

**MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

INPE-6645-TDI/622

**SEGMENTAÇÃO DE IMAGENS E LÓGICA NEBULOSA PARA
TREINAMENTO DE UMA REDE NEURAL ARTIFICIAL NA
CARACTERIZAÇÃO DO USO DATERRA NA
REGIÃO DE TUCURUÍ (PA)**

Adriano Venturieri

**Dissertação de Mestrado em Sensoriamento Remoto, orientada pelo
Dr. João Roberto dos Santos, aprovada em fevereiro de 1996.**

**INPE
São José dos Campos
Fevereiro de 1996**

528.711.7:621.376.5(811.5)

VENTURIERI, A.

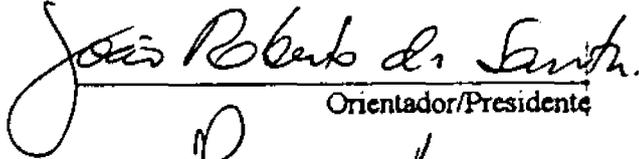
Segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização do uso da terra na região de Tucuruí (PA) / A. Venturieri. - São José dos Campos: INPE, 1996.

140 p. - (INPE-6645-TDI/622)

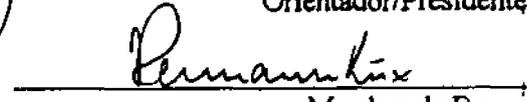
1. Segmentação de imagens. 2. Classificação de imagens. 3. Uso da terra. 4. Redes neurais. 5. Tucuruí (PA). 6. Mapeamento temático (Landsat). I. Título.

Aprovada pela Banca Examinadora em
cumprimento a requisito exigido para a
obtenção do Título de Mestre em
Sensoriamento Remoto

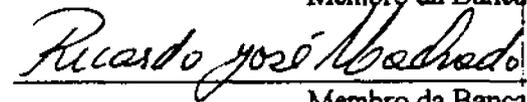
Dr. João Roberto dos Santos


Orientador/Presidente

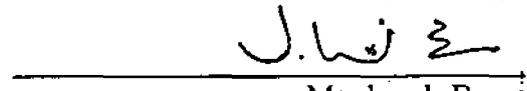
Dr. Hermann Johann Heinrich Kux


Membro da Banca

Dr. Ricardo José Machado


Membro da Banca
- Convidado -

Dr. Evaristo Eduardo de Miranda


Membro da Banca
- Convidado -

Candidato: Adriano Venturieri

São José dos Campos, 05 de fevereiro de 1996

“Não te prendas excessivamente às dificuldades
do dia de ontem, nem te inquietes demasiado
pelos prováveis obstáculos de amanhã.
Vive e age bem no dia de hoje,
equilibra-te e vencerás.”

Francisco Cândido Xavier

À memória de meu pai, Antônio
À minha mãe, Lourdes
À minha esposa, Sandra e
À minha pequena filha Amanda,
Dedico com amor

AGRADECIMENTOS

Agradeço as seguintes pessoas e instituições que colaboraram neste trabalho, sem ajuda das quais não seria possível essa realização:

À EMBRAPA por ter-me propiciado a oportunidade de concluir este curso com de Mestrado.

Ao Dr. João Roberto dos Santos, orientador acadêmico e coordenador do curso de mestrado em Sensoriamento Remoto pela minha aceitação como orientando, transmitido-me conhecimentos necessários para a realização deste trabalho.

Ao Centro Científico IBM-Rio, na pessoa do Dr. Ricardo José Machado e de Frederico dos Santos Liporace pelo apoio incondicional ao desenvolvimento desta pesquisa.

Aos tecnologistas Leonardo Bins, Guaraci Erthal, Juan Garrido, Fernando e Sílvia Ii, da Divisão de Processamento de Imagens do INPE, pelo desenvolvimento de mecanismos que viabilizaram a produção deste trabalho.

Aos colegas pós-graduandos, em especial a Camilo Daleles Rennó, Orlando Watrin, Sérgio Bernardes, Sílvia Lacruz e Jorge Gavina pelas contribuições durante o desenvolvimento desta pesquisa.

Ao João Carrilho, Gerardo Kuntchik, Kátia Fernandes, Marinaldo Gleriani e a Sra. Maria Etelvina (secretária acadêmica SER) pelo apoio nos momentos difíceis desta caminhada.

À SUDAM pelo apoio durante a realização do trabalho de campo e também pela utilização dos seus equipamentos em Belém.

À CAPES pela concessão da bolsa de estudo.

À minha irmã Ângela, e todos os meus irmãos que sempre estiveram ao meu lado na busca desta meta e ao Sr. Santana e D. Helena Santana, pelos cuidados dispensados a pequena Amanda durante minha ausência.

RESUMO

Para avaliação e monitoramento das áreas desflorestadas na Amazônia têm sido desenvolvidas, atualmente, técnicas de segmentação e classificação de imagens TM/LANDSAT por redes neurais. O sucesso desta abordagem tem permitido direcionar esforços para uma estratificação das áreas desflorestadas, hoje em uso agropecuário ou em pousio. Por conseguinte, o objetivo deste trabalho é o desenvolvimento do processo de segmentação de imagens e rotulação de segmentos utilizando a lógica nebulosa como suporte para treinamento (através do algoritmo *backpropagation*) de redes neurais artificiais especializadas em classes de vegetação e uso da terra na região de Tucuruí (PA). Em complementação à este objetivo é apresentada a comparação (através da estatística Kappa) entre imagens temáticas resultantes dos algoritmos de classificação tradicionais (ISOSEG e Máxima Verossimilhança) como primeiro passo para uma avaliação geral dos diferentes processos classificatórios de imagens, incluindo futuramente aquele derivado das redes neurais. O estudo foi desenvolvido em parte da região sob influência da barragem de Tucuruí (SE do Estado do Pará). O processo de segmentação da imagem foi realizado com base nas características de natureza espectral, através da técnica de crescimento de regiões. Foram rotulados individualmente 15.033 segmentos de imagem para formação da base de conhecimento/treinamento da rede nas geoclasses: Floresta, Sucessão Secundária Avançada, Sucessão Secundária Inicial, Pasto Sujo, Pasto Limpo, Cultura Agrícola, Área Urbana e Água (categorias básicas) além de Sombra e Nuvem (categorias de interferência). No processo de rotulação destes segmentos foi atribuído a cada categoria temática, graus de pertinência parciais (0,0; 0,25; 0,50; 0,75 e 1,0), entre os conceitos booleanos de falso e verdadeiro, dentro do procedimento que define o conceito de lógica nebulosa. Na arquitetura deste sistema classificador por rede neural foram consideradas para treinamento, as informações espectrais (média) e texturais (variância, correlação e entropia). Para avaliar os resultados preliminares da rede utilizaram-se os índices MSE (*Mean Square Error*), Sensibilidade e Especificidade. No treinamento da rede houve uma minimização do MSE com o número de épocas deste treinamento, indicando uma sensibilidade e especificidade coerente à identificação das geoclasses. No caso de comparação das classificações temáticas entre as abordagens ISOSEG e Máxima Verossimilhança e a imagem de referência, foi constatada a superioridade do algoritmo não supervisionado em função deste utilizar regiões resultantes da segmentação de imagens. É esperado que, em oportunidade futura, com a realização de uma equalização da rede, nova fase de treinamento e procedimento de classificação temática (associando descritores de vizinhança), seja possível a comparação deste processo classificatório com aqueles convencionais (ISOSEG e Máxima Verossimilhança) para um adequado entendimento da estratificação de classes de ocupação da terra na Amazônia Oriental.

IMAGE SEGMENTATION AND FUZZY LOGIC FOR TRAINING A NEURAL
NETWORK TO CHARACTERIZE LAND USE IN TUCURUI (PA)

ABSTRACT

Neural net-based segmentation and classification techniques of TM/LANDSAT imagery are presently being developed for the evaluation and monitoring of the deforested areas of Amazon. The good results obtained using this approach allowed to direct efforts towards a stratification of deforested areas, presently under agricultural use and fallow. As such, the objective of this work is the development of the process of image segmentation and labeling of the segments, using fuzzy logic sets as the basis for training of artificial neural nets, that are specialized in vegetation and land use classes in the region of Tucuruí (PA-Brazil). As a first step for a general evaluation of different image classification processes, including those based on neural nets, a comparison using KAPPA statistics is done between thematic images resulting from the use of traditional classification algorithms (ISOSEG, Maximum Likelihood). The study was developed over a part of the region under influence of the Tucuruí dam (SE of Pará State). The segmentation process of the imagery was based on spectral characteristics, using the regions-growth technique. A total of 15.033 segments were individually labeled: as basic categories, Forest, Advanced Secondary Succession, Initial Secondary Succession, Shrub Rangeland, Herbaceous Rangeland, Agricultural Land, Urban Land and Water, besides the interference categories of Shadows and Clouds. In the labeling process of those segments, they were attributed degrees of partial membership (0,0; 0,25; 0,50; 0,75 and 1,0), using the Boolean concepts of *true* and *false*, according to the procedures that define the fuzzy logic sets. Spectral characteristics such as average, as well as textural ones, such as variance, correlation and entropy, were considered for class training in the architecture of this neural net classifier system. Mean Square Error (MSE), Sensitivity and Specificity were used to evaluate the preliminary results of the network. The training aimed at minimizing the MSE with the number of seasons, indicating sensitivity and specificity coherent to the identification of geo-classes. The performance of the unsupervised classification algorithm against a reference image when using regions based on the image segmentation was superior when compared to the performance of ISOSEG and Maximum. For an adequate understanding of the stratification of land-cover classes in East Amazon, it is expected in the future, that a comparison of the proposed classification process with the conventional ones (ISOSEG and Maximum Likelihood) can be done after an equalization of the neural net and a new training phase.

SUMÁRIO

	Pág.
LISTA DE FIGURAS	xix
LISTA DE TABELAS	xxi
<u>CAPÍTULO 1 - INTRODUÇÃO E OBJETIVOS</u>	1
<u>CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA</u>	5
2.1 - O geoprocessamento como ferramenta no estudo do uso da terra	5
2.1.1 - Considerações Gerais	5
2.1.2 - Utilização de Imagens Orbitais para Caracterização da Vegetação e Uso da Terra	8
2.2 - Processamento de Imagens Digitais	11
2.2.1 - Considerações Gerais	11
2.2.2 - Técnicas de Pré-Processamento	12
2.2.2.1 - Correção Radiométrica	13
2.2.2.2 - Correção Geométrica e Registro de Imagens	13
2.2.2.3 - Atenuação Atmosférica	15
2.2.3 - Técnicas de Processamento de Realce	16
2.2.3.1 - Filtragem	16
2.2.4 - Técnicas de Segmentação	17
2.2.4.1 - Tipos de Segmentação	17
2.2.4.2 - Propriedades da Segmentação	18
2.2.4.3 - Crescimento de Regiões	20
2.2.5 - Técnicas de Classificação	23
2.2.5.1 - Classificação Supervisionada por Máxima Verossimilhança	24
2.2.5.2 - Redes Neurais Artificiais	25
2.2.5.3 - Classificação Não Supervisionada	29
2.3 - Estimativa da Exatidão de Mapeamento	30

CAPÍTULO 3 - MATERIAL E MÉTODO	35
3.1 - Área de Estudo.....	35
3.1.1 - Aspectos Fisiográficos e Climáticos.....	35
3.2 - Material.....	38
3.2.1 - Imagens de Satélite.....	38
3.2.2 - Material Cartográfico.....	38
3.2.3 - Infra-Estrutura Operacional.....	39
3.3 - Métodos.....	39
3.3.1 - Definição da Legenda Temática.....	40
3.3.2 - Trabalho de Campo.....	48
3.3.3 - Processamento Digital.....	49
3.3.3.1 - Registro de Imagens.....	50
3.3.3.2 - Reconhecimento de Padrões.....	50
3.3.3.3 - Segmentação de Imagens.....	51
3.3.3.4 - Inspeção das Médias dos Níveis de Cinza das Classes.....	52
3.3.3.5 - Elaboração da Imagem de Referência.....	53
3.3.3.6 - Classificação Não Supervisionada (ISOSEG).....	53
3.3.3.7 - Classificação Supervisionada por Máxima Verossimilhança.....	54
3.3.3.8 - Classificação Supervisionada por Redes Neurais Artificiais.....	55
3.3.4 - Análise Estatística.....	61
CAPÍTULO 4 - RESULTADOS E DISCUSSÃO	63
4.1 - Avaliação da Legenda Temática.....	63
4.2 - Avaliação das Técnicas de Pré-Processamento.....	64
4.2.1 - Registro de Imagens.....	64
4.3 - Segmentação de Imagens.....	65
4.4 - Reconhecimento de Padrões.....	68
4.5 - Rotulação de Segmentos.....	69
4.6 - Inspeção das Médias Espectrais.....	76
4.7 - Classificação Digital.....	80
4.7.1 - Classificação Não Supervisionada.....	80
4.7.2 - Classificação Supervisionada Maxver.....	82
4.7.3 - Análise Estatística.....	84

4.8 - Redes Neuras	87
<u>CAPÍTULO 5 - CONCLUSÕES E RECOMENDAÇÕES</u>	93
5.1 - Conclusões.....	93
5.2 - Recomendações.....	95
REFERÊNCIAS BIBLIOGRÁFICAS	97
APÊNDICE A - TABELAS	109
APÊNDICE B - PROGRAMAS DESENVOLVIDOS	113

LISTA DE FIGURAS

	Pág
2.1 - Fases do processamento digital de imagens	12
2.2 - Critério de similaridade	19
2.3 - Segmentação de imagens em regiões	20
2.4 - Início do processo de segmentação	21
2.5 - Segmentação de imagem com uma zona problema	22
2.6 - Função de distribuição espectral de algumas classes	25
2.7 - Modelo de neurônio artificial	27
2.8 - Rede Neural com uma Camada Escondida	27
3.1 - Localização da área de estudo	36
3.2 - Média de precipitação anual para a região de Tucuruí	37
3.3 - Média de precipitação mensal para a região de Tucuruí	38
3.4 - Pasto Limpo	42
3.5 - Pasto Sujo	43
3.6 - Cultura Agrícola	44
3.7 - Floresta Primária	45
3.8 - Sucessão secundária inicial	46
3.9 - Área de sucessão secundária avançada	47
3.10 - Localização dos pontos visitados no campo	49
3.11 - Fluxograma de atividades	51
3.12 - Sequência de preparação da rede neural	56
3.13 - Interface gráfica para rotulação nebulosa de segmentos	58
3.14 - Arquitetura do sistema classificador por redes neurais artificiais	62
4.1 - Perfil esquemático da paisagem na região de influência da represa de Tucuruí	63
4.2 - Exemplo de agrupamento das classes em função da legenda adotada no Programa de Desflorestamento da Amazônia	64
4.3 - Segmentação excessiva utilizando-se limiar de similaridade 6	66
4.4 - Sub-segmentação utilizando-se limiar de similaridade 14	67
4.5 - Segmentação considerada ideal com limiar de similaridade 10	68
4.6 - Comportamento dos níveis de cinza médios dos segmentos rotulados como Floresta, Sucessão Secundária Avançada e Sucessão Secundária Inicial nas Bandas TM/Landsat	71

4.7 - Percentual de combinações de pertinências para cada classe temática.....	71
4.8a - Distribuição dos números de combinações de pertinência entre classes para o tema Floresta.....	72
4.8b - Distribuição dos números de combinações de pertinência entre classes para o tema Sucessão Secundária Avançada.....	73
4.8c - Distribuição dos números de combinações de pertinência entre classes para o tema Sucessão Secundária Inicial.....	73
4.8d - Distribuição dos números de combinações de pertinência entre classes para o tema Pasto Sujo.....	74
4.8e - Distribuição dos números de combinações de pertinência entre classes para o tema Pasto Limpo.....	75
4.9 - Imagem de referência resultante do processo de rotulação de segmentos.....	76
4.10a - Média dos níveis de cinza de pixels e segmentos para Floresta.....	78
4.10b - Média dos Níveis de cinza de pixels e segmentos para S. S. Avançada.....	79
4.10c - Média dos níveis de cinza de pixels e segmentos para S. S. Inicial.....	79
4.10d - Média dos níveis de cinza de pixels e segmentos para Pasto Limpo.....	79
4.10e - Média dos níveis de cinza de pixels e segmentos para Pasto Sujo.....	80
4.10f - Média dos níveis de cinza de pixels e segmentos para Cultura Agrícola.....	80
4.11 - Imagem resultante do algoritmo de classificação ISOSEG.....	81
4.12 - Imagem resultante do algoritmo de classificação supervisionado (MAXVER).....	84
4.13 - Desempenho geral de cada classe temática nos algoritmos de classificação ISOSEG e Máxima Verossimilhança.....	87
4.14 - Minimização do MSE para as classes: Sombra (S), Sucessão Secundária Inicial (I), Pasto Limpo (L), Pasto Sujo (U), Área Urbana (R), Sucessão Secundária Avançada (V) e Floresta (F).....	88
4.15 - Minimização do MSE para Floresta.....	88
4.16 - Minimização do MSE para Sucessão Secundária Avançada.....	89
4.17 - Minimização do MSE para Sucessão Secundária Inicial.....	89
4.18 - Relação entre Sensibilidade, Especificidade e Distância para a classe Sucessão Secundária Avançada.....	90
4.19 - Relação entre Sensibilidade, Especificidade e Distância para a classe Sucessão Secundária Inicial.....	90

LISTA DE TABELAS

	Pág.
2.1 - Níveis de classificação e características típicas dos dados de sensoriamento remoto	6
2.2 - Características do sistema de classificação do uso da Terra por sensoriamento remoto.....	7
2.3 - Matriz de erro	32
2.4 - Qualidade da classificação associada a um valor de Kappa.....	32
3.1 - Cartas topográficas da DSM, escala 1:100.000 que recobrem a área de estudo ...	39
3.2 - Sistema de uso da terra e revestimento do solo para utilização com dados de sensoriamento remoto	41
4.1 - Apresentação dos índices de precisão obtidos para as etapas de registro de imagens.....	65
4.2 - Chave de interpretação visual em imagem TM 3B/4G/5R para as classes de uso da terra em Tucuruí (PA)	69
4.3 - Total de segmentos/pixels rotulados para formação da base de treinamento das redes neurais	70
4.4 - Total de segmentos/pixels rotulados para formação da imagem de referência (R2)	75
4.5 - Média do nível de cinza e desvio padrão das classes obtidos através da leitura de pixels.....	77
4.6 - Média do nível de cinza e desvio padrão obtidos após segmentação de imagens.	77
4.7 - Resultado do teste de médias entre os valores de nível de cinza e segmentos (95% de aceitação).....	78
4.8 - Resultado da classificação não supervisionada e sua associação com a legenda temática	81
4.9 - Área de cada classe obtida pelo algoritmo ISOSEG.....	82
4.10 - Matriz de classificação Maxver a partir do subconjunto de bandas TM1 a 5 e 7	83
4.11 - Área de cada classe obtida pelo algoritmo de classificação por máxima verossimilhança	84
4.12 - Matriz de erro para a imagem de referência e algoritmo ISOSEG.....	85

4.13 - Matriz de erro para a imagem de referência e algoritmo Maxver	85
4.14 - Resultado da estatística Kappa.....	87

CAPÍTULO 1

INTRODUÇÃO E OBJETIVOS

"Nos anos 70, depois de décadas de abandono entrecortados por aventuras malogradas, a Amazônia começou a atrair a atenção e a cobiça dos homens, afinal convencidos de que era necessário incorporá-la de alguma forma ao processo de desenvolvimento brasileiro" (Pinto, 1981). Desde então desenvolveu-se uma crescente corrente migratória à região com milhares de agricultores deslocando-se das diversas regiões do país em busca de facilidades de aquisição de terras. A política de incentivos fiscais à agropecuária e mais recentemente aos projetos industriais e de mineração aumentaram consideravelmente este contingente humano. A consequência desta invasão nos dias de hoje, é uma ocupação desorientada e predatória do campo, causadora de grandes conflitos pela posse da terra.

A alteração da paisagem e do uso da terra da Amazônia deve-se principalmente à aplicação de técnicas agropecuárias e de mineração de origem dos migrantes, nem sempre próprias para o ambiente amazônico. Estas alterações vem sendo motivo de discussões em vários segmentos da sociedade e envolvem em linhas gerais, a velocidade da ocupação do espaço, o aproveitamento racional dos recursos naturais disponíveis e a degradação desse espaço pela má utilização desses recursos.

Em função dessa rápida dinâmica de ocupação da região, caracterizada por elevadas taxas de alteração da cobertura da terra e devido à sua grande extensão territorial, torna-se necessária a utilização de técnicas de sensoriamento remoto para um efetivo monitoramento dos recursos naturais. Os dados oriundos de plataformas orbitais são caracterizados pela visão sinótica, repetitividade e possibilidade de detecção da radiação em diversas faixas de comprimentos de onda, o que transforma as técnicas de sensoriamento remoto em um instrumento de gerenciamento ambiental muito indicado à região.

Essas técnicas já vem sendo utilizadas com sucesso para todos os Estados da região, observando-se porém uma demora na obtenção destas informações pois, o processo de obtenção ainda é realizado, via de regra, de forma manual, exigindo um alto custo e elevado número de técnicos especializados.

A ideia de utilizar a classificação digital como ferramenta para o levantamento e monitoramento dos recursos naturais na Amazônia é antiga e reside no fato da importância da região na conservação de recursos genéticos pouco conhecidos e no controle do clima global. Dessa forma, faz-se necessário um acompanhamento rápido, seguro e economicamente viável das transformações que lá ocorrem.

Métodos convencionais de classificação estatística (pixel a pixel), limitados ao uso de atributos espectrais, têm sido empregados na análise de imagens digitais. No entanto, considerando que estes algoritmos de classificação utilizam apenas o atributo espectral para a análise, esta fica prejudicada já que outras informações contidas nas imagens de sensores remotos, tais como a textura e o contexto, que poderiam auxiliar na separabilidade das classes, não são utilizadas.

Técnicas baseadas na segmentação de imagens e posterior classificação através de sistemas supervisionados e não supervisionados, apresentam-se como uma possível alternativa para a automação do processo de levantamento de informações sobre as diversas formas de ocupação da terra. O bom desempenho desses processamentos tem permitido que se obtenham resultados confiáveis em um curto espaço de tempo.

Nestas abordagens, a fase de análise é precedida por uma fase de segmentação, onde são formadas regiões que exibem alguma uniformidade interna com respeito a propriedades da imagem e contrastam com a sua vizinhança. Posteriormente essas imagens são submetidas aos algoritmos de classificação de regiões os quais extraem os objetos relevantes da imagem, utilizados na classificação, tais como as médias espectrais e a variância no sistema não-supervisionado, mais a textura e vizinhança (informação de contexto) de cada região, no método supervisionado.

Deste modo, delineia-se como objetivo geral deste trabalho, o desenvolvimento do processo de segmentação de imagens e rotulação de segmentos utilizando a lógica nebulosa como suporte para treinamento de redes neurais artificiais especializadas em classes de vegetação e uso da terra na região de Tucuruí (PA).

Os objetivos específicos deste trabalho são: 1) Estabelecer critérios de rotulação de segmentos via lógica nebulosa para classes de uso da terra na região de Tucuruí (PA); 2) Realizar o treinamento de redes neurais para as classes de uso estabelecidas após trabalho de campo; 3) Avaliar o desempenho do treinamento das

redes neurais através dos critérios Sensibilidade, Especificidade e Erro Médio Quadrático (MSE); 4) Caracterização da vegetação e outros usos da terra, fazendo uso de dois sistemas de classificação tradicionais de imagens; e 5) Avaliar o desempenho dos algoritmos de classificação tradicionais em relação a uma imagem de referência utilizando procedimentos de estatística Kappa.

É oportuno registrar que os objetivos 4 e 5 são fases preparatórias e foram elaborados dentro de um procedimento contextual de pesquisa que, em prosseguimento ao atual trabalho, permitirá uma análise comparativa entre as informações temáticas oriundas de classificadores convencionais e aquele da rede neural.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados alguns tipos de sistemas de classificação de uso da terra, bem como uma revisão de alguns trabalhos onde foram utilizadas imagens orbitais para a caracterização da vegetação e do uso da terra na Amazônia e em outras regiões. Adicionalmente, será apresentada uma visão geral das várias técnicas utilizadas para processamento digital de imagens de modo a obter uma melhoria da qualidade dos dados, classificá-los de acordo com uma legenda pré-estabelecida e avaliar a qualidade dos produtos gerados, através de análises estatísticas, a partir da verdade terrestre.

2.1 - O GEOPROCESSAMENTO COMO FERRAMENTA NO ESTUDO DO USO DA TERRA

2.1.1 - CONSIDERAÇÕES GERAIS

Entende-se de maneira geral o uso da terra como sendo a posição no espaço assumida pelas diferentes formas de cobertura do solo, sejam naturais ou desenvolvidas pelo homem. Para Santos et al. (1981), refere-se à descrição das características da paisagem em uma época determinada, sem levar em conta sua vocação ou uso futuro. Estes autores salientam ainda que os estudos do uso da terra são fundamentais para o planejamento regional, pois irão superar problemas de desenvolvimento descontrolado e de deterioração da qualidade ambiental pela perda de terras agrícolas.

No intuito de possibilitar análises da tendência de ocupação da cobertura da terra é necessário entretanto que os trabalhos de levantamento e avaliação deste uso sejam constantemente atualizados. Devido aos elevados custos envolvidos no emprego dos métodos tradicionais para a execução dos trabalhos de levantamento do uso da terra, a imensa maioria das regiões do país não dispõem dos mesmos. Com o lançamento dos satélites destinados à coleta de dados de os recursos naturais, tornou-se possível a obtenção de informações da cobertura terrestre a um custo relativamente baixo com elevada frequência de repetição.

A utilização de informações obtidas a nível orbital como ferramenta para o levantamento e atualização do uso da terra mostrou-se valiosa nos trabalhos desenvolvidos por Lins Jr. (1976), Novo (1978) e Pereira et al.(1987), sendo enfatizadas as vantagens da manipulação dos dados bem como a facilidade de aquisição dos mesmos.

Para compatibilizar os produtos gerados a partir de dados orbitais oriundos de diversos tipos de sensores e escalas, Anderson et al. (1979) desenvolveram um sistema de classificação, objetivando padronizar as legendas dos mapas do uso da cobertura vegetal da terra (Tabela 2.1).

TABELA 2.1 - NÍVEIS DE CLASSIFICAÇÃO E CARACTERÍSTICAS TÍPICAS DOS DADOS DE SENSORIAMENTO REMOTO ORBITAL

Nível de Classificação	Características Típicas dos Dados
I.....	Tipo de dados Landsat (anteriormente ERTS).
II.....	Dados de grande altitude, tomados a 12.000 m ou mais (escala menor que 1:80.000).
III.....	Dados de altitude média tomados entre 3.100 m e 12.400 m (escala 1:20.000 a 1:80.000).
IV.....	Dados de baixa altitude tomados a menos de 3.100 m (escala maior que 1:20.000).

FONTE: Anderson et al (1979).

O Sistema de Classificação de Anderson et al. (1979) foi organizado hierarquicamente, sendo subdividido em vários níveis, onde o primeiro é o mais genérico. Tal sistema apresenta um grau de detalhamento maior, com a utilização de produtos de diversas escalas e resoluções que possibilitando uma melhor discriminação das classes presentes.

Recentemente, com o lançamento dos satélites de segunda geração, dotados de sensores mais avançados e de maior resolução espacial, este panorama foi alterado. Desta forma, os estudos sobre a vegetação e uso da terra passaram a contar com instrumentos mais poderosos a partir dos dados do sensor Thematic Mapper dos satélites da série Landsat 4 e 5 e do sensor HRV do satélite SPOT, havendo então a necessidade de desenvolvimento de outros sistemas de classificação adaptados à nova realidade. Dentre estes sistemas de classificação citam-se aqueles desenvolvidos por Jensen (1983), que descreve as características do sistema de classificação do uso da terra associado aos dados sensoriados (Tabela 2.2) e de Pereira et al. (1987).

TABELA 2.2 - CARACTERÍSTICAS DO SISTEMA DE CLASSIFICAÇÃO DO USO DA TERRA POR SENSORIAMENTO REMOTO

CRITÉRIOS	NÍVEL I	NÍVEL II	NÍVEL III	NÍVEL IV
Utilização Principal	Nacional	Nacional	Estadual / Regional	Local
Escala de Mapeamento	1: 250.000- 1:1.000.000	1: 125.000- 1:250.000	1: 50.000 - 1:125.000	1: 25.000- 1:50.000
Unidade Mínima Mapeável	95 ha - 1497 ha	24 ha - 95 ha	4 ha - 25 ha	0,8 ha - 4 ha
Base para Classificação	Cobertura do Solo	Cobertura do Solo	Cobertura / Atividade	Cobertura / Atividade
Fonte de Dados	Interpretação de Imagens	Interpretação de Imagens	Interpretação de Imagens e Dados de Campo	Interpretação de Imagens e Dados de Campo

FONTE: Adaptada de Jensen (1983).

Segundo Jensen (1983), a discussão sobre a unidade mínima mapeável deve ser centralizada na habilidade do sensor em detectar, identificar e classificar diferentes modelos de cobertura da terra. Desta forma, com a evolução dos sistemas de aquisição de dados, novos valores de área mínima mapeável passarão a ser utilizados, de forma que possam atender às necessidades de cada projeto.

2.1.2 - UTILIZAÇÃO DE IMAGENS ORBITAIS PARA CARACTERIZAÇÃO DA VEGETAÇÃO E USO DA TERRA

Os dados multiespectrais obtidos através de plataformas orbitais podem ser apresentados sob a forma de papel ou transparência fotográfica e fitas compatíveis com sistemas analisadores de imagens. Os produtos digitais apresentam-se mais "flexíveis" de serem manipulados na medida em que permitem a aplicação de técnicas de processamento digital de imagens.

Em ambientes tropicais úmidos, os estudos sobre a cobertura e uso da terra, apesar de não serem muito numerosos, representam hoje uma fonte valiosa de informações sobre esses ecossistemas que vem sofrendo rápidas mudanças.

Dentro do contexto do programa de monitoramento da cobertura vegetal da Amazônia Legal, Tardin e Cunha (1989) realizaram uma avaliação da alteração antrópica em áreas sob o domínio da vegetação com fisionomia florestal, a partir da análise visual de imagens do satélite TM/Landsat. Nos resultados obtidos foi constatada a eficiência desses produtos orbitais, na escala 1:250.000, para detecção e avaliação de áreas desflorestadas.

Considerando imagens temáticas do Landsat sob a composição colorida TM3-B/TM2-G/TM4-R, na escala 1: 250.000, Almeida et al. (1990) utilizaram a interpretação visual de imagens em papel e trabalho de campo para definição das classes: formações florestais e áreas urbanas, com o objetivo de identificar e analisar os recursos naturais do Estado do Mato Grosso. Foi também utilizando a interpretação visual de imagens, trabalhando com as bandas TM 3 e TM 4, em papel fotográfico Branco&Preto na escala 1: 100.000, para o levantamento do desmatamento e uso da terra no Estado do Acre, que Lunz et al. (1990) identificaram como áreas de pastagens, agricultura, açudes, áreas urbanas, colonização de seringueiros, colônias, roçados e projetos de colonização.

Utilizando ainda a interpretação visual de imagens, Rosa (1990) realizou o levantamento e mapeamento do uso da terra, em ambiente de cerrado na região de Uberlândia (MG). Foram utilizadas imagens em papel TM/Landsat, bandas TM 3, 4 e 5 isoladamente (Branco&Preto) e composições coloridas TM1-B/TM2-G/TM3-R e TM2-B/TM3-G/TM4-R, na escala 1: 100.000. Foram identificadas as classes de área urbana, mata, cerrado, eucaliptos, pinus, culturas perenes, culturas

temporárias, pastagem natural, pastagem plantada e água. Nascimento e Motti (1990) utilizaram as imagens em papel TM/Landsat, bandas 4 e 5, na escala 1: 50.000, para o mapeamento do uso da terra em região de cerrado, no oeste do Estado da Bahia. Foram identificadas e mapeadas as áreas de culturas, reflorestamento, campos de origem antrópica, queimadas e pastagens.

Miranda e Mattos (1990) trabalharam com as imagens TM/Landsat, em papel fotográfico, bandas 3, 4 e 5, (Branco&Preto) e composições coloridas (TM B3 4G 5R), escala 1: 250.000, para identificação dos temas relacionados ao uso da terra no Estado de Rondônia. Foram cartografadas as classes de área urbana, culturas, pastagem, campo cerrado, várzea, cerrado e floresta.

Watrin e Rocha (1992) no levantamento semi-detalhado (escala 1:100.000) da vegetação e do uso da terra no município de Paragominas (PA), utilizaram produtos em papel Branco&Preto, bandas TM 3 e TM4 e mapearam as classes de floresta densa, exploração madeireira, agropecuária e capoeira. Para definição daquela legenda, os dados e informações obtidas no trabalho de campo mostraram-se muito valiosos, na medida em que otimizaram a interpretação das imagens TM/Landsat.

Com o objetivo de conhecer a dinâmica de ocupação da terra e mapear a vegetação natural e o uso da terra, na região de Jaurú (MT), Arima et al. (1993) utilizaram imagens TM, composição colorida 3B 4G 5R, escala 1:100.000, e 2B 3G 4R, escala 1:250.000. Utilizando interpretação visual das imagens em papel, foi possível a identificação das classes de floresta, áreas de transição floresta/cerrado, pastagens cultivadas e áreas com edificações.

Lima e Lima (1993) com o intento de diagnosticar a cobertura vegetal natural e antrópica na região do Triângulo Mineiro (MG), utilizaram a interpretação visual das imagens TM/Landsat em papel, na escala 1:100.000, composição colorida 2B/4G/5R. Os autores discriminaram as classes de mata, cerrado, cerradão, mata galeria, água, pastagem, pinus, eucalipto, cultura temporária, cultura perene e área urbana.

Visando o mapeamento de projetos agropecuários na região de Santana do Araguaia (PA), Medeiros et al. (1988) utilizaram as bandas TM3-B/TM5-G/TM4-R na forma de diapositivos coloridos, escala 1: 500.000, bem como as bandas

individuais em papel fotográfico Branco&Preto, escala 1: 100.000, e fitas CCT. Através da aplicação integrada de técnicas de interpretação visual de imagens e processamento digital de imagens, foi possível a caracterização das classes, tais como: mata, pasto limpo, pasto sujo, pasto muito sujo, pastagem em formação, solo exposto, infraestrutura, capoeira, queimada, estradas e represas, representadas em mapas temáticos na escala 1:100.000. No entanto, Sano et al. (1989) modificaram esta técnica ao trabalharem em três microrregiões do nordeste do Estado do Pará, utilizando interpretação visual de módulos na escala 1:50.000 de imagens realçadas por ampliação linear de contraste. Puderam ser discriminadas três classes de cobertura vegetal (floresta primária, vegetação secundária e campo natural) e cinco classes de uso da terra (cultura agrícola intensiva, cultura agrícola extensiva, reflorestamento, pastagem e queimada) sendo que o mapa final foi elaborado em escala de semi-detulhe, 1: 100.000.

Venturieri et al. (1990) utilizaram imagens em papel fotográfico Branco&Preto (banda TM 5) e no formato digital as bandas TM3-B/TM4-G/TM5-R, que foram processadas pelo Sistema de Tratamento de Imagens (SITIM), para a caracterização do uso da terra na região de Tucuruí (PA). Através da classificação supervisionada por máxima verossimilhança foram identificadas as classes de floresta, capoeira, cultura agrícola, pasto sujo, pasto limpo, área queimada, solo exposto e água. As vantagens oferecidas pelo processamento digital de imagens, como realces e filtragens para identificação de alvos específicos fez com que González et al. (1993) também utilizassem imagens TM no formato digital, para o levantamento do uso da terra na região do lago de Valencia, Venezuela. Foram identificadas as classes de áreas agrícolas, uso urbano e industrial, floresta, vegetação secundária, cerrado, água, queimada e nuvem. Segundo os autores, a utilização das combinações TM1-B/TM4-G/TM5-R e TM2-B/TM3-G/TM4-R possibilitou a obtenção de elevada quantidade de informações sobre o uso da terra.

Moran et al. (1993) utilizaram uma abordagem de classificação digital híbrida, considerando um algoritmo de classificação não supervisionado como subsídio para coleta de amostras de treinamento em algoritmo supervisionado utilizando imagens TM/Landsat, em estudo da dinâmica da vegetação e uso da terra em área da rodovia BR-010 (Transamazônica), município de Altamira (PA). Dentre outras contribuições de tal estudo, destaca-se a diferenciação das etapas de sucessão secundária no leste amazônico, denominadas de inicial, intermediária e avançada. Abordagem

semelhante foi utilizada por Brondízio et al. (1993) para a região de Ponta de Pedras (PA) e Watrin (1994) na região de Tomé-Açu (PA).

O que se pode observar é que cada vez mais dados obtidos através de plataformas orbitais estão sendo utilizados para o levantamento e monitoramento dos recursos naturais em ambientes tropicais. Os trabalhos desenvolvidos na região amazônica têm apresentado resultados satisfatórios e possuem um baixo custo quando comparados aos métodos convencionais.

A utilização de técnicas de processamento de imagens digitais constituem ferramentas poderosas para retificar, realçar e classificar imagens orbitais, sendo as mesmas de grande aplicação na área de recursos naturais. Dentre estes processamentos, serão tratados a seguir, de forma sucinta, algumas técnicas que estão ligadas à abordagem metodológica do presente trabalho.

2.2- PROCESSAMENTO DE IMAGENS DIGITAIS

2.2.1 - CONSIDERAÇÕES GERAIS

A utilização de sistemas computacionais para auxiliar o elemento humano, na interpretação das informações contidas em imagens de sensores remotos, é a principal característica do processamento digital de imagens. Segundo Crósta (1992) este procedimento facilita a identificação e a extração das informações das imagens para análises posteriores.

O processamento digital de imagens foi subdividido por Taranik (1978) e Schowengerdt (1983) em três fases, denominadas de:

- Técnicas de Pré-Processamento,
- Técnicas de Realce e;
- Técnicas de Classificação

Com a inclusão das técnicas de segmentação de imagens, a referida sub-divisão passa a contar com uma fase alternativa, dentre as técnicas de realce e classificação. Na Figura 2.1 são apresentados os dois modelos referentes às fases do processamento digital.

2.2.2 - TÉCNICAS DE PRÉ-PROCESSAMENTO

O pré-processamento refere-se ao conjunto de técnicas utilizadas inicialmente nos dados originais obtidos por sensores remotos. Segundo Novo (1989), as técnicas de pré-processamento permitem a transformação de dados digitais brutos em dados radiométrica e geometricamente corrigidos.

A utilização dessas técnicas se faz necessária pois, segundo Menezes et al. (1991), é comum os dados das imagens de sensores remotos apresentarem algum tipo de degradação. Estas degradações são devidas a desajustes de calibração dos detetores, mal funcionamento esporádico do sensor, problemas na transmissão, recepção e registro dos dados, interferência na radiância por efeitos atmosféricos e distorções na forma dos pixels causadas por variações da atitude e altitude da plataforma.

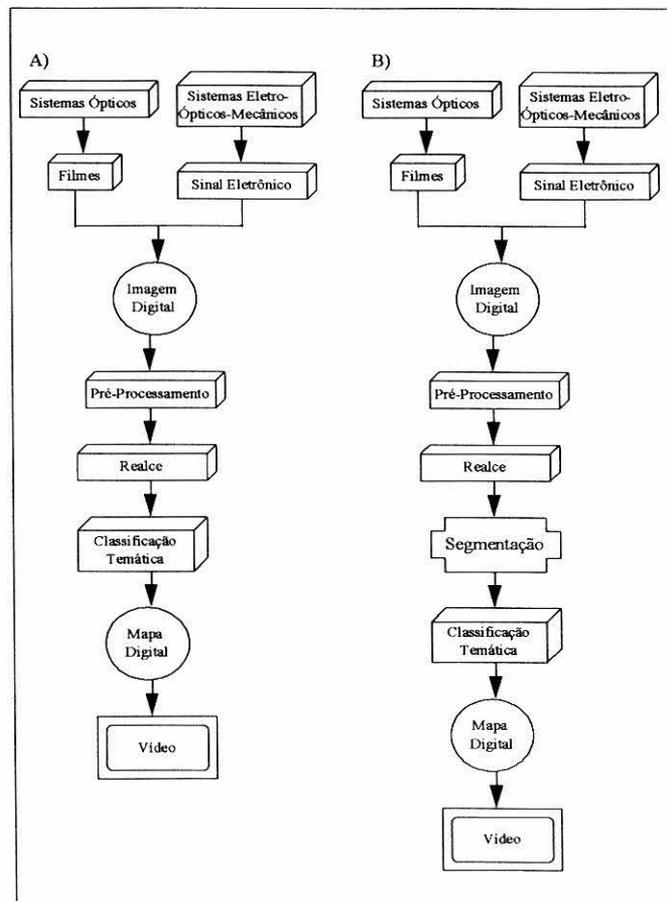


Fig 2.1 - Fases do processamento digital de imagens.

a) Modelo tradicional; b) Modelo incluindo a segmentação de imagens

FONTE: Modificada a partir de Schowengerdt (1983)

2.2.2.1 - CORREÇÃO RADIOMÉTRICA

A ocorrência de algumas degradações nas imagens de sensoriamento remoto, como desajustes de calibração dos detetores, mal funcionamento esporádico do sensor, problemas na transmissão, recepção e registro dos dados ocasionam o aparecimento de pixels com valores digitais alterados, conhecidos como ruídos. Segundo Schowengerdt (1983), um ruído severo é suficiente para degradar a qualidade da imagem e impedir a extração de informações da mesma.

Para Menezes (1991) os ruídos são classificados como tipos coerentes, quando ocorrem em um padrão sistemático, contínuo e aleatórios quando não possuem um padrão definido de ocorrência. Como ruído coerente destaca-se o "stripping", que é o aparecimento de faixas horizontais com abruptas mudanças de brilho devido a diferença de resposta do conjunto de detetores de uma banda. Entre os ruídos aleatórios o autor destaca as linhas de dados ruins ("dropped lines") e os pixels isolados.

As linhas de dados ruins estão relacionadas com a má qualidade de pixels ao longo da linha ou mesmo perda de informação devido a saturação de algum detetor ou problemas de processamento dos dados recebidos das plataformas orbitais. Os pixels isolados ocorrem devido perda de informação na transmissão dos dados, rápida saturação do detetor ou outras interferências eletrônicas (Schowengerdt, 1983).

A utilização de filtros passa-baixa é citada por Schowengerdt (1983) como opção para eliminação dessas interferências, destacando porém que utilização desta técnica apresenta como desvantagem a desfocagem da imagem simultaneamente com a eliminação do ruído.

2.2.2.2 - CORREÇÃO GEOMÉTRICA E REGISTRO DE IMAGEM

Para Richards (1986), as distorções geométricas observadas em imagens orbitais devem-se a fatores tais, como rotação da Terra durante o tempo de imageamento, instabilidade da plataforma e grande campo de visada de alguns sensores. A rotação da Terra durante o tempo de imageamento faz com que ocorra um deslocamento relativo dos conjuntos de linhas da imagem para oeste.

Segundo Richards (1986), as distorções geométricas causadas pela variação de altitude provocam uma distorção na escala, enquanto as variações na

velocidade da plataforma provocam mudanças na escala ao longo da direção da órbita. O autor comenta ainda da ocorrência de distorções relativas ao deslocamento da plataforma em relação ao seu eixo, ou deslocamentos de atitude.

De acordo com Davison (1986), embora os dados das plataformas orbitais sejam corrigidos de distorções, existe um grande número de usuários necessitado de imagens transformadas geometricamente, sendo este processamento é realizado para:

- Localização de pontos comuns em diferentes cenas da mesma área;
- Realizar análises multi-temporais pela sobreposição de imagens da mesma área adquiridas em diferentes datas;
- Juntar imagens adjacentes para serem mosaicadas e;
- Sobrepor imagens da mesma área produzida por diferentes sensores.

Segundo Schowengerdt (1983), o modelo mais comum de correção geométrica consiste em estabelecer relações matemáticas entre as posições dos pixels na imagem e as correspondentes coordenadas destes pixels no terreno, através de mapas geometricamente corretos. Para a determinação do valor do pixel da imagem de saída é escolhido um valor análogo na imagem original, sendo tal valor calculado através do processo de interpolação. Para este fim, Davison (1986) destaca a utilização de três técnicas: interpolação do vizinho mais próximo, interpolação bilinear e interpolação por convolução cúbica.

Segundo Davison (1986) a interpolação por vizinho mais próximo preserva a qualidade radiométrica da imagem original pois, neste processo, ocorre somente a transferência do valor do pixel da imagem de entrada para a imagem de saída. O autor comenta ainda que este processo introduz distorções geométricas localizadas nas imagens. O interpolador bilinear corrige as distorções geométricas mas atua como um filtro passa baixa, introduzindo erros radiométricos. Neste processo o valor do pixel na imagem de saída é resultante da média dos quatro pixels vizinhos, próximos ao pixel da imagem de entrada. O interpolador por convolução cúbica é considerado pelo autor como ideal para a utilização em registros de imagens, porém com aumento substancial do tempo computacional. Neste processo, é utilizada a média dos 16 pixels da imagem de entrada para o cálculo do pixel resultante na imagem de saída.

Belaid et al. (1992) realizaram o registro entre imagem HRV/Spot com carta topográfica antes da classificação de segmentos em áreas de pequena agricultura.

Moran et al. (1993) utilizaram o registro de imagens de duas datas diferentes, visando a formação de uma imagem multi-temporal de 12 canais no estudo da dinâmica da paisagem da Amazônia Oriental.

Santos et al. (1993) utilizaram o registro da imagem TM/Landsat versus mapa, objetivando introduzir a imagem corrigida geometricamente no SGI/INPE, a fim de que esta fosse sobreposta com os planos de informação digitalizados, para avaliação da classificação não supervisionada baseada em segmentos, na definição das classes de vegetação e uso da terra no norte do Mato Grosso.

2.2.2.3 - ATENUAÇÃO ATMOSFÉRICA

Segundo Slater (1980), a atmosfera afeta a radiação recebida pelo sensor de diferentes maneiras, ou seja:

- 1) Atenuando o fluxo solar incidente sobre o alvo;
- 2) Atenuando a radiação que chega ao sensor, vinda diretamente do alvo; e
- 3) Contribuindo com a radiação espalhada, não proveniente do alvo no campo de visada do sensor e, conseqüentemente, confundindo as características espectrais dos diferentes alvos.

Taranik (1978) comenta que a atmosfera influi de duas maneiras nos dados de sensores remotos: através da absorção e do espalhamento, causados pelos aerossóis, gases e moléculas d'água em suspensão. O processo de absorção subtrai valores de brilho nas imagens para as regiões de grandes comprimentos de onda, devido a absorção de energia pelas moléculas d'água em tais regiões do espectro eletromagnético. Assim, a absorção reduz os níveis mínimos de brilho das bandas do infravermelho para valores próximos a zero.

O processo de espalhamento atua adicionando valores de brilho ao sinal detectado pelo sensor, obedecendo a uma relação inversamente proporcional a

¹Sistema Geográfico de Informações.

quarta potência do comprimento de onda, conhecido como espalhamento Rayleigh. Isso significa que os menores comprimentos de onda (região do visível) são os mais afetados pelos efeitos do espalhamento.

2.2.3 - TÉCNICAS DE PROCESSAMENTO DE REALCE

Entende-se por técnicas de realce de imagens como um conjunto de aplicativos desenvolvidos para processamento digital de imagens, visando aumentar a qualidade visual da cena como um todo, ou apenas feições específicas. Tais técnicas são realizadas através de funções matemáticas modificando a distribuição dos níveis de cinza das imagens originais, auxiliando desta maneira a extração de informações.

Segundo Crósta (1992), os dados contidos em uma imagem orbital dificilmente distribuem-se por todo o intervalo disponível dos níveis de cinza (256 no sensor TM/Landsat). Deste modo, os histogramas que representam a distribuição de frequência dos níveis de cinza em número de pixels numa imagem, apresentam-se comprimidos, com pequena variância, resultando em baixo contraste visual na imagem.

Como o sistema visual humano consegue distinguir no máximo de 30 a 60 tons de cinza, quando bem distribuídos em um intervalo de 0 a 255, é necessário fazer as informações contidas no histograma sejam então expandidas para ocupar todo o intervalo possível, e assim facilitar a extração das informações de interesse. Dentre estas técnicas será tratada aquela de interesse neste trabalho.

2.2.3.1 - FILTRAGEM

De acordo com Moik (1980) a filtragem é basicamente uma operação do processamento de imagens, utilizada na restauração radiométrica e realce de imagens. Schowengerdt (1983) comenta que esta transformação, pixel-a-pixel, não depende somente do pixel processado mas também do nível de cinza dos pixels vizinhos. Desta forma a filtragem espacial é uma operação dependente do contexto, alterando o nível de cinza do pixel, de acordo com seu relacionamento com os níveis de cinza dos pixels vizinhos.

Nas imagens de sensoriamento remoto, regiões onde ocorre uma grande variação dos níveis de cinza em pequenas áreas são conhecidas como de altas frequências. Quando a distribuição dos níveis de cinza em uma região é mais uniforme, com limites menos nítidos, é chamada de imagem de baixa frequência (Crósta, 1992)

Segundo o autor, a grande mistura de frequências em uma imagem dificulta a interpretação de feições com padrões específicos. Para resolver este problema, são utilizadas as técnicas de filtragem espacial, visando realçar seletivamente as feições de alta ou baixa frequência componentes das imagens.

2.2.4 - TÉCNICAS DE SEGMENTAÇÃO

A segmentação é o processo que subdivide uma imagem em suas partes constituintes ou objetos (regiões), de acordo com algumas propriedades intrínsecas da imagem, isto é, nível de cinza, contraste ou propriedades texturais (Moigne e Tilton, 1992). Para Woodcock e Harward (1992) o objetivo da segmentação de imagens é particionar a imagem em um conjunto de regiões correspondentes a feições na superfície terrestre servindo de base para análises futuras.

De acordo com Gonzales e Wintz (1987), a segmentação é muito importante no processamento digital de imagens pois, através dela objetos ou outras entidades de interesse são extraídos de uma imagem para subseqüentes processamentos como a descrição e o reconhecimento. Desta forma, segundo Haralick e Shapiro (1985), uma região resultante do processo de segmentação deve-se apresentar de forma uniforme e homogênea com respeito ao nível de cinza e textura, possuindo da mesma forma tais características diferentes das vizinhas que a cercam.

Para Schoenmakers et al. (1991), apesar das técnicas de segmentação de imagens serem utilizadas há algum tempo no processamento digital de imagens o assunto não está esgotado existindo ainda muita pesquisa a ser realizada.

2.2.4.1 - TIPOS DE SEGMENTAÇÃO

Segundo Hautakoski (1989), as técnicas de segmentação podem ser classificadas em três métodos: por agrupamento espectral, baseado em bordas e baseado em regiões homogêneas.

- a) Método baseado em agrupamento espectral (spectral clustering) - Neste método os pixels de uma imagem irão pertencer a uma determinada região após a definição de superfícies de borda em um espaço de medida n-dimensional. Após a definição destas superfícies, cada pixel é agrupado dentro das regiões sugerida pela média.

- b) Método baseado em borda - A meta é encontrar descontinuidades nas imagens. Primeiramente a imagem é "varrida" e então é calculada a probabilidade de cada pixel pertencer a uma borda. Isto é realizado com algum operador local, como o operador gradiente. Posteriormente esses pixels são ligados para a formação das bordas contínuas.
- c) Método baseado em regiões - O interesse são os pixels interiores de regiões homogêneas definidas por um determinado critério de homogeneidade. Os métodos mais comuns são: crescimento de regiões, junção de regiões, separação de regiões e o método híbrido de junção e separação de regiões.

2.2.4.2 - PROPRIEDADES DA SEGMENTAÇÃO

Os algoritmos de segmentação são geralmente baseados em uma das duas propriedades básicas dos valores de nível de cinza: descontinuidade e similaridade (Gonzalez e Wintz, 1987).

a) DESCONTINUIDADE

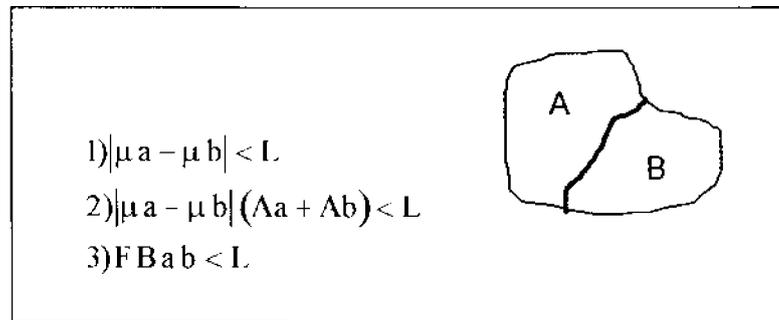
No processo de descontinuidade a imagem é fragmentada com base nas mudanças abruptas dos níveis de cinza. As áreas de maior interesse nesta categoria são: detecção de pontos isolados, linhas e bordas em uma imagem. Maiores detalhes sobre este procedimento podem ser observados em Robison (1977), Hueckel (1978) e Lacroix (1988).

De acordo com Gonzalez e Wintz (1987), na abordagem de descontinuidade, o procedimento mais comum para a realização da segmentação é a detecção de bordas. Segundo Schoenmakers et al. (1991), o método de extração de bordas é o processo pelo qual os fragmentos de bordas são definidos e posteriormente compostos em uma estrutura mais elaborada representando uma fronteira de classe homogênea. O método mais comum para a realização deste procedimento de acordo com Moik (1980) consiste em ressaltar as bordas seguido de uma operação de limiarização para determinar a localização de bordas significativas.

b) SIMILARIDADE

A propriedade de similaridade pode ser definida em termos de proximidade radiométrica. As principais aplicações de similaridade (Figura 2.2) estão

baseadas na limiarização, junção de região, separação de região, separação e junção de regiões e crescimento de regiões (Gonzales e Wintz, 1987 e Hautakoski, 1990). Desta forma, dois pixels vizinhos serão similares caso o valor absoluto da diferença entre seus níveis de cinza seja suficientemente pequena de forma a permitir que sejam conectados por um arco.



onde, L = Limiar

μ_a e μ_b = média do objeto

A_a e A_b = área do objeto

F_{Bab} = força da borda

Fig 2.2 - Critério de similaridade

FONTE: Erthal (1992).

Para Haralick e Shapiro (1985), em uma imagem que apresente objetos brilhantes contra um fundo escuro, estes poderão agrupar-se de forma satisfatória mediante a aplicação de um limiar, de forma que os pontos menores ou iguais ao limiar serão atribuídos em um agrupamento (“cluster”) e os pontos restantes serão atribuídos a um segundo agrupamento.

Segundo Hautakoski (1989) o processo de junção é realizado sobre uma imagem extremamente segmentada, onde então procura-se juntar as áreas vizinhas similares dentro de uma única região. O processo de separação começa com uma imagem sub-segmentada, procurando-se posteriormente encontrar uma segmentação ótima pela separação das regiões não homogêneas em homogêneas.

Ainda de acordo com Hautakoski (1989) o processo de separação e junção, consiste na combinação dos métodos tratados anteriormente, ou seja, os processos de junção e separação de regiões. Neste processo é realizada uma segmentação, assumida inicialmente não “ser satisfatória”. As tentativas de separação e

junção para encontrar a segmentação correta são realizadas pelo particionamento das regiões não homogêneas em partes e posteriormente é executada a junção das regiões homogêneas. Quando uma região é separada, suas partes podem ser unidas dentro de alguns de seus vizinhos, desde que estes obedeçam ao critério de similaridade previamente estabelecido.

Segundo Schoenmakers et al. (1991), no método de crescimento de regiões, o princípio básico é o agrupamento de pixels com características similares em regiões contínuas. Para Hautakoski (1989) neste processo as regiões tendem a crescer pela junção adequada de pixels vizinhos. Devido ser este o processo implementado no Sistema de Processamento de Informações Georeferenciadas (SPRING), maiores detalhes sobre o mesmo serão abordados no item 2.2.4.3.

De acordo com Moik (1980), uma segmentação do domínio R de uma imagem (Figura 2.3) é um conjunto finito de regiões, $\{R_1, R_2, \dots, R_n\}$ tal que:

$$R = \bigcup_{i=1}^j R_i$$

$$R_j \cap R_i = 0 \longrightarrow \text{para } j \neq i \quad (2.1)$$

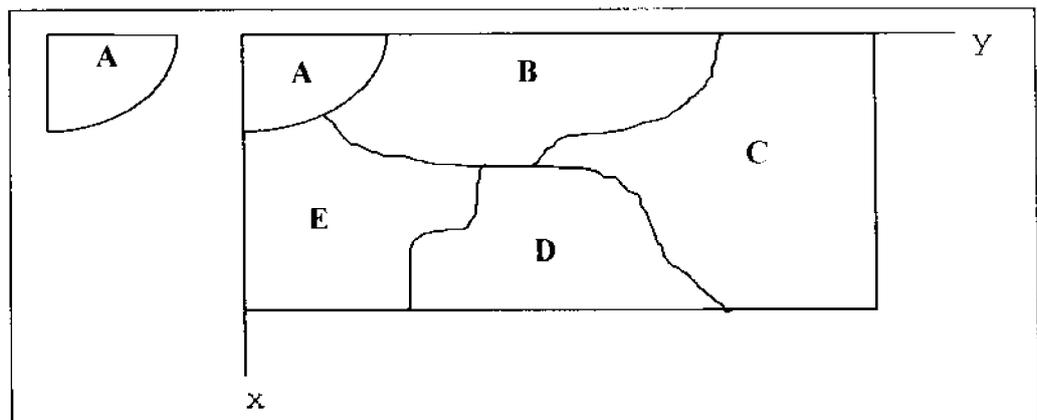


Fig 2.3 - Segmentação de imagens em regiões.

FONTE: Adaptada de Moik (1980).

2.2.4.3 - CRESCIMENTO DE REGIÕES

O algoritmo de crescimento de regiões gera, a partir de um pixel (i, j) uma região representada por (i, j) e possui um valor médio de nível de cinza próximo ao de (i, j) . O grau de similaridade é determinado por um parâmetro de

tolerância t , representado pela distância euclidiana entre os vetores associados a cada segmento. Tomando-se, segundo Liporace (1994), uma Distância (R_i, R_j) como medida de similaridade entre regiões R_i e R_j , aumentando a medida em que R_i e R_j se tornem mais distintas e A (número de pixels) uma constante que determina um tamanho mínimo para cada região, a operacionalização do algoritmo de crescimento de regiões considera:

- (a) Inicialmente, cada pixel da imagem como uma região (Figura 2.4);
- (b) Seja R_i e R_j duas regiões, tais que R_i seja o vizinho mais próximo de R_j e vice-versa. Uma região R_i é a vizinha mais próxima de R_j quando a Distância $(R_j, R_i) \leq \text{Distância}(R_j, R_k)$ para todo R_k vizinho de R_j ;
- (c) Se a Distância $(R_j, R_i) < t$, necessário criar uma região $R_l = R_j \cup R_i$ e voltar ao passo (b).
- (d) Para cada região R_j cujo tamanho em pixels seja menor que A , criar um segmento $R_k = R_j \cup R_i$ onde R_i é o vizinho mais próximo de R_j . Repetir esse passo até que nenhuma região tenha tamanho inferior que A .

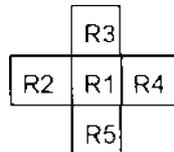


Fig 2.4 - Início de processo de segmentação, onde vizinhos de $(R_1) = R_2, R_3, R_4$ e R_5 (vizinhança 4).

De acordo com Schoenmakers et al. (1991), o método do crescimento de regiões procura por pixels com características similares aos segmentos adjacentes e os liga a estes segmentos se o critério de similaridade for satisfeito. Toda vez que um novo pixel é adicionado ao segmento, as características deste, tais como média e variância, são redefinidas. O crescimento de regiões continua até o encontro de uma zona problema, onde as características dos pixels não correspondem mais aos critérios fornecidos para inclusão no segmento, e o crescimento de cessa (Figura 2.5).

Os pixels internos à zona problema podem ser agrupados nas regiões mais próximas ou não serem associados a nenhuma região permanecendo como pixels isolados. Em alguns casos, ruídos do sensor ou irregularidades nas características do uso do solo (grande quantidade de solo nú surgindo sob o dossel de vegetação em uma

pequena área) também deixam pixels isolados no meio de outros segmentos homogêneos, gerando segmentos anômalos. Segundo Benie et al. (1989), este problema ocorre com frequência nas imagens de sensoriamento remoto.

De acordo com Santos et al. (1993), se o limiar de similaridade definido for muito alto, o processo de crescimento de regiões deixará muitos pixels espectralmente diferentes compondo uma região única. Por outro lado, se for definido um limiar muito baixo, uma classe de cobertura da terra que possua uma pequena variância apresentará uma fragmentação excessiva, dificultando assim sua interpretação.

No processo de crescimento de regiões, o algoritmo de agregamento possui um limiar de área definindo o tamanho mínimo de cada segmento. Regiões com áreas inferiores a um tamanho pré-estabelecido, sem interesse para o usuário são eliminadas, sendo absorvida por outra que possuir a média espectral mais próxima.

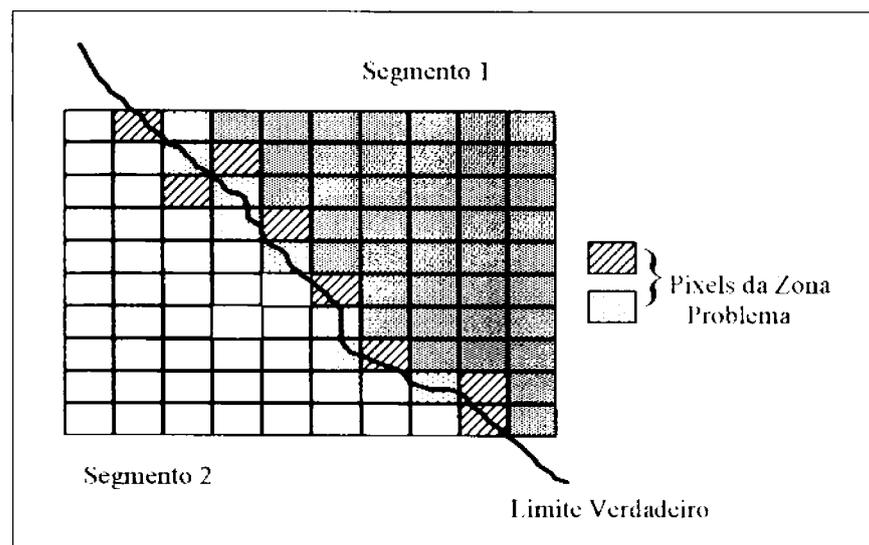


Fig 2.5 - Segmentação de imagem com uma zona problema.

FONTE: Adaptada de Schoenmakers et al. (1991)

Na medida em que um pixel é incorporado a uma região, esta é rotulada e seus atributos são extraídos. Alguns destes atributos são: média, variância, área, perímetro, compacticidade (razão entre a área e o quadrado do perímetro), a excentricidade (razão entre os eixos maior e menor do objeto), linearidade média das bordas e textura (derivada a partir dos níveis de cinza e do arranjo espacial do ponto). Para Fonseca et al. (1990), no final da segmentação tem-se uma descrição da imagem, representando as características vetoriais, uma lista de regiões com seus respectivos

atributos, uma lista de arcos (fronteira entre duas regiões) com seus atributos (força e orientação média das bordas) e uma lista de nós (ponto de encontro entre três ou mais regiões). Desta forma, tem-se todas as informações necessárias para posterior análise da imagem, numa forma compacta, sem necessidade de se ter a cena original armazenada, pois trata-se de uma quantidade de dados muito grande (Benie e Thomson, 1992).

Corr et al. (1989) utilizaram várias técnicas de segmentação de imagens objetivando um avanço no processo de análise automática de dados multi-temporais sensoriados remotamente. Dentro de uma abordagem semelhante Belaid et al. (1992) realizaram a classificação digital de pequenas áreas agrícolas após o processo de segmentação de imagens, sendo constatada uma melhor acurácia global na classificação quando comparado aos métodos convencionais onde o objeto pictórico é o pixel.

2.2.5 - TÉCNICAS DE CLASSIFICAÇÃO

Entende-se por técnicas de classificação digital de imagens os procedimentos utilizados para separar e identificar alvos na superfície terrestre utilizando sistemas eletrônicos, auxiliando o elemento humano na interpretação das informações contidas na cena. Silva (1992) menciona a classificação de imagens como o processo responsável por associar elementos de imagem (pixel) à classes, as quais seriam regiões formadas por pixels que tenham características semelhantes ou comuns.

Novo (1989) ressalta como objetivo da classificação digital, tornar o processo de mapeamento ou reconhecimento de características da superfície terrestre menos subjetivo e com maior potencial de repetição em situações subseqüentes.

As técnicas de classificação multiespectral adotadas neste trabalho podem ser divididas em:

- Técnicas de classificação supervisionada; e
- Técnicas de classificação não supervisionadas.

Segundo Richards (1986) a classificação supervisionada é o procedimento mais utilizado para análises quantitativas de dados de sensoriamento remoto. O uso deste algoritmos é apropriado para rotular os pixels nas imagens como representantes dos tipos das classes de cobertura da terra.

Os algoritmos de classificação supervisionados utilizam conhecimento “a priori” sobre as áreas de interesse. Este conhecimento é utilizado para fornecer amostras de treinamento confiáveis para o algoritmo e assim permitir a classificação com base na distribuição de probabilidade da classe, com base no treinamento.

2.2.5.1 - CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA

Segundo Dutra et al. (1981) o algoritmo associa cada elemento presente na imagem à probabilidade do mesmo pertencer a cada uma das classes pré-definida anteriormente na fase de treinamento, onde são extraídos os parâmetros estatísticos (média e matriz de covariância) necessários à classificação. Conforme Richards (1986) a classificação por máxima verossimilhança é o método de classificação supervisionado mais utilizado em dados de sensoriamento remoto.

De acordo com Menezes et al. (1991) a realização da classificação envolve diversas fases: determinação do número de classes; escolha das amostras; extração dos parâmetros média e variância; cálculo das funções densidade de probabilidade, considerando função gaussiana; e classificação dos demais pontos.

Ainda de acordo com Menezes et al. (1991), supondo-se a probabilidade de ocorrência de cada classe seja igual, um ponto Z será pertencente à classe 1 se: $\Pr(z/S1) > \Pr(z/S2) > \dots > \Pr(z/Sn)$ e $\Pr(z/S1) > \text{Limiar}$. O limiar é utilizado para evitar pixels que possuam pequenas probabilidades de pertencer a uma determinada classe sejam incluídos nesta classe (Richards, 1986). Se os pixels não atingirem um valor de probabilidade superior a esse limiar em nenhuma classe, não serão classificados (Figura 2.6).

Este algoritmo de classificação foi utilizado por Santos (1985), sobre imagens TM/Landsat, para avaliação de áreas queimadas em propriedades agropecuárias na Amazônia Ocidental. Venturieri et al. (1990) utilizaram a classificação por máxima verossimilhança em imagens TM/Landsat, no mapeamento da cobertura vegetal e uso da terra na região de Tucuruí (PA).

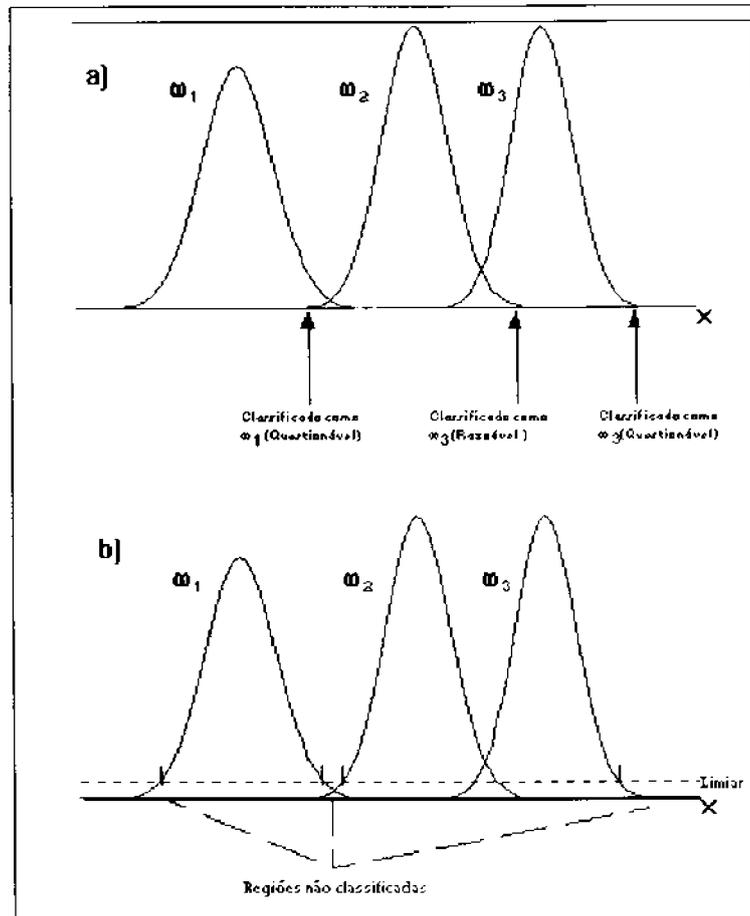


Fig 2.6 - Função de distribuição espectral de algumas classes

a) antes e b) depois da utilização do limiar.

FONTE: Adaptada de Richards (1986).

2.2.5.2 - REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são modelos computacionais inspirados no sistema nervoso biológico, cujo funcionamento é semelhante a alguns procedimentos humanos, ou seja, aprendem pela experiência, generalizam exemplos através de outros e abstraem características (Wasserman, 1989). Para Emaruchi et al. (1994), a rede neural artificial é um método que procura resolver problemas pela imitação do cérebro humano, através da utilização de um grande número de neurônios interligados para processar os sinais de entrada. Ainda segundo Emaruchi et al. (1994), as redes neurais possuem muitas vantagens pois, na maior parte dos casos utilizados apresentaram resultados superiores aos métodos tradicionais de classificação. Os autores afirmam que desta forma um grande número de classes de uso da terra podem ser obtidas com elevada precisão de classificação. Tais resultados foram também observados por Kim et

al. (1995) que comentam a robustez do sistema de inteligência artificial oferece um grande potencial na discriminação das classes de cobertura da terra em comparação com os sistemas de classificação convencionais.

Segundo Liporace (1994) as redes neurais são caracterizadas por:

- a) Grande quantidade de elementos de processamento muito simples, baseados no funcionamento de um neurônio,
- b) Grande número de conexões entre os elementos de processamento;
- c) Controle altamente paralelo e distribuído;
- d) Capacidade de aprendizado através da observação de um conjunto de exemplos;
- e) Robustez, ou seja, queda gradual de desempenho quando ocorre um mau funcionamento ou mesmo inutilização do sistema e;
- f) Manutenção do desempenho na presença de ruído e capacidade de lidar com dados incompletos.

Basicamente as redes neurais são constituídas por um conjunto de elementos de entrada, interligados a outros elementos que fazem o processamento (elemento de processamento - PE), chamados de neurônios artificiais. Desta forma, uma rede neural consiste num conjunto de neurônios conectados por sinapses.

Segundo Liporace (1994) o processamento dos neurônios artificiais consiste na aplicação de uma função não linear G (denominada função de ativação) sobre o somatório das informações de entrada que chegam a este elemento, gerando um resultado de saída (Figura 2.7). Aumentando-se o número de neurônios, aumenta-se também a capacidade da rede em processamento, porém, com elevado custo computacional (Freitas, 1993).

De acordo com Wasserman (1989), as redes neurais se organizam pelo número de camadas que compõem sua tipologia. Existem as redes neurais de camada simples, constituídas por um grupo de neurônios arranjados em apenas uma camada e as redes multicamadas que são a composição de várias redes de camada simples. A Figura 2.8 apresenta um modelo de rede neural com três camadas sendo uma

escondida, onde podemos observar uma camada de entrada E , uma camada escondida V e uma camada de saída S .

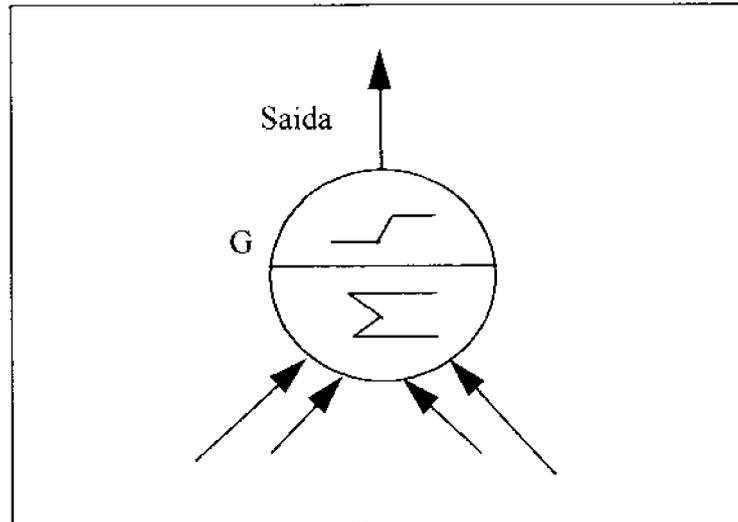


Fig 2.7 - Modelo de neurônio artificial

FONTE: Liporace (1994)

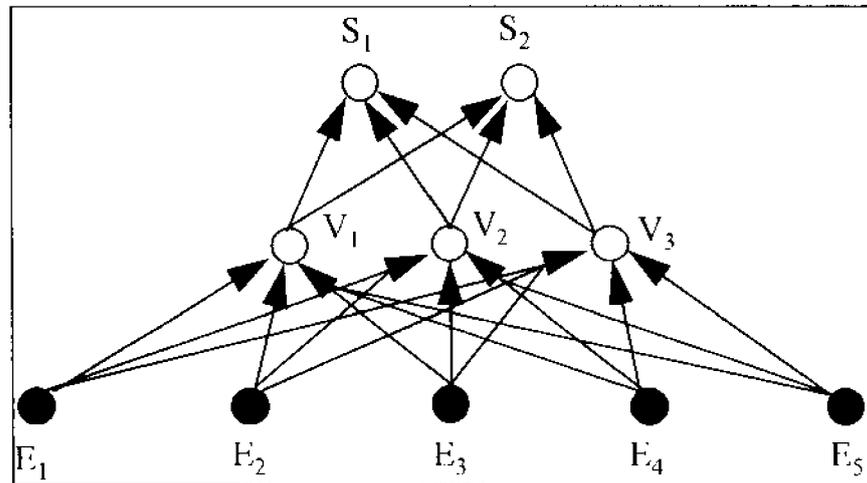


Fig 2.8 - Rede com uma camada escondida

FONTE: Liporace (1994).

Segundo Liporace (1994) não existem regras para a definição do número de camadas escondidas. De acordo com Emaruchi et al. (1994) os estudos mostram que uma camada escondida é suficiente para resolver a maioria dos problemas de classificação em imagens multiespectrais. Desta forma algumas normas são utilizadas para a determinação de uma rede neural:

- a) Muitos neurônios em uma rede podem levá-la facilmente ao processo de memorização;
- b) Quanto mais complexo o mapeamento, maior deve ser a rede neural;
- c) Deve-se realizar experimentos com uma camada escondida inicialmente e caso seja necessário, utilizar duas camadas escondidas; e
- d) Quanto maior for o número de entradas na rede, maior deverá ser o número de neurônios na rede, e maior deverá ser o conjunto de treinamento.

Segundo Emaruchi et al. (1994), a rede neural pode aceitar diferentes dados de entrada e não somente valores dos pixels. Dados de campo tais como comprimento de rampa, elevação e tipos de solos também podem ser utilizados nos cálculos, aumentando assim a precisão da classificação da cobertura da terra.

Para o treinamento das redes neurais é necessário um agente externo que direcione o sistema. Esse direcionamento pode ser realizado através do algoritmo de treinamento denominado "backpropagation" (retropropagação de erro), que consiste na apresentação de um conjunto de amostras, que produz um resultado, o qual é comparado com uma imagem de saída desejada (Schlünzen et al, 1993). Desta forma o algoritmo necessita dispor de um conjunto de amostras com pares de entradas e saídas, ou padrões corretos, sendo a partir deste conjunto de amostras que o algoritmo constrói uma configuração capaz de realizar o mapeamento desejado (Liporace, 1994).

De acordo com Emaruchi et al. (1994), as redes neurais têm sido utilizadas com sucesso para a classificação de imagens de satélite. Os autores utilizaram a média, desvio padrão e valores médios da transformada de Fourier para o mapeamento do uso da terra na região de New Brunswick (Canadá).

Liporace (1994) utilizou informações espectrais, texturais e de vizinhança, em segmentos obtidos pelo processo de crescimento de regiões, para a identificação de desflorestamento na região Amazônica, mais precisamente nos Estados do Acre, Pará, Mato Grosso e Rondônia. A comparação com método Bayesiano indicou que as redes neurais produziram melhores resultados pois foram capazes de tratar regiões de transição e com interferência, as quais não puderam ser discriminadas nos trabalhos realizados com algoritmo Maxver.

Decatur (1989), citado por Emaruchi et al (1994), utilizou imagens de radar de abertura sintética para classificar três tipos de cobertura da terra na região de São Francisco (USA). Foi observado que o uso de redes neurais diminuiu o erro de classificação quando comparada ao método Bayesiano.

Comparando ainda os sistema de classificação convencional e por redes neurais, sob as mesmas áreas de treinamento, a partir de imagens de sensoriamento remoto, Hepner (1990) constatou que a rede neural, para as condições da área de estudo, apresentou um melhor desempenho global.

Ritter e Hepner (1990) utilizaram a abordagem de redes neurais artificiais para classificar quatro tipos de cobertura da terra utilizando imagens TM/Landsat, em área teste no Estado de Washington (USA). Os autores verificaram que a abordagem com a utilização de redes neurais obteve um desempenho de aproximadamente 70% de precisão, enquanto que a definida pelo método Bayesiano foi de apenas 59%.

Utilizando imagens SPOT, Kanellopoulos et al. (1991) aplicaram a rede neural para classificar diversos tipos de cobertura da terra no sul da França. Conforme os autores, a rede neural tem grande potencialidade para classificar um número significativo de tipos de cobertura da terra com precisão superior às observadas para os métodos de classificação tradicionais.

De acordo com Kim et al. (1995) o método de classificação convencional por máxima verossimilhança foi menos capaz de discriminar classes de cobertura da terra do que o sistema de classificação por redes neurais, na região de Daejon no sul de Seul, especialmente quando o modelo de uso da terra é misturado e complexo.

2.2.5.3 - CLASSIFICAÇÃO NÃO SUPERVISIONADA

Neste tipo de classificação não se utiliza nenhum conhecimento “a priori” sobre as classes existentes na imagem, procurando-se apenas determinar se um conjunto de dados multi espectral possui tendência a se aglomerar naturalmente em certo número de grupos isolados. Esta análise é feita pelo próprio classificador que define as classes componentes e atribui cada um dos pixels a uma determinada classe. Neste ítem será tratado apenas o algoritmo ISOSEG, devido ao interesse deste trabalho.

A principal característica deste algoritmo de classificação não supervisionada é o seu objeto de trabalho, que são as regiões obtidas na fase de segmentação.

A fase de classificação propriamente dita consiste na aplicação de um algoritmo de "clustering" sobre os segmentos (regiões). Este algoritmo utiliza a matriz de covariância e o vetor média das regiões para estimar os centros das classes.

Tal algoritmo é dividido em diversas etapas, sendo que a primeira fase envolve a definição do limiar de aceitação. Este limiar, dado em percentual, define um hiperelipsóide no espaço de atributos, de tal forma que todas as regiões cujas médias estiverem dentro da mesma, serão consideradas como pertencentes a uma dada classe (Bins et al. 1993).

Em uma segunda fase, ocorre a detecção das classes iniciais. Nesta detecção, a lista de regiões é ordenada de forma decrescente pela área. Toma-se a primeira região como centro inicial do "cluster". Os parâmetros estatísticos como média e matriz de covariância desta região serão os parâmetros iniciais da classe. Remove-se todas as regiões da lista cuja distância de Mahalanobis ao cluster for inferior ao limiar de afastamento. Toma-se novamente a primeira região para gerar novos "clusters" até que a lista da região fique vazia (Bins et al. 1993).

Utilizando o SGI/INPE, Santos et al. (1993) avaliaram o desempenho deste tipo de classificação baseada em segmentos, sobre imagens TM/Landsat, para a caracterização do uso da terra na Amazônia brasileira sendo os resultados preliminares bastante promissores para atender aos objetivos propostos. Batista et al. (1994) utilizaram também algoritmo ISOSEG, objetivando desenvolver uma nova metodologia para a quantificação do desflorestamento na região Amazônica.

2.3 - ESTIMATIVA DA EXATIDÃO DE MAPEAMENTO

Após os processos de classificação das imagens, é necessário que seja feita uma avaliação da exatidão do mapeamento. Este procedimento, visa principalmente determinar qual dos sistemas de classificação utilizados retrataram, da melhor forma, o ambiente estudado.

Segundo Chen (1991), a exatidão do mapeamento deve ser devidamente avaliada por dois motivos: 1) para que o executor possa verificar se o

produto gerado satisfaz à exatidão de classificação estipulada; e 2) para o usuário definir se o produto pode ser utilizado para suas atividades específicas de gerenciamento, de acordo com a exatidão do mapa.

De acordo com Congalton e Mead (1983), a estatística Kappa (K) é a mais apropriada para avaliar e comparar as exatidões de mapas temáticos, levando em consideração tanto os erros de omissão quanto os de inclusão pois, esta estatística trata os dados da matriz de erro como multivariáveis discretas e multinominais. A vantagem da utilização desta análise é que a mesma não assume que as categorias sejam, independentes e também não necessitam de normalizações como ocorre na utilização da análise de variância (ANOVA).

A estatística Kappa avalia o grau de similaridade entre mapas, podendo ser um mapa classificado e outro de referência. Para Fitzgerald e Lees (1994), esta estatística é a ferramenta que melhor discrimina a avaliação da precisão entre classificações e classificadores.

A exatidão de classificação da estatística Kappa é representada normalmente pelo teste de concordância de matrizes, que é utilizada para avaliar o desempenho de uma classificação (Congalton e Mead, 1983). Nestas matrizes, segundo Mead e Congalton (1983), as colunas, geralmente, correspondem aos dados de referência, as linhas aos resultados da classificação e a diagonal representa a concordância ao acaso (Tabela 2.3). Uma análise comparativa da matriz de erro pode ser considerada adequada para avaliação da classificação do uso da terra (Aronoff, 1982).

Segundo Congalton e Mead (1983), a fórmula para calcular a estatística Kappa é:

$$K = \frac{P_o - P_c}{1 - P_c} \quad (2.2)$$

Onde:

$$P_o = \sum_{i=1}^k P_{ii} \quad \text{e} \quad P_c = \sum_{i=1}^k P_i P_i \quad (2.3)$$

O elemento P_o é chamado de coeficiente de concordância e o P_e de coeficiente de probabilidade de concordância. Segundo Congalton e Mead (1983) o valor computado para cada matriz de erro é uma medida de como uma classificação concorda com a verdade terrestre.

Os valores resultantes da utilização deste método podem variar entre “zero” e “um”, onde a tendência para valores menores indica não haver nenhuma similaridade entre os mapas temáticos e valores próximos de um indicam haver uma grande similaridade entre os mesmos. Estes valores foram agrupados por Landis e Koch (1977) conforme tabela 2.4.

TABELA 2.3 - MATRIZ DE ERRO

CLASSIFICAÇÃO	VERDADE TERRESTRE				TOTAL
	1	2	...	K	
1	P_{11}	P_{12}	...	P_{1K}	$P_{1.}$
2	P_{21}	P_{22}	...	P_{2K}	$P_{2.}$
...					
K	P_{K1}	P_{K2}	...	P_{KK}	$P_{K.}$
TOTAL	$P_{.1}$	$P_{.2}$...	$P_{.K}$	1

FONTE: Fleiss (1981).

TABELA 2.4 - QUALIDADE DA CLASSIFICAÇÃO ASSOCIADA A UM VALOR DE KAPPA

Kappa	Qualidade
< 0.000	Péssima
0.000 - 0.20	Ruim
0.21 - 0.40	Razoável
0.41 - 0.60	Boa
0.61 - 0.80	Muito Boa
0.81 - 1.00	Excelente

De acordo com Fleiss (1981), para testar a hipótese de que as avaliações são independentes ($K=0$), o erro padrão de Kappa é estimado por:

$$S_{eo}(K) = \frac{1}{(1 - P_c)\sqrt{n}} \left(P_c + P_c^2 - \sum_{i=1}^r P_{i.} P_{.i} (P_{i.} + P_{.i}) \right)^{1/2} \quad (2.4)$$

Sendo que a hipótese pode ser testada através da utilização da equação:

$$Z = \frac{K}{S_{\text{eo}}(K)} \quad (2.5)$$

De acordo com Foody (1988), a importância da utilização desta equação baseia-se no fato de que em uma classificação digital temática assume-se implicitamente que as informações adquiridas independem das características espaciais de sua obtenção. Entretanto, a resposta espectral dos alvos incluídos de uma classe é, em parte, dependente da geometria angular da visada do sensor.

Para determinar se duas matrizes de erro são significativamente diferentes, utiliza-se a equação:

$$Z = \frac{K_1 - K_2}{\sqrt{\sigma_1 + \sigma_2}} \quad (2.6)$$

Onde σ_1 e σ_2 representam as variâncias das duas classificações, e são definidas por:

$$(K) = \frac{1}{N} \left[\frac{\mu_1(1-\mu_1)}{1-\mu_2} + \frac{2(1-\mu_1)(2\mu_1\mu_2 - \mu_3)}{(1-\mu_2)^3} + \frac{(1-\mu_1)^2(\mu_4 - 4\mu_2^2)}{(1-\mu_2)^4} \right] \quad (2.7)$$

Onde:

$$\mu_1 = \sum_{i=1}^r \frac{X_{ii}}{N} \quad (2.8)$$

$$\mu_2 = \sum_{i=1}^r \frac{(X_{i.}, X_{.i})}{N^2} \quad (2.9)$$

$$\mu_3 = \sum_{i=1}^r \frac{X_{ii}(X_{i.}, X_{.i})}{N^2} \quad (2.10)$$

$$\mu_4 = \sum_{i=1}^r \frac{X_{ii}(X_{i.}, X_{.i})^2}{N^3} \quad (2.11)$$

Esta análise estatística vem sendo utilizada largamente na avaliação de classificações temáticas digitais como pode ser observado nos trabalhos de Benson e De Gloria (1985), que avaliaram os resultados da classificação de estratificação de florestas. Chuvieco et al. (1988) utilizaram a estatística Kappa na comparação dos

resultados dos trabalhos de agrupamentos estatísticos de pixels de treinamento entre classificadores supervisionados e não supervisionados. Gong et al. (1992) utilizaram este procedimento estatístico na comparação entre diferentes algoritmos de extração de informações de uso da terra com dados do HRV/SPOT.

CAPÍTULO 3

MATERIAL E MÉTODOS

3.1 - ÁREA DE ESTUDO

A área de estudo localiza-se na porção sudeste do Estado do Pará, entre as latitudes 03° 37' 5" S e 03° 58' 48" S e entre as longitudes 49° 11' 58" W e 49° 55' 09" W (Figura 3.1), abrangendo a região de influência da barragem de Tucuruí, bacia do Rio Tocantins, com uma superfície de aproximadamente 3.200 Km².

Em relação ao sistema viário, destacam-se as rodovias PA - 150 que liga Belém ao sul do Estado; a PA - 263, principal acesso a Tucuruí e a rodovia BR - 010, conhecida como Transamazônica.

A escolha da área para a realização deste trabalho relaciona-se ao fato da mesma possuir a vegetação e outros tipos de uso da terra comuns da região Amazônica, bem como por ter sido objeto de estudos anteriores facilitando desta forma a obtenção de informações referentes sobre a infra-estrutura local.

3.1.1 - ASPECTOS FISIOGRAFICOS E CLIMÁTICOS

Do ponto de vista geológico, a região de estudo apresenta uma composição litológica variável, devido a grande diversidade de origem dos sedimentos. predominam os Arenitos Finos e Grosseiros, Siltitos e Argilitos Cauliníticos, da Formação Barreiras do Terciário (Projeto RADAMBRASIL, 1974).

Em relação a geomorfologia, a região encontra-se na Depressão Periférica do Sul do Pará, fazendo parte da circundesnudação resultante de processos erosivos pós-pleiocênicos na periferia das bacias paleozóicas do Piauí-Maranhão e do Amazonas. A dissecação fluvial no pediplano originou vales pouco encaixados em grandes áreas, formando relevos definidos como colinas de topo aplainado.

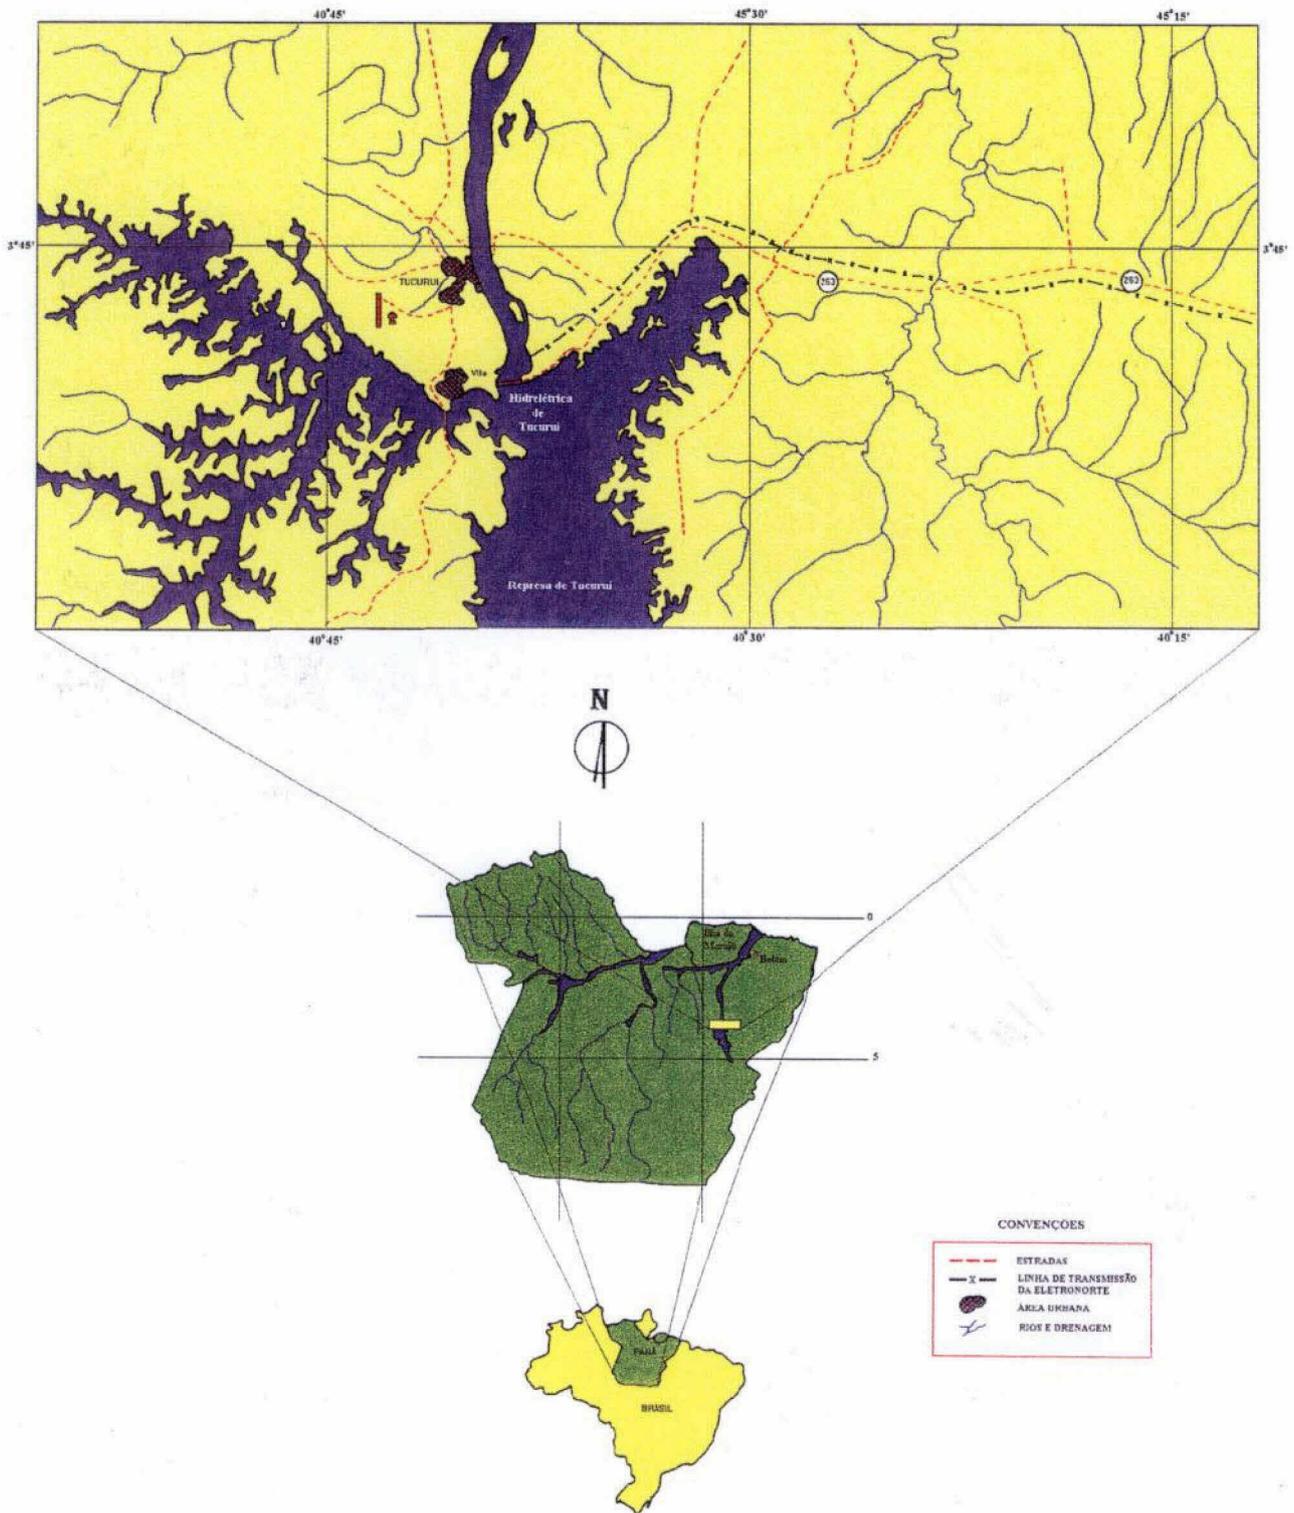


Fig. 3.1 - Localização da Área de Estudo

Na região predominam solos profundos, de textura variando entre média a muito argilosa, de boa drenagem, permeáveis e de baixa fertilidade natural, como os Latossolos Amarelo e Vermelho-Amarelo presentes em relevos ondulados a suave ondulados (Convênio Eletronorte/INPA, 1983). Encontram-se ainda pequenas áreas de Podzólico Vermelho-Amarelo, que são solos de profundidade variável, de textura média a argilosa, com drenagem variando de boa a moderada. São observados também áreas de Podzol Hidromórfico, relacionados a solos hidromórficos e arenosos, localizados em relevos planos, em pequenas áreas, associados a Areia Quartzosa e solos Gley Pouco Húmico que correspondem a solos hidromórficos, sujeitos a inundação periódica devido estarem localizados nas planícies aluviais de inundação (Silva e Carvalho, 1986 e Projeto RADAMBRASIL, 1974).

Em relação a vegetação, a área de estudo está localizada nos domínios da Floresta Amazônica, Projeto RADAMBRASIL (1974), região ecológica da Floresta Ombrófila Densa (Floresta Pluvial Tropical).

A região é representada por um clima tropical úmido, com precipitação anual variando entre 1600 mm a 3100 mm (Figura 3.2), com moderado período de estiagem, variando de um a três meses com precipitação abaixo de 60 mm (Figura 3.3). Possui uma temperatura média anual em torno de 26^o C, com umidade relativa do ar variando entre 80 a 90% (SUDAM/PHCA, 1984).

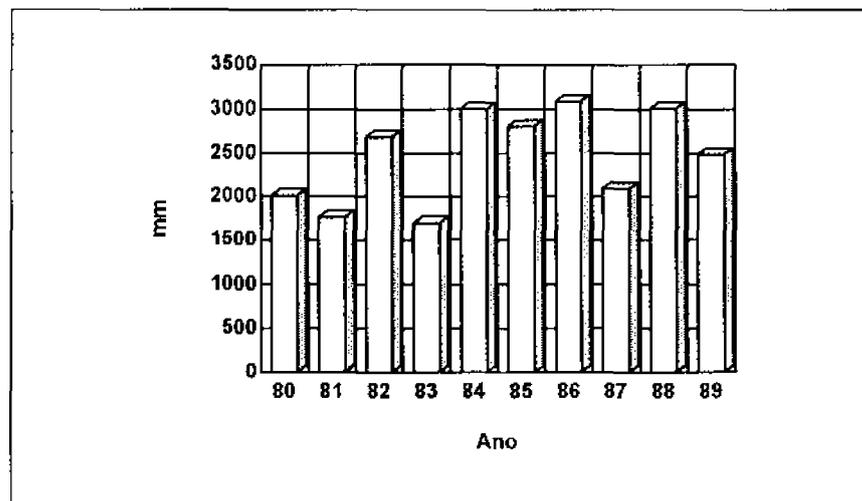


Fig. 3.2 - Média de precipitação anual para a região de Tucuruí, (PA).

FONTE: DNMET (1994).

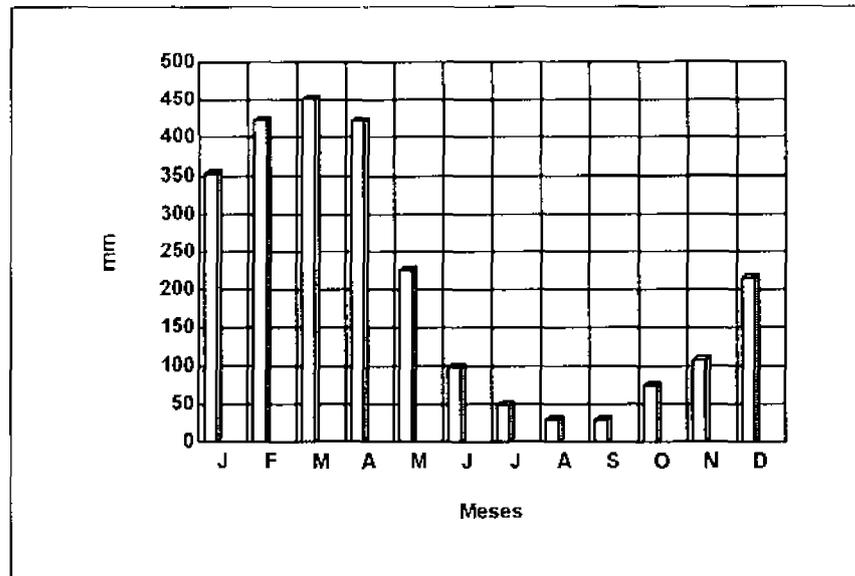


Fig. 3.3 - Média de precipitação mensal para a região de Tucuruí, (PA).
 FONTE: DNMET (1994).

3.2 - MATERIAL

3.2.1 - IMAGENS DE SATÉLITE

Neste trabalho, foram utilizadas imagens geradas do sensor TM/Landsat, órbita/ponto 224/63, referente a data de 22/06/1992, cedida pelo Programa de Desflorestamento da Amazônia (PRODES) - INPE. Tais imagens foram selecionadas considerando-se dois formatos: o digital em fitas do tipo CCT, abrangendo as bandas do espectro refletido (TM1 a 5 e 7), para a realização da etapa de processamento; e papel fotográfico na escala 1:250.000 a partir da composição colorida TM3-B/TM-4G/TM5-R para dar suporte na delimitação da área de estudo.

3.2.2 - MATERIAL CARTOGRÁFICO

Foram empregadas duas cartas topográficas (Tabela 3.1), escala 1:100.000, em projeção UTM² produzidas pela DSG³. Primeiramente as cartas foram empregadas objetivando dar suporte cartográfico as imagens digitais para o planejamento do trabalho de campo, sendo também utilizadas durante a fase de registro de imagens.

² Projeção Universal Transversa de Mercator.

³ Diretoria de Serviço Geográfico, do Ministério do Exército.

TABELA 3.1 - CARTAS TOPOGRÁFICAS DA DSG, ESCALA 1:100.000 QUE RECOBREM A ÁREA DE ESTUDO

Mapa-Índice	Folha	Código
662	Tucuruí	SA.22-Z-C-VI
663	Goianésia	SA.22-Z-D-IV

3.2.3 - INFRA-ESTRUTURA OPERACIONAL

Na etapa de pré-processamento dos dados digitais foram utilizados os programas existentes no Sistema de Tratamento de Imagens (SITIM-340), versão 2.4 que opera em microcomputador do tipo "PC" (486) de maneira análoga ao SGI/INPE, empregados para registro de imagens e análise estatística das imagens temáticas. As fases de realce, segmentação e classificação não supervisionada, foram realizadas no Sistema de Processamento de Informações Georeferenciadas (SPRING), versão 1.1 que funciona em estações de trabalho UNIX, sob o sistema "Solaris" (SUN-Sparcstation 10).

A rotulação dos segmentos foi realizada por um programa de classificação nebulosa, utilizando também a plataforma SPRING, na versão 2.0, desenvolvido pela Divisão de Processamento de Imagens-DPI, do INPE e também através do "Neural Image Classification Environment"-NICE, da IBM. O desenvolvimento da rede neural artificial ficou a cargo do Centro Científico IBM - Rio de Janeiro (CCRIO).

Os dados estatísticos dos segmentos (média e desvio padrão) e o teste de comparação entre médias de segmentos e pixels, foram obtidos através de programas específicos, ESTSEG.EXE e TCALC.EXE, apresentados nas Tabelas A1 e A2.

3.3 - MÉTODOS

A metodologia desenvolvida neste trabalho é parte integrante do projeto de pesquisa para o desenvolvimento de técnicas de processamento digital de imagens, objetivando a caracterização do desflorestamento da Amazônia. Tal projeto é realizado em conjunto pelo Instituto Nacional de Pesquisas Espaciais, INPE, São José

dos Campos e o CCRIO. A seguir são apresentadas e discutidas algumas seções necessárias para a execução deste trabalho.

3.3.1 - DEFINIÇÃO DA LEGENDA TEMÁTICA

Uma legenda preliminar foi proposta com o apoio de imagens em papel fotográfico, escala 1:250.000, composição colorida TM3-B/TM4-G/TM5-R para a definição das classes mapeadas. Posteriormente ao trabalho de campo foi possível fazer uma nova análise e definir a legenda final.

Com base nos trabalhos de Anderson et al. (1979) e de Jensen (1983) foi possível a definição do nível de detalhamento do produto final. O resultado apresentado é uma legenda temática com dez classes (Tabela 3.2) descritas a seguir.

Do sistema original proposto por Anderson et al. (1979), estão sendo mantidas as classes do nível I como referência, com a introdução de duas classes de interferência que são as nuvens e sombra. Nos níveis II e III, as classes apresentadas são basicamente um agrupamento das diversas classes cartografadas em vários trabalhos de vegetação e uso da terra na região. Segundo a classificação de Jensen (1983), a legenda proposta se enquadra no nível IV, devido a mínima unidade mapeável variar entre 0,8 a 4 ha e ainda discriminar as diferentes atividades de uso da terra com a utilização de trabalho de campo.

As classes temáticas finais propostas neste trabalho são as seguintes:

I - ÁREA URBANA E INFRA-ESTRUTURA

Nesta classe, segundo Anderson et al. (1979), estão incluídas as cidades, vilas, áreas de rodovias, áreas de serviços de energia e comunicações. Estas áreas possuem como característica, em imagens de sensores remotos, altas frequências espaciais, proporcionando a estas um aspecto de elevada rugosidade. Representando esta classe na área de estudo estão as sedes dos municípios de Tucuruí e Breu Branco, além das áreas referentes ao distrito industrial, as estradas e as linhas de transmissão de energia da Eletronorte.

Devido as características que a compõem, principalmente concreto, asfalto e solo exposto, esta classe apresenta uma alta reflectância nas bandas do visível; baixa no infravermelho próximo, tornando a apresentar elevados valores de reflectância

no infravermelho médio. Esta classe não apresenta um padrão geométrico definido, variando de acordo com cada tipo de ocupação do solo urbano.

TABELA 3.2 - SISTEMA DE USO DA TERRA E REVESTIMENTO DO SOLO PARA UTILIZAÇÃO COM DADOS DE SENSORIAMENTO REMOTO

NÍVEL I	NÍVEL II	NÍVEL III
1 - ÁREA URBANA E INFRA-ESTRUTURA		
2 - TERRA AGRÍCOLA	- TERRA DE AGRICULTURA E PASTAGEM	- PASTO LIMPO - PASTO SUJO - CULTURA AGRÍCOLA
3- TERRA FLORESTAL	- FLORESTA - SUCESSÃO SECUNDÁRIA INICIAL - SUCESSÃO SECUNDÁRIA AVANÇADA	
4 - ÁGUA		
5 - NUVEM		
6 - SOMBRA		

FONTE: Modificada a partir de Anderson et al. (1979) e Jensen (1983).

2 - PASTO LIMPO

Esta classe é representada pelas grandes extensões de terra, em formatos simétricos, de elevada influência do solo na resposta espectral que chega ao sensor (Figura 3.4) pois apresentam-se recém implantadas e as espécies normalmente utilizadas para a formação de pastagens (p.e. *Brachiaria humidicola*, *Brachiaria*

decumbens e Panicum maximum), apresentam folhas estreitas, aumentando ainda mais a passagem da radiação eletromagnética, ocorrendo desta forma maior interação com o solo.



Fig 3.4 - Pasto limpo.

3 - PASTO SUJO

Da mesma forma que a classe anterior, nesta categoria estão as grandes áreas de formato simétrico, porém, com menor influência do solo na resposta que chega ao sensor, devido ao desenvolvimento de plantas invasoras. Normalmente esta invasão ocorre através de espécies de palmeiras como o inajá (*Maximiliana maripa*) e o babaçu (*Orbignia martiana*) (Figura 3.5) e ainda por espécies de porte arbustivo proporcionando a cobertura parcial do terreno.

Segundo Serrão (1986) esta infestação de plantas invasoras ocorre principalmente pelo fato de que as gramíneas utilizadas para a formação das pastagens serem exigentes com relação as qualidades químicas e físicas dos solos, o que não ocorre na maioria dos solos amazônicos. Segundo ainda o autor, de sete a dez anos após

a implantação das pastagens há uma baixa na produtividade devido a participação da vegetação secundária.

Devido a esta dinâmica, as áreas de pastagens plantadas apresentam uma característica espectral muito particular, para cada fase de desenvolvimento ou degradação, permitindo desta forma a sua discriminação utilizando produtos de sensores remotos a nível orbital.

4 - CULTURA AGRÍCOLA

Esta classe está representada na região de estudo por pequenas áreas de culturas agrícolas, como a mandioca (*Manihot esculenta*) e o milho (*Zea mays*) (Figura 3.6) nos domínios das feições florestais e ainda por regiões totalmente descobertas de vegetação, representando áreas que estão sendo preparadas para implantação de agropecuária. Também estão agrupadas nesta classe, áreas de agricultura intensiva, como por exemplo a cultura do maracujá (*Passiflora edulis*) e da pimenta-do-reino (*Piper nigrum*), que apresentam como característica dos tratos culturais, a limpeza constante da cobertura do solo (capina).



Fig 3.5 - Pasto sujo.



Fig 3.6 - Cultura Agrícola.

5 - FLORESTA

Esta formação possui como característica o total recobrimento do solo pela vegetação de porte florestal contituída por vários estratos, minimizando a interferência deste na composição da energia que chega ao sensor (Figura 3.7).

Na região amazônica, de acordo com a posição topográfica em que se encontram, as florestas podem se apresentar de diferentes formas, sendo classificadas como: floresta de terra firme, que se localiza nas cotas mais altas do relevo e caracterizam-se pela presença de árvores de grande porte e conseqüentemente elevada biomassa; floresta de várzeas, localizada em áreas periodicamente inundadas pelos rios; e floresta de igapó, que são características das regiões permanentemente alagadas.

Por possuírem diversificada composição florístico-estrutural, as florestas apresentam o dossel heterogêneo, o que aliado ao ângulo de aquisição de dados pelo sensor e o horário de passagem do satélite, ocasiona o aparecimento de feições de sombra, causando uma grande variação das frequências espaciais, resultando em imagens de textura rugosa.

6 - SUCESSÃO SECUNDÁRIA

Segundo Denich (1986), sucessão secundária é a denominação dada ao tipo de vegetação que se desenvolve em consequência de intervenções do homem sobre a cobertura vegetal existente. Estas intervenções ocorrem na floresta natural basicamente através de processo histórico de desmatamento e queimada, destinando-se posteriormente a terra para o plantio de lavouras e implantação de pastagens.

Após algum tempo de abandono (pousio) estas áreas tendem a se recompor novamente, porém dificilmente atingindo o “clímax” observado para a floresta primária. Watrin (1994) discriminou três diferentes estádios de sucessão secundária (inicial, intermediário e avançada) utilizando imagens TM/Landsat relacionados com o período de abandono da área. Os estádios encontrados neste trabalho (inicial e avançada) diferem do autor visto que a região de Tucuruí apresenta um histórico de ocupação da terra muito mais recente em comparação a tradicional região Bragantina (PA).



Figura 3.7 - Floresta primária.

6.1 - SUCESSÃO SECUNDÁRIA INICIAL

Durante o trabalho de campo foi possível identificar e caracterizar esta classe (Figura 3.8), apesar da mesma apresentar a resposta espectral próxima a classe pasto sujo. A diferença entre o pasto sujo e sucessão secundária inicial é, que neste caso, as invasoras são dominantes e não comportam mais satisfatoriamente o pastejo. Observa-se ainda uma certa textura rugosa nas imagens do sensor TM/Landsat, devido ao grande número de indivíduos de porte arbustivo ou mesmo arbóreo. Foi constatado em campo que estas áreas normalmente ficam abandonadas ou em pousio por um período de até 6 anos.



Fig 3.8 - Sucessão secundária inicial.

6.2 - SUCESSÃO SECUNDÁRIA AVANÇADA

Esta é a formação característica de áreas com mais de seis anos de pousio ou abandono (Figura 3.9). Apresentam, quanto mais desenvolvidas, características espectrais semelhantes às florestas primárias, com valores de nível de cinza muito próximo tanto na região do espectro visível como do infra-vermelho distante, devido a formação de estratos e altura de dossel próximos a floresta (Moran et

al., 1993). Observa-se ainda, no entanto, os contornos geométricos definidos o que evidencia ação antrópica sofrida na área.

7 - ÁGUA

Abrange todos os corpos d'água presentes na imagem. O delineamento dos corpos d'água depende das escalas de apresentação dos dados e das características de resolução dos sensores que geram as imagens utilizadas para interpretação do uso da terra (Anderson et al. 1979).

Na região do visível, a resposta espectral desta classe será função da concentração e composição dos sedimentos em suspensão. A ausência de grandes variações de frequências resulta em um aspecto homogêneo e em uma textura lisa. Este padrão de textura também é apresentado na região do infravermelho devido à absorção total da radiação eletromagnética pela água.



Fig 3.9 - Área de sucessão secundária avançada.

8 - NUVEM

Devido estar localizada na região equatorial, com clima quente e úmido, a Amazônia apresenta uma grande nebulosidade. Durante o ciclo da água no ambiente, há formação de nuvens que refletem a radiação eletromagnética a caminho da superfície terrestre, não permitindo desta forma que o satélite Landsat, que possui um sensor passivo, obtenha imagens com boa visibilidade e constantes destas regiões.

Estas formações ao refletirem a energia eletromagnética em todos os comprimentos de onda, de forma uniforme, conferem a esta classe uma resposta espectral de valores elevados na escala de nível de cinza em todas as bandas do sensor TM.

9 - SOMBRA

As sombras ocorrem através das diversas formas de relevo da região e ainda como resultado da formação de nuvens. Como não há incidência direta da radiação eletromagnética nestas áreas, as áreas sombreadas apresentam valores de reflectância muito próximos de zero em todas as bandas do sensor TM, não chegando nestes valores devido ao espalhamento da radiação pela atmosfera.

3.3.2 - TRABALHO DE CAMPO

Com o objetivo de fazer o reconhecimento e caracterização da paisagem “in loco” dentro da área de estudo, foi realizada uma missão visando correlacionar as feições espectrais presentes na imagem com os padrões de cobertura vegetal e uso da terra observados no campo.

O trabalho de campo foi realizado no período de 10 a 25 de janeiro de 1994, e contou com o apoio da Superintendência do Desenvolvimento da Amazônia (SUDAM). Entre a saída de Belém (PA), chegada a Tucuruí e retorno a Belém, foram percorridos um total de 1800 Km de estradas.

Devido a grande extensão da área de estudo e com a finalidade de observar todas as diferentes formas de ocupação da terra, como os assentamentos de pequenos agricultores, exploração madeireira e implantação de pastagens, foi realizado previamente uma seleção sobre as áreas que deveriam ser visitadas. Foi tomada como

base a grade formada pelas coordenadas planas (UTM) das cartas topográficas na escala 1:100.000.

Todos os pontos escolhidos foram visitados por via terrestre, onde puderam ser descritos em uma caderneta de campo e anotadas as coordenadas geográficas obtidas através de um GPS ("TRIMBLE NAVIGATION"). Desta forma, foram descritos 138 pontos, incluindo o registro fotográfico das áreas mais representativas. Posteriormente, as coordenadas geográficas obtidas através do GPS foram transformadas em um arquivo no formato ASCII para que pudessem ser inseridas SGI/INPE. Através do programa "PLOTACD.EXE", foi possível plotar os dados de latitude e longitude em um plano de informação no SGI, rotulando-os através de números (Figura 3.10).



Fig 3.10 - Localização de pontos visitados no campo.

3.3.3 - PROCESSAMENTO DIGITAL

De acordo com os objetivos do trabalho, procurou-se desenvolver uma metodologia de classificação de imagens digitais a partir da segmentação de imagens como suporte ao treinamento de uma rede neural artificial especialista em classes de uso

da terra na região de Tucuruí (PA). Este sistema de classificação é subdividido em várias partes componentes, as quais serão vistas posteriormente.

Vale ressaltar que este sistema foi desenvolvido com o intento de dimensionar a dinâmica de desflorestamento da Região Amazônica, projeto este desenvolvido pelo INPE, com apoio computacional do CCRIO. Devido ao grande potencial apresentado por esta técnica resolveu-se aproveitar esta metodologia, adaptando-a, visando a estratificação das diversas classes de uso da terra, incluindo também áreas que se encontram em processo de regeneração (sucessão secundária). As diversas fases do processo podem ser visualizadas esquematicamente na Figura 3.11.

3.3.3.1 - REGISTRO DE IMAGENS

Devido a área de estudo compreender dois módulos de 1024 pixels x 763 pixels, foram realizadas duas operações de registro de imagens (imagem x mapa) permitindo desta forma a sobreposição das mesmas com as bases cartográficas, cartas Tucuruí e Goianésia. Foram coletados pontos de controle facilmente identificáveis tanto nas imagens quanto na carta topográfica, os quais foram submetidos a uma equação do primeiro grau para a criação da matriz de reamostragem e geração da imagem de saída através da interpolação pelo vizinho mais próximo.

Estas correções permitiram a utilização das imagens originais e das diversas imagens temáticas resultantes de cada processo de classificação de área de estudo dentro do Sistema de Informações Geográficas (SGI).

3.3.3.2 - RECONHECIMENTO DE PADRÕES

Após estarem georreferenciadas, as imagens foram introduzidas no SGI/INPE. O principal objetivo foi estabelecer uma correlação entre os pontos coletados através do GPS, fotografados e descritos na caderneta de campo, com a resposta espectral exibida pela imagem TM/Landsat. Desta forma foi possível obter uma chave de interpretação para a elaboração da base de exemplos para a rede neural, bem como, para a imagem de referência (verdade de campo).

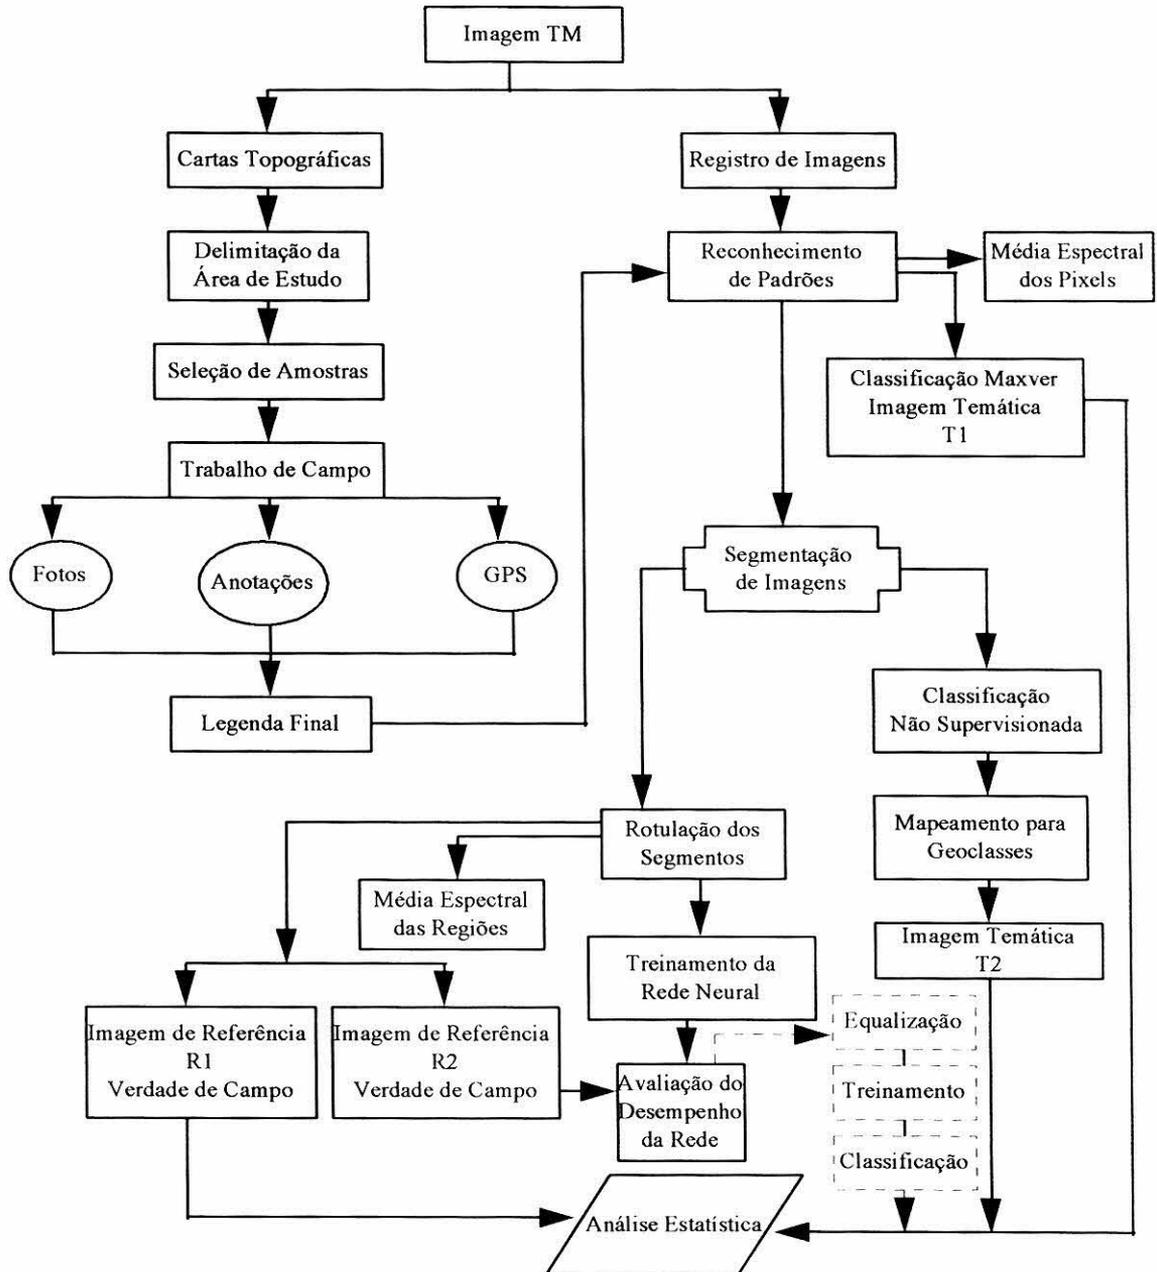


Fig 3.11 - Fluxograma de atividades

3.3.3.3 - SEGMENTAÇÃO DE IMAGENS

Nesta fase a imagem foi particionada em diversas regiões homogêneas, geradas pela técnica de crescimento de regiões onde foram testados cinco valores de limiares de similaridade (6, 8, 10, 12 e 14) para a escolha do melhor a ser utilizado.

Cada mudança realizada nos valores de similaridade implica em variações do esforço computacional para este processamento pois o grau de similaridade é determinado por um parâmetro de tolerância t , representado pela distância euclidiana entre os vetores associados a cada segmento.

Na definição do tamanho da região mínima a ser formada no processo de segmentação, foi observado primeiramente no trabalho de campo a dimensão das áreas cultivadas mais comuns. Nesta fase, observou-se então que as classes representantes definidas para a legenda temática estavam contidas em áreas superiores a 10.000 m² (1 ha).

Desta forma, o número de pixels escolhidos para o tamanho da região mínima foi igual a 10, ou seja, a menor região formada apresentou uma área mínima de 9.000 m². Este valor foi o mesmo adotado por Machado et al. (1993) e Liporace (1994), que obtiveram resultados satisfatórios utilizando a metodologia semelhante, encontrando no entanto menor precisão de classificação para regiões de menores dimensões.

3.3.3.4 - INSPEÇÃO DAS MÉDIAS DOS NÍVEIS DE CINZA DAS CLASSES

Após o reconhecimento e identificação de todas as classes presentes na imagem, foi feita uma inspeção dos atributos espectrais de cada classe. Primeiramente esta inspeção foi conduzida a partir da coleta de amostras de pixels referentes as classes de interesse, através do programa de leitura de pixels, do SITIM. Nesta primeira inspeção foram adquiridos cerca de 200 pixels de cada classe, distribuídos uniformemente sobre toda a imagem, tomando-se como referência o trabalho de campo para a determinação do posicionamento do cursor.

Posteriormente, foi realizada a inspeção dos segmentos representando todas as classes definidas anteriormente, através do programa de rotulação de segmentos. A inspeção dos valores das imagens segmentadas foi realizada com a utilização do programa de rotulação de segmentos, que gerou para cada segmento um arquivo ASCII com a descrição dos mesmos, como média e variância em cada banda TM. Desta forma, pôde-se fazer uma análise da influência do processo de segmentação de imagens sobre a média do número digital de cada classe de estudo

3.3.3.5 - ELABORAÇÃO DA IMAGEM DE REFERÊNCIA

Para avaliação dos algoritmos de classificação a serem testados, foi necessária a elaboração de duas imagens temáticas de referência (R1 e R2) que representassem a real ocupação da terra. Este procedimento foi realizado pois, os métodos de avaliação do desempenho das redes neurais diferem dos aplicados aos algoritmos de máxima verossimilhança e ISOSEG.

Os métodos normalmente utilizados para elaboração de uma imagem de referência constam de interpretação visual de imagens em papel fotográfico e posterior digitalização manual desta informação através de um "SIG". O que se observa é que em cada fase deste processo há inclusão de um fator de erro, que ao final pode se tornar significativo.

Objetivando eliminar estas fontes de erro, procurou-se desenvolver uma imagem de referência baseada no trabalho de campo, enriquecida com a experiência de fotointerpretação de imagens, combinada com o processamento digital de imagens.

Para a elaboração desta, foram realizados então os procedimentos de segmentação de imagens, com posterior identificação e rotulação digital de cada segmento da imagem de acordo com a legenda pré-estabelecida.

3.3.3.6 - CLASSIFICAÇÃO NÃO SUPERVISIONADA (ISOSEG)

Após a fase de segmentação, a imagem foi submetida ao processo de extração de atributos estatísticos, onde foram adquiridos os parâmetros necessários para a realização da classificação que são: média, matriz de covariância e área (Bins et al. 1993).

Posteriormente a fase de extração de atributos, a imagem segmentada da área de estudo foi submetida ao classificador não supervisionado por regiões (ISOSEG) presente no pacote SPRING. Inicialmente foram utilizados vários limiares de classificação (75%, 95%, 99% e 99,9%) com objetivo de encontrar um resultado que melhor representasse as classes de vegetação e uso da terra. Para selecionar este valor, foram utilizados basicamente dois critérios:

Análise Qualitativa da Imagem Temática - onde após cada classificação a imagem era visualizada no monitor de vídeo e feita a inspeção visual. Nesta inspeção procurava-se localizar pontos de referência e observar a sua classificação.

Geração do Número Mínimo de Classes - foi estabelecido que por se tratar de uma classificação não supervisionada, onde não há um controle do número de classes resultantes, a imagem temática resultante inicialmente deveria apresentar o mínimo de três vezes o número de classes da legenda adotada no trabalho.

Após a definição do valor do limiar a ser utilizado, foi realizada a classificação das imagens. Devido não haver controle no número de classes geradas pelo algoritmo, foi necessário após a classificação efetuar um agrupamento das n classes resultantes de forma que estas pudessem ser enquadradas na legenda estabelecida para este trabalho. Este reagrupamento foi realizado no SPRING através do módulo de mapeamento para geoclasses.

Como resultado deste procedimento foi gerada a segunda imagem temática (T2), com o número de classes definidas de acordo com a legenda adotada para o trabalho (Tabela 3.1). Posteriormente esta imagem foi introduzida no SGI, para que pudessem ser feitas as análises estatísticas.

3.3.3.7 - CLASSIFICAÇÃO SUPERVISIONADA POR MÁXIMA VEROSSIMILHANÇA

A utilização de um sistema de classificação pixel a pixel neste trabalho reside no fato que tal classificador ser empregado com maior frequência nos estudos que envolvem a cobertura vegetal e o uso da terra. Assim, tal como proposto em Corr et al. (1989) e Belaid et al. (1992), o produto gerado pela classificação por máxima verossimilhança (imagem temática T1) foi empregado de modo a fornecer uma base de referência na comparação de resultados com produtos oriundos de classificação pós-segmentação.

Com o objetivo de não beneficiar nenhum sistema de classificação (ISOSEG e MAXVER), foi fornecido o mesmo tipo de informação para todos os algoritmos de classificação. Desta forma, utilizaram-se todas as bandas TM/Landsat nesta etapa.

As informações utilizadas para fornecimento das amostras de treinamento para o algoritmo de classificação foram baseadas nos resultados do trabalho de campo. Procurou-se utilizar um mínimo de 200 pontos de amostragem por cada classe, distribuídos uniformemente sobre toda a imagem.

Durante a fase de aquisição de amostras, as classes de pastagens e sucessão secundária passaram a contar com subdivisões devido apresentarem uma grande amplitude espectral. Na fase de classificação propriamente dita, foi utilizado o limiar de aceitação de 99,9%, o que corresponde a uma grande área das amostras adquiridas. Posteriormente, as classes que contavam com subdivisões foram reagrupadas de acordo com a legenda pré-estabelecida.

3.3.3.8 - CLASSIFICAÇÃO SUPERVISIONADA POR REDES NEURAIIS ARTIFICIAIS

Entre as metas propostas para este estudo encontra-se o treinamento de uma rede neural artificial, especializada nas classes de uso da terra na região de Tucuruí (PA), utilizando para tal treinamento o algoritmo “backpropagation”.

Após o treinamento e cumprido todo o procedimento de equalização da rede, conforme dito na parte introdutória deste trabalho, espera-se realizar o mapeamento das classes de uso da terra utilizando, além dos valores espectrais, informações geométricas, texturais e contextuais (vizinhança). A imagem temática assim gerada pela rede neural poderá ser comparada com imagens temáticas resultantes de algoritmos tradicionais de classificação (Máxima Verossimilhança e ISOSEG).

O sistema completo de classificação por redes neurais que motivou a realização desta pesquisa envolve as etapas definidas na Figura 3.12. Aqui serão descritas as fases propostas para este trabalho, que se referem a rotulação de segmentos e treinamento, sendo que maiores informações sobre este sistema são encontrados em Liporace (1994).

1) Rotulação dos segmentos das imagens

A rede neural se utiliza de segmentos de imagens gerados através do processo de segmentação de imagens. A principal vantagem da utilização de segmentos para uma classificação temática é que estes possuem, além da informação espectral, informações de natureza geométrica e textural, que não podem ser extraídas

individualmente dos pixels, mas que são muito utilizadas no processo de interpretação visual de imagens.

Como foi visto em 2.5.5.1, as redes neurais necessitam de uma base de exemplos para que possam “aprender” e utilizar tais informações na classificação das imagens. A formação desta base de exemplos fundamentou-se na legenda temática: Floresta (F), Sucessão Secundária Avançada (V), Sucessão Secundária Inicial (I), Pasto Limpo (L), Pasto Sujo (U), Cultura Agrícola (G), Área Urbanizada (R), Água (A), Nuvem (N) e Sombra (S), geoclasses estas também identificadas nos métodos convencionais de classificação (Máxima Verossimilhança e ISOSEG).

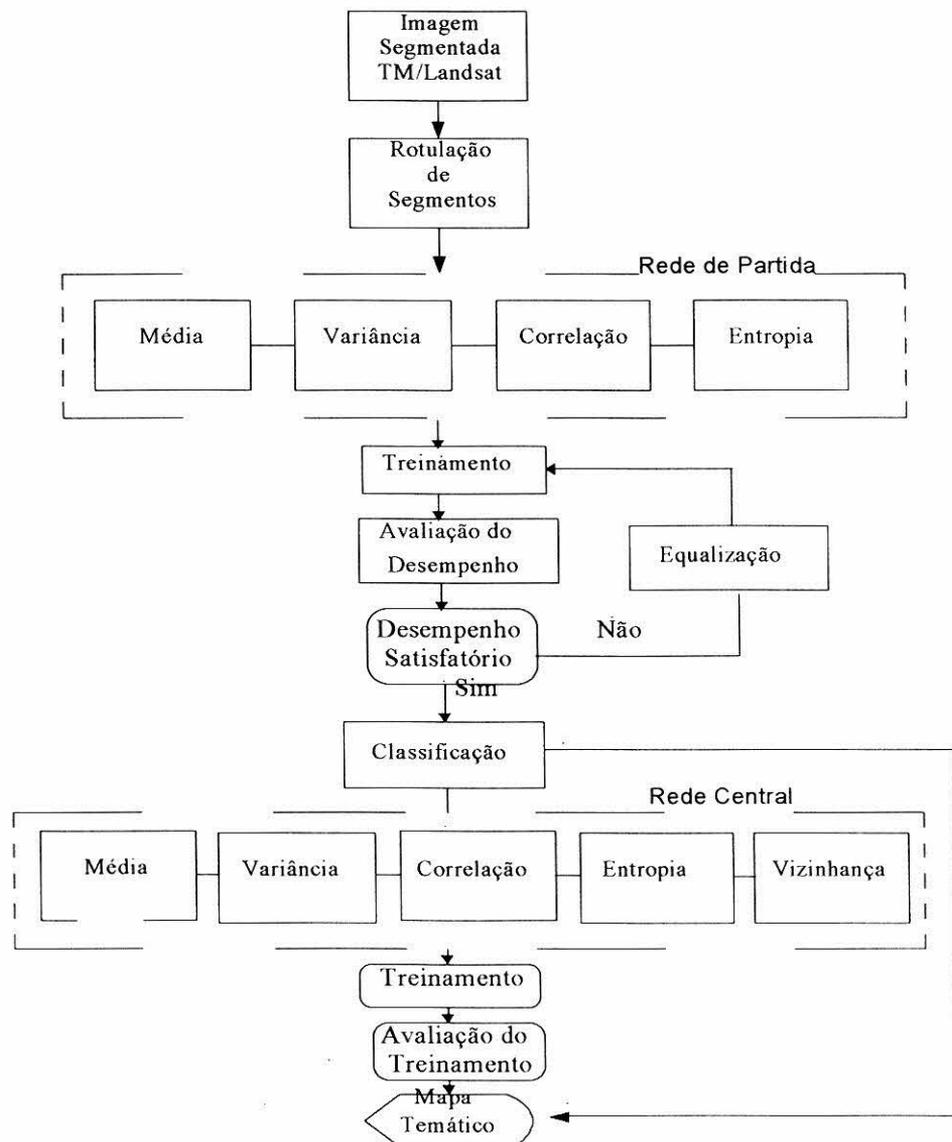


Fig. 3.12 - Sequência de preparação da rede neural.

As classes F, V, I, L, U, G, R e A, foram chamadas de **categorias básicas**, pois são os temas principais a serem mapeados. As classes N e S foram chamadas de **categorias de interferência**, que segundo Liporace (1994), são necessárias por levarem em conta o efeito das nuvens e sombras no processo de classificação.

O conjunto de exemplos utilizado foi elaborado tendo como base a **lógica nebulosa** (*fuzzy logic*). De acordo com Blonda et al. (1995) a principal vantagem da utilização desta abordagem é que permite modelar os fenômenos de transição, como os diferentes estádios de vegetação secundária e pastagens, e incertezas devidas a fenômenos de fronteira, pois estas possuem características dos diferentes alvos devido as particularidades inerentes a resolução do sensor TM/Landsat.

A lógica nebulosa permite que sejam atribuídos graus de pertinência parciais entre os conceitos booleanos de verdadeiro e de falso, representados numericamente pela faixa dos números reais entre 0 e 1.

Na elaboração da base exemplos foi utilizado o programa de rotulação nebulosa de segmentos desenvolvido pelo DPI-INPE (Figura 3.13) e em algumas áreas foi utilizado o sistema NICE-IBM. De forma a facilitar a rotulação de cada segmento, a faixa contínua entre 0 e 1 foi discretizada em cinco níveis (0; 0,25; 0,5; 0,75, e 1), utilizados de acordo com a característica de cada segmento.

A fase de rotulação de segmentos foi dividida em duas partes **A** e **B**: A primeira etapa (**A**) foi destinada a identificação de todos os segmentos do módulo da imagem de treinamento para a rede neural, na formação da base de conhecimento. Neste processo, cada segmento foi analisado individualmente e recebeu uma rotulação de acordo com o tipo de vegetação e/ou uso que estivesse ocorrendo.

A utilização da lógica nebulosa permitiu que um segmento obtivesse rotulação com grau de pertinência total (1) para classes ditas "puras", sem pertinência (0) e pertinências parciais (0,75, 0,50 e 0,25) para segmentos onde ocorresse uma mistura entre as classes temáticas. Utilizou-se ainda como regra no processo de rotulação que o somatório dos pesos dados à cada segmento, sem a presença de interferências (Nuvem e Sombra) deveria ser igual a 1, e que na presença destas interferências os segmentos poderiam possuir um somatório maior que 1. Esta regra

possibilitou, p.e, que um segmento considerasse pertinência 0,75 para a classe X , 0,25 para a outra classe Y e ainda 0,25 de interferência.

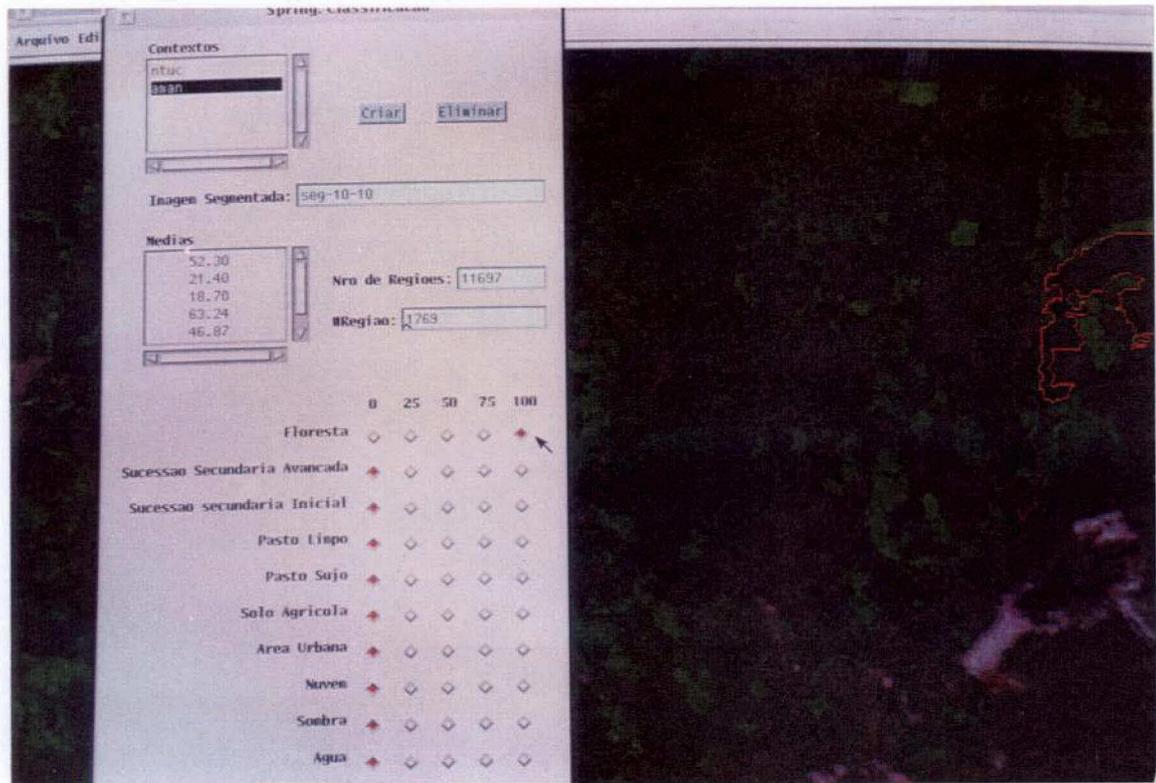


Fig. 3.13 - Interface gráfica para rotulação nebulosa de segmentos

A segunda fase (**B**) compreendeu a rotulação dos segmentos pelo mesmo processo, porém dentro da área de teste, tendo como objetivo avaliar o desempenho da rede e também gerar uma imagem de referência (verdade de campo). Esta separação entre “área de treinamento” e “área de teste” se fez necessário para que não houvesse nenhuma tendência por parte dos algoritmos classificadores em definir corretamente somente os segmentos que serviram como amostra (Liporace, 1994).

Na fase (**B**) não foi feita a rotulação de toda imagem como efetuado na área de treino, visto que a finalidade deste procedimento foi de monitorar o desempenho da rede, e ainda servir de referência às imagens temáticas geradas pelos diferentes processos de classificação. O produto resultante deste processo, apresentando todas as classes temáticas no módulo de treino de forma significativa foi introduzido no SGI, para que pudessem ser submetidas à análise estatística. Ambas rotulações das fases (**A**) e (**B**) foram realizadas com base na experiência do fotointérprete que contou ainda com o apoio de trabalho de campo descrito no item 3.3.2.

2) Treinamento da Rede

Após a rotulação da área de treino, formou-se uma **rede de partida** que utilizou o algoritmo *backpropagation* para o treinamento. Nesta rede, foram utilizados os descritores, que são as informações numéricas extraídas de cada segmento a partir da forma e do conteúdo do mesmo considerando-se o conjunto das bandas TM/Landsat, recomendados por Liporace (1994) e descritos a seguir. No total foram utilizados seis descritores espectrais e os descritores de textura baseados na variância, correlação e entropia.

Descritor Espectral - Relativo ao nível de cinza médio de cada segmento. Dada uma banda b , do TM, o descritor espectral de um segmento $De(S)$ é definido pelo nível de cinza médio dos pixels que estão contidos neste segmento, sendo calculado por:

$$De(S) = \frac{1}{|S|} \sum_{(i,j) \in S} I_{ij}^b \quad (3.1)$$

Descritores Texturais - Relacionados com atributos de suavidade, rugosidade e regularidade de um segmento de imagem:

Variância: $Vb(S)$

$$Vb(S) = 1 - \frac{1}{1 + \sigma^2(S)} \quad (3.2)$$

Correlação: Co

$$co(S, \theta) = \frac{\sum_{z_1=0}^{L-1} \sum_{z_2=0}^{L-1} (z_1 - \mu_1(S, \theta))(z_2 - \mu_2(S, \theta)) C_{z_1 z_2}(1, \theta)}{\sigma_1(S, \theta) \sigma_2(S, \theta)} \quad (3.3)$$

onde:

$$\mu_1(S, \theta) = \sum_{z_1=0}^{L-1} Z_1 \sum_{z_2=0}^{L-1} C_{z_1 z_2}(1, \theta), \quad (3.4)$$

$$\mu_2(S, \theta) = \sum_{z_1=0}^{L-1} Z_1 \sum_{z_2=0}^{L-1} Z_2 C_{z_1 z_2}(1, \theta), \quad (3.5)$$

$$\sigma_1^2(S, \theta) = \sum_{z_1=0}^{L-1} (Z_1 - \mu_1(S, \theta))^2 \sum_{z_2=0}^{L-1} C_{z_1 z_2}(1, \theta), \quad (3.6)$$

$$\sigma_2^2(S, \theta) = \sum_{z_1=0}^{L-1} \sum_{z_2=0}^{L-1} (Z_2 - \mu_2(S, \theta))^2 C_{z_1 z_2}(1, \theta). \quad (3.7)$$

Entropia: ent

$$ent(S, \theta) = - \sum_{z1=0}^{L-1} \sum_{z2=0}^{L-1} C_{z1z2}(S, \theta) \ln C_{z1z2}(S, \theta) \quad (3.8)$$

Durante esta fase foi sendo realizado um monitoramento dos índices que avaliam o desempenho de rede, associada a cada classe temática. Para esta avaliação foram utilizados:

(Erro Médio Quadrático) MSE - Através do processo de treinamento procura-se minimizar esta função para o conjunto de segmentos utilizados para treinamento e teste. Segundo Liporace (1994) este é o índice mais natural para verificação do desempenho da rede, sendo definido como:

$$MSE = \frac{1}{M} \sum_{\mu=1}^M \frac{1}{2} \sum_{i=1}^{10} [F_i^{\mu} - R_i^{\mu}]^2 \quad (3.9)$$

Onde: $F^{\mu} = \{F_1^{\mu}, F_2^{\mu}, \dots, F_{10}^{\mu}\}$ é o vetor resultante da rotulação visual dada a cada segmento S^{μ} pertencentes ao conjunto $S = \{S^1, S^2, \dots, S^M\}$, e $R^{\mu} = \{R_1^{\mu}, R_2^{\mu}, \dots, R_{10}^{\mu}\}$ é o vetor resultante da classificação da rede neural para o mesmo conjunto de segmentos.

Sensibilidade e Especificidade - Estes índices estão relacionados com a capacidade da rede neural em detectar (sensibilidade) e rejeitar (especificidade) cada tema. Definindo um limiar de aceitação L , dado um conjunto de dez matrizes M_c , com $c = \{1, 2, \dots, 10\}$, associando cada matriz a uma classe c , a cada elemento m_{ij} , com $0 \leq i \leq 1$ e $0 \leq j \leq 1$, definimos:

m_{00} : Número de segmentos em S onde $F_c^{\mu} < L$ e $R_c^{\mu} < L$.

m_{01} : Número de segmentos em S onde $F_c^{\mu} \geq L$ e $R_c^{\mu} < L$.

m_{10} : Número de segmentos em S onde $F_c^{\mu} < L$ e $R_c^{\mu} \geq L$.

m_{11} : Número de segmentos em S onde $F_c^{\mu} \geq L$ e $R_c^{\mu} \geq L$.

Segundo Liporace (1994), um classificador ideal, que não cometesse erros, geraria matrizes M_c onde os elementos m_{01} e m_{10} seriam iguais a zero. Dessa forma, define-se a sensibilidade e a especificidade de uma rede neural, num dado conjunto de segmentos S , para uma determinada classe c através das equações:

$$\text{Sens}(S, c) = \frac{m_{11}}{m_{11} + m_{01}} \quad (3.10)$$

$$\text{Esp}(S, c) = \frac{m_{00}}{m_{00} + m_{10}} \quad (3.11)$$

Concluída esta fase, que se constitui em um dos objetivos deste trabalho, tivemos a indicação do desempenho de cada classe e assim foi possível separar quais redes estavam aptas a prosseguir para a próxima fase, de classificação, e aquelas que deveriam passar por um processo de equalização até a formação de uma nova rede neural. A equalização é realizada pois em um treinamento normal, classes pouco representadas no banco de exemplos tendem a ser ignoradas, pois o sistema visa minimizar o erro médio quadrático, e esse erro continua baixo mesmo desprezando uma classe pouco representada. O procedimento de equalização simula a ampliação do número de amostras de classes menos representadas no banco de exemplos, de tal forma a forçar que o algoritmo de treinamento a leve em consideração.

Após o treinamento e avaliação da rede de partida (treinamento, equalização e retreinamento) deverá ser construída uma nova rede para incorporação de descritores contextuais. Essa rede passará por um treinamento, utilizando como valores iniciais dos pesos aqueles da rede de partida (e pesos aleatórios para as conexões novas introduzidas). Nesta nova rede, cada segmento S é apresentado à rede neural, agora denominada de **rede central**. A rede neural, através da informação proporcionada pelos descritores de vizinhança, consegue melhorar substancialmente a qualidade da classificação de imagens, principalmente nos casos de presença de interferência e de classes espectralmente semelhantes (p.e. sombra e água)

Cada segmento apresentado à rede central gera um vetor em $[0,1]^{10}$ cujas componentes são interpretadas como graus de pertinência de S a cada uma das classes F, V, I, L, U, G, R, A, N e S representadas como apresentada na Figura 3.14.

3.3.4 - ANÁLISE ESTATÍSTICA DAS IMAGENS TEMÁTICAS

Nesta etapa as imagens temáticas (T1 e T3), resultantes dos algoritmos isoseg e máxima verossimilhança, foram comparadas com a imagem de referência (R1) através da estatística Kappa, sendo sobrepostas a partir do SGI. O objetivo desta análise foi verificar qual dos classificadores utilizados apresentou melhor desempenho na caracterização da cobertura vegetal e demais classes de uso da terra, em comparação com a imagem de referência. Nesta análise, foi também observado o desempenho

apresentado pelos algoritmos de classificação visando a discriminação de cada classe envolvida neste trabalho.

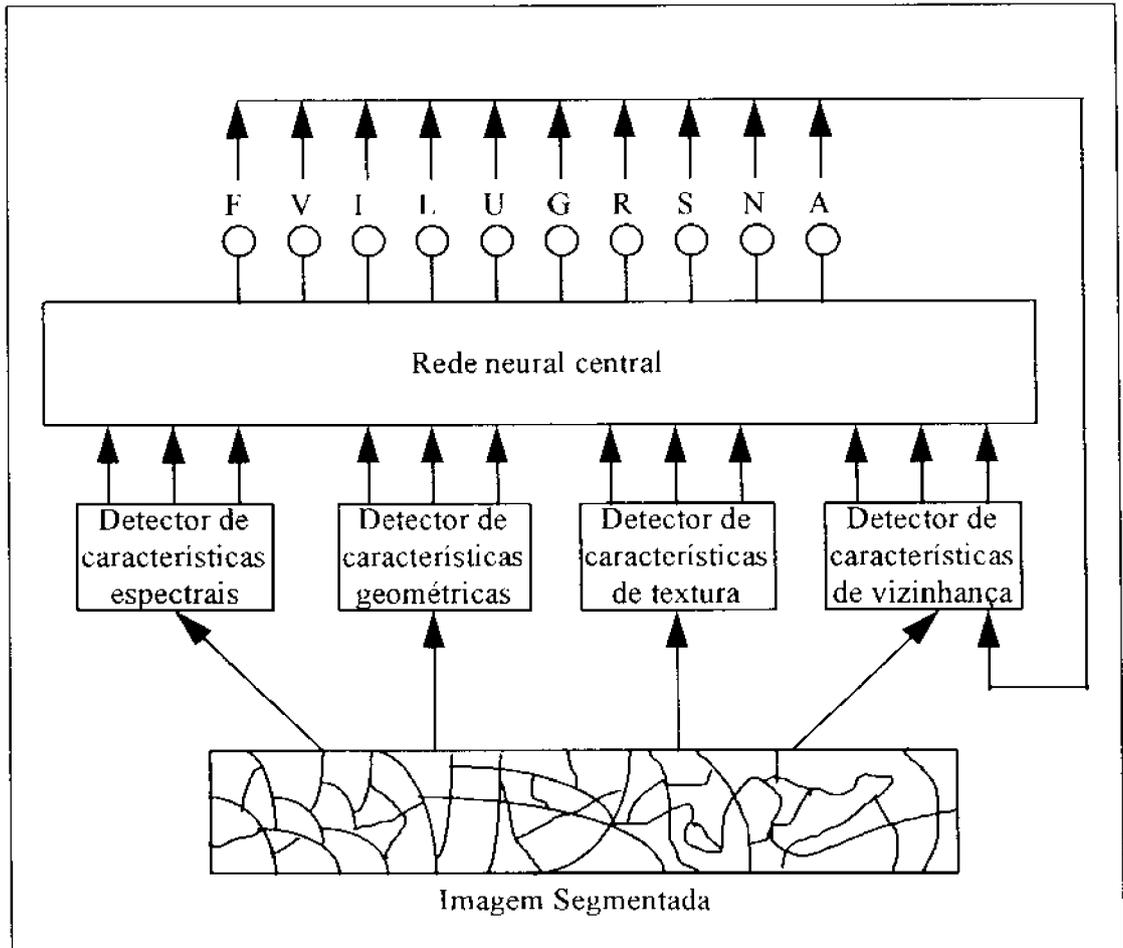


Fig. 3.14 - Arquitetura do sistema classificador por redes neurais artificiais.

FONTE: Adaptada de Liporace (1994).

CAPÍTULO 4

RESULTADOS E DISCUSSÃO

O desenvolvimento deste trabalho foi subdividido em várias partes constituintes de acordo com a proposta apresentada, de forma que os resultados foram sendo alcançados em cada passo metodológico. Desta forma, serão apresentados os resultados referentes a legenda temática, os processamentos digitais, ao trabalho de campo, avaliação dos métodos de classificação digital para a caracterização da vegetação e uso da terra na Amazônia e sobretudo, o desempenho do treinamento das redes neurais artificiais.

4.1 - AVALIAÇÃO DA LEGENDA TEMÁTICA

A legenda temática utilizada nesta trabalho teve origem no trabalho de campo realizado na região e ainda contou com a combinação entre os diversos trabalhos abrangendo a vegetação e outros tipos de uso da terra na Amazônia. O trabalho de campo possibilitou, através da descrição de 138 pontos de observação, a correlação das paisagens naturais com os padrões da imagem TM/Landsat. Desta forma, foi possível a discriminação de Florestas, Sucessão Secundária Avançada, Sucessão Secundária Inicial, Pasto Sujo, Pasto Limpo, Cultura Agrícola (Figura 4.1) e ainda Áreas Urbanas, Água, Nuvem e Sombra. A grande preocupação na elaboração da mesma, foi a de manter a estrutura utilizada por Anderson et al. (1979) que possibilita uma grande flexibilidade na manipulação dos temas, de acordo com as necessidades do produto gerado.

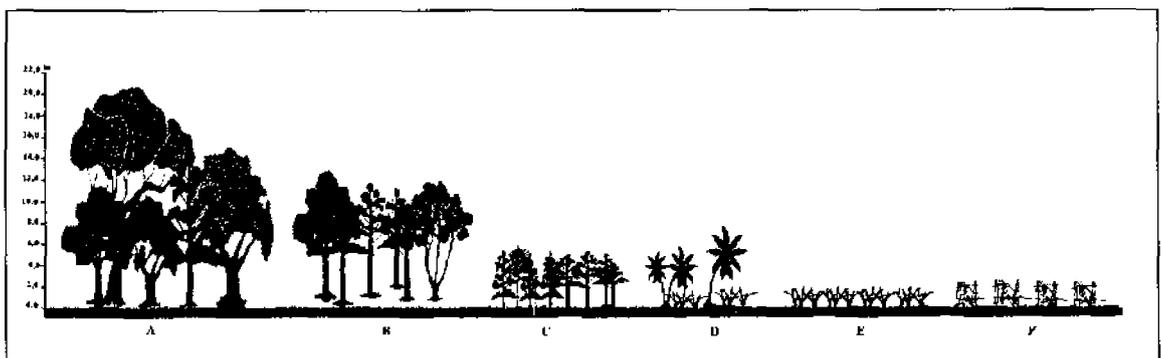


Fig 4.1 - Perfil esquemático da paisagem na região de influência da represa de Tucuruí.
A) Floresta; B) Sucessão Secundária Avançada; C) Sucessão Secundária Inicial; D) Pasto Sujo; E) Pasto Limpo e F) Cultura Agrícola.

Desta forma, as informações geradas neste trabalho, originadas através de interpretação de imagens TM/Landsat em papel fotográfico na escala de semi-detulhe (1:100.000) e das verificações de campo, podem ser cartografadas para escalas menores, de reconhecimento (1:250.000) como a adotada no projeto PRODES-INPE (Figura 4.2).

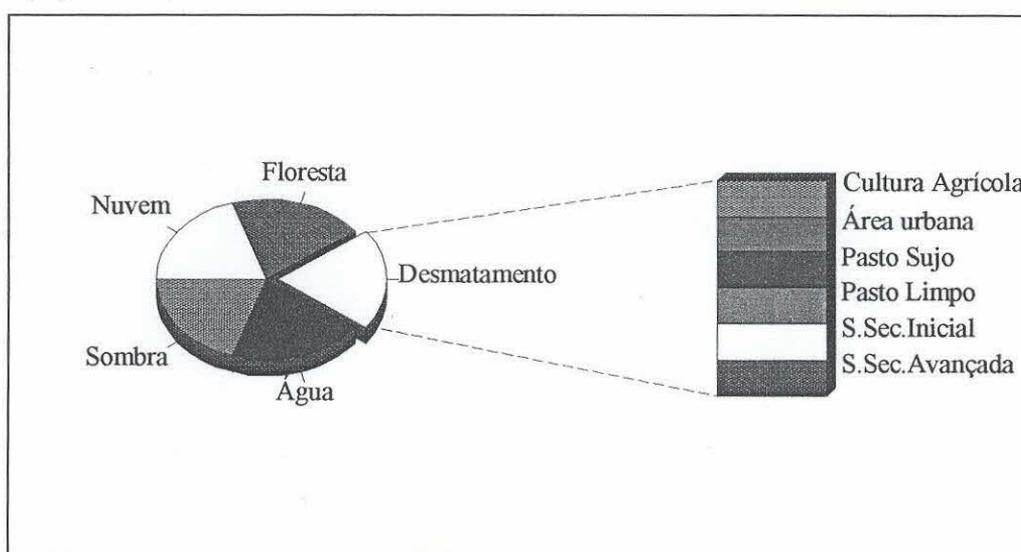


Fig 4.2 - Exemplo de agrupamento das classes em função da legenda adotada no Programa de Desflorestamento da Amazônia.

Da mesma forma, esta legenda pode ainda ser utilizada para trabalhos a nível de detalhe em algumas regiões, utilizando-se neste casos de mais alguns produtos de sensoriamento remoto como fotografias aéreas e/ou imagens orbitais de maior resolução espacial.

4.2 - AVALIAÇÃO DAS TÉCNICAS DE PRÉ-PROCESSAMENTO

4.2.1 - REGISTRO DE IMAGENS

Foram realizadas duas operações de registro de imagens TM/Landsat com as cartas topográficas da área de estudo. Para este processamento foi observado que o índice de precisão deveria ficar dentro dos limites de precisão cartográfica conforme recomendado por Espartel (1982), ou seja, superior a 0,2 mm da escala da carta topográfica utilizada como referência. Utilizando-se uma base topográfica na escala 1:100.000, a precisão exigida é de 20 m. Sendo a resolução espacial da imagem TM/Landsat de 30 m, o registro deveria apresentar um erro interno de posicionamento inferior a 0,66 pixel, como de fato ocorreu (Tabela 4.1).

TABELA 4.1 - APRESENTAÇÃO DOS ÍNDICES DE PRECISÃO OBTIDOS PARA AS ETAPAS DE REGISTRO DE IMAGENS.

Módulo de Estudo	Nº de Pontos Utilizados	Erro Interno dos Pontos Utilizados no Mapeamento		
		Horizontal	Vertical	Total
Tucuruí	7	0,407	0,420	0,520
Goianésia	7	0,390	0,350	0,512

A precisão alcançada no registro de imagens foi de fundamental importância para a sobreposição dos pontos coletados no campo com GPS, o que serviu para reconhecimento dos padrões de cada classe bem como para elaboração da chave de interpretação.

4.3 - SEGMENTAÇÃO DE IMAGENS

Foram testados diferentes níveis de segmentação nos dois módulos de interesse objetivando a definição dos valores necessários à segmentação das imagens. Foram utilizados cinco valores de limiares de similaridade (6, 8, 10, 12 e 14), sendo possível observar que os menores valores (6 e 8) apresentavam uma fragmentação excessiva (Figura 4.3) ou seja, uma mesma classe temática com uma pequena variância apresentava-se demasiadamente particionada.

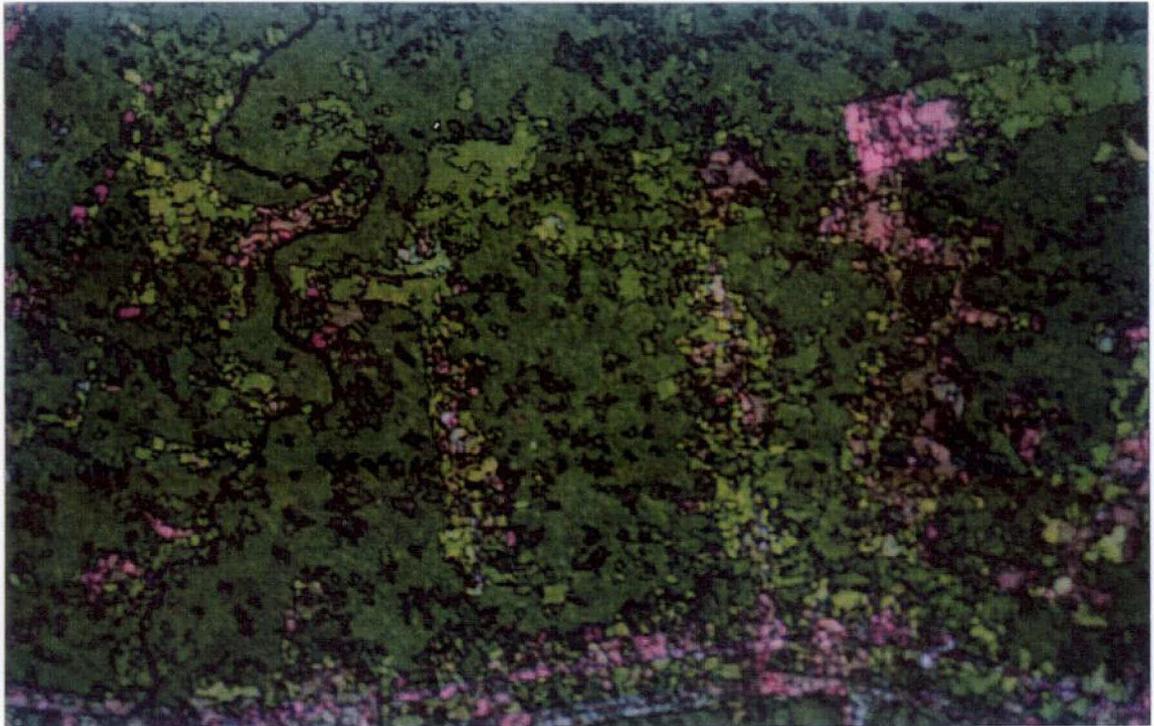


Fig 4.3 - Segmentação excessiva utilizando-se limiar de similaridade 6.

Para maiores valores de limiar de similaridade (12 e 14), observou-se que ocorria uma sub-segmentação, de forma que diferentes classes temáticas compartilhavam um mesmo segmento (Figura 4.4).

Os resultados que melhor representaram a verdade terrestre foram obtidos com limiar de similaridade igual a 10, o mesmo utilizado por Machado et al. (1993) e Liporace (1994). Com este valor as imagens foram particionadas de forma uniforme sem que houvesse qualquer perda de informação em nível de contorno das classes (Figura 4.5).

O limiar de área foi mantido fixo em todas as análises, ou seja 10 pixels, visto que poucos locais presentes na área de estudo possuem padrões de uso com áreas inferior a este valor. Outro fator que contribuiu na escolha deste valor foram os trabalhos de Machado et al. (1993) e Fidalgo (1995), que observaram haver uma quantidade maior de erros de classificação em pequenos segmentos.

O tempo de processamento para segmentação de imagens é diretamente proporcional ao número de bandas envolvidas e inversamente proporcional ao limiar de área e ao limiar de similaridade estabelecidos.

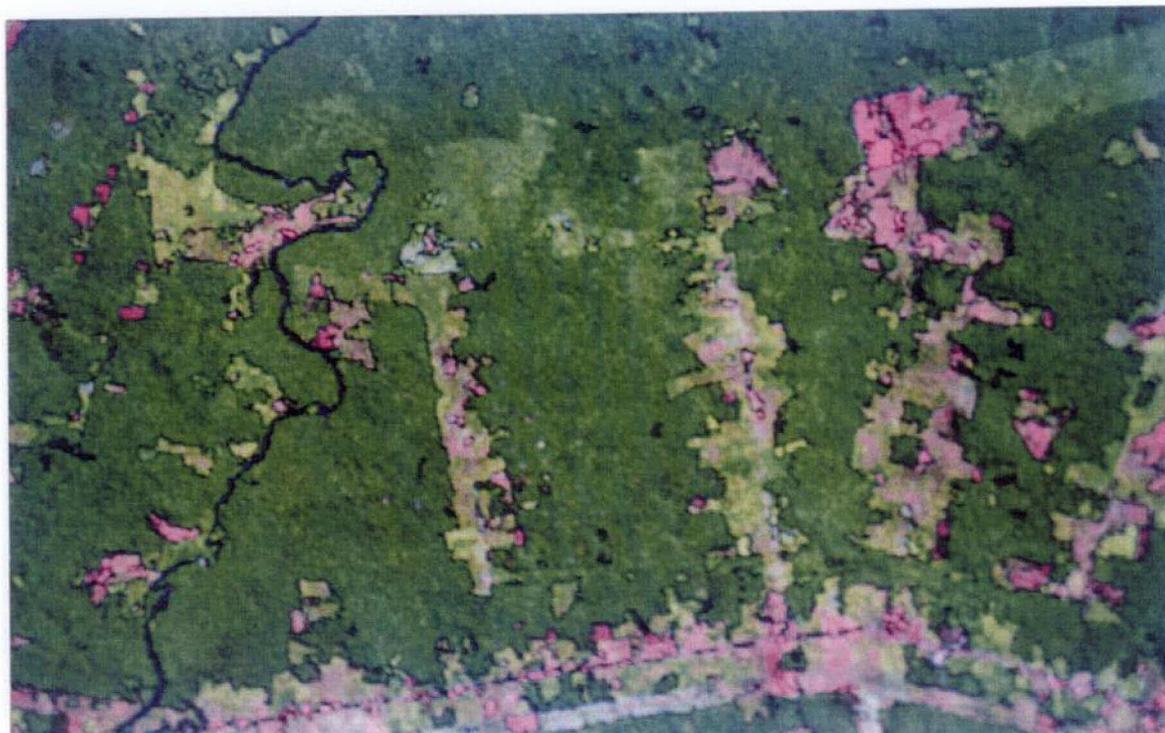


Fig. 4.4 - Sub-segmentação utilizando-se limiar de similaridade 14.

Nesta fase, a eficiência do algoritmo de segmentação de imagens foi avaliada visualmente, sendo possível observar que as diferentes formações observadas no campo e identificadas pela interpretação visual na tela do computador estavam separadas pelas bordas geradas no processo.

O esforço computacional gasto no processo foi diretamente proporcional ao número de bandas envolvidas e inversamente proporcional ao limiar de similaridade utilizado. Para segmentar cada módulo de imagem (1025 colunas x 763 linhas) foi necessário, em média, 45 minutos de processamento nas estações SUN-Sparc 10, com as seis bandas de interesse (TM 1 a 5 e 7).



Fig. 4.5 - Segmentação considerada ideal com limiar de similaridade 10.

4.4 - RECONHECIMENTO DE PADRÕES

As imagens particionadas foram importadas para o SGI/INPE onde foi possível identificar e localizar, com auxílio dos pontos de verificação no campo coletados com auxílio do GPS, as diferentes classes de vegetação e uso da terra. Através desta observação foi possível elaborar uma chave de classificação (Tabela 4.2) que pôde ser assim utilizada para interpretação de toda área de estudo.

Esta identificação foi necessária para execução de algumas fases da metodologia proposta tais como: geração da imagem de referência (verdade de campo), aquisição de amostras de treinamento para a classificação Maxver e rotulação dos segmentos necessários à rede neural.

Podemos observar na Tabela 4.2 que ocorre uma mistura de cores em duas classes temáticas. A variabilidade na classe pasto limpo é função de diferentes espécies plantadas, condições fitofenológicas de pastejo e diferentes estádios de desenvolvimento, o que está diretamente associado com a influência do solo na composição do sinal que chega ao sensor. Na classe pasto sujo, predominam em

diversas áreas o babaçu (*Orbignia martiana*), outras há maior incidência de inajá (*Maximiliana maripa*), além da variabilidade estrutural arbustiva ocasionada pelos processos de substituição da pastagem plantada pela vegetação natural (juquira).

TABELA 4.2 - CHAVE DE INTERPRETAÇÃO VISUAL EM IMAGEM TM 3B/4G/5R PARA AS CLASSES DE USO DA TERRA EM TUCURUI (PA).

Classe	Cor	Textura	Limite	Forma
Floresta Primária	Verde Escuro	Rugosa	Irregular	Irregular
Sucessão Secundária Avançada	Verde Médio	Média	Irregular e Regular	Regular
Sucessão Secundária Inicial	Verde Claro	Lisa a Média	Geralmente Regular	Geralmente Geométrica
Pasto Limpo	Rosa, Magenta e Laranja	Lisa	Regular	Geométrica
Pasto Sujo	Ciano, Verde Claro e Azul Claro	Lisa	Regular	Geométrica
Solo Agrícola	Magenta	Lisa	Regular	Geométrica
Área Urbana	Magenta Brilhante	Rugosa	Regular	Geométrica
Água	Azul Escuro	Lisa	Irregular	Sinuosa
Nuvem	Branca	Lisa	Irregular	Irregular
Sombra	Preta	Lisa	Irregular	Irregular

4.5 - ROTULAÇÃO DE SEGMENTOS

A combinação de técnicas de processamento digital e interpretação visual de imagens foi bastante satisfatória no que diz respeito a formação de uma base de treinamento para as redes neurais e ainda na geração de imagens de referência para análise dos dados classificados. A utilização de uma interface gráfica para rotulação de segmentos desenvolvida pelo INPE e também o sistema NICE da IBM, foram de fundamental importância à realização desta fase.

Com estas ferramentas, foi possível interpretar visualmente através da tela do computador a imagem, aproveitando-se desta forma de todas as informações

normalmente utilizadas para tal tarefa, porém com maior agilidade e precisão já que os contornos dos polígonos foram obtidos no processo de segmentação de imagens.

Tal procedimento permitiu que fossem eliminadas duas fontes de erros normalmente presentes nos processos de extração de informações de imagens de sensoriamento remoto, ou seja as deformações sofridas pelos “overlays” utilizados nas interpretações manuais e ainda o erro na digitalização destas informações para um “SIG”.

Este procedimento foi utilizado na geração da base de conhecimento necessária ao treinamento da rede neural (módulo de treino) e das imagens de referência R1 e R2 (módulo de teste).

Na formação da base de conhecimento necessária ao treinamento da rede neural foram rotulados através da lógica nebulosa 11.697 segmentos, utilizando procedimento descrito em 3.3.4.3, conforme apresentado na Tabela 4.3

TABELA 4.3 - TOTAL DE SEGMENTOS/PIXELS ROTULADOS PARA FORMAÇÃO DA BASE DE TREINAMENTO DAS REDES NEURAI

Classe	Nº de Pixels	Nº de Segmentos
Floresta	23.306	656
Sucessão Secundária Avançada	66.222	1.146
Sucessão Secundária Inicial	21.922	407
Pasto Limpo	29.709	498
Pasto Sujo	75.326	2.147
Solo Agrícola	2.763	69
Área Urbana	14.254	507
Nuvem	20.078	2.274
Sombra	26.873	1.215
Água	12.554	1.691
Outros	29.093	1.087
TOTAL	322.100	11.697

A utilização da lógica nebulosa permitiu que ocorressem várias combinações de pertinências para cada classe (Tabelas B1 a B10), indicando as transições entre as classes “vizinhas” (Figura 4.6).

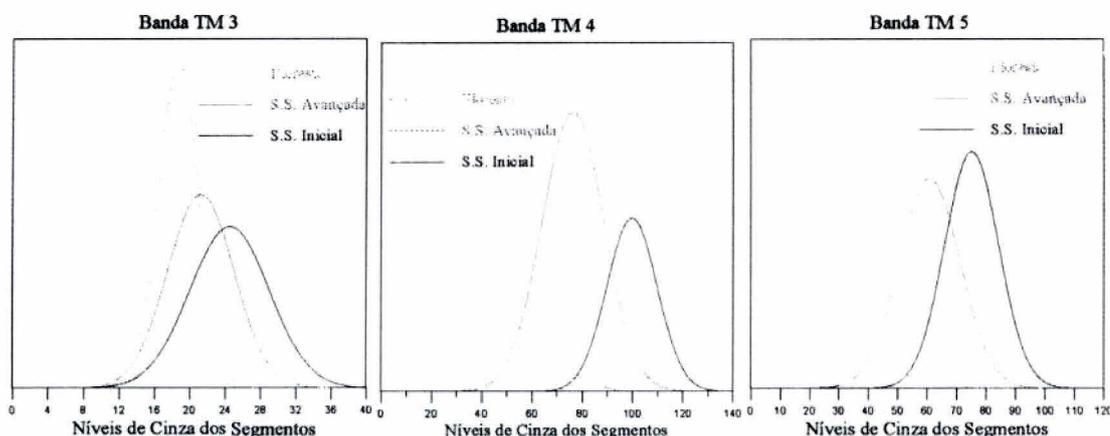


Fig. 4.6 - Comportamento dos níveis de cinza médios dos segmentos rotulados como Floresta, Sucessão Secundária Avançada e Sucessão Secundária Inicial nas Bandas TM/Landsat.

A Figura 4.7 apresenta, para cada classe rotulada, os percentuais de segmentos nos quais ocorreram combinações de pertinências (totais e parciais). Observa-se um maior grau de combinações entre classes vizinhas, representadas por pastagens e estádios sucessionais, justificado pela ocorrência de regiões de transição entre estes temas, como pode ser observado no perfil esquemático apresentado na Figura 4.1.

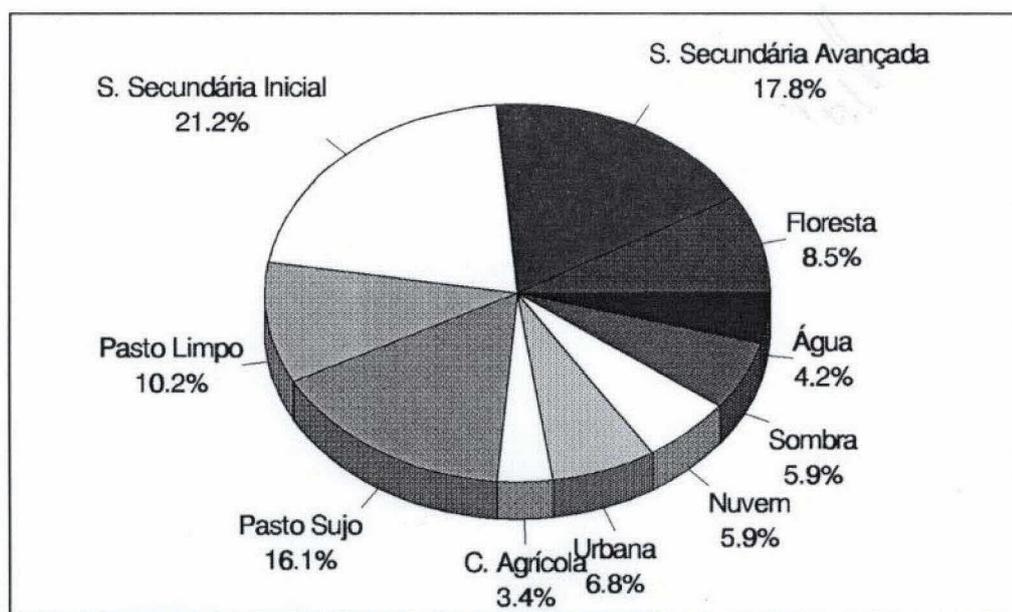


Fig. 4.7 - Percentual de combinações de pertinências para cada classe temática.

A Figura 4.8 apresenta a distribuição das ocorrências de combinações de Floresta, Sucessão Secundária Avançada, Sucessão Secundária Inicial, Pasto Sujo e Pasto Limpo, quando comparadas às demais classes⁴. Para a realização desta análise foram considerados os segmentos com grau de pertinência igual ou superior a 0,75, para os temas mencionados.

Para a Floresta (Figura 4.8a), o maior número de combinações ocorreu com a classe S, em função do efeito de sombreamento promovido pelo relevo e ocorrência de nuvens. As classes Floresta e V apresentaram combinações em função de semelhanças texturais e de cor em alguns pontos da imagem. A utilização da lógica nebulosa possibilitou ainda a identificação de segmentos anômalos (F+A e F+V+A) e segmentos com a presença de classes de interferência (F+V+S, F+S e F+N).

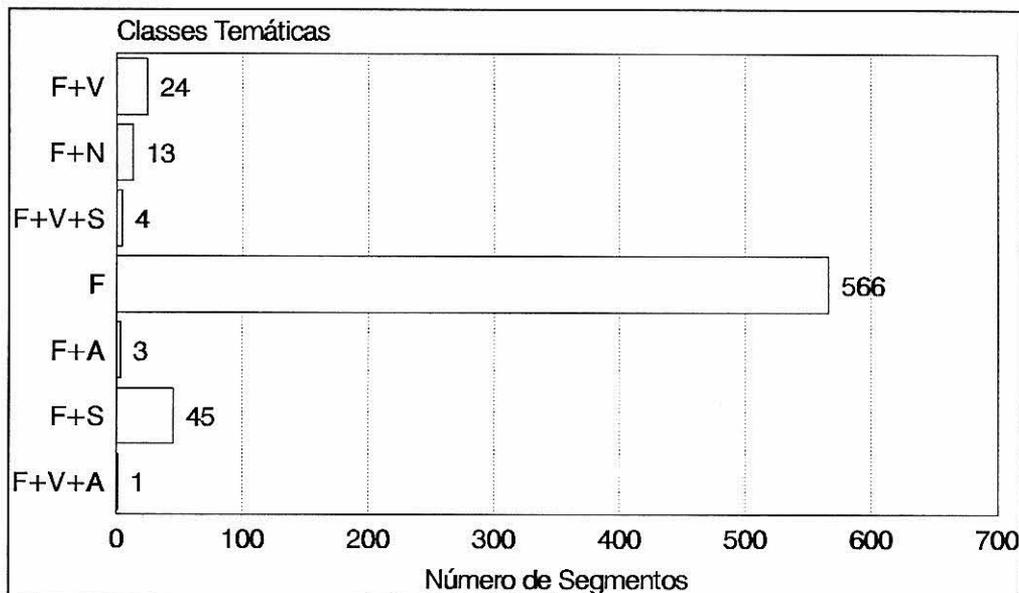


Fig. 4.8a - Distribuição dos números de combinações de pertinência entre classes, para o tema Floresta.

Para os temas Sucessão Secundária Avançada e Inicial, observou-se uma elevada combinação entre classes vizinhas, assim como a presença de interferências nos segmentos (Figuras 4.8b a 4.8c). Para Sucessão Secundária Avançada, a maior ocorrência são de segmentos rotulados com pertinência total (1), seguido das combinações de pertinências parciais (0,25) para as demais classes (V+I e V+F).

⁴ F-Floresta; V-Sucessão Secundária Avançada; I-Sucessão Secundária Inicial; U-Pasto Sujo; L-Pasto Limpo; G-Cultura Agrícola; R-Área Urbana; A-Água; N-Nuvem e S-Sombra.

Na Sucessão Secundária Inicial, o número de segmentos com pertinência total foi inferior ao número de segmentos com presença da classe U. Esta interferência poderia ser minimizada, através da utilização de diferentes limiares durante a segmentação da imagem, os quais permitiriam a separação destas classes em segmentos distintos. No entanto, este procedimento implicaria na geração de um número excessivo de segmentos para as demais classes. Desta forma, este resultado foi considerado satisfatório para a imagem analisada.

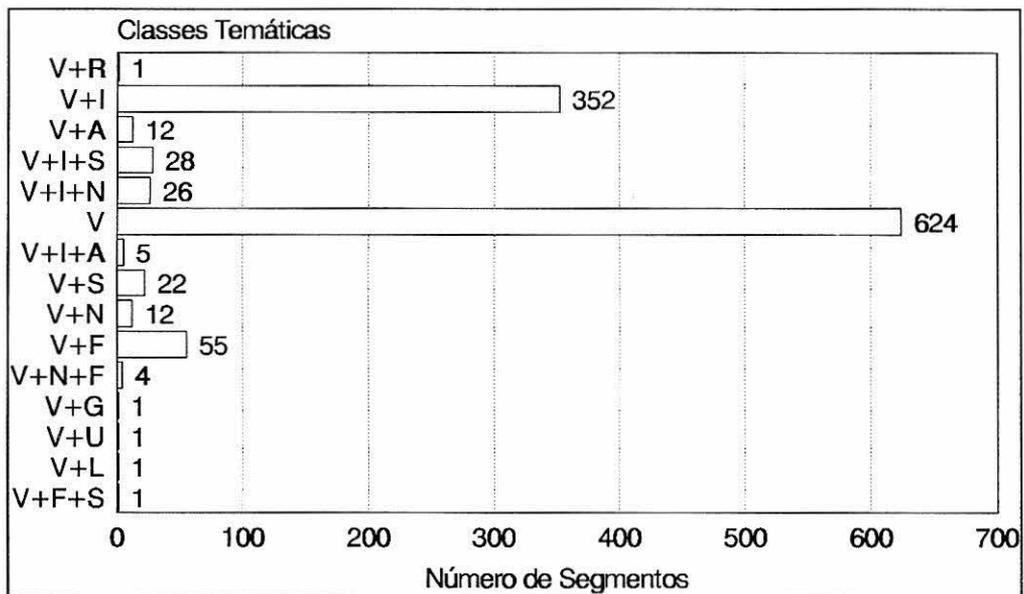


Fig. 4.8b - Distribuição dos números de combinações de pertinência entre classes, para o tema Sucessão Secundária Avançada.

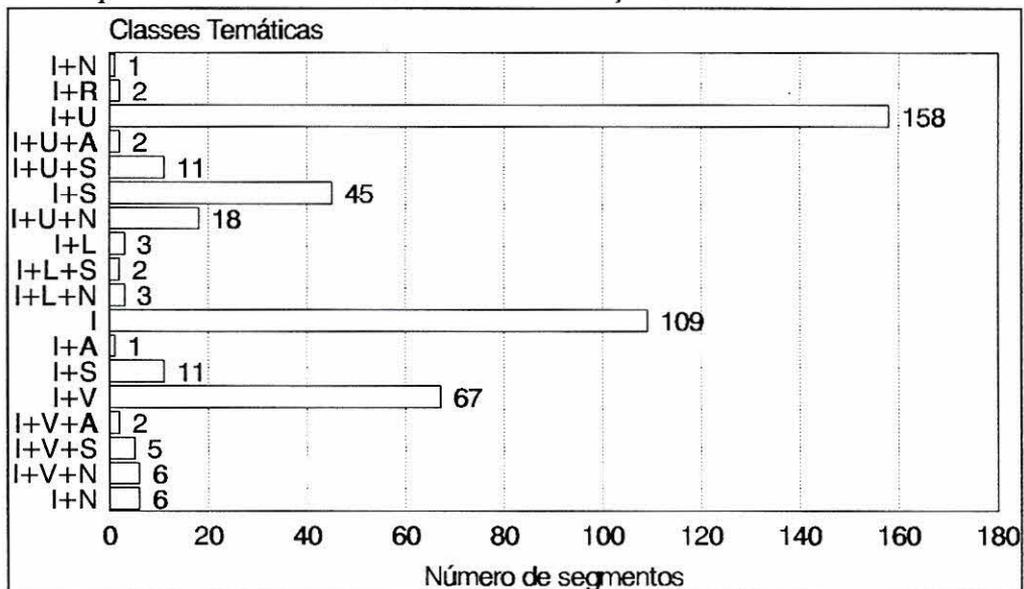


Fig. 4.8c - Distribuição dos números de combinações de pertinência entre classes, para o tema Sucessão Secundária Inicial.

Para a classe Pasto Sujo (Figura 4.8d), a maioria dos segmentos foi rotulada com pertinência total. Observa-se uma semelhança entre as classes L e I, no que se refere ao número de segmentos com pertinências parciais. Este resultado apresenta-se coerente com os dados de campo, visto que, na dinâmica da sucessão, a classe Pasto Sujo é intermediária entre as classes Pasto Limpo e Sucessão Secundária Inicial, considerando ainda que as transições entre estes temas, via de regra, não são bem definidas.

No Pasto Limpo (Figura 4.8e) predominam segmentos com pertinência total. A presença de pertinência parcial ocorre basicamente com a classe U, possivelmente em função da ocorrência de degradação nas pastagens da região analisada. A ocorrência de pertinência com a classe G, a qual também apresenta elevada influência da resposta espectral do solo, não foi verificada devido à facilidade de identificação, através de interpretação visual, a partir dos atributos cor, forma, dimensão e textura.

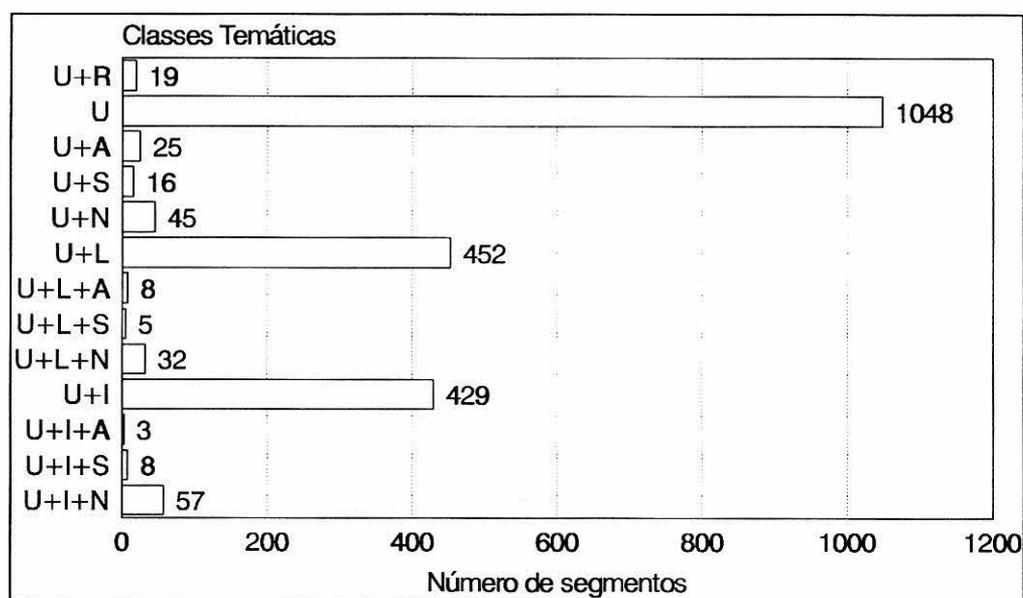


Fig. 4.8d - Distribuição dos números de combinações de pertinência entre classes, para o tema Pasto Sujo.

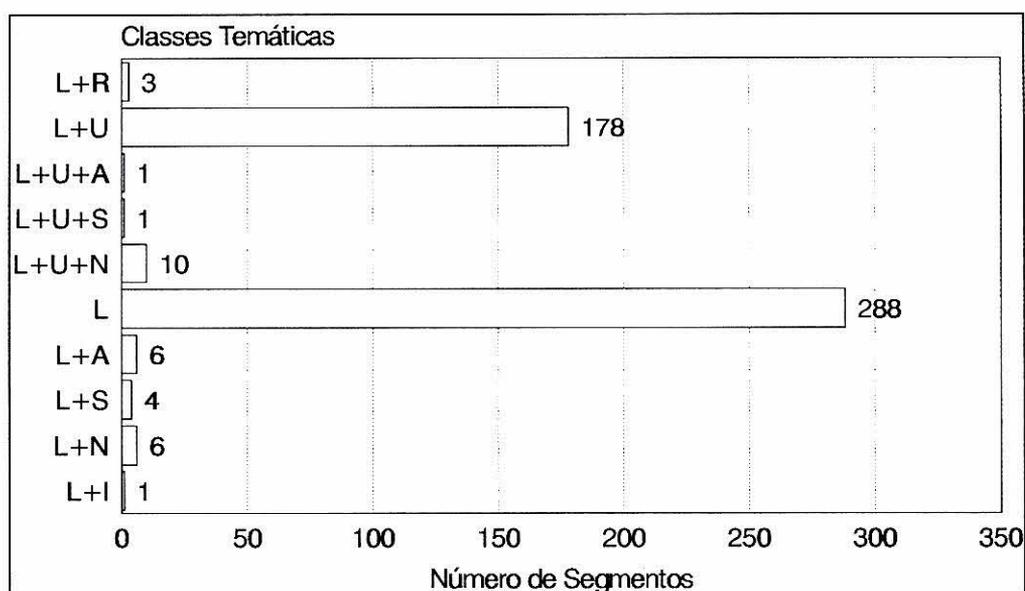


Fig. 4.8e - Distribuição dos números de combinações de pertinência entre classes, para o tema Pasto Limpo.

Para formação da imagem de referência R2 (módulo de teste), foram rotulados pelo mesmo processo 3.336 segmentos de imagem, distribuídos entre todas as classes presentes na legenda temática conforme pode ser observado na Tabela 4.4.

TABELA 4.4 - TOTAL DE SEGMENTOS/PIXELS ROTULADOS PARA FORMAÇÃO DA IMAGEM DE REFERÊNCIA (R2)

Classe	Nº de Pixels	Nº de Segmentos
Floresta	23.108	525
Sucessão Secundária Avançada	39.228	437
Sucessão Secundária Inicia	4.706	88
Pasto Limpo	12.638	260
Pasto Sujo	13.061	934
Solo Agrícola	2.207	43
Área Urbana	5.550	225
Nuvem	9.494	415
Sombra	30.360	285
Água	13.148	124
TOTAL	153.000	3.336

De um modo geral, foi possível observar que a lógica nebulosa constituiu-se como uma ferramenta valiosa na definição das áreas que apresentam transições entre classes e interferências de nuvens e sombra. Estas áreas estão presentes normalmente nas imagens de sensoriamento remoto, obtidas através de sensores ópticos, limitando a performance do algoritmo de classificação digital.

A imagem de referência R1 (Figura 4.7), foi gerada a partir da interpretação da imagem segmentada utilizando-se apenas pertinências totais (1) para cada segmento.

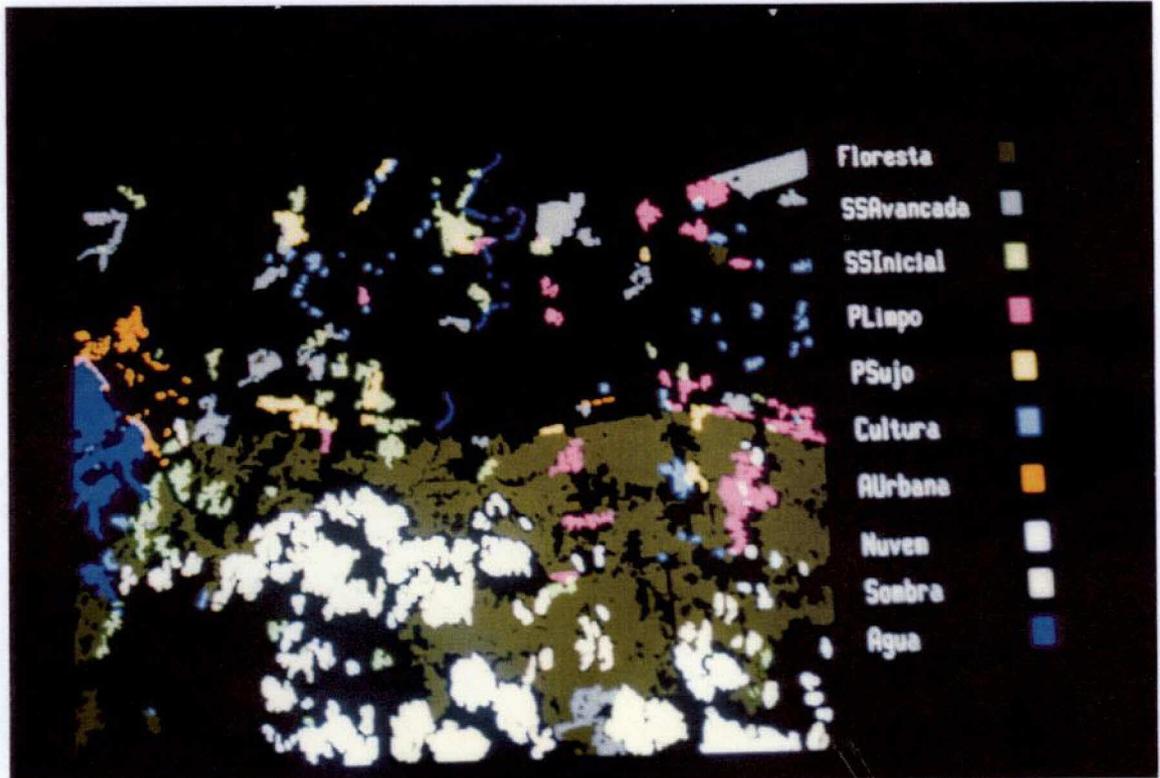


Fig. 4.9 - Imagem de referência resultante do processo de rotulação dos segmentos.

4.6 - INSPEÇÃO DAS MÉDIAS ESPECTRAIS

Devido as características do processo de segmentação de imagens utilizado nesta abordagem (crescimento de regiões), foram realizadas duas inspeções dos valores espectrais de cada classe, com o objetivo de verificar algum tipo de mudança significativa nos níveis de cinza antes e depois do processamento. Os valores dos níveis de cinza médios das classes podem ser observados nas Tabelas 4.5 e 4.6.

TABELA 4.5 - MÉDIA DO NÍVEL DE CINZA E DESVIO PADRÃO DAS CLASSES OBTIDOS ATRAVÉS DA LEITURA DE PIXELS

Classe	TM1	TM2	TM3	TM4	TM5	TM7
Floresta Primária	51.17	20.17	17.12	60.27	40.79	7.21
Desvio Padrão	0.96	1.30	1.50	4.27	2.87	0.5
Sucessão Secundária Avançada	54.84	23.28	20.84	76.8	62.12	13.48
Desvio Padrão	0.37	0.93	1.31	3.2	1.16	0.65
Sucessão Secundária Inicial	56.14	26.58	23.57	103.93	73.31	13.79
Desvio Padrão	1.85	2.19	1.64	7.58	2.98	0.92
Pasto Limpo	59.28	27.98	30.34	62.88	82.08	21.76
Desvio Padrão	0.92	1.04	1.92	1.38	5.28	2.68
Pasto Sujo	59.48	29.98	30.22	78.88	75.16	18.36
Desvio Padrão	0.67	0.68	1.5	7.4	2.69	1.00
Cultura Agrícola	63.2	28.38	33.84	44.84	89.7	35.48
Desvio Padrão	1.64	0.49	1.23	2.31	2.87	2.84
Área Urbanizada	23.98	33.4	42.42	31.84	42.78	18.34
Desvio Padrão	2.36	2.27	2.11	2.07	3.34	1.2
Nuvem	167.3	87.18	108.38	103.06	159.1	95.38
Desvio Padrão	51.88	29.55	39.01	22.03	38	39.01
Sombra	49.92	18.48	14.5	32.94	14.82	1.28
Desvio Padrão	1.02	0.5	0.8	1.96	1.85	0.80
Água	54.2	19.58	16.32	10.06	2.56	0.06
Desvio Padrão	1.24	0.64	1.75	0.97	0.92	0.24

TABELA 4.6 - MÉDIA DO NÍVEL DE CINZA E DESVIO PADRÃO OBTIDOS APÓS SEGMENTAÇÃO DE IMAGENS

Classe	TM1	TM2	TM3	TM4	TM5	TM7
Floresta Primária	52.8	21.7	18.7	64.8	48.0	9.1
Desvio Padrão	2.09	1.7	2.23	8.74	7.63	2.53
Sucessão Secundária Avançada	54.9	23.8	21.2	76.1	60.7	12.7
Desvio Padrão	2.79	2.52	3.76	12.36	10.4	4.35
Sucessão Secundária Inicial	58.3	27.4	24.4	99.6	75.0	16.3
Desvio Padrão	4.15	3.51	4.55	10.04	9.23	4.13
Pasto Limpo	64.6	32.1	37.4	68.6	100.6	30.6
Desvio Padrão	6.36	4.26	7.19	8.58	15.34	7.32
Pasto Sujo	59.1	27.8	27.5	73.4	75.0	18.9
Desvio Padrão	4.23	3.07	5.05	10.29	11.43	5.07
Cultura Agrícola	62.8	29.5	34.4	53.1	90.6	31.9
Desvio Padrão	5.67	4.83	9.05	9.16	14.5	8.34
Área Urbanizada	75.6	41.0	56.9	63.7	113.2	45.0
Desvio Padrão	12.74	10.41	20.56	13.04	35.48	18.62
Nuvem	114.2	57.3	68.8	77.7	108.7	51.0
Desvio Padrão	36.34	20.62	27.5	18.78	31.51	19.18
Sombra	59.0	25.1	24.7	49.4	43.8	12.0
Desvio Padrão	8.82	6.15	8.96	14.02	14.44	8.58
Água	55.8	21.6	19.3	14.1	9.7	3.0
Desvio Padrão	7.57	4.93	6.98	9.09	13.01	6.22

A Tabela 4.7 apresenta o resultado do teste de comparação entre as médias dos níveis de cinza para cada classe em pixels e segmentos. Pode ser observado que somente 11,1% aceita a hipótese nula (H_0) na qual as médias oriundas dos pixels é igual a média dos segmentos. Somente a classe “Cultura Agrícola” apresenta um valor correspondente a 50% de aceitação de H_0 . Estes resultados indicam, em um sentido estatístico, que há uma alteração dos níveis de cinza médio após o processo de segmentação, devido provavelmente a ocorrência de pixels isolados dentro de regiões formada através do processo de crescimento de regiões e também há fatores de mistura de pixels de borda.

Observa-se no entanto que, apesar de existir uma diferença significativa, devido a correlação existente entre os valores dos níveis de cinza observados de pixels e regiões, conforme apresentado na Tabela 4.7, há uma tendência de similaridade no comportamento para as bandas TM, quando se observam tais valores no contexto espacial (Figuras 4.8 a 4.13).

TABELA 4.7 - RESULTADO DO TESTE DE MÉDIAS ENTRE OS VALORES DE NÍVEL DE CINZA DE PIXELS E SEGMENTOS (95% DE ACEITAÇÃO)

Classe	TM1	TM2	TM3	TM4	TM5	TM7
Floresta	R	R	R	R	R	R
Sucessão Secundária Avançada	A	R	R	R	R	R
Sucessão secundária Inicial	R	R	R	R	R	R
Pasto Limpo	R	R	R	R	R	R
Pasto sujo	R	R	R	R	A	R
Solo Agrícola	A	R	A	R	A	R

A - Aceita a Hipótese Nula, H_0 (média dos pixels seja igual a média dos segmentos).

R - Rejeita a Hipótese Nula, H_0 .

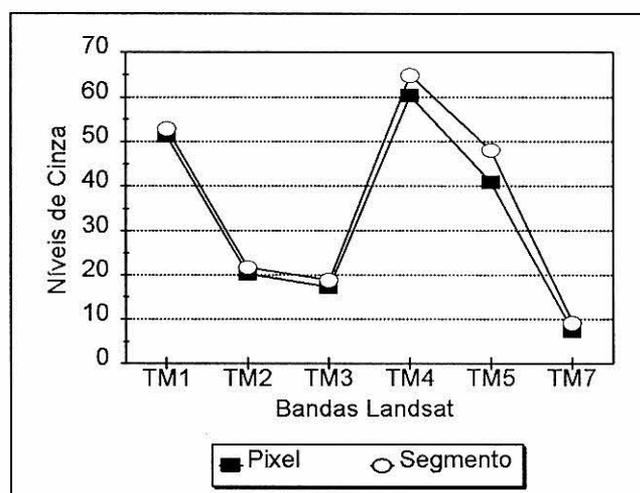


Fig 4.10a - Média dos níveis de cinza de pixels e segmentos para Floresta

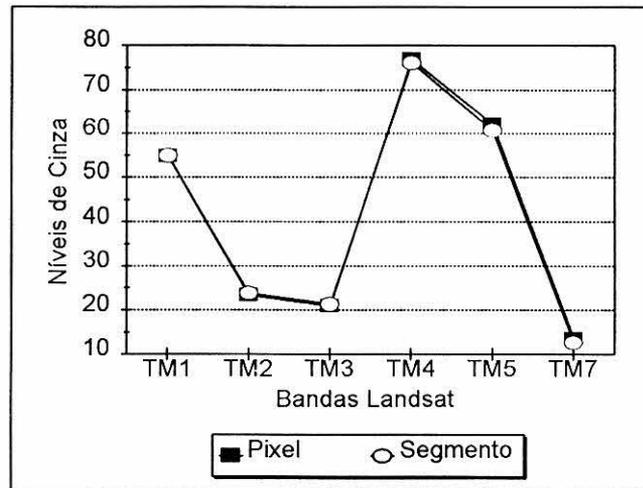


Fig 4.10b - Média dos níveis de cinza de pixels e segmentos para S.S Avançada.

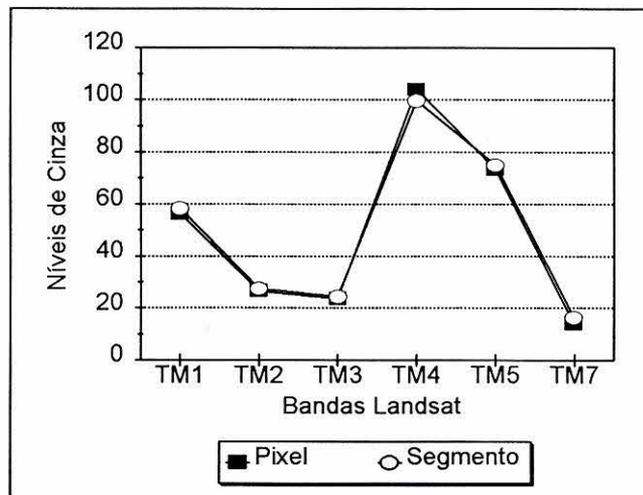


Fig. 4.10c - Média dos níveis de cinza de pixels e segmentos para S.S Inicial.

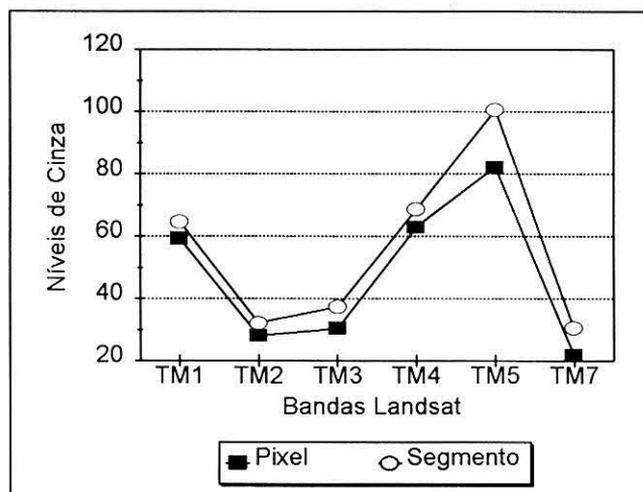


Fig. 4.10d - Média dos níveis de cinza de pixels e segmentos para Pasto Limpo.

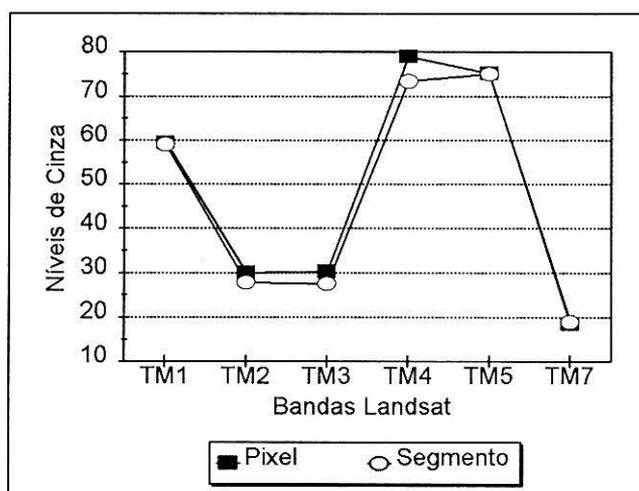


Fig. 4.10e - Média dos níveis de cinza de pixels e segmentos para Pasto Sujo.

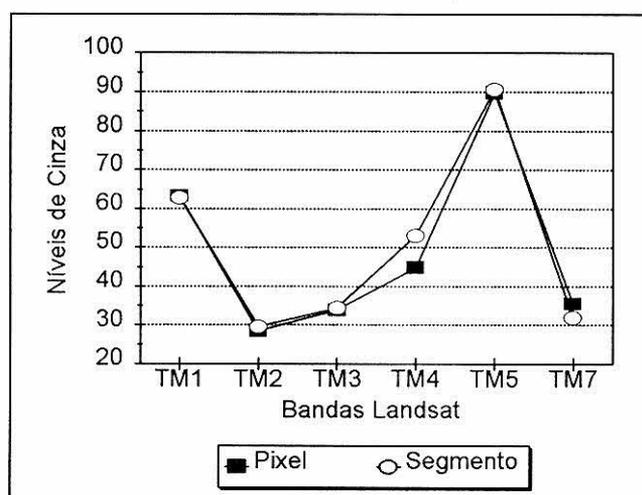


Fig. 4.10f - Média dos níveis de cinza de pixels e segmentos para Cultura Agrícola.

4.7 - CLASSIFICAÇÃO DIGITAL

4.7.1 - CLASSIFICAÇÃO NÃO SUPERVISIONADA

Logo após o processo de segmentação, a imagem (módulo de teste) foi submetida ao algoritmo de classificação não supervisionado de regiões, ISOSEG, presente no pacote SPRING. Foram utilizados os limiares de classificação de 75%, 95%, 99% e 99,9% e observou-se que os valores acima de 90% não discriminavam corretamente ou agrupavam determinadas classes (floresta e sucessão secundária avançada, sucessão secundária inicial e pasto sujo, pasto limpo e cultura agrícola). Estes problemas foram relatados por Watrin (1994) durante a análise da dinâmica da paisagem agrícola da Amazônia oriental.

O limiar de 75% foi o que melhor representou as diferentes formas de ocupação da terra, gerando um total de 36 classes temáticas, o que estava de acordo com as metas estabelecidas, que foi a geração de um número de classes três vezes maior que a legenda estabelecida. A Tabela 4.8 apresenta o resultado da classificação, onde os números (1 a 36) correspondem as classes obtidas pelo algoritmo e ao lado encontram-se as classes definidas para legenda temática.

TABELA 4.8 - RESULTADO DA CLASSIFICAÇÃO NÃO SUPERVISIONADA E SUA ASSOCIAÇÃO COM A LEGENDA TEMÁTICA

1	Floresta	10	S.S Inicial	19	Área Urbana	28	Nuvem
2	Água	11	Sombra	20	Nuvem	29	Nuvem
3	Sombra	12	S.S Inicial	21	Nuvem	30	Nuvem
4	P.Sujo	13	Nuvem	22	P.Limpo	31	P.Sujo
5	Sombra	14	S.S Inicial	23	P.Sujo	32	Nuvem
6	S.S. Inicial	15	Solo Agrícola	24	Nuvem	33	Nuvem
7	Nuvem	16	P.Limpo	25	Área Urbana	34	Nuvem
8	P.Limpo	17	Nuvem	26	Nuvem	35	Solo Agrícola
9	S.S Avançada	18	S.S Avançada	27	Solo Agrícola	36	Nuvem

Após a classificação da imagem, foi necessário realizar o mapeamento para geoclasses, onde as diversas classes temáticas puderam ser agrupadas de acordo com a legenda estabelecida e assim formar a imagem temática referente a este algoritmo de classificação (Figura 4.14).

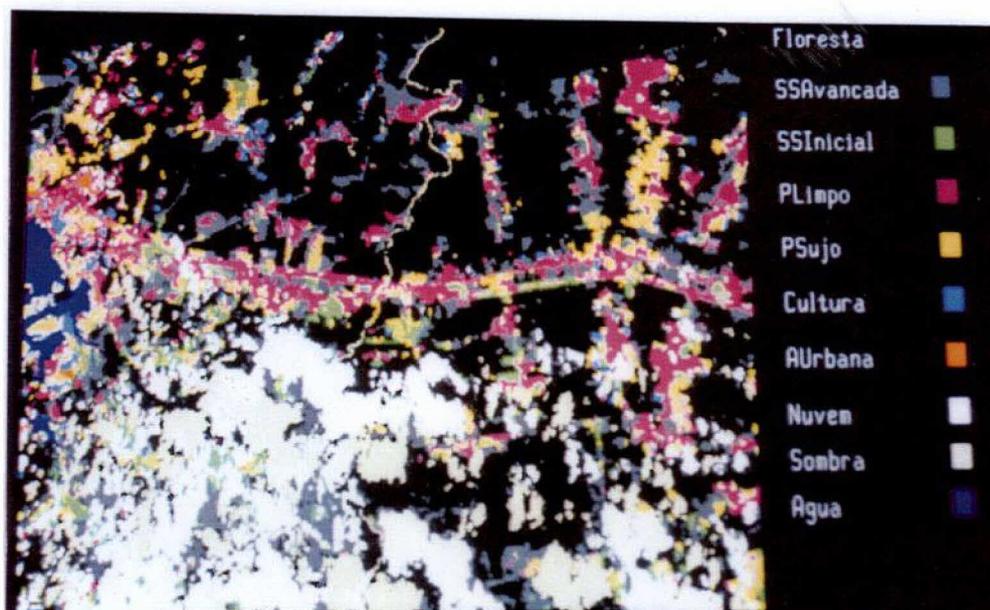


Fig. 4.11 - Imagem resultante do algoritmo de classificação ISOSEG.

A fase de mapeamento para geoclasses apresentou um elevado custo homem/máquina, pois para a realização do mesmo é necessário que o operador identifique cada classe temática gerada pelo algoritmo e a associe com uma das classes definidas no banco de dados. Devido o SPRING não possuir uma função de "liga/desliga" da imagem temática sobre a composição colorida, torna-se necessário a abertura de uma segunda janela de visualização somente com a composição colorida. Desta forma, pode-se identificar os polígonos temáticos em uma janela, procurando-se o seu correspondente na janela vizinha, para então associar a classe correspondente.

Podemos observar através da Tabela 4.8, que as nuvens apresentaram um maior número de classes ou seja, do total de classes encontrada pelo algoritmo de classificação a maior parte está associada a esta categoria devido haver uma grande variância. As classes de sucessão secundária apresentaram 16,7% do total das classes encontradas pelo algoritmo, enquanto que a floresta apresentou somente 2,7% deste total. Esses valores confirmam o que foi observado no campo, que as classes de regeneração apresentam-se constituídas de vários estádios de desenvolvimento, em um grande número porém de pequenas áreas, enquanto que a floresta é constituída de grandes áreas homogêneas. A Tabela 4.9 mostra a área total de cada classe encontrada pelo algoritmo de classificação.

TABELA 4.9 - ÁREA DE CADA CLASSE OBTIDA PELO ALGORITMO ISOSEG

Classes	Área (Km ²)
Floresta	354,8889
Sucessão Secundária Avançada	85,3038
Sucessão Secundária Inicial	22,176
Pasto Limpo	55,3986
Pasto Sujo	32,5863
Solo Agrícola	8,0289
Área Urbana	4,0482
Nuvem	81,728096
Sombra	49,5711
Água	9,4509
Total	703,18079

4.7.2 - CLASSIFICAÇÃO SUPERVISIONADA MAXVER

Para aplicação do algoritmo de classificação Maxver, onde o objeto pictórico é o pixel, a aquisição das amostras de treinamento foi realizada baseada nas informações obtidas durante o trabalho de campo e posicionadas geograficamente com auxílio do GPS.

As imagens foram submetidas ao algoritmo de classificação Maxver considerando-se o limiar de aceitação de 99,9%, o que possibilitou que uma classificação com um desempenho médio de 91,93% e uma abstenção de 0,71%. A confusão média de 7,36% foi considerada normal devido a proximidade do nível de cinza médio de algumas classes temáticas. Os resultados da matriz de classificação Maxver e as áreas de cada classe são apresentados nas Tabelas 4.10 e 4.11.

A imagem resultante deste algoritmo de classificação (Figura 4.14) possibilitou a identificação de todas as classes propostas. Foi observado no entanto que devido este algoritmo utilizar o pixel para classificação, algumas áreas não foram classificadas por não apresentarem valores de nível de cinza próximos aos das classes definidas na fase de aquisição de amostras.

TABELA 4.10 - MATRIZ DE CLASSIFICAÇÃO MAXVER A PARTIR DO SUBCONJUNTO DE BANDAS TMI A 5 E 7

Classe	N	1	2	3	4	5	6	7	8	9	10
1	0.5	86.9	9.4	0.3	0.0	0.0	0.0	0.0	0.0	0.0	0.2
2	0.0	11.1	88.9	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	0.0	0.0	0.0	97.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	0.0	0.0	0.0	0.0	100.	0.0	0.0	0.0	0.0	0.0	0.0
5	0.0	0.0	0.0	0.0	0.0	100	0.0	0.0	0.0	0.0	0.0
6	0.0	0.0	0.0	0.0	0.0	0.0	98.5	0.0	1.5	0.0	0.0
7	2.2	0.0	0.0	0.0	0.0	0.0	0.5	96.8	0.0	0.0	0.5
8	0.5	0.0	0.0	0.0	0.0	0.0	0.1	0.0	99.4	0.0	0.0
9	3.6	0.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	95.8	0.0
10	0.7	0.0	0.0	0.0	0.0	3.6	0.0	0.0	0.0	0.0	95.0

1) Floresta; 2) S.S. Avançada; 3) S.S. Inicial; 4) Pasto Limpo; 5) Solo Agrícola; 6) Área Urbana; 7) Água; 8) Nuvem; 9) Sombra; 10) Pasto Sujo.

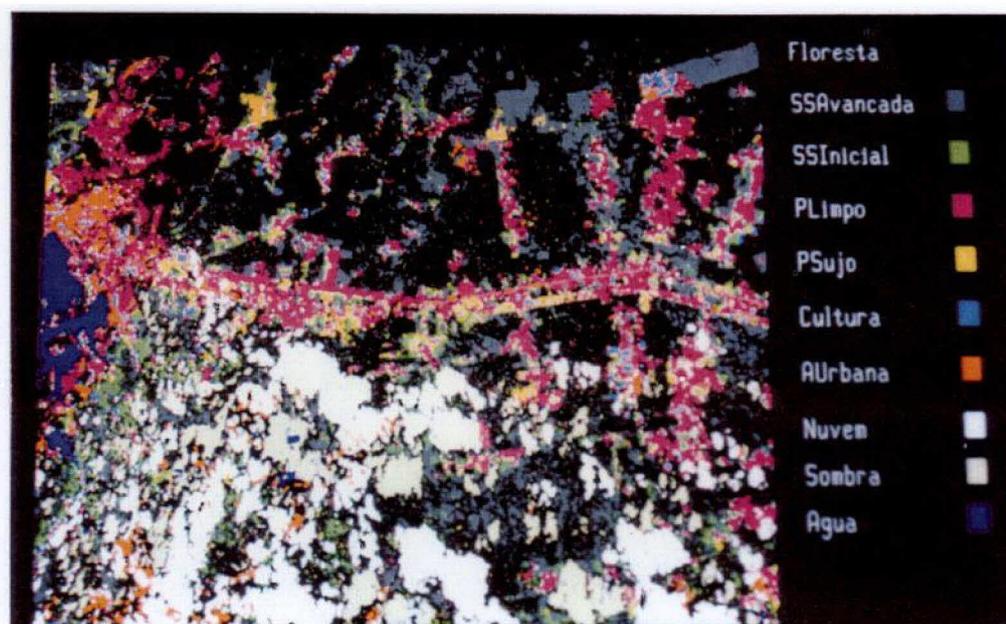


Fig. 4.12 - Imagem resultante do algoritmo de classificação supervisionado (Maxver).

TABELA 4.11 - ÁREA DE CADA CLASSE OBTIDA PELO ALGORITMO DE CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA.

Classes	Área (Km ²)
Floresta	302,84282
Sucessão Secundária Avançada	82,8702
Sucessão Secundária Inicial	24,237
Pasto Limpo	70,578896
Pasto Sujo	9,7605
Solo Agrícola	7,4619
Área Urbana	29,9187
Nuvem	70,722896
Sombra	26,6418
Água	10,6002
Total	635,63491

4.7.3 - ANÁLISE ESTATÍSTICA

A utilização da estatística Kappa permitiu que fossem geradas matrizes de erro que possibilitaram a comparação entre a imagem temática de referência e as imagens resultantes do método não supervisionado, ISOSEG, e do método de classificação supervisionado por Máxima Verossimilhança (Tabelas 4.12 e 4.13).

TABELA 4.12 - MATRIZ DE ERRO PARA IMAGEM DE REFERÊNCIA E ALGORITMO ISOSEG.

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	Erros de Inclusão
Floresta (1)	116809	2733	258	466	341	33	2	680	1366	0	4,8
SSAvançada (2)	6414	9583	151	221	517	8	0	9	12	0	43,4
SSInicial (3)	353	8151	2730	174	279	7	1	170	36	1	77,1
Plimpo (4)	79	123	170	9394	86	28	0	52	13	0	5,6
Psujo (5)	47	83	1276	2279	515	18	0	2	4	0	87,9
Cultura (6)	101	43	22	2027	32	1707	195	50	5	0	59,2
Urbana (7)	4	5	0	882	10	23	1996	63	30	17	34,2
Nuvem (8)	21	55	6	1	2	0	16	24342	5	0	0,5
Sombra (9)	433	83	5	4	33	2	0	219	27051	12	2,9
Água (10)	192	7	12	32	104	24	17	13	568	9893	8,9
Erros de Omissão	6,15	54,1	41,1	39,4	73,2	7,8	10,4	4,9	7,1	0,4	

TABELA 4.13 - MATRIZ DE ERRO PARA IMAGEM DE REFERÊNCIA E ALGORITMO MAXVER.

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	Erros de Inclusão
Floresta (1)	88194	24028	823	2411	320	35	434	1337	388	6	25,3
SSAvançada (2)	1315	9897	2341	1470	623	22	78	35	2	0	37,3
SSInicial (3)	276	3143	5546	588	766	12	28	59	1	0	46,8
Plimpo (4)	27	8	24	6523	471	1109	1116	58	0	0	31,2
PSujo (5)	38	50	67	2350	1103	12	131	6	0	0	70,7
Cultura (6)	39	4	10	1089	9	1650	992	12	0	0	56,7
Urbana (7)	0	0	0	46	0	126	2648	3	0	2	6,3
Nuvem (8)	0	0	0	1	0	0	786	23533	0	0	3,3
Sombra (9)	1771	7	1	24	3	0	36	24	19894	904	12,3
Água (10)	111	12	0	13	1	0	14	0	12	9524	1,7
Erros de Omissão	3,9	73,4	37,1	55,1	66,6	44,4	57,8	6,2	2,0	8,8	

A razão entre o número de pixels classificados corretamente (correspondente à soma dos elementos da diagonal principal da matriz) e o número total de pixels, representa a exatidão global da classificação. Desta forma, o algoritmo de classificação não supervisionado apresentou um desempenho de 86,43%, enquanto que o algoritmo de classificação por máxima verossimilhança apresentou desempenho de 76,39%, quando comparados com a imagem de referência.

A matriz de erro possibilita que sejam calculados os erros de inclusão, que representam os pixels classificados numa dada categoria e que não pertencem a mesma, e os erros de omissão, que representam os pixels de uma categoria classificados como pertencentes às demais classes (Congalton, 1991).

As matrizes resultantes das análises entre a imagem de referência e os algoritmos de classificação mostram que há um maior erro de classificação entre as classes “vizinhas”, que expressam uma transição em termos fisionômico-estrutural. Como exemplo desses casos, temos a classe sucessão secundária avançada que apresenta um erro maior de classificação com a classe sucessão secundária inicial. A classe pasto limpo está apresentando erros com as áreas de cultura agrícola devido as mesmas apresentarem uma grande influência do solo na composição do sinal que chega ao sensor. A classe pasto sujo apresenta confusão com várias classes devido a grande variabilidade espectral, resultante de sua heterogeneidade no campo com a presença de babaçu (*Orbignia martiana*), inajá (*Maximiliana maripa*) e outras espécies colonizadoras de áreas degradadas.

Através do resultado da análise estatística (Tabela 4.14) podemos observar que o valor de Kappa para o algoritmo ISOSEG foi superior ao do algoritmo por Máxima Verossimilhança, indicando que o método não supervisionado apresentou melhor desempenho. Os valores de Z foram maior que 1,64 mostrando que existe concordância entre as classificações e a verdade terrestre. Segundo a avaliação sugerida por Landis e Koch (1977) os dois valores estão na qualidade “muito boa” que varia entre 0.61 e 0.80.

A Figura 4.13 apresenta o desempenho de cada classe nos diferentes algoritmos de classificação, obtido através da divisão do número de pixels corretamente classificados pelo total de pixels da coluna. Podemos observar que somente 40% das classes no algoritmo Maxver apresentam desempenho superior a 85% enquanto que este valor é de 60% no algoritmo ISOSEG. Podemos observar ainda que algumas classes apresentam um desempenho muito melhor no método de classificação não supervisionado, como áreas com cultura agrícola e áreas urbanas. Este fato está relacionado provavelmente ao limiar de área utilizado no processo de segmentação de imagens que não permite que áreas heterogêneas, com alta frequência, fiquem isoladas diminuindo o desempenho de classificação. De outra forma, as classes V, I, L e U apresentaram baixos desempenhos na classificação evidenciando que somente as características espectrais destas áreas não são suficientes para uma perfeita discriminação por parte dos algoritmos utilizados.

TABELA 4.14 - RESULTADO DA ESTATÍSTICA KAPPA.

CLASSIFICADOR	KAPPA LIMITE INFERIOR	KAPPA	KAPPA LIMITE SUPERIOR	TESTE Z
ISOSEG	0.800842	0.802764	0.804686	818.677700
MAXVER	0.676909	0.679242	0.681574	570.732307

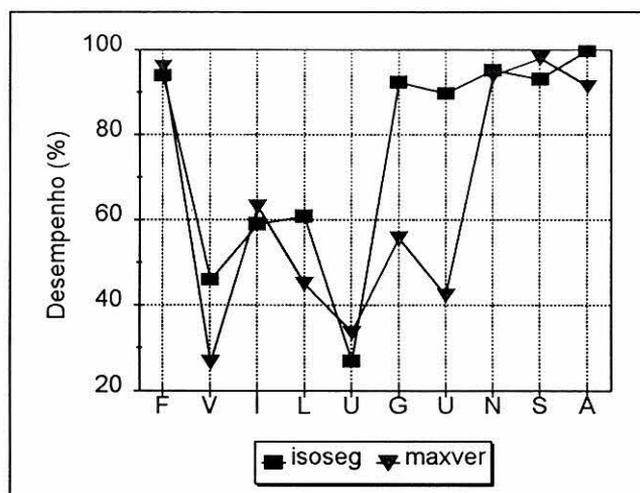


Fig. 4.13 - Desempenho geral de cada classe temática nos algoritmos de classificação ISOSEG e Máxima Verossimilhança.

4.8 - REDES NEURAIAS

Conforme os objetivos propostos neste trabalho foi realizado, a partir do procedimento de construção de uma rede neural artificial, o treinamento para caracterização do uso da terra na região amazônica, levando-se em consideração a estratificação em dez classes temáticas.

O resultado aqui apresentado é referente ao desempenho do treinamento das diversas redes neurais, associadas a cada classe temática. A determinação deste desempenho foi realizada utilizando os índices descritos em 3.3.2.2 que são o Erro Médio Quadrático (MSE) e os índices de Sensibilidade e Especificidade.

Podemos verificar através das Figura 4.16 houve uma minimização do Erro Médio Quadrático (MSE) de acordo com o tempo de treinamento de todas as redes.

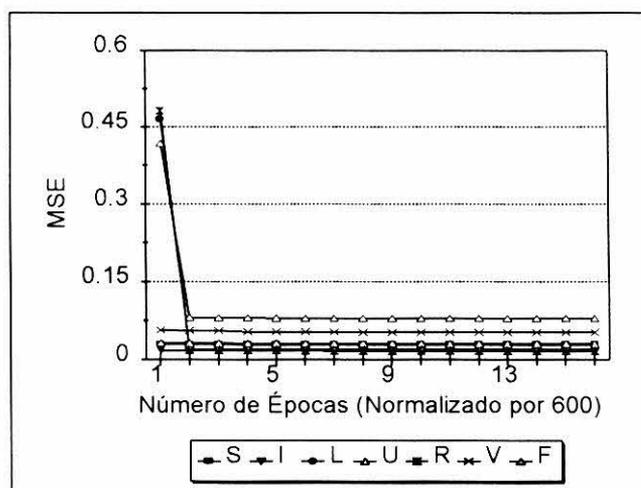


Fig. 4.14 - Minimização do MSE para as classes: Sombra (S), Sucessão Secundária Inicial (I), Pasto Limpo (L), Pasto Sujo (U), Área Urbana (R), Sucessão Secundária Avançada (V) e Floresta (F).

As Figuras 4.17 a 4.19 apresentam a evolução, mais detalhada, do erro para as classes Floresta, Sucessão Secundária Avançada e Sucessão Secundária Inicial. Podemos observar que tanto áreas mais homogêneas, como as florestas e áreas de diversificada estrutura, como os diversos estádios de sucessão secundária, que normalmente apresentam problemas com classificações digitais obtiveram desempenho satisfatório, ou seja redução do MSE com o decorrer do treinamento.

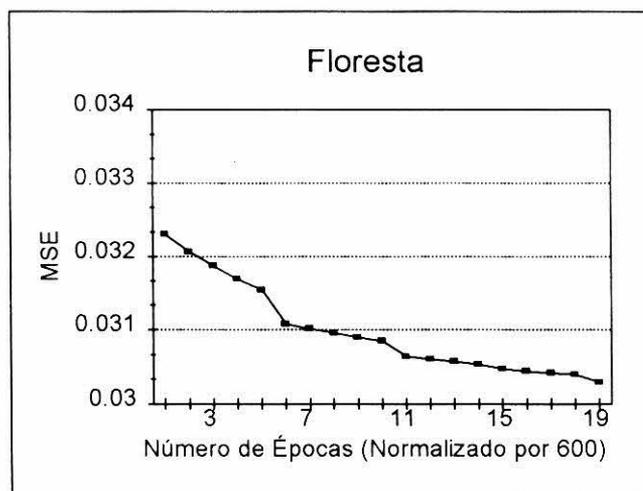


Fig. 4.15 - Minimização do MSE para Floresta

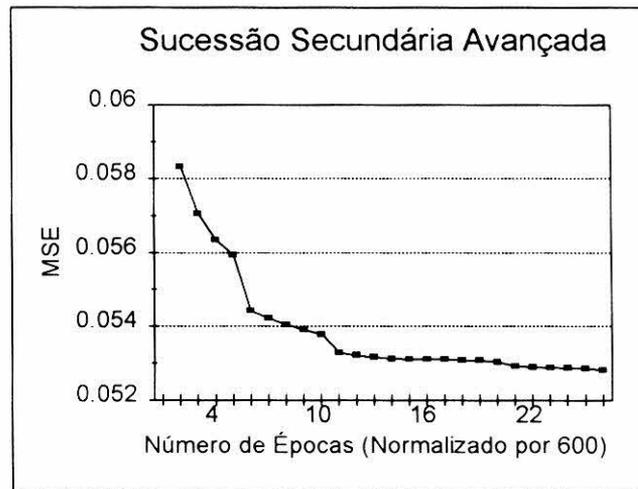


Fig. 4.16 - Minimização do MSE para Sucessão Secundária Avançada

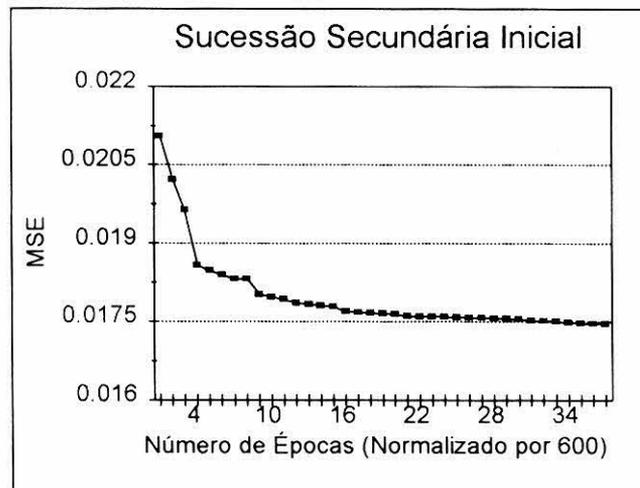


Fig. 4.17 - Minimização do MSE para Sucessão Secundária Inicial

As Figuras 4.20 e 4.21 apresentam a evolução da **distância** para a classe sucessão secundária avançada e sucessão secundária inicial. Esta distância está associada a relação entre os índices de sensibilidade e especificidade, ou seja, a capacidade que a rede neural tem em detectar ou rejeitar cada tema. Podemos observar que a sucessão secundária avançada vem apresentando valores intermediários com uma tendência de minimização, já que os valores de sensibilidade vão aumentando com o decorrer do treinamento. A sucessão secundária inicial apresenta menores valores, indicando neste caso um melhor desempenho por parte da rede neural em detectar esta classe.

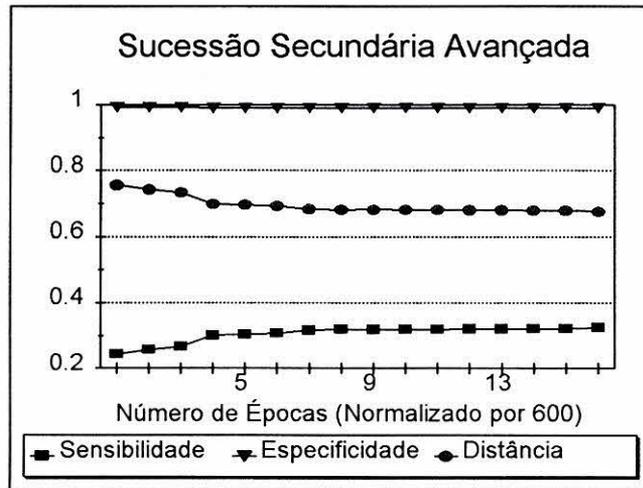


Fig. 4.18 - Relação entre Sensibilidade, Especificidade e Distância para a classe Sucessão Secundária Avançada

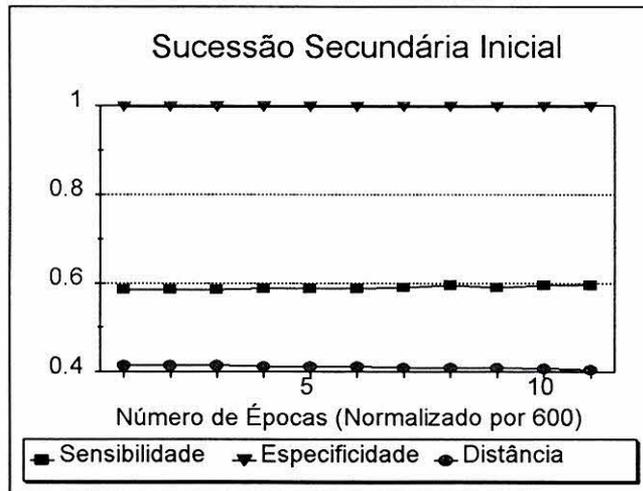


Fig. 4.19 - Relação entre Sensibilidade, Especificidade e Distância para a classe Sucessão Secundária Inicial.

Levando em consideração os resultados obtidos nesta fase de treinamento, observamos que a utilização de novos elementos para análise e classificação de imagens de sensoriamento remoto mostraram-se muito importantes. Observamos através da Figura 4.6 que existe uma tendência natural de classes vizinhas apresentarem áreas de transição, e que estas representam “problemas” para algoritmos de classificação que utilizam apenas a característica espectral. A utilização da lógica nebulosa para rotulação de segmentos de imagem permitiu que estas áreas de transição fossem “mapeadas”, possibilitando dessa forma o aparecimento de áreas “misturadas” que representam a real ocupação do solo. Esta informação possibilitou, juntamente com as características texturais, a melhor diferenciação entre as diversas classes de uso da

terra, o que pôde ser comprovada através dos índices utilizados na avaliação do desempenho das redes neurais.

Foi observado que para algumas classes os valores de MSE, sensibilidade e especificidade não foram satisfatórios, para permitir a realização da classificação. Desta forma, sugere-se que as classes que, ao final da primeira fase de treinamento, não apresentaram rendimento satisfatório, sejam utilizadas em um processo de equalização com o objetivo de gerar índices de desempenho compatíveis com os níveis de classificação desejados. Segundo Liporace (1994), se o rendimento das amostras fornecidas para treinamento não for satisfatório, um conjunto de “pesos” deverá ser associado à cada amostra deste conjunto. Esses pesos deverão estar distribuídos de forma que o número de exemplos “contra” a classe seja igual ao número de exemplos “a favor”. Os conceitos de “contra” e “a favor” estão relacionados com a ativação abaixo ou acima de um limiar definido em 0,5. Os exemplos “a favor” deverão ser distribuídos de forma que $\frac{1}{3}$ dos pesos sejam concentrados onde a rede errou primeiro, impondo que a mesma adote maior valor de importância aos casos de resolução mais difícil. Após a fase de equalização, deverá ser criada a “rede central” que passará então a utilizar as características contextuais de cada segmento para a classificação temática final.

CAPÍTULO 5

CONCLUSÕES E RECOMENDAÇÕES

De acordo com os resultados obtidos neste trabalho, a metodologia proposta mostrou-se satisfatória no desenvolvimento e treinamento de redes neurais artificiais especializadas em classes de uso da terra através de segmentos de imagens rotulados por lógica nebulosa, sendo necessário destacar os seguintes aspectos:

5.1 - CONCLUSÕES

Dentre as principais conclusões destacam-se:

- 1) O registro das imagens TM com a carta topográfica da área de estudo foi de fundamental importância para localização exata dos pontos coletados em campo, através da utilização do GPS, e que foram utilizados para identificação dos diversos padrões das classes. Este fato possibilitou a aquisição de amostras de treinamento confiáveis para o processo classificatório por Máxima Verossimilhança, agrupamento das classes após a classificação não supervisionada e ainda na rotulação de segmentos para formação da imagem de referência e da base de treinamento para a rede neural artificial
- 2) O processo de segmentação de imagens mostrou-se eficiente na separabilidade das classes. Valores de limiar de similaridade mais baixos (6 e 8) apresentaram uma fragmentação excessiva, o que dificultou a identificação dos segmentos. Por outro lado, valores de limiar de similaridade mais altos (12 e 14) agruparam em um mesmo segmento áreas espectralmente diferentes. O melhor resultado foi alcançado com limiar de similaridade 10, que possibilitou a separabilidade das diversas classes de forma coerente. A utilização de um limiar de área equivalente a 10 pixels mostrou-se conveniente. No entanto, em alguns casos essa área mostrou-se demasiadamente pequena, dificultando a identificação do tipo de uso da terra.
- 3) O limiar de classificação 75%, utilizado no algoritmo não supervisionado (ISOSEG), foi o que melhor representou as classes de uso da terra. Para os demais valores utilizados (95%, 99% e 99,9%) não foi possível discriminar algumas geoclasses, em função de seu agrupamento em um único segmento.

- 4) A classificação pixel-a-pixel, através do algoritmo de Máxima Verossimilhança, não apresentou um desempenho satisfatório para a caracterização das classes. Devido à grande complexidade da região, muitas áreas não foram classificadas em nenhuma das classes pré-estabelecidas. Esse tipo de problema vem sendo reportado na literatura como uma das limitações para o emprego desta técnica. A utilização de tratamentos pós-classificação (filtros) não é indicada para a região que apresenta pequenas áreas de uso da terra, as quais poderiam ser eliminadas durante o processamento. De forma complementar, a aplicação de filtragens implica na alteração dos limites dos temas, inclusive daqueles corretamente classificados, reduzindo a exatidão do mapeamento gerado.
- 5) O algoritmo de classificação não supervisionada de regiões (ISOSEG) pode ser utilizado como opção para o conhecimento prévio da distribuição das classes temáticas (classificação híbrida) em uma dada região. A facilidade de aplicação deste método e seu rápido processamento foram as principais vantagens encontradas nesta pesquisa. Como fator negativo, podemos destacar a formação de um elevado número de classes temáticas e o alto custo homem/máquina para realizar o mapeamento para geoclasses (edição do mapa temático) no SPRING.
- 6) Somente os valores espectrais não foram suficientes para uma discriminação mais detalhada das classes de uso da terra. A sobreposição espectral entre os estádios de sucessão secundária e pastagens mostram que há uma necessidade de utilização de novos descritores que tenham a capacidade de detectar e identificar essas transições.
- 7) O resultado da estatística Kappa apontou um melhor desempenho para o algoritmo ISOSEG, quando comparado com o método por Máxima Verossimilhança.
- 8) A utilização de uma interface gráfica para identificação de segmentos mostrou-se eficiente visto que neste processo visual/digital, eliminou-se duas fontes de erro normalmente presentes no processo de extração de informações em imagens de sensoriamento remoto. Neste caso não ocorreram erros de deformações de overlays e também de digitalização pois, as bordas (linhas)

utilizadas foram resultantes do processo de segmentação de imagens, as mesmas que também foram utilizadas pelos algoritmos de classificação.

- 9) O processo de rotulação de segmentos para formação da base de conhecimento necessário ao treinamento da rede neural e para formação da imagem de referência utilizando a lógica nebulosa apresentou-se muito promissor pois, permitiu que fenômenos de transição fossem mapeados corretamente. Dessa forma, regiões que apresentavam duas ou mais diferentes classes puderam ser rotuladas assim como também regiões com interferências de nuvens e sombras, que são comuns na região amazônica, foram perfeitamente identificadas.
- 10) Classes mais complexas em termos de estrutura, como a sucessão secundária avançada, necessitam de um tempo de processamento (treinamento) superior a classes mais homogêneas para obterem desempenho satisfatório.
- 11) De maneira geral, durante a fase de treinamento, a utilização da rede neural apresentou um elevado custo computacional, para todas as classes temáticas. Com o procedimento de equalização e incorporação de novos descritores o tempo demandado pelo processamento deverá se elevar.

5.2 - RECOMENDAÇÕES

Considerando os resultados obtidos e as dificuldades encontradas durante a realização deste trabalho podem ser delineadas algumas linhas de ação que visem o aprimoramento dos algoritmos de classificação digital.

- 1) Desenvolvimento de novos algoritmos de classificação supervisionada para regiões resultantes do processo de segmentação de imagens, que utilizem descritores texturais e contextuais na separabilidade das classes. Visto que esta técnica vem apresentando resultados satisfatórios na separabilidade das diversas formas de ocupação da terra.
- 2) Os valores a serem estabelecidos para os limiares de similaridade e área deverão atender às peculiaridades de cada região analisada, considerando a escala de trabalho e classes de uso de interesse.
- 3) A rotulação de segmentos utilizando categorias básicas e categorias de interferência, através de pertinências totais ou parciais (utilizando a lógica

nebulosa), permitiu a modelagem das diversas formas de ocupação da terra e suas transições. Sendo assim, na impossibilidade de utilização dessa forma de análise por parte de algoritmos tradicionais, a criação destas classes deverá ser considerada, para um melhor desempenho dos algoritmos.

- 4) A redução dos índices MSE e das distâncias relacionadas com a sensibilidade e especificidade em todas as classes temáticas treinadas pela rede neural sugere que este procedimento poderá ser capaz de discriminar com grande precisão as várias classes temáticas envolvidas nesta pesquisa. Neste sentido, torna-se necessária a continuação dos processos de treinamento e posterior formação da rede central que poderá então trabalhar com mais um atributo necessário a melhor discriminação dos diferentes tipos de uso da terra na Amazônia.
- 5) Devido à grande versatilidade encontrada pelo processo de classificação através de redes neurais, deveriam ser aproveitados em trabalhos futuros a utilização de diversas fontes de informação para formação da base de conhecimento necessário ao treinamento das redes neurais. Entre estas informações destacam-se: tipos de solos, declividade, comprimento de rampa, dados geológicos e geomorfológicos.

REFERÊNCIAS BIBLIOGRÁFICAS

- Almeida, L. J., Oliveira, L. G.; Bezerra, C. C. S. Uso atual da terra com ênfase aos aspectos fitofisionômicos da região noroeste do Estado de Mato Grosso. In: Simpósio Brasileiro de Sensoriamento Remoto, 6. Manaus, 24-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v 2, p.341-349.
- Anderson, J. R., Hardy, E. E.; Roach, J. T. Witmer, R. E. **Sistema de classificação do uso da terra e do revestimento do solo para utilização com dados de sensores remotos**. Rio de Janeiro, SUPREN - IBGE, 1979. 78p. (Série Paulo Assis Ribeiro. 9).
- Arima, L. I. A. ; Oliveira, L. G. ; Barros, I. T. L. P. Sifuentes, D. V., Madruga, L. C.; Paiva, M. A. C. Estudo da vegetação natural/uso do solo como subsídio ao zoneamento sócio-econômico do município de Jaurú (MT) In: Simpósio Brasileiro de Sensoriamento Remoto, 7 Curitiba, 10-14 maio, 1993 **Anais**, São José dos Campos, INPE, 1993 v. 2 p 006-014.
- Aronoff, S. Classification accuracy: an user approach. **Photogrammetric Engineering and Remote Sensing**, 48(8):1299-1307, Aug. 1982.
- Batista, G. T., Medeiros, J. S.; Mello, E. M. K.; Moreira, J. C.; Bins, L. S. A new approach for deforestation assessment. In: International Symposium on Resource and Environmental Monitoring. Rio de Janeiro, 1994. **Proceedings**, Rio de Janeiro, ISPRS Comission VII, 1994, v. 30, p. 7a, p. 170-174.
- Belaid, M.; Edwards, G.; Jaton, A.; Thomson, K. P. B.; Beaulieu, J. M. Post-segmentation classification of images containing small agricultural fields **Geocarto International**, 7 (3) : 53-60, Sept 1992.

- Benie, G. B Thomson, K. P. B. Hierarchical image segmentation using local and adaptative similarity rule. **International Journal of Remote Sensing**, 13 (8). 1559-1570, May 1992.
- Benie, G. B ; Thomson, K. P. B., Goldbery, M. A comparison of four segmentation algorithms in the context of agricultural remote sensing. I.S.P.R.S **Journal of Photogrammetry and Remote Sensing**,44(7). 1-13, Jun 1989.
- Benson, A. S ; De Gloria, S. D. Interpretation of Landsat -4 Thematic Mapper and Multispectral Scanner data for forest surveys. **Photogrammetric Engineering and Remote Sensing**, 51(9): 1281-1289, Sept. 1985
- Bins, L. S.; Erthal, G. J.; Fonseca, L. M. G. Um método de classificação não supervisionada por regiões In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 6., Recife, PE, out., 1993. **Anais**. São José dos Campos, INPE, 1993, v.2, p. 65-68.
- Blonda, P.; Bennardo, A.; Forgia, V.; Satalino, G. **Modular neural system, based on fuzzy clustering network, for classification**. In: International Geoscience and Remote Sensing Symposium (IGARSS'95), Firenze, Italy. v 1 p.449-451. 1995
- Brondizio, E. S ; Moran, E. F.; Mausel, P.; Wu, Y. Dinâmica da vegetação do Baixo Amazonas: análise temporal do uso da terra integrando imagens Landsat-TM, levantamento florístico e etnográfico. In: Simpósio Brasileiro de Sensoriamento Remoto, 7., Curitiba, 10-14 maio, 1993. **Anais**. S. José dos Campos, INPE, 1993, v. 2, p. 38-46.
- Chen, S. C **Avaliação da exatidão de mapa temático e medição da área mapeada a partir de dados de satélite**. São José dos Campos, INPE.. 1991. (INPE-5223-NTE/296)

- Chuvieco, E.; Congalton, R. G. Using cluster analysis to improve the selecting of training statistics in classifying remotely sensed data. **Photogrammetric Engineering and Remote Sensing**, 54 (9): 1275-1281, Sep. 1988.
- Congalton, R.G., Mead, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**, 49 (1): 69-74, 1983.
- Congalton, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, 37 (1): 35-46, July, 1991.
- Convênio Eletronorte/Inpa. **Levantamento de solos da área de influência do reservatório da represa de Tucuruí**. Manaus, INPA - Departamento de Ciências Agronômicas. 1983. 167p (Relatório Semestral, 5).
- Corr. D. J.; Taylor, A. M.; Cross, A.; Hogg, D. C.; Lawrence, D. H.; Mason, D. C.; Petrou, M. Progress in analysis of multi-temporal remotely-sensed data. **International Journal of Remote Sensing**, 10 (7): 1175-1195, July 1989
- Crósta, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas, UNICAMP, 1992. 170p.
- Davison, G. J. Ground control pointing and geometric transformation of satellite imagery. **International Journal of Remote Sensing**, 1(7): 65-74, 1986.
- Denich, M. A vegetação da Amazônia Oriental com ênfase na vegetação antrópica. In: Pesquisas sobre a utilização e conservação do solo na Amazônia Oriental. In: **Relatório Final do Convênio EMBRAPA-CPATU/GTZ**. Belém, EMBRAPA-CPATU, 1986 p 43-68 ,(Documentos, 40).

- Dutra, L. V.; Souza, R. C. M.; Mitsuo, F. A.; Moreira, J. C. **Análise automática de imagens multiespectrais**. São José dos Campos, INPE, 1981. (INPE-2212-MD/009).
- Emaruchi, B.; Jin, Y.; Sauchyn, D.; Kite, G. Land cover mapping using an artificial neural networks. In: **ISPRS Mapping and Geographic Information Systems**, Georgia, 1994. v.30, p. 84-89.
- Erthal, G. J. **Processamento digital de imagens**: notas de aulas dadas no Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 1992. 79p. Manuscrito.
- Espartel, L. **Curso de topografia**. 8 ed. Porto Alegre, Globo, 1982. 665p.
- Fidalgo, E. C. C. **Exatidão no processo de mapeamento temático da vegetação de uma área de mata atlântica no Estado de São Paulo, a partir de imagens TM/Landsat**. (Dissertação de Mestrado em Novembro de 1995) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995. 186 p. (INPE - 5955-TDI/570).
- Fitzgerald, R. W.; Lees, B. G. Assessing the classification accuracy of multisource remote sensing data. **Remote Sensing of Environment**, 47(3):362-368, Mar. 1994.
- Fleiss, J. L. **Statistical methods for rates and proportions**. New York, John Willey, 1981. 321 p.
- Fonseca, L. M. G.; Bins, L. S. ; Velasco, F. R. D.; Monteiro, A. M. V. Um sistema de segmentação baseado em conhecimento para imagens de satélite. In: Simposio Brasileiro de Sensoriamento Remoto, 6. Manaus 24-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v.1, p.197-200.
- Foody, G. M. The effects of viewing geometry on image classification. **International Journal of Remote Sensing**, 9(12):1909-1915, Dec. 1988.

- Freitas, C. M. Reconhecimento de padrões utilizando rede neural. In. Simpósio Brasileiro de Cartografia, 16. Rio de Janeiro, 1993. **Anais**, Rio de Janeiro, Sociedade Brasileira de Cartografia, 1993, v.1, p. 67-82.
- Gong, P.; Marceau, D. J.; Howarth, P. J. A comparison of spatial feature extraction algorithms for land-use classification with Spot HRV data. **Remote Sensing Environment**, 40(2):137-151, May, 1992.
- González, B. Z. E., Villarroel, G.; Ruiz, G. Procesamiento digital de imágenes de satélite como fuente de información sobre uso y cobertura de la tierra en una área de la cuenca del lago Valencia. In. Simpósio Brasileiro de Sensoriamento Remoto, 7 Curitiba, 10-14 maio, 1993. **Anais**, São José dos Campos, INPE, 1993, v. 4, p. 140-151.
- Gonzalez, R. C., Wintz, P. **Digital image processing**. 2.ed. Reading, MA, Addison-Wesley, 1987. 503p.
- Haralick, R. M.; Shapiro, L. G. Image segmentation techniques. **Computer Vision, Graphics, and Image Processing**, 29 (1): 100-132, Jan. 1985.
- Hautakoski, M. Area-based segmentation. **The Photogrammetry Journal of Finland**. 12 (1): 126-132, 1990
- Hautakoski, M. Implementation of split-and-merge segmentation. **The Photogrammetry Journal of Finland**. 11 (2): 32-39, 1989
- Hepner, G. F. Artificial neural network classification using a minimal training set: comparison to conventional supervised classification. **Photogrammetric Engineering and Remote Sensing**, 56 (4). 469-473, 1990

- Hueckel, M. H. An operator which locates edges in digitized. **Journal of the Association for Computing Machinery**, 18 (1): 113-125, 1978
- Jensen, J. R. Urban/suburban land use analysis. In: Colwell, R. N. **Manual of Remote Sensing**. Falls Church, VA, ASP, 1983, v. 2, cap. 30, p. 1511-1666.
- Kanellopoulos, I.; Varfis, A.; Wilkinson, G. G.; Megier, J. Classification of remotely-sensed satellite images using multilayer perceptron networks. **Artificial Neural Networks**. New York, NY, 1991.
- Kim, K.; Yang, Y.; Lee, J.; Choi, K.; Kim, T. **Classification of multispectral image using neural network**. In: International Geoscience and Remote Sensing Symposium (IGARSS'95), Firenze, Italy, v.1, p.446-448, 1995.
- Lacroix, V., A Three module strategy for edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 10 (6): 803-810, 1988
- Landis, J.; Koch, G. G. The measurements of observer agreement for categorical data. **Biometrics**, 33 (3): 159-174, Mar. 1977.
- Lima, J. D., Lima, S. C. Mapeamento da cobertura vegetal e do uso antrópico na região do Triângulo Mineiro (MG), através de imagens TM/Landsat. In: Simpósio Brasileiro de Sensoriamento Remoto, 7. Curitiba, 10-14 maio, 1993. **Anais**, São José dos Campos, INPE, 1993, v. 2, p. 162-170.
- Lins Jr., M. A. Land use mapping from Skylab S 190B Photography. **Photogrammetric Engineering and Remote Sensing**, 52 (3): 301-302, Mar. 1976.

- Liporace, F. dos S. **Um sistema neural para monitoração do desflorestamento na Região Amazônica utilizando Imagens do Landsat.** (Dissertação de Mestrado em Engenharia Elétrica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1994. 122p
- Lunz, H.; Pereira, V. F. G.; Pereira, A. M. B. Desmatamento e uso atual da terra no Estado do Acre. In: Simpósio Brasileiro de Sensoriamento Remoto, 6. Manaus, 24-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v.2, p.373-380.
- Machado, J. R.; Barbosa, V. C.; Liporace, F. S., Ferlin, C. Monitoring the deforestation of the Amazon region with neural networks. In: Proceedings. Nagoya, International Joint Conference on Neural Networks, Japan, 1993
- Mead, R. A.; Congalton, R. G. A quantitative method to consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**, 10(1).69-74, Jan. 1983.
- Medeiros, J. S.; Dias, R. W. O.; Toledo, F. L.; Sano, E. E. **Mapeamento de projetos agropecuários.** Belém, SUDAM-CHSRA/OEA, 1988. 46p
- Meneses, P. R.; Assad, E. D., Sano, E. E. **Introdução ao processamento de imagens digitais de satélite de Sensoriamento Remoto.** Brasília, DF, Universidade de Brasília, 1991. 96p.
- Miranda, E. E.; R. Z. Mattos, C. Aplicações de imagens TM/Landsat na análise do uso da terra no Estado de Rondônia. In: Simpósio Brasileiro de Sensoriamento Remoto, 6. Manaus, 25-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v.2, p 451-456.

- Moigne, J. L. , Tilton, J. C. Refining image segmentation by integration of edge region data. In: International Geoscience and Remote Sensing Symposium IGARSS'92, Houston, TX, May 26-29, 1992. International Space Year: Space Remote Sensing. Piscataway, NJ, 1992, v. 2, p.1406-1408.
- Moik, J. G. **Digital processing of remotely sensed images**. Washington, DC, NASA, 1980. (NASA SP-431).
- Moran, E. F ; Brondizio, E.; Mausel, P ; Li, Y. H. Assinaturas espectrais diferenciando etapas de sucessão secundária no leste amazônico. In: Simpósio Brasileiro de Sensoriamento Remoto, 7. Curitiba, 10-14 maio, 1993. **Anais**, São José dos Campos, INPE, 1993. v. 2. p. 202-209.
- Nascimento, D. M. C.; Motti, P. J. M. Mapa de uso atual do cerrado - oeste do Estado da Bahia. In: Simpósio Brasileiro de Sensoriamento Remoto, 6. Manaus, 25-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v 2, p.432-439
- Novo, E. M. L. **Projeto UTVAP: análise comparativa entre fotografias aéreas convencionais e imagens do Landsat para fins de levantamento de uso da terra** São José dos Campos, INPE, ago. 1978. (INPE-1373-NTI/113).
- Novo, E. M. L. **Sensoriamento Remoto**: princípios e aplicações. São Paulo, Edgard Blücher, 1989. 308p.
- Pereira, M. N.; Novo, E. M. L. M.; Kurkdjian, M. L. N. O.; D'alge, J. C. L.; Florenzano, T. G. **Atualização do uso da terra do município de São José dos Campos através de dados de sensoriamento remoto**. São José dos Campos, INPE, 1987. (INPE-4479-RPE/568).

- Pinto, L. F. **Carajás, o ataque ao coração da Amazônia**. Rio de Janeiro, Marco Zero, 1981. 140p.
- Projeto RADAMBRASIL. **Folha SA 22 Belém**; geologia, geomorfologia, solos, vegetação e uso potencial da terra. Rio de Janeiro, 1974. (Levantamento de Recursos Naturais, 5).
- Richards, J. A. **Remote sensing digital images analysis: an introduction**. Berlin, Springer-Verlag, 1986. 281p.
- Ritter, N. D.; Hepner, G. F. Application of an artificial network to land-cover classification of thematic mapper imagery. **Computers and Geosciences**, 16 (6): 837-880, 1990.
- Robinson, G. S. Edge detection by compass gradient masks. **Computer Graphics and Image Processing**. 6 (5): 492-501, 1977.
- Rosa, R. A utilização de imagens TM/Landsat em levantamento de uso do solo. In: Simpósio Brasileiro de Sensoriamento Remoto, 6. Manaus, 25-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v.2, p.419-425.
- Sano, E. E.; Watrin, O. S.; Funaki, R. S.; Medeiros, J. S.; Dias, R. W. O. **Levantamento do uso atual da terra através de imagens do Landsat 5-TM na microrregião de Tomé-Açu e alguns municípios das microrregiões do baixo Tocantins e Guajarina (PA)**. Belém, SUDAM-CHSRA/OEA, 1989. 67p.
- Santos, A. P.; Foresti, C.; Novo, E. M. L.; Niero, M.; Lombardo, M. A. **Metodologia de interpretação de dados de sensoriamento remoto no uso da terra**. São José dos Campos, INPE, nov. 1981. (INPE-2261-MD/016).

- Santos, J. R. **Análise automática de dados do sensor MSS/Landsat para avaliação de áreas queimadas na instalação e conservação de projetos agropecuários.** São José dos Campos, INPE, fev. 1985, 10 p. (INPE-3417-PRE/683).
- Santos, J. R.; Venturieri, A.; Bernardes, S.; Krug, T.; Erthal, G. J.; Bins, L. S. **Uso do SGI na avaliação do desempenho da classificação baseada em segmentos para a caracterização de uso da terra na Amazônia brasileira.** Submetido ao Simpósio Latinoamericano de Percepción Remota, Cartagena, Colombia, 3-8, outubro, 1993
- Schlünzen, E. T. M.; Trindade, M. L. B.; Shimabukuro, M. H.; Junior, K. S.; Neto, M. L. A. Perspectiva da aplicação de redes neurais na classificação de dados multiespectrais de sensoriamento remoto. In: Simpósio Brasileiro de Sensoriamento Remoto, 7. Curitiba, 10-14 maio, 1993. **Anais**, São José dos Campos, INPE, 1993. v. 2. p. 438-444
- Schoenmakers, R. P. H. M.; Wilkinson, G. G.; Schoauten, T. E. Segmentation of remotely-sensed images: a redefinition for operational applications. In: International Geoscience and Remote Sensing Symposium, 11., IGARSS'91, Espoo, Finland, June 3-6, 1991. **Proceedings**. New York, NY, 1991, v.1, p.1087-1090.
- Schowengerdt, R. A. **Techniques for image processing and classification in remote sensing.** Orlando, FL, Academic Press, 1983. 249p.
- Serrão, E. A. S. Pastagem em área de floresta no trópico húmido brasileiro: conhecimentos atuais. In: Simpósio do Trópico Húmido, 1, Belém, 1984. **Anais**. Belém, EMBRAPA-CPATU, 1986. v.5.
- Silva, A. J. F. M. **Classificação automática bayesiana de imagens de satélite.**, Rio de Janeiro, IBM - Centro Científico, 1992. 15p.

- Silva, B. N. R.; Carvalho, J. S. Os solos da Amazônia Oriental. In : Pesquisas sobre a utilização e conservação do solo na Amazônia Oriental. **Relatório Final do Convênio EMBRAPA-CPATU/GTZ**. Belém, EMBRAPA-CPATU, 1986. p. 15-42 (Documentos, 40).
- Slater, P. N. **Remote sensing. optics and optical systems**. Reading, MA, Addison-Wesley, 1980. 575p.
- SUDAM/PHCA. Projeto de Hidroclimatologia e Climatologia da Amazônia. **Atlas Climatológico da Amazônia Brasileira**. Belém, 1984.
- Taranik, J. V. **Principles of computer processing of Landsat for geological applications**. Washington, DC, USGS, 1978. (open file rept. 78-117) 50 p.
- Tardin, A.T.; Cunha, R.P. Avaliação da alteração da cobertura florestal na Amazônia Legal utilizando sensoriamento remoto orbital. São José dos Campos, INPE, 1989. 30 p.
- Venturieri, A.; Funaki, R. S.; Medeiros, J. S. Mapeamento da cobertura vegetal e uso da terra na região de Tucuruí(PA) através da classificação digital supervisionada de imagens TM/Landsat. In: Simpósio Brasileiro de Sensoriamento Remoto, 6. Manaus, 25-29 junho, 1990. **Anais**, São José dos Campos, INPE, 1990, v.1, p.97-102.
- Wasserman, P. D. **Neural Computing Theory and Practice**. New York. Van Nostrand Reinhold, 1989.
- Watrin, O. S. **Análise da dinâmica da paisagem agrícola da Amazônia Oriental: abordagem integrando técnicas de processamento digital de imagens e sistemas de informações geográfica**. (Dissertação de Mestrado em 1994), Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1994. 175 p. (INPE - 5631-TDI/555).

Watrin, O. S., Rocha, A. M. A. **Levantamento da vegetação natural e uso da terra no município de Paragominas (PA) utilizando imagens TM/Landsat**. Belém, EMBRAPA-CPATU, Fev.1992. 40 p. (EMBRAPA/CPATU, Boletim de Pesquisa, 124).

Woodcock, C., Harward, V. J. Nested-hierarchical scene models and image segmentation. **International Journal of Remote Sensing**, 13 (16): 3167-3187, 1992.

APÉNDICE A

PROGRAMAS DESENVOLVIDOS

TABELA A1 - PROGRAMA ESTSEG.EXE, UTILIZADO PARA CÁLCULO DA MÉDIA E DESVIO PADÃO DOS SEGMENTOS

```

CLS
K$=COMMAND$
Arq$=LEFT$(K$,INSTR(K$," ")-1)
K$=MID$(K$,INSTR(K$,"")+1)+" "
DIM proc%(1..12)
I%=1
DO WHILE K$<>" "
  proc%(I%)=VAL(K$)
  K$=MID$(K$,INSTR(K$,"")+1)
  INCR I%
LOOP
Nbandas%=6
OPEN "I" #1,ARQ$+" .CEL"
INPUT #1,NN%
? NN%
DIM pesos%(1..12),med#(0),var#(0)
segmentos$=""
DIM Soma#(Nbandas%),Soma2#(Nbandas%)
Ntotal&=0
Nsegmentos%=0
DO WHILE NOT EOF(1)
  INPUT #1,segm%,nsegm&,nband%,nviz%,Lmin%,Lmax%,Cmin%,Cmax%
  LOCATE 2,1:?" segm%"
  FOR I%=1 TO UBOUND(pesos%(1))
    INPUT #1,pesos%(I%)
  NEXT I%
  ERASE med#,var#
  DIM med#(1:Nbandas%),var#(1:Nbandas%)
  FOR I%=1 TO Nbandas%
    INPUT #1,med#(I%)
  NEXT I%
  FOR I%=1 TO Nbandas%
    INPUT #1,var#(I%)
  NEXT I%
  FOR I%=1 TO nviz%
    INPUT #1,temp%
  NEXT I%
  incorpora%=-1
  FOR I%=1 TO UBOUND(pesos%(1))
    IF pesos%(I%)<>proc%(I%) THEN incorpora%=0
  NEXT I%
  IF incorpora% THEN
    INCR Ntotal&.nsegm&
    FOR I%=1 TO Nbandas%
      INCR Soma#(I%),CLNG(med#(I%)*nsegm&)
      INCR Soma2#(I%),CLNG(nsegm&*(var#(I%)+med#(I%)^2))
    NEXT I%
    segmentos$=segmentos$+STR$(segm%)
    INCR Nsegmentos%

```

```

    END IF
    IF INKEY$=CHR$(27) THEN EXIT LOOP
LOOP
CLOSE #1
OPEN "A",#1,ARQ$+" EST"
PRINT #1,"Pesos: ";
FOR I%=1 TO 12
    PRINT #1,proc%(I%);
NEXT I%
PRINT #1,""
PRINT #1,"No. de pixels: ";Ntotal&
PRINT #1,"No. de segmentos: ";Nsegmentos%
PRINT #1,""
FOR I%=1 TO Nbandas%
    PRINT #1, "Banda: ";I%
    PRINT #1, "M.dia: ";Soma#(I%)/Ntotal&
    PRINT #1, "Desvio padr.,o: ";SQR((Soma2#(I%)-(Soma#(I%)^2)/Ntotal&)/Ntotal&)
    PRINT #1,""
NEXT I%
PRINT #1,"Segmentos:"
PRINT #1, segmentos$
PRINT #1,""
CLOSE #1
? "FIM"
END

```

TABELA A2 - PROGRAMA TCALC.EXE, UTILIZADO NO TESTE DE MÉDIAS
ENTRE PIXELS E REGIÕES

```

CLS
INPUT "Nome do Arquivo de Saída: ",ARQ$
OPEN "O",#1,ARQ$
DO
  INPUT "Nome da Classe: ",class$
  IF class$="" THEN EXIT LOOP
  PRINT #1,class$
  INPUT "M,dia do Segmento: ",Xseg
  INPUT "Desvio Padr.,o do Segmento: ",Dseg
  INPUT "Tamanho do Segmento: ",Nseg&
  INPUT "M,dia do Pixel: ",Xpix
  IF Xseg < 0 THEN EXIT LOOP
  INPUT "Desvio Padr.,o do Pixel: ",Dpix
  INPUT "Tamanho do Pixel: ",Npix&
  tcalc=(Xseg-Xpix)/sqr(Dseg^2/Nseg&+Dpix^2/Npix&)
  PRINT #1, "      M,dia  Desvio      N"
  PRINT #1, USING "Segmento ###.### ###.### #####":Xseg,Dseg,Nseg&
  PRINT #1, USING "Pixel   ###.### ###.### #####":Xpix,Dpix,Npix&
  PRINT #1, USING "T Calculado: ###.###",tcalc
  IF ABS(tcalc) <= 1.96 THEN PRINT #1,"Aceita Ho a 95%" ELSE PRINT #1,"Rejeita Ho a 95%"
  PRINT #1,""
  ?
LOOP
CLOSE #1
? "Fim"

```

APÊNDICE B

TABELAS

TABELA B1 - COMBINAÇÕES UTILIZADAS PARA A CLASSE FLORESTA

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
Floresta	3	1	0	0	0	0	0	0	0	0	5519	24
	3	1	0	0	0	0	0	0	0	1	79	1
	3	1	0	0	0	0	0	0	1	0	76	4
	4	0	0	0	0	0	0	0	0	0	14444	566
	4	0	0	0	0	0	0	0	0	1	1117	3
	4	0	0	0	0	0	0	0	1	0	1064	31
	4	0	0	0	0	0	0	0	2	0	630	12
	4	0	0	0	0	0	0	0	3	0	82	2
	4	0	0	0	0	0	0	1	0	0	239	10
	4	0	0	0	0	0	0	2	0	0	56	3

TABELA B2 - COMBINAÇÕES UTILIZADAS PARA A CLASSE SUCESSÃO SECUNDÁRIA AVANÇADA

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
SSAvan	0	3	0	0	0	0	1	0	0	0	18	1
	0	3	0	0	0	1	0	0	0	0	26	1
	0	3	0	0	1	0	0	0	0	0	17	1
	0	3	0	1	0	0	0	0	0	0	50	1
	0	3	1	0	0	0	0	0	0	0	28212	352
	0	3	1	0	0	0	0	0	0	1	185	4
	0	3	1	0	0	0	0	0	0	2	20	1
	0	3	1	0	0	0	0	0	1	0	1370	28
	0	3	1	0	0	0	0	1	0	0	894	26
	0	4	0	0	0	0	0	0	0	0	24117	624
	0	4	0	0	0	0	0	0	0	1	1272	11
	0	4	0	0	0	0	0	0	0	2	16	1
	0	4	0	0	0	0	0	0	1	0	743	17
	0	4	0	0	0	0	0	0	2	0	208	5
	0	4	0	0	0	0	0	1	0	0	269	11
	0	4	0	0	0	0	0	2	0	0	19	1
	1	3	0	0	0	0	0	0	0	0	8649	55
	1	3	0	0	0	0	0	0	1	0	15	1
	1	3	0	0	0	0	0	0	2	0	21	1
	1	3	0	0	0	0	0	1	0	0	69	3
1	3	0	0	0	0	0	2	0	0	32	1	

TABELA B3 - COMBINAÇÕES UTILIZADAS PARA A CLASSE SUCESSÃO
SECUNDÁRIA INICIAL

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
SSInicia	0	0	3	0	0	0	0	1	0	0	12	1
	0	0	3	0	0	0	1	0	0	0	32	2
	0	0	3	0	1	0	0	0	0	0	11705	158
	0	0	3	0	1	0	0	0	0	1	35	2
	0	0	3	0	1	0	0	0	1	0	568	10
	0	0	3	0	1	0	0	0	2	0	30	1
	0	0	3	0	1	0	0	1	0	0	563	17
	0	0	3	0	1	0	0	2	0	0	13	1
	0	0	3	1	0	0	0	0	0	0	92	3
	0	0	3	1	0	0	0	0	1	0	26	1
	0	0	3	1	0	0	0	0	2	0	52	1
	0	0	3	1	0	0	0	1	0	0	147	3
	0	0	4	0	0	0	0	0	0	0	4743	109
	0	0	4	0	0	0	0	0	0	1	11	1
	0	0	4	0	0	0	0	0	1	0	241	7
	0	0	4	0	0	0	0	0	2	0	107	4
	0	0	4	0	0	0	0	1	0	0	112	5
	0	0	4	0	0	0	0	2	0	0	24	1
	0	1	3	0	0	0	0	0	0	0	2758	67
	0	1	3	0	0	0	0	0	0	1	18	1
	0	1	3	0	0	0	0	0	0	2	45	1
	0	1	3	0	0	0	0	0	1	0	232	4
	0	1	3	0	0	0	0	0	2	0	37	1
	0	1	3	0	0	0	0	1	0	0	223	5
0	1	3	0	0	0	0	2	0	0	96	1	

TABELA B4 - COMBINAÇÕES UTILIZADAS PARA A CLASSE PASTO SUJO

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
PSujo	0	0	0	0	3	0	1	0	0	0	613	19
	0	0	0	0	4	0	0	0	0	0	11298	1048
	0	0	0	0	4	0	0	0	0	1	699	20
	0	0	0	0	4	0	0	0	0	2	206	5
	0	0	0	0	4	0	0	0	1	0	525	15
	0	0	0	0	4	0	0	0	2	0	23	1
	0	0	0	0	4	0	0	1	0	0	1268	40
	0	0	0	0	4	0	0	2	0	0	127	5
	0	0	0	1	3	0	0	0	0	0	26292	452
	0	0	0	1	3	0	0	0	0	1	179	7
	0	0	0	1	3	0	0	0	0	2	13	1
	0	0	0	1	3	0	0	0	1	0	124	5
	0	0	0	1	3	0	0	1	0	0	1484	30
	0	0	0	1	3	0	0	2	0	0	34	2
	0	0	1	0	3	0	0	0	0	0	30459	429
	0	0	1	0	3	0	0	0	0	1	96	3
	0	0	1	0	3	0	0	0	1	0	217	8
0	0	1	0	3	0	0	1	0	0	1592	55	
0	0	1	0	3	0	0	2	0	0	77	2	

TABELA B5 - COMBINAÇÕES UTILIZADAS PARA A CLASSE PASTO LIMPO

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
PLimpo	0	0	0	3	0	0	1	0	0	0	116	3
	0	0	0	3	1	0	0	0	0	0	16215	178
	0	0	0	3	1	0	0	0	0	1	143	1
	0	0	0	3	1	0	0	0	1	0	60	1
	0	0	0	3	1	0	0	1	0	0	181	8
	0	0	0	3	1	0	0	2	0	0	184	2
	0	0	0	4	0	0	0	0	0	0	12279	288
	0	0	0	4	0	0	0	0	0	1	275	5
	0	0	0	4	0	0	0	0	0	2	12	1
	0	0	0	4	0	0	0	0	1	0	70	4
	0	0	0	4	0	0	0	1	0	0	131	6
	0	0	1	3	0	0	0	1	0	0	43	1

TABELA B6 - COMBINAÇÕES UTILIZADAS PARA A CLASSE SOLO AGRÍCOLA

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
Solo	0	0	0	0	0	4	0	0	0	0	2628	65
	0	0	0	0	1	3	0	0	0	0	102	3
	0	0	1	0	0	3	0	0	0	0	13	1
	0	0	1	0	0	3	0	1	0	0	20	1

TABELA B7 - COMBINAÇÕES UTILIZADAS PARA A CLASSE ÁREA URBANA

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
Urbana	0	0	0	0	0	0	3	0	0	1	87	1
	0	0	0	0	0	0	4	0	0	0	13260	476
	0	0	0	0	0	0	4	0	0	1	36	2
	0	0	0	0	0	0	4	0	1	0	80	2
	0	0	0	0	0	0	4	0	2	0	17	1
	0	0	0	0	0	0	4	1	0	0	172	7
	0	0	0	0	0	0	4	2	0	0	267	6
	0	0	0	0	0	1	0	3	0	0	195	5
0	0	0	1	0	0	0	3	0	0	140	7	

TABELA B8 - COMBINAÇÕES UTILIZADAS PARA A CLASSE NÚVEM

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
Núvem	0	0	0	0	0	0	0	3	1	0	106	4
	0	0	0	0	0	0	0	4	0	0	16250	2129
	0	0	0	0	0	0	0	4	1	0	2803	108
	0	0	0	0	0	0	0	4	0	2	540	20
	0	0	0	0	0	0	0	4	1	0	277	10
	0	0	0	0	0	0	0	4	2	0	68	2

TABELA B9 - COMBINAÇÕES UTILIZADAS PARA A CLASSE SOMBRA

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
Sombra											26	1
											27	1
									4		25451	1174
											489	14
											44	1
											122	4
											714	20

TABELA B10 - COMBINAÇÕES UTILIZADAS PARA A CLASSE ÁGUA

Classe	F	V	I	L	U	G	R	N	S	A	Nº de Pixels	Nº de Segmentos
Água	0	0	0	0	0	0	0	0	0	4	5790	1453
	0	0	0	0	0	0	0	0	1	4	12	1
	0	0	0	0	0	0	0	1	0	3	28	1
	0	0	0	0	0	0	0	1	0	4	5400	180
	0	0	0	0	0	0	0	2	0	4	1324	56