as estimativas oficiais (LSPA) apresentam caráter subjetivo diferente do caráter objetivo das classificações das imagens Landsat.

Gürtler (2003) utilizou uma metodologia baseada em banco de dados geográficos relacional, criado no Sistema de Processamento de Imagens Georeferenciadas - SPRING. Esta metodologia facilitou a identificação de pontos amostrais em imagens orbitais, e permitiu gerar estimativas de área agrícola para as principais culturas presentes na área de estudo (cana-de-açúcar, soja e milho), por município (Guará, Ipuã e São Joaquim da Barra), nas safras de 2000, 2001 e 2002. Para este autor (Gürtler, 2003), a metodologia fornece uma boa estimativa devido à proximidade com as estimativas oficiais do LSPA.

De acordo com Baban e Luke (2000), na comparação dos dados de área plantada obtidos pelas estatísticas censitárias com estimativas realizadas a partir de imagens dos satélites Landsat/TM, na região de Warwickshire (Inglaterra), a diferença encontrada foi de 0,45%, 0,61%, 1,49% e 0,77% para trigo, cevada, canola e floresta, respectivamente. Esta pouca diferença foi atribuída a diversos fatores: as assinaturas espectrais dos alvos foram bastante distintas para sua identificação; as áreas de treinamento foram bem representativas para os tipos de cobertura presentes na cena; e a área de estudo é morfologicamente uniforme e caracterizada por cultivos semelhantes.

Fang et al. (1998), utilizou uma metodologia para determinar a área de plantio de arroz ano a ano, na província de Hubei, localizada na parte central da China, utilizando dados Landsat/TM e NOAA/AVHRR. A partir das amostras de treinamento obtidas pela classificação da imagem Landsat/TM, foram classificadas as imagens NOAA com decréscimo de 4,957% de 1992 para 1994. Foram obtidas da mesma forma a classificação com imagens NOAA do ano 1995, mas com as amostras de treinamento a partir de interpretação de fotografias aéreas. Comparando esses dados com os dados oficiais do *Agricultural Investigation Team* (AIT), observou-se que a estimativa do ano de 1995 (91,6%) foi mais precisa que a do ano de 1994 (84,5%). Esta melhora na precisão ocorreu devido à forma de obtenção das amostras de treinamento.

Pax-Lenney e Woodcock (1997) examinaram a implicação de variação nas degradações das resoluções espaciais das imagens TM/Landsat (30 m de resolução espacial) para resoluções mais grosseiras (120, 240, 480 e 960 m), em áreas de agricultura irrigada próximas ao deserto, no Egito. Com esta análise, foi avaliada a habilidade do então futuro sensor MODIS em monitorar áreas agrícolas. Verificaram que as estimativas foram levemente subestimadas, 4,3 % para imagens com resolução de 120 m e 9,4 % para imagens com resolução de 960 m, em relação às imagens TM. Foi constatado também, que a exatidão global do mapa obtido para cultivos agrícolas foi surpreendentemente boa em todas as resoluções.

Outro trabalho foi realizado para estimar áreas de cada cultura agrícola, utilizando filtragem espacial de dados ETM+/Landsat-7, em São Paulo, nos seguintes municípios: Ipuã, Guará e São Joaquim da Barra. Foram simuladas as seguintes resoluções de 90 m, 150 m, 210 m e 270 m, a partir das imagens ETM+ com resolução de 30 m. Os resultados deste trabalho demonstram que sensores de resolução espacial moderada (ex. MODIS, 250m), podem ser utilizados para estimar áreas que não apresentem fragmentação acentuada, como soja e cana-de-açúcar (Soares, 2006).

Price (2003) comparou os dados ETM+ e MODIS para a classificação de diferentes tipos de cobertura em áreas extensas. Segundo este autor, a variação de brilho dos tipos dos alvos pode produzir ambigüidade na classificação, devido ao caráter global das imagens MODIS. Porém, ao contrário disso, este estudo revelou que as imagens MODIS podem gerar estimativas compatíveis para mapear áreas com vasta vegetação na superfície terrestre.

Yi (2005) utilizou imagens MODIS, com 250 m de resolução, para estimar a área plantada no Estado do Rio Grande do Sul das safras 2002-2003 e 2003-2004. Esse autor observou que o valor de área estimada pelas imagens MODIS foi apenas 7% menor que a área estimada pelas imagens Landsat. Entretanto, foi verificada uma diferença bem maior quando comparado com as estimativas oficiais do LSPA, subestimando a área em 17%. Ainda que estes resultados sejam subestimados, a estimativa de área a partir dos dados MODIS - com alta resolução temporal e o baixo custo -

pode indicar de forma rápida apenas um número aproximado da área plantada.

2.2.1 Sensor Orbital

Existem basicamente três níveis para obtenção de dados de uma cena em sensoriamento remoto, a saber: terrestre, suborbital e orbital. A utilização de um sensor ou de outro, em determinado nível de coleta de informações espectrais, depende, sobretudo de fatores relacionados com objetivo da pesquisa, tamanho da área imageada, disponibilidade de equipamentos sensores e custo e precisão desejados (Moreira, 2003). Desta forma, optou-se por limitar este estudo apenas aos sensores presentes em plataformas orbitais.

No acompanhamento da dinâmica agrícola, cada vez mais utiliza-se dados de sensor TM (Ippoliti-Ramilo, 1999) e ETM+ (Gleriani, 2005), do satélite Landsat, pois a resolução espacial permite a delimitação dos talhões agrícolas de grandes culturas e outros alvos, como estradas, áreas de floresta, corpos d'água, etc (Rizzi, 2005). No entanto, a resolução temporal do sistema Landsat (16 dias) tem limitado a análise de fenômenos de grande dinâmica temporal. Além disso, quando não são feitos mosaicos das imagens do Landsat, a aplicação desses dados fica, geralmente, restrita a estudos de caráter local, com uma extensão territorial de 185 km x 185 km (Anderson, 2005).

Alguns sensores são capazes de captar a radiação proveniente da cena em mais de um intervalo/banda espectral. Por isso, estes sensores são conhecidos com sensores multiespectrais. O sistema sensor MODIS possui um número maior de bandas espectrais, trinta e seis, enquanto que o sensor Landsat tem apenas oito.

Para Zhan et al. (2002), com o surgimento de novos sensores como o MODIS, o monitoramento da cobertura terrestre por meio do sensoriamento remoto foi bastante aprimorado, pois suas características radiométricas e geométricas que, associadas às correções atmosféricas, conferem a esse sensor capacidades superiores de monitoramento da vegetação.

O sistema sensor predecessor que inspirou o surgimento da experiência para a concepção do sistema MODIS – EOS (*Earth Observing System*) foi o sensor AVHRR (*Advanced Very High Resolution Radiometer*) dos satélites da série NOAA (*National Oceanic and Atmospheric Administration*). Um sensor originalmente concebido para observações meteorológicas, AVHRR/NOAA está sendo utilizado para fins de monitoramento da cobertura da superfície terrestre em larga escala. Este sensor, assim como o MODIS, vem demonstrando ser uma alternativa para descrever o comportamento fenológico da vegetação ao longo do ano, e assim permitir a classificação da cobertura do solo sobre áreas de grande extensão territorial (Jonathan, 2005).

As imagens fornecidas pelo sensor MODIS constituem a fonte principal de dados que fundamentam a pesquisa desta dissertação. Desta forma, na próxima seção serão expostas as principais características do sensor MODIS.

2.2.1.2 Sensor MODIS

O sensor MODIS encontra-se a bordo de dois satélites diferentes do programa Sistema de Observação da Terra - EOS (*Earth Observing System*) da agência espacial norte-americana NASA. O Sistema EOS compreende três grandes componentes, cujas funções são: i) coordenar emissão de uma série de satélites de observação da Terra; ii) configurar um sistema avançado de computadores, para processar, armazenar e distribuir os dados, denominados de EOSDIS; e iii) criar uma equipe de especialistas, envolvendo cientistas de todos os continentes para analisar estes dados (Justice et al., 2002; Shimabukuro et al., 2005).

O Satélite Terra, primeiro satélite para atender o projeto EOS, foi lançado em dezembro de 1999 iniciando a coleta de dados em fevereiro de 2000, esse satélite cruza a linha do Equador às 10h30min. O segundo satélite denominado *Aqua*, colocado em órbita em maio de 2002, com horário de passagem pelo Equador às 13h30min. Juntas, espera-se que estas plataformas espaciais ajudem os cientistas a desvendar os processos climáticos e de mudanças ambientais e seus impactos. Atualmente existem

três satélites do projeto EOS em órbita, e outros 15 estão previstos para serem lançados nos próximos quatro anos (Shimabukuro et al., 2005).

Na concepção EOS, o MODIS foi projetado para estudar a atmosfera, o oceano e os continentes, com resolução espectral e espacial, selecionadas para o conhecimento de diferentes necessidades observacionais, e com uma cobertura global quase diária (Justice et al., 2002).

Dados do sensor MODIS já vêm corrigidos dos efeitos atmosféricos (nuvens, aerossóis, etc.) e georreferenciados, distribuídos na forma de diferentes produtos entre os quais destacam-se os índices de vegetação que incluem o *Normalized Difference Vegetation Index* (NDVI) e um novo índice, o *Enhanced Vegetation Index* (EVI) (Huete et al., 2002).

Para Zhan et al. (2002) este sensor é um radiômetro-imageador com cobertura diária em resoluções espaciais de 250, 500 e 1000 m, contando com 36 bandas espectrais que se estendem do visível ao infravermelho termal (Tabela 1). O MODIS fornece dados com uma alta resolução radiométrica (16 bits) e com uma excelente resposta para cada banda. O produto MOD09, disponibilizado pela EOS, pode ser direcionado a aplicações específicas, como por exemplo, na agricultura. Este produto contém as bandas do vermelho, infravermelho próximo, azul e infravermelho médio.

Tabela 1: Especificações do Sensor MODIS.

Canais	Bandas Espectrais	Principais Usos
1 Vermelho	0,620 – 0,670 μm	Limiars de superfície, nuvens e aerossóis.
2 IV próximo	0,841 – 0,876 μm	
3 Azul	0,459 – 0,479 μm	Propriedades da superfície, nuvens e aerossóis.
4 Verde	0,545 – 0,565 μm	
5 IV próximo	1,230 – 1,250 μm	
6 IV médio	1,628 – 1,652 μm	
7 IV médio	2,105 – 2,155 μm	
8	0,405 – 0,420 μm	Cor do oceano Fitoplancton Biogeoquímica
9	0,438 – 0,448 μm	
10	0,483 – 0,493 μm	
11	0,526 – 0,536 μm	
12	0,546 – 0,556 μm	
13	0,662 – 0,672 μm	
14	0,673 – 0,683 μm	
15	0,743 – 0,753 μm	
16	0,862 – 0,877 μm	
17	0,890 – 0,920 μm	
18	0,931 – 0,941 μm	
19	0,915 – 0,965 μm	
20	3,660 - 3,840 μm	Temperatura de nuvens e da superfície
21	3,929 - 3,989 μm	
22	3,929 - 3,989 μm	
23	4,020 - 4,080 μm	
24	4,433 - 4,498 μm	Temperatura da atmosfera
25	4,482 - 4,549 μm	
26	1,360 - 1,390 μm	Nuvens cirrus Vapor d'água
27	6,535 - 6,895 μm	
28	7,175 - 7,475 μm	
29	8,400 - 8,700 μm	Propriedades de nuvens
30	9,580 - 9,880 μm	Ozônio
31	10,780 - 11,280 μm	Temperatura de nuvens e da superfície
32	11,770 - 12,270 μm	
33	13,185 - 13,485 μm	Altitude do topo de nuvens
34	13,485 - 13,785 μm	
35	13,785 - 14,085 μm	
36	14,085 - 14,385 μm	

Fonte: <<http://modis.gsfc.nasa.gov/about/specifications.php>>. Disponível em 15/05/2006.

As primeiras sete bandas foram projetadas para o sensoriamento remoto continental, com a resolução espacial de 250 m e de 500 m. As demais bandas (bandas de 8 a 36) com resolução espacial de 1 km para cobertura global. Estes valores nominais de resolução espacial são para

pixels no nadir do imageamento, degradando para os limites da imagem (que corresponde a 2.330 km). Assim, as dimensões dos *pixels* (Figura 1) variam com um fator de 2 vezes na direção longitudinal e com um fator de 5 vezes na direção transversal a linha de imageamento. Além disso, o erro de geolocalização é computado no centro de cada *pixel*, que é devido a incertezas no conhecimento de localização da plataforma e sua orientação (Justice et al., 2002).

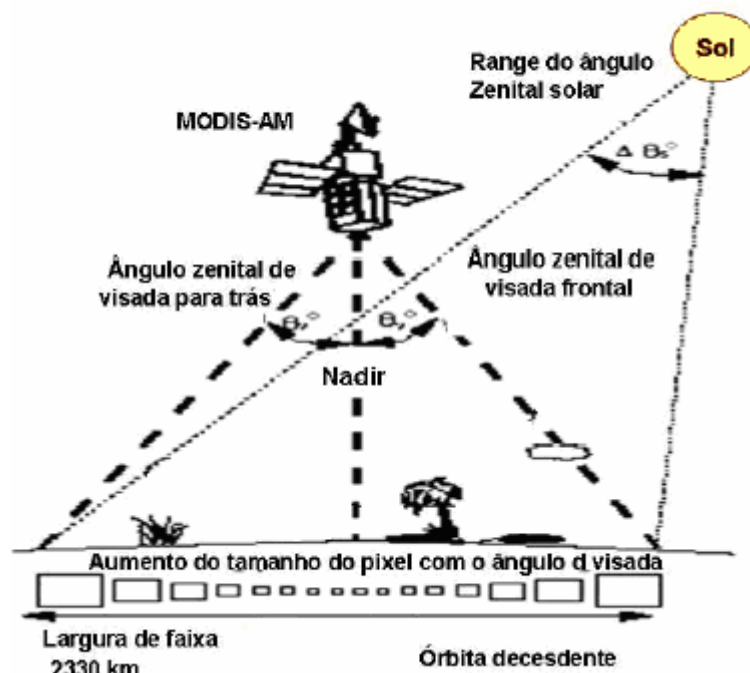


Figura 1: Varredura do sensor MODIS, mostrando o aumento no tamanho dos *pixels* com a variação do ângulo de visada.
Fonte: adaptada de van Leeuwen et al. (1999).

Para Shimabukuro *et al.* (2005), as melhores estimativas do erro são por volta de 85 metros na direção longitudinal e de 153 metros na direção transversal. Erros de geolocalização, junto com o crescimento do tamanho dos *pixels*, geram um EIFOV (*effective instantaneous field view*), significando dizer que o sensor projetado para ter uma determinada resolução espacial nominal, na realidade tem-se uma resolução espacial degradada. O EIFOV não inclui a névoa óptica ou espalhamento do instrumento, e esta é uma estimativa preservada da resolução espacial efetiva.

2.2.2 Classificação de Imagens

O mapeamento temático a partir das bandas espectrais de imagens de satélites depende também das características da área de estudo (região plana ou acidentada); época do ano (inverno ou verão); ou de variações regionais (Norte, Nordeste, Centro-Oeste, Sudeste, Sul). No mapa temático mostra-se a distribuição das características de superfície de terra, na forma de '*descrição informacional*', sob uma determinada área, no lugar de uma descrição de dados (Schowengerdt, 1997). Esse produto, mapa temático, pode ser obtido a partir da classificação digital, que de acordo com Lillesand e Kiefer (1999), tem como objetivo categorizar, por meio de procedimentos computacionais, todos os *pixels* de uma determinada imagem, atribuindo a cada um deles um "rótulo" que os relaciona a um objeto do mundo real (Mather, 1999).

Conforme as feições utilizadas no classificador, o processo de classificação pode ser dividido em classificadores '*pixel a pixel*', que é uma operação pontual, e classificadores por regiões, operação de vizinhança. Os classificadores *pixel a pixel*, agregam *pixels* homogêneos a partir de suas informações espectrais utilizando métodos estatísticos (com regras de probabilidade) ou determinísticos (não utilizam probabilidade). Os classificadores por regiões utilizam como critério de decisão, a informação espectral de cada *pixel* da imagem e a informação espacial que envolve a relação entre o *pixel* e seus vizinhos.

Os métodos de classificação de imagens podem ser divididos também entre classificadores supervisionados e classificadores não-supervisionados. Nos classificadores supervisionados, o analista identifica alguns *pixels* pertencentes às classes desejadas e a partir de uma regra de decisão localiza todos os demais *pixels* pertencentes àquelas classes. A classificação supervisionada é a mais adequada às necessidades do usuário, pois utiliza a verdade de campo ou mapas de referência, enquanto que o método não-supervisionado, o algoritmo agrupa os *pixels* semelhantes segundo algum critério de similaridade no espaço característico.

Para Mather (1999) nos métodos não-supervisionados não se tem qualquer informação prévia sobre os alvos presentes na cena. Uma das

técnicas utilizadas baseia-se na resposta espectral dos *pixels* da imagem em uma banda espectral - através do seu histograma - ou através do método de agrupamento (“*clustering*”). Esse método leva em conta os agrupamentos de *pixels* formados a partir da sua resposta espectral em duas ou mais bandas. Cada agrupamento representa o comportamento característico de um determinado alvo, a partir de uma amostragem, em um conjunto de bandas espectrais.

Os processos de classificação podem ser agrupados em duas grandes categorias: métodos paramétricos e métodos não-paramétricos. Nos métodos paramétricos, tem-se o conhecimento da forma geral da função densidade de probabilidade, descrevendo o comportamento dos dados. Os parâmetros existentes são estimados a partir das amostras de treinamento disponíveis para cada classe. Ocorrem casos em que a forma geral da função densidade probabilidade associada aos dados não é conhecida. A alternativa nestes casos consiste na utilização dos chamados métodos não-paramétricos.

Muitos algoritmos têm sido empregados na classificação de imagens digitais provenientes de sensores remotos, entre eles o algoritmo de Mínima Distância Euclidiana e o algoritmo Gaussiano de Máxima Verossimilhança. Nas últimas décadas as redes neurais artificiais apresentaram contribuições na classificação de padrões, com algumas vantagens sobre esses classificadores tradicionais, tais como o treinamento com pequenas amostras, como também não serem paramétricas, e com grande capacidade de generalização (Tso e Mather, 2001; Kavzoglu e Mather, 2003). Nos subseções seguintes maiores detalhes serão dados sobre esses algoritmos.

2.2.2.1 Regra da Mínima Distância Euclidiana

Nessa regra de decisão utiliza a distância euclidiana para associar um *pixel* a uma determinada classe, tomando-se como base a distância espectral entre o nível digital do *pixel* e o vetor de médias da classe, também denominado centróide. Se o *pixel* for idêntico à média de uma classe, então a distância espectral entre o *pixel* e esta classe será nula (Centeno, 2004).

Segundo Vieira (2000), o algoritmo calcula da distância euclidiana (D) de cada *pixel* desconhecido do vetor X até o centróide de cada classe (M_i), antes é necessário obter as amostras de treinamento dos dados. O *pixel* será rotulado a classe que apresentará a menor distância entre eles. A distância euclidiana entre um desconhecido vetor X e uma classe i é obtida usando a Equação 6:

$$D_j = \sqrt{\sum_{i=1}^n (X_i - M_i^{(j)})^2} \quad (6)$$

Outra forma de se obter a distância entre uma observação e o centro da classe pode ser medida adotando-se à distância de *Mahalanobis* (MD), que calcula a matriz de variância-covariância da específica classe (S_i). Podendo ser definida como (Equação 7):

$$MD_i^2 = (X - M_i)^T S_i^{-1} (X - M_i) \quad (7)$$

Segundo Luiz (2002), o método da mínima distância é matematicamente simples e computacionalmente eficiente, porém possui algumas limitações, a principal delas é que esse método é totalmente indiferente aos diferentes graus de variância nos dados de resposta espectral. Estabelece somente média das amostras de treinamento, assumindo que as classes são distribuídas simetricamente ao redor do centróide (Wilkie e Finn, 1996).

2.2.2.2 Classificador Gaussiano da Máxima Verossimilhança

O classificador Gaussiano da Máxima verossimilhança (MaxVer) é a estratégia paramétrica mais utilizada em classificação por meio de imagens orbitais, devido ao simples entendimento e implementação.

Em imagens de sensoriamento remoto, a maioria das feições segue distribuição normal, com grande concentração de dados em torno da média e freqüências de dados decrescentes nos extremos, que representam o aumento gradual de mistura com outras feições contribuindo assim para um melhor desempenho do MaxVer (Costa et al., 2005).

Espera-se que a classificação resultante do MaxVer seja precisa que os outros classificadores estatísticos, tais como o método do paralelepípedo. Pois o MaxVer, utiliza dados de cada classe no espaço característico n -dimensional além da localização do *pixel* do centro de cada classe (Mather, 1999). Neste mesmo classificador, o MaxVer, empregam-se as amostras de treinamento para prover avaliação das formas da distribuição dos *pixels*.

O classificador MaxVer é um classificador supervisionado que pode ser usado tanto na operação *pixel a pixel* (operação pontual), como para a operação por região. O MaxVer utiliza a distribuição dos valores de reflectância em uma área de treinamento é descrita por uma função densidade de probabilidade, desenvolvida com base na estatística *Bayseana* (Mather, 1999).

Segundo Wilkie e Finn (1996), o MaxVer esta baseado no teorema fundamental de probabilidade, máxima verossimilhança, o *pixel* pertencerá à classe ω_i de maior valor de $P(X|\omega_i)$, utilizando o valor do vetor X (nível de cinza) composto de p elementos (bandas espectrais). A probabilidade é calculada para cada classe pela determinação da matriz de variância-covariância e a distância de *Mahalanobis* (Seção 2.2.2.1; Equação 7), usando a Equação 8:

$$P(X|\omega_i) = 2\pi^{-p/2} |S_i|^{-1/2} \exp\left[-\frac{1}{2}(X - M_i)^T S_i^{-1}(X - M_i)\right] \quad (8)$$

onde,

$P(X|\omega_i)$ - função de probabilidade;

ω_i - determinada classe;

X - valor nível de cinza do vetor composto de p bandas espectrais;

M_i - vetor de médias;

S_i - matriz de covariância.

O MaxVer está implementado em quase todos os *softwares* de processamentos de imagem, sendo usado freqüentemente como classificação padrão para comparação com outros algoritmos (Vieira, 2000).

2.2.2.3 Classificador Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA's) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes que adquirem conhecimento através da experiência (Carvalho, 2006). Antes de apresentar o funcionamento de uma RNA descreve-se de forma simplificada, nesta subseção, o funcionamento básico do cérebro humano.

O cérebro humano contém aproximadamente 10^{11} neurônios, cada um dos neurônios processa e se comunica com milhares de outros neurônios continuamente e em paralelo.

Um neurônio (ou célula de nervo) é uma célula biológica especial com capacidade de processamento de informação. O neurônio (Figura 2) é composto pelo corpo celular e por outros dois ramos: *axônio* e *dendritos*. O corpo celular contém um núcleo com informações sobre características hereditárias e um plasma que contém material molecular para a produção de material necessário ao neurônio. Um neurônio recebe sinais (impulsos) de outros neurônios através dos *dendritos* (receptores), e transmite sinais gerados pelo corpo celular ao longo do *axônio* (transmissor). No término dessas ramificações estão as *sinapses*. Uma *sinapse* é um local de contato entre dois neurônios (uma ramificação do *axônio* de um neurônio e um *dendrito* de outro neurônio). Quando o impulso alcança o término da *sinapse*, certas substâncias químicas são liberadas, denominadas de neurotransmissores. Os neurotransmissores espalham através de uma abertura sináptica, não existindo um contato físico. Dependendo do tipo da sinapse, o neurônio receptor possui a tendência de emitir impulsos elétricos, dando seqüência à propagação. A sinapse pode ser ajustada pelo transcurso de sinais, por isso ela pode aprender nas atividades das quais eles participam (Jain et al., 1996).

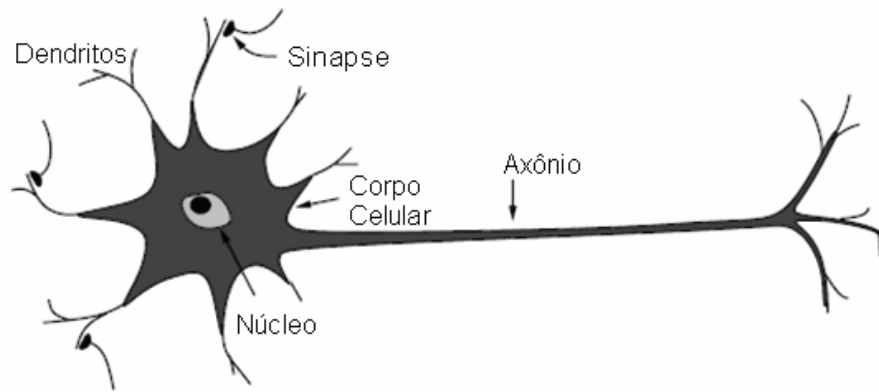


Figura 2: Esboço de um neurônio biológico.

Fonte: Jain et al. (1996).

Um neurônio artificial tem um funcionamento análogo ao processo biológico descrito anteriormente, o qual é ilustrado na Figura 3. Segundo Haykin (2001), o neurônio K recebe os sinais x_1 , x_2 e x_3 dos neurônios A, B e C, respectivamente; esses sinais são ponderados pelos pesos w_1 , w_2 e w_3 de maneira excitatória ou inibitória. Ocorre ainda a entrada do viés (θ_k), cuja função é aumentar ou diminuir a entrada líquida na função de ativação (Equação 9):

$$y_{\text{entrada}} = w_1 * x_1 + w_2 * x_2 + w_3 * x_3 + \theta_k \quad (9)$$

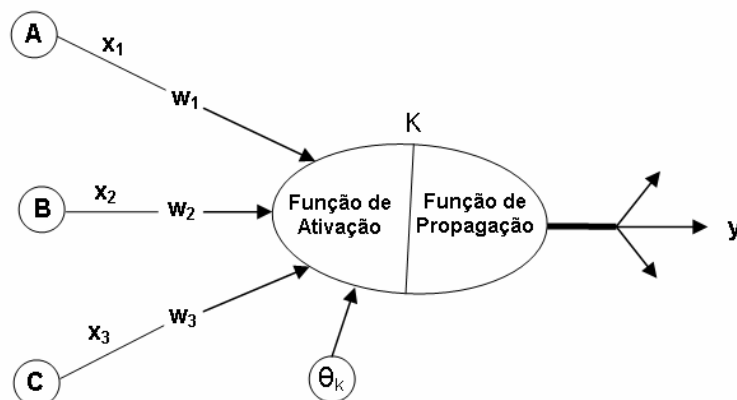


Figura 3: Modelo de Neurônio.

Fonte: Haykin (2001).

Assim, as entradas no neurônio K são ponderadas pelos respectivos pesos e somadas juntamente com o viés. A introdução do viés resulta no deslocamento da função de transferência, a partir de sua origem, tendo maior rapidez na convergência do processo de aprendizado. O resultado desta soma é aplicado à função de ativação que processa os estímulos

ponderados pelos respectivos pesos (sinapses) e mede o estado de ativação para o neurônio. A função de propagação encarrega-se de propagar o estado de ativação como estímulo para outros neurônios. Para Thomé, (2006), as funções de ativação mais utilizadas são (Equações 10, 11, 12, 13, 14 e 15):

- Linear

$$a_i(\underline{x}, \underline{w}) = \underline{w}^T \underline{x} = \sum_{j=1}^n w_{ij} x_j \quad (10)$$

- Esférica

$$a_i(\underline{x}, \underline{w}) = \rho^{-2} \sum_{j=1}^n (x_j - w_{ij})^2 \quad (11)$$

- *Mahalanobis*

$$a_i(\underline{x}, \underline{w}) = (\underline{x} - \underline{w}_i)^T \Omega^{-1} (\underline{x} - \underline{w}_i) \quad (12)$$

$$\Omega = \underline{X}\underline{X}^T \quad (13)$$

- Polinomial

$$a_i(\underline{x}, \underline{w}) = \sum_{j=1}^n x_j^{w_{ij}} \quad (14)$$

- Sigmóide

$$a_i(\underline{x}, \underline{w}) = \frac{1}{1 + e^{-\sum_{j=1}^n x_j w_j}} \quad (15)$$

A função de propagação, também conhecida como limiar lógico (*threshold*), é quem define e envia para fora do neurônio o valor do estímulo a ser passado adiante, para os próximos neurônios da rede. As funções de propagação mais encontradas na literatura são (Thomé, 2006):

- Função degrau: é limitada (*bounded*), porém não é derivável. Normalmente é utilizada para criar neurônios que tomem decisões binárias, como nos classificadores;
- Função linear: é ilimitada. Neurônios com esta função de propagação podem ser utilizados como aproximadores lineares;

Dentre as topologias aplicadas numa Rede Neural a mais utilizada é a arquitetura completamente conectada por múltiplas camadas (*Multi Layer Perceptron*). Devido ao fluxo unidirecional na rede, elas são denominadas de

redes neurais de entrada-saída (*feed-forward*). Desta forma, um neurônio situado em uma determinada camada tem sua saída conectada a todos os neurônios da camada seguinte (a sua direita).

Os neurônios são organizados e ligados em rede, de modo a constituírem camadas formando as redes neurais. Frequentemente, uma camada de entrada está ligada a uma camada de saída, via uma ou mais camadas internas (Atkinson e Tatnall, 1997).

O número suficiente de camadas para maioria dos problemas, normalmente, é de, no mínimo, três e no máximo quatro, a menos que o problema seja complexo. O número de neurônios na camada de entrada deve ser igual ao número de variáveis discriminantes utilizadas no processo e o número de neurônios na camada de saída igual ao número de classes informacionais. O número de neurônios da camada interna (ou escondida) depende do problema que se deseja resolver, desta forma quanto mais simples é o problema, menos neurônios na camada interna são necessários para a convergência da rede (Chagas, 2006).

A definição da estrutura interna de uma rede é um processo de tentativa e erro, conforme sugerido por Hirose et al. (1991). A estrutura de uma rede neural artificial aplicada ao processo de reconhecimento de padrões, pode ser utilizada três diferentes tipos de camadas (Figura 4). A primeira camada de contribuição inclui uma unidade para cada variável característica, por exemplo, bandas espectrais em diferentes datas. Na segunda, pode haver uma ou mais camadas escondidas cada uma contendo o número de unidades definido pelo usuário. No caso de sensoriamento remoto normalmente utilizam-se duas camadas escondidas. E a terceira, a camada de saída que contém uma unidade para cada classe. A rede pode ser treinada para caracterizar corretamente as classes com dados de sensoriamento remoto, por um processo iterativo de aprendizagem (Foody e Arora, 1997).

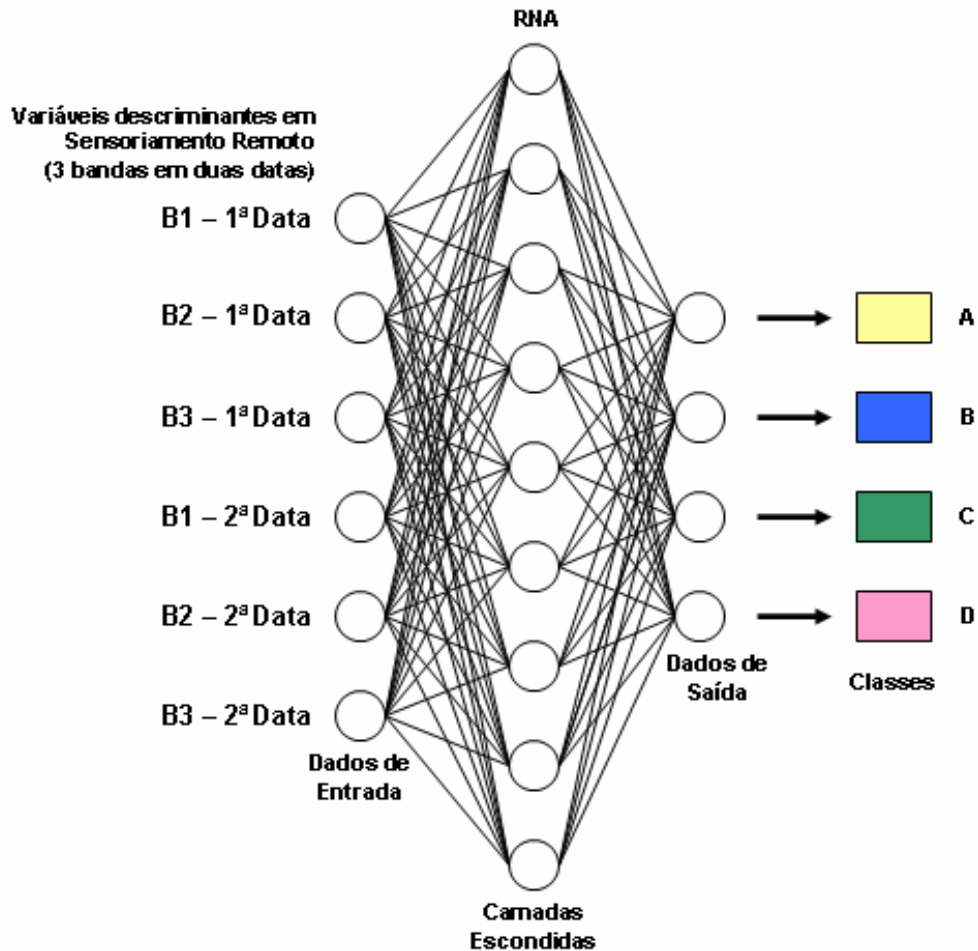


Figura 4: Exemplo de uma rede neural (Adaptado de Foody e Arora, 1997).

A taxa de aprendizado η é uma constante de proporcionalidade no intervalo $[0, 1]$ e normalmente utiliza-se o valor de 0,2. Quanto menor for a variação da taxa de aprendizagem η , menores serão as variações de pesos sinópticos da rede e menor será o deslocamento no espaço de pesos em direção ao mínimo global. Por outro lado, quando maior for η , maior será a variação dos pesos sinópticos resultantes e a rede pode ficar instável (Gleriani, 2004).

Os seguintes procedimentos são utilizados no treinamento de uma rede neural artificial de entrada-saída, usando um aprendizado supervisionado (Vieira, 2000):

- A rede no seu estágio inicial, começa tipicamente com alocação de pesos aleatórios entre neurônios. Os pesos devem ser inicializados com valores aleatórios próximos a zero, evitando assim o problema de saturação

com valores altos, ou a dificuldade da rede não aprender devido à presença de valores homogêneos de peso;

- Um padrão de entrada é apresentado à rede. A entrada é propagada a vante (*forward*) na rede até que ativação obtenha a camada de saída.
- A saída (*output*) gerada pela rede neural é então comparada com o valor esperado correspondendo à amostra de treinamento. Encontra-se o erro da rede, pela diferença (delta) δ_j , entre a saída O_j e o aprendizado da entrada T_j , numa unidade de saída u_j . Usa-se este erro com a saída O_j de uma unidade de origem u_j para computar a mudança da conexão w_{ij} . O cálculo do delta das camadas escondidas é avaliado para cada entrada do treinamento. Os deltas das camadas seguintes que já foram calculados são usados na fórmula dada abaixo (Equação 16). Nesse modo os erros (deltas) são propagados para trás (*backward*). Esta fase é chamada então de propagação *backward*. O aprendizado de retropropagação (*backpropagation*) atualiza o peso, também pode ser chamada de “regra-delta”, pode ser vista abaixo (Equação 16):

$$\Delta w_{ij} = \eta \delta_i O_i \quad (16)$$

$$\delta_i = \begin{cases} f'_i(\text{net}_i)(T_i - O_i) \therefore \forall(\text{saída} - \text{unidade}) \\ f'_i(\text{net}_i) \sum_k \delta_k w_{ik} \therefore \forall(\text{hidden} - \text{unidade}) \end{cases}$$

onde,

w_{ij} - peso da conexão entre a unidade u_j e a unidade u_i ;

η - taxa de aprendizado;

δ_i - uma constante específica da largura do passo do gradiente;

O_i - saída da unidade j no tempo t ;

k - índice de um sucessor da unidade atual u_j com uma ligação w_{ik} variando de u_j até u_k .

- Esse processo é repetido para o resto das amostras de treinamento, iterativamente submetido aos dados de treinamento até que se encontre um erro aceitável.

As Redes Neurais Artificiais começaram a ser usada em sensoriamento remoto para classificação no final da década de 80, com o trabalho de Lipmann (1987), no entanto o seu uso foi consolidado a partir da década de 90 (Kanellopoulos e Wilkinson, 1997). Os classificadores por RNA diferem do MaxVer, por assumir nenhuma forma de distribuição de probabilidade para o conjunto de dados. As redes neurais podem precisar de um longo tempo de treinamento, mas podem ser relativamente rápido na classificação dos dados e incorpora diferentes tipos de variáveis discriminantes na análise (Atkinson e Tatnall, 1997; Benediktsson e Sveinsson, 1997).

Recentemente, as redes neurais artificiais têm sido empregadas com sucesso na classificação de imagens, pois apresentam algumas vantagens sobre os classificadores estatísticos, como por exemplo, o treinamento com um pequeno número de amostras, não ser um método paramétrico, e com grande capacidade de generalização - capacidade de reconhecer com precisão padrões que não participaram do processo de treinamento (Tso e Mather, 2001; Kavzoglu e Mather, 2003). Outra vantagem do uso das RNA está na facilidade de processar e interpretar grandes quantidades de dados (Atkinson e Tatnall, 1997).

Dentre esses modelos o mais utilizado para classificação de imagens é a arquitetura completamente conectada por múltiplas camadas (*Multi Layer Perceptron*) de entrada-saída (*feed-forward*), com o algoritmo de treinamento para aprendizagem supervisionada retropropagação *backpropagation* (Vieira, 2000). Esse algoritmo minimiza o erro médio quadrático, ajustando os pesos das conexões entre os neurônios da rede de acordo com o erro (Jain et al., 1996). Após a aprendizagem da rede, são rotulados os padrões usando o conjunto de pesos ajustados durante a fase de treinamento, e reconhece um dado padrão como pertencente a uma determinada classe.

2.2.3 Avaliação da Classificação

Após o processo de classificação da imagem, é importante conhecer a confiabilidade do mapa temático. Segundo Lillesand e Kiefer (1994) para analisar esta exatidão, na maioria dos estudos de classificação, têm como

ponto de partida a construção de uma matriz de erros de classificação, chamada também de matriz de confusão. A matriz de erro é a forma de comparar as contradições entre os dados de referência e os dados resultantes do processo de classificação. Podem-se obter os dados de referência a partir de dados de campo (orientados por GPS), auxílio de fotografias aéreas ou até o uso sistemas de informações geográficas.

A matriz de confusão é representada por uma disposição quadrada, tendo número de linhas e colunas igual ao número de classes informacionais que estão sendo avaliadas. As linhas correspondem aos dados classificados e as colunas representam os dados de referência. Os conjuntos de *pixels* dispostos na diagonal principal indicam o grau de acerto entre as amostras de referência e os *pixels* resultantes da classificação. A Tabela 2 mostra a representação de uma matriz de confusão (Foody, 2002).

Tabela 2: Representação da matriz de confusão.

Classes	Dados de Referência				Σ	Exatidão usuário
	A	B	C	D		
A	n_{AA}	n_{AB}	n_{AC}	n_{AD}	n_{A+}	n_{A+}/n
B	n_{BA}	n_{BB}	n_{BC}	n_{BD}	n_{B+}	n_{B+}/n
C	n_{CA}	n_{CB}	n_{CC}	n_{CD}	n_{C+}	n_{C+}/n
D	n_{DA}	n_{DB}	n_{DC}	n_{DD}	n_{D+}	n_{D+}/n
Σ	n_{+A}	n_{+B}	n_{+C}	n_{+D}	n	
Exatidão produtor	n_{+A}/n	n_{+B}/n	n_{+C}/n	n_{+D}/n		

Fonte: Adaptada de Foody (2002).

A exatidão do produtor e do usuário são maneiras de representar individualmente a exatidão de uma classe. Na exatidão do produtor computa as amostras que não foram classificadas corretamente, ou seja, as amostras foram omitidas da classe informacional correta. Já a exatidão do usuário, indica se o *pixel* na imagem classificada pertence à classe informacional obtida a partir da imagem de referência, ou seja, as amostras foram incluídas na classe informacional incorreta.

A exatidão global (G), definida como a estimativa da porcentagem corretamente classificada quando comparada com os dados de referência ou verdade de campo. Podendo ser computada pela razão da soma da diagonal

principal, número de classificações correta n_{ii} , pelo número total de amostras coletadas n , de acordo com a Equação 17:

$$G(\%) = \frac{\sum_{i=1}^c n_{ii}}{n} \times 100 \quad (17)$$

Congalton e Green (1999) recomendam o coeficiente *Kappa* K_a como uma medida adequada da exatidão de uma classificação temática, pois essa é a medida de como a classificação coincide com a imagem de referência. Este índice leva em conta toda a matriz de confusão (incluindo a precisão do usuário e do produtor), diferente da exatidão que leva somente em conta os elementos da diagonal principal (Equação 18).

$$K_a = \frac{n \sum_{i=1}^c n_{ii} - \sum_{i=1}^c n_{i+} n_{+i}}{n^2 - \sum_{i=1}^c n_{i+} n_{+i}} \quad (18)$$

de acordo com Foody (2002),

K_a - estimativa do coeficiente *kappa* (Equação 18);

n_{ii} - valor na linha i e coluna i ; n_{i+} é a soma da linha i e n_{+i} é a soma da coluna i ;

n - número total de amostras da matriz de confusão;

c - número total de classes informacionais.

Os valores de *kappa* podem variar de -1,0 a +1,0; espera-se alta correlação entre a classificação e os dados de referência, logo são esperados valores positivos. O valor zero indica nenhuma concordância, enquanto um valor de 1,0 mostra uma perfeita concordância entre o resultado da classificação e os dados de referência (Vieira, 2000).

Na utilização do coeficiente *Kappa*, não existe uma fundamentação teórica para recomendar quais os níveis mínimos aceitáveis deste coeficiente no processo de classificação. Entretanto, Galparsoro e Fernández (1999), sugerem que valores de *Kappa* de 0,81 ou maiores

mostram um desempenho do classificador de muito bom, enquanto valores entre 0,61 e 0,80 representam desempenho bom, para valores entre 0,41 e 0,60 apresentam desempenho moderado, um fraco desempenho para valores entre 0,21 e 0,40, e valores menores que do que 0,2, uma pobre concordância.

Intervalos de confiança ao redor do valor *Kappa* podem ser computados usando a variância da amostra e o fato de que a estatística de *Kappa* é assintótica e normalmente distribuída. Congalton e Green (1999) sugeriram meios para testar a significância da estatística de *Kappa* para uma matriz de confusão individual, através da variância, para determinar se o nível de concordância, entre a classificação de imagens de sensores remotos e os dados de referência, é significativamente maior que zero (melhor do que uma classificação aleatória). O teste estatístico para avaliar a significância de uma matriz de confusão individual é dado pela Equação 19 (Hudson e Ramm, 1987):

$$Z = \frac{k}{\sqrt{\text{var}(k)}} \quad (19)$$

para Hudson e Ramm (1987),

Z = unificado e normalmente distribuído;

$\text{var}(k)$ = é a variância do *Kappa*, que pode ser calculada (Equação 20).

$$\hat{\sigma}^2(\hat{k}) = \frac{1}{n} \left[\frac{\theta(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (20)$$

$$\text{Onde, } \theta_1 = \frac{1}{n} \sum_{i=1}^j n_{ii} \quad \theta_2 = \frac{1}{n^2} \sum_{i=1}^c n_{i+} n_{+i} \quad \theta_3 = \frac{1}{n^2} \sum_{i=1}^c n_{ii} (n_{i+} + n_{+i})$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c n_{ij} (n_{j+} + n_{+j})^2$$

O teste Z é padronizado e distribuído normalmente é dada uma hipótese nula $H_0 : K_1 = 0$ e uma hipótese alternativa $H_1 : K_1 \neq 0$, H_0 é rejeitada se $Z \geq Z_{\alpha/2}$, onde $\alpha/2$ é o nível de confiança do teste Z . Para um nível de

confiança de 95% o valor crítico deveria ser 1,96. Nesse caso se o valor de Z for maior que 1,96, o resultado é significativamente melhor que uma distribuição aleatória e existe concordância entre a classificação e a verdade terrestre.

Segundo Congalton e Green (1999), com o teste estatístico Z também é possível verificar a significância entre dois classificadores. Utilizando os valores de $Kappa$ nas matrizes independentes (k_1, k_2) verifica se as duas classificações são significativamente diferentes. O teste estatístico é expresso por (Equação 21):

$$Z = \frac{|k_1 - k_2|}{\sqrt{\text{var}(k_1) + \text{var}(k_2)}} \quad (21)$$

onde,

k_1, k_2 - são dois coeficientes de $kappa$ que estão sendo comparados;
 $\text{var}(k_1)$ e $\text{var}(k_2)$ - são as variâncias dos coeficientes.

Para a equação anterior (Equação 20), o teste Z é padronizado e distribuído normalmente e dada uma hipótese nula $H_0 : K_1=K_2$ e uma hipótese alternativa $H_1 : K_1-K_2 \neq 0$, H_0 é rejeitada se $Z \geq Z_{\alpha/2}$. Para um nível de confiança de 95% o valor crítico deveria ser 1,96. Desta forma, se o valor de Z for maior que 1,96, as duas classificações serão diferentes estatisticamente (Congalton e Green, 1999).

Uma das finalidades da validação (ou análise de erro) é permitir comparação de classificações diferentes. Tal comparação pode ser feita através da elaboração de uma matriz de significância para os classificadores, a um nível de confiança de 95% (valor crítico de Z igual a 1,96), com o índice $Kappa$. Utiliza-se o índice $Kappa$, pois ele quantifica o desempenho do classificador em relação à imagem de referência.

Os valores da diagonal principal da matriz de significância representam a precisão do classificador comparado a uma classificação aleatória, enquanto os valores de fora da diagonal representam o desempenho relativo entre os classificadores (Vieira, 2000). Os valores menores que 1,96, fora da diagonal, indicam que não há diferença estatística

significativa entre os classificadores. Para os valores maiores ou iguais a 1,96, também fora da diagonal, representam a superioridade ou inferioridade relativa entre cada par de classificador.

2.2.4 Abordagem Multitemporal

Nos levantamentos agrícolas, utilizando imagens multitemporais, podem-se detectar mudanças espectrais registradas durante a estação de crescimento das culturas, o que seria impossível de determinar em uma única data (Vieira, 2000). Pax-Lenney e Woodcock (1997) afirmam que imagens multitemporais são necessárias para monitorar áreas agrícolas devido ao caráter dinâmico, mas a escolha do número de imagens necessárias, do período dentro do calendário agrícola e do intervalo entre as datas de aquisição das imagens podem afetar os resultados.

Recomenda-se a classificação multitemporal, para análise do comportamento espectral ao longo do ciclo de desenvolvimento das culturas (Medeiros et al., 1996), devido aos dados multitemporais aumentarem a discriminação espectral das culturas agrícolas (Murthy et al., 2003).

Vieira (2000) comprovou que a precisão de classificação das culturas agrícolas a partir de imagens multitemporais, foi consideravelmente mais alta comparada com a precisão obtida com imagem em única data. Desta forma, diversos trabalhos descritos na literatura (Pax-Lenney e Woodcock, 1997; Tso e Mather, 1999; Shao et al., 2001; Murthy et al. 2003; Turker e Arıkan, 2005), para aplicações na agricultura, leva-se em consideração o estágio fenológico das culturas, a sua multitemporalidade, devido à dinâmica agrícola.

Segundo Guerschman et al. (2003), a análise de imagens multitemporais é uma alternativa para discriminar diferentes tipos de cobertura. Para uma classificação satisfatória, informações multitemporais, são necessárias pelo menos duas imagens abrangendo a troca de colheitas entre inverno e verão. Para esses mesmos autores (Guerschman et al., 2003), diversos fatores podem afetar a precisão de uma classificação multitemporal do uso e cobertura da terra, tais como resolução temporal;

resolução espectral; resolução espacial; e o número de classes informacionais.

Empregando um banco de dados multitemporal e dados auxiliares referenciando em três anos consecutivos, Ortiz et al. (1997) apresentam uma metodologia para classificar os cultivos. Com o intuito de aprimorar o resultado final da classificação de imagens, nesse trabalho foi elaborado um banco de dados integrando dados de diferentes origens e tomados em diferentes épocas (multitemporal).

Shao et al. (2001), utilizou dados multitemporais de Radar para estimar a produção de arroz na China. Esses autores afirmaram que é necessária a aquisição de três imagens para acompanhar os estádios de desenvolvimento e de crescimento da cultura: ao término do plantio com o início do desenvolvimento da cultura; durante a diferenciação do período de desenvolvimento da cultura; e no início do período da colheita.

Dados multitemporais foram analisados para caracterizar a mudança sazonal de cada cultura utilizando os perfis espectrais do NDVI, das imagens SPOT, em áreas agrícolas no Japão. Foram utilizadas nove imagens em diferentes datas: janeiro, março, abril, maio, junho, julho, setembro e dezembro, sendo que duas imagens foram adquiridas em setembro. O índice *Kappa* foi aplicado para avaliar as precisões das classificações multitemporais. Comparando os valores de *kappa* observou-se que a classificação com a combinação de quatro imagens (abril, julho, junho e setembro), indicaram que o resultado foi estatisticamente igual comparando com a classificação de nove imagens (Murakami et al., 2001).

Mais recentemente, Xiao et al. (2005) utilizou um método que leva em consideração o perfil temporal de resposta espectral da cultura do arroz, através dos seguintes índices *Normalized Difference Vegetation Index* (NDVI), *Enhanced Vegetation Index* (EVI) e *Land Surface Water Index* (LSWI), a partir dos dados MODIS, permitindo assim estimar a área de cultivos de arroz em extensas áreas.

Outro trabalho empregou NDVI para estimar áreas agrícolas, mas utilizou uma série de dados do AVHRR. Os resultados mostraram ser mais confiável o uso de uma série temporal NDVI de 11 anos para estimar áreas

agrícolas, comparando com dados em apenas uma data baseada no NDVI (Kastens et al., 2005).

Murthy et al. (2003), utilizou imagens multitemporais para classificação de culturas agrícolas pelo método paramétrico MaxVer e pelo não paramétrico RNA. O uso de dados multitemporais ajudou a separar espectralmente as culturas agrícolas, pois uma única data para classificação tem o problema de sobreposição espectral das classes de culturas agrícolas. A classificação RNA produziu resultados superiores na classificação, pois com um número menor de amostras de treinamento, pode classificar completamente os dados da imagem multidimensional.

3 - MATERIAIS E MÉTODOS

3.1 Área de Estudo

A área de estudo corresponde à abrangência do Escritório de Desenvolvimento Regional (EDR) de Limeira, uma das divisões administrativas da Coordenadoria de Assistência Técnica Integral (CATI) do Estado de São Paulo (Figura 5), compreendendo os seguintes municípios: Porto Ferreira, Pirassununga, Analândia, Santa Cruz da Conceição, Araras, Cordeirópolis, Corumbataí, Ipeúna, Iracemápolis, Itirapina, Leme, Limeira, Rio Claro e Santa Gertrudes (Figura 6). Esta área situa-se a leste do Estado de São Paulo, cuja área estimada chega a 497.598,3000 ha e seu município sede, Limeira, está a 150 km da capital.

A área está delimitada pelo seguinte retângulo envolvente (Coordenadas Geográficas):

Canto superior direito: 22°45'33,72"S e 47°59'7,21"W;

Canto inferior esquerdo: 21°44'47,09"S e 47°09'20,76"W.

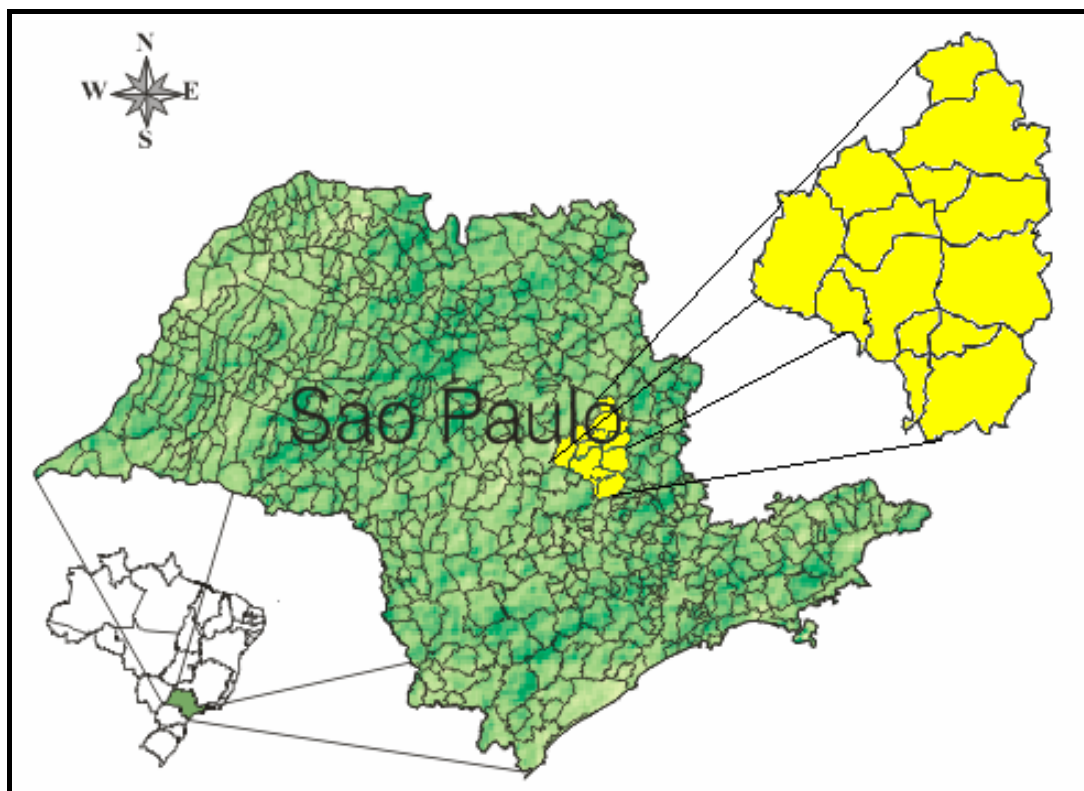


Figura 5: Localização da área de estudo.

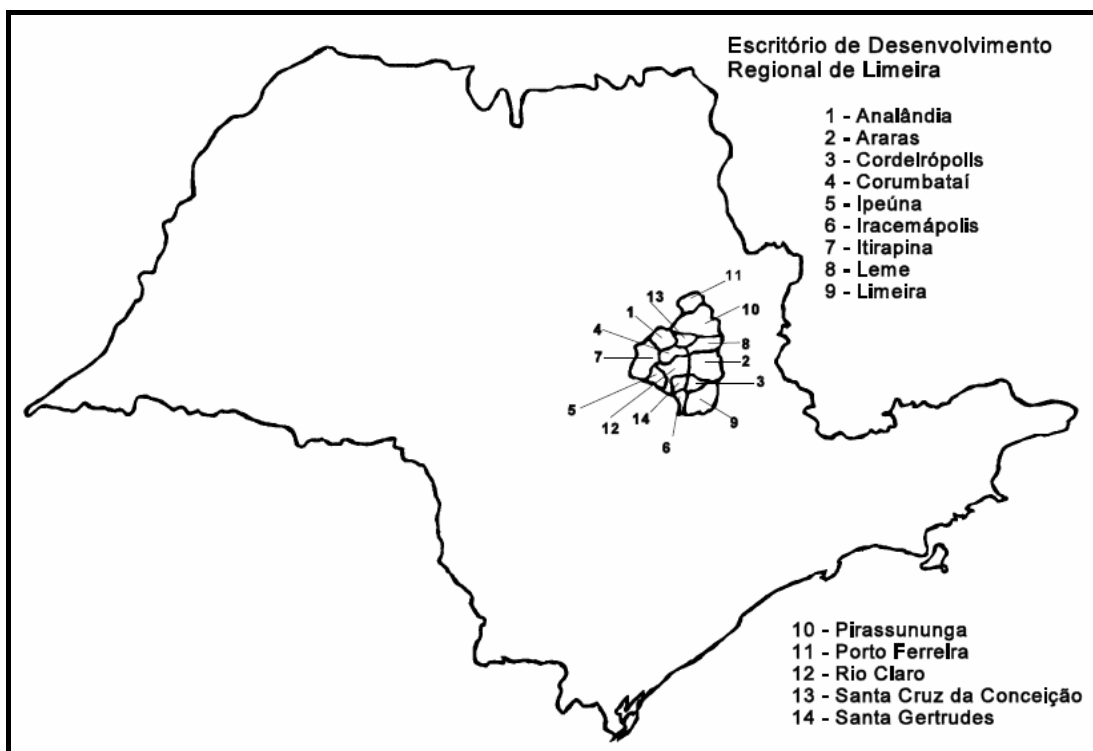


Figura 6: Localização dos municípios que compõe a EDR de Limeira.

A região encontra-se acima do nível do mar, com altitude variando de 500m a 800m, na área geográfica denominada Depressão Periférica. Partes dos municípios de Analândia, Corumbataí e Itirapina apresentam um relevo

montanhoso, na região leste da regional. A vegetação arbórea é predominantemente Mata Atlântica, atualmente restrita aos trechos de matas ciliares e pequenas reservas, e em alguns trechos o cerrado. O clima caracteriza-se como verão úmido e inverso seco. Três bacias hidrográficas dividem a região: Bacia Hidrográfica do Rio Piracicaba, Bacia Hidrográfica do Rio Mogi-Guaçu e Bacia Hidrográfica do Rio Jacaré-Guaçu (Otani et al., 1998).

A agricultura é a principal atividade da região, onde cultiva-se principalmente cana de açúcar, frutas cítricas, milho e soja. Outra atividade importante é a agropecuária, para a qual são destinadas áreas importantes para o desenvolvimento de pastos. Finalmente, os solos nesta área têm um uso de floresta com plantações importantes de *pinus* e eucalipto, para industrialização da celulose (Arce et al., 2005).

3.2 Materiais

3.2.1 Dados Orbitais

A área teste refere-se a um recorte de imagens MODIS. Para Zhan et al. (2002), o sensor MODIS fornece uma alta resolução radiométrica (16 bits), com uma excelente resposta para cada banda. Dados MODIS já vêm corrigidos dos efeitos atmosféricos e georreferenciados.

As imagens provenientes do sensor MODIS são disponibilizadas no portal de dados do EOS no formato *Hierarchical Data Format* (HDF) e foram reprojatadas para o formato *Georeferenced Tag Image File Format* (Geo-TIFF), através do software *Modis Reprojection Tool* 3.1, desenvolvido pelo EOS especificamente para transformação de formatos.

Essas imagens são disponibilizadas na forma de produtos. Para esta pesquisa utilizou-se o produto MOD09, com as seguintes bandas: vermelho (0,620 - 0,670 μm), infravermelho próximo - NIR (0,841 - 0,876 μm), azul (0,459 - 0,479 μm), além de uma banda localizada na faixa do infravermelho médio - MIR (1,628 - 1,652 μm), onde essas bandas são denominadas respectivamente: Banda 1, Banda 2, Banda 3 e Banda 6, do sensor MODIS.

As bandas do vermelho (Banda 1) e NIR (Banda 2) possuem resolução de 250m; as outras duas bandas (Banda 3 e 6) foram reamostradas de 500m para 250m. Esse procedimento de reamostragem serve apenas para padronização das imagens para o cálculo matricial, ou seja, a classificação multitemporal. Na análise multitemporal foram utilizadas 15 imagens do sensor MODIS (Tabela 3; Figura 7), com 424 linhas x 309 colunas, todas convertidas para 8 Bits. Todas as imagens foram projetadas no sistema UTM com a utilização do Datum WGS84.

Tabela 3: Imagens MODIS.

Data	Dia do Ano	Data	Dia do Ano	Data	Dia do Ano
01/01/2004	001	21/03/2004	081	09/06/2004	161
17/01/2004	017	06/04/2004	097	25/06/2004	177
02/02/2004	033	22/04/2004	113	11/07/2004	193
18/02/2004	049	08/05/2004	129	27/07/2004	209
05/03/2004	065	24/05/2004	145	12/08/2004	225




Figura 7: Imagens MODIS, na composição colorida R - Banda 6, G - Banda 1 e B - Banda 3.




Figura 7 (continuação): Imagens MODIS, na composição colorida R - Banda 6, G - Banda 1 e B - Banda 3.

3.2.1.1 Conversão Radiométrica

A resolução radiométrica de uma imagem digital é definida pela quantidade de bits usados para armazenar os dados correspondentes a um *pixel*, representando um nível de cinza. Assim, utilizando apenas 1 bit, são armazenados apenas dois valores, zero e um. Para uma imagem digital com 2 Bits, aumentam para quatro os valores representados. A maioria dos *softwares* de processamento de imagens do sensoriamento remoto

normalmente utilizam 8 Bits, justificando a necessidade da conversão radiométrica.

As imagens do presente trabalho encontram-se originalmente em 16 Bits ($2^n = 2^{16} = 65.536$ níveis de cinza). Para garantir o processo de conversão de 16 Bits para 8 Bits ($2^n = 2^8 = 256$ níveis de cinza, variando entre 0 a 255), foi utilizada a seguinte fórmula (Equação 22):

$$ND_{8bits} = \frac{(ND_{16bits} - \min_{16bits})}{(\max_{16bits} - \min_{16bits})} \cdot (\max_{8bits} - \min_{8bits}) + \min_{8bits} \quad (22)$$

onde,

ND_{8bits} - valor encontrado em 8 Bits;

ND_{16bits} - valor retirado da imagem em 16 Bits;

\max_{8bits} - valor máximo da escala de 8 Bits;

\min_{8bits} - valor mínimo da escala de 8 Bits;

\max_{16bits} - máximo valor retirado da imagem em 16 Bits;

\min_{16bits} - mínimo valor retirado da imagem em 16 Bits.

Substituindo os valores \max_{8bits} e \min_{8bits} na Equação 22, por 0 e 255 respectivamente, chega-se a Equação 22:

$$ND_{8bits} = 255 \cdot \frac{(ND_{16bits} - \min_{16bits})}{(\max_{16bits} - \min_{16bits})} \quad (23)$$

3.2.2 Ferramentas Computacionais

O software Idrisi Kilimanjaro foi utilizado na coleta das amostras de treinamento para a classificação, e também para a edição das imagens temáticas finais. O software ERDAS Imagine 8.5 foi utilizado para manipulação das imagens e importação/exportação para formatos compatíveis com os programas utilizados para classificar a imagem.

Para a aplicação da metodologia da STRS, empregou-se o aplicativo *Transform.exe*, desenvolvido em linguagem C por Vieira (2000). Para a extração dos coeficientes pela interpolação “Análise de Tendência

Polinomial da Superfície” foi utilizado o *software* estatístico *R* (Hornik, 2003), que é um aplicativo de código aberto e de domínio público; e para a extração dos coeficientes pela interpolação *Collocation*, usou-se o *Transform.exe*.

Para o treinamento da rede neural, utilizou-se o simulador de redes neurais “*Java Neural Network Simulator*”, desenvolvido pelo Instituto Wilhem-Schickard para Ciência da Computação (WSI) em Tübingen, Alemanha. Este simulador é baseado no *Stuttgart Neural Network Simulator* 4.2 (Zell et al., 1996), com uma nova interface gráfica desenvolvida para o ambiente Windows.

No caso da classificação pelo MaxVer, usou-se o aplicativo “*Max_like_cof.exe*”, desenvolvido por Vieira (2000). Esse aplicativo se diferencia dos tradicionais *softwares* existentes, pelo fato de permitir a utilização de diversas bandas espectrais (até 60 bandas espectrais) das imagens digitais em todas as fases do processo classificação.

3.3 Modelagem Multitemporal-Multiespectral

Uma única imagem de satélite pode não fornecer informações espectrais suficientes para permitir identificar todas as culturas plantadas ou até uma mesma cultura em diferentes estádios fenológicos. Entretanto, imagens multitemporais podem fornecer maiores informações sobre a área plantada e indicações sobre o crescimento e desenvolvimento de culturas, os quais podem ser elementos chaves na discriminação espectral de diferentes culturas (Apan e Potgieter, 2002). Vieira (2000) propôs uma metodologia que explora o uso da STRS, para caracterizar o comportamento de cada *pixel* em relação ao tempo de aquisição das imagens e o comprimento de onda utilizado.

Na metodologia STRS (Figura 8), cada *pixel* é representado como um ponto no espaço tridimensional, onde os eixos X, Y e Z representam o dia, o comprimento de onda e a reflectância, respectivamente. Com essa representação tridimensional, uma superfície analítica é interpolada por estes pontos (pontos de controle), os quais podem ser irregularmente espaçados. Os pontos de controle são extraídos com o auxílio da imagem de referência. Para interpolar estas superfícies podem ser utilizados, entre

outros, dois métodos de interpolação: a Análise de Tendência Polinomial da Superfície (*Polynomial Trend Surface* - PTS) e o *Collocation* - COL. O método interpolador PTS, normalmente interpola os pontos de controle extraindo a tendência da superfície, enquanto que o método COL, tenta ajustar completamente a superfície aos pontos de controle.

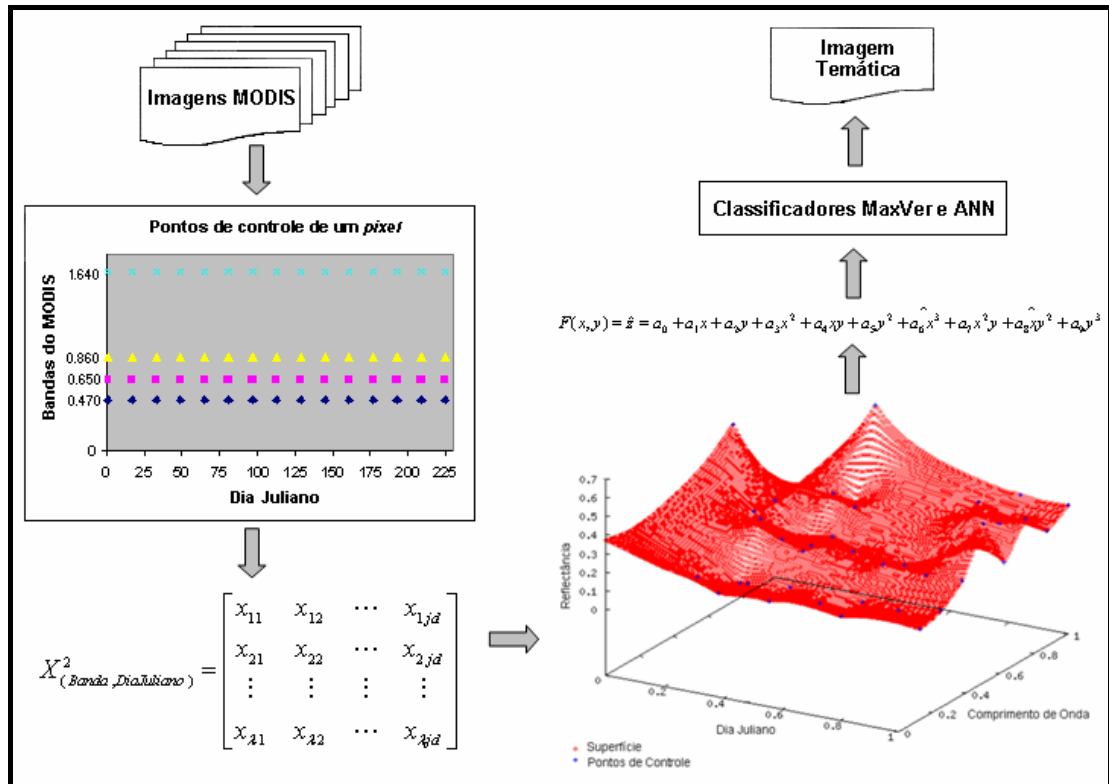


Figura 8: Um esboço da metodologia STRS.

Fonte: Vieira (2000).

As imagens foram adquiridas em 15 datas diferentes (Tabela 3) expressas em dia do ano (eixo x) e as bandas espectrais foram caracterizadas pelo valor médio do comprimento de onda (eixo y). Dessa forma as quatro bandas do sensor MODIS, vermelho (0,620 - 0,670 μm), infravermelho próximo - NIR (0,841 - 0,876 μm), azul (0,459 - 0,479 μm), além de uma banda localizada na faixa do infravermelho médio - MIR (1,628 - 1,652 μm), foram representadas pelo seu valor médio: 0,650 μm ; 0,859 μm ; 0,469 μm ; 1,640 μm , respectivamente (gráfico da Figura 8). A propriedade radiométrica foi expressa em reflectância (eixo z).

Foram gerados para cada *pixel* 60 pontos de controle tridimensionalmente (15 imagens MODIS com quatro bandas espectrais). Antes da fase de interpolação das superfícies, estes pontos de controle

foram re-escalados para o intervalo $[0,1]$, para os três eixos. Esse procedimento de re-escalamento é empregado para facilitar o processo computacional.

As interpolações, tanto para o interpolador PTS quanto para o interpolador COL, resultam em superfícies com coeficientes de magnitudes muito variáveis, devido à variação espectro-temporal dos diversos alvos presentes na área de estudo. Dessa maneira, antes de disponibilizar os coeficientes como parâmetros de entrada ao classificador, os coeficientes foram re-escalados para um intervalo $[0,1]$, em relação aos valores máximos e mínimos encontrados entre os coeficientes de cada termo do polinômio para todos os *pixels* da cena.

Após essa fase de interpolação, as superfícies foram parametrizadas através dos coeficientes do polinômio, para cada superfície, os quais são extraídos para formar os atributos que serão empregados no processo de classificação supervisionada.

Feita a parametrização, realizou-se a análise da comparação de superfícies analíticas, onde têm-se dois distintos métodos: o método direto e o método indireto. No método direto o *pixel* é representado em função dos parâmetros das superfícies analíticas. Já no método indireto, tem-se a representação do *pixel* em função dos coeficientes; desta forma espera-se que os *pixels* com superfícies semelhantes pertençam ao mesmo tipo de classe informacional. Nesta dissertação utilizou-se o método indireto para comparação das superfícies, pois o método direto requer muito esforço computacional.

3.3.1 Interpolação das Superfícies Analíticas

Neste estágio de interpolação das superfícies analíticas, Vieira (2000) simplesmente definiu como: a função que melhor representa a superfície a partir de um conjunto de pontos tridimensionais, representando os pontos de controle das superfícies, onde estes pontos podem ser obtidos na forma de pontos discretos ou subáreas.

Nesta dissertação utilizaram-se dois métodos de interpolação. O primeiro, uma aproximação polinomial (*Polynomial Trend Surface* - PTS), que

é uma combinação linear de elementos expressos em termos de potências e cruzamentos de produtos de coordenadas cartesianas. O segundo, um modelo de função de interpolação, *Collocation* (COL). Estes dois métodos são brevemente apresentados nas duas próximas seções.

3.3.1.1 Análise de Tendência Polinomial da Superfície

O primeiro método, conhecido como análise de tendência polinomial da superfície (PTS), é um interpolador determinístico global. Essa aproximação utiliza um ajuste polinomial dos dados para obter estimativas para os pontos de controle, através de uma função polinomial. No método PTS, normalmente os pontos de controle são interpolados extraído a tendência da superfície, reduzindo assim os efeitos de pequenas variações nos pontos de controle.

A suposição implícita nestes interpoladores é que, para a caracterização do fenômeno em estudo, predomina a variação em larga escala e a variabilidade local não é relevante (Camargo et al., 2004). Seria como ajustar um plano aos pontos de controle observados, que pode ser uma função linear (função polinomial de primeiro grau, Equação 24), ou uma função de segundo grau (função polinomial quadrática, Equação 25), ou uma função de terceiro grau (função polinomial cúbica, Equação 26), ou até uma função de grau n . Esses pontos de controle devem ser bem distribuídos aleatoriamente e devem-se evitar os pontos de extremidades na área de estudo. É necessário ter uma quantidade de pontos de controle superior ao número de coeficientes do polinômio para permitir o ajuste da superfície.

$$F(x, y) = \hat{z} = a_0 + a_1x + a_2y \quad (24)$$

$$F(x, y) = \hat{z} = a_0 + a_1x + a_2y + a_3x^2 + a_4xy + a_5y^2 \quad (25)$$

$$F(x, y) = \hat{z} = a_0 + a_1x + a_2y + a_3x^2 + a_4xy + a_5y^2 + a_6x^3 + a_7x^2y + a_8xy^2 + a_9y^3 \quad (26)$$

onde,

\hat{z} - representa a observação do fenômeno para cada par de coordenadas (x, y) ;

$a_0, a_1, a_2, \dots, a_8, a_9$ - são os coeficientes.

Observando as Equações 24, 25 e 26 o número de coeficientes depende do grau da função polinomial que pode ser dado pela Equação 27:

$$P = \frac{(p+1)(p+2)}{2} \quad (27)$$

onde,

P - número de coeficientes;

p - grau da função polinomial.

Os coeficientes das equações polinomiais constituem um vetor de valores que efetivamente resumem a forma da superfície e, portanto, a caracterizam. O coeficiente inicial, a_0 , é uma medida do valor absoluto da distância da superfície até a origem. Os coeficientes restantes, $a_0, a_1, a_2, \dots, a_n$, descrevem o formato da superfície e estão relacionados as propriedades geométricas. Esses coeficientes podem ser usados de duas maneiras: para comparar tanto a forma como a posição absoluta da superfície quando todos os coeficientes são usados ou então comparar apenas a forma geométrica, descartando o coeficiente a_0 .

A interpolação polinomial é ajustada pelo método dos mínimos quadrados, ajustando aos pontos de controle e minimizando o erro médio quadrático (MSE - *Mean Square Error*) (Equações 28 e 29).

$$\sum_{i=1}^n [\hat{z}(x_i, y_i) - z(x_i, y_i)]^2 = \text{mínimo} \quad (28)$$

$$m = \pm \sqrt{\frac{\sum_{i=1}^n [\hat{z}(x_i, y_i) - z(x_i, y_i)]^2}{n-1}} \quad (29)$$

onde,

z - representa a observação, observada, do fenômeno para cada par de coordenadas (x, y) ;

\hat{z} - representa a observação, ajustada, do fenômeno para cada par de coordenadas (x, y) ;

m - erro médio quadrático;
 n - número de observações.

Vieira (2000) constatou experimentalmente que polinômios do terceiro grau, para uso na interpolação, são suficientes para descrever a superfície sem perdas na exatidão da classificação. O autor chegou a essa conclusão realizando um estudo do polinômio de ordem sete decrescendo até o de ordem três, para verificar se a exatidão da classificação mudava significativamente. Portanto, no presente trabalho, utilizou-se diretamente polinômios do terceiro grau (Equação 25).

Obtiveram-se dez coeficientes que descrevem a distribuição da superfície no espaço tridimensional, através do polinômio de terceiro grau (Equação 25). Assim, para uma mesma classe informacional as distribuições ou os valores dos coeficientes devem ser próximos, já que representam aproximadamente uma mesma superfície espectral.

3.3.1.2 *Collocation*

O segundo método, denominado *Collocation* (COL), tenta ajustar completamente a superfície aos pontos de controle. Esse método proporciona superfícies que se aproximam consideravelmente dos pontos de controle. O interpolador de superfície de aproximação não filtra a presença de nuvens ou ruídos nos *pixels* das imagens, essa é uma desvantagem em relação ao interpolador PTS. Por exemplo, no caso de nuvens nos *pixels*, tem-se *pixels* com a máxima reflectância (valor de nível de cinza 255). Ao interpolar os coeficientes através desses *pixels* com nuvens obtêm-se superfícies com valores altos de reflectância, comprometendo o resultado da classificação.

Os mesmos pontos de controle usados no interpolador PTS foram empregados para ajustar superfícies que usa o interpolador COL. Esse método, descrito por Watson (1996), utiliza as observações $z(P_i)$ para um conjunto de localizações espacialmente distribuídas P_i , determinando-se os coeficientes a_i através de um sistema de equações lineares. Pode-se

observar a modelagem deste método para até i número de pontos de controle pela Equação 30.

$$\begin{array}{c} D \\ \downarrow \\ \left[\begin{array}{cccccc} e_1 & C(P_1P_2) & C(P_1P_3) & C(P_1P_4) & \dots & C(P_1P_j) \\ C(P_2P_1) & e_2 & C(P_2P_3) & C(P_2P_4) & & \cdot \\ C(P_3P_1) & C(P_3P_2) & e_3 & C(P_3P_4) & & \cdot \\ C(P_4P_1) & C(P_4P_2) & C(P_4P_3) & e_4 & & \cdot \\ \dots & & & & \dots & C(P_jP_i) \\ C(P_iP_1) & \cdot & \cdot & \cdot & C(P_jP_i) & e_i \end{array} \right] \cdot \begin{array}{c} a \\ \downarrow \\ \left[\begin{array}{c} a_1 \\ a_2 \\ \cdot \\ \cdot \\ \cdot \\ a_i \end{array} \right] = \begin{array}{c} z \\ \downarrow \\ \left[\begin{array}{c} z(P_1) \\ z(P_2) \\ \cdot \\ \cdot \\ \cdot \\ z(P_i) \end{array} \right] \end{array} \end{array} \quad (30)
 \end{array}$$

onde,

$$C(P_iP_j) = \sqrt{(P_{ix} - P_{jx})^2 + (P_{iy} - P_{jy})^2 + e_i^2}$$

O termo $C(P_iP_j)$ é uma função da distância no plano x-y entre pontos P_i e P_j . Modifica-se o termo $C(P_iP_j)$ pela constante não-negativa e_j forçando todas as distâncias menores que este limiar arbitrário serem positivas. O sistema de referência (x y z) desta dissertação está no intervalo [0,1], esperam-se pequenas variações nas distâncias, podendo o valor de e ser igual a zero.

Os coeficientes da superfície a_i (elementos do vetor a) cuja soma é zero ou próxima a zero, é obtido resolvendo o sistema de equações lineares de acordo com o seguinte modelo, Equação 31:

$$D \cdot a = z \quad (31)$$

onde,

D - matriz de distâncias entre os pontos P_i ;

z - vetor de reflectância de $z(P_i)$;

a - vetor de coeficientes desconhecidos que serão estimados para os dados.

O método dos mínimos quadrados é usado para encontrar os coeficientes do vetor a_i usando a seguinte fórmula padrão (Equação 32):

$$a = (D^T \cdot D)^{-1} \cdot D^T \cdot z \quad (32)$$

onde,

D^T - transposição da matriz de distâncias entre os pontos P_i ;

$(D^T \cdot D)^{-1}$ - inversão da matriz encontrada pelo produto $D^T \cdot D$.

Se P é o ponto de interpolação expressos na forma de coordenadas cartesianas (x, y) , e foram determinados os coeficientes, então o valor interpolado, $F(x, y)$, pode ser determinado pela Equação 32:

$$F(x, y) = a_1 \cdot C_{(PP_1)} + a_2 \cdot C_{(PP_2)} + a_3 \cdot C_{(PP_3)} + \dots + a_i \cdot C_{(PP_i)} \quad (33)$$

Todos estes passos acima do interpolador *Collocation* estão implementados num aplicativo desenvolvido em linguagem C (Vieira, 2000).

Na Figura 9 pode-se observar um exemplo das superfícies analíticas geradas para cada interpolador, PTS e COL, para cada classe informacional, cana-de-açúcar, cítrus, mata, pasto, eucalipto, soja e milho. Torna-se oportuno mencionar novamente que o interpolador PTS, normalmente interpola os pontos de controle extraíndo a tendência da superfície, enquanto que o interpolador COL tenta ajustar completamente a superfície aos pontos de controle.




Figura 9: Superfícies Analíticas de Contorno para os dois interpoladores PTS e COL.

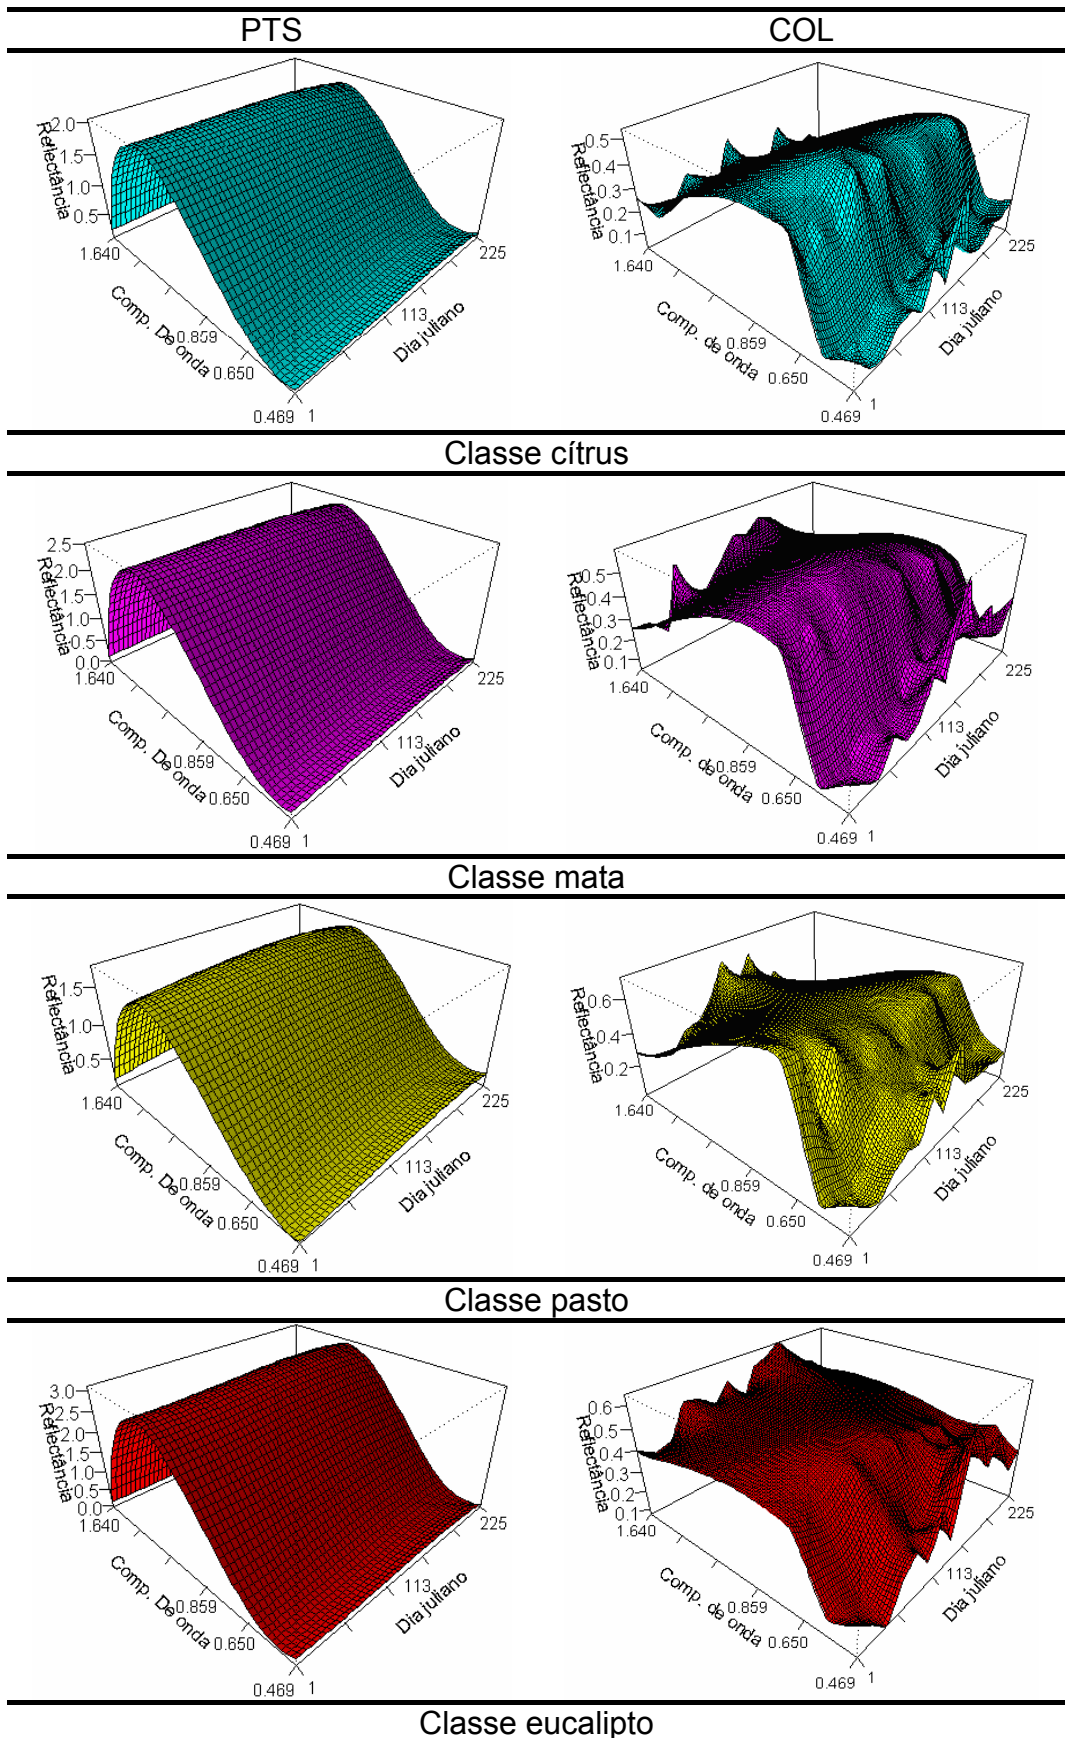


Figura 9 (continuação): Superfícies Analíticas de Contorno para os dois interpoladores PTS e COL.

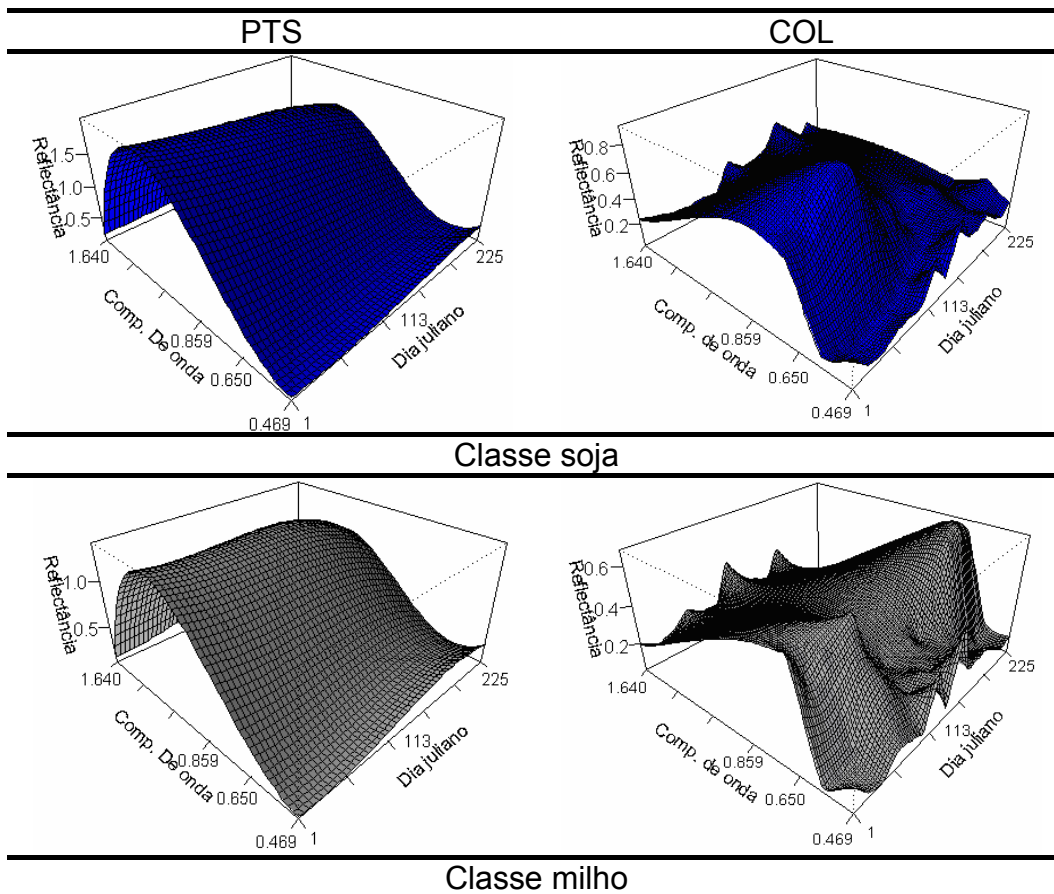


Figura 9 (continuação): Superfícies Analíticas de Contorno para os dois interpoladores PTS e COL.

3.4 Experimento

As etapas de desenvolvimento do trabalho estão apresentadas de forma genérica na Figura 10. Estas etapas envolvem uma fase da classificação multitemporal e multispectral das imagens, a partir da normalização dos coeficientes.

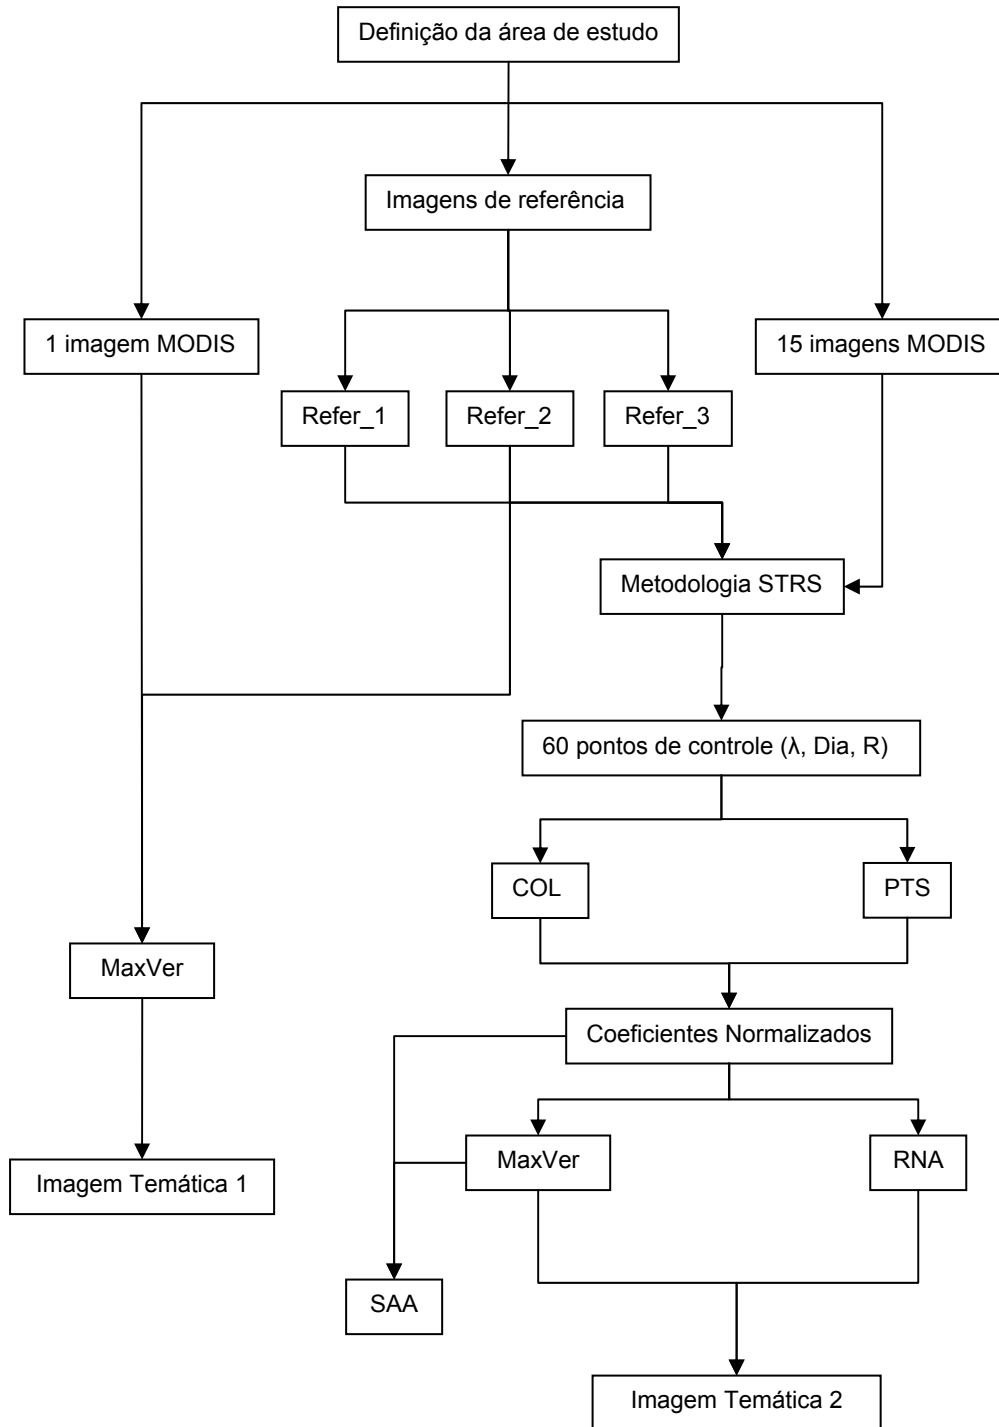


Figura 10: Fluxograma das atividades desenvolvidas nesta dissertação.

Legenda: Refer_1 - Imagem de Referência por Reamostragem; Refer_2 - Imagem de Referência por Digitalização em tela; Refer_3 - Imagem de Referência por Operação de vizinhança; SAA - Seleção de Atributos Aditiva; Imagem Temática 1 - Classificação uma data; Imagem Temática 2 - Classificação Multitemporal com a metodologia SRTS.

Um dos fatores determinantes no sucesso do processo de classificação são as imagens de referência. Para esta dissertação foram utilizadas três diferentes imagens de referência, na seção 3.4.1 serão dados maiores detalhes.

De acordo com o fluxograma foram geradas duas imagens temáticas (Figura 10).

A primeira imagem temática foi gerada a partir da classificação com apenas uma imagem MODIS. Foi verificado que a cultura mais representativa da região, cana-de-açúcar, possui o período de colheita entre os meses de abril a novembro, assim utilizou-se a imagem MODIS na data 21/03/2004 (81º dia do ano), data pouco antes da primeira colheita. Nessa classificação no vetor de entrada foram em função das bandas do sensor MODIS (Banda 1, Banda 2, Banda 3 e Banda 6) com a utilização do algoritmo MaxVer.

Obteve-se a segunda imagem aplicando a técnica de classificação multitemporal STRS onde o vetor de entrada é dado em função dos coeficientes normalizados, na seção 3.4.2 serão mostrados todos os passos seguidos para a sua obtenção. Foi aplicada a técnica SAA (Seleção de Atributos Aditiva, seção 3.4.2), na metodologia STRS para diminuir o vetor de entrada sem perdas no processo de classificação.

3.4.1 Imagens de Referência

Uma das questões básicas que limitam o uso de imagens de satélite no monitoramento de culturas agrícolas é o período de aquisição, devido à interferência de nuvens. Com as características dos sensores atualmente em uso, há um conflito entre uma redução expressiva na resolução espacial em favor da ampliação da resolução temporal. Assim sendo, coexistem sensores de alta resolução espacial, como o TM do Landsat 5 (30 m x 30 m) e baixa frequência de aquisição com sensores de baixa resolução espacial como o MODIS e alta frequência de re-visita.

Para geração da imagem de referência por Reamostragem foi utilizada a imagem temática produzida por Arce et al. (2005). As imagens utilizadas no processo de geração da imagem temática foram: do sensor TM

do Landsat (15/10/2003; 19/01/2004; 04/04/2004; 08/08/2004), em duas órbitas/pontos (220/75 e 220/76); e do sensor CCD e IR-MSS do CBERS (16/03/2004; 24/07/2004; 19/08/2004), na órbita 125 e pontos 154 e 155, que acompanharam o calendário agrícola da região. No processo de registro dessas imagens foram usadas imagens ortorretificadas disponibilizadas pela NASA do sensor TM do satélite Landsat-5 do ano 2000 em WGS84.

A metodologia utilizada por esses autores (Arce et al., 2005), consistiu em duas etapas, no processo de classificação supervisionada: segmentação e interpretação visual. Na primeira fase, a segmentação, utilizou-se a segmentação das imagens com o algoritmo de crescimento de regiões. Segundo Moreira (2003), a segmentação de imagens simula o comportamento de um foto-intérprete, agrupando áreas homogêneas pelo nível de cinza dos *pixels*. No processo de segmentação, é necessária a definição dos limites de similaridade e área. Em seu trabalho (Arce et al., 2005) utilizou o valor de 20 níveis de cinza para a similaridade e 50 *pixels* (aproximadamente 4,5000 ha) para a área.

Na fase seguinte, as imagens foram classificadas usando o algoritmo ISOSEG do SPRING, com 95% de probabilidade, no agrupamento das regiões em classes espectralmente homólogas. Posteriormente a essa fase, foi realizada a análise qualitativa, uma inspeção visual. Na análise qualitativa foram sobrepostas as imagens classificadas automaticamente em diferentes épocas, separando os diferentes tipos de cultivos. Assim, a partir da análise multitemporal foi obtido o mapa temático da EDR de Limeira.

Três estratégias para confecção de imagens de referência foram utilizadas:

(i) - Imagem de Referência por Reamostragem

A primeira imagem de referência foi gerada a partir da imagem temática da EDR de Limeira (cedida por Arce et al., 2005; INPE). Adotou-se o seguinte procedimento:

- Remoção de classes informacionais com menos de 1000 *pixels* na imagem temática de Limeira (resolução espacial de 30 m), gerando uma imagem com 7 classes informacionais. Essa remoção foi necessária devido a baixa resolução espacial das imagens MODIS (250x250m), pois essas

imagens apresentam limitações para o mapeamento de pequenas extensões de culturas agrícolas (Pax-Lenney e Woodcock, 1997);

- Reamostragem das imagens temáticas com resolução de 30 m para 250 m, utilizando-se o método de reamostragem do vizinho mais próximo. Esse procedimento utiliza o valor numérico do nível de cinza do *pixel* da imagem original mais próximo para atribuí-lo ao *pixel* da imagem re-amostrada;
- Filtragem da imagem re-amostrada em 250m, usando um filtro da mediana 3 x 3. Normalmente utiliza-se esse filtro para remoção de ruídos nas imagens. Nesse filtro, os pontos da vizinhança de (x,y), dentro de uma janela na imagem, são ordenados e tomados como novo valor para (x,y) o valor mediano desta ordenação (Figura 11). Foi necessária essa operação de filtragem, pois no procedimento de reamostragem alguns *pixels*, principalmente os das bordas, ficaram escuros, isto é, com ruídos.




Figura 11: Máscara de um filtro 3x3 é sobreposta à imagem na posição (i j).

Gerou-se então uma imagem de referência, por Reamostragem, com 7 classes informacionais, com as respectivas proporções dispostas na Tabela 6.

(ii) - Imagem de Referência por Digitalização

A segunda imagem de referência foi gerada a partir de amostras coletadas digitalizando-se em tela polígonos sobre as classes de interesse na imagem. Nessa metodologia buscou-se capturar amostras mais

homogêneas, para representar o máximo possível às características de cada classe informacional (Tabela 6).

(iii) - *Imagem de Referência por Operação de Vizinhança*

A terceira imagem de referência foi gerada a partir da imagem de referência por Digitalização de polígonos homogêneos, usando o desvio padrão do nível de cinza (também denominado nível digital) do *pixel* com os seus vizinhos. Para tal procedimento utilizou-se a ferramenta *Focal Statistics* do ArcGis (Figura 12).




Figura 12: Representação da operação de vizinhança para o cálculo do desvio padrão.

A ferramenta *Focal Statistics* do ArcGis realiza diversas operações estatísticas, valor médio, soma, valor máximo, valor mínimo, mediana, desvio padrão, entre outros. No caso desta dissertação optou-se pelo desvio padrão, pois esta medida leva em consideração a totalidade dos valores da variável em estudo. Para determinação do desvio padrão, escolheu-se uma máscara retangular no tamanho 3x3, para efetuar a operação de vizinhança. O desvio padrão é calculado pela Equação 34:

$$DesvioPadrão(i, j) = \sqrt{\frac{\sum_{i=1}^n \sum_{j=1}^n (x - \bar{x})^2}{(n-1)}} \quad (34)$$

onde,

$DesvioPadr\tilde{a}o(i, j)$ - valor do desvio padr\~ao do *pixel* central da m\~ascara, em n\~ivel de cinza, na posi\~c\~ao (i, j) ;

x - corresponde ao valor do n\~ivel de cinza do *pixel*, na posi\~c\~ao (i, j) ;

\bar{x} - representa o valor m\~edio de acordo com a m\~ascara (3x3);

n - n\~umero de *pixels* da m\~ascara.

A janela m\~ovel percorre toda a imagem (424 linhas por 309 colunas, imagens MODIS). Na Tabela 4, mostra-se um exemplo ilustrativo da opera\~c\~ao de vizinhan\~ca com apenas (5 linhas por 5 colunas), utilizando a Equa\~c\~ao 33. No lado esquerdo, o recorte da imagem e no lado direito o resultado da opera\~c\~ao de vizinhan\~ca.

Tabela 4: Exemplo ilustrativo da Opera\~c\~ao de vizinhan\~ca.

	0	1	2	3	4	5	...	308
0	18	22	22	19	18	18	...	
1	18	18	22	14	18	18	...	
2	28	22	22	25	15	19	...	
3	24	25	25	27	23	21	...	
4	25	24	26	21	20	22	...	
5	24	21	21	17	19	19	...	
...				
423								

→

	0	1	2	3	4	5	...	308
0	x	x	x	x	x		...	
1	x	3,2	3,2	3,6	3,1		...	
2	x	3,3	4,1	4,6	4,4		...	
3	x	1,9	2,0	3,7	3,5		...	
4	x	1,8	3,2	3,4	2,9		...	
5							...	
...				
423								

Para chegar-se ao produto final, a imagem de refer\~encia, foi feita uma opera\~c\~ao de sobreposi\~c\~ao (*overlay*). Foi utilizado um *overlay* multiplicativo, com a imagem resultante do processo de opera\~c\~ao de vizinhan\~ca e com a imagem de refer\~encia por Digitaliza\~c\~ao.

Utilizou-se a imagem MODIS, na \~unica data (21/03/2004, 81\~o dia do ano), para gera\~c\~ao de diversas imagens variando o desvio padr\~ao, em 2, 3, 4 e 5 n\~iveis de cinza (NC), para cada uma das 4 bandas do sensor MODIS (Banda 1, Banda 2, Banda 3 e Banda 6). Na Tabela 5, est\~a indicado a quantidade de *pixels* para cada varia\~c\~ao do n\~ivel digital. Escolheu-se a Banda 2, pois esta banda apresentou a menor varia\~c\~ao dos NC.

Tabela 5: Números de *pixel* / classe para cada limiar do desvio padrão do nível de cinza do *pixel* e sua vizinhança.

Classes	Variação dos Níveis de Cinza (NC)				
	5 NC	4 NC	3 NC	2 NC	1 NC
Cana-de-açúcar	1421	1297	843	302	240
Cítrus	735	661	365	117	99
Mata	733	684	356	116	96
Pasto	304	268	135	49	42
Eucalipto	279	246	161	67	48
Soja	249	223	129	28	26
Milho	222	201	102	32	27
Total	3943	3580	2091	711	578

O ideal seria uma imagem com desvio padrão que não ultrapasse o valor de zero nível de cinza. Valor de zero NC significa dizer que não há variação do nível digital do *pixel* com os seus vizinhos, isso seria o ideal, pois resultaria em amostras homogêneas na imagem de referência. Porém, à medida que diminui o nível de cinza também diminui o número de *pixels* por classe (Tabela 5), resultando assim numa amostragem insatisfatória. Optou-se desta forma, por gerar uma imagem de referência eliminando os *pixels* que possuíssem o desvio padrão da variância do nível de cinza maior que 5 níveis de cinza (Tabela 6).

As imagens de referência foram rotuladas distintamente para fins de comparação das metodologias empregadas na sua obtenção como Reamostragem para a imagem de referência 1 (Refer_1), Digitalização em tela para a imagem de referência 2 (Refer_2) e Operação de vizinhança para a imagem de referência 3 (Refer_3).

Tabela 6: Classes da imagem de referência.

Classes	Refer_1		Refer_2		Refer_3	
	<i>Pixels</i>	Percentual (%)	<i>Pixels</i>	Percentual (%)	<i>Pixels</i>	Percentual (%)
1	5167	7,01	824	17,70	1421	18,59
2	28327	38,45	1651	35,40	735	36,04
3	4406	5,98	288	6,20	733	5,63
4	3044	4,13	318	6,80	304	6,31
5	9365	12,71	836	18,00	279	18,64
6	22261	30,22	410	8,80	249	7,71
7	1102	1,50	329	7,10	222	7,08
Total	73672	100	4656	100	3943	100

Legenda: (1) Mata; (2) Cana-de-açúcar; (3) Milho; (4) Soja; (5) Cítrus; (6) Pasto; (7) Eucalipto.

3.4.2 O Processo de Classificação

No processo de classificação multitemporal, as superfícies foram parametrizadas através dos coeficientes. Os coeficientes foram usados como variáveis discriminantes no processo de classificação para os algoritmos MaxVer e RNA. Foram selecionadas amostras aleatórias e independentes, tanto para o treinamento como para a validação das classificações MaxVer e RNA.

Mather (1999) recomendou que uma amostragem representativa para o treinamento e a validação, seja pelo menos 30 vezes o número de variáveis discriminantes (por exemplo, bandas espectrais) por classe.

A maioria dos pesquisadores usa equações que estão baseadas na aproximação normal à distribuição binominal para calcular o tamanho de amostra (Congalton e Green, 1999). Essas equações são aplicáveis para cálculo do tamanho de amostra necessário para estimar a precisão global de uma classificação, onde um analista só está interessado na proporção das amostras corretamente classificadas e em algum erro permissível. Entretanto, é necessário reunir um número suficiente de amostras para poder representar adequadamente a matriz de confusão para todas as classes no estudo (Congalton e Green, 1999). Sendo assim, Congalton e Green (1999), originalmente apresentado por Tortora (1978), utiliza uma alternativa com base na distribuição multinomial (Equação 35).

$$n = B\Pi_i(1 - \Pi_i)/b_i^2 \quad (35)$$

onde,

n - tamanho da amostra;

$\Pi_i (i = 1, \dots, k)$ - proporção de área da imagem na classe de i^{th} ;

B - superior $(\alpha/k) \cdot 100^{th}$ percentil da distribuição de χ^2 com 1 grau de liberdade, α é o nível de confiança desejado;

b_i - precisão absoluta i^{th} da amostra;

k - número de classes.

Para aplicação nesta dissertação, têm-se sete categorias na classificação ($k = 7$; 7 classes informacionais), o nível de confiança desejado é 95%, sendo o erro admissível de 5% ($\alpha = 0,05$). Conforme mostra a Tabela 6 a classe de cana-de-açúcar é a mais representativa da região de estudo, assim foi utilizada a sua porcentagem da área ocupada para o cálculo da amostragem. O valor B deve ser determinado a partir de uma tabela *Chi quadrado* com 1 grau de liberdade e α/k (0,007142857). Neste caso, o valor apropriado para B é $\chi^2 (1; 0,992857) = 7,348571$.

- Cana-de-açúcar para Imagem de Referência 1: 38,45% ($\Pi_i = 0,38$);

$$n = 7,348571(0,38)(1 - 0,38)/(0,05)^2 = 693 \quad (35)$$

- Cana-de-açúcar para Imagem de Referência 2: 35,45% ($\Pi_i = 0,35$);

$$n = 7,348571(0,35)(1 - 0,35)/(0,05)^2 = 672 \quad (36)$$

- Cana-de-açúcar para Imagem de Referência 3: 36,04% ($\Pi_i = 0,36$);

$$n = 7,348571(0,36)(1 - 0,36)/(0,05)^2 = 677 \quad (37)$$

Com os valores acima encontrados (Equações 35, 36 e 37) e sabendo que a amostragem mínima para a validação é de pelo menos 1/3 das amostras de treinamento (Mather, 1999), encontrou-se a amostragem para cada metodologia de classificação:

- Imagem de Refer_1: 99 *pixels*/classe para o treinamento e 33 *pixels*/classe para a validação (total 924 *pixels*);

- Imagem de Refer_2: 96 *pixels*/classe para o treinamento e 32 *pixels*/classe para a validação (total 896 *pixels*);
- Imagem de Refer_3: 96 *pixels*/classe para o treinamento e 32 *pixels*/classe para a validação (total 896 *pixels*).

Como visto anteriormente, foram gerados para cada *pixel*, 60 pontos de controle tridimensionalmente (15 imagens MODIS com quatro bandas espectrais). Para o interpolador PTS foram utilizados estes 60 pontos de controle para ajustar a superfície empregando uma função polinomial do terceiro grau (10 coeficientes), considerando as restrições matemáticas no processo de interpolação.

Os mesmos pontos de controle foram utilizados para ajustar a superfície usando o interpolador COL, gerando-se assim 60 coeficientes. Para ambos interpoladores, os coeficientes foram re-escalados novamente para o intervalo [0, 1], para utilização nas fases de treinamento e teste dos classificadores.

Após esse procedimento, foram realizados o treinamento e a validação propriamente dita das amostras de treinamento e teste, respectivamente, por dois diferentes algoritmos classificadores MaxVer e por RNA. Para esses dois algoritmos, a classificação é realizada de forma supervisionada, onde é necessário o conhecimento do número de classes informacionais presentes na área de estudo a partir de mapas de referência.

Na etapa de treinamento e validação, diferentes arquiteturas foram testadas: variou-se o número de neurônios na camada de entrada, correspondentes ao número de variáveis discriminantes, de duas formas diferentes, 10 coeficientes para o PTS e 60 coeficientes para o COL; foi variado o número de neurônios na camada interna e/ou número de camadas internas; e todas tendo o mesmo número de neurônios na camada de saída (7 classes informacionais).

Conforme sugerido por Hirose et al. (1991), o número de neurônios da(s) camada(s) interna(s) foi determinado experimentalmente usando uma estratégia de acréscimo de neurônios até atingir uma convergência pré-estabelecida, seguida de uma retirada de neurônios, enquanto permanecer a convergência desejada.

Esse procedimento começa com uma rede pequena composta de uma camada de entrada (número de variáveis discriminantes) e uma de saída (número de classes informacionais envolvidas, 7 classes), com somente um neurônio em uma camada interna. O critério empregado para adicionar neurônios na camada interna está baseado no comportamento do erro (MSE - *Mean Square Error*) durante a etapa de treinamento. Acrescentam-se mais neurônios na camada interna até encontrar o MSE pré-estabelecido (mínimo MSE), em alguns casos ao acrescentar mais neurônios aumenta o MSE. Quando ocorre o aumento do MSE, volta-se o número de neurônios anterior, encontrando assim a arquitetura da rede. Deste modo, o erro do treinamento foi usado como critério para avaliar o desempenho da rede. O erro do treinamento da rede mede a diferença entre os valores estimados e os valores desejados para o conjunto de dados do treinamento.

Após esse método de tentativa e erro, encontrou-se o número ótimo de duas camadas internas, sendo que no interpolador COL o número de neurônios foi de 30 para a primeira camada e 15 para segunda camada, e no interpolador PTS o número de neurônios foi de 30 para a primeira camada e 21 para a segunda camada.

O modelo de arquitetura RNA utilizado foi o *feed-forward*, com múltiplas camadas, com o algoritmo de treinamento para aprendizagem supervisionada *backpropagation*. O treinamento das redes utilizando um aprendizado supervisionado consistiu dos seguintes procedimentos:

- Alocação aleatória dos pesos interneurônios. Redes com valores grandes têm o problema de saturação ou até a dificuldade de aprendizado, desta forma evitam-se esses problemas quando os pesos são inicializados com valores aleatórios pequenos. Nesta dissertação os pesos foram inicializados com valores aleatórios entre -0,5 e +0,5;
- O treinamento sempre foi feito com a função “*shuffle*” ativada, essa função permitia uma entrada aleatória dos padrões de treinamento, evitando tendências durante o treinamento;
- A função sigmóide (Equação 15) foi utilizada para ativação da rede, uma vez que os resultados estavam normalizados entre 0 e 1. Maiores detalhes sobre essa função podem ser observados na seção 2.2.2.3;

- O parâmetro taxa de aprendizado tem grande influência durante o processo de treinamento da rede. Uma taxa de aprendizado muito baixa torna o aprendizado da rede muito lento, ao passo que uma taxa de aprendizado muito alta provoca oscilações no treinamento e impede a convergência do processo de aprendizado. Foi variada a taxa de aprendizado de 0,2; 0,1; 0,075 e também o número de ciclos de aprendizagem 1.000, 2.000, 3.000 variando até 10.000, 15.000 e 20.000.

Os resultados da classificação obtidos com a aplicação do método STSR foram submetidos a procedimentos de avaliação estatística com o intuito de verificar a precisão da classificação. Para tanto, gerou-se uma matriz de confusão, a partir de uma amostragem independente, com os coeficientes de exatidão global, *Kappa* e variância do *Kappa*, para cada classificador, e ambos interpoladores e algoritmos, ou seja, para cada metodologia de classificação. O coeficiente *Kappa* é a medida de como a classificação coincide com a imagem de referência (Congalton e Green, 1999). Os classificadores (RNA e MaxVer) foram comparados para verificar se existem diferenças estatisticamente significantes entre os classificadores. Além dessa comparação, verificou-se a precisão da classificação de única data.

Utilizando-se o classificador redes neurais observam-se as configurações das redes com as imagens de referência Refer_1, Refer_2 e Refer_3, para cada interpolador, PTS e COL nas Tabelas 6, 7 e 8, respectivamente. À medida que aumenta o número de ciclos no treinamento das redes não significa que aumenta as precisões das classificações, tanto para classificações usando o interpolador PTS e o COL.

Apesar do MSE ser utilizado como uma medida do desempenho das redes neurais, não se mostrou apropriado para a escolha da melhor classificação.

Foi escolhida a rede treinada com 3.000 ciclos para o interpolador PTS e a rede treinada com 1.000 ciclos para o interpolador COL, para classificação com a imagem de referência Refer_1 (Tabela 7). Para a classificação com a imagem Refer_2, escolheu-se a rede treinada com 3.000 ciclos para o interpolador PTS e a rede treinada com 8.000 ciclos para o

interpolador COL, de acordo com as configurações mostradas na Tabela 8. E a classificação com a imagem Refer_3 foi escolhida a rede treinada com 3.000 ciclos para o interpolador PTS e para o interpolador COL (Tabela 9).

Tabela 7: Comparação entre o número de ciclos e a precisão da classificação com a imagem Refer_1.

Ciclos	PTS				COL			
	MSE	global	kappa	variância	MSE	global	kappa	variância
1000	0,736	44,2	0,348	0,001348	0,655	46,8	0,379	0,001268
2000	0,716	45,9	0,369	0,001365	0,596	29,0	0,172	0,001136
3000	0,698	51,5	0,434	0,001471	0,563	36,8	0,263	0,001187
4000	0,675	44,2	0,348	0,001346	0,534	40,7	0,308	0,001268
5000	0,653	36,8	0,263	0,001304	0,491	39,8	0,298	0,001264
6000	0,634	45,0	0,359	0,001398	0,471	38,5	0,283	0,001129
7000	0,629	34,2	0,232	0,001156	0,446	36,8	0,263	0,001278
8000	0,616	45,5	0,364	0,001427	0,416	41,1	0,313	0,001330
9000	0,597	42,4	0,328	0,001262	0,394	33,3	0,222	0,001215
10000	0,609	44,2	0,348	0,001428	0,368	38,1	0,278	0,001271
15000	0,545	35,5	0,247	0,001283	0,216	36,4	0,258	0,001313
20000	0,499	26,8	0,146	0,000914	0,168	37,7	0,273	0,001280
Entrada 10 Camadas Ocultas 30 e 21 Saída 7					Entrada 60 Camadas Ocultas 30 e 15 Saída 7			

Tabela 8: Comparação entre o número de ciclos e a precisão da classificação com a imagem Refer_2.

Ciclos	PTS				Colocação			
	MSE	global	kappa	variância	MSE	global	kappa	variância
1000	0,673	51,8	0,438	0,001483	0,513	46,4	0,375	0,001483
2000	0,585	52,7	0,448	0,001490	0,436	51,8	0,438	0,001490
3000	0,541	54,9	0,474	0,001460	0,357	54,0	0,464	0,001469
4000	0,493	53,1	0,453	0,001497	0,286	58,5	0,516	0,001467
5000	0,458	48,7	0,401	0,001499	0,239	39,7	0,297	0,001443
6000	0,433	54,9	0,474	0,001492	0,225	58,5	0,516	0,001468
7000	0,423	37,5	0,271	0,001426	0,179	40,6	0,307	0,001434
8000	0,393	46,4	0,375	0,001472	0,174	64,7	0,589	0,001360
9000	0,397	53,6	0,458	0,001492	0,126	46,4	0,375	0,001491
10000	0,363	29,9	0,182	0,001265	0,121	53,6	0,458	0,001498
15000	0,271	38,8	0,286	0,001428	0,083	40,2	0,302	0,001443
20000	0,246	33,9	0,229	0,001365	0,078	37,5	0,271	0,001382
Entrada 10 Camadas Ocultas 30 e 21 Saída 7					Entrada 60 Camadas Ocultas 30 e 15 Saída 7			

Tabela 9: Comparação entre o número de ciclos e a precisão da classificação Refer 3.

Ciclos	PTS				Colocação			
	MSE	global	kappa	variância	MSE	global	kappa	variância
1000	0,634	54,0	0,464	0,001471	0,517	55,4	0,479	0,001451
2000	0,530	56,3	0,490	0,001438	0,409	47,8	0,391	0,001407
3000	0,473	62,9	0,568	0,001370	0,319	59,8	0,531	0,001425
4000	0,439	50,0	0,417	0,001512	0,257	46,4	0,375	0,001416
5000	0,412	56,3	0,490	0,001465	0,220	42,4	0,328	0,001467
6000	0,407	46,9	0,380	0,001468	0,457	50,9	0,427	0,001470
7000	0,373	46,9	0,380	0,001495	0,448	44,2	0,349	0,001392
8000	0,361	49,1	0,406	0,001481	0,151	39,7	0,297	0,001324
9000	0,072	42,9	0,333	0,001461	0,128	43,8	0,344	0,001330
10000	0,347	47,3	0,385	0,001494	0,116	47,3	0,385	0,001501
15000	0,295	43,3	0,385	0,001499	0,009	48,2	0,396	0,001462
20000	0,254	42,0	0,323	0,001474	0,085	48,7	0,401	0,001463
Entrada 10 Camadas Ocultas 30 e 21 Saída 7					Entrada 60 Camadas Ocultas 30 e 15 Saída 7			

3.4.3 Seleção de Atributos Aditiva

Com a análise multitemporal aumenta o número de variáveis discriminantes no processo de classificação, provocando-se assim um aumento de coeficientes das STRS. À medida que se aumenta o número de variáveis discriminantes, cresce também o número de parâmetros a serem estimados em um classificador paramétrico, os que por sua vez requer um número também crescente de amostras de treinamento para uma melhor exatidão na classificação.

O fenômeno de “Hughes” está ligado à degradação da precisão dos resultados da classificação com o aumento da dimensionalidade dos dados, mantendo constante o número de amostras de treinamento (Tadjudin, 1998). Conforme demonstrado por Vieira (2000) a aplicação da técnica de Seleção de Atributos Aditiva sobre índices de separabilidade das classes, permite reduzir a quantidade de coeficientes de entrada sem comprometer ou reduzir a qualidade das precisões estatísticas.

Neste trabalho utilizou-se o método da Seleção de Atributos Aditiva (Jain et al., 1997). Tal escolha é justificada, já que essa metodologia é de fácil implementação, necessita de pouco esforço computacional e é muito utilizada na solução de problemas de otimização e busca (Oliveira, 2005).

O algoritmo adota uma estratégia de busca adicionando atributos. Podem-se utilizar diversos critérios para otimizar a separabilidade entre classes, entretanto, para este trabalho utilizou-se coeficiente *kappa* (usando a Equação 18, seção 2.2.3).

Inicialmente identifica-se o melhor conjunto de feições obtido iterativamente, dado um conjunto inicialmente vazio de coeficientes. Adiciona-se um coeficiente a cada iteração, uma vez selecionado o coeficiente não pode mais ser descartado. O classificador usado foi o algoritmo supervisionado MaxVer (descrito na seção 2.2.2.2).

O método de seleção de atributos aditiva começa com o melhor subconjunto de tamanho $m = 1$ para a melhor única característica f_1 . O próximo passo é encontrar o melhor subconjunto de tamanho $m = 2$ que incluem f_1 , isto é, f_1 e um outro coeficiente no qual a precisão de classificação é maximizada. O melhor subconjunto ao término do segundo ciclo será f_1 e f_2 . O procedimento continua com subconjunto f_1, f_2, f_3 , e assim por diante. Esse procedimento para quando não há nenhuma diferença significativa entre um subconjunto de coeficientes e todas as características originais (coeficientes originais), a algum nível de 95% de confiança, definido arbitrariamente.

4 - RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados e discutidos os resultados desta dissertação. São demonstrados os resultados da classificação de extensas áreas agrícolas da EDR de Limeira, estimando-se a área plantada. Primeiramente, são apresentados os resultados que levam em consideração apenas o aspecto multiespectral das imagens MODIS. Posteriormente, os resultados oriundos da aplicação da técnica que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS.

4.1 Classificação de uma única imagem

Para essa classificação utilizaram-se as três metodologias diferentes na geração de imagens de referência, Refer_1, Refer_2 e Refer_3, com o algoritmo MaxVer. O pior desempenho obtido foi pela classificação utilizando a metodologia de imagem de referência Refer_1. Esta reamostragem causa inclusão e/ou exclusão de *pixels* às classes contidas na imagem de referência que estão no limiar entre classes, *pixels* de mistura, causando assim confusão na classificação. Observa-se uma melhora nas outras classificações, devido à escolha de amostras mais homogêneas. Na Tabela 10, observa-se o melhor resultado obtido pela metodologia Refer_3, pela sua matriz de confusão. As matrizes de confusão para as outras classificações,

assim como as imagens temáticas geradas, podem ser observadas no Anexo B e no Anexo C, respectivamente.

Tabela 10: Matriz de Confusão da Classificação com imagem de referência Refer_3.

Classificação (Refer_3)									Acurácia do Usuário
Classe	1	2	3	4	5	6	7	Total	
1	18	3	3	3	0	2	3	32	56,1
2	0	5	0	0	0	1	0	6	83,3
3	0	1	11	0	12	2	1	28	39,3
4	3	3	0	12	0	0	6	24	50,0
5	2	1	10	0	18	0	0	31	58,1
6	5	8	6	15	1	22	2	59	37,3
7	4	11	2	2	0	5	20	44	45,5
Total	32	32	32	32	32	32	32	224	
Acurácia do Produtor	56,2	15,6	34,4	37,5	56,2	68,8	62,5		

Exatidão Global = 47,3; $kappa = 0,385$; Var = 0,001444;

$Z_{calculado} = 10,142$; $Z_{tabelado} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Todas as classificações geradas a partir das imagens em uma data foram comparadas usando os índices $kappa$ e de exatidão global, para cada imagem de referência e com o classificador MaxVer (Tabela 11).

Tabela 11: Índices derivados das matrizes de confusão.

Metodologia	MaxVer		
	Global(%)	$Kappa$	Var
Refer_1 (R)	32,0	0,207	0,001209
Refer_2 (D)	39,2	0,292	0,001297
Refer_3 (O)	47,3	0,385	0,001444

Baseado na Tabela 12 vale a pena mencionar novamente, os valores da diagonal principal da matriz de significância representam a precisão do classificador comparado a uma classificação aleatória, enquanto os valores de fora da diagonal representam o desempenho relativo entre os classificadores (Vieira, 2000). Os valores em negrito indicam que não há diferença estatística significativa entre os classificadores, os outros valores

representam a superioridade ou inferioridade relativas entre cada par de classificador. Analisando a Tabela 12, observa-se que não há diferença estatística significativa entre as classificações com a metodologia de imagem de referência Refer_1 e Refer_2, assim como as classificações com a Refer_2 e Refer_3.

Tabela 12: Avaliação do desempenho dos classificadores MaxVer por metodologia de obtenção da imagem de referência através dos resultados dos coeficientes *Kappa*, a um nível de confiança de 95% ($Z = 1,96$).

	Refer_1	Refer_2	Refer_3
<i>Kappa</i>	0,207	0,292	0,385
Variância	0,001209	0,001297	0,001444
Refer_1	5,953		
Refer_2	1,698	8,108	
Refer_3	3,456	1,776	10,132

■ Indica haver diferença estatística significativa entre os classificadores ($>1,96$).

Apesar do acréscimo no valor do índice *kappa* variando a imagem de referência, pode-se ainda melhorá-los. Assim, é oportuno destacar a necessidade de que sejam realizados estudos complementares com os dados MODIS, levando em conta a possibilidade de uso de dados multitemporais. Nos próximos tópicos serão apresentados resultados oriundos de classificações multitemporais.

A Figura 13, mostra a imagem temática oriunda do melhor resultado aplicando a metodologia com a imagem de referência, Refer_3, utilizando o algoritmo MaxVer.

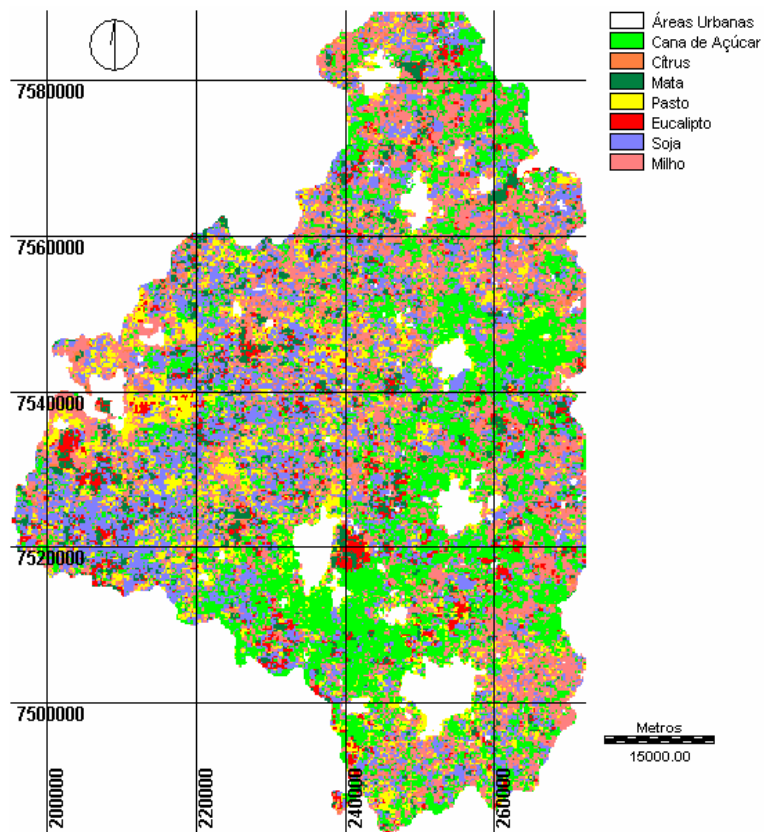


Figura 13: Imagem classificada a partir da imagem de referência Refer_3, de acordo com o limite as EDR Limeira.

4.2 Classificações Multitemporais

Os procedimentos de classificação multitemporal tiveram a finalidade de estimar áreas de extensas culturas agrícolas, utilizando-se a metodologia STRS. Para tal, foi selecionado um conjunto de amostras aleatórias, tanto para o treinamento quanto para a validação. Para a imagem de referência Reamostragem (Refer_1) foram selecionados 924 *pixels* representados temporal e espectralmente, com 132 *pixels* por classe. Já para as outras duas imagens de referência, Digitalização em tela (Refer_2) e Operação de vizinhança (Refer_3), selecionou-se 896 *pixels* representados temporal e espectralmente, com 132 *pixels* por classe. Nesta amostragem representaram-se os sete tipos de cobertura mais representativos área de estudo: cana-de-açúcar, cítrus, mata, pasto, eucalipto, soja e milho.

Para as classificações com a imagem de referência Refer_1, foram utilizados 693 *pixels* para o treinamento e 231 *pixels* para a validação. E para as outras classificações com as imagens de referência Refer_2 e

Refer_3, utilizou-se 672 *pixels* para o treinamento e 224 *pixels* para a validação. A precisão da classificação foi expressa como porcentagem correta para as amostras independentes de validação. Tanto, em classificações usando o algoritmo RNA como o MaxVer, os *pixels* foram rotulados para a classe informacional que possuía a maior probabilidade.

A seguir maiores detalhes serão dados sobre os resultados de todas as classificações multitemporais: variando as imagens de referência (Refer_1, Refer_2 e Refer_3), variando os interpoladores (COL e PTS) e variando o algoritmo classificador (MaxVer e RNA).

Todas as classificações geradas foram comparadas usando os índices *kappa* e de exatidão global, para cada interpolador e com os classificadores MaxVer e RNA. Observando-se a Tabela 13, verifica-se que o melhor desempenho da classificação (*Kappa* = 0,589) foi obtido utilizando-se a Refer_2 (D), com o classificador RNA e interpolador COL, e a pior classificação obtida (*Kappa* = 0,197) foi a configuração usando a Refer_1 (R), com o classificador MaxVer e o interpolador COL. Conseqüentemente, esse resultado evidencia a importância da escolha de amostras de treinamento mais homogêneas, quando da geração da imagem de referência, como também confirma a deficiência do método MaxVer em gerar os parâmetros adequados durante a fase de treinamento, quando há limitação no tamanho das amostras de treinamento.

Na classificação pelo MaxVer, obteve-se melhores índices *kappa* e de exatidão global para o interpolador PTS, para as três metodologias de Refer_1, Refer_2 e Refer_3, em relação ao interpolador COL (Tabela 13). A superioridade verificada pelo MaxVer utilizando o interpolador PTS deve-se ao fato de haver menos coeficientes utilizados como variáveis discriminantes no processo de classificação. Portanto, há que se ter muito cuidado quando o número de amostras for consideravelmente reduzido em relação ao número de variáveis discriminatórias.

Notou-se um melhor desempenho do classificador RNA usando o interpolador COL em relação ao PTS, para as metodologias Refer_2, provavelmente devido às características não-paramétricas desse classificador (Tabela 13). Uma das vantagens da RNA é justamente a possibilidade de se obter um bom resultado com poucas amostras de

treinamento. Uma característica importante no desempenho deste classificador é a definição da arquitetura da rede, pois redes menores generalizam melhor.

No caso da metodologia Refer_3, esperavam-se melhores resultados em comparação com a metodologia Refer_2. O que não ocorreu para nenhum dos interpoladores, COL e PTS, com o algoritmo MaxVer, possivelmente deve-se ao fato das amostras presentes nesta imagem de referência não seguirem a distribuição multinormal (tem-se como premissa do classificador MaxVer para imagens de sensoriamento remoto: a maioria das feições segue distribuição multinormal).

Problema de “*pixels de mistura*” ocorre em imagens de Sensoriamento Remoto, devido à resolução espacial dos sensores, onde um elemento da cena (correspondente a um *pixel* da imagem) inclui mais de um tipo de cobertura do terreno. Esse problema observado no processo de classificação, deve-se a resolução espacial das imagens MODIS (250 m) utilizadas nesta dissertação. Foi observado que este tipo de problema ocorre principalmente nas fronteiras entre os diferentes alvos, como por exemplo, na fronteira entre cana-de-açúcar e pasto.

A imagem temática que serviu de base para a geração da imagem de referência Reamostrada, Refer_1, foi feita uma classificação supervisionada (segmentação com a posterior utilização do algoritmo ISOSEG) seguida de uma interpretação visual. Nessa classificação realizou-se apenas uma avaliação qualitativa, não foi quantificado o erro agregado, avaliação quantitativa. Assim, não foi possível verificar o erro agregado antes da classificação pela metodologia Refer_1.

Tabela 13: Índices derivados da matriz de confusão.

		MaxVer		RNA		
		PTS	COL	PTS	COL	
Metodologia	Refer_1	Global(%)	45,5	31,2	51,5	46,8
		<i>Kappa</i>	0,364	0,197	0,434	0,379
		Variância	0,001329	0,001204	0,001471	0,001268
	Refer_2	Global(%)	63,8	42,0	54,9	64,7
		<i>Kappa</i>	0,578	0,323	0,474	0,589
		Variância	0,001338	0,001288	0,001460	0,001360
	Refer_3	Global(%)	60,3	40,6	62,9	59,8
		<i>Kappa</i>	0,536	0,307	0,568	0,531
		Variância	0,001401	0,001313	0,001370	0,001425

Uma vez que o coeficiente *Kappa* quantifica o desempenho do classificador em relação à imagem de referência, foi empregado para avaliar os interpoladores (COL e PTS) e as metodologias de obtenção da imagem de referência (Refer_1, Refer_2 e Refer_3). Tal comparação pôde ser feita através da elaboração de uma matriz de significância para os classificadores a um nível de confiança de 95% (valor crítico de Z igual a 1,96) com os coeficientes de exatidão global e *Kappa*, variando o interpolador (Tabela 14).

Analisando a Tabela 15, a melhor performance do índice *Kappa* foi obtida pelo interpolador COL, utilizando o classificador RNA e a partir da imagem de referência Refer_2, como descrito anteriormente. Ao interpolar as superfícies o COL possui mais variáveis discriminantes em comparação com PTS, deste modo utilizando o classificador RNA foram obtidos melhores resultados. Utilizando o classificador MaxVer, foi verificado um pior desempenho utilizando o COL, representando que esses coeficientes possivelmente não seguem a distribuição normal ou as amostras de treinamento não são suficientes para gerar os parâmetros aceitáveis para esse classificador obter uma razoável exatidão.

Tabela 14: Avaliação do desempenho dos classificadores por interpolador e por metodologia de obtenção da imagem de referência através dos resultados dos coeficientes *Kappa*, onde: C (COL), P (PTS), A (RNA), M (MaxVer), R (Refer_1), D (Refer_2) e O (Refer_3) a um nível de confiança de 95% ($Z = 1,96$).

CLASS	DAC	DMP	OAP	OMP	OAC	DAP	RAP	RAC	RMP	DMC	OMC	RMC
KAPPA	0,589	0,578	0,568	0,536	0,531	0,474	0,434	0,379	0,364	0,323	0,307	0,197
VAR	0,001360	0,001338	0,0013070	0,001401	0,001425	0,001460	0,001471	0,001268	0,001329	0,001288	0,001313	0,001204
DAC	15,972											
DMP	0,212	15,802										
OAP	0,402	0,192	15,346									
OMP	1,009	0,803	0,608	14,320								
OAC	1,099	0,894	0,700	0,094	14,067							
DAP	2,166	1,966	1,767	1,159	1,061	12,405						
RAP	2,913	2,717	2,514	1,903	1,802	0,739	11,316					
RAC	4,096	3,898	3,680	3,039	2,929	1,819	1,051	10,643				
RMP	4,339	4,144	3,927	3,292	3,182	2,083	1,323	0,294	9,985			
DMC	5,169	4,976	4,752	4,108	3,993	2,881	2,113	1,108	0,801	9,000		
OMC	5,454	5,263	5,039	4,396	4,281	3,171	2,407	1,417	1,109	0,314	8,472	
RMC	7,742	7,557	7,313	6,642	6,514	5,367	4,582	3,661	3,318	2,524	2,193	5,677

Legenda: Indica haver diferença estatística significativa entre os classificadores ($>1,96$).

A metodologia Refer_2, com o interpolador COL e algoritmo RNA, apresentou o melhor resultado de todas as metodologias de classificação. Assim, optou-se por mostrar a sua matriz de confusão (Tabela 16) e a imagem temática do processo de classificação (Figura 14). As matrizes de confusão para as outras metodologias estão no Anexo B, com suas respectivas imagens temáticas no Anexo C.

Tabela 15: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador COL e algoritmo RNA.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	26	0	0	0	1	0	7	34	76,5	
2	3	25	4	0	4	2	8	46	54,3	
3	0	2	17	1	0	0	0	20	85,0	
4	0	4	0	26	0	2	5	37	70,3	
5	0	0	7	2	27	2	0	38	71,1	
6	0	0	0	3	0	14	2	19	73,7	
7	3	1	4	0	0	12	10	30	33,3	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	81,3	78,1	53,1	81,3	84,4	43,8	31,3			
Exatidão Global = 64,7; $kappa = 0,589$; $Var = 0,001360$; $Z_{calculado} = 15,958$; $Z_{tabelado} = 1,96$.										

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

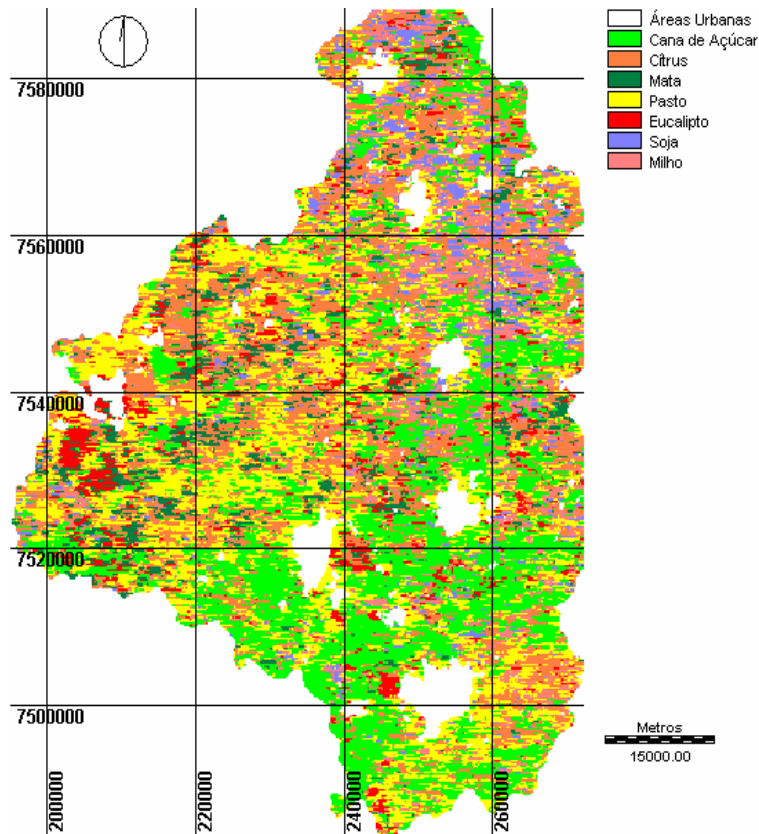


Figura 14: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador COL e algoritmo RNA, de acordo com o limite as EDR Limeira.

4.3 Seleção de Atributos

O resultado do algoritmo Seleção de Atributos Aditiva (SAA) utilizou-se o índice *kappa* como medida de exatidão, sendo nível de confiança de 95% com valor crítico tabelado de $Z_{\alpha/2}$ igual a 1,96. Esse método foi aplicado para testar a ordem dos coeficientes, buscando-se obter um custo computacional menor com a exatidão aceitável. Os resultados do SAA podem ser observados para o interpolador PTS na Figura 15, para as seguintes metodologias: Reamostragem (Refer_1), Digitalização em tela (Refer_2) e Operação de vizinhança (Refer_3). Já os resultados do SAA para o interpolador COL podem ser notados na Figura 16, para as seguintes metodologias Reamostragem, Digitalização em tela e Operação de vizinhança. A precisão global e o coeficiente *kappa* são mostrados para cada metodologia, variando interpolador PTS e COL, utilizado o algoritmo MaxVer, nas Tabelas 15, 16 e 17.

Observando-se a Figura 15, para o interpolador PTS, percebe-se que a exatidão começou relativamente baixa e a partir de certo número de coeficientes adicionados foi aumentando, mas para a metodologia Refer_3 ocorreu um leve decréscimo na exatidão. Na Figura 16, para o interpolador COL, foi observado que a exatidão começou relativamente baixa e a partir de certo número de coeficientes adicionados foi aumentando, até que certo número de coeficiente houve um decréscimo no valor do *kappa*.

Assim, encontrou-se certo limite para os coeficientes com a exatidão aproximadamente constante ou até com uma redução na exatidão, usando uma determinada sucessão. Isto deve-se ao efeito de *Hughes* (seção 3.4.3), que a medida que aumenta o número de coeficientes ocorre uma redução na precisão do índice *kappa*. A ordem correta com os valores do coeficiente *Kappa*, para cada metodologia (Refer_1, Refer_2 e Refer_3), dos coeficientes PTS e COL observam-se na Tabelas 15, 16 e 17.

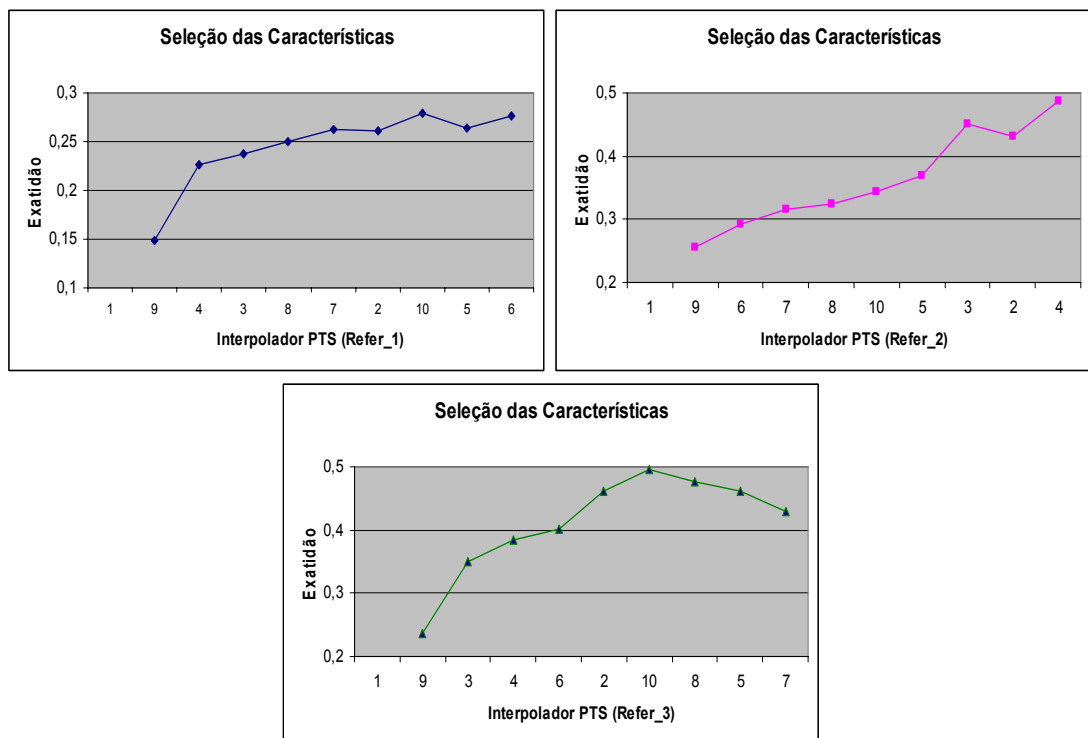


Figura 15: Seleção das Características, coeficientes PTS, para as metodologias Refer_1, Refer_2 e Refer_3.






Figura 16: Seleção das Características, coeficientes COL, para as metodologias Refer_1, Refer_2 e Refer_3.

As Tabelas 16, 17 e 18 apresentam os resultados da análise do *kappa* para cada metodologia, Refer_1, Rfer_2 e Refer_3, respectivamente. Compara-se o valor de *kappa* para cada metodologia de classificação com o coeficiente *kappa* de cada combinação de coeficientes. Checar se eles são significativamente diferentes ($Z_{\text{calc}} > 1,96$), por exemplo, usa o *kappa* e a variância do *kappa* da classificação com todos os coeficientes originais (10 PTS e 60 COL) com o *kappa* e a variância do *kappa* da classificação de cada iteração da variação de coeficiente (Tabelas 15, 16 e 17). Essa verificação utiliza a Equação 18, seção 2.2.3.

Para a metodologia de Reamostragem (Tabela 16), observa-se que para o teste aplicado entre um subconjunto de coeficientes originais, 10 PTS e 60 COL, mostra que usando a sucessão de característica [1, 9, 4, 3, 8, 7] para PTS e [1, 59, 43] para os coeficientes de COL, os resultados estão significativamente diferentes para o nível de confiança de 95%.

Para a metodologia de Digitalização em tela (Tabela 17), observa-se que para o teste aplicado entre um subconjunto de coeficientes originais, 10 PTS e 60 COL, mostram que usando a sucessão de característica [1, 9, 6, 7, 8, 10, 5, 3, 2, 4] para PTS e [1, 58, 39, 33, 23] para os coeficientes de COL, os resultados estão significativamente diferentes para o nível de confiança de 95%.

Para a metodologia de Operação de vizinhança (Tabela 18), observa-se que para o teste aplicado entre um subconjunto de coeficientes originais, 10 PTS e 60 COL, mostram que usando a sucessão de característica [1, 9, 3, 4, 6, 2] para PTS e [1, 30, 49, 58] para os coeficientes de COL, os resultados estão significativamente diferentes para o nível de confiança de 95%.

Complementado esta análise, verifica-se que usando mais que estas sucessões de características (coeficientes) encontram-se resultados aproximadamente iguais nas classificações. Desta forma, usando a seqüência dada pelo método SAA, reduzem as exigências computacionais quando se tem um número de características reduzidas, sem perder muita informação dos dados e mantendo a precisão da classificação.

Os valores foram comparados para verificar se são significativamente diferentes Z_{calc} , com o valor de *kappa* e variância do *kappa* para classificação original, 0,364 e 0,001329 para o interpolador PTS, 0,197 e 0,001204 para o interpolador COL. O valor crítico de $Z = 1,96$ ao nível de significância de 95%.

Tabela 16: Seleção de Atributos para metodologia Refer. 1, para cada interpolador PTS e COL.

Interpolador PTS				Interpolador COL											
Coeficiente	<i>Kappa</i>	Variância	Z_{calc}	Coeficiente	<i>Kappa</i>	Variância	Z_{calc}	Coeficiente	<i>Kappa</i>	Variância	Z_{calc}	Coeficiente	<i>Kappa</i>	Variância	Z_{calc}
	1					1					4		0,279	0,001766	1,50
9	0,148	0,001069	4,41	59	0,070	0,000877	2,78	5	0,274	0,001802	1,40	27	0,203	0,001708	0,11
4	0,227	0,001350	2,65	43	0,129	0,001051	1,43	54	0,276	0,001718	1,46	6	0,203	0,001722	0,11
3	0,238	0,001678	2,30	2	0,152	0,001007	0,96	22	0,282	0,001773	1,56	8	0,197	0,001618	0,00
8	0,250	0,001840	2,03	34	0,176	0,001008	0,45	37	0,271	0,001730	1,37	49	0,194	0,001596	0,06
7	0,263	0,001646	1,85	19	0,175	0,001050	0,46	25	0,268	0,001654	1,33	12	0,179	0,001574	0,34
2	0,261	0,001624	1,90	14	0,180	0,001055	0,36	18	0,272	0,001712	1,39	60	0,171	0,001464	0,50
10	0,279	0,001771	1,53	3	0,203	0,001253	0,12	38	0,276	0,001677	1,47	32	0,174	0,001424	0,45
5	0,264	0,001821	1,78	21	0,218	0,001402	0,41	58	0,279	0,001589	1,55	55	0,162	0,001366	0,69
6	0,277	0,001794	1,56	24	0,217	0,001334	0,40	48	0,266	0,001601	1,30	56	0,189	0,001427	0,16
				7	0,227	0,001597	0,57	52	0,253	0,001538	1,07	30	0,187	0,001460	0,19
				15	0,252	0,001757	1,01	57	0,258	0,001474	1,18	39	0,170	0,001412	0,53
				47	0,248	0,001695	0,95	40	0,260	0,001609	1,19	31	0,171	0,001458	0,50
				28	0,247	0,001645	0,94	26	0,250	0,001641	0,99	23	0,172	0,001438	0,49
				51	0,266	0,001673	1,29	42	0,258	0,001623	1,15	45	0,168	0,001399	0,57
				11	0,264	0,001679	1,25	50	0,249	0,001534	0,99	13	0,169	0,001534	0,54
				44	0,272	0,001726	1,39	9	0,238	0,001590	0,78	17	0,157	0,001402	0,78
				53	0,265	0,001711	1,26	35	0,240	0,001598	0,81	29	0,145	0,001509	1,00
				36	0,287	0,001729	1,66	16	0,236	0,001649	0,73	41	0,102	0,001347	1,88
				10	0,280	0,001778	1,52	20	0,220	0,001636	0,43	33	0,127	0,001434	1,36

Os valores são comparados para verificar se são significativamente diferentes Z_{calc} , com o valor de *kappa* e variância do *kappa* para classificação original, 0,589 e 0,001360 para o interpolador PTS, 0,323 e 0,001288 para o interpolador COL. O valor crítico de $Z = 1,96$ ao nível de significância de 95%.

Tabela 17: Seleção de Atributos para metodologia Refer_2, para cada interpolador PTS e COL.

Interpolador PTS				Interpolador COL											
Coeficiente	<i>Kappa</i>	Variância	Z_{calc}	Coeficiente	<i>Kappa</i>	Variância	Z_{calc}	Coeficiente	<i>Kappa</i>	Variância	Z_{calc}	Coeficiente	<i>Kappa</i>	Variância	Z_{calc}
	1					1					12		0,363	0,002466	0,67
9	0,255	0,002386	5,29	58	0,117	0,002010	3,59	27	0,364	0,002463	0,67	3	0,288	0,002142	0,60
6	0,292	0,002188	4,82	39	0,171	0,001791	2,74	25	0,362	0,002470	0,64	45	0,286	0,002245	0,63
7	0,316	0,002129	4,45	33	0,203	0,001707	2,19	44	0,362	0,002503	0,64	11	0,290	0,002057	0,56
8	0,325	0,002084	4,32	23	0,255	0,002905	1,05	52	0,360	0,002538	0,60	47	0,276	0,002189	0,81
10	0,344	0,002412	3,82	8	0,262	0,002533	0,99	38	0,366	0,002465	0,70	16	0,290	0,002295	0,56
5	0,370	0,002529	3,34	10	0,315	0,002745	0,13	35	0,365	0,002412	0,69	18	0,305	0,002336	0,30
3	0,450	0,002662	2,02	4	0,330	0,002652	0,11	32	0,388	0,002470	1,07	29	0,290	0,002229	0,55
2	0,431	0,002505	2,37	7	0,321	0,002844	0,03	22	0,367	0,002632	0,72	41	0,287	0,002126	0,61
4	0,487	0,002492	1,47	13	0,329	0,002711	0,09	2	0,351	0,002559	0,45	55	0,268	0,002225	0,94
				17	0,343	0,002175	0,34	56	0,349	0,002336	0,42	31	0,269	0,002252	0,91
				14	0,355	0,002403	0,53	46	0,344	0,002192	0,35	40	0,256	0,002090	1,13
				59	0,371	0,002196	0,81	28	0,342	0,002220	0,32	54	0,243	0,002075	1,38
				37	0,382	0,002705	0,93	30	0,341	0,002245	0,30	51	0,235	0,002144	1,52
				21	0,396	0,002701	1,16	26	0,333	0,002063	0,17	20	0,246	0,001901	1,31
				15	0,379	0,002777	0,88	48	0,325	0,002078	0,03	5	0,244	0,001838	1,40
				19	0,379	0,002929	0,86	50	0,310	0,002022	0,22	36	0,247	0,001835	1,36
				60	0,373	0,002765	0,79	24	0,312	0,002052	0,19	53	0,241	0,001825	1,47
				57	0,386	0,002679	1,00	42	0,307	0,001936	0,28	34	0,253	0,001722	1,25
				6	0,375	0,002558	0,84	49	0,301	0,001965	0,39	9	0,239	0,002096	1,53

Os valores são comparados para verificar se são significativamente diferentes Z_{calc} , com o valor de *kappa* e variância do *kappa* para classificação original, 0,536 e 0,001401 para o interpolador PTS, 0,307 e 0,001313 para o interpolador COL. O valor crítico de $Z = 1,96$ ao nível de significância de 95%.

Tabela 18: Seleção de Atributos para metodologia Refer. 3, para cada interpolador PTS e COL.

Interpolador PTS				Interpolador COL												
	<i>Kappa</i>	Variância	Z_{calc}		<i>Kappa</i>	Variância	Z_{calc}		<i>Kappa</i>	Variância	Z_{calc}		<i>Kappa</i>	Variância	Z_{calc}	
Coeficiente	1			1				17	0,325	0,002313	0,30	6	0,259	0,002178	0,81	
	9	0,237	0,001987	5,14	30	0,182	0,001591	2,32	57	0,315	0,002295	0,13	55	0,268	0,002174	0,66
	3	0,349	0,002543	2,98	49	0,181	0,001818	2,25	31	0,319	0,002253	0,20	56	0,249	0,002313	0,96
	4	0,385	0,002640	2,38	58	0,172	0,017220	0,99	41	0,316	0,002335	0,15	60	0,269	0,002267	0,64
	6	0,402	0,002768	2,08	24	0,21	0,002303	1,61	52	0,305	0,002534	0,03	28	0,257	0,002187	0,85
	2	0,462	0,002831	1,14	14	0,213	0,002432	1,54	59	0,303	0,002370	0,07	19	0,259	0,002269	0,80
	10	0,495	0,002757	0,64	2	0,245	0,002750	0,97	40	0,301	0,002551	0,10	50	0,257	0,002250	0,84
	8	0,476	0,003328	0,87	25	0,267	0,002697	0,63	13	0,292	0,002247	0,25	33	0,239	0,002097	1,16
	5	0,462	0,003027	1,11	18	0,267	0,002704	0,63	22	0,288	0,002368	0,31	32	0,244	0,001967	1,10
	7	0,429	0,002954	1,62	34	0,284	0,002631	0,37	8	0,28	0,002273	0,45	29	0,244	0,002168	1,07
Coeficiente				20	0,299	0,002513	0,13	26	0,287	0,002495	0,32	47	0,239	0,002310	1,13	
				4	0,317	0,002656	0,16	5	0,286	0,002594	0,34	45	0,243	0,002238	1,07	
				46	0,318	0,002687	0,17	51	0,29	0,002582	0,27	12	0,24	0,002187	1,13	
				48	0,327	0,002638	0,32	42	0,282	0,002432	0,41	11	0,231	0,002105	1,30	
				37	0,317	0,002497	0,16	9	0,295	0,002516	0,19	27	0,229	0,002150	1,33	
				38	0,309	0,002496	0,03	35	0,296	0,002708	0,17	15	0,239	0,002013	1,18	
				23	0,319	0,002813	0,19	44	0,292	0,002541	0,24	16	0,241	0,002359	1,09	
				53	0,311	0,002779	0,06	36	0,273	0,002471	0,55	3	0,226	0,002219	1,36	
				21	0,313	0,002814	0,09	10	0,272	0,002309	0,58	39	0,224	0,002272	1,39	
				43	0,308	0,002580	0,02	54	0,263	0,002332	0,73	7	0,202	0,002105	1,80	

5 -CONCLUSÕES

Uma metodologia que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*), foi utilizada para classificar com sucesso extensas áreas de culturas agrícolas numa região de Limeira.

Em estudos que utilizam dados multitemporais são necessários diversos procedimentos adicionais, etapas de pré-processamento das imagens (ex. correção geométrica e correção radiométrica das imagens). Entretanto, o projeto dos sensores MODIS permitiu que estes processamentos fossem abstraídos da metodologia, considerando qualidades radiométrica e geométrica destas imagens.

A abordagem multitemporal e multiespectral produziu resultados significativamente mais exatos do que a abordagem multiespectral, para realizar a classificação de culturas agrícolas em imagens de sensoriamento remoto. Esta análise foi comparada com os resultados da classificação usando o algoritmo MaxVer, para as metodologias Digitalização de polígonos homogêneos e Operação de vizinhança.

A eficiência da metodologia de aquisição das imagens de referência é promissora, tanto para a Digitalização de polígonos homogêneos em tela quanto para a metodologia de Operação de vizinhança.

A análise dos resultados permite concluir que as duas metodologias, de Digitalização de polígonos homogêneos em tela e a metodologia de Operação de vizinhança apresentaram melhores desempenhos na classificação do que a metodologia de Reamostragem das imagens temáticas (ETM 7) reamostradas de 30 para 250 metros, tanto para os dados interpolados pelo método *Collocation* quanto pelo método PTS e para ambos classificadores MaxVer e RNA.

O classificador RNA utilizando o interpolador *Collocation* apresentou o melhor desempenho, seguido pelo classificador MaxVer utilizando o interpolador PTS. Ambas as classificações não apresentaram diferenças significativas ao nível de 95% de confiança. O classificador RNA no geral apresentou grande eficiência, proporcionando melhores resultados mesmo com uma pequena quantidade de dados de amostra para treinamento.

Os resultados encontrados mostraram a viabilidade em se utilizar o método de Seleção de Atributos Aditiva (SAA), quando o objetivo é a redução no número de coeficientes, principalmente quando se trata do interpolador *Collocation*, sem que haja perda no processo de classificação. Com o emprego do índice *kappa* no método SAA, observou-se que com um número reduzido de coeficientes, podem-se obter resultados estatisticamente similares.

Considerando as dificuldades para obter um número significativo de amostras para treinamento e validação, devendo-se ao fato da resolução das imagens MODIS, sugere-se a repetição desses experimentos para uma amostragem compatível com o número de variáveis discriminantes (30 x número de coeficientes x número de classes informacionais).

O relevo, em alguns casos, torna-se uma variável importante para classificação de culturas. Assim, propõe-se a utilização de atributos do terreno derivados de um modelo digital de elevação (MDE) para auxiliar na melhora da precisão da classificação.

Sugere-se também, uso de uma classificação contextual antes da classificação multitemporal propriamente dita, onde se eliminaria as áreas com classes informacionais diferentes (ex. estradas, área urbana, etc...) daquelas 7 classes usadas na classificação temporal.

Referências Bibliográficas

Adami, M. 2003. **Estimativas de Áreas Agrícolas por meio de Técnica de sensoriamento Remoto, Geoprocessamento e Amostragem**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-10235-TDI/900). 185 pp.

Anderson, L. O. 2005. **Classificação e Monitoramento da Cobertura Vegetal do Estado do Mato Grosso Utilizando dados Multitemporais do Sensor MODIS**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-12290-TDI/986). 249 pp.

Apan, A. & Potgieter, A. 2002. **Using satellite imagery in determining winter crop area planted in support of regional commodity forecasting: a case study of the Darling Downs, Queensland**. Toowoomba, Australia: Faculty of Engineering and Surveying, University of Southern Queensland. 31 pp. Disponível em 20/01/2006: <http://www.usq.edu.au/users/apana/cropforecasting_finalreport.pdf>

Arce, E. C. Rudorff, B. F. T. Berka, L. M. S; Pereira, P. F. C. 2005. Imágenes Landsat y CBERS en la identificación del uso del suelo con cultivos agrícolas. *In*: Simpósio Brasileiro de Sensoriamento Remoto, 12. **Anais**. Goiânia. 41-48 pp.

Atkinson, P. M. & Tatnall, A. R. L. 1997. Neural networks in remote sensing. **International Journal of Remote Sensing**, vol. 18, n. 4. 699-709 pp.

Baban, S. M. J. & Luke, C. 2000. Mapping agricultural land use using retrospective ground referenced data, satellite sensor imagery and GIS. **International Journal Remote Sensing**, vol. 21, n. 8, 1757-1762 pp.

Benediktsson, J. A. & Sveinsson, J. R. 1997. Feature extraction for multisource data classification with artificial neural networks. **International Journal of Remote Sensing**, vol. 18, n. 4, 727-740 pp.

Braga, A. L. Countinho, G. F. Vieira, C. A. O. 2005. Avaliar a Potencialidade do Uso de Imagens MODIS para fins de Atualização Cartográfica. *In*: Congresso Brasileiro de Cartografia, 20. **Anais**. Macaé. 7 pp.

Camargo, E. C. G. Druck, S. Câmara, G. 2004. Análise Espacial de Superfícies. *In*: Druk, S. Carvalho, M. S. Câmara, G. M. A. M. V. **Análise espacial de dados geográficos**. Brasília: Embrapa Cerrados. 209 pp.

Carvalho, A. P. L. F. 2006. **Redes neurais artificiais**. Disponível em 6/06/2006: <<http://www.icmc.sc.usp.br/~andre/>>.

Centeno, J. A. S. 2004. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: Ed. Curso de Pós Graduação em Ciências Geodésicas, Universidade Federal do Paraná - UFPR. 219 pp.

Chagas, C. S. 2006. **Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de mar de morros**. Viçosa: Tese de Doutorado em Solos e Nutrição de Plantas, Universidade Federal de Viçosa. 223 pp.

Comissão de Cartografia (COCAR). 1986. **Cartografia e Aerolevantamento: Legislação**. Brasília, Ministério da Ciência e Tecnologia.

Cochran, W.G. 1977. **Sampling Techniques**. New York: John Wiley & Sons, 3 Ed. 428 pp.

Companhia Nacional de Abastecimento, CONAB, 2006. **Safras**. Disponível em 12/06/2006: <<http://www.conab.gov.br>>.

Congalton, R. G. & Green, K. 1999. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. New York: Lewis Publishers. 137 pp.

Costa, T. C. C. Marco Júnior, P. Brites, R. S. 2005. Classificação do Uso/Cobertura da Terra por Meio de Algoritmos não Paramétricos comparados ao Classificador de Máxima Verossimilhança. **Boletim Paranaense de Geociências**, n. 56, p. 65-87 pp.

Epiphânio, J. C. N. Luiz, A. J. B. Formaggio, A. R. 2002. Estimativa de Áreas Agrícolas Municipais utilizando Sistema de Amostragem Simples sobre Imagens de Satélite. **Bragantia**, Campinas, vol. 61, n. 2, 187-197 pp.

Figueiredo, D. C. 2005. Projeto GeoSafras Sistema de Previsão de Safras da Conab. **Revista Política Agrícola**, Brasília, ano XIV, n 2, 110-120 pp.

Fang, H. Wu, B. Liu, H. Huang, X. 1998. Using NOAA AVHRR and Landsat TM to estimate rice area year-by-year. **International Journal Remote Sensing**, vol. 19, n. 3, 521-525 pp.

Fontana, D. C. Weber, E. Ducati, J. Figueiredo, D. C. Berlato, M. A. 2000. Bergamaschi, H. A case study for crop monitoring and harvest forecast in south Brazil. *In: International Symposium on Remote Sensing of Environment*, 28. **Cape Town. Proceedings**. 91-94 pp.

Foody, G. M. Arora, M. K. 1997. An evaluation of some factors affecting the accuracy of classification by an artificial neural network. **International Journal Remote Sensing**, vol. 18, n. 4, 799-810 pp.

Foody, G. M. 2002. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, vol. 80, 185-201 pp.

Formagio, A. R. & Epiphanyo, J. C. N. 1990. **Características espectrais de culturas agrícolas e rendimento agrícola**. São José dos Campos: Relatório Técnico INPE (INPE-5125-RPE/630). 166 pp.

Formaggio, A. R. Martins, S. P. Gurtler, S. Campos, R. C. Fiorio, P. R. Lemos, C. 2005. Avaliação de dados MODIS 250m para áreas de agricultura intensa. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 12. **Anais**. Goiânia. 135-142 pp.

Galparsoro, I. L. U. & Fernández, S. P. 1999. **Medidas de Concordancia: el Índice Kappa**. A Coruña - Espana: Unidad de Epidemiología Clínica y Bioestadística - Cad Aten Primaria. 169-171 pp. Disponível em 25/10/2006: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>.

Ganan, J. R. Rocha, J. V. Mercante, E. Antunes, J. F. G. 2005. Mapeamento da cultura da soja com imagens Landsat 5/TM utilizando algoritmos de classificação supervisionada. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 12. **Anais**. Goiânia. 549-555 pp.

Gleriani, J. M. 2005. **Redes Neurais Artificiais para Classificação Espectro-Temporal de Culturas Agrícolas**. São José dos Campos: Tese de Doutorado em Sensoriamento Remoto - INPE (INPE-12908-TDI/1011). 212 pp.

González-Alonso, F. Cuevas, J. M. Arbiol, R. Baulies, X. 1997. Remote sensing and agricultural statistics: crop area estimation in north-eastern Spain through diachronic Landsat TM and ground sample data. **International Journal of Remote Sensing**, vol. 18, n. 2, 467-470 pp.

Guerschman, J. P. Paruelo, J. M. Di Bella, C. Giallorenzi, M. C. Pacin, F. 2003. Land cover classification in the Argentine Pampas using multi-temporal Landsat TM data. **International Journal Remote Sensing**, vol. 24, n. 17, 3381-3402 pp.

Gürtler, S. 2003. **Estimativa de Área Agrícola a partir de Sensoriamento Remoto e Banco de Dados de Pixels Amostrais**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-9774-TDI/858). 181 pp.

Haykin, S. 2001. **Redes Neurais : princípios e práticas**. Porto Alegre, Brasil: Bookman, 2ed. 900 pp.

Hirose, Y. Yamashita, K. Hijiya, S. 1991. Back-propagation algorithm which varies the number of hidden units. **Neural Networks**, vol. 4, 61-66 pp.

Hornik, K. R. 2003. **Development Core Team: A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing (ISBN 3-900051-00-3).

Hudson, W. D. & Ramm, C. W. 1987. Correct formulation of the Kappa coefficient of agreement. **Photogrammetric Engineering and Remote Sensing**, vol. 53, 421-422 pp.

Huete, A. Didan, K. Miura, T. Rodriguez, E. P. Gao, X. Ferreira, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, vol.83, 195-213 pp.

Instituto Brasileiro de Geografia e Estatística - IBGE. 1991. **Produção Agrícola Municipal 1990: culturas temporárias e permanentes**. São Paulo: Superintendência de estudos geográficos e sócio-econômicos/IBGE, Produção Agrícola Municipal. 40 pp.

_____. 2002. **Pesquisas Agropecuárias**. Rio de Janeiro: Superintendência de estudos geográficos e sócio-econômicos/IBGE, 2ª Ed, Série Relatórios Metodológicos, n. 6. 96 pp.

_____. 2006. **Notícia em 17/07/2006**. IBGE. Disponível em: 24/07/2006.
<http://www.ibge.com.br/home/presidencia/noticias/noticia_visualiza.php?id_noticia=646&id_pagina=1>

Ippoliti-Ramilo, G. A. 1999. **Imagens Tm/Landsat-5 da Época de Pré-Plantio para a Previsão da Área de Culturas de Verão**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-7116-TDI/668). 185 pp.

Jain, A. K. Mao, J. Mohiuddin, K. 1996. Artificial Neural Networks: A Tutorial. **Institute of Electrical and Electronics Engineers (IEEE) Computer**, vol.29, n.3, 31-44 pp.

Jain, A. K. & Zongker, D. 1997. Feature-selection: evaluation, application, and small sample performance. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, vol.19, n.2, 152-157 pp.

Jonathan, M. 2005. **Classificação do Uso e Cobertura do Solo em Escala Regional a partir de Seqüências Temporais de Dados MODIS**. Rio de Janeiro: Dissertação de Mestrado em Geomática - UERJ. 142 pp.

Justice, C. O. Townshend, J.R.G. Vermote, E.F. Masuoka, E. Wolfe, R.E. Saleous, N. Roy, D.P. Morisette, J.T. 2002. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, vol. 83, 3-15 pp.

Kanellopoulos, I. & Wilkinson, G. G. 1997. Strategies and best practice for neural network image classification. **International Journal of Remote Sensing**, vol. 18, n. 4, 711-725 pp.

Kastens, J. H. Kastens, T. L. Kastens, D. L. A. Price, K. P. Martinko, E. A. Lee, R. 2005. Image masking for crop yield forecasting using AVHRR NDVI time series imagery. **Remote Sensing of Environment**, v. 99, 341 - 356 pp.

Kavzoglu, T.; Mather, P. M. The use of backpropagation artificial neural networks in land cover classification. 2003. **International Journal of Remote Sensing**, vol. 24, n.13, 4907-4938 pp.

Lillesand, T. M. & Kiefer, R. W. 1999. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 4 Ed. 724 pp.

Lipmann, R. P. 1987. An introduction to computing with neural nets. **IEEE ASSP Magazine**, vol. 4, n. 2, 4-22 pp.

Luiz, A. J. B. **Sensoriamento remoto agrícola**. 2002. São José dos Campos: Trabalho realizado como parte das exigências do exame de qualificação do curso de Doutorado em Sensoriamento Remoto, INPE (INPE-88586-PUD/111). 102 pp.

Mather, P. M. 1999. **Computer processing of remotely-sensed images: An introduction**. Chichester: John Wiley & Sons, 2 Ed. 292 pp.

Medeiros, A. M. P. Rudorff, B. F. T. Shimabukuro, Y. E. 1996. Imagens Landsat na Estimativa de Áreas de Cana-de-Açúcar, Milho e Soja. *In*: Simpósio Brasileiro de Sensoriamento Remoto, 8. **Anais**. Salvador. 33-37 pp.

Merchant, D. C. 1982. Spatial Accuracy Standards for Large Scale Line Maps. **Technical Congress on Surveying and Mapping Proceedings**, v. 1, 222-231 pp.

Moreira, M. A. 2003. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Viçosa: Universidade Federal de Viçosa - UFV, 2ª Ed. 250 pp.

Motta, J. L. G. Fontana, D. C. Weber, E. 2001. Comparação de áreas estimadas por classificação digital e áreas medidas com GPS em lavouras

de soja. *In*: Congresso Brasileiro de Cartografia - CBC, 20. **Anais**. Porto Alegre. 6 pp.

Moura, V. 2000. **Imagens Multitemporais TM/Landsat-5 da Época de Pré-Plantio na Estimativa de Áreas Destinadas a Culturas de Verão**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-7527-TDI/734). 117 pp.

Murakami, T. Ogawa, S. Ishitsuka, N. Kumagai, K. Saito, G. 2001. Crop discrimination with multitemporal SPOT/HRV data in the Saga Plains, Japan. **International Journal of Remote Sensing**, vol. 22, n.7, 1335-1348 pp.

Murthy, C.S. Raju, P.V. Badrinath, K.V.S. 2003 Classification of wheat crop with multitemporal images: performance of maximum likelihood and artificial neural networks. **International Journal of Remote Sensing**, vol. 24, n. 23, 4871-4890 pp.

Noguchi, M. T. G. 2004. **Um Sistema Baseado em Regras Fuzzy para Classificação Supervisionada de Imagens Multiespectrais de Alta Resolução**. Curitiba: Dissertação de Mestrado em Informática - UFPR. 150 pp.

Novo, E. M. L. M. 1989. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Ed. Edgard Blucher. 308 pp.

Oliveira, J. A. 2005. **Classificação de regiões usando atributos de forma e seleção de atributos**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-13746-TDI/1050). 104 pp.

Ortiz, M. J. Formaggio, A. R. Epiphano, J. C. N. 1997 Classification of croplands through integration of remote sensing, GIS and historical database. **International Journal of Remote Sensing**, vol. 18, n. 1, 95-105 pp.

Otani, M. N. Maia, M. L. Mello, N. T. C. Franca, T. J. F. Francisco, V. L. F. S. 1998. Perfil agropecuário do escritório de Desenvolvimento Rural de Limeira. **Informações Econômicas**, São Paulo, vol. 28, n. 6, 25-43 pp.

Pax-Lenney, M. & Woodcock, C.E. 1997. Monitoring agricultural lands in Egypt with multitemporal Landsat TM imagery: how many images are needed? **Remote Sensing of Environment**, vol. 59, n. 3, 522-529 pp.

Picoli, M. C. A. Anjos, C. S. Rosa, V. G. C. Rizzi, R.; Rudorff, B. F. 2005. Estimativa de área com cana-de-açúcar na micro-região de Ribeirão Preto - SP por meio de amostragem por segmentos quadrados. *In*: Simpósio Brasileiro de Sensoriamento Remoto, 12. **Anais**. Goiânia. 213-215 pp.

Pino, F. A. 1999. Estatísticas agrícolas para o século XXI. **Agricultura em São Paulo**, vol. 46, n. 2, 71-105 pp.

Price, J. C. 2003. Comparing MODIS and ETM+ data for regional and global land classification. **Remote Sensing of Environment**, vol. 86, n. 4, 491-499 pp.

Rizzi, R. 2005. **Geotecnologias em um Sistema de Estimativa da Produção de Soja: Estudo de Caso no Rio Grande do Sul**. São José dos Campos: Tese de Doutorado em Sensoriamento Remoto - INPE (INPE-12271-TDI/983). 216 pp.

Rudorff, B. F. T. & Moreira, M. A. 2002. Sensoriamento remoto aplicado à agricultura. *In*: Curso de uso de sensoriamento remoto no estudo do meio ambiente. São José dos Campos: INPE (INPE-8984-PUD/62), **Cap. 9**. 19 pp. Disponível em 10/05/2006: <<http://mtc-m12.sid.inpe.br/rep-/sid.inpe.br/sergio/2005/06.14.13.14>>.

Sanches, I. D. A. 2004. **Sensoriamento Remoto para o Levantamento Espectro-Temporal e Estimativa de Área de Culturas Agrícolas**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (INPE-10290-TDI/909). 174 pp.

Sanches, I. D. A. Epiphany, J. C. Formaggio A. R. 2005. Culturas Agrícolas em Imagens Multitemporais do Satélite Landsat. **Agricultura em São Paulo**. vol. 52, n. 1, 83-96 pp.

Shao, Y. Fan, X. Liu, H. Xiao, J Ross, S. Brisco, B. Brown, R. Staples, G. 2001. Rice monitoring and production estimation using multitemporal RADARSAT. **Remote Sensing of Environment**, vol. 76, 310-325 pp.

Shimabukuro, Y. E. Duarte, D. Moreira, M. A. Arai, E. Rudorff, B. F. Andreson, L. O. Espírito Santo, F. D. B. Freitas, R. M. Aulicino, L. C. Maurano, L. E. P. Aragão, J. R. L. 2005. Detecção de Áreas Desflorestadas em Tempo Real: **Conceitos Básicos, Desenvolvimento e Aplicação do Projeto DETER**. São José dos Campos: Relatório Técnico INPE (INPE-12288-RPE/796). 63 pp. Disponível em 09/02/2006: <<http://www.obt.inpe.br/deter/metodologia.pdf>>

Schowengerdt, R. A. 1997. **Models and methods for image processing**. San Diego: Academic Press, 2 Ed. 522 pp.

Soares, D. M. 2006. **Áreas agrícolas em sensores com resolução espacial de 30 m estimadas a partir de dados originais e simulados MODIS e métricas da paisagem**. São José dos Campos: Dissertação de Mestrado em Sensoriamento Remoto - INPE (no prelo). 156 pp.

Tadjudin, S. 1998. **Classification of High Dimensional Data with Limited Training Samples**. Purdue: Thesis Doctor of Philosophy, School of Elec. And Comp. Eng., Purdue University. 123 pp.

Thomé, A. C. G. 2006. **Redes Neurais – Uma Ferramenta para KDD e Data Mining**. Apostila. Disponível em 10/06/2006: <http://equipe.nce.ufrj.br/thome/grad/nn/mat_didatico/apostila_kdd_mbi.pdf>.

Tortora, R. 1978. A note on sample size estimation for multinomial populations. **The American Statistician**, vol. 32, n. 3, 100-102 pp.

Tso, B., & Mather, P. M. 1999. Crop discrimination using multi-temporal SAR imagery. **International Journal of Remote Sensing**, vol. 20, n. 12, 2443-2460 pp.

Turker, M. & Arıkan, M. 2005. Sequential masking classification of multi-temporal Landsat7 ETM+ images for field-based crop mapping in Karacabey, Turkey. **International Journal Remote**, vol. 26, n. 17, 3813-3830 pp.

van Leeuwen, W. J. D. Huete, A. R. Laing, T. W. 1999. MODIS vegetation index compositing approach: A prototype with AVHRR data. **Remote Sensing of Environment**, vol. 69, 264-280 pp.

Vieira, C. A. O. 2000. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. Nottingham: Thesis Doctor of Philosophy, University of Nottingham. 327pp.

Vieira, C. A. O. Mather, P. M. Borges, P. A. F. 2002. Assessing the positional accuracy of remotely sensed products. Melbourne - Australia. *In*: 5th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences.

Vieira, C. A. O. & Mather, P. M., 2005. Techniques for Estimating the Positional and Thematic Accuracy of Remotely Sensed Products. *In*: Simpósio Brasileiro de Sensoriamento Remoto, 12. **Anais**. Goiânia. 4351-4359 pp.

Watson, D. F. 1996. **Contouring: A Guide to the Analysis and Display of Spatial Data**. Oxford: Pergamon Press.

Wilkie, D. S. & Finn J. T. 1996. **Remote sensing imagery for natural resources monitoring: a guide for first-time users**. Columbia University Press, 1^a ed. 295 pp.

Yi, J. L. R. 2005. **Dados do Sistema Sensor Modis-Terra Para Avaliação e Monitoramento de Áreas Agrícolas na Região Sul do Brasil**. São Paulo: Tese de Doutorado em Engenharia de Transportes - USP. 181 pp.

Xiao, X. Bolesa, S. Liub, J. Zhuangb, D. Frokinga, S. Lia, C. Salas, W. Moore III, B. 2005. Mapping paddy rice agriculture in southern China using multi-temporal MODIS images. **Remote Sensing of Environment**, vol. 95, 480-492 pp.

Zhan, X. Sohlberg, R. A. Townshend, J. R. G. DiMiceli, C. Carroll M. L. Eastman, J. C. Hansen, M. C. DeFries, R. S. 2002. Detection of land cover changes using MODIS 250 m data. **Remote Sensing of Environment**, vol. 83, 336-350 pp.

Zell, A. Mamier, G. Vogt, M. Mache, N. Hubner, R. Doring, S. Herrmann, K. Soyez, T. Schmalzl, M. Sommer, T. Hatzigeorgiou, A. Posselt, D. Schreiner, T. Kett, B. Clemente, G. Wieland, J. Gatter, J. 1996. **Stuttgart Neural Network Simulator v 4.2**. University of Stuttgart: Institute for Parallel and Distributed High Performance Systems/University of Tübingen - Wilhelm-Schickard-Institute for Computer Science - Department of Computer Architecture.

ANEXO A

QUALIDADE CARTOGRÁFICA

No Brasil, para avaliar a precisão posicional foi regulamentado o Padrão de Exatidão Cartográfica (PEC), conforme especifica o Decreto 89.817/84 (1984), que garante o controle e a qualidade dos produtos cartográficos. Neste Decreto-lei os artigos 8º a 11º, diz respeito ao PEC que é definido pelas normas de regulamentação e classificação de produtos cartográficos, tratando da classificação de uma carta quanto à sua exatidão (COCAR, 1986).

Na aplicação do PEC, referentes a dados planimétricos, para garantir a confiabilidade geométrica das cartas digitais devem-se comparar as coordenadas dos pontos facilmente identificados na imagem orbital (X_c , Y_c) com as coordenadas homólogas de referência (X_r , Y_r), coletados em carta ou em levantamento de campo, desde que possuam exatidão superior a 1/3 do erro padrão esperado para a classe da carta (Vieira et al., 2002).

Na coleta dos pontos de controle para realizar a verificação da qualidade posicional na imagem MODIS, utilizou-se pontos bem distribuídos e seus homólogos na imagem Landsat geometricamente corrigida (imagem de referência). Devido a baixa resolução espacial das imagens MODIS não foi possível utilizar cartas topográficas para coleta desses pontos de controle, pois não foi possível identificar feições homólogas na carta e na imagem. Assim, utilizou-se um documento cartográfico (carta imagem Landsat) na escala 1:400.000 para identificação dos pontos homólogos.

De posse das coordenadas podem-se avaliar as discrepâncias $(dx_i, dy_i) = (x_{ci} - x_{ri}, y_{ci} - y_{ri})$ e calcular as estatísticas das amostras (média, desvio padrão, erros máximo e mínimo). Com estas estatísticas amostrais foram realizados testes para avaliação de tendência e precisão (Vieira e Mather, 2005).

Segundo Merchant (1982), a análise estatística da acurácia planimétrica é composta por duas fases:

- a) a análise de tendências, com o objetivo de se averiguar a presença de erros sistemáticos; e,
 b) análise da exatidão.

A partir das análises das discrepâncias médias amostrais, aplica-se o teste de tendência, e, onde se essas discrepâncias forem estatisticamente iguais a zero, para dentro de certo nível de significância, admite-se a não existência de tendência.

Da comparação entre a variância das discrepâncias amostrais com os valores pré-estabelecidos no PEC, faz-se o teste de precisão. Estes testes são realizados a partir de testes de hipóteses sobre a média e o desvio padrão amostral das discrepâncias obtidas em cada uma das coordenadas planimétricas.

Segundo o decreto, a respeito do PEC nos artigos 8° a 11°, noventa por cento dos pontos testados não podem ter discrepâncias superiores ao padrão de exatidão planimétrica (PEP) e o desvio padrão deve ser menor ou igual ao erro padrão (EP).

Para a análise de tendência utilizou-se o Teste *t* de *Student*, observando um nível de confiança $(1-\alpha)$ igual a 90% ($\alpha = 0,10$) e com grau de liberdade $(n-1)$, onde n corresponde ao número de amostras coletadas. Se $t_{n-1,\alpha/2}$ calculado for inferior ao valor limite $t_{n-1,\alpha/2}$ obtido por meio de tabelas, então a imagem orbital não apresenta erros sistemáticos nas coordenadas N e E (Vieira e Mather, 2005).

O teste *t* de *Student* é calculado obedecendo as seguintes hipóteses e fórmulas (Equações A.1 e A.2):

Para a abscissa:

H_0 : Se $\Delta X = 0$, então X não é tendencioso.

H_1 : Se $\Delta X \neq 0$, então X é tendencioso.

Para a ordenada:

H_0 : Se $\Delta Y = 0$, então Y não é tendencioso.

H_1 : Se $\Delta Y \neq 0$, então Y é tendencioso.

$$t_x = \frac{\overline{\Delta x} \times \sqrt{n}}{S_x} \quad (\text{A.1})$$

$$\bar{t}_y = \frac{\overline{\Delta y} \times \sqrt{n}}{S_y} \quad (\text{A.2})$$

O Teste *Qui-quadrado* (χ^2) aplica-se obedecendo aos valores pré-estabelecidos do Erro Padrão (EP), com objetivo de verificar em qual classe o produto analisado se enquadra segundo a Lei (Equação A.3).

$$\sigma_x = \sigma_y = \frac{EP}{\sqrt{2}} \quad (\text{A.3})$$

As precisões serão atendidas nas direções X e Y das imagens orbitais quando os valores calculados $\chi^2_{x \alpha, n-1}$ e $\chi^2_{y \alpha, n-1}$ forem inferiores ao valor limite $\chi^2_{\alpha, n-1}$ obtido por meio de tabela. O Teste *Qui-quadrado* é empregado para avaliar a precisão das medidas das discrepâncias existentes entre as freqüências observadas e esperadas, sendo calculado pelas seguintes fórmulas (Equações A.4 e A.5):

$$\chi^2_{x \alpha, n-1} = (n-1) \times \left(\frac{S_x^2}{\sigma_x^2} \right) \quad (\text{A.4})$$

$$\chi^2_{y \alpha, n-1} = (n-1) \times \left(\frac{S_y^2}{\sigma_y^2} \right) \quad (\text{A.5})$$

A partir dos 25 pontos coletados (Tabela A.1), apresenta-se o resultado das análises.

Tabela A1: Pontos de controle homólogos referentes à abrangência da EDR – Limeira/SP.

	LANDSAT / ETM+		MODIS		Resíduos (m)	
	Abcissa	Ordenada	Abcissa	Ordenada	ΔX	ΔY
1	236813,643	7525858,170	236814,306	7525859,143	-0,663	-0,973
2	240780,637	7514453,543	240769,162	7514445,130	11,475	8,413
3	247801,270	7510344,364	247777,766	7510340,090	23,504	4,274
4	248321,011	7504584,840	248328,442	7504583,022	-7,431	1,818
5	243426,539	7501181,196	243422,419	7501228,905	4,120	-47,709
6	209659,358	7536879,817	209660,666	7536912,900	-1,308	-33,083
7	249692,355	7568922,325	249715,080	7568924,146	-22,725	-1,821
8	250733,501	7561879,278	250720,131	7561888,792	13,370	-9,514
9	259289,679	7566036,046	259288,542	7566042,402	1,137	-6,356
10	242675,306	7581598,181	242683,887	7581590,801	-8,581	7,380
11	242417,358	7578463,124	242418,149	7578477,863	-0,791	-14,739
12	242556,432	7522585,042	242571,374	7522605,148	-14,942	-20,106
13	215780,175	7545093,762	215710,871	7545063,512	69,304	30,250
14	203372,433	7534463,179	203341,400	7534450,768	31,033	12,411
15	225726,777	7524764,918	225820,425	7524704,130	-93,648	60,788
16	207055,520	7540637,885	207065,944	7540619,646	-10,424	18,239
17	210711,644	7543813,461	210722,842	7543797,883	-11,198	15,578
18	262493,805	7567600,802	262494,811	7567622,302	-1,006	-21,500
19	250595,089	7582668,911	250589,525	7582656,920	5,564	11,991
20	243642,088	7581881,294	243622,059	7581873,080	20,029	8,214
21	247169,803	7526140,459	247187,331	7526134,641	-17,528	5,818
22	260740,566	7490598,531	260730,810	7490591,716	9,756	6,815
23	201957,619	7538205,977	201970,345	7538199,041	-12,726	6,936
24	255174,524	7541807,484	255179,353	7541793,844	-4,829	13,640
25	257226,919	7496592,400	257242,910	7496610,902	-15,991	-18,502
				Máximo	69,304	60,788
				Mínimo	-93,648	-47,709
				Média	-1,380	1,530
				Desvio Padrão	27,233	21,354

A partir dos resultados da estatística descritiva, realizou-se o teste de tendência *t* de *Student* ao nível de significância $\alpha = 10\%$, com $n = 25$ amostras e 24 graus de liberdade. Assim temos:

$$t_{\text{tabelado}} = t_{\alpha\%}(n-1) = t_{10\%}(24) = 1,71$$

Para ΔX : $t_{\text{calculado}} = -0,253$.

Para ΔY : $t_{\text{calculado}} = 0,358$.

Logo, $|t_{\text{calculado}}| < t_{\text{tabelado}}$ no teste realizado.

De acordo com as hipóteses testadas e comparando os valores calculados com o valor tabelado, pode-se concluir que não ocorrem erros sistemáticos, pois não se rejeita a hipótese H_0 .

Por não haver erros sistemáticos pôde-se então avaliar precisão posicional da imagem orbital aplicando-se o Teste *Qui-quadrado*, ao nível de significância $\alpha = 10\%$ e $n = 25$ amostras representadas na Tabela A.1.

Para os valores nas direções X e Y, temos:

$$\chi^2_{\text{tabelado}} = \chi^2_{\alpha, n-1} = \chi^2_{10, 24} = 33,196$$

Para o cálculo de χ^2 nas direções X e Y, os valores de σ_x e σ_y são obtidos por meio do EP. Os valores do EP de acordo com o decreto 89.817/84 variam em função da classe segundo a Tabela A.2. Os resultados do cálculo de χ^2 referentes a área de estudo são mostrados na Tabela A.3.

Tabela A.2: Resultado do PEC, EP, σ_x e σ_y .

Classe	Planimetria		Escala 1:400.000	
	PEC	EP	σ_x (m)	σ_y (m)
A	0,5 mm	0,3 mm	84,853	84,853
B	0,8 mm	0,5 mm	141,421	141,421
C	1,0 mm	0,6 mm	169,706	169,706

Tabela A.3: Valores de $\chi^2_x \alpha, n-1$ e $\chi^2_y \alpha, n-1$.

Classe	Direção	Modis
A	E	2,472
	N	1,520
B	E	0,890
	N	0,547
C	E	0,618
	N	0,380

Como citado, se $\chi^2_x \alpha, n-1$ e $\chi^2_y \alpha, n-1$ forem inferiores ao valor limite χ^2_{tabelado} , as precisões nas direções X e Y serão atendidas para a imagem orbital. Comparando os valores calculados com o valor tabelado, pode-se concluir que há precisão posicional, pois o $\chi^2_{\text{calculado}}$ para ambas as direções foi menor que o χ^2_{tabelado} .

Comparando os resultados dos testes, pode-se concluir que a imagem orbital MODIS, referente a região da EDR de Limeira-SP, se enquadra na classe A ao nível de significância de $\alpha = 10\%$. Isto nos mostra

que esta imagem orbital poderá ser utilizada para fins de planejamento e monitoramento de mudanças em larga escala (Braga et al., 2005).

ANEXO B

MATRIZES DE CONFUSÃO OBTIDAS PELAS DIFERENTES METODOLOGIAS

Tabela B1: Matriz de Confusão da Classificação com imagem de referência Refer_1, com a imagem MODIS na data 21/03/2004.

Classificação (Refer_1)									
Classe	1	2	3	4	5	6	7	Total	Exatidão do Usuário
1	1	1	0	1	4	1	12	20	5,0
2	5	15	1	4	2	5	1	33	45,5
3	1	3	8	3	2	2	0	19	41,1
4	8	5	11	20	9	11	0	64	31,2
5	2	0	5	3	4	3	2	19	21,1
6	6	8	8	1	11	10	2	46	21,7
7	10	1	0	1	1	1	16	30	53,3
Total	33	33	33	33	33	33	33	231	
Exatidão do Produtor	3,0	45,5	24,2	60,6	12,1	30,3	48,5		

Exatidão Global = 32,0; kappa = 0,207; Var = 0,001219;
 $Z_{\text{calculado}} = 5,957$; $Z_{\text{tabelado}} = 1,96$.

Tabela B2: Matriz de Confusão da Classificação com imagem de referência Refer_2, com a imagem MODIS na data 21/03/2004.

Classificação (Refer_2)									Exatidão do Usuário
Classe	1	2	3	4	5	6	7	Total	
1	16	6	5	4	0	1	4	36	44,4
2	0	5	0	2	1	1	1	10	50,0
3	1	2	16	0	21	0	0	40	40,0
4	1	1	0	3	0	1	2	8	37,5
5	1	2	3	0	8	0	0	14	57,1
6	10	8	7	20	2	24	9	80	30,0
7	3	8	1	3	0	5	16	36	44,4
Total	32	32	32	32	32	32	32	224	
Exatidão do Produtor	50,0	15,6	50,0	9,4	25,0	75,0	50,0		

Exatidão Global = 39,3; kappa = 0,292; Var = 0,001297;

$Z_{\text{calculado}} = 8,100$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B3: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador PTS e algoritmo MaxVer.

Classificação									Exatidão do Usuário
Classe	1	2	3	4	5	6	7	Total	
1	5	1	1	2	2	1	1	13	38,5
2	6	28	3	5	2	14	0	58	48,3
3	2	0	11	10	4	3	0	30	36,7
4	2	1	12	13	5	1	0	34	38,2
5	3	1	4	2	9	5	0	24	37,5
6	3	2	2	1	5	7	0	20	35,0
7	12	0	0	0	6	2	32	52	61,5
Total	33	33	33	33	33	33	33	231	
Exatidão do Produtor	15,2	84,8	33,3	39,4	27,3	21,2	97,0		

Exatidão Global 45,5%; kappa = 0,364; Var = 0,001329;

$Z_{\text{calculado}} = 9,976$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Mata; (2) Cana de açúcar; (3) Milho; (4) Soja; (5) Cítrus; (6) Pasto; (7) Eucalipto.

Tabela B4: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador COL e algoritmo MaxVer.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	2	0	0	0	0	0	2	4	50,0	
2	8	13	6	5	5	12	4	53	24,5	
3	8	11	12	11	8	8	0	58	20,7	
4	7	8	12	15	12	3	1	58	25,9	
5	3	0	1	1	6	5	1	17	35,3	
6	1	1	2	1	2	5	6	18	27,8	
7	4	0	0	0	0	0	19	23	82,6	
Total	33	33	33	33	33	33	33	231		
Exatidão do Produtor	6,1	39,4	36,4	45,5	18,2	15,2	57,6			

Exatidão Global = 31,2; kappa = 0,197; Var = 0,001204;
 $Z_{\text{calculado}} = 5,677$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Mata; (2) Cana de açúcar; (3) Milho; (4) Soja; (5) Cítrus; (6) Pasto; (7) Eucalipto.

Tabela B5: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador PTS e algoritmo RNA.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	18	4	0	0	1	7	0	30	60,0	
2	1	18	4	2	5	5	4	39	46,2	
3	0	2	12	2	3	3	0	22	54,5	
4	0	1	0	20	0	1	0	22	90,9	
5	3	3	1	3	14	9	0	33	42,4	
6	2	4	16	6	8	8	0	44	18,2	
7	9	1	0	0	2	0	29	41	70,7	
Total	33	33	33	33	33	33	33	231		
Exatidão do Produtor	54,5	54,5	36,4	60,6	42,4	24,2	87,9			

Exatidão Global = 51,5; kappa = 0,434; Var = 0,001471;
 $Z_{\text{calculado}} = 11,323$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Mata; (2) Cana de açúcar; (3) Milho; (4) Soja; (5) Cítrus; (6) Pasto; (7) Eucalipto.

Tabela B6: Matriz de Confusão da Classificação com imagem de referência Refer_1, com o interpolador COL e algoritmo RNA.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	1	0	0	0	0	0	1	2	50,0	
2	4	18	4	1	4	2	0	33	54,5	
3	0	1	14	7	2	0	0	24	58,3	
4	9	0	7	19	10	4	0	49	38,8	
5	0	0	0	0	0	0	0	0	0,0	
6	7	13	8	6	17	25	1	77	32,5	
7	12	1	0	0	0	2	31	46	67,4	
Total	33	33	33	33	33	33	33	231		
Exatidão do Produtor	3,0	54,5	42,4	57,6	0,0	75,8	93,9			

Exatidão Global = 46,8; kappa = 0,379; Var = 0,001268;

$Z_{\text{calculado}} = 10,638$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Mata; (2) Cana de açúcar; (3) Milho; (4) Soja; (5) Cítrus; (6) Pasto; (7) Eucalipto.

Tabela B7: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador PTS e algoritmo MaxVer.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	30	12	7	10	1	2	7	69	43,5	
2	0	10	1	0	0	0	0	11	90,9	
3	0	2	14	0	6	0	0	22	63,6	
4	0	1	2	18	0	1	0	22	81,8	
5	1	6	8	1	25	0	0	41	61,0	
6	0	0	0	0	0	22	2	24	91,7	
7	1	1	0	3	0	7	23	35	65,7	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	93,8	31,2	43,8	56,2	78,1	68,8	71,9			

Exatidão Global = 63,8; kappa = 0,578; Var = 0,001338;

$Z_{\text{calculado}} = 15,804$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B8: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador COL e algoritmo MaxVer.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	23	6	11	14	9	0	2	65	35,4	
2	1	7	3	0	4	0	0	15	46,7	
3	1	1	6	0	4	0	0	12	50,0	
4	0	2	2	5	3	0	0	12	41,7	
5	0	0	0	1	10	0	0	11	90,9	
6	1	4	1	1	0	17	4	28	60,7	
7	6	12	9	11	2	15	26	81	32,1	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	71,9	21,9	18,8	15,6	31,2	53,1	81,2			

Exatidão Global = 42,0; kappa = 0,323; Var = 0,001288;
 $Z_{\text{calculado}} = 8,999$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B9: Matriz de Confusão da Classificação com imagem de referência Refer_2, interpolador PTS e algoritmo RNA.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	9	0	1	4	3	0	0	17	52,9	
2	8	29	2	10	1	1	2	53	54,7	
3	8	1	14	1	8	2	0	34	41,2	
4	3	0	0	12	1	0	17	33	36,4	
5	1	0	10	0	19	1	0	31	61,3	
6	0	1	3	0	0	27	0	31	87,1	
7	3	1	2	5	0	1	13	25	52,0	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	28,1	90,6	43,8	37,5	59,4	84,4	40,6			

Exatidão Global = 54,9; kappa = 0,474; Var = 0,001460;
 $Z_{\text{calculado}} = 12,405$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B10: Matriz de Confusão da Classificação com imagem de referência Refer_3, interpolador PTS e algoritmo MaxVer.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	30	4	5	9	3	3	9	63	47,6	
2	0	13	0	0	0	0	0	13	100,0	
3	0	1	12	1	8	0	0	22	54,5	
4	0	2	0	20	0	0	1	23	87,0	
5	1	5	15	0	21	0	0	42	50,0	
6	0	3	0	1	0	22	5	31	71,0	
7	1	4	0	1	0	7	17	30	56,7	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	93,8	40,6	37,5	62,5	65,6	68,8	53,1			

Exatidão Global = 60,3; kappa = 0,536; Var = 0,001401;
 $Z_{\text{calculado}} = 14,334$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B11: Matriz de Confusão da Classificação com imagem de referência Refer_3, interpolador COL e algoritmo MaxVer.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	25	3	14	15	5	2	8	72	34,7	
2	0	14	0	0	4	0	1	19	73,7	
3	0	0	6	0	11	0	0	17	35,3	
4	0	0	0	4	1	0	0	5	80,0	
5	0	0	1	0	7	0	0	8	87,5	
6	1	6	1	6	2	18	6	40	45,0	
7	6	9	10	7	2	12	17	63	27,0	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	78,1	43,8	18,8	12,5	21,9	56,2	53,1			

Exatidão Global = 40,6; kappa = 0,307; Var = 0,001313;
 $Z_{\text{calculado}} = 8,480$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B12: Matriz de Confusão da Classificação com imagem de referência Refer_3, interpolador PTS e algoritmo RNA.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	10	0	4	4	5	1	0	24	41,7	
2	6	28	3	8	0	0	2	47	59,6	
3	4	0	11	0	4	0	0	19	57,9	
4	6	4	0	12	2	0	0	24	50,0	
5	2	0	14	1	20	0	0	37	54,1	
6	1	0	0	2	0	31	1	35	88,6	
7	3	0	0	5	1	0	29	38	76,3	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	31,3	87,5	34,4	37,5	62,5	96,9	90,6			

Exatidão Global = 62,9; kappa = 0,568; Var = 0,001370;
 $Z_{\text{calculado}} = 15,337$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

Tabela B13: Matriz de Confusão da Classificação com imagem de referência por Operação de Vizinhança, interpolador COL e algoritmo RNA.

Classificação									Total	Exatidão do Usuário
Classe	1	2	3	4	5	6	7			
1	26	2	10	5	0	0	0	43	60,5	
2	2	21	5	1	0	0	0	29	72,4	
3	0	0	10	0	14	5	0	29	34,5	
4	0	1	1	22	2	4	0	30	73,3	
5	3	0	5	2	12	0	0	22	54,5	
6	0	2	1	2	0	15	4	24	62,5	
7	1	6	0	0	4	8	28	47	59,6	
Total	32	32	32	32	32	32	32	224		
Exatidão do Produtor	81,3	65,6	31,3	68,6	37,5	46,9	87,5			

Exatidão Global = 59,8; kappa = 0,531; Var = 0,001425;
 $Z_{\text{calculado}} = 14,072$; $Z_{\text{tabelado}} = 1,96$.

Legenda: (1) Cana de açúcar; (2) Cítrus; (3) Mata; (4) Pasto; (5) Eucalipto; (6) Soja; (7) Milho.

ANEXO C

IMAGENS TEMÁTICAS OBTIDAS PELAS DIFERENTES METODOLOGIAS (CAPÍTULO 3)

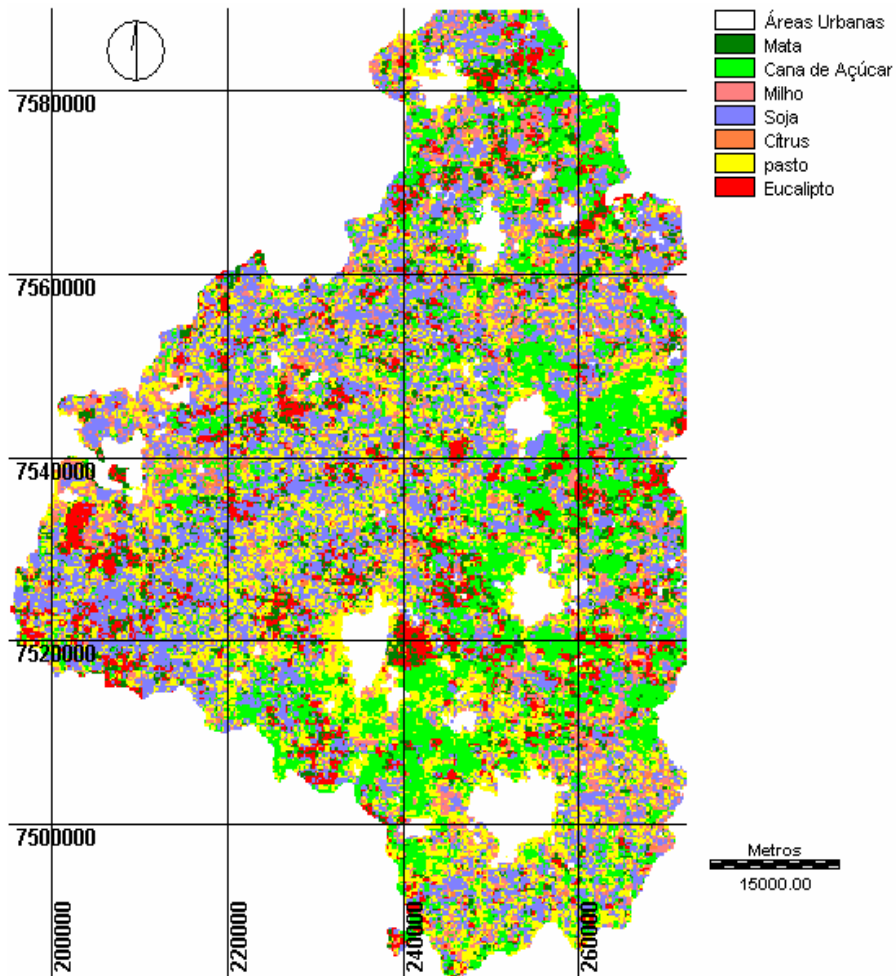


Figura C1: Imagem classificada a partir da imagem de referência Refer_1, com a imagem MODIS na data 21/03/2004, de acordo com o limite as EDR Limeira.

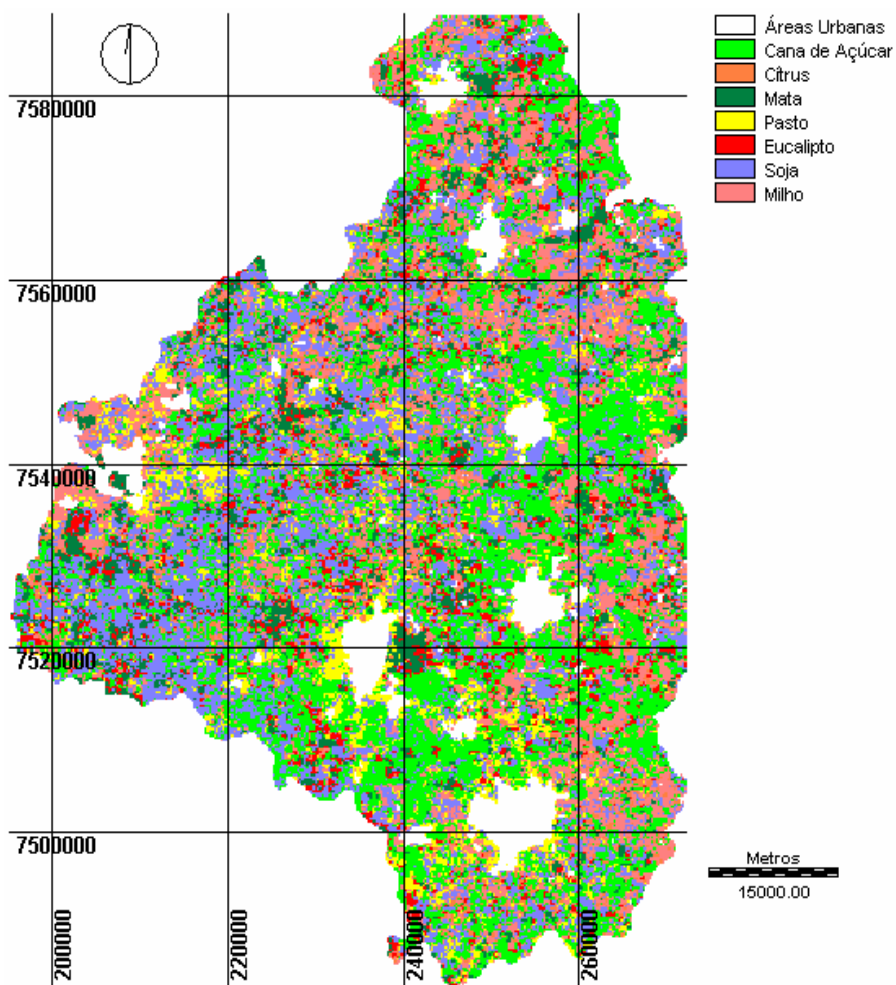


Figura C2: Imagem classificada a partir da imagem de referência Refer_2, com a imagem MODIS na data 21/03/2004, de acordo com o limite as EDR Limeira.

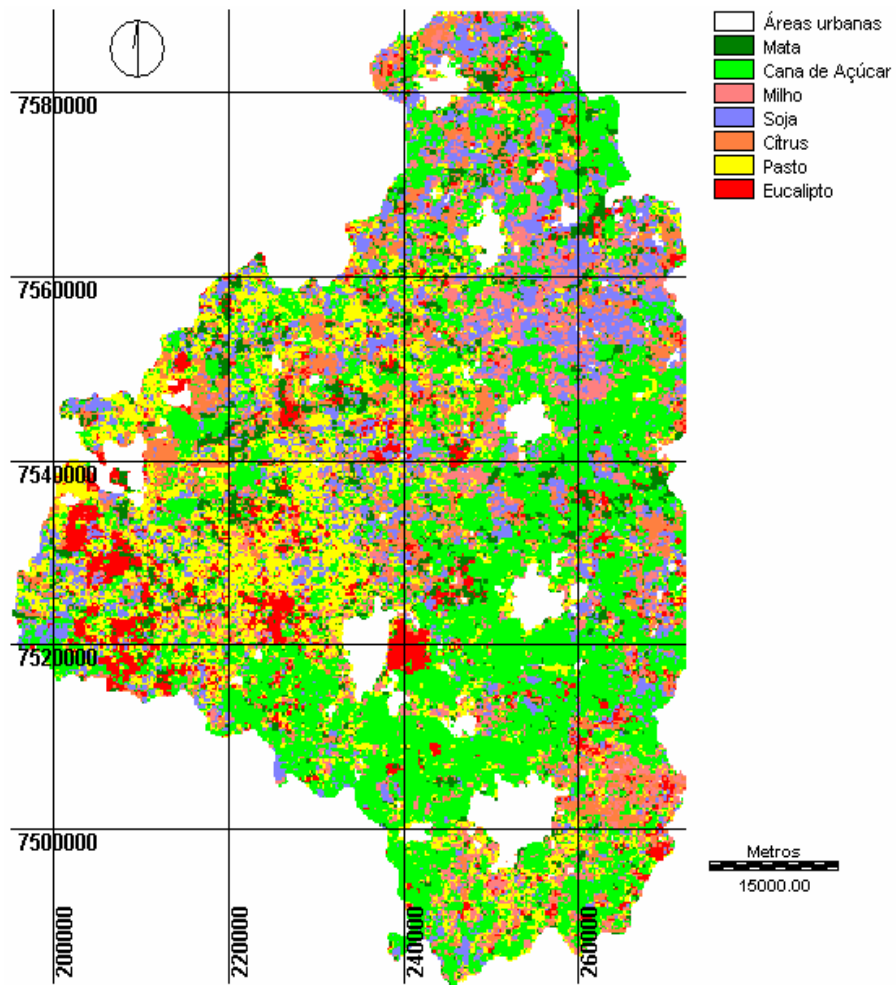


Figura C3: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador PTS e algoritmo MaxVer, de acordo com o limite as EDR Limeira.

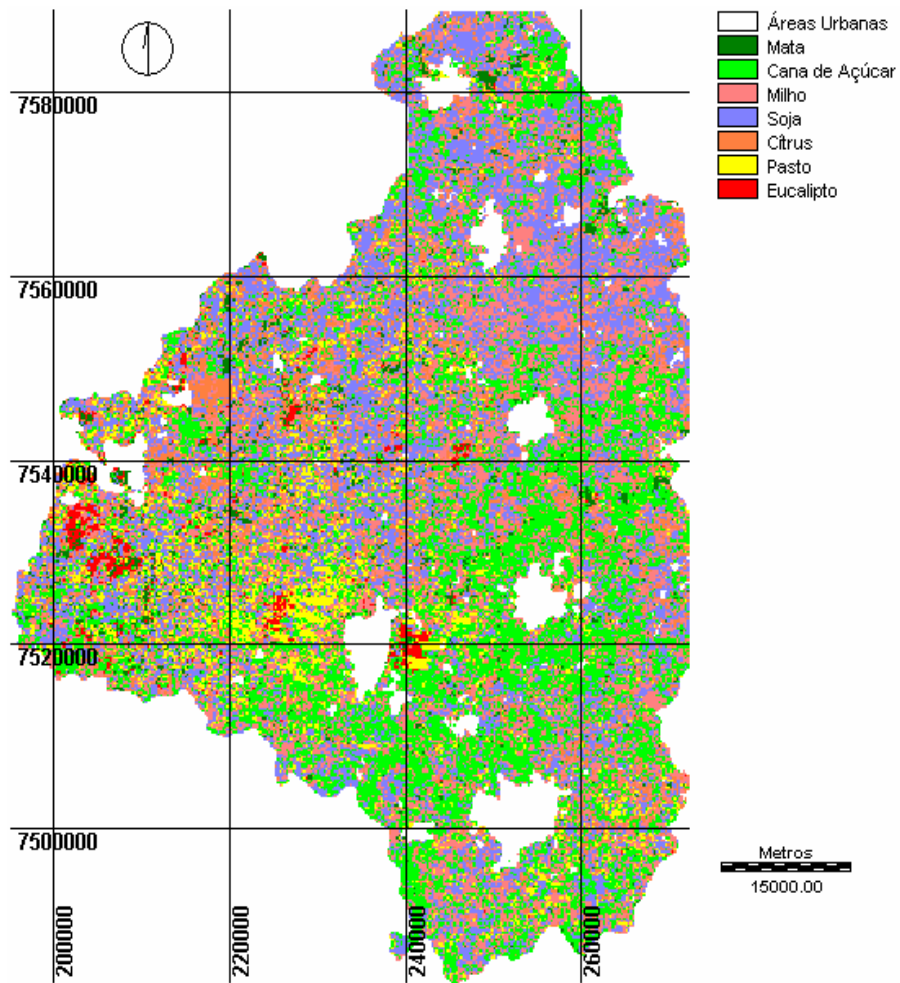


Figura C4: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador COL e algoritmo MaxVer, de acordo com o limite as EDR Limeira.

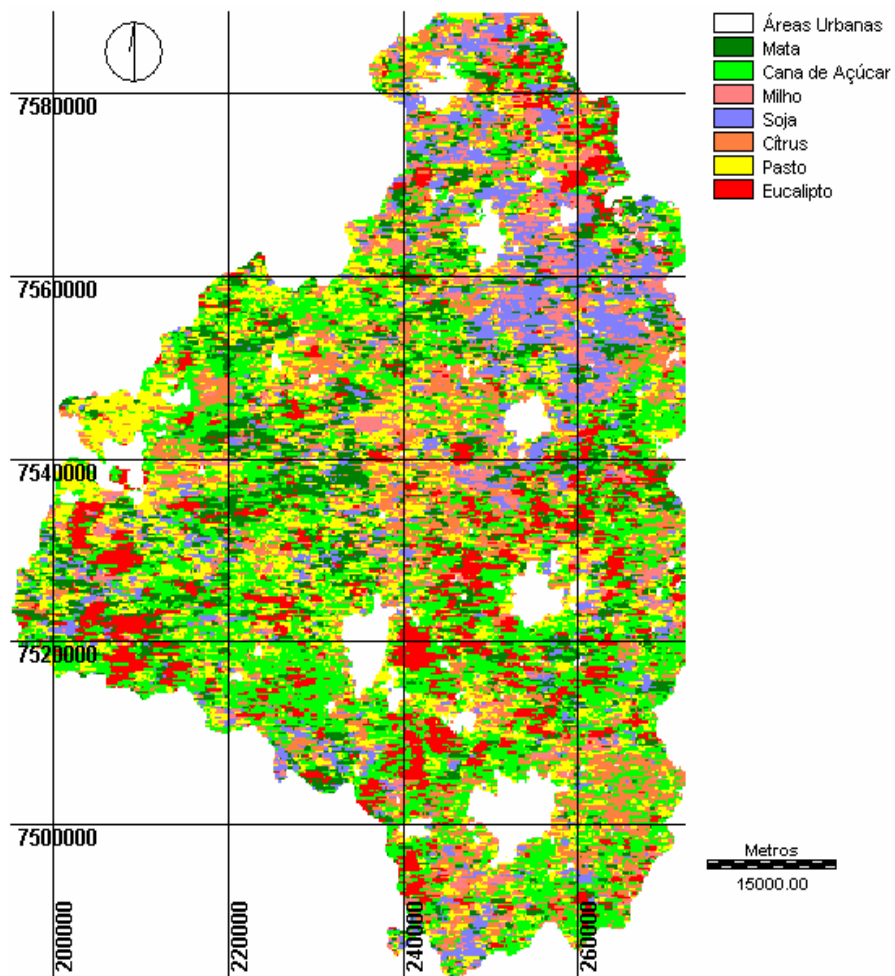


Figura C5: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador PTS e algoritmo RNA, de acordo com o limite as EDR Limeira.

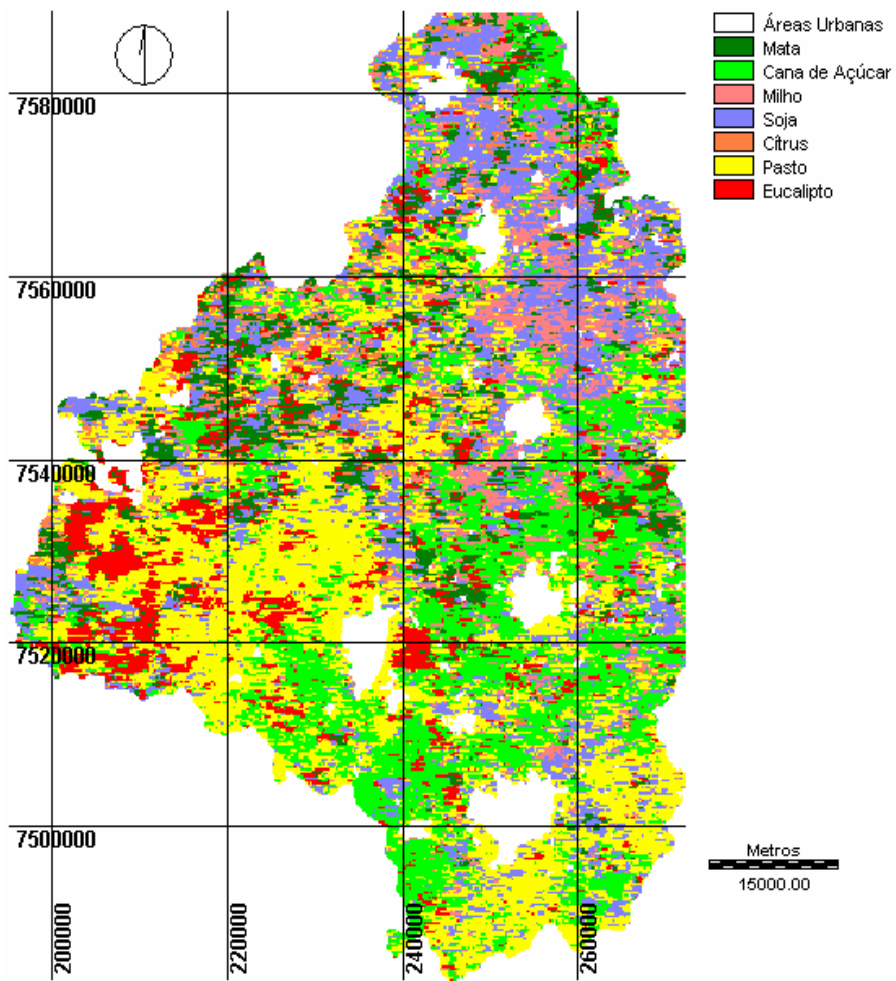


Figura C6: Imagem classificada a partir da imagem de referência Refer_1, com o interpolador COL e algoritmo RNA, de acordo com o limite as EDR Limeira.

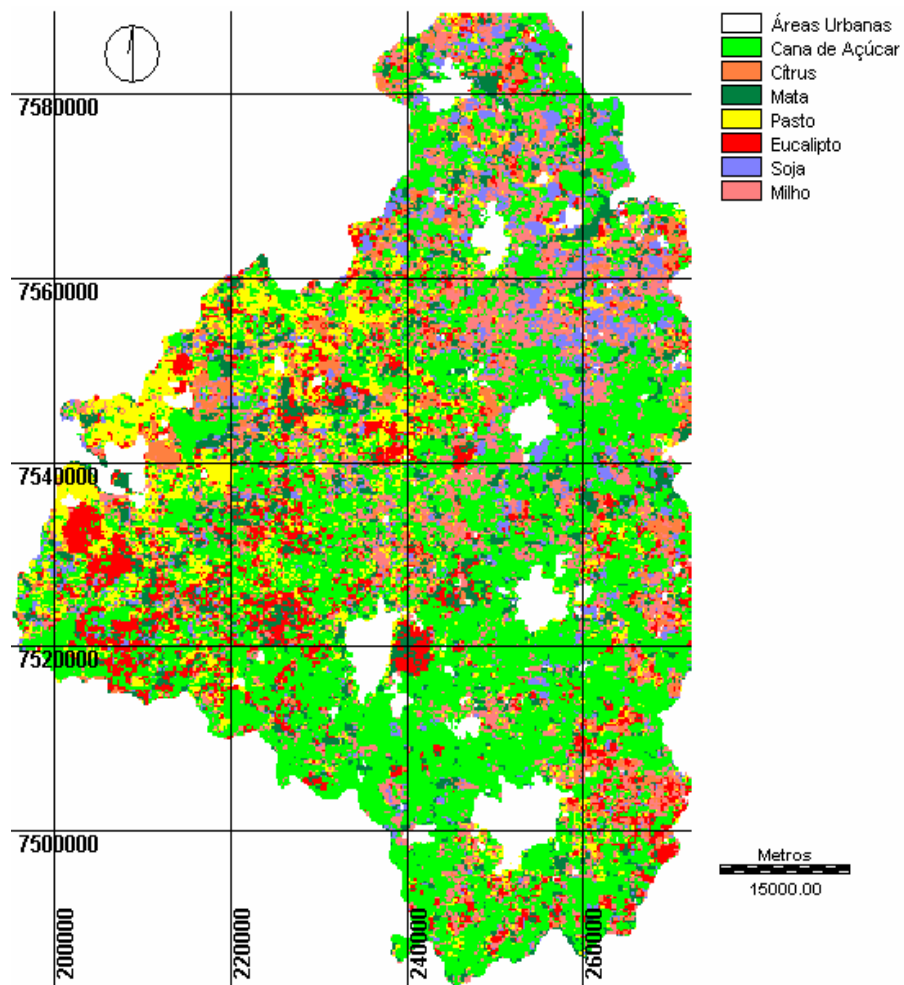


Figura C7: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador PTS e algoritmo MaxVer, de acordo com o limite as EDR Limeira.

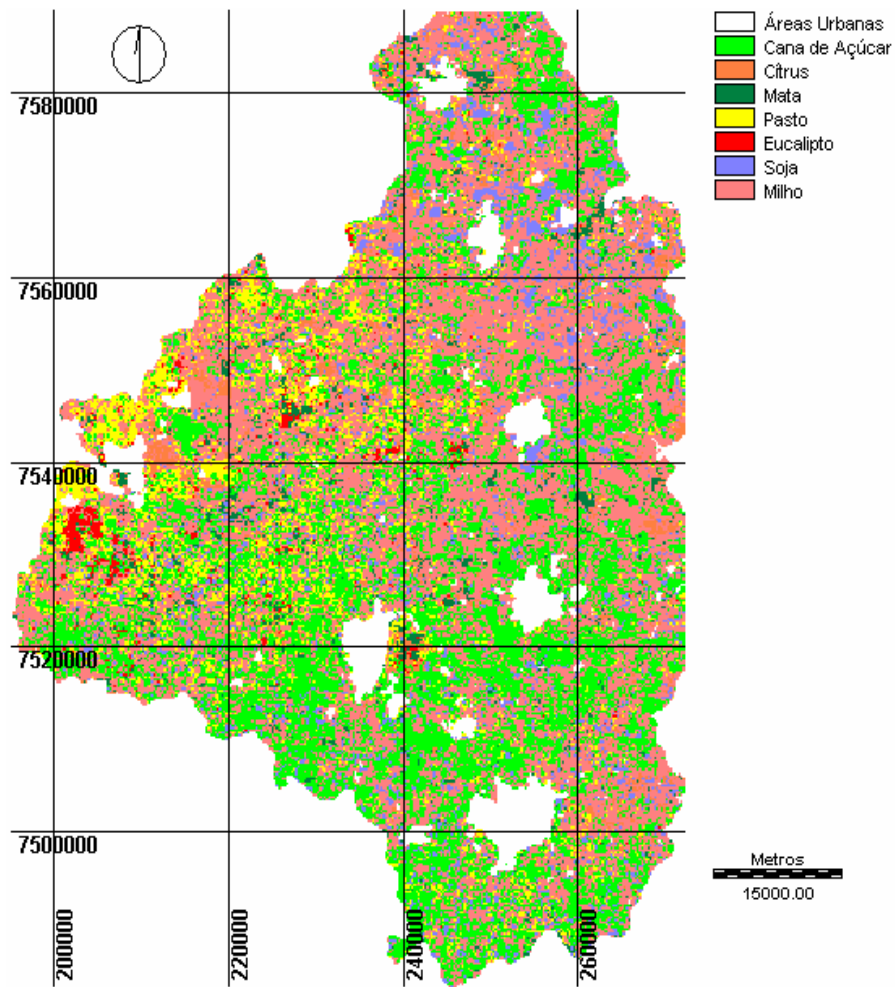


Figura C8: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador COL e algoritmo MaxVer, de acordo com o limite da EDR Limeira.

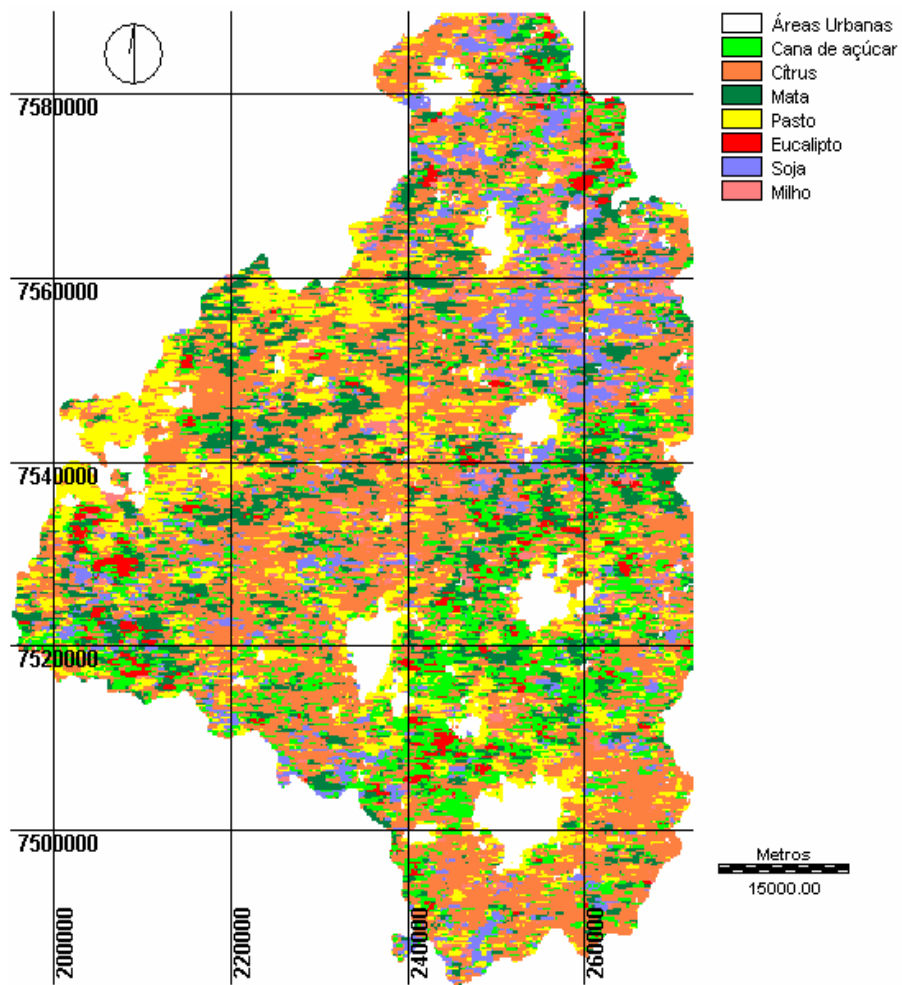


Figura C9: Imagem classificada a partir da imagem de referência Refer_2, com o interpolador PTS e algoritmo RNA, de acordo com o limite da EDR Limeira.

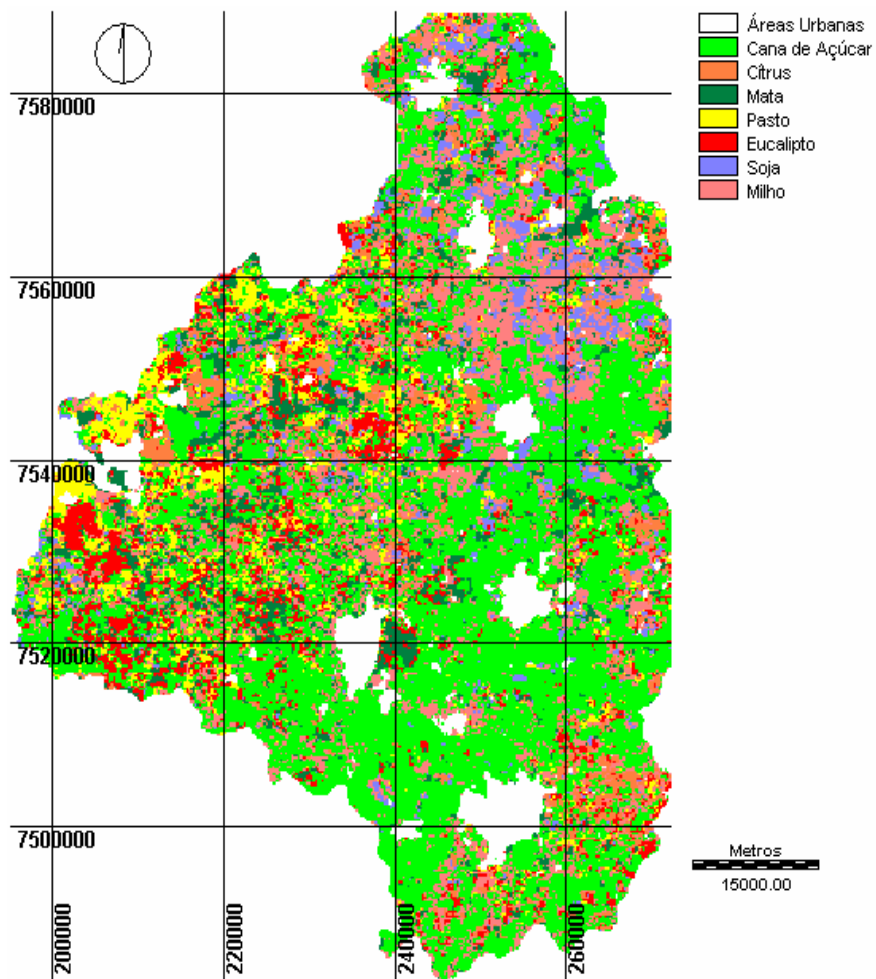


Figura C10: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador PTS e algoritmo MaxVer, de acordo com o limite da EDR Limeira.

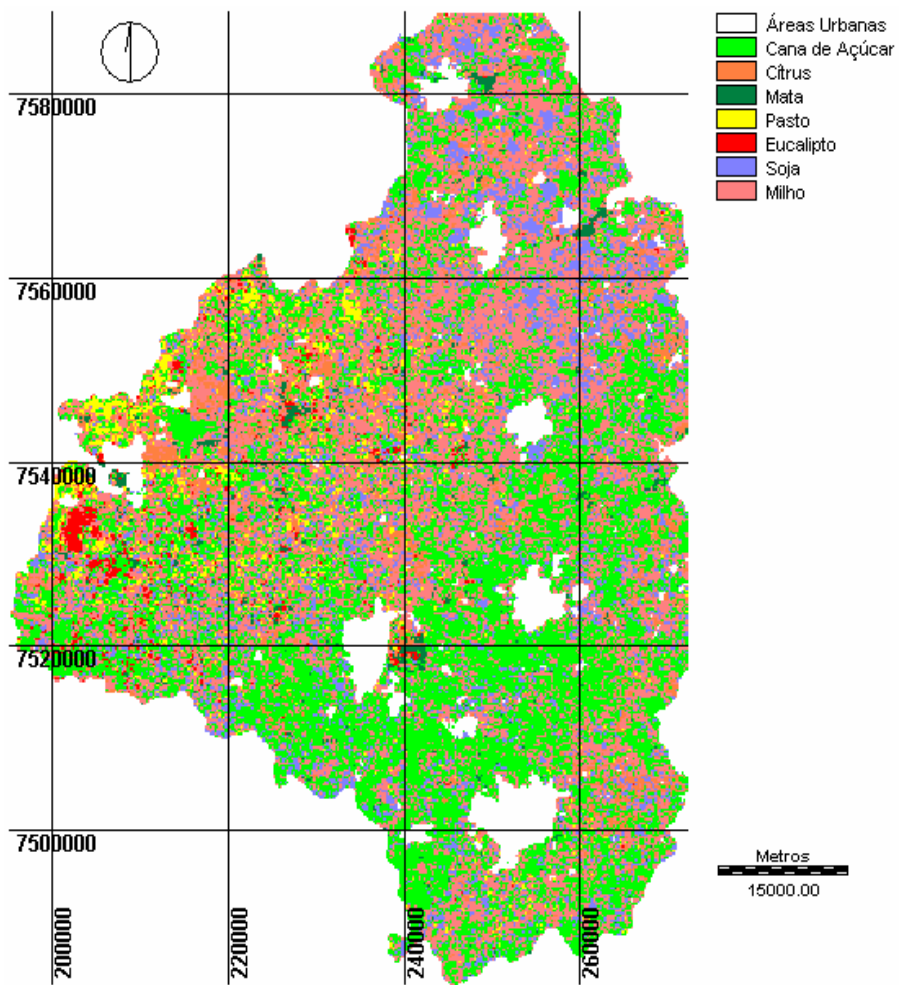


Figura C11: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador COL e algoritmo MaxVer, de acordo com o limite da EDR Limeira.

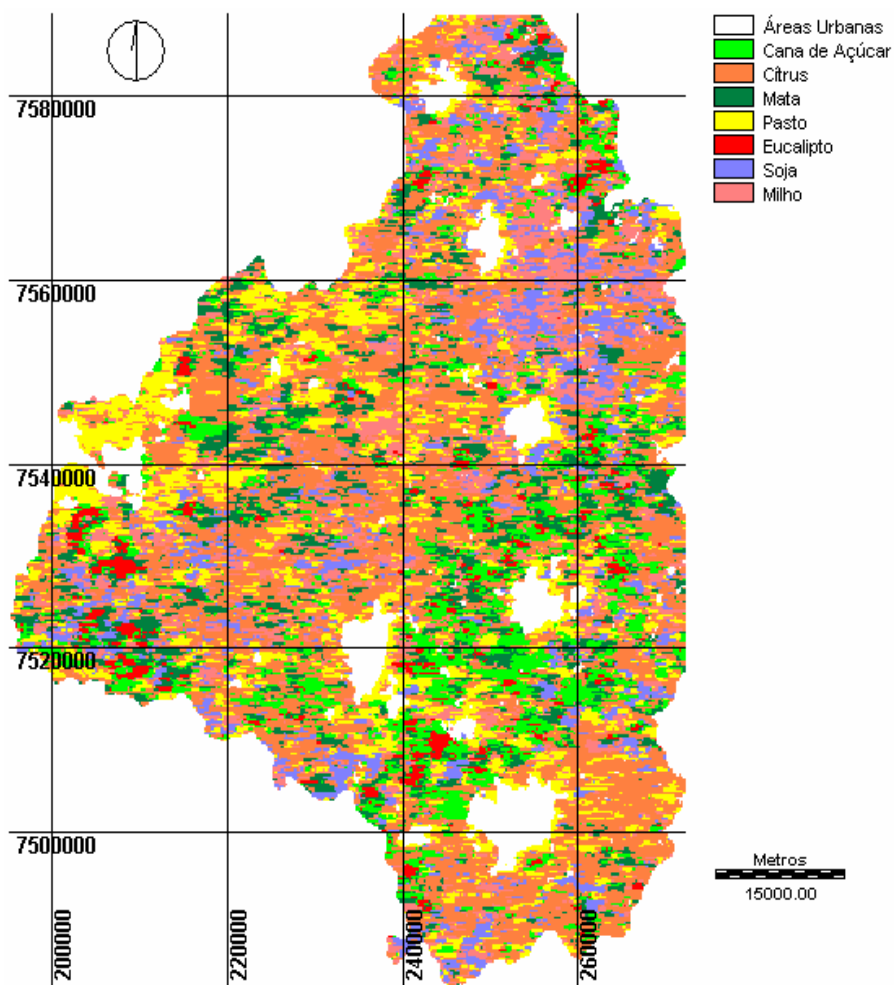


Figura C12: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador PTS e algoritmo RNA, de acordo com o limite da EDR Limeira.

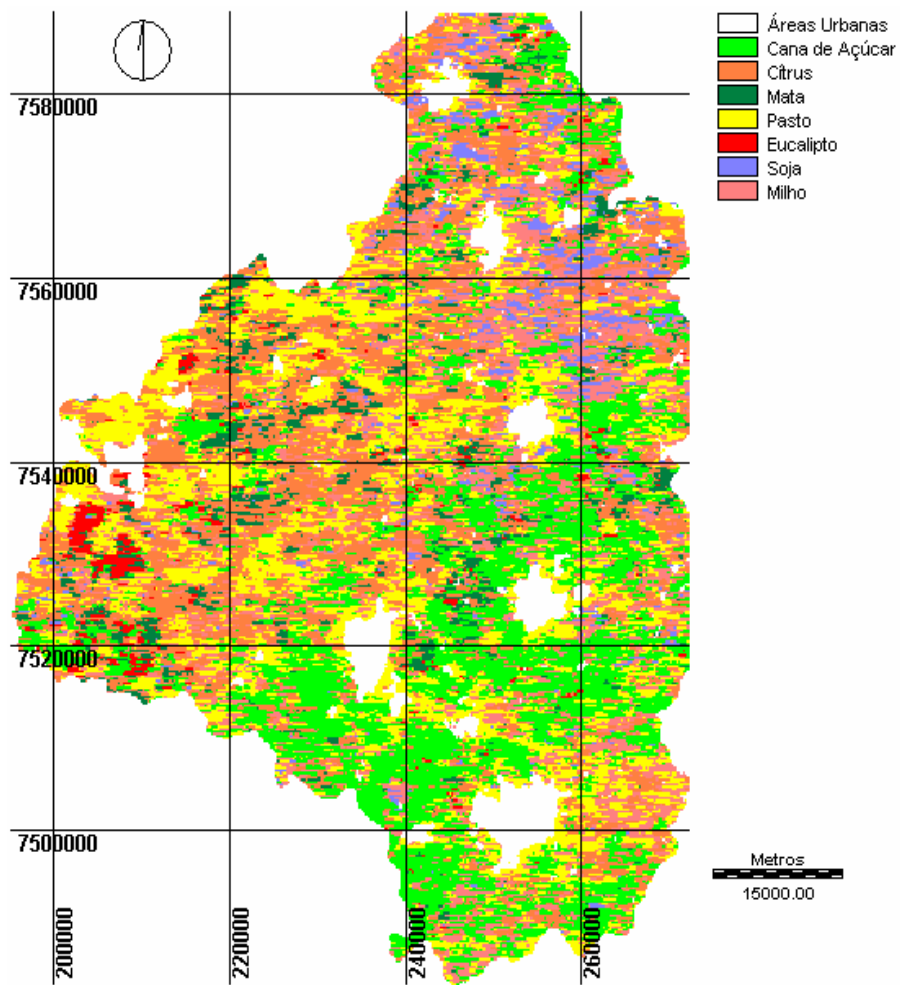


Figura C13: Imagem classificada a partir da imagem de referência Refer_3, com o interpolador COL e algoritmo RNA, de acordo com o limite as EDR Limeira.