



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-12908-TDI/1011

**REDES NEURAIAS ARTIFICIAIS PARA CLASSIFICAÇÃO
ESPECTRO-TEMPORAÇ DE CULTURAS AGRÍCOLAS**

José Marinaldo Gleriani

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. José Carlos Neves Epiphanyo e José Demisio Simões da Silva, aprovada em 30 de agosto de 2004.

528.711.7 : 681.3.019

GLERIANI, J. M.

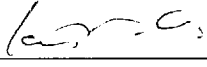
Redes neurais artificiais para classificação de espectro-temporal de culturas agrícolas / J. M. Gleriani. – São José dos Campos: INPE, 2004.

211p. – (INPE-12908-TDI/1011).

1. Identificação de culturas agrícolas. 2. análise multitemporal. 3. Índice de Vegetação da Diferença Normalizada (NDVI). 4. Redes neurais. 5. Fenologia. I. Título.

Aprovado(a) pela Banca Examinadora em cumprimento ao requisito exigido para a obtenção do Título de **Doutor em Sensoriamento Remoto.**

Dra. Leila Maria Garcia Fonseca



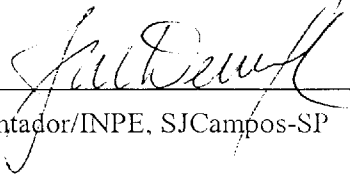
Presidente/INPE, SJCampos-SP

Dr. José Carlos Neves Epiphânio



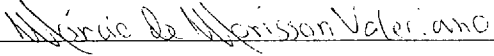
Orientador/INPE, SJCampos-SP

Dr. José Demísio Simões da Silva



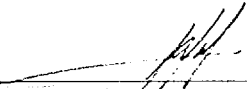
Orientador/INPE, SJCampos-SP

Dr. Márcio de Morisson Valeriano




Membro da Banca/INPE, SJCampos-SP

Dr. Carlos Alberto Vettorazzi



Membro da Banca/Convidado - ESALQ/USP,
São Paulo-SP

Dr. Mauro Antonio Homem Antunes



Membro da Banca/Convidado - UFRRJ,
Rio de Janeiro-RJ

Candidato(a): José Marinaldo Gleriane

*"Apenas quando o homem matar o último peixe,
poluir o último rio e derrubar a última árvore,
irá compreender que não poderá comer o dinheiro que ganhou".*

(provérbio indígena)

Dedico a meus pais e meus irmãos.

AGRADECIMENTOS

Agradeço a Deus por mais uma longa e rica etapa concluída.

Aos Drs. José Carlos Neves Epiphânio e José Demisio Simões da Silva por este período de crescimento profissional, por todo o apoio e conselhos, os quais enriqueceram este documento.

À minha família, pelo incentivo, as orações, e a mão amiga que nunca faltaram.

À Fundação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pelo auxílio financeiro.

Ao Instituto Nacional de Pesquisas Espaciais – INPE, pela oportunidade de estudos e utilização de suas instalações.

À Universidade Federal de Viçosa - UFV, principalmente às funcionárias do setor de capacitação e treinamento.

Ao Departamento de Engenharia Florestal da UFV, principalmente aos colegas Vicente Soares e José Carlos Ribeiro, que assumiram enormes tarefas num momento difícil da Universidade.

Aos irmãos adotivos Aníbal e Rovedy, pelos programas computacionais essenciais para a conclusão deste trabalho.

Ao sempre pronto Paulo Eduardo Ubaldino de Souza, pelas macros que facilitaram a construção dos vetores de amostras da rede neural.

Pelos valiosos conselhos sobre o SNNS: Maria Valverde, Maria Conceição, Ubiratan Freitas e Simeão Medeiros.

Aos amigos Rogério Cardoso e Carlos Alberto Silva, da Casa da Agricultura de Miguelópolis, que tornaram o trabalho de campo um momento de grande descontração.

Aos colegas pelas mais diversas ajudas: Elizabete Caria, Maria Etelvina Rennó, Camilo Daleles Rennó, Silvia Pardi Lacruz, Manoel Araújo Júnior, Ana Paula Abrantes de Castro, Ana Paula Figueiredo, Élcio Hideiti Shiguemori, Rodrigo Rizzi, Francisco Maldonado, Marcos Adami, Reinaldo Arakaki, Salete Gürtler, Rosa Shimabukuro, Paulo Graça, Angelucci Rodrigues.

Aos Drs. Carlos Alberto Vettorazzi, Márcio de Morisson Valeriano, Leila Maria Garcia Fonseca e Mauro Antonio Homem Antunes pelas sugestões.

Às orações e ao apoio da eterna professora Jeanette Crespi.

RESUMO

Investigou-se nesse trabalho uma nova metodologia de classificação de cenas agrícolas em imagens digitais. As cenas agrícolas possuem uma complexidade intrínseca causada pela desuniformidade fenológica encontrada em uma cena, além da perda de particularidades espectrais quando imageadas pelos sensores orbitais de bandas largas. Visando solucionar esse problema, foi analisada uma metodologia onde um pixel é analisado de maneira contínua no tempo, e a espectro-temporalidade obtida é analisada através de redes neurais. Dez imagens do sensor ETM+ (“Enhanced Thematic Mapper Plus”) da órbita/ponto 220/74, do ano de 2002 da região de Miguelópolis (SP) foram utilizadas. Estas imagens foram retificadas radiometricamente para a uniformização dos efeitos atmosféricos e classificadas através de perceptrons de múltiplas camadas treinados com o algoritmo de retropropagação do erro (RPE); outra rede utilizada foi a rede de Funções de Base Radial (FBR), além do classificador Gaussiano de máxima verossimilhança. Foram utilizados como parâmetros de entrada as bandas 3, 4 e 5, e o índice NDVI como indicador de variação de IAF (Índice de Área Foliar). As classificações foram supervisionadas tendo 6 classes agrícolas: feijão1, feijão2, milho, sorgo, cana colhida no ano e cana de ano e meio. Foram testados diferentes parâmetros estatísticos para alimentar as redes como a média e/ou desvio padrão de janelas com 3x3 pixels, em três combinações diferentes: média e desvio padrão das bandas 3, 4 e 5 e do NDVI; média do NDVI e média e desvio padrão das bandas 3, 4 e 5 e, por último, somente os arquivos de média das bandas e do NDVI. A melhor combinação de parâmetros foi a utilização apenas dos arquivos de média, uma vez que o uso do desvio padrão introduziu ruído na classificação. Após a escolha da melhor combinação de parâmetros estatísticos, analisou-se, através da classificação temporal, o desempenho dos algoritmos RPE, FBR e o MaxVer. Numa análise posterior, executaram-se com esses três algoritmos, classificações de única data, que foram confrontadas com a classificação temporal. Por último, testou-se a tolerância das redes neurais a dados falhos, simulando-se a perda alternada de imagens. Essas imagens foram suprimidas e substituídas pela média entre a imagem anterior e a posterior à data considerada. Os desempenhos das classificações foram analisados através de procedimentos de estatística kappa e kappa condicional, este último permitiu verificar o desempenho dos classificadores e a influência da temporalidade para cada classe específica. Na análise dos classificadores, o algoritmo de RPE apresentou um valor de kappa superior à rede FBR e ao MaxVer; porém sem diferença significativa. A simulação de dados falhos, resultou numa queda não significativa do kappa, mas a classe sorgo desapareceu do mapa temático final. O kappa condicional mostrou que a temporalidade na caracterização das culturas agrícolas é relevante principalmente com a rede RPE, embora a melhora na classificação nem sempre ocorra simultaneamente em relação aos erros de omissão e comissão de cada classe. A única classe que não se beneficiou com o uso da temporalidade foi a classe cana de ano. Essa classe é de difícil definição do vetor espectro-temporal pela ação antrópica que pode ocorrer em sete meses ao longo do ano. No entanto, a classificação com uma única data, em meados de abril, mostrou ser bastante satisfatória. A análise espectro-temporal de cenas agrícolas processada através de redes neurais é promissora em relação aos tradicionais métodos de classificação.

ARTIFICIAL NEURAL NETWORKS TO SPECTRAL-TEMPORAL CLASSIFICATION OF AGRICULTURAL CROPS

ABSTRACT

This work aimed at investigating a new classification methodology for agricultural scenes in digital images. Agricultural scenes are intrinsically complex due to phenological differences found in the scene and to the loss of spectral particularities when surveyed by broad-band orbital sensors. In order to solve this problem, a new methodology is presented, where the pixel is seen as a continuum in time and the spectral-temporality is analyzed using neural networks. Ten ETM+ images, path/row 220/74 of Miguelópolis-SP, Brazil, from the winter of 2002 were used. These images were radiometrically corrected to uniform the atmospheric effects and classified by a multilayer perceptron trained with the backpropagation error (BPE) algorithm; another neural network used was radial basis function (FBR), besides the Maximum Likelihood Gaussian classifier (MaxVer). The input parameters were bands 3, 4 and 5 and the NDVI (Normalized Difference Vegetation Index) as an LAI (Leaf Area Index) variation indicator. Supervised classifications were used with six agricultural classes: beans1, beans2, corn, sorghum, one-year sugarcane and one-year-and-half sugarcane. Different ways of feeding the network with the average and/or standard deviation of 3x3 pixel windows were tried with three different combinations: average and standard deviation of bands 3, 4 and 5 and of NDVI; average of NDVI and average and standard deviation of bands 3, 4 and 5; and only the files of average of the bands and the NDVI. The best combinations parameters was the use only the average files, because the standard deviation introduced noise in classification. After choosing the best statistical parameters to be used, the performance of the BPE, FBR and the MaxVer algorithms were analyzed through a temporal classification. Then, the classification within each date was carried out with these three algorithms and the results were analyzed and compared against the temporal classification of each algorithm. At last, the tolerance of the neural network was tested for missing data, simulating the loss of images from every other date. These images were suppressed and substituted by the average between the preceding and the posterior images to the considered date. The performance of these classifications was tested using kappa and conditional kappa statistics; this last test allowed the evaluation of the performance of the classifiers and of the temporal trend of each specific class. Results for the statistical parameters showed that using only the files of average is enough to represent the classes, as the standard deviation introduces noise to the classification. The BPE algorithm presented a higher kappa value than FBR network and MaxVer algorithms, but without significant difference; however without statistical significance. The simulation of missing data caused no significant decrease on kappa statistics, but the class sorghum was suppressed from the final thematic map. The conditional kappa showed that the use of temporal characteristics of the data in the classification of agricultural crops is relevant, mainly with the BPE network, although the improvement in the classification is not always simultaneous in relation to the commission and omissions errors of each class. The only class that did not show an improvement with the temporal characteristic was the one-year sugarcane. In this class

the spectral-temporal vector is difficult to define due to tillage practices that may occur any time during seven months throughout the year. Meanwhile, the classification using only one date from April showed rather satisfactory. The spectral-temporal analysis of the agricultural scenes by neural network is promising in comparison with traditional classification methods.

SUMÁRIO

LISTA DE FIGURAS	
LISTA DE TABELAS	
LISTA DE SÍMBOLOS	
LISTA DE SIGLAS E ABREVIATURAS	
CAPÍTULO 1- INTRODUÇÃO	29
CAPÍTULO 2 -FUNDAMENTAÇÃO TEÓRICA	33
2.1 – Importância da Atividade Agrícola Para o Brasil	33
2.2 - Extração de Informação a Partir de Dados de Sensores Orbitais	34
2.3 – Correção da Interferência da Atmosfera	36
2.4 – Retificação de Imagens	43
2.5 – Sensoriamento Remoto na Agricultura.....	45
2.6 - Classificação de Imagens Digitais.....	49
2.6.1 – Classificador Gaussiano de Máxima Verossimilhança.....	50
2.6.2 – Redes Neurais Artificiais	53
2.7 – Temporalidade na Análise de Alvos Agrícolas	71
2.8 – Fenologia de Algumas Culturas Agrícolas	78
2.8.1 - Fenologia da Cultura do Sorgo	78
2.8.2 - Fenologia da Cultura do Milho	79
2.8.3 - Fenologia da Cultura de Feijão	81
2.8.4 - Fenologia da Cultura da Cana-de-Açúcar	83
CAPÍTULO 3 - MATERIAIS E MÉTODOS.....	87
3.1 - Localização da Área de Estudo e Descrição do Uso do Solo.....	87
3.2 - Escolha da Área.....	88
3.3 - Dados de Sensoriamento Remoto.....	89
3.4 - Dados de Campo	92
3.5 - Entrada dos Dados	92
3.6 - Correção Atmosférica.....	92
3.7 - Retificação Radiométrica	94
3.8 – Obtenção de Amostras via PI Cadastral no Ambiente SPRING	95
3.9 – Cálculo do NDVI, Análise Visual dos Dados e Definição das Classes.....	97
3.10 - Criação de PIs Cadastrais Para Extração de Amostras.....	99
3.11 - Pré-Processamento dos Dados.....	99
3.12 - Sequenciamento Para Entrada e Codificação de Saída	103
3.13 - Treinamento e Classificação	106
3.14 - Rede Treinada com o Algoritmo de Retopropagação do Erro (RPE)	107
3.15 - Função de Base Radial (FBR)	108
3.16 – Organização dos Dados Para Produzir Mapas Temáticos	109
3.17 - Classificação com o Classificador Gaussiano de Máxima Verossimilhança (MaxVer)	111
3.18 – Análises, Arquiteturas, Algoritmos e Parâmetros Estatísticos	112
3.19 - Geração de Grade com Pontos de Referência e Análise Estatística	114
CAPÍTULO 4 - RESULTADOS E DISCUSSÕES	119

4.1- Complexidade da Área de Estudo	119
4.2 – Resultados da Correção Atmosférica.....	121
4.3 – Retificação	121
4.4 – Normalização dos Dados	124
4.4.1 – Normalização dos Arquivos de Média	124
4.4.2 – Normalização dos Arquivos de Desvio Padrão	125
4.5 – Definição das Classes	127
4.5.1 – Perfil Espectro-Temporal da Cultura de Feijão	127
4.5.2 – Perfil Espectro-Temporal da Cultura de Milho	131
4.5.3 – Perfil Espectro-Temporal da Cultura do Sorgo	132
4.5.4 – Perfil Espectro-Temporal da Cultura da Cana-de-Açúcar	133
4.5.4.1 – Cana Colhida no Ano	133
4.5.4.2 – Cana de Ano e meio.....	139
4.6 – Discriminação e Identificação	140
4.7 – Avaliação das Classificações	142
4.7.1 – Avaliação dos Parâmetros Estatísticos	142
4.7.2 – Avaliação da Temporalidade	146
4.7.2.1 – Rede Neural com Algoritmo de Retropropagação do Erro	146
4.7.2.2 – Função de Base Radial (FBR)	148
4.7.2.3 – Classificador por Máxima Verossimilhança (MaxVer).....	150
4.7.3 – Desempenho dos Classificadores	152
4.7.4 – Tolerância a Dados Falhos.....	153
4.8 – Kappa Condicional	156
4.9 – Avaliação do Kappa Condicional Para a Classe Milho	158
4.10 – Avaliação do Kappa Condicional Para a Classe Sorgo	161
4.11 – Avaliação do Kappa Condicional Para a Classe Cana Colhida no Ano	164
4.12 – Avaliação do Kappa Condicional Para a Classe Cana de Ano e Meio.....	168
4.13 – Avaliação do Kappa Condicional Para a Classe Feijão 1	171
4.14 – Avaliação do Kappa Condicional Para a Classe Feijão 2	174
CAPÍTULO 5 – CONCLUSÕES E RECOMENDAÇÕES	179
REFERÊNCIAS BIBLIOGRÁFICAS	183
APÊNDICE A - MODELO DE CORREÇÃO ATMOSFÉRICA DOS3 EM LEGAL	197
APÊNDICE B- GERAÇÃO DAS COMPONENTES GREENESS (GR) E BRIGHNESS (BR)	197
APÊNDICE C – MACRO PARA A GERAÇÃO DE POLÍGONOS	205
APÊNDICE D – LEGAL DE FILTRO DE MÉIDA 3X3	207
APÊNDICE E – ORGANIZADOR DE ARQUIVOS PARA SNNS.....	209
APÊNDICE F – ORGANIZADOR DE ARQUIVOS SNNS - SPRING	211

LISTA DE FIGURAS

2.1 – A subtração de uma constante de cada banda não altera a posição relativa dos agrupamentos de cada classe, sem efeitos nos valores finais da matriz de variância-covariância e sem alteração no resultado da classificação.....	37
2.2- Interações da radiação eletromagnética com a atmosfera e a superfície terrestre. E_d é a irradiância difusa, E_0 é a irradiância solar direta, T_v é a transmitância na trajetória superfície terrestre-sensor, T_z é a transmitância na trajetória Sol-superfície terrestre. L_{haze} é a radiância difusa, L_{sat} é a radiância total que chega ao sensor.	40
2.3 – Gráfico ilustrativo da dispersão “brightness” versus “greenness”. Os pontos claros e escuros dos pontos de controle radiométrico para a componente “brightness” se situam em valores extremos, já os valores de controle radiométrico claros da componente “greenness” são ligeiramente superiores escuros.	44
2.4 – Níveis de informação no monitoramento da lavoura.....	46
2.5 - Dinâmica da infestação da helmintosporiose em diferentes níveis de severidade.	47
2.6 – Princípios, aplicações e limitações logísticas em sensoriamento remoto agrícola.	49
2.7 - Esquema de um neurônio biológico.	54
2.8 – Modelo de Neurônio.	55
2.9 – Ilustração das funções logísticas e tangentes hiperbólicas.	55
2.10 – Rede de múltiplas camadas com arquitetura 4-3-5.....	56
2.11 – Gráfico de fluxo de sinal de um neurônio.	58
2.12 – Ilustração esquemática do algoritmo de RPE.	60
2.13- Arquitetura de uma rede neural de função de base radial.	61
2.14 – Exemplo de dados que se distribuem em três classes. Na primeira são separados por hiperplanos através de redes RPE e na segunda são separados e ajustados por funções representadas pela FBR.	62
2.15 – Reescalamento de uma banda hipotética com DN máximo 110 segundo Jarvis e Stuart (1996) (a), e segundo Miller et al. (1995) (b).	65
2.16 – Bandas espectrais (B_1 a B_n) e duas possíveis maneiras de entrada dos dados na RNA: (a) pixel a pixel e (b) através de janela 3x3 a qual adiciona informação textural além da espectral.	69
2.17 - Ilustração do ponto e parada antecipada baseado na validação cruzada.	70
2.18 – Formas de representação de dados multispectrais; λ é o comprimento de onda.	71

2.19 – Modelo de perfil temporal para o índice “greenness”.	73
2.20 – Perfil temporal do índice RS para as o trigo, milho e o grão-de-bico.	74
2.21 – Valor de pico do índice RS versus período de ascensão do valor.	75
2.22 - Perfil temporal do índice RS para alfafa, milho e pastagem.	76
2.23 – Estádios fenológicos da cultura do sorgo.	78
2.24 – Estádios fenológicos da cultura do milho.	80
2.25 – Ciclo fenológico do feijoeiro.	82
2.26 – Tempo médio de duração das etapas de desenvolvimento do feijoeiro pertencentes a quatro grupos de desenvolvimento.	83
2.27 – Curvas de crescimento da cana de açúcar.	85
3.1 - Localização da área de estudo no Estado de São Paulo.	87
3.2 – Metodologia desenvolvida.	91
3.3 – Ilustração dos parâmetros estatísticos média (\bar{x}) e desvio padrão (s) utilizados na entrada na rede.	96
3.4 – O ponto (cruz) de coordenada x y e polígono 3x3 gerado a partir deste ponto com um incremento Δ de 45.	96
3.5 – Imagem na composição 3B4R5G de 30/06/2002 e os correspondentes objetos com texto e tabela de atributos.	98
3.6 – Exemplo de um objeto espacial (polígono 29) da classe feijão 1 e alguns dos seus atributos: parâmetros estatísticos das bandas b3, b4 e b5 e do NDVI para a quarta data (29 de maio de 2002).	98
3.7 – Fluxograma da extração de amostras e geração de arquivos de classificação do SPRING para o SNNS (“Stuttgart Neural Network Simulator”).	100
3.8 – Procedimento para delimitar o limiar de um histograma.	102
3.9 – Procedimento adotado neste trabalho para delimitar o limiar.	103
3.10 – Exemplo de matriz de entrada de dados.	104
3.11 – Entrada multitemporal do NDVI e das bandas ETM+ 3, 4 e 5 na rede com arquivos de médias e a correspondente codificação de saída.	106
3.12 – Duas simulações de perda de dados por nebulosidade em datas alternadas. Situação (a) perda das imagens 3, 5, 7 e 9. Situação (b) perda das imagens 2, 4, 6, 9 (A imagem 8 já é simulada no conjunto original de onde se extraíram amostras de treinamento).	111
4.1 – Imagem composição 3B4R5G de 27 de abril de 2002 e fotos do dia 22 de abril. O milho do polígono 10/122 está com 0,3 m de altura e o milho do polígono 10/107 com aproximadamente 1,0 m, enquanto que o milho do polígono 6/27 está pronto para colheita. A numeração dos polígonos é a mesma utilizada no trabalho de campo: n° quadrícula/n° talhão.	119

4.2 – Mapa de referência obtido através dos levantamentos de campo de abril e agosto de 2002.....	111
4.3 – Comparação dos valores de DN em dosséis de algodão e água antes e após a correção atmosférica.....	121
4.4 – Nuvens de pixels do gráfico “greenness” versus “brighthness” da imagem referência e da imagem objeto.....	122
4.5 – Histograma resultante do cálculo do desvio padrão de uma janela 3x3. Na porção A do histograma encontram-se as altas frequências de baixo valores provindos de talhões agrícolas. Na porção B, altos valores resultantes de bordas de rios, estradas e talhões.....	126
4.6 – Visualização da imagem ASCII desvio padrão. No interior dos talhões agrícolas o desvio padrão é baixo; apenas os carregadores aumentam o desvio padrão. Em contraste, nas bordas de estradas, talhões e rios o desvio padrão é alto.	126
4.7 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe feijão 1.	128
4.8 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe feijão 2.	129
4.9 – Perfis temporais do NDVI oriundos de dois polígonos de feijão 2 cuja cultura anterior era feijão (a) e milho (b).	130
4.10 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe milho.....	131
4.11 – Perfis temporais de NDVI e bandas 3,4 e 5 ETM+ para a classe sorgo.	132
4.12 – Perfis temporais de NDVI e bandas 3,4 e 5 ETM+ para a classe cana colhida no ano.....	134
4.13 – Foto de campo ilustrando as folhas senescentes do dossel de cana adulta.	135
4.14 – Variações do NDVI para talhões de cana-de-açúcar colhidos antes de novembro.....	136
4.15 - Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para cana colhida mecanicamente.	137
4.16 – Composição 3B4R5G destacando-se um talhão de cana colhido mecanicamente.	137
4.17 - Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para cana colhida mecanicamente com remoção da palhada.	138
4.18 – Composição 3B4R5G destacando com seta amarela o talhão de cana colhido manualmente com incorporação da palhada.....	138
4.19 – Perfis temporais de NDVI e bandas 3,4 e 5 ETM+ para a classe cana de ano e meio.....	139
4.20 – Resultado da classificação com a rede RPE com arquivos de média e desvio padrão do NDVI e das bandas 3, 4 e 5 nas 10 datas. Rede 80-70-8.	143

4.21 – Resultado da classificação com a rede RPE com arquivo de média e desvio padrão das bandas 3, 4 e 5, com o arquivo de média do NDVI nas 10 datas. Rede 70-70-8.	144
4.22 – Resultado da classificação com a rede RPE com arquivo de média e das bandas 3, 4 e 5 e do NDVI nas dez datas. Rede 40-70-8.	145
4.23 - Resultado da classificação da rede de RPE para a quinta data.	148
4.24 - Resultado da classificação temporal com a rede FBR	149
4.25 - Resultado da classificação da rede FBR para a segunda data.	150
4.26 – Classificação temporal realizada com o classificador MaxVer.	151
4.27 – Resultado da classificação MaxVer para a segunda data.	152
4.28 – Classificação com a rede RPE com arquivo da primeira falha simulada.	155
4.29 – Classificação com a rede FBR com arquivo da primeira falha simulada.	156
4.30 – Classificação de culturas com duração do ciclo fenológico muito distinto, utilizando redes com arquiteturas mais específicas. O mapa final é gerado pela união dos mapas temáticos parciais.	177

LISTA DE TABELAS

2.1 - Intervalos das bandas espectrais de alguns sensores orbitais em três regiões do espectro refletivo.....	35
2.2 – Descrição dos valores adotados para os parâmetros: transmitância superfície-sensor (T_v), transmitância Sol-superfície (T_z) e irradiância difusa (E_{disusa}) na evolução do modelo de correção atmosférica subtração do pixel escuro (DOS).....	42
2.3 – Resultado das análises discriminantes de alguns trabalhos que fizeram classificação de cenas agrícolas.	53
3.1 – Imagens de satélite utilizadas neste trabalho.	89
3.2 - Recomendação de alto (H) e baixo (L) ganho para os canais do sensor ETM+ para a órbita ponto 220/74 para o hemisfério Sul.	93
3.3 – Tabela ilustrativa do procedimento para obtenção da distância máxima ($dist_{MAX}$) entre os parâmetros utilizados na classificação. A primeira linha e a primeira coluna são resultados da média de 800 vetores utilizados no treinamento das redes.	109
3.4 – Análises, algoritmos, arquiteturas e parâmetros estatísticos utilizados.	113
3.5 – Matriz de confusão genérica.	115
4.1 - Média e diferença dos alvos claros e escuros entre a imagem referência e as imagens objeto (retificadas).	123
4.2 - Avaliação estatística do índice kappa resultante da classificação com a rede RPE temporal utilizando dados de média e desvio padrão do NDVI e das bandas 3, 4 e 5 (classificação 1), média e desvio padrão excetuando-se o desvio do padrão do NDVI (classificação 2) a rede treinada só com arquivos de média (classificação 3).	146
4.3 - Avaliação estatística do índice kappa resultante da classificação com a rede de RPE temporal em relação às classificações de retropropagação com única data.....	147
4.4 - Avaliação estatística do índice kappa resultante da classificação com a rede FBR temporal em relação às classificações FBR com única data.....	149
4.5 – Avaliação estatística do índice kappa resultante da classificação MaxVer temporal em relação às classificações MaxVer com única data.	151
4.6 - Avaliação estatística do índice kappa resultante das classificações temporais com a rede de retropropagação, FBR e MaxVer.	153
4.7 – Avaliação estatística do índice kappa resultante da classificação da rede RPE em duas situações: com dados completos e duas falhas simuladas.	154
4.8 - Avaliação estatística do índice kappa resultante da classificação da rede FBR em duas situações: com dados completos e duas falhas simuladas.	154

4.9 – Matriz de confusão resultante do classificador MaxVer para a quarta data.	157
4.10– Análise estatística do kappa condicional da classe milho, comparando-se as classificações com a rede treinada com o algoritmo RPE com única data, com a classificação temporal.	159
4.11 – Análise estatística do kappa condicional da classe milho, comparando-se as classificações com a rede FBR com única data com a classificação temporal.	160
4.12 – Análise estatística do kappa condicional para a classe milho, comparando-se as classificações do MaxVer com única data e com a classificação temporal.	161
4.13 – Análise estatística do kappa condicional para a classe sorgo, comparando-se as classificações com a rede RPE com única data e na classificação temporal.	162
4.14 – Análise estatística do kappa condicional para a classe sorgo, comparando-se as classificações com a rede FBR com única data com a classificação temporal.	163
4.15 – Análise estatística do kappa condicional para a classe sorgo, comparando-se as classificações com o MaxVer com única data e na classificação temporal.	164
4.16 – Análise estatística do kappa condicional para a classe cana colhida no ano, comparando-se as classificações com a rede RPE com única data com a classificação temporal.	166
4.17 – Análise estatística do kappa condicional para a classe cana colhida no ano, comparando-se as classificações com a rede FBR com única data com a classificação temporal.	167
4.18 – Análise estatística do kappa condicional, para a classe cana colhida no ano, comparando-se as classificações com o MaxVer com única data com a classificação temporal.	168
4.19 – Análise estatística do kappa condicional para a classe cana de ano e meio, comparando-se as classificações com a rede RPE com única data com a classificação temporal.	169
4.20 – Matriz de confusão resultante da classificação temporal com o classificador de RPE.	169
4.21 - Análise estatística do kappa condicional para a classe cana ano e meio, comparando-se as classificações com o FBR com única data com classificação temporal.	170
4.22 – Análise estatística do kappa condicional para a classe cana de ano e meio, comparando-se as classificações com o MaxVer com única data com a classificação temporal.	171

4.23 – Análise estatística do kappa condicional para a classe feijão1, comparando-se as classificações com a rede RPE com única data e na classificação temporal.	172
4.24 – Análise estatística do kappa condicional para a classe feijão1, comparando-se as classificações a rede FBR com única data com classificação temporal.	173
4.25 – Análise estatística do kappa condicional para a classe feijão1, comparando-se as classificações com o MaxVer com única data com a classificação temporal.	174
4.26 – Análise estatística do kappa condicional para a classe feijão2, comparando-se as classificações com a rede RPE com única data com classificação temporal.	175
4.27 – Análise estatística do kappa condicional, para a classe feijão2, comparando as classificações com a rede FBR com única data com a classificação temporal.	176
4.28 – Análise estatística do kappa condicional para a classe feijão2, comparando as classificações com o MaxVer com única data com a classificação temporal.....	177

LISTAS DE SÍMBOLOS

5S - Simulation of the Satellite Signal in the Solar Spectrum

6S - Second Simulation of the Satellite Signal in the Solar Spectrum

ϵ - Tempo (em dias) decorrido entre o vigor e a senescência na análise temporal do GVI

LISTA DE SIGLAS E ABREVIATURAS

ASCII – American Standard Code for Information Interchange

AVHRR – Advanced Very High Resolution Radiometer

DOS - Dark Object Subtraction

EDR – Escritório de Desenvolvimento Rural

EMQ – Erro Médio Quadrático

ENVI - The Environment for Visualizing Images

ETM+ - Enhanced Thematic Mapper Plus

FBR – Função de Base Radial

Gm – Máximo valor do índice Greenness

GVI - Greenness Vegetation Index

HRV/SPOT – High Resolution Visible / Systeme Pour l’Observation de la Terre

IAF – Índice de Área Foliar

MLP – Multi Layer Perceptron

MSS – Multi-Spectral Scanner

NDVI – Índice de Vegetação Diferença Normalizada

RNA – Rede Neural Artificial

RPE – Retropropagação do Erro

RS – Índice de Vegetação Razão Simples

SAIL - Scattering by Arbitrarily Inclined Leaves

SAR/ERS-1 – Synthetic Aperture Radar / European Remote Sensing Satellite

SNNS - Stuttgart Neural Network Simulator

SPRING – Sistema de Processamento de Informações Georeferenciadas

TM – Thematic Mapper

tp – Tempo (em dias) decorrido até o máximo valor do GVI

CAPÍTULO 1

INTRODUÇÃO

Entre as atividades econômicas nacionais, a agricultura tem um tradicional e expressivo papel. No ano de 2003 a agricultura foi responsável por 42% dos US\$ 73 bilhões das exportações brasileiras. A produção agrícola nacional é diversificada em produtos para alimentação, vestuário e combustível renovável em grande escala. Na safra 2002/2003 a produção de grãos alcançou 120 milhões de toneladas, em contraste com a produção de 96,7 milhões de toneladas na safra 2001/2002.

Apesar dos bons números, apenas três produtos: soja, milho e trigo representaram 94% desse aumento. Produtos como o arroz e o feijão, por não serem “commodities”, tiveram aumentos inexpressivos e terão que ser importados (Netto, 2003). Esse contraste mostra a necessidade de políticas de planejamento que incentivem a produção para evitar o desabastecimento e a oscilação de preços danosa ao consumidor e ao produtor.

O traçado de políticas de planejamento exige conhecimento do uso e ocupação do solo: quais culturas, área ocupada, onde estão e provável produtividade. Obter essas respostas de maneira segura e em tempo hábil é um desafio uma vez que a agricultura é uma atividade dinâmica e o país tem dimensões continentais. Desde 1972, dados sinópticos, multiespectrais e multitemporais fornecidos por sensores orbitais são uma realidade que visam atender essa necessidade de conhecimento. O benefício do sensoriamento remoto orbital já havia sido antecipado para a agricultura Norte Americana desde as especificações originais do sensor Multispectral Scanner (MSS) do primeiro Landsat (Steven e Jaggard, 1995) e só aumentou como o lançamento de novos sensores do programa. O pesquisador norte americano Ray D. Jackson (1984) lembra que a manchete do jornal Los Angeles Times de 4 de março de 1984 foi: “New Satellite Will Keep an Eye on Crops”. Apesar do uso multidisciplinar dos dados de sensores orbitais, esta manchete expressa o quanto era grande a expectativa dos dados do sensor TM/Landsat-5 em benefício do agronegócio.

O mapeamento da cobertura do solo por meio da classificação multiespectral é uma das principais aplicações do sensoriamento remoto. Em muitas das principais aplicações previstas para o Thematic Mapper (TM-4) (USGS, 1984) está a discriminação de alvos

bem distintos espectralmente, como água e vegetação, ou alvos com grande diferença de morfologia foliar, como coníferas e decíduas. No entanto, uma discriminação mais ambiciosa, além dos objetivos originalmente planejados, é almejada: trata-se das espécies agrícolas. Diferentes espécies exibem curvas espectrais similares, com a agravante que com a grande largura de bandas dos atuais sensores orbitais, pequenas diferenças que possam existir são reduzidas.

Outro problema existente é a diferença de estágio fenológico em que uma mesma espécie é encontrada nos diferentes talhões. Essa diferença causa uma complexa interação com diferentes IAFs (Índice de Área Foliar) e diferentes porcentagens de exposição do solo, resultando numa variabilidade indesejada para uma mesma classe. Entretanto, a variação temporal de uma espécie, associada à repetitividade de aquisição dos sensores orbitais, é uma possível solução para a caracterização e discriminação de uma espécie, quanto se faz a análise no decorrer do ciclo vegetativo (Badhwar, 1984).

No Brasil, as classificações têm sido realizadas em duas épocas distintas: na época de pré-plantio para a quantificação de áreas destinadas a culturas de verão (ADCVs) (Ippoliti-Ramilo et al., 2003), e na discriminação de diferentes culturas com a classificação de uma única data, preferencialmente com o dossel pleno. A análise temporal, ao longo do ciclo, não tem sido utilizada, possivelmente pela dificuldade de aplicação, uma vez que a safra de maior expressão econômica ocorre durante o verão, que é chuvoso, com reduzidas chances de obtenção de dados ópticos de sensores remotos de plataformas orbitais.

Em termos de tratamentos de dados, novas abordagens têm sido introduzidas na análise dos dados orbitais que levam em conta o conhecimento prévio de determinada área e a complexidade intrínseca dos dados de sensores orbitais. Entre essas abordagens os sistemas de tratamento baseados em sistemas especialistas, algoritmos genéticos e redes neurais artificiais (RNA) têm se apresentado bastante promissores (Myneni et al., 1995; Landgrebe, 1997). As redes neurais, por exemplo, têm sido utilizadas principalmente com a finalidade de classificação. São classificadores que, entre as muitas vantagens, são não-paramétricos, integram com facilidade dados multisensores, são tolerantes a

falha de dados, são treinadas com pequenas amostras e realizam análise textural com simples mudança da arquitetura de entrada na rede.

Outra vantagem das redes neurais é que, uma vez treinadas, permitem uma fácil generalização para outros anos agrícolas sem novas coletas de amostras de treinamentos. A tolerância à falha de dados é uma alternativa às datas com ausência de imagens, muito comuns na análise temporal de alvos agrícolas. Com o objetivo de melhorar a classificação de culturas agrícolas, e de se fazer uso da análise temporal e de novos classificadores, essa tese visa:

Aplicar um método alternativo de classificação de culturas agrícolas que leve em conta a multiespectralidade e a multitemporalidade descritas pela fenologia de cada cultura.

Analisar a utilidade de parâmetros estatísticos - média e desvio padrão - para classificação com as Redes Neurais Artificiais.

Fazer uma análise comparativa de desempenho entre uma rede neural com algoritmos de retropropagação de erro (RPE) e uma rede de função de base radial (FBR) gaussiana.

Fazer uma análise comparativa de desempenho entre as redes neurais e o classificador paramétrico Gaussiano de máxima verossimilhança.

Verificar a tolerância a dados falhos, com simulação de nuvens, que causam perda alternada de imagens.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

2.1 – Importância da Atividade Agrícola Para o Brasil

No ano de 2003 as exportações brasileiras do agronegócio somaram 30,6 bilhões de dólares, o que correspondeu a 42% das exportações nacionais. No Brasil, além da alimentação e vestuário, a agricultura tem sua importância na produção de energia alternativa aos combustíveis fósseis. Na safra 2002/03, o Brasil atingiu um recorde histórico ao produzir 120 milhões de toneladas de grãos, sendo 22 milhões a mais que na safra anterior. Porém, apenas 3 produtos responderam por 94% desse aumento, cujo destaque foi a soja. Arroz e feijão, que são alimentos essenciais à cesta básica do brasileiro, tiveram aumentos inexpressivos e terão que ser importados. No caso do arroz a insuficiência nacional é ainda mais grave devido à queda de produção que ocorre na Argentina e Uruguai desde 1998 (Netto, 2003).

Evitar esses problemas de desabastecimento, com conseqüente oscilação de preços, exige planejamento e uma política de incentivos. Para traçar essas políticas, é necessário o conhecimento do uso e cobertura do solo: quais culturas agrícolas são cultivadas, onde estão, qual a área ocupada e provável produtividade.

Conhecer, quantificar e monitorar a ocupação de uma certa cultura numa atividade dinâmica como a agricultura é um desafio para um país de dimensões continentais. O sensoriamento remoto, com suas características multiespectrais, multitemporais e sinópticas, atende a essa necessidade de conhecimento fornecendo informações que auxiliem nas tomadas de decisões. O benefício do sensoriamento remoto orbital à atividade agrícola já havia sido planejado desde as especificações do sensor Multi-Spectral Scanner (MSS) do programa Landsat (Steven e Jaggard, 1995). Com o lançamento de novos sensores do programa houve aumento do uso, fazendo da agricultura um dos alvos terrestres com maior demanda de dados (Jackson, 1984; Moran et al., 1997; Anderson et al., 1999).

2.2 - Extração de Informação a Partir de Dados de Sensores Orbitais

O desafio do sensoriamento remoto é a aquisição de informação da biosfera terrestre a partir de dados obtidos de sensores a bordo de satélites. Esses dados são a medição da radiação eletromagnética refletida e/ou emitida a centenas de quilômetros com características bidirecionais, influências atmosféricas e topográficas e impurezas dentro do pixel (Myneni et al., 1995).

Segundo Verstraete et al. (1996), apesar de serem dados complexos, várias informações são derivadas como, evolução temporal da distribuição espacial da biomassa, fluxos de água, fluxos de energia, estado de vigor e produtividade de culturas agrícolas. Em função dessa demanda por informações, avanços têm sido observados tanto no sensoriamento remoto óptico como no sensoriamento remoto por microondas. Quanto aos sensores de microondas ativos, van der Sanden et al. (2001) mostram o ganho de informação em muitas áreas de aplicação com as novas polarizações na banda C em plataformas *Synthetic Aperture Radar* (SAR) como o Envisat-1 e o RADARSAT-2. No sensoriamento remoto óptico, com exceção de pequenas mudanças, observa-se uma certa repetição das bandas em variados sensores/satélites desde 1982, como se pode observar na Tabela 2.1. Essas bandas têm sua posição e larguras bem planejadas, e são de uso tradicional pela comunidade científica. Novas posições no espectro são, obviamente, limitadas dentro janelas atmosféricas.

Nos últimos anos, observou-se o surgimento de sensores hiperespectrais, como o *Airborne Visible/InfraRed Imaging Spectrometer* (AVIRIS), que é um sensor aerotransportado de 224 bandas entre 400 e 2500 nm (Green et al., 1998). O sensor hiperespectral Hyperion é orbital, possui 220 bandas com resolução espacial de 30 m, mas com a faixa de imageamento de 7,7 km, o que reduz em muito a sua visão sinóptica (USGS, 2002). Apesar da vantagem de oferecerem dados em comprimentos de onda específicos, Mather (1999) lembra que tais sensores têm uma relação sinal/ruído inferior aos sensores de bandas mais largas.

TABELA 2.1 - Intervalos das bandas espectrais de alguns sensores orbitais em três regiões do espectro refletivo.

Sensor	Visível (μm)			IVP*(μm)	IVM*(μm)	
TM/Landsat-4	0,45-0,52	0,52-0,60	0,63-0,69	0,76-0,90	1,55-1,75	2,08-2,35
TM/Landsat-5	0,45-0,52	0,52-0,60	0,63-0,69	0,76-0,90	1,55-1,75	2,08-2,35
CCD/CBERS	0,45-0,52	0,52-0,59	0,63-0,69	0,77-0,89		
ETM+/Landsat-7	0,45-0,52	0,53-0,61	0,63-0,69	0,78-0,90	1,55-1,75	2,09-2,35
ASTER/EOS		0,52-0,60	0,63-0,69	0,76-0,86	1,60-1,70	2,145-2,185
					2,185-2,225	
					2,235-2,285	
					2,295-2,235	
					2,360-2,430	

* IVP – Infravermelho Próximo. IVM - Infravermelho Médio.

Alguns estudos comparativos entre os sensores hiperespectrais e multiespectrais mostram que os sensores hiperespectrais contêm informação redundante. Entre esses estudos, Jacquemoud et al. (1995) inverteram o modelo PROSPECT, que descreve propriedades ópticas da folha e o acoplaram e com o modelo *Scattering by Arbitrarily Inclined Leaves* (SAIL), que descreve as propriedades estruturais do dossel e as características da cena. Utilizando dados obtidos em dosséis de beterraba açucareira com o espectrorradiômetro de campo GER MK IV IRIS, que tem 975 bandas entre 350 e 2500 nm, simularam as 188 bandas do sensor AVIRIS e as seis bandas refletivas do sensor TM. Segundo os autores, utilizando espectros de ambos os sensores como dados de entrada, os resultados de inversão foram similares para a estimativa de parâmetros como Índice de Área Foliar (IAF), concentração de clorofilas “a” mais “b” [C_{ab}] e concentração de água [C_w].

Para Myneni et al. (1995), a hipótese central em sensoriamento remoto é que a radiação contém informação sobre as características do alvo em estudo, mas ressalta que o isolamento e a análise dessa informação exige cautela. Para os autores, a interpretação de alvos vegetados tem complexidades intrínsecas como a bidirecionalidade, a

interferência da atmosfera, a estrutura dos dosséis, o brilho do solo, a topografia, a não-linearidade de resposta dentro de um pixel heterogêneo, entre outras. Tanto Myneni et al. (1995) como Verstraete et al. (1996) não recomendam relações simples do tipo $y=a+bx$ na estimativa de parâmetros biofísicos ou bioquímicos de dosséis, uma vez que tais relações não ilustram a complexidade dos dados orbitais. Para os autores, no espectro óptico, as novidades de extração de informação estão nas inversões de modelos, os quais evitam a simplificação dos dados, na criação de sistemas especialistas a partir da base de conhecimento de determinada área (Verstraete et al., 1996), assim como na utilização de algoritmos genéticos e redes neurais (Myneni et al., 1995).

Para a obtenção de resultados confiáveis a partir de dados orbitais, a correção atmosférica é um primeiro passo, para que os resultados sejam quantitativamente próximos à realidade.

2.3 – Correção da Interferência da Atmosfera

A correção¹ da interferência da atmosfera nos dados de sensoriamento remoto é importante, embora nem sempre necessária. Song et al. (2001) afirmam que na classificação de uma imagem de uma única data a correção atmosférica² não é necessária, pois o deslocamento dos eixos (bandas), no espaço n-dimensional, não altera a posição relativa entre as classes (Figura 2.1) e, portanto, não altera a matriz de covariância.

¹ Ao contrário da correção geométrica, onde um valor numérico EMQ (Erro Médio Quadrático) mostra o quão bom foi o ajuste, na correção atmosférica é muito difícil saber o verdadeiro valor da reflectância dos alvos e, numericamente, o erro cometido. Assim, o termo mais adequado seria atenuação. Usa-se aqui o termo “correção” por ser de uso comum na literatura.

² Song et al (2001) não deixam explícito que essa não alteração da posição dos agrupamentos das classes ocorre para modelos lineares. Para modelos de transferência radiativa na atmosfera, onde a correção é não linear, a afirmação não é verdadeira (Antunes, 2004)

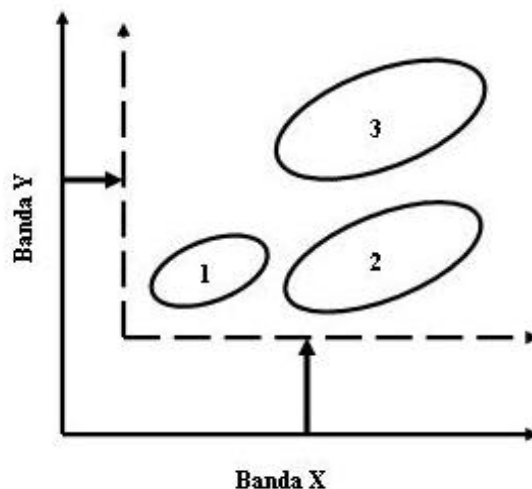


FIGURA 2.1 – A subtração de uma constante de cada banda não altera a posição relativa dos agrupamentos de cada classe, sem efeitos nos valores finais da matriz de covariância e sem alteração no resultado da classificação.

FONTE: Adaptada de Song et al. (2001, p.232).

Entretanto, existem situações em que a correção atmosférica faz-se necessária, como por exemplo, na generalização da classificação, definidas por Pax-Lenney et al. (2001), como o aumento da separação no tempo e/ou no espaço entre os dados de treinamento e os dados de teste. Uma das primeiras tentativas de generalização foi relatada por Myers (1983). Neste trabalho, o autor relata a experiência obtida no projeto *Crop Identification Technology Assessment for Remote Sensing* (CITARS) onde testou-se a possibilidade de classificar áreas de soja numa determinada cena, com classificador treinado em outra. O autor relata queda de 23% na área original estimada, cuja causa foi atribuída a diferenças nas condições atmosféricas. Num trabalho mais aprofundado, Pax-Lenney et al. (2001) utilizaram 17 imagens de 1984 a 1996 pertencentes a quatro órbitas/pontos diferentes, com o objetivo de classificar áreas com coníferas e não-coníferas. A primeira generalização, dentro da cena, foi temporal, pois treinou-se um classificador com a imagem de uma data e testou-se a classificação com a imagem de outra data; a segunda generalização, também foi temporal, mas com um intervalo de tempo menor, e envolveu cenas de órbitas/pontos diferentes para os dados de treinamento e classificação. Os autores testaram a possibilidade de uniformização das condições atmosféricas através de

vários métodos como o de subtração do pixel escuro, denominado Dark Object Subtraction (DOS) (Chavez Jr., 1988) e suas variantes, até métodos que utilizam modelos complexos de transferência radiativa, como o *Second Simulation of the Satellite Signal in the Solar Spectrum* (6S) (Vermote et al., 1997). A queda na exatidão de mapeamento das imagens uniformizadas com métodos simples, como o DOS não foi significativa.

Outras ocasiões em que as correções atmosféricas se fazem necessárias são nos estudos onde a resposta espectral do pixel é analisada continuamente no tempo; quando se traça o perfil temporal dos índices de vegetação, como o Razão Simples (RS) e *Greenness Vegetation Index* (GVI) (Lo et al., 1986), Índice de Vegetação Diferença Normalizada (NDVI) (Murakami et al., 2001) e estes são analisados ou quando se deseja obter a resposta espectral de feições naturais e artificiais a partir de dados orbitais (Hill e Sturm, 1991; Gilabert et al., 1994). Entretanto, existem estudos temporais em que a correção atmosférica não é executada, como o trabalho de Xin et al. (2002). Estes autores mapearam três estádios fenológicos do trigo de inverno e do milho de verão por meio do perfil de NDVI derivado das imagens do sensor *Advanced Very High Resolution Radiometer* (AVHRR). Deve-se ressaltar que, neste caso, os autores utilizaram a técnica de composição do máximo valor temporal, onde, para um dado pixel georreferenciado, o maior valor de NDVI num período de 10 ou 15 dias será de um pixel próximo ao nadir, com uma menor turbidez atmosférica e sem nuvens menores que um pixel (Holben, 1986).

De acordo com Gilabert et al. (1994), os métodos de correção atmosférica são divididos basicamente em dois grupos: aqueles que utilizam complexos modelos de transferência radiativa, como o 6S (Vermote et al., 1997), e modelos mais simples, que utilizam remoção do espalhamento e da turbidez atmosférica pela subtração do valor do pixel escuro (Chavez Jr., 1988). Uma limitação do primeiro método é bastante óbvia porque não depende apenas de dados da própria imagem digital, e necessita de dados coletados *in situ* simultâneos com a aquisição orbital, inviáveis principalmente em estudos retrospectivos (Gilabert et al., 1994; Lu et al., 2002). Murakami et al. (2001), por trabalharem em uma área agrícola perto de uma cidade, utilizaram o modelo de aerossol

urbano e tinham um centro meteorológico próximo que ofereceu a visibilidade (em km) para alimentar o modelo 6S. O valor desse parâmetro é de grande peso no resultado final, e, na ausência de medição, seu valor é arbitrado (Zullo Jr., 2002). O trabalho de Murakami et al. (2001) é um dos poucos a ilustrar a variação da visibilidade: no ano 1997, na posição geográfica 33°N e 130,5°E, a visibilidade era de 10 km no dia 17 janeiro, caiu para oito km no dia cinco de março, e subiu para 30 km no dia 26 abril.

Dos métodos baseados apenas na correção do espalhamento atmosférico, o método de subtração do pixel escuro (DOS) (Chavez Jr., 1988), ou também conhecido como método “Chavez”, é um dos mais utilizados. O método consiste em encontrar um conjunto de pixels sombreados ou em águas limpas e profundas que teriam resposta espectral zero ou próxima de zero em determinada banda; o seu valor representaria o valor do espalhamento, pois a absorção atmosférica é ignorada. A correção consiste da subtração, corrigida pelo ganho e *off set*, para toda a imagem. Supõe-se um espalhamento uniforme em toda a cena de acordo com o modelo atmosférico adotado³, o que raramente acontece (Chavez Jr., 1988). Uma descrição didática do método foi feita por Milton (1994), e na página eletrônica de Milton (2002) obtém-se a planilha eletrônica descrita no artigo.

Moran et al. (1992) compararam dados TM/Landsat-4 aerotransportados, tomados como referência, com dados TM/Landsat-4 orbitais corrigidos atmosféricamente com onze diferentes modelos. Os autores concluíram que os melhores resultados foram obtidos com os modelos de transferência radiativa, como o *Simulation of the Satellite Signal in the Solar Spectrum (5S)* (Tanré et al., 1990). Outra conclusão é que o modelo de correção proposto por Chavez Jr. (1988) é adequado para as bandas do visível (de 1 a 3), onde existe predominância de espalhamento; para a banda 4, onde existe espalhamento e absorção, o erro do método pode ser grande.

³ Chavez Jr. (1988) propõe cinco modelos de atmosfera: muito clara (λ^4), clara (λ^2), moderada (λ^1), turbida ($\lambda^{0.7}$) e muito turbida ($\lambda^{0.5}$), onde λ , é o comprimento de onda central da banda.

Com o objetivo de minimizar as limitações iniciais do modelo apontadas por Moran et al. (1992), Chavez Jr. (1996) propôs mudanças no modelo, onde a transmitância da trajetória Sol-alvo (T_z) (Fig 2.2) deixa de ser simplificada pelo valor um, e passa a ser estimada pelo cosseno do ângulo zenital do Sol. O novo modelo é nomeado em alguns artigos como “Chavez melhorado” ou simplesmente DOS2. Song et al. (2001) afirmam que se fossem desprezados os aerossóis e se fosse levado em consideração apenas o espalhamento de Rayleigh, a transmitância poderia ser mais bem descrita pela Equação 2.5 proposta por Kaufman (1989), onde a transmitância é descrita em função do comprimento de onda e não apenas do cosseno do ângulo zenital solar. Song et al. (2001) denominam este modelo de *Dark Object Subtraction* (DOS3).

Para ilustrar a evolução do modelo de subtração do pixel escuro (DOS), observam-se na Figura 2.2 as principais interações da radiação solar com a atmosfera e a superfície terrestre e as radiações que chegam ao sensor.




FIGURA 2.2- Interações da radiação eletromagnética com a atmosfera e a superfície terrestre. E_d é a irradiância difusa, E_0 é a irradiância solar direta, T_v é a transmitância na trajetória superfície terrestre-sensor, T_z é a transmitância na trajetória Sol-superfície terrestre. L_{haze} é a radiância difusa, L_{sat} é a radiância total que chega ao sensor.

A reflectância na superfície é descrita segundo Moran et al. (1992) pela Equação (2.1)

$$\rho_{\text{sup}} = \frac{\pi * d^2 * (L_{\text{sat}} - L_{\text{haze}})}{T_v * (E_0 \cos(\theta_z) * T_z + E_{\text{difusa}})} \quad (2.1)$$

onde: ρ_{sup} é a reflectância na superfície, π (sr) é a constante de conversão da radiância em irradiância, d é a distância Terra-Sol em unidades astronômicas, L_{sat} e L_{haze} são as radiâncias total e difusa, respectivamente ($\text{W.m}^{-2}.\text{sr}^{-1}.\mu\text{m}$), T_v é a transmitância na trajetória superfície-sensor, E_0 é a irradiância solar ($\text{W.m}^{-2}.\mu\text{m}$), θ_z é o ângulo zenital solar, T_z é a transmitância na trajetória Sol-superfície e E_{difusa} é a irradiância difusa ($\text{W.m}^{-2}.\mu\text{m}$).

O parâmetro L_{haze} , é dado pela seguinte expressão (Moran et al., 1992; Chavez Jr., 1996):

$L_{\text{haze}} = L_{\text{min}} - L_{0,01}$, onde L_{min} é a radiância do alvo escuro e $L_{0,01}$ é o valor 1% de reflectância do alvo escuro que deve ser considerado (Moran et al., 1992), ou seja:

$$L_{\text{min}} = L_{\text{MIN}} + \frac{(L_{\text{MAX}} - L_{\text{MIN}}) * \text{DN}_{\text{pixelescuro}}}{255} \quad (2.2)$$

onde: L_{MIN} e L_{MAX} são as radiâncias mínima e máxima necessárias à calibração do valor (NASA, 2002a), e $\text{DN}_{\text{pixelescuro}}$ é o valor, em número digital, do alvo escuro.

A radiância do alvo escuro é dada por:

$$L_{0,01} = 0,01 * E_0 \cos^2 \theta_z / \pi * d^2 \quad (2.3)$$

onde: E_0 é a irradiância difusa (W/m^2), θ_z é o ângulo zenital solar, π (sr) é a constante de conversão de irradiância em radiância ($\text{W.m}^{-2}.\text{sr}^{-1}.\mu\text{m}$) e d é a distância Terra-Sol em unidades astronômicas.

O parâmetro d , segundo Mather (1999) é dado por:

$$d = 1 - 0,01673 * \cos(0,9856 * (\text{DA} - 4)) \quad (2.4)$$

onde: DA é o dia do ano.

Esta mesma seqüência pode ser obtida na página de Skirvin (2002) para o modelo DOS2 implementado no aplicativo ERDAS. A evolução no modelo DOS ocorreu, basicamente, no cálculo da transmitância Sol-superfície (T_z), cujas mudanças estão ilustradas na Tabela 2.2.

TABELA 2.2 – Descrição dos valores adotados para os parâmetros: transmitância superfície-sensor (T_v), transmitância Sol-superfície (T_z) e irradiância difusa (E_{difusa}) na evolução do modelo de correção atmosférica subtração do pixel escuro (DOS).

Modelo	T_v	T_z	E_{difusa}
DOS1	1,0	1,0	0,0
DOS2	1,0	$\cos(\theta_z)$	0,0
DOS3	$e^{-\tau_r/\cos(\theta_v)}$	$e^{-\tau_r/\cos(\theta_z)}$	(6S)

O termo τ_r do modelo DOS3 é dado, segundo Kaufman (1989) pela Equação 2.5:

$$\tau_r = 0,008569\lambda^{-4} (1 + 0,0113\lambda^{-2} + 0,00013\lambda^{-4}) \quad (2.5)$$

onde: λ é o comprimento central da banda em questão, θ_z o ângulo zenital solar e θ_v é o ângulo zenital de visada.

Embora menos simplista que o modelo DOS1, no modelo DOS3, a Equação 2.5 não considera a latitude que afeta a espessura da atmosfera e, conseqüentemente, o espalhamento de Rayleigh.

Todas as correções anteriores, provenientes de modelos complexos ou não, visam uniformizar as imagens para as variações atmosféricas. Muitos métodos têm sido propostos com vistas à uniformização das imagens e garantir, o máximo possível, que as mudanças detectadas numa série temporal, sejam devidas à mudança do alvo em si, e não devidas a variações dos ângulos solares, degradação de detectores, ou variações atmosféricas. Murakami et al. (2001) e Pax-Lenney et al. (2001) aplicaram modelos de

correção atmosférica data a data, mas alguns autores propõem métodos onde, tomando-se uma data como referência, as cenas seguintes são ajustadas, em alguns parâmetros, à essa imagem referência.

2.4 – Retificação de Imagens

A uniformização de imagens pode ser encontrada na literatura segundo os termos normalização (Schott et al., 1988; Du et al., 2002), ou retificação (Hall et al., 1991) radiométrica de imagens. No presente trabalho, usa-se o termo retificação radiométrica por ser o termo adotado pelos autores (Hall et al., 1991) do método de uniformização utilizado. Estes autores alertam que, ao contrário da correção geométrica, onde os pontos de registro têm localização fixa nas imagens, os pontos para retificação, comumente denominados de pontos de controle radiométrico (Hall et al., 1991) ou pontos pseudoinvariantes (Schott et al., 1988), podem ter localização variada em diferentes cenas, como o solo exposto, por exemplo. Para facilitar a localização desses pontos (Hall et al., 1991) propõem a geração das componentes “brightness” e “greenness”. Estas duas componentes são resultantes da transformação espectral proposta por Kauth e Thomas (1976), onde a primeira componente maximiza a variação de brilho dos solos e a segunda, é uma componente perpendicular à primeira, que maximiza a variação de vigor vegetal. Um gráfico (Figura 2.3) com essas duas componentes tem, nas extremidades, a localização (valor) dos pixels claros e escuros não-vegetados e pouco variantes no tempo.

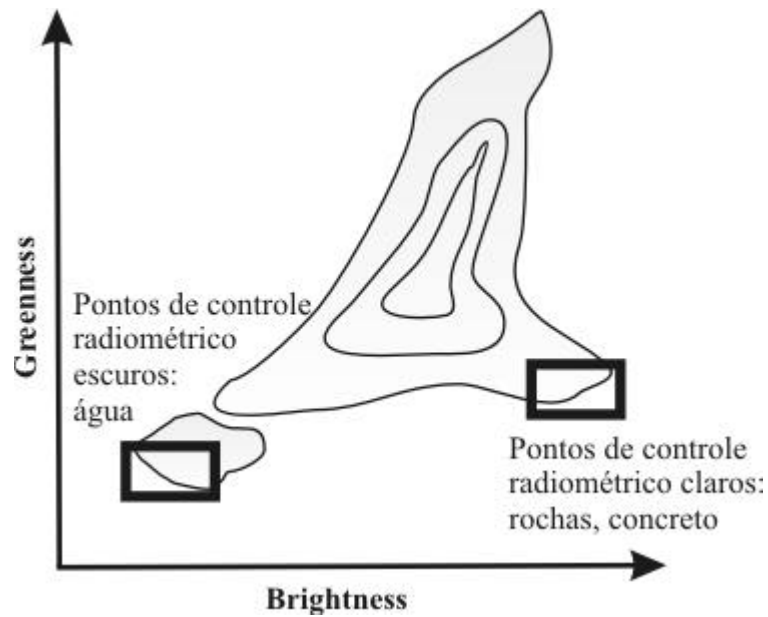


FIGURA 2.3 – Gráfico ilustrativo da dispersão “brightness” versus “greenness”. Os pontos claros e escuros dos pontos de controle radiométrico para a componente “brightness” situam-se em valores extremos, enquanto os valores de controle radiométrico claros da componente “greenness” são ligeiramente superiores aos escuros.

FONTE: Adaptada de Hall et al. (1991, p. 14).

A banda retificada $T(i)$ é calculada por uma transformação linear do tipo:

$$T(i) = m_i x_i + b_i \quad (2.6)$$

onde: x_i é a banda a ser retificada e m_i e b_i são calculados pelas equações:

$$m_i = (B_{Ri} - D_{Ri}) / (B_{Si} - D_{Si}) \quad (2.7)$$

$$b_i = (D_{Ri} B_{Si} - D_{Si} B_{Ri}) / (B_{Si} - D_{Si}) \quad (2.8)$$

onde D_{Si} , D_{Ri} , B_{Si} , B_{Ri} são as médias para as áreas pseudoinvariantes escuras (D) e claras (B) para as imagens a serem retificadas (S) e para as imagens de referência (R). Para verificar se a retificação foi bem sucedida, os autores sugerem que a diferença da média do número digital encontrado nas áreas de controle radiométrico na imagem retificada e na imagem de referência não seja maior que uma unidade.

A retificação radiométrica permite uma extração de informação temporal dos alvos de maneira confiável quando o pixel é analisado de maneira contínua. Entre os alvos terrestres, os alvos agrícolas, por seu dinamismo, raramente são bem caracterizados numa única data (Badhwar et al., 1982; Odenweller e Johnson, 1984; Lo et al., 1986; Jewell 1989; Hill e Sturm, 1991; Murakami et al., 2001, Murthy et al., 2003). Portanto, a execução da retificação radiométrica é um imperativo no estudo multitemporal desses alvos.

2.5 – Sensoriamento Remoto na Agricultura

Segundo Steven e Jaggard (1995), as aplicações do sensoriamento remoto em agricultura enquadram-se, amplamente, em três categorias: identificação de estresses (fitossanitário e nutricional) das culturas, monitoramento da produção, e classificação e mapeamento. Descrevem-se, nos parágrafos seguintes, algumas aplicações do sensoriamento remoto, discutindo-se, no estágio atual desse campo, a viabilidade e as limitações devido às resoluções dos sensores atualmente em órbita.

Antes de discutir as possibilidades potenciais dos sensores orbitais, ressaltam-se os três níveis de obtenção de informação discutidos por Lillesand e Kiefer (1994). Segundo os autores, quando se deseja apenas separar grosseiramente alvos terrestres trabalha-se em *detecção*; por exemplo, detecção de água ou vegetação. Num nível mais avançado é feito o *reconhecimento* dos alvos, como na separação de vegetação em floresta e área agrícola. Num último nível pode-se chegar à *identificação* dos alvos, como a separação da floresta em Pinus e Eucaliptus, ou da área agrícola em milho e trigo. Por analogia, pode-se expressar os níveis de detalhamento de informação, para proteção de culturas, de acordo com a Figura (2.4)

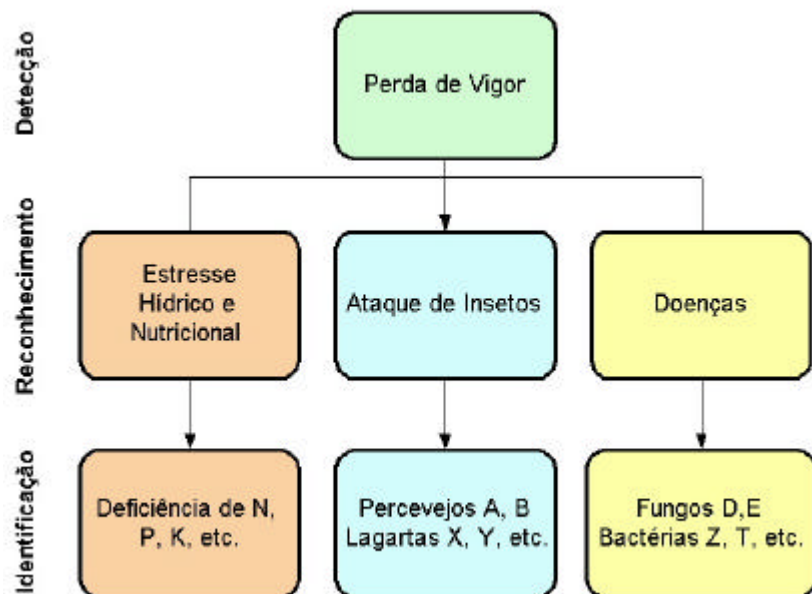


FIGURA 2.4 – Níveis de informação no monitoramento da lavoura.

A analogia das fases de detecção, reconhecimento e identificação para proteção de culturas pode ser descrita da seguinte forma: numa fase superficial, apenas se detecta a perda de vigor da cultura. Numa fase mais aprofundada pode-se reconhecer se a causa da perda de vigor é ataque de insetos, doenças ou estresse nutricional, e no último estágio identifica-se o elemento mineral crítico ou qual o agente causador da doença ou desfolhamento.

Entre os trabalhos visando os fins acima citados pode-se destacar o de Moran et al. (1989) que geraram, a partir de dados *in situ* (temperatura do ar, pressão de vapor) e bandas TM/Landsat-5, um mapa de evapotranspiração de culturas. A resolução espacial do sensor foi adequada, mas a informação instantânea obtida foi muito restrita para um fenômeno com necessidade de monitoramento diário. Outros trabalhos, como o de Rao et al. (1995), ilustram o potencial das bandas refletivas na identificação de solos salinos por aumento de albedo. No entanto, para solos com problemas salinos o monitoramento a nível de campo é insubstituível uma vez que “não se pode esperar que o solo mude a sua aparência...para começar a preocupar-se com a salinização” (Bernardo, 1989).

Na área de fitopatologia, MacDonald et al. (1972) relatam a experiência com o *Corn Blight Watch Experiment* (CBWE). Neste experimento, avaliaram-se a extensão e a severidade da helmintosporiose, doença do milho causada pelo fungo *Helminthosporium maydis*, que havia reduzido em 15% a produção no ano anterior. Neste experimento, utilizou-se a fotointerpretação de fotografias infravermelhas e imagens multiespectrais, e uma das várias dificuldades apontadas foi a subestimação do nível de infecção da doença. Isto ocorreu porque a infestação da planta ocorre de baixo para cima (Figura 2.5), começando nas folhas próximas ao solo. Trabalhos como o de MacDonald et al. (1972) mostram a dificuldade de identificação de doenças, pois mesmo a detecção de perda de vigor é difícil e tardia (Johannsen e Carter, 2002).




FIGURA 2.5 - Dinâmica da infestação da helmintosporiose em diferentes níveis de severidade.

FONTE: MacDonald et al. (1972, p.19).

Jackson (1984) enfoca a utilização do sensoriamento remoto como auxílio direto ao fazendeiro, para o monitoramento hídrico, nutricional e fitossanitário. Steven e Jaggard (1995) concordam com Jackson (1984) e afirmam que existe um grande interesse por parte dos fazendeiros nas possibilidades acima citadas. Entretanto, tais aplicações exigiriam uma obtenção de dados com alta frequência e resoluções da ordem de poucos metros, incompatíveis com os sensores orbitais atuais. A viabilidade das aplicações estaria em sensores aerotransportados e futuros sensores orbitais (Moran et al., 1997).

Os atuais sensores orbitais podem não fornecer os dados ideais para muitas aplicações, mas permitem uma boa visão sinóptica, numa resolução temporal entre 16 e 26 dias, e uma resolução entre 10 e 30 metros, razoável para aplicações agrícolas, sendo o mapeamento temático a principal aplicação. O mapeamento temático de culturas agrícolas multiplicado pela produtividade média de determinada cultura, permite estimar a produção agrícola. Desse modo, uma boa classificação temática é um importante passo na avaliação da produção agrícola.

O mapeamento permite saber quais são as culturas, onde estão e qual a área ocupada por cada uma, auxiliar na definição de políticas agrícolas e no estabelecimento de quotas de importação e/ou exportação, na antecipação de preços e planejamento do uso de recursos (Steven e Jaggard, 1995). Apesar de, aparentemente, ser um benefício de pouca valia para o produtor e de interesse imediato de governos e agronegociantes (Figura 2.6), a previsão de safras e uma política agrícola bem direcionada mantêm preços atrativos ao agricultor e evita o prejuízo e a falência dos mesmos. Como exemplo brasileiro, pode-se citar a cultura do café. Esta cultura passou por problemas fitossanitários, como o bicho mineiro (*Leucoptera coffeella*) e a ferrugem (*Hemileia vastatrix*) e climáticos, como as geadas, mas superou todos. Porém, quase sucumbiu à falta de política para o setor (Francis, 1989).

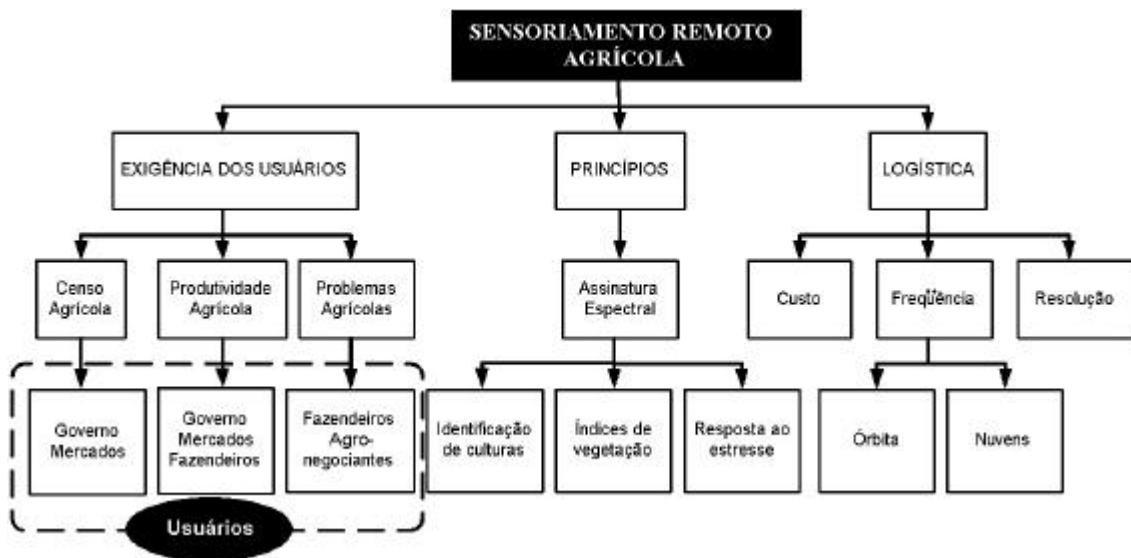


FIGURA 2.6 – Princípios, aplicações e limitações logísticas em sensoriamento remoto agrícola.

FONTE : Adaptada de Steven e Jaggard (1995, p.145).

2.6 - Classificação de Imagens Digitais

A classificação de imagens digitais consiste em rotular os pixels de uma cena em classes pré-definidas ou não. O processo de rotulação de cada pixel é feito levando em consideração a proximidade do padrão do pixel, descrito com as n bandas espectrais, com o padrão determinado para uma classe (Swain, 1978; Lillesand e Kiefer, 1994; Mather, 1999). Muitos algoritmos têm sido utilizados para classificação em imagens digitais provenientes de sensores remotos, entre eles o algoritmo de Distância Mínima e o algoritmo Gaussiano de Máxima Verossimilhança (Kavzoglu e Mather, 2003). Na última década, as redes neurais artificiais têm chamado a atenção como uma nova ferramenta de classificação de padrões em imagens de sensores remotos, com algumas vantagens sobre esses classificadores tradicionais como o treinamento com pequenas amostras, não serem paramétricas, e tolerantes a dados falhos (Bischof et al., 1992; Tso e Mather, 2001; Kavzoglu e Mather, 2003). Nos itens que se seguem, faz-se uma descrição do classificador Gaussiano de Máxima Verossimilhança e das Redes Neurais Artificiais.

2.6.1 – Classificador Gaussiano de Máxima Verossimilhança

Um dos algoritmos de classificação supervisionada pixel a pixel é o classificador de máxima verossimilhança. Neste algoritmo supõe-se que o comportamento das classes envolvidas pode ser descrito por funções de densidade de probabilidade Gaussianas. A regra consiste em associar o elemento à classe para a qual ele tenha maior probabilidade de pertencer. Costuma-se introduzir um limiar para a probabilidade de o pixel pertencer a uma classe, abaixo da qual o pixel não será incluso (Swain, 1978). Segundo Mather (1999), este método baseia-se na suposição que a distribuição de frequência de cada classe possa ser aproximada para uma distribuição de probabilidade normal (com um pico de frequência), o que parece ser altamente restritivo para aplicações. No entanto, segundo o mesmo autor, o método não é tão sensível a pequenos afastamentos dessa suposição.

De acordo com Swain (1978), a função de probabilidade normal n-dimensional é dada pela Equação 2.9.

$$p(\mathbf{X}/\omega_i) = \frac{1}{(2\pi)^{n/2} |\mathbf{S}_i|^{1/2}} \exp \left[-\frac{1}{2} (\mathbf{X} - \mathbf{U}_i)^T \mathbf{S}_i^{-1} (\mathbf{X} - \mathbf{U}_i) \right] \quad (2.9)$$

Essa equação expressa a probabilidade de determinado pixel, representado pelo vetor \mathbf{X} (2.10), de n bandas espectrais, pertencer a uma determinada classe ω_i . Essa classe tem o vetor de médias em n bandas dado por \mathbf{U}_i (2.11), e a matriz de covariância dada por \mathbf{S}_i (2.12):

$$\mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{bmatrix} \quad (2.10)$$

$$\mathbf{U}_i = \begin{bmatrix} \mu_{i1} \\ \mu_{i2} \\ \cdot \\ \cdot \\ \cdot \\ \mu_{in} \end{bmatrix} \quad (2.11)$$

$$\mathbf{S}_i = \begin{bmatrix} \sigma_{i11} & \sigma_{i12} & \dots & \sigma_{i1n} \\ \sigma_{i21} & \sigma_{i22} & \dots & \sigma_{i2n} \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ \sigma_{in1} & \sigma_{in2} & \dots & \sigma_{inn} \end{bmatrix} \quad (2.12)$$

O termo $|\mathbf{S}_i|$ é o determinante da matriz de covariância \mathbf{S}_i ; \mathbf{S}_i^{-1} é a matriz inversa de \mathbf{S}_i ; e $(\mathbf{X} - \mathbf{U}_i)^T$ é o vetor transposto do vetor $(\mathbf{X} - \mathbf{U}_i)$.

Na prática, o vetor de médias e a matriz de covariância para cada classe são desconhecidos e têm que ser estimados. Os cálculos de cada elemento do vetor $\hat{\mathbf{U}}_i$ e da matriz $\hat{\mathbf{S}}_i$, que são estimativas não tendenciosas de \mathbf{U}_i e \mathbf{S}_i , são dados pelos estimadores $\hat{\mu}_{ij}$ (2.13) e $\hat{\sigma}_{ijk}$ (2.14).

$$\hat{\mu}_{ij} = \frac{1}{q_i} \sum_{l=1}^{q_i} x_{jl} \quad (2.13)$$

onde $j = 1, 2, \dots, n$

$$\hat{\sigma}_{ijk} = \frac{1}{q_i - 1} \sum_{l=1}^{q_i} (x_{jl} - \hat{\mu}_{ij})(x_{kl} - \hat{\mu}_{ik}) \quad (2.14)$$

onde $j = 1, 2, \dots, n$; $k = 1, 2, \dots, n$ e q_i o número de amostras da classe i .

Muitos autores, antes de aplicarem o classificador Gaussiano de máxima verossimilhança, verificam qual o conjunto de bandas que proporciona a melhor discriminação das classes. Embora existam pequenas divergências quanto aos canais,

Townshend (1984) afirma que o melhor conjunto de bandas é composto por uma banda do visível (preferencialmente a banda do vermelho), uma banda do infravermelho próximo e uma banda do infravermelho médio. A Tabela 2.3 ilustra o melhor conjunto de bandas de alguns trabalhos de classificação com cenas agrícolas.

Quanto ao sucesso da classificação, Chen et al. (1986) reportam uma classificação de 99% de exatidão, no entanto, os autores descrevem particularidades na cena que devem ser analisadas: a homogeneidade fenológica do milho, que estava entrando na senescência; e homogeneidade da soja, que estava em fase de floração; a única cultura que apresentava variação fenológica era a cana-de-açúcar. Tennakoon et al. (1992) conseguiram uma exatidão de 90% na discriminação de solo exposto, citrus, grama e arroz inundado. Muitos dos sucessos de classificação são observados em legendas pouco ambiciosas, como no trabalho de Tennakoon et al. (1992), ou com as culturas com estádios fenológicos homogêneos intraclasse e bem distintos entre classes (Chen et al., 1986; Lobell e Asner, 2003).

Um exemplo de heterogeneidade intraclasse encontra-se em Medeiros et al. (1996). Esses autores classificaram a área de cana-de-açúcar, soja e milho de quatro municípios da EDR (Escritório de Desenvolvimento Rural) de Orlândia (SP), com uma imagem TM-5 de janeiro de 1995. Para melhor homogeneizar as classes, criaram 19 classes temáticas; desse total a cana teve três subclasses, a soja cinco subclasses, e o milho duas subclasses. Água, nuvens, mata, cidades completaram as outras classes. Essa variabilidade ilustra a variação fenológica dos polígonos, assim como, a mesma cultura em diferentes solos e/ou coberturas, como palha. Os autores ressaltaram a necessidade de classificar novamente os talhões quando as culturas estivessem num estágio mais desenvolvido.

TABELA 2.3 – Resultado das análises discriminantes de alguns trabalhos que fizeram classificação de cenas agrícolas.

Trabalho/sensor	Análise	Combinação de bandas para melhor discriminação	Culturas
Townshend (1984) Daedalus (simulador TM-4)	Divergência	3/4/5	Beterraba, pomares, gramados e ervilha
Chen et al. (1986) TM-5	Distância J-M ("Jeffries-Matusita")	2/4/5	Soja, milho, cana
Sharma et al. (1995) TM-5	IOF (Índice de Fator Ótimo)	1/4/5 e 3/4/5	Oleaginosas, pomares, arbustos, acácia e floresta
Dadhwal et al. (1996) TM-5	Teste t na diferença de exatidão de classificação	3/4/5	Trigo, mostarda, ervilha, grama, nabo branco

2.6.2 – Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) ganharam muita atenção na análise de dados de sensores remotos a partir da década de noventa e, segundo Kanellopoulos e Wilkinson (1997), o número de artigos com enfoque na utilização das mesmas tem crescido muito nas principais revistas. Uma rede neural artificial (RNA) é definida como um processador massivo e paralelamente distribuído, constituído de unidades de processamento simples, que tem a capacidade para armazenar conhecimento experimental e torná-lo disponível para uso (Haykin, 2001). Antes de descrever o funcionamento de transmissão e processamento de um sinal por uma RNA descreve-se de forma simplificada o funcionamento básico do cérebro humano.

O cérebro humano é organizado em camadas, sendo o córtex cerebral a camada mais complexa, na qual as células nervosas estão extremamente adensadas permitindo grande interconectividade (Haykin, 2001).

A unidade básica do cérebro é o neurônio (Figura 2.7), que é composto por dendritos, axônio, corpo celular e sinapse. Os dendritos formam uma rede receptora na forma de árvore que carrega os sinais elétricos para o corpo da célula. Estima-se que existam 10.000 conexões em cada célula. O corpo celular impõe um limiar para execução destes sinais. O axônio é uma fibra longa que leva o sinal processado de um neurônio para outro. Entre o axônio e os dendritos existe um ponto de contato chamado sinapse onde não existe contato físico, mas sim uma liberação temporária de neurotransmissores; esta liberação ocorre em função do impulso elétrico disparado. Os neurotransmissores fluem através de fendas quimicamente ativas dos dendritos (neurorreceptores). Com a existência de uma nova diferença de potencial, um novo impulso elétrico é transmitido para o corpo celular sucessivo, dando seqüência à propagação (Hagan et al., 1996).




FIGURA 2.7 - Esquema de um neurônio biológico.

FONTE: Hagan et al. (1996, p.1-8).

Um neurônio artificial tem um funcionamento análogo ao processo biológico descrito anteriormente, o qual é ilustrado na Figura 2.8. O neurônio K recebe os sinais x_1 , x_2 e x_3 dos neurônios A, B e C, respectivamente; esses sinais são ponderados pelos pesos w_1 , w_2 e w_3 de maneira excitatória ou inibitória. Ocorre ainda a entrada do bias (θ_k),

cuja função é aumentar ou diminuir a entrada líquida (2.15) na função de ativação, ou seja:

$$y_{\text{entrada}} = w_1 * x_1 + w_2 * x_2 + w_3 * x_3 + \theta_k \quad (2.15)$$




FIGURA 2.8 – Modelo de Neurônio.

Assim, as entradas no neurônio K são ponderadas pelos respectivos pesos e somadas juntamente com o bias. O resultado dessa soma é aplicado à função de ativação que determina o sinal de saída do neurônio. A Figura 2.9 ilustra duas funções de ativação não-lineares: a logística (2.16) e a tangente hiperbólica (2.17), ambas do tipo sigmoidal.

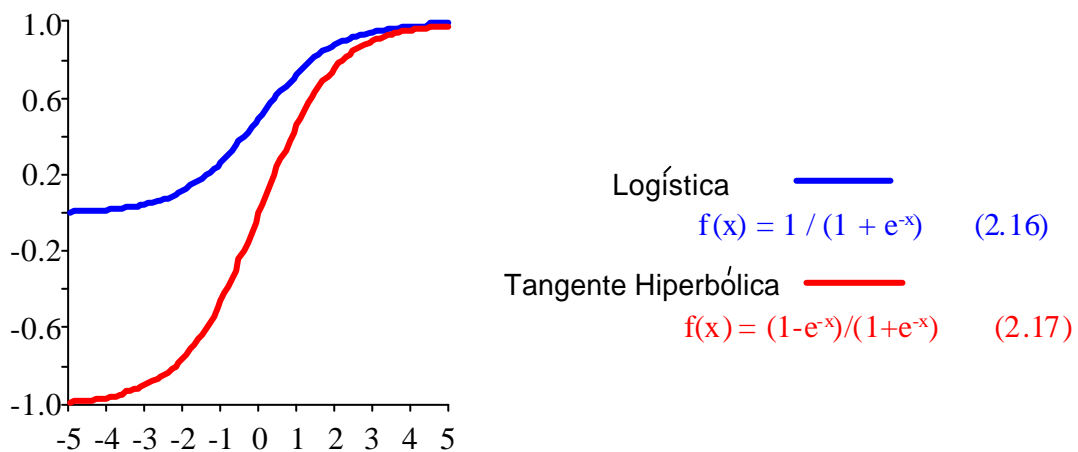


FIGURA 2.9 – Ilustração das funções logísticas e tangentes hiperbólicas.

Os neurônios são organizados e ligados em rede, de modo a constituírem camadas como formando as redes neurais. Existem diversos modelos de redes neurais (Haykin, 2001).

Nesta tese consideram-se as redes formadas por múltiplas camadas de neurônios do tipo perceptron.

Essas redes são constituídas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A alimentação dessas redes é progressiva, onde o sinal é propagado camada por camada. As redes de Perceptrons de Múltiplas Camadas (MLP) foram concebidas para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico (Lipmann, 1987; Haykin, 2001). Um exemplo de rede MLP é ilustrado na Figura 2.10. Nela existe uma camada de entrada com quatro neurônios, uma camada oculta com três neurônios e a camada de saída com cinco neurônios, o que resulta numa arquitetura 4-3-5 (Bishop, 1995).

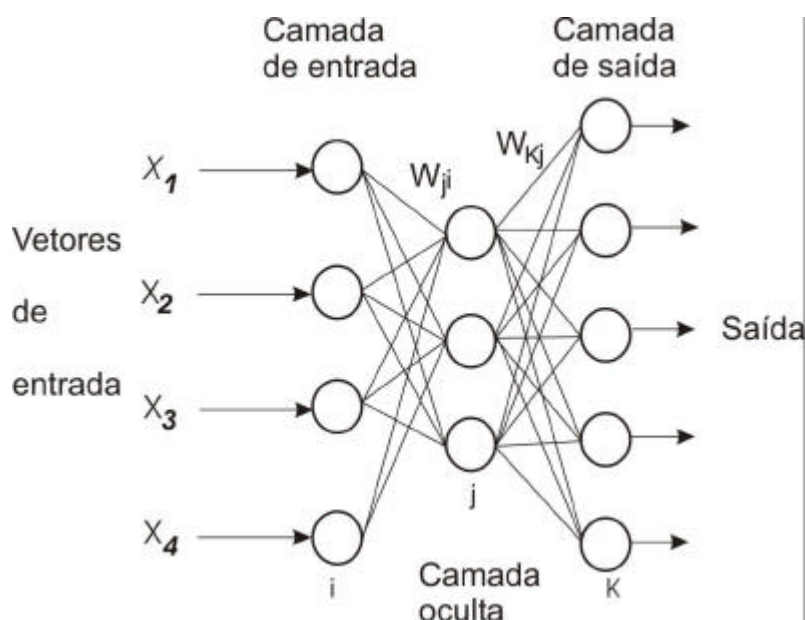


FIGURA 2.10 – Rede de múltiplas camadas com arquitetura 4-3-5.

FONTE: Adaptada de Bishop (1995, p.117).

Segundo Haykin (2001), as redes de múltiplas camadas têm sido usadas para os mais diversos fins, sendo principalmente treinadas com o algoritmo de retropropagação do erro (RPE). Em sensoriamento remoto, e particularmente como classificador de imagens digitais, essas redes têm sido usadas amplamente (Paola e Schowengerdt, 1995; Kanellopoulos e Wilkinson, 1997; Atkinson e Tatnall, 1997).

O algoritmo de retropropagação do erro (RPE) é descrito a seguir, segundo Haykin (2001). Na Figura 2.11, observa-se o termo $e_j(n)$ que se refere ao sinal de erro do neurônio j na n -ésima iteração, que é dado por:

$$e_j(n) = d_j(n) - y_j(n) \quad (2.18)$$

onde: d_j é a resposta desejada para o neurônio j ; e y_j é o sinal funcional que aparece na saída do neurônio j .

Admitindo-se que esta rede tenha C neurônios na camada de saída, o valor instantâneo da soma dos erros quadráticos é dado por $E(n)$:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.19)$$

À esquerda (Figura 1) do neurônio j , um conjunto de neurônios produz sinais funcionais que o alimentam. O campo local induzido v_j resultante na entrada da função de ativação no neurônio j , é dado por:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (2.20)$$

onde m é o número total de entradas (incluindo o bias) aplicadas ao neurônio j . O peso sináptico w_{j0} , (correspondendo à entrada fixa $y_0=+1$) é igual ao bias θ_j aplicado ao neurônio j . O sinal funcional $y_j(n)$ que aparece na saída do neurônio j na n -ésima iteração é dado por:

$$y_j(n) = \varphi_j(v_j(n)) \quad (2.21)$$

onde φ_j é a função de ativação, como por exemplo, a função logística:

$$\varphi_j(v_j(n)) = \frac{1}{1 + \exp(-av_j(n))} \quad \text{com } a > 0 \text{ e } -\infty < v_j(n) < +\infty$$

cuja derivada em relação a $v_j(n)$ é

$$\varphi'_j(v_j(n)) = \frac{a \exp(-av_j(n))}{[1 + \exp(-av_j(n))]^2}$$

O algoritmo de RPE aplica uma correção de $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$, que é proporcional à derivada parcial do erro em relação ao peso, ou seja:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.22)$$

A seguir, descreve-se cada uma das derivadas parciais:




FIGURA 2.11 – Gráfico de fluxo de sinal de um neurônio.

FONTE: Adaptada de Haykin (2001, p.189).

Da Equação 2.19 pode-se escrever:

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (2.23)$$

Da Equação 2.18 pode-se escrever:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (2.24)$$

E diferenciando a Equação 2.21, temos:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (2.25)$$

E o diferencial da Equação 2.20 em relação a $w_{ji}(n)$, resulta:

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (2.26)$$

Combinando-se as equações 2.23 a 2.26 na Equação 2.22, resulta:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n)\phi'_j(v_j(n))y_i(n) \quad (2.27)$$

E a correção $\Delta w_{ji}(n)$ aplicada a w_{ji} é definida pela regra delta:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (2.28)$$

onde η é o parâmetro conhecido como taxa de aprendizagem. Quanto menor for a variação da taxa de aprendizagem η , menores serão as variações de pesos sinápticos da rede e mais suave será a trajetória no espaço de pesos. Por outro lado, quando maior for η , maior será a variação dos pesos sinápticos resultantes e a rede pode ficar instável.

O sinal negativo na Equação 2.28 indica a descida do gradiente no espaço de pesos, ou seja, a busca de uma direção para mudar o peso que reduza o valor de $E(n)$.

Onde δ_j é o gradiente local, que indica as modificações necessárias aos pesos sinápticos, para o neurônio j , é igual ao produto do sinal de erro $e_j(n)$ pela derivada ($\phi'_j(v_j(n))$) da função de ativação associada, ou seja:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n)\phi'_j(v_j(n)) \quad (2.29)$$

A substituição da Equação 2.27 em 2.28 resulta:

$$\Delta w_{ji}(n) = \eta \delta_j(n)y_i(n) \quad (2.30)$$

Segundo Haykin (2001), um fator chave no cálculo do ajuste de peso Δw_{ji} é o sinal de erro $e_j(n)$ na saída do neurônio j . Nesse cálculo, dois casos têm que ser considerados:

No primeiro caso, o mais simples, o neurônio j é um neurônio de saída. O neurônio é suprido com a resposta desejada, ou seja, a resposta (valor) que o usuário definiu para o treinamento. Dessa maneira, calcula-se o sinal de erro e através da Equação 2.30, e calcula-se o gradiente local $\delta_j(n)$.

No segundo caso, o mais complexo, o neurônio j está localizado na camada oculta da rede sem resposta desejada específica, e o sinal de erro do neurônio oculto é determinado de forma recursiva, através da Equação 2.31:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (2.31)$$

onde k é o neurônio de saída e j o neurônio oculto.

A Figura 2.12 ilustra o resumo do algoritmo de RPE, segundo Haykin (2001). Após a inicialização dos pesos apresenta-se à rede os exemplos de treinamento e a saída desejada. Calcula-se a saída do campo local induzido, a saída do neurônio e o erro cometido. Caso não seja atingindo o erro desejado, calcula-se o gradiente local de acordo com um dos casos da Equação 2.22 ou 2.23. Executam-se iterações até atingir o erro desejado.

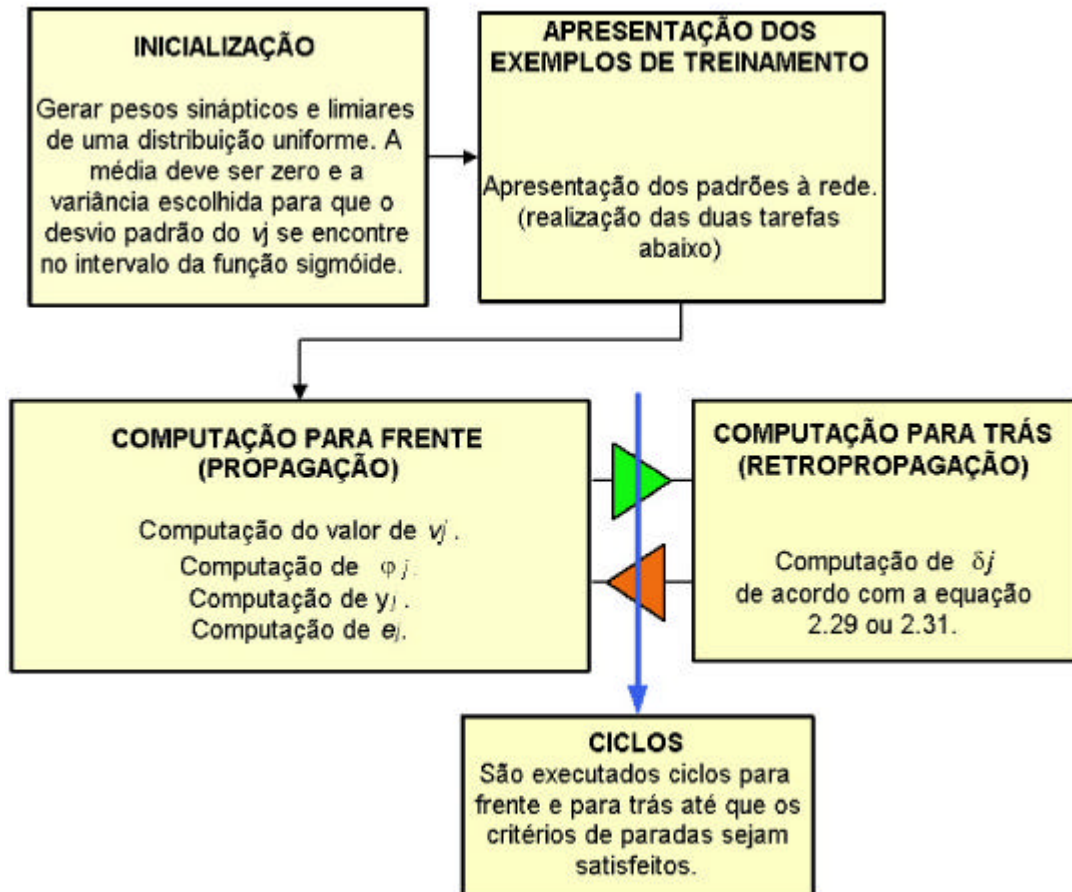


FIGURA 2.12 – Ilustração esquemática do algoritmo de RPE.

Segundo Haykin (2001), o algoritmo de RPE pode ser visto como a aplicação da técnica recursiva conhecida na estatística como aproximação estocástica. Segundo o autor,

aprender é encontrar uma superfície, em um espaço multidimensional, que forneça o melhor ajuste para os dados de treinamento, e *generalizar* é utilizar esta superfície para interpolar os dados de teste.

Este mesmo ponto de vista é a motivação das Funções de Base Radial (FBR), as quais possuem, no conjunto de neurônios da camada oculta, uma “base” arbitrária para os padrões de entrada, utilizando um espaço de alta dimensionalidade para existir uma maior probabilidade de que um padrão seja separável.

A arquitetura típica de uma rede FBR é ilustrada na Figura 2.13. Ao contrário das redes de perceptrons de múltiplas camadas (MLP) treinadas com o algoritmo de retropropagação do erro (RPE), que podem ter mais de uma camada oculta, a rede FBR tem apenas uma camada oculta com funções que podem ser multiquadráticas, multiquadráticas inversas ou gaussianas.

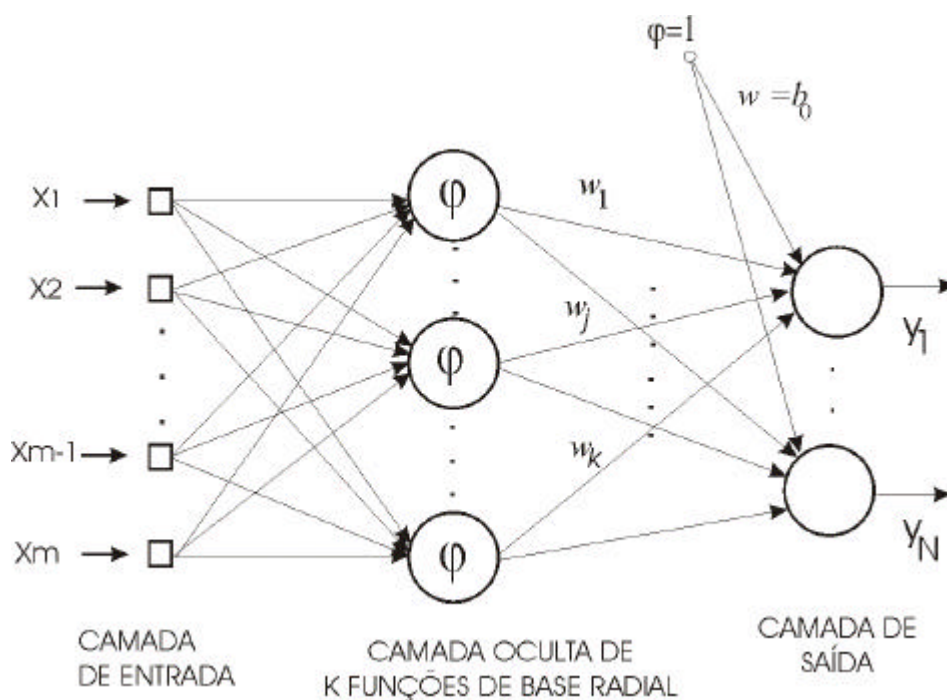


FIGURA 2.13- Arquitetura de uma rede neural de função de base radial.

FONTE: Adaptada de Haykin (2001, p.307).

Na Figura 2.13, sendo ϕ uma função de base radial, com o centro dado pelo vetor $\bar{\mu}_k$, e variância σ_k^2 , tomando o vetor de entrada \bar{x} na iteração n , a saída da função de base radial é dada pela Equação 2.32.

$$\phi_k = \exp\left(-\frac{\|\bar{x} - \bar{\mu}_k\|^2}{2\sigma_k^2}\right) \quad .32)$$

A saída $y_n(n)$ da rede FBR é descrita por:

$$y_k(n) = \sum_{j=1}^q w_{kj} \phi_k(x) + b_k \quad (2.33)$$

Segundo Bishop (1995), as redes FBR e RPE desempenham papéis muito semelhantes de mapeamento do espaço multidimensional, uma vez que ambas fazem aproximações arbitrárias e não lineares. No entanto existem diferenças:

- Todos os parâmetros de uma RPE são determinados ao mesmo tempo. Já uma FBR é treinada em dois estágios, primeiro com a função de base sendo determinada por técnicas não supervisionadas usando os dados de entrada somente, e, em segundo, ajustando-se os pesos da segunda camada com aprendizagem supervisionada.
- Enquanto uma rede MLP com algoritmo RPE divide o espaço de atributos em hiperplanos, a FBR divide o mesmo espaço em elipses (Figura 2.14) (Bishop, 1995).




FIGURA 2.14 – Exemplo de dados que se distribuem em três classes. Na primeira são separados por hiperplanos através de redes RPE e na segunda são separados e ajustados por funções representadas pela FBR.

FONTE: Adaptada de Bishop (1995, p.180).

As RNA receberam muita atenção da comunidade científica de sensoriamento remoto a partir da década de 90. Entre as vantagens do uso das RNA está a facilidade de processar e interpretar grandes quantidades de dados (Atkinson e Tatnall, 1997). Assim, os sensores da plataforma Terra⁴, como o *Moderate Resolution Imaging Spectroradiometer* (MODIS), o *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER), o *Clouds and the Earth's Radiant Energy System* (CERES), o *Multi-Angle Imaging SpectroRadiometer* (MISR), o *Measurements of Pollution in the Troposphere* (MOPITT), que produzem 850 Gigabytes/dia (NASA, 1999), têm, nas redes neurais, um grande potencial de processamento. Outra vantagem está na possibilidade de integração de dados multi-sensores (Benediktsson et al., 1990; Wilkinson et al., 1995). Wilkinson et al. (1995) utilizaram as 6 bandas refletivas do sensor (TM) de 30 metros de resolução e 8 bits, e dados SAR/ERS-1 de 12,5 metros e 16 bits. Após a padronização dos dados para 25 metros e 8 bits, os autores alimentaram uma rede de arquitetura 7-17-8 no mapeamento de classes florestais. Neste trabalho, nem sempre a adição de dados microondas SAR/ERS-1 aos dados ópticos levou a uma melhor exatidão de mapeamento, porém os autores relatam a facilidade de integração (entrada) de dados ópticos e microondas.

Observa-se na literatura que muitos autores buscaram respostas nas aplicações de RNA em classificação de imagens visando ao máximo proveito destas. Ao contrário do classificador Gaussiano de máxima verossimilhança, onde o operador pouco decide sobre o resultado final (por exemplo: no limiar de probabilidade a ser classificado), o uso das RNA exige uma maior interação do operador. Dúvidas com relação ao pré-processamento dos dados, arquitetura de rede, número de neurônio da camada oculta, tamanho de amostras e interrupção do treinamento são as mais comumente encontradas na literatura (Paola e Schowengerdt, 1995; Kavzoglu e Mather, 2003).

Com relação ao pré-processamento, Bishop (1995) ressalta a necessidade de normalização dos dados para que a saída da rede expresse, no resultado final, a combinação dos dados de entrada. Por exemplo, numa RNA onde as entradas sejam a

⁴ Denominada anteriormente EOS “Earth Observing System” AM-1

temperatura e a pressão, dependendo das unidades utilizadas, as grandezas numéricas podem ter ordens de grandeza de diferença. Assim, o campo local induzido v_j , não expressaria as duas entradas. O autor propõe que o conjunto de dados de uma grandeza G , com variáveis x_G , média μ_G e desvio padrão σ_G , seja reescalado de tal maneira que cada novo valor \tilde{x}_G do conjunto seja dado por:

$$\tilde{x}_G = \frac{x_G - \mu_G}{\sigma_G} \quad (2.34)$$

onde:

$$\mu_G = \frac{1}{N} \sum_{G=1}^N x_G \quad (2.35)$$

$$s_G = \left[\frac{1}{N-1} \sum_{G=1}^N (x_G - \mu_G)^2 \right]^{1/2} \quad (2.36)$$

onde N é o número de elementos no conjunto G .

O conjunto de dados resultante terá média zero e desvio padrão unitário.

Porém, para dados com baixos valores de desvio e média elevada, os dados transformados terão valores fora do intervalo zero e um [0 - 1]. Jarvis e Stuart (1996) descrevem que apenas dividiram os dados digitais (de 8 bits) por 255 como forma de reescalá-los entre 0 e 1. Miller et al. (1995) afirmam que este procedimento ainda pode deixar as bandas com diferentes pesos no resultado final de classificação. Segundo os autores, em algumas bandas, como no vermelho, o valor máximo encontrado está muito aquém de 255 e o reescalamento linear simples deve levar em consideração o valor máximo encontrado. A Figura 2.15 ilustra o reescalamento linear proposto por Jarvis e Stuart (1996) e Miller et al. (1995).

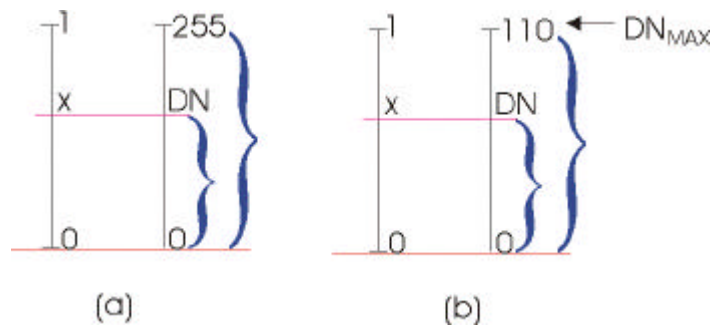


FIGURA 2.15 – Reescalonamento de uma banda hipotética com DN máximo 110 segundo Jarvis e Stuart (1996) (a), e segundo Miller et al. (1995) (b).

Miller et al. (1995), por utilizarem a função de ativação tangente hiperbólica (-1 a 1), descrevem a normalização (x'_i) em termos dos valores máximos (x_{MAX}), e mínimos (x_{MIN}) que determinada banda espectral apresenta.

$$x'_i = \text{Normalizado}(x_i) = \frac{2(x_i - (x_{MIN}))}{(x_{MAX}) - (x_{MIN})} - 1 \quad (2.37)$$

Além da normalização dos dados de entrada, outra incerteza muito comum nos trabalhos é a arquitetura da rede a ser utilizada. Paola e Schowengerdt (1997) utilizaram as 6 bandas refletivas do sensor TM para verificar, por tentativa e erro, o número ideal de neurônios da camada oculta para obter a melhor classificação. Utilizaram 1, 2, 3, 6, 9, 12, 15, 18, 24, 30 e 36 neurônios, e verificaram que, com qualquer número maior que 3, a rede produzia resultado satisfatório na classificação das sete classes. Bernard et al. (1997) usaram as 6 bandas refletivas do TM para classificar sete classes e observaram o efeito do incremento unitário do número de neurônios, na camada oculta, de um a 21. Concluíram que ao redor de 13 neurônios ocorreu a melhor exatidão de classificação, e de oito a 21 neurônios as exatidões não diferiram de forma significativa.

Foody e Arora (1997) classificaram seis classes agrícolas com dados do sensor ATM (“Airborne Thematic Mapper”) testando quatro arquiteturas de rede com 5, 10, 20 neurônios em uma camada oculta, além de uma rede com 20 neurônios divididos em duas camadas ocultas (10:10). Para os autores, redes grandes e complexas permitiram uma melhora na exatidão de classificação, mas esta melhora não foi estatisticamente significativa. Han et al. (2003) chegaram às mesmas conclusões utilizando as bandas 2,

3, e 4 do sensor TM. Estes autores mostraram que uma rede com duas camadas ocultas apresentou, em relação a uma rede com apenas uma camada oculta, uma melhor classificação num menor tempo de treinamento; e, ao utilizar uma rede com duas camadas ocultas, a primeira deve ter, no mínimo, o dobro de neurônios da camada de entrada.

Kavzoglu e Mather (2003) verificaram a influência da arquitetura das redes no resultado da classificação com dados ópticos e de microondas. Foram testadas redes com uma camada oculta e redes com duas camadas ocultas. Na rede com uma camada oculta, foi utilizado o incremento unitário de um a 25 neurônios, na rede com duas camadas ocultas foram utilizadas as seguintes arquiteturas: 5:5, 5:10, 10:10, 10:20, 16:14 e 24:21. Ao verificarem a exatidão global de classificação, observaram que esta aumenta bruscamente com o aumento de neurônios, até o terceiro neurônio; acima de oito a exatidão não passava de 90%. As redes com duas camadas ocultas também não forneceram exatidão maior que 90%.

Fletcher e Goss (1993) propuseram uma fórmula onde o número ótimo de neurônios na camada oculta estaria entre $2n + 1$ e $2\sqrt{n + m}$, onde n é o número neurônios de entrada e m o número de neurônios de saída.

A obtenção do tamanho ideal da rede é sempre uma preocupação, pois a redução do seu tamanho com a manutenção do bom desempenho é sempre desejável. Segundo Kavzoglu e Mather (1999), redes com mais neurônios ou camadas têm a vantagem de aprender padrões mais complexos uma vez que descrevem, no espaço n -dimensional, decisões-limites muito mais complexas (Lipmann, 1987), além de serem menos influenciadas pelos pesos iniciais aleatórios (Paola e Schowengerdt, 1997). Mas essas redes mais complexas necessitam de um tempo maior para serem treinadas e, em geral, generalizam mal com dados desconhecidos. Tal dificuldade de generalização é ruim devido à memorização excessiva de ruídos dos dados de treinamento (Haykin, 2001).

Com vistas a construir uma rede ótima e eliminar pesos sinápticos de maneira progressiva e ordenada, Kavzoglu e Mather (1999) testaram três algoritmos de poda,

que é o processo de determinar quais conexões ou neurônios são mais úteis em determinadas soluções e determinar a eliminação dos menos úteis: “Magnitude-based pruning”, “Optimum brain damage” e o “Optimum brain surgeon”. O último algoritmo “Optimum brain surgeon” foi o que melhor generalizou após reduzir o número de conexões de 210 para 80.

O tamanho da amostra também foi investigado por vários autores. Ao contrário dos métodos paramétricos, onde um tamanho de amostras equivalente a 30 vezes o número de variáveis discriminantes (bandas) é tido como adequado (Mather, 1999), o número ideal para classificação com RNA é ainda objeto de estudo. Em um dos primeiros trabalhos de aplicações de RNA em sensoriamento remoto, Hepner (1990), classificou uma imagem de 459x368 pixels em quatro classes. Fez um estudo comparativo e concluiu que a rede neural consegue um resultado semelhante com $\frac{1}{4}$ da amostra necessária ao classificador de máxima verossimilhança. Zhuang et al. (1994), com uma imagem TM/Landsat de 107x107 pixels, classificaram 6 classes (soja, milho, floresta, pasto, solo exposto e rio) com amostras correspondentes a 5, 10, 15 e 20% dos pixels da imagem. Aplicando o teste de Tukey, os autores verificaram que uma amostra contendo entre 5 e 10% dos pixels da imagem produz resultados satisfatórios sem diferença significativa com amostras maiores. Foody e Arora (1997) não informam o tamanho percentual das amostras em relação à imagem, mas utilizaram amostras de 10, 30, 50 e 100 pixels por classe, e observaram que o tamanho da amostra tem grande influência na exatidão final da classificação.

Além do tamanho mínimo de amostras por classe, deve-se ter cautela para que todas as classes sejam amostradas igualmente para que tendenciosidades sejam evitadas durante o treinamento (Foody e Arora, 1997), embora haja indicações de que isso seja necessário em algumas situações. Blamire (1996) trabalhou a influência do tamanho relativo das amostras numa imagem com duas classes dominantes: solo exposto e urbano. A classe urbana com subclasses industriais, residenciais além de rodovias, apresentava uma variância maior que a feição solo exposto. O autor testou vários tamanhos de amostras, visando a uma maior amostragem da classe com maior variância. As proporções utilizadas foram de 90:90, 90:60, 90:45 e 90:30 pixels de urbano:solo,

respectivamente. A proporção que forneceu o melhor resultado da exatidão global e de exatidão do usuário foi a 90:45.

Civco (1991) comentou sobre qual parâmetro estatístico deve ser utilizado na classificação. O vetor de médias não seria ideal para ser utilizado uma vez que este não exploraria a variabilidade de cada classe, embora o autor reconheça que uma amostragem variada pode introduzir essa variabilidade. Outros autores também tiveram dificuldades quanto à variância de uma determinada classe não introduzida durante o treinamento. Foody (1999), tendo dificuldades em classificar talhões agrícolas que são muito homogêneos pela natureza intrínseca⁵, testou amostras impuras que continham pixels fora dos talhões de determinada classe. Como resultado, o tempo de treinamento aumentou mas a generalização foi melhor.

Outro ponto explorado pelos autores é a estrutura de entrada de rede, a qual pode ser construída utilizando janelas $N \times N$ ao redor do pixel-alvo (Figura 2.16). Dessa maneira, uma informação adicional de textura é captada sem uma explícita definição da medida de textura (Bischof et al., 1992). Paola e Schowengerdt (1997) fizeram um estudo comparativo entre as entradas simples e janelas 3×3 . Observaram que com a janela 3×3 a classificação ficava mais homogênea, sem o efeito ruidoso, além de necessitar de 3 mil iterações para chegar a um mesmo EMQ (Erro Mínimo Quadrático) obtido com 50 mil iterações para a entrada simples. Bischof et al. (1992) relatam que a textura foi fundamental para separar as classes agrícolas das urbanas, as quais apresentavam confusão espectral. He e Collet (1999) também tiveram melhoras na classificação com a adição de textura. Ao testarem janelas 3×3 , 5×5 , 7×7 e 9×9 observaram que as janelas 5×5 e 7×7 foram as melhores na adição de informação textural, apesar de que esta conclusão fica restrita às características espaciais da imagem analisada.

⁵ Em geral, em um talhão agrícola utilizam-se mesma semente, mesmos tratamentos culturais e mesmas dosagens de qualquer agroquímico, o que o torna um polígono muito homogêneo.

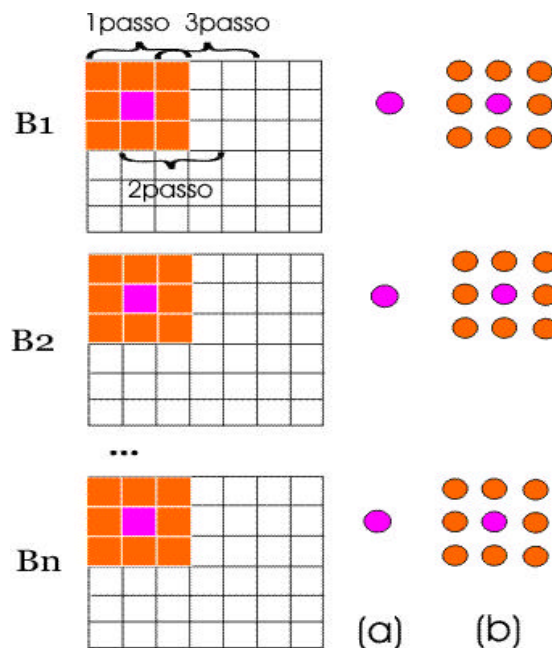


FIGURA 2.16 – Bandas espectrais (B₁ a B_n) e duas possíveis maneiras de entrada dos dados na RNA: (a) pixel a pixel e (b) através de janela 3x3 a qual adiciona informação textural além da espectral.

Além do pré-processamento, arquitetura, tamanho da mostra, proporções da amostra por classes, parâmetros estatísticos e estrutura de entrada, existem outros questionamentos feitos para um bom desempenho da rede para operar uma classificação. Por exemplo, o número de iterações ou épocas de treinamento. Recomenda-se cautela durante o processo de treinamento, pois uma rede sobre-treinada tem a capacidade de generalização reduzida. Para alcançar um treinamento ideal, utiliza-se o método de validação cruzada com parada antecipada, o qual é descrito por Haykin (2001). A Figura 2.17 ilustra a curva de aprendizagem, com o decréscimo do EMQ para os dados de treinamento e de validação. Os dados de validação são uma pequena amostra dos dados de teste, os quais a rede vai classificar *a posteriori*. Observa-se para a amostra de treinamento que inicialmente o EMQ cai rapidamente e depois mais vagarosamente, uma vez que as diferenças de ajustes de pesos ficam sutis. A curva de erros para os dados de validação, cai até um certo ponto e depois começa a crescer, mostrando o ponto ideal de parada de treinamento onde o erro para os dados de teste, representados pelos dados de validação, é mínimo. A partir desse ponto a rede começa a ficar específica para os dados com os quais ela foi treinada.




FIGURA 2.17 - Ilustração do ponto e parada antecipada baseado na validação cruzada.

FONTE : Adaptada de Haykin (2001, p.243).

Blamire (1996) descreveu o uso da validação cruzada na sua metodologia de treinamento e, ao invés de utilizar o EMQ como indicador de aprendizado da rede, utilizou uma amostra de validação em intervalos regulares, que evitou o sobre-treinamento. O número de iterações ficou entre 900 e 2500. Berberoglu et al. (2000) sugerem treinar a rede até um valor constante de EMQ (não citado) “esperançosamente aceitável”, que foi alcançado próximo de 1500 ciclos. Observa-se, na literatura, uma grande variação do número de ciclos de treinamento: Kavzoglu e Mather (1999) precisaram de 15 mil ciclos de treinamento para que a rede encontrasse o mínimo da função de erro. Foody (1999), que utilizou amostras nas bordas dos polígonos, aplicou 10 mil iterações; Paola e Schowengerdt (1997) reportam 25 mil iterações para alcançar um EMQ de 0,002 com uma rede de entrada 3x3, e 50 mil iterações para alcançar um erro de 0,008 com uma rede de entrada simples; Civco (1993) fez 250 mil ciclos de treinamento para chegar a um EMQ de 0,18. Em contraste, Kanellopoulos et al. (1992), para classificar 20 classes, não precisou mais do que 900 ciclos de treinamento. German e Gahegan (1996) utilizam, no máximo, 5 mil iterações pois, por experiência com variados problemas, os autores nunca observaram melhora nas classificações após mil ciclos de treinamento.

2.7 – Temporalidade na Análise de Alvos Agrícolas

Como mencionado no item 2.4 , uma única imagem orbital raramente permite uma correta classificação das culturas. Uma das causas é a variabilidade da resposta espectral (Hill e Sturm, 1991), que muda nas diferentes fases do ciclo. Outro fato é que os polígonos agrícolas não estão, necessariamente, na mesma fase fenológica ou num mesmo tipo de solo (Hall e Badhwar, 1987). Outro problema é a perda de particularidades espectrais em função das larguras das largas bandas atualmente utilizadas nos sensores (Steven e Jaggard, 1995).

Assim, culturas diferentes podem apresentar respostas espectrais similares; ou talhões diferentes cultivados com uma mesma cultura, por variações fenológicas ou de tipos de solos, podem ser espectralmente diferentes numa imagem. Para buscar soluções para este problema faz-se necessário analisar o trabalho de Landgrebe (1997). Segundo este autor, um importante passo na definição da análise de um problema é o modo de representar matematicamente e conceitualmente as variações. Existem três principais maneiras de representar e visualizar quantitativamente os dados de sensores multiespectrais: na forma de imagem, na forma de curva espectral e num espaço de atributos, como pode ser observado na Figura 2.18.




FIGURA 2.18 – Formas de representação de dados multiespectrais; λ é o comprimento de onda.

FONTE: Landgrebe (1997, p.15)

A forma de imagem é a maneira mais comum de representação, serve como uma interface homem/dados ajudando o usuário a fazer a conexão entre um pixel e a área que ele representa. O espaço espectral descreve a variação da reflectância de uma dada superfície em função do comprimento de onda, resultando na “assinatura” espectral, muito utilizado de maneira didático-ilustrativa. Por último, a forma de representar dados discretizados em determinados comprimentos de onda, no espaço N-dimensional, para análise através de algoritmos (Landgrebe, 1997). Devido ao dinamismo dos alvos agrícolas, a análise em qualquer um desses espaços, para uma única data, não fornece uma boa caracterização dos mesmos. A melhor descrição de uma cultura agrícola é através da análise temporal, a qual visa descrever a fenologia de uma cultura (Bauer, 1985; Hall e Badhwar, 1987). A fenologia refere-se ao desenvolvimento das plantas, ou seja, aos fenômenos periódicos das plantas, como a brotação, a floração e a frutificação, os quais estão correlacionados com as condições ambientais.

Um dos primeiros trabalhos a utilizar a temporalidade para classificação de culturas é descrito em Badhwar et al. (1982). A partir de imagens *Multi-Spectral Scanner* (MSS), esses autores calcularam os parâmetros α e β derivados do modelo descrito na Equação 2.30 para gerar um espaço de atributos diferenciado dos atributos espectrais (Badhwar et al., 1982; Bauer, 1985).

$$G(t) = G_0 + (G_m - G_0)(2\beta/\alpha)^{\alpha/2} (t - t_0)^\alpha \exp[-\beta(t - t_0)^2] \quad (2.30)$$

onde G_0 é o valor do índice “greenness” para o solo exposto, G_m é o valor do índice “greenness” no máximo vigor, $G(t)$ o valor do índice para a data t , α e β são parâmetros específicos para a cultura e a condição da mesma, t_0 é a data da emergência espectral.

Este modelo tem dois pontos de inflexão (t_1 e t_2) relacionados às taxas de mudança do “greenness” conforme pode ser observado na Figura 2.19. A diferença entre t_2 e t_1 é chamada ε :

$$\varepsilon^2 = (t_2 - t_1)^2 \quad (2.31)$$

Na evolução dessa linha de pesquisa, Badhwar (1984) afirma que os parâmetros G_m , ε e t_p , o qual é o tempo decorrido até o máximo valor de “greenness”, seriam os melhores parâmetros a serem utilizados para classificação em substituição aos dados espectrais originais; estes parâmetros resumem mais de 95% das informações dos dados originais. Em um trabalho de aplicação, Hall e Badhwar (1987) também utilizaram, com melhoria na classificação, os parâmetros G_m , t_p e ε para classificação das culturas de milho e soja na Argentina.




FIGURA 2.19 – Modelo de perfil temporal para o índice “greenness”.

FONTE: Adaptada de Bauer (1985, p.1077).

Para Ajai et al. (1985), outros parâmetros poderiam descrever as características temporais de uma cultura. Esses autores estudaram o comportamento temporal do índice de vegetação razão simples (RS^6) para as culturas do trigo, grão-de-bico e mostarda com um radiômetro operando nas faixas de 665-685 nm (vermelho) e 815-835 nm (infravermelho próximo). Os parâmetros propostos foram o período de ascensão,

⁶ $RS = IVP/V$, onde IVP – Infravermelho Próximo, V – Vermelho.

período de queda, valor máximo do índice, período até o pico, e duração do perfil (ciclo). A Figura 2.20 ilustra graficamente estes parâmetros propostos.

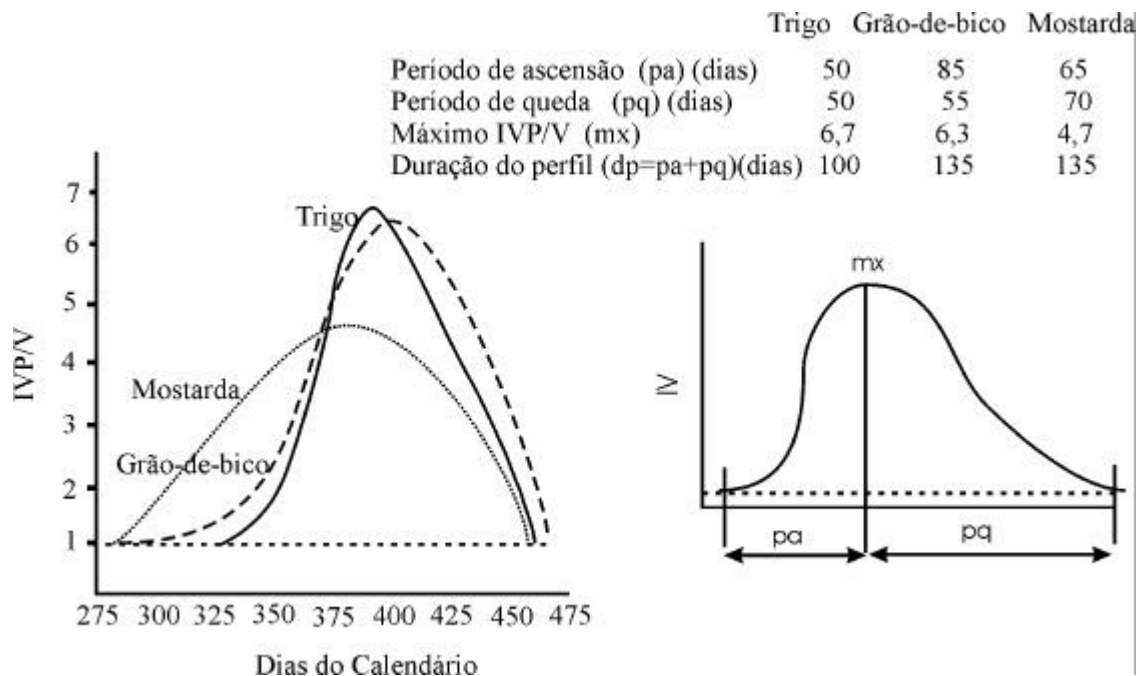


FIGURA 2.20 – Perfil temporal do índice RS para o trigo, milho e o grão-de-bico.

FONTE: Adaptada de Ajai et al. (1985, p.1578).

Pela análise desses parâmetros em espaços de atributos bidimensionais – período de ascensão versus valor máximo ou período de ascensão versus período de queda (Figura 2.21), observa-se a separabilidade que existe entre as culturas.

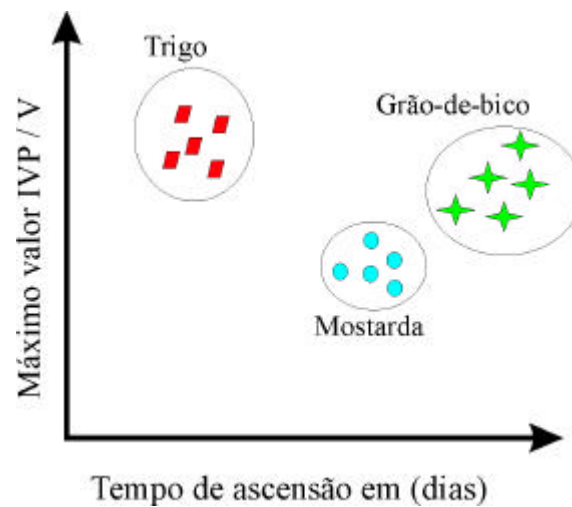


FIGURA 2.21 – Valor de pico do índice RS versus período de ascensão do valor.

FONTE: Adaptada de Ajai et al. (1985, p.1578).

Outros trabalhos relataram o uso da temporalidade em estudos agrícolas. Odenweller e Johnson (1984) analisam a potencialidade dos perfis temporais do “greenness” para identificação de culturas agrícolas. Num primeiro nível, os autores separaram culturas agrícolas de áreas não-vegetadas, num segundo nível separaram culturas anuais de inverno de culturas perenes e, num terceiro nível, fizeram identificação de milho, soja e girassol. Este estudo da possibilidade de identificação de culturas foi realizado com oito imagens MSS sem nenhuma correção atmosférica ou uniformização das imagens. Os autores somente relatam a potencialidade da análise do perfil temporal por intérpretes ou a utilização do equacionamento matemático proposto por Badhwar (1984).

Outros trabalhos também analisaram perfis temporais *via* algoritmos, sem a pretensão e equacionamento dos perfis (Figura 2.22) como o trabalho de Lo et al. (1986) com quatro cenas MSS, analisadas com o algoritmo de distância mínima; Murakami et al. (2001) com nove cenas HRV/SPOT e Jewell (1989) com quatro cenas do mesmo sensor, utilizaram o algoritmo de máxima verossimilhança; Tso e Mather (1999) com sete imagens SAR/ERS-1, utilizaram as redes de Kohonen. Quanto ao pré-processamento necessário à uniformização das imagens, Lo et al. (1986) não menciona nenhum método, Jewell (1989) apenas relata a calibração das imagens com a radiâncias

máximas e mínimas recomendadas para o sensor HRV e, somente Murakami et al. (2001), utilizaram o código 6S em todas as datas.




FIGURA 2.22 - Perfil temporal do índice RS para alfafa, milho e pastagem.

FONTE: Lo et al. (1986, p.539).

Todos esses trabalhos visam à identificação das culturas de acordo com a fenologia das diferentes espécies. Nas fases fenológicas ocorrem alterações reprodutivas, como emissão de flores e vagens, porém nas fases vegetativas, os incrementos de folhas, típicos a cada cultura, é o objeto principal de estudo.

Dos diversos elementos componentes do dossel, as folhas são as principais unidades de espalhamento de radiação. O IAF, definido como a razão entre a área total das folhas e a área total do terreno amostrada, é um parâmetro biofísico chave para retratar o desenvolvimento do dossel agrícola (Hall e Badhwar, 1987; Baret e Guyot, 1991; Xin et al., 2002). Entre os trabalhos citados anteriormente para avaliar a variação de IAF através de índices de vegetação, Jewell (1989) utilizou o índice razão simples (RS), Hall e Badhwar (1987) o índice *Greenness*, e Lo et al. (1986) fizeram um estudo comparativo entre os índices RS e o *Greenness* conseguindo exatidões de 83,9% e 85,4%, respectivamente. O “greenness” gerado por Lo et al. (1986) com dados MSS foi derivado de quatro bandas: verde, vermelho e duas bandas no infravermelho próximo e, segundo os autores, apesar de agregar mais bandas, o resultado da estimativa não foi relevante em relação ao índice RS, que agrega apenas vermelho e infravermelho próximo. A informação dos dosséis vegetais, concentrada nessas duas bandas, também é enfatizada por Tucker (1979) e Wiegand et al. (1991).

Entre os índices que utilizam a combinação de vermelho/visível⁷ e infravermelho próximo, o Índice de Vegetação Diferença Normalizada (NDVI) tem uma utilização bastante aceita e apresenta bons resultados ao descrever a fenologia da vegetação (Justice et al., 1985) ou a fenologia agrícola (Benedetti e Rossini, 1993; Xin et al., 2002). É um índice que pondera bem a informação do vermelho e infravermelho próximo e tem uma boa sensibilidade à vegetação esparsa (Myneni et al., 1997). Em relação ao índice RS, o NDVI é mais sensível a pequenas quantidades de vegetação e radiação na faixa do vermelho (Jackson e Pinter Jr. 1986) e menos sensível às variações da geometria de aquisição (Jackson et al., 1990). Uma desvantagem do NDVI é a baixa sensibilidade às maiores quantidades de vegetação (Jackson e Huete, 1991), pois o índice tende a saturar e não responder a variações de IAF maiores que três. Esse comportamento foi observado em dosséis de soja, trigo e feijão (Holben et al., 1980; Asrar et al., 1984; Gleriani, 1994).

Baret e Guyot (1991) executaram o modelo SAIL com sete diferentes solos, oito valores de IAF e nove distribuições angulares de folhas, num total de 504 simulações de dosséis. De acordo com os autores, os índices Índice de Vegetação Ajustado para o Solo (SAVI), TSAVI Índice de Vegetação Transformado e Ajustado para o Solo (TSAVI) e NDVI tendem à saturação para um IAF maior que 3. O único parâmetro biofísico que exibe uma relação linear com o NDVI é a fração de radiação fotossinteticamente absorvida (fAPAR) (Asrar et al., 1984; Baret e Guyot, 1991; Myneni et al., 1995).

Observa-se que a saturação assim como a influência quanto a diferentes tipos de solos ocorre também com outros índices (Qi et al., 1994). Apesar das limitações, o NDVI ainda é bastante utilizado, é de fácil interpretação, sendo de uso consagrado pela comunidade científica (Ray, 2000). É um bom indicador do vigor da vegetação, índice de área foliar (IAF) e, conseqüentemente, fenologia.

⁷ Para cálculo do NDVI com dados AVHRR/NOAA a fórmula é descrita por muitos autores (Justice et al., 1985) como: $(ch2-ch1)/(ch2+ch1)$ ou $(VIS-IVP)/(VIS+IVP)$. O canal 1 (0,58-0,68 μ m) do AVHRR contém a região do vermelho e parte do verde. O canal 2 (0,725-1,00 μ m) contém informação da região do IVP.

2.8 – Fenologia de Algumas Culturas Agrícolas

As fenologias das culturas agrícolas encontradas na área de estudo desse trabalho são descritas a seguir.

2.8.1 - Fenologia da Cultura do Sorgo

Segundo Vanderlip e Reeves (1972), o ciclo fenológico da cultura do sorgo (*Sorghum bicolor* L. Moench), para um cultivar de ciclo médio de 100 dias, pode ser descrito como a seguir, com a correspondente ilustração das fases (Figura 2.23).




FIGURA 2.23 – Estádios fenológicos da cultura do sorgo.

FONTE: Fageria (1989, p.349).

Estádio 0 - Emergência. Nesta fase ocorre a emergência do coleóptilo.

Estádio 1 – Visível o colar ou cartucho da terceira folha (aproximadamente 10 dias após a emergência).

Estádio 2 – Visível o colar da quinta folha (aproximadamente três semanas após a emergência).

Estádio 3 – Diferenciação do ponto de crescimento de vegetativo para reprodutivo. A planta tem de 7 a 10 folhas (30 dias após a emergência).

Estádio 4 – Rápido alongamento do colmo. Quase todas as folhas estão desenvolvidas.

Estádio 5 - Emborrachamento. A panícula alcança o seu comprimento máximo dentro da bainha da folha bandeira.

Estádio 6 – 50% de floração. Nesta fase, 50% das plantas estão floridas e isto ocorre aproximadamente 60 dias após a emergência.

Estádio 7 – Leiteiro. Aproximadamente 50% da matéria seca dos grãos já foi acumulada e o peso do colmo diminui.

Estádio 8 – Pastoso. Aproximadamente $\frac{3}{4}$ de matéria seca dos grãos já foi acumulada, 85 dias após a emergência.

Estádio 9 – Maturação Fisiológica. Nesta fase os grãos estão com 22 a 23% de matéria seca, e a cultura com aproximadamente 95 dias.

2.8.2 - Fenologia da Cultura do Milho

A fenologia da cultura do milho (*Zea mays* L.) é descrita em 10 estádios segundo (Shaw e Thom, 1951) citados por Fageria (1989), e está ilustrada na Figura 2.24.




FIGURA 2.24 – Estádios fenológicos da cultura do milho.

FONTE: Fageria (1989, p.349).

Estádio 0 - Emergência. Ocorre de 4 a 5 dias após o plantio.

Estádio 1 – Visível o colar da quarta folha. Em cultivares de ciclo em torno de 120 dias, ocorre próximo do 15º dia após a emergência.

Estádio 2 – Visível o colar da oitava folha. Ao redor de 30 dias após a emergência.

Estádio 3 – Visível o colar da décima segunda folha. Nesta fase, que se inicia ao redor de 40 dias, ocorre um aumento quase linear de massa seca.

Estádio 4 – Visível o colar da décima sexta folha. Último estágio antes do aparecimento do pendão masculino. Ocorre de 55 a 58 dias após a emergência.

Estádio 5 – Primeiras bonecas aparecem entre a décima-segunda e décima quarta folhas. Esta fase ocorre de aproximadamente 65 dias após a emergência.

Estádio 6 – Ocorre doze dias após 75% das plantas estarem embonecadas. Espigas estão com o tamanho próximo do máximo; início da formação dos grãos.

Estádio 7 – Doze dias após o estágio anterior. Nesta fase acontece nesta fase um rápido desenvolvimento dos grãos.

Estádio 8 – Doze dias após o estágio 7. Aproximadamente 25% das plantas possuem grãos com dente.

Estádio 9 – Doze dias após a fase 8. A taxa de acúmulo de matéria seca pela planta começa a diminuir. Todos os grãos estão dentados.

Estádio 10 – Doze dias após o estágio 9. Plantas com folhas senescentes e alta perda de umidade.

2.8.3 - Fenologia da Cultura de Feijão

A cultura de feijão (*Phaseolus vulgaris* L.), em função das diferentes gradações relativas ao porte, distribuição de flores e vagens, grau e tipo de ramificação pode ser agrupada em quatro diferentes tipos de crescimentos. Tipo I – determinado, tipo II – indeterminado e arbustivo, III – indeterminado e prostrado, e IV – indeterminado e trepador. As variedades comerciais se enquadram nos tipos de I a III. A fenologia da cultura é ilustrada na Figura 2.25 e cada uma das fases é descrita segundo o Centro Internacional de Agricultura Tropical (CIAT) citado por Fageria (1989):




FIGURA 2.25 – Ciclo fenológico do feijoeiro.

FONTE: Adaptada de Fageria (1989, p.385).

Germinação (V0) – Ocorre de 4 a 5 dias após a sementeira.

Emergência (V1) – Inicia-se quando os cotilédones aparecem em pelo menos 50% das plantas.

Folhas primárias (V2) – Começa quando as folhas primárias de 50% das plantas estão desenvolvidas.

Primeira folha trifoliada (V3) – Esta etapa começa quando 50% das plantas estão com a folha trifoliada aberta.

Terceira folha trifoliada (V4) – Inicia-se quando 50% das plantas estão com 50% das terceiras folhas trifoliadas abertas.

Pré-floração (R5) – É o primeiro estágio reprodutivo da cultura. Considera-se neste estágio quando 50% das plantas apresentam o primeiro botão floral.

Floração (R6) – Ocorre quando 50% das plantas apresentam a primeira flor.

Formação das vagens (R7) – Esta fase tem início quando 50% das plantas apresentam a primeira vagem.

Enchimento de vagens (R8) – A fase inicia-se quando 50% das plantas começam a ter enchimento de grãos. No final desta fase a cor dos grãos deixa de ser verde e adquire a cor característica da variedade, e inicia-se o desfolhamento das plantas.

Maturação (R9) – Ocorre quando metade da população apresenta a primeira vagem descolorida e seca.

O tempo médio de duração de cada estágio fenológico para plantas dos grupos de crescimento I, II, III e IV é descrito na Figura 2.26.

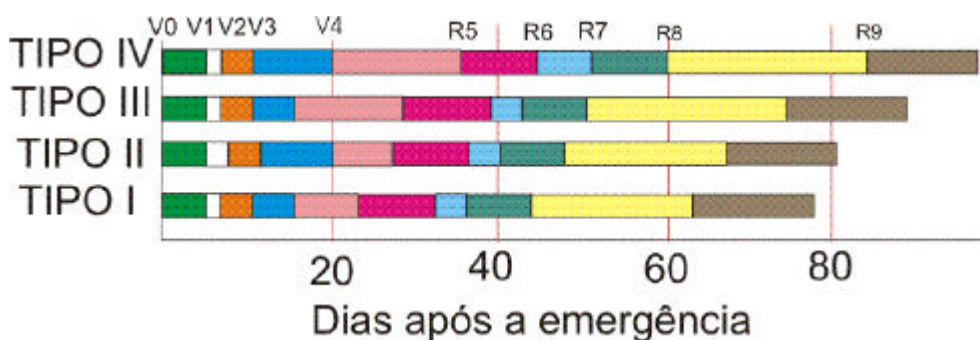


FIGURA 2.26 – Tempo médio de duração das etapas de desenvolvimento do feijoeiro pertencentes a quatro grupos de desenvolvimento.

FONTE: Adaptada de Dourado Neto e Fancelli (2000, p.30).

2.8.4 - Fenologia da cultura da cana-de-açúcar

Segundo Gascho e Chih (1983), citados por Câmara e Oliveira (1993), a cultura da cana-de-açúcar apresenta quatro estádios fenológicos diferentes:

Primeiro estágio – Brotação e emergência dos colmos.

Segundo estágio – Perfilhamento e estabelecimento da cultura, fase que vai da emergência dos brotos ao final do perfilhamento.

Terceiro estágio – Grande crescimento, fase que vai do perfilhamento final à concentração de sacarose.

Quarto estágio – Maturação. Fase caracterizada pela intensa concentração de sacarose nos colmos.

O período de desenvolvimento de cada um desses estágios é diferente para a cana-soca em relação à cana-planta. Conceitua-se cana-planta como aquela cana cuja origem está em mudas plantadas e que, posteriormente, sofrerão o primeiro corte. Após o primeiro corte, a cana brota e, nos ciclos sucessivos de corte/brotação, é denominada de cana-soca.

Há dois períodos de plantio de cana: o primeiro vai de setembro a outubro e a cultura apresenta um ciclo com duração média de 12 meses. Este ciclo é denominado de cana de ano.

Numa segunda época de plantio, a cana é plantada de janeiro a março e apresenta ciclo variável que vai de 14 a 21 meses, conforme a época de plantio e a época de maturação da variedade utilizada. Este ciclo é denominado de cana de ano e meio, uma vez que este tipo de cana passa por um repouso fisiológico (no inverno) no mesmo ano de plantio, sendo cortada no inverno do ano seguinte aproximadamente um ano e meio após o plantio (Figura 2.27).

A colheita da cana-de-açúcar inicia-se em abril/maio, e prolonga-se até novembro.

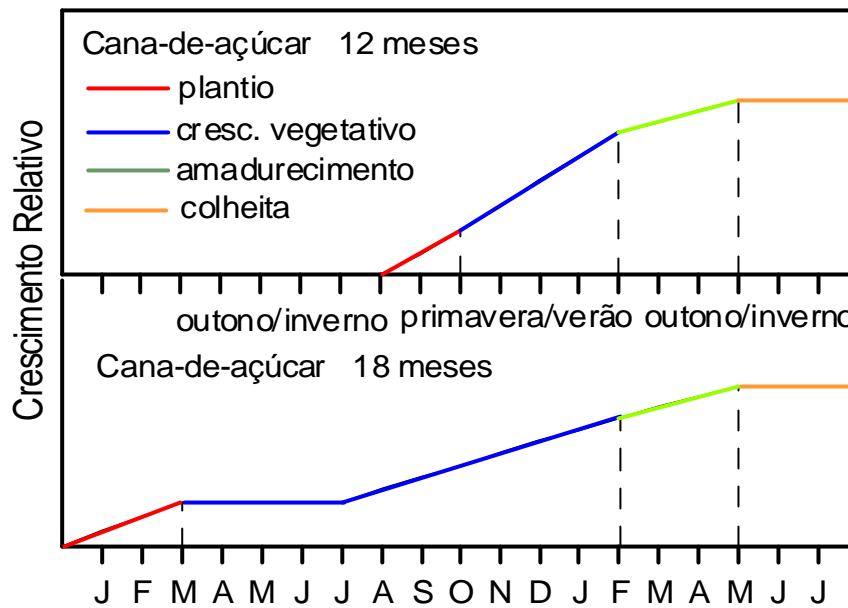


FIGURA 2.27 – Curvas de crescimento da cana de açúcar.

FONTE: Adaptada de Alfonsi et al. (1987, p.48).

Embora seja importante conhecer o ciclo fenológico de cada cultura, uma vez que incrementos de fitomassa foliar, típicos a cada cultura, ocorrerão temporalmente, deve-se também observar as práticas culturais como o espaçamento entre linhas de plantio (EF) e densidades de plantas por metro (NPM), uma vez que influenciam o parâmetro biofísico IAF, como mostrado na Equação 2.32:

$$IAF = \frac{NPM * AFMP}{EF} \quad (2.32)$$

onde NPM é o número de plantas por metro (m^{-1}), AFMP é a área foliar média por planta (m^2) e EF é o espaçamento médio entre as linhas de plantio (m).

CAPÍTULO 3

MATERIAIS E MÉTODOS

3.1 - Localização da Área de Estudo e Descrição do Uso do Solo

A área de estudo localiza-se no Norte do Estado de São Paulo, entre as coordenadas 47° 54' 8'' e 48° 16' 31,7'' de longitude oeste e 20° 5' 14,2'' e 20° 23' 16,8'' de latitude sul. A maior porção está dentro do município de Miguelópolis, como pode ser observado no retângulo pontilhado do destaque da Figura 3.1.

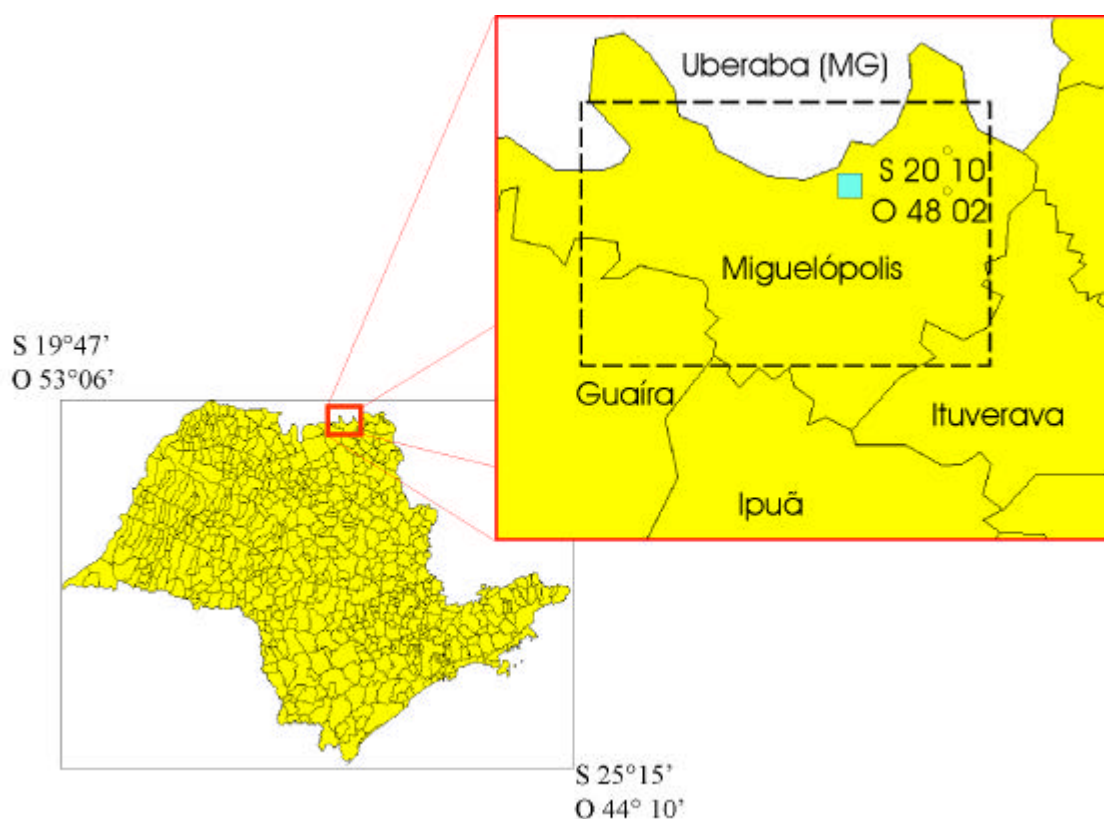


FIGURA 3.1 - Localização da área de estudo no Estado de São Paulo.

O município de Miguelópolis, pertence à EDR (Escritório de Desenvolvimento Rural) de Orlândia e está situado a uma altitude média de 548 m. A região é constituída predominantemente por Latossolos VERMELHOS (LV) e Latossolos AMARELOS (LA), com um relevo suavemente ondulado (Oliveira et al., 1999).

No ano de 2002, o município possuía 138 sistemas de irrigação do tipo pivô central, com mais três novos em implantação. Juntamente com o município de Guaíra, Miguelópolis compõe uma das maiores concentrações desses sistemas de irrigação no Estado de São Paulo. Nem todos os sistemas de irrigação estavam ativados, e vários estavam ocupados pela cultura da cana-de-açúcar.

As culturas predominantes na região são a da cana-de-açúcar durante o ano todo, e o cultivo de milho e soja durante o verão. Durante o inverno há cultivos nas áreas irrigadas, com predomínio do milho e do feijão, e, em menor extensão, sorgo. Ortiz (1993) fez um levantamento no município vizinho – Guaíra – e reportou que, além do sorgo, milho e feijão era freqüente na região o cultivo de trigo, tomate, ervilha e abobrinha. Atualmente, existe uma menor diversificação de culturas e uma expansão da cana-de-açúcar até mesmo sobre áreas irrigadas. A cultura da cana-de-açúcar tem tido fortes incentivos governamentais e a manutenção de bons preços mesmo com produção excedente (Spinelli, 2003).

3.2 - Escolha da Área

Na região sudeste do Brasil o inverno é seco e a probabilidade de obtenção de imagens livres de nuvens nesse período é muito maior do que no período de verão que é quente e chuvoso. A escolha da área deu-se, principalmente, por existir uma grande área irrigada na região. Outro ponto buscado foi uma variabilidade de datas de plantio que agregasse variações espectro-temporais importantes. Ao contrário do cultivo de verão, onde as chuvas marcam um início quase simultâneo do plantio e fazem com que os talhões com mesma cultura tenham estádios fenológicos próximos, a irrigação permite uma flexibilidade maior da data de plantio, o que causa maiores diferenças fenológicas entre os talhões (pivôs). Por outro lado, o plantio da cana de ano (setembro-outubro) ou cana de ano e meio (janeiro-março), cujos períodos de colheita estendem-se de maio a novembro, adicionam complexidade temporal de cultivo a cena. Assim, a região tem características ideais para teste da metodologia proposta, que envolve a aplicação de redes neurais artificiais para a classificação multitemporal de culturas agrícolas.

3.3 - Dados de Sensoriamento Remoto

Para a execução do trabalho foram utilizadas 10 imagens do ano de 2002 do sensor *Enhanced Thematic Mapper Plus* (ETM+) a bordo do satélite Landsat 7, da órbita/ponto (WRS) 220/74, com resolução de 30m. As imagens foram solicitadas com reamostragem pelo método do pixel do vizinho mais próximo, uma vez que este método preserva o valor digital original do pixel (Thomas et al., 1987). A imagem do dia 10 de março, por ter excelente qualidade visual foi utilizada como referência para a retificação. Das 10 imagens, 9 foram utilizadas efetivamente na classificação. A imagem adicional, do dia 01 de agosto, por conter nuvens, foi simulada a partir da média aritmética das imagens de 16 de julho e 17 de agosto após procedimento de retificação (Tabela 3.1). Este procedimento foi adotado para homogeneizar a extensão do perfil temporal, o qual será discutido no capítulo 4.

TABELA 3.1 – Imagens de satélite utilizadas neste trabalho.

Data da imagem	Sensor	Uso
10/03/2002	ETM+/Landsat7	Referência para retificação radiométrica
11/04/2002	ETM+/Landsat7	Classificação
27/04/2002	ETM+/Landsat7	Classificação
13/05/2002	ETM+/Landsat7	Classificação
29/05/2002	ETM+/Landsat7	Classificação
14/06/2002	ETM+/Landsat7	Classificação
30/06/2002	ETM+/Landsat7	Classificação
16/07/2002	ETM+/Landsat7	Classificação
01/08/2002	(simulada)	Classificação
17/08/2002	ETM+/Landsat7	Classificação
02/09/2002	ETM+/Landsat7	Classificação

As atividades desse trabalho foram executadas de acordo com o fluxograma de atividades ilustrado na Figura 3.2.

Após o registro das imagens, executou-se a correção atmosférica da imagem de 10 de março e, com essa imagem, todas as imagens foram retificadas radiometricamente. Com as imagens retificadas analisaram-se as amostras temporais com o objetivo de selecionar polígonos que traziam o ciclo completo de determinada cultura. Executaram-se as classificações com o algoritmo de máxima verossimilhança com única data onde era avaliado o padrão espectral e, posteriormente a classificação temporal, onde o padrão espectro-temporal foi levado em consideração.

As classificações com redes neurais foram executadas com arquivos ASCII. Estes arquivos continham a média e o desvio-padrão de uma janela 3x3 pixels. Após a seleção do melhor parâmetro estatístico, foram executadas as classificações com os algoritmos de RPE e FBR com única data e multitemporal. Do conjunto de imagens temporais suprimiram-se quatro datas de duas maneiras alternadas de modo a simular a perda de imagens por presença de nuvens.

A análise dos resultados foi feita através de procedimentos de estatística kappa e do kappa convencional, o qual permitiu avaliar isoladamente classe-a-classe se a temporalidade permite uma melhor classificação ou não.

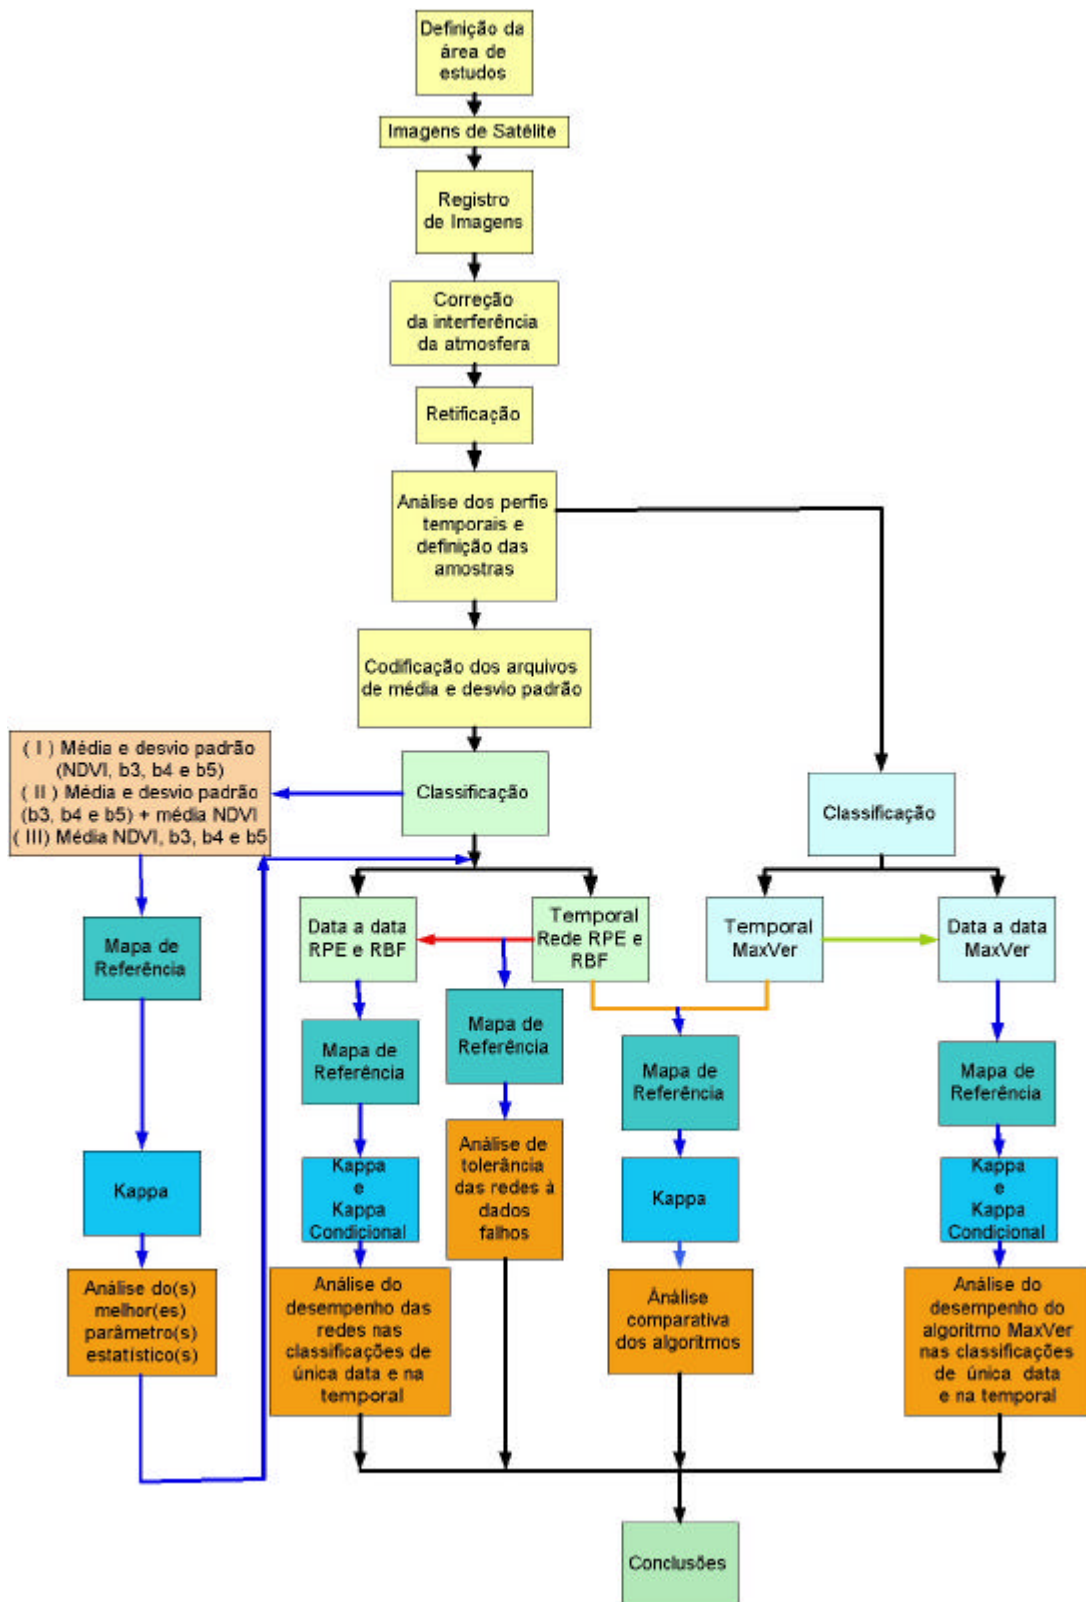


FIGURA 3.2 – Metodologia desenvolvida.

3.4 - Dados de Campo

Nas semanas de 22 a 27 de abril e 05 a 10 de agosto de 2002 foram realizados dois trabalhos de campo. A localização das áreas foi feita através de uma composição 3B4R5G impressas em papel A4 glossy na escala de 1:60.000. Uma transparência era fixada no canto esquerdo da composição colorida, o que permitia sobrepô-la e levantá-la a qualquer momento diante de dúvida de interpretação. Na transparência foram desenhados os talhões e anotados nomes e/ou números para os mesmos; o correspondente rótulo era anotado em uma ficha de campo com os dados da cultura presente no talhão: espécie, porcentagem de cobertura do solo (estimativa visual), altura (m), plantio direto ou convencional, espaçamento e densidade de plantas por metro.

3.5 - Entrada dos Dados

Todas as imagens foram registradas e inseridas num banco de dados no programa Sistema de Processamento de Informações Georreferenciadas (SPRING) versão 3.6.03 (Câmara et al., 1996), com o modelo UTM/SAD-69. Foram utilizados quatro pontos de controle diagonalmente opostos e cinco pontos de teste. Na reamostragem utilizou-se o método do vizinho mais próximo. Os pontos localizam-se em cruzamentos de estradas ou pontes sobre rios. Objetivou-se sempre um erro médio quadrático (EMQ) menor ou igual a 0,5 pixel, uma vez que o mesmo pixel seria analisado temporalmente. Durante os processos de correção atmosférica e retificação utilizou-se a cena toda; esse procedimento foi feito porque aumenta a probabilidade de localizar áreas sombreadas para obter o valor do pixel escuro, assim como encontrar áreas de controle radiométrico, uma vez que estas não têm localização fixa de cena para cena (Hall et al., 1991). Após estes procedimentos, foi criado um novo projeto no SPRING com as coordenadas limites descritas no item 3.1, com um total de 1087 linhas por 1281 colunas. Estas imagens foram utilizadas para classificação.

3.6 - Correção Atmosférica

Como descrito anteriormente, a imagem do dia 10 de março tem uma excelente qualidade visual e foi utilizada como referência para a retificação. Antes de iniciar a retificação, fez-se a correção atmosférica através do método DOS3, descrito por Song et

al. (2001). A mudança necessária foi considerar a irradiância difusa (E_{difusa}) como zero, uma vez que Song et al. (2001) propõem a estimação do valor desse parâmetro pelo modelo 6S. O modelo 6S não foi usado por razões já descritas (Secção 2.3).

O modelo DOS3 foi implementado em linguagem Linguagem Espacial para Geoprocessamento Algébrico (LEGAL) (Câmara et al., 1996), para as bandas 1, 2, 3 e 4 (Apêndice A). A leitura do pixel escuro para cada banda foi feita numa área sombreada sobre o rio Grande. Os parâmetros de irradiância solar (w.m^{-2}) e a radiância ($\text{w.m}^{-2}.\text{sr}^{-1}.\mu\text{m}^{-1}$) para cada canal foram obtidos na página eletrônica da NASA (2002a), e a recomendação de uso de alto e baixo ganho para radiância foi obtido no arquivo *American Standard Code for Information Interchange* (ASCII) disponível na página eletrônica da NASA (2002b), os quais são descritos na Tabela 3.2.

TABELA 3.2 - Recomendação de alto (H) e baixo (L) ganho para os canais do sensor ETM+ para a órbita ponto 220/74 para o hemisfério Sul.

				Canal								
Órbita	Ponto	Dia do ano	Dia/mês	1	2	3	4	5	6	6	7	8
220	74	1	01-Jan	H	H	H	L	H	L	H	H	L
220	74	113	22-Abr	H	H	H	H	H	L	H	H	L
220	74	236	23-Ago	H	H	H	L	H	L	H	H	L

FONTE: Adaptada de NASA (2002b)

Os valores da distância Terra-Sol (d) em unidades astronômicas (ua) foram calculados pela implementação da fórmula $d = 1 - 0,01673 * \cos(0,9856 * (DA - 4))$, onde DA é o dia do ano, em planilha eletrônica Excel.

As nove imagens restantes foram transformadas em reflectância aparente através da Equação 3.2:

$$\rho_{\text{ap}} = \frac{\pi * d^2 * L}{E_0 \cos(\theta_z)} \quad (3.2)$$

onde r_{ap} é a reflectância aparente, π (sr) é a constante de conversão da radiância em irradiância, E_0 é a irradiância solar, θ_z é ângulo zentral solar, e L é dado pela Equação 3.3:

$$L = \frac{L_{\max} - L_{\min}}{255} * DN + L_{\min} \quad (3.3)$$

onde DN é o número digital da imagem bruta, L_{\min} e L_{\max} os valores de radiância mínimos e máximos de cada canal obtidos na página eletrônica da NASA (NASA, 2002a).

Todas as implementações foram feitas em linguagem LEGAL através de procedimento descrito por Luiz et al. (2003).

3.7 - Retificação Radiométrica

Utilizando a imagem do dia 10 de março como referência, executou-se a retificação radiométrica com programas em linguagem LEGAL (Apêndice B) na seguinte ordem:

1. Geração das componentes *Greenness* (GR) e *Brightness* (BR).
2. Fatiamento das componentes GR e BR em dois níveis, obtendo-se os alvos pseudoinvariantes (de controle radiométrico) nos temas claros e escuros. Neste trabalho escolheram-se solo exposto e água como alvos pseudoinvariantes claros e escuros, respectivamente.
3. Cruzamento dos temas claros GR e BR, e escuros GR e BR, para obter áreas comuns e de controle radiométrico.
4. Obtenção, para cada banda i a ser retificada, da média dos valores nas regiões temáticas claras e escuras, ou seja, obtenção banda a banda do D_{Si} , D_{Ri} , B_{Si} , B_{Ri} que são as médias para as áreas escuras (D) e claras (B) para as imagens a serem retificadas (S) e para as imagens de referência (R). O resultado foi armazenado num plano de informação (PI) numérico, por expressar números reais.

5. Execução da retificação pela formulação proposta por Hall et al. (1991) onde, para cada banda espectral $T(i)$, a transformação linear é dada pela equação $T(i) = m_i x_i + b_i$, onde x_i é a banda a ser retificada e m_i e b_i são dados pelas equações:

$$m_i = (B_{Ri} - D_{Ri}) / (B_{Si} - D_{Si}) \quad (3.4)$$

$$b_i = (D_{Ri} B_{Si} - D_{Si} B_{Ri}) / (B_{Si} - D_{Si}) \quad (3.5)$$

6. Como no item 4, obteve-se a média dos valores para os alvos claros e escuros da imagem retificada. Com este procedimento, é verificado se os valores médios não diferem em mais de uma unidade em relação aos valores para os mesmos alvos na imagem referência. Esta condição de verificação é proposta em Hall et al. (1991).

3.8 – Obtenção de Amostras Via PI Cadastral no Ambiente SPRING

O procedimento de criação do PI Plano de Informação (PI) cadastral foi necessário para obtenção de amostras tanto para a análise visual e definição das classes como para amostras de treinamento da rede. Um problema operacional foi construir (digitalizar) na tela polígonos de 3x3 pixels⁸ que amostrariam o talhão agrícola. Era necessário manter esta dimensão uma vez que um filtro, com janela de 3x3 pixels, iria percorrer a imagem extraindo média e desvio padrão para classificação (Figura 3.3). Apenas na digitalização para amostragem, seria necessário digitalizar 120 polígonos por classe, sendo 100 polígonos para obter dados de treinamento e 20 para validação.

⁸ A partir da versão 3.6.03 do SPRING, no menu ferramentas existe a opção – ESTATÍSTICA POR POLÍGONO – onde, para os polígonos de um dado PI Numérico (número Real) ou Imagem (número Inteiro), calculam-se os seguintes parâmetros: mínimo, máximo, amplitude, média, variância, desvio padrão, assimetria, curtose, coeficiente de variação, mediana, moda.




FIGURA 3.3 – Ilustração dos parâmetros estatísticos média (\bar{x}) e desvio padrão (s) utilizados na entrada na rede.

A solução encontrada foi digitalizar apenas o ponto que seria o centro do polígono e exportá-lo para o Excel, onde, através de uma MACRO (Apêndice C), gerou-se um arquivo de cinco coordenadas⁹ que foram importadas para o SPRING. A Figura 3.4 ilustra o ponto 1' (de coordenadas x,y) exportado do SPRING e o polígono fechado (cinco coordenadas) gerado no Excel com $\Delta x = \Delta y = 45$. O valor 45 permite criar polígonos com lado de 3 pixels ou 90 m . Após a geração dos polígonos, realizou-se a importação para o ambiente SPRING e se fez a associação dos mesmos (Nomes/Rótulos) de acordo com o rótulo adotado no trabalho de campo.




FIGURA 3.4 – O ponto (cruz) de coordenada $x y$ e polígono 3x3 gerado a partir deste ponto com um incremento Δ de 45.

⁹ No SPRING um polígono fechado de n vértices é armazenado em $n+1$ coordenadas. A coordenada inicial é armazenada duas vezes.

3.9 – Cálculo do NDVI, Análise Visual dos Dados e Definição das Classes

O cálculo do NDVI foi feito a partir das imagens com a transformação das mesmas em grade numérica. O fator multiplicador, de acordo com Luiz et al. (2003), para a exibição da imagem (número inteiro) a partir da reflectância (número real) foi de 667 para a banda 3, 285 para a banda 4, e 478 para a banda 5 para a imagem de 10 de março, usada para referência da retificação. Dessa maneira, dividiram-se todas as demais imagens retificadas, do mesmo canal, pelo respectivo número multiplicador da imagem referência, obtendo-se a grade numérica (reflectância) retificada. As grades numéricas foram utilizadas para plotagem da variação temporal de cada cultura e para geração da grade NDVI de acordo com a Equação 3.6:

$$\text{NDVI} = \frac{\rho_4 - \rho_3}{\rho_4 + \rho_3} \quad (3.6)$$

onde ρ_4 e ρ_3 são as reflectâncias das bandas 4 e 3, respectivamente.

Para extrair amostras, plotar e analisar o comportamento temporal de cada cultura agrícola, criou-se um PI (Plano de Informação) do modelo cadastral. Este modelo tem duas vantagens para o estudo: permite a rotulação/visualização dos polígonos e que o mesmo nome/número anotado na planilha de campo para o talhão, seja colocado na tela (Figura 3.5). A segunda vantagem é que os atributos (parâmetros estatísticos) que são extraídos, os quais são atributos do polígono (objeto espacial), são organizados de forma prática em uma tabela (objeto não-espacial), como pode ser observado na Figura 3.6.

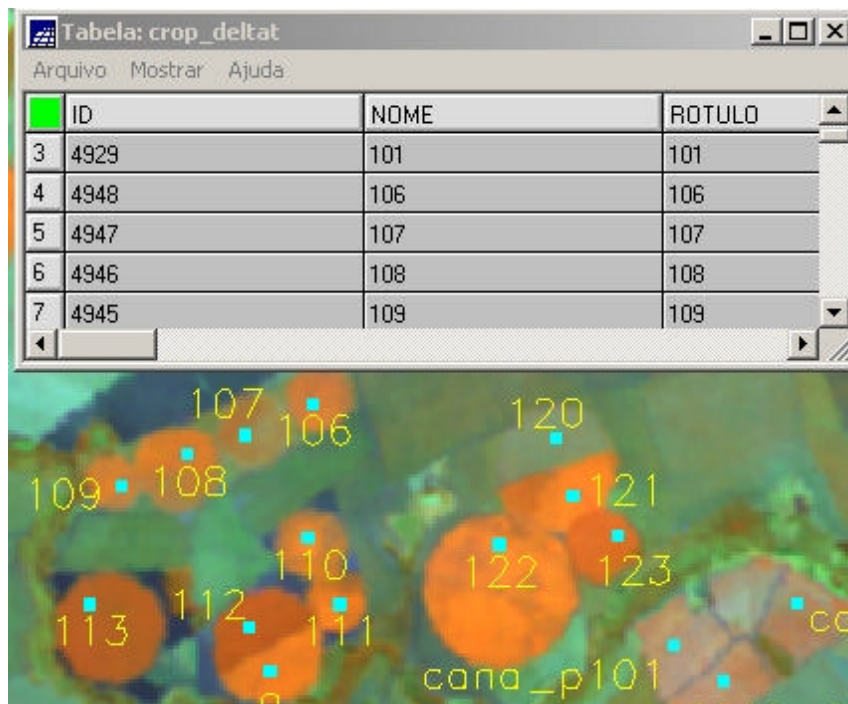


FIGURA 3.5 – Imagem na composição 3B4R5G de 30/06/2002 e os correspondentes objetos com texto e tabela de atributos.



FIGURA 3.6 – Exemplo de um objeto espacial (polígono 29) da classe feijão 1 e alguns dos seus atributos: parâmetros estatísticos das bandas b3, b4 e b5 e do NDVI para a quarta data (29 de maio de 2002).

Para a análise e definição das classes, calculou-se para cada polígono 3x3 (no menu ferramentas? estatística por polígono) a temporalidade do índice NDVI, o que permitiu,

após análise visual, definir as seguintes classes: água, não-agrícola (não-cultivado), milho, sorgo, cana colhida no ano, cana colhida no ano e meio, feijão1 e feijão2¹⁰.

3.10 - Criação de PIs Cadastrais Para Extração de Amostras

Foram criados oito PIs cadastrais para extração de amostras de treinamento. Ao contrário do primeiro PI cadastral criado, que continha polígonos amostrais sobre todos os talhões e amostras de todas as classes, esses novos PIs possuem polígonos (3x3) somente de talhões de mesma classe (por exemplo: ex. cana de ano e meio). Como não havia necessidade de saber de qual talhão a amostra veio, mas apenas de que PI (cada PI fornecerá amostras de uma classe), optou-se pela rotina de rotulação automática dos polígonos existentes no SPRING¹¹.

Com o auxílio da planilha de campo e dos perfis temporais de NDVI foram criados 120 polígonos (3x3) em cada PI (como descrito no item 3.7) somente nos talhões que tinham o ciclo completo de determinada classe. Isso foi feito para que o classificador, ao “aprender” o ciclo completo de uma cultura, pudesse classificá-la mesmo que nos dados de teste apenas parte do ciclo fosse apresentada à rede neural, como consequência da variação temporal encontrada na cena.

3.11 - Pré-Processamento dos Dados

A Figura 3.7 ilustra a seqüência de atividades executadas para gerar arquivos de média e desvio-padrão. Após esse procedimento executou-se a normalização e a exportação para fora do ambiente SPRING. Através de programas em linguagem C esses arquivos foram organizados para entrada em ambiente *Stuttgart Neural Network Simulator* (SNNS)

¹⁰ Devido ao tamanho do ciclo da cultura de feijão, dos dois períodos de cultivo ao longo do ano, e das práticas culturais antecedentes e precedentes a esses dois períodos, decidiu-se criar duas classes para esta cultura.

¹¹ Após a rotulação, cada polígono é denominado de “objeto espacial”, que possui atributos numa tabela de “objeto não-espacial”.

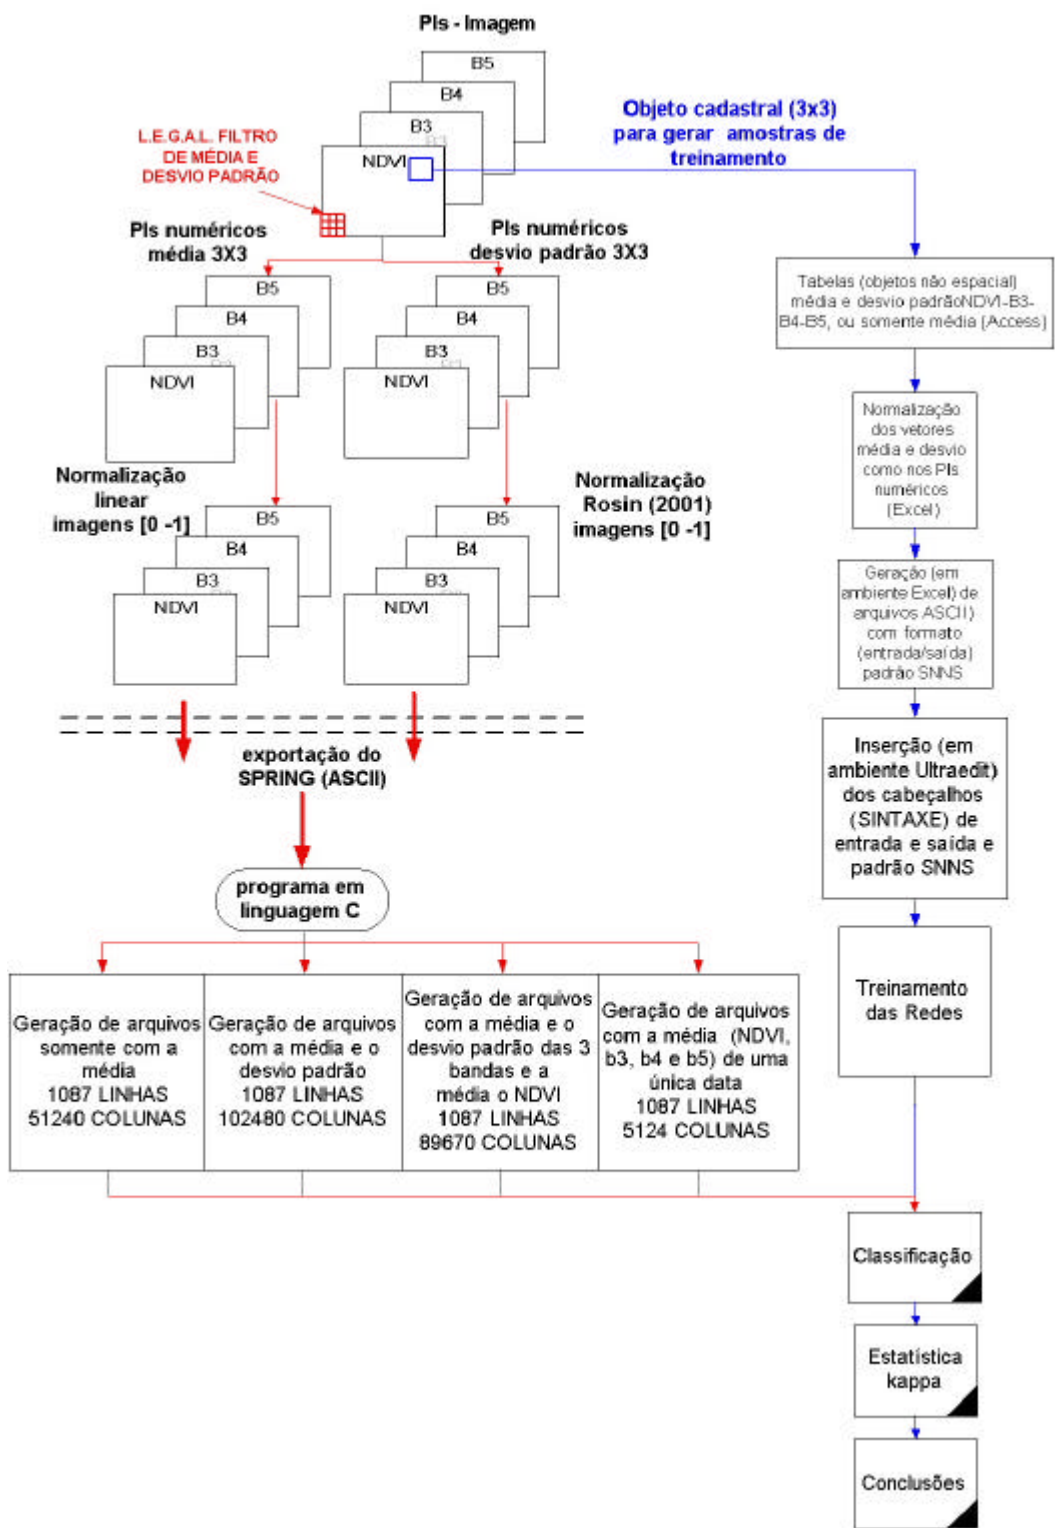


FIGURA 3.7 – Fluxograma da extração de amostras e geração de arquivos de classificação do SPRING para o *Stuttgart Neural Network Simulator* (SNNS).

(Zell et al., 1998) na mesma seqüência vetorial dos parâmetros extraídos do arquivo de treinamento.

Para avaliar qual o melhor parâmetro de entrada na rede, geraram-se arquivos (1087 x 1281) de média e desvio-padrão de uma janela 3x3 pixels através de linguagem LEGAL. Esse procedimento foi feito para cada uma das bandas e para a imagem NDVI.

Faz-se uma ressalva que, devido aos baixos valores de desvio padrão, estes foram multiplicados por 100, conforme pode ser visto no Apêndice D. Como já descrito, é necessário que os valores dos parâmetros de entrada (média e desvio padrão) tenham mesma ordem de grandeza, caso contrário, a saída da rede não expressa a importância relativa dos mesmos no resultado final.

Para normalizar os arquivos de média, analisaram-se os histogramas das 10 imagens de cada componente espectral (bandas 3, 4 e 5 e NDVI) com o objetivo de obter o valor mínimo (DN_{iMIN}) o valor máximo (DN_{iMAX}) que cada componente espectral (i) apresentava nas 10 imagens analisadas. A normalização foi feita de acordo com a Equação 3.6:

$$x_i = \frac{DN_i - DN_{iMIN}}{DN_{iMAX} - DN_{iMIN}} \quad (3.7)$$

onde x_i é a grade numérica resultante da banda i, DN_i é o valor digital de cada pixel da banda i, DN_{iMIN} é o menor valor de DN da banda i nas 10 datas, DN_{iMAX} é o maior valor de DN nas 10 datas analisadas.

A normalização das imagens de desvio padrão teve um procedimento diferente. Os valores de desvio padrão foram muito discrepantes como mostra o histograma típico exibido na Figura 3.8. Para encontrar o valor da normalização das imagens de desvio padrão utilizou-se o método proposto por Rosin (2001). Este autor propõe calcular a equação da reta que liga o pico do histograma à intersecção do mesmo no eixo x. Após este procedimento, calculam-se as distâncias dessa reta ao histograma e, no ponto de maior distância, projeta-se uma reta perpendicular ao eixo x. Adota-se este ponto de limiar para o histograma.




FIGURA 3.8 – Procedimento para delimitar o limiar de um histograma.

FONTE: Adapta de Rosin (2001, p.2084).

A mudança necessária neste trabalho é porque no histograma da imagem de desvio padrão, como será visto no capítulo 4, os altos valores de desvio padrão encontrados são assintóticos e não cruzam o eixo x. Desse modo, a coordenada limite em x foi estabelecida onde o histograma acumulava 98,3%¹² dos valores (Figura 3.9). Os dados de frequência e frequência acumulada foram obtidos através do programa ENVI 3.5 (“The Environment for Visualizing Images”).

¹² Valor arbitrado – Na maior parte dos histogramas existiam menos de 100 valores para cada novo valor de desvio exibido.




FIGURA 3.9 – Procedimento adotado neste trabalho para delimitar o limiar.

O maior valor de desvio padrão encontrado nas dez datas, para cada uma das componentes (bandas 3, 4, 5 e NDVI) foi utilizado na normalização dos arquivos de acordo com a Equação 3.8.

$$y_i = \frac{R_i - R_{iMIN}}{R_{iLIMIAR} - R_{iMIN}} \quad (3.8)$$

onde y é a grade numérica de desvio padrão normalizado da banda i ; R_i é o valor do desvio padrão da célula (x,y) da banda i ; R_{iMIN} é o menor valor de desvio padrão encontrado nos dez arquivos da banda i ; $R_{iLIMIAR}$ é o maior valor de desvio padrão nas dez datas analisadas.

Antes da aplicação dessa equação, para cada conjunto de dez arquivos de mesma banda, foram eliminados os valores de desvio padrão maiores que o valor limiar através do seguinte algoritmo:

Se $R_i > R_{LIMIAR}$ então $R_i = R_{LIMIAR}$, caso contrário $R_i = R_i$.

3.12 - Seqüenciamento Para Entrada e Codificação de Saída

Os dados de classificação tiveram que ser organizados para que a rede neural “entendesse” que um certo conjunto de dados representava uma única posição (x,y) da imagem, ou seja, entender a temporalidade de 10 datas do NDVI e das bandas 3, 4 e 5

pixel a pixel. Dessa maneira, uma rede com 40 neurônios de entrada, por exemplo, terá que ler 40 números dos quais são 10 valores de NDVI e 10 de cada uma das bandas 3, 4 e 5 correspondentes à mesma posição x,y .

Após a normalização dos arquivos de média e desvio padrão, executou-se a exportação de todas as 80 grades numéricas do SPRING. Em ambiente do aplicativo Ultraedit removeram-se todos os cabeçalhos (banco, projeto, PI, etc.) e a palavra “END” da última linha. Foi feita a substituição de todos os “nodatavalue”, cujo valor é $3.400000000e+037$, por 0.500000. Esses valores aparecem em todas as últimas linhas e colunas das matrizes ASCII exportadas do SPRING, uma vez que o projeto não foi definido com dimensões múltiplas inteiras de 30, que é a resolução do sensor. Os “nodatavalue” também aparecem no meio da imagem com a falha/ruído de um detector.

Um programa em linguagem C (Apêndice E) organizou os arquivos de média e desvio padrão, ou somente arquivos de média ou arquivos de média e desvio padrão para as bandas e média para o NDVI num único arquivo usado na classificação. A seqüência de ordenação é determinada pela ordem em que os nomes dos arquivos (1087x1281) exportados do SPRING são escritos dentro do arquivo – “arquivos.txt”, que o executável consulta na ordenação.

Um exemplo de seqüenciamento dos dados na construção de uma matriz de classificação é observado na Figura 3.10. Para cada elemento $S_{d(x,y)}$, de ordem cronológica d e posição (x,y) na matriz tem-se:

NDVI _{1(1,1)}	b3 _{1(1,1)}	b4 _{1(1,1)}	b5 _{1(1,1)}	...	NDVI _{1(1087,1281)}	b3 _{1(1087,1281)}	b4 _{1(1087,1281)}	b5 _{1(1087,1281)}
.
.
.
NDVI _{1(1087,1)}	b3 _{1(1087,1)}	b4 _{1(1087,1)}	b5 _{1(1087,1)}	...	NDVI _{1(1087,1281)}	b3 _{1(1087,1281)}	b4 _{1(1087,1281)}	b5 _{1(1087,1281)}

FIGURA 3.10 – Exemplo de matriz de entrada de dados.

Dessa maneira o número de linhas (1087) era sempre mantido e o número de colunas (1281) era multiplicado pelo número de bandas espectrais mais o NDVI (4), número de datas (10) e número de parâmetros estatísticos como a média e/ou desvio padrão (2). Os arquivos tiveram dimensões variadas de acordo com os objetivos, os quais serão detalhados: (1) arquivos de média e desvio padrão, com as dez datas, para as três bandas e o NDVI, com um total de 102480 colunas; (2) arquivos de média e desvio padrão para as bandas e somente média para o NDVI, em 10 datas, com um total de 89670 colunas; (3) somente arquivos de média para as bandas e o NDVI, nas 10 datas, com um total de 51240 colunas; (4) arquivos com a média das bandas 3, 4 e 5 e NDVI de uma única data comum, com um total de 5124 colunas. Para avaliação do melhor parâmetro estatístico utilizaram-se os arquivos gerados em (1), (2) e (3) e, uma vez escolhido o melhor parâmetro estatístico, avaliou-se a classificação temporal em relação à classificação de uma única data.

Os arquivos de treinamento foram obtidos através do menu ferramentas → estatística por polígono, de onde se extraíram vetores (amostras) de classes específicas. De todos os parâmetros estatísticos gerados pelo SPRING, apenas a média e o desvio padrão foram utilizados. Cada tabela, com 120 vetores, gerada no SPRING fica armazenada no Access, o gerenciador de banco de dados utilizado na criação do projeto. Cada uma das tabelas (uma por classe) foi exportada em formato Excel. Os procedimentos de normalização adotados para os arquivos (matrizes) de média e desvio padrão também foram aplicados nos vetores em ambiente Excel.

Apenas para a classe sorgo as amostras não vieram das imagens (1087x1281) utilizadas na classificação. Haviam poucos pivôs com a cultura do sorgo, o que poderia resultar na falta de áreas para avaliação estatística, uma vez que as áreas de amostragem para treinamento não devem ser utilizadas para avaliar o desempenho do classificador. Um recorte da área, maior do que 1087x1281, para incluir outros pivôs com sorgo levaria a um acréscimo desnecessário da área total, uma vez que as áreas irrigadas não são contínuas. Um pequeno projeto, de uma área vizinha à área classificada foi criado somente para se extraírem amostras de sorgo.

A codificação utilizada para treinamento foi: 0 0 0 0 0 0 1 para a classe feijão1, 0 0 0 0 0 0 1 0 para a classe feijão2, até 1 0 0 0 0 0 0 0 para a classe não agrícola, conforme ilustra a Figura 3.11.




FIGURA 3.11 – Entrada multitemporal do NDVI e das bandas ETM+ 3, 4 e 5 na rede com arquivos de médias e a correspondente codificação de saída.

3.13 - Treinamento e Classificação

Nesse estudo, procurou-se utilizar aplicativos de uso livre como o SPRING, desenvolvido pela Divisão de Processamento de Imagens (DPI), do INPE. Para realizar o processamento com RNA o programa escolhido foi o *Stuttgart Neural Network Simulator* (SNNS) (Zell et al., 1998). Este pacote foi desenvolvido pelos pesquisadores da Universidade de Stuttgart e Tübingen e está disponível no portal <http://www-ra.informatik.uni-tuebingen.de/SNNS/>. No endereço <http://www-ra.informatik.uni-tuebingen.de/SNNS/SNNS-Mail/> existe uma lista de discussão onde, desde 1994, usuários de todo o mundo trocam informações. Há três versões do aplicativo: em JAVA,

Linux e Unix. Utilizou-se a versão 4.2 para Unix, as versões para Unix são mais robusta e rápidas e permitiram ler e classificar arquivos da ordem de 1 Gb, como os utilizados neste trabalho. Todos os treinamentos foram desenvolvidos em micro computador com processador Atlon 1,7 GHz, 512 Mb de memória RAM, com windows XP, utilizando emulador (xwin) de ambiente Unix.

O programa SNNS trabalha com arquivos de entrada e saída em formato ASCII e as configurações de rede (arquivos.net) armazenam a arquitetura, funções de ativação e pesos de treinamento. Assim, uma determinada rede treinada pode ser salva e carregada para uma classificação *a posteriori*.

O treinamento sempre foi feito com a função “shuffle” ativada – o que permitia uma entrada aleatória dos vetores, evitando tendenciosidades¹³ durante o treinamento. A entrada dos arquivos de treinamento e a validação faz-se em janelas específicas, e o usuário pode também definir após quantos ciclos de treinamento os dados de validação são apresentados à rede para visualizar a validação cruzada.

3.14 - Rede Treinada com o Algoritmo de Retopropagação do Erro (RPE)

As redes Perceptrons de Múltiplas Camadas (MLP) utilizando o algoritmo de RPE têm sido as redes de maior uso para classificação de imagens de sensores remotos (Paola e Schowengerdt, 1995). No aplicativo SNNS existem muitas variantes desse algoritmo, como a rede RPE com momentum, as quais evitam que o aprendizado da rede pare num mínimo local e não global (Kavzoglu e Mather, 2003).

Neste estudo, o treinamento foi realizado com o algoritmo de treinamento “Std_Backpropagation”, com o parâmetro da taxa de aprendizagem (η) de 0,2. A diferença máxima ($d_j = I_j - o_j$) entre os valores de entrada (I_j) e saída (o_j), foi ajustada para 0,1.

¹³ Caso esta função não seja ativada, a rede irá ler os 800 vetores na ordem seqüencial, e os últimos 100 vetores lidos podem deixar a rede tendenciosa para a classe que eles representam.

Utilizou-se a função sigmóide logística (Equação 3.9), uma vez que os valores estavam normalizados entre 0 e 1.

$$f(x) = \frac{1}{1 + e^{(-x)}} \quad (3.9)$$

3.15 - Função de Base Radial (FBR)

Para classificação com as Funções de Base Radial (FBR), todas as redes foram montadas utilizando a função Gaussiana na camada oculta e a função logística na saída. Segundo Zell et al. (1998), o objetivo em inicializar a FBR é encontrar pesos computacionalmente eficientes entre a camada oculta e a camada de saída. Existem três procedimentos de inicialização implementados no pacote SNNS. O procedimento utilizado foi o *FBR_Weights*, o qual seleciona centros uniformemente distribuídos dos padrões de treinamento e os distribui entre as camadas de entrada e saída. Na seqüência, o viés fornecido pelo usuário é distribuído na camada oculta e, posteriormente, os pesos entre a camada oculta e a camada de saída são computados. O parâmetro de inicialização – desvio (σ) – foi ajustado de acordo com a Equação 3.10. Este valor determina a máxima porcentagem de desvio que pode ocorrer aleatoriamente a partir do centro de uma classe. A rede FBR foi treinada com a função de aprendizagem *Radial Basis Learning*, onde a taxa de aprendizagem para o ajuste dos centros das classes foi de 0,01, a taxa de incremento dos pesos também de 0,01, com o erro máximo tolerado (*delta max*), em relação aos dados de saída, de 0,1.

$$\sigma = \frac{\text{dist}_{\text{MAX}}}{\sqrt{2m}} \quad (3.10)$$

onde m é o número de centros de classes, e dist_{MAX} é a máxima distância encontrada entre os parâmetros utilizados na classificação. A determinação desse parâmetro foi feita através de uma tabela de diferença, onde a média das 800 amostras (100 de cada classe) utilizadas no treinamento foram inseridas na linha e na coluna inicial e, célula a célula, calculou-se a diferença entre cada parâmetro (Tabela 3.3)

TABELA 3.3 – Tabela ilustrativa do procedimento para obtenção da distância máxima ($dist_{MAX}$) entre os parâmetros utilizados na classificação. A primeira linha e a primeira coluna são resultados da média de 800 vetores utilizados no treinamento das redes.

	\overline{NDVI}_1	$\overline{b3}_1$	$\overline{b4}_1$	$\overline{b5}_1$..	\overline{NDVI}_{10}	$\overline{b3}_{10}$	$\overline{b4}_{10}$	$\overline{b5}_{10}$
\overline{NDVI}_1	0	$b3_1 - NDVI_1$	$b4_1 - NDVI_1$	$b5_1 - NDVI_1$		$NDVI_{10} - NDVI_1$	$b3_{10} - NDVI_1$	$b4_{10} - NDVI_1$	$b5_{10} - NDVI_1$
$\overline{b3}_1$	$NDVI_1 - b3_1$	0	$b4_1 - b3_1$	$b5_1 - b3_1$		$NDVI_{10} - b3_1$	$b3_{10} - b3_1$	$b4_{10} - b3_1$	$b5_{10} - b3_1$
$\overline{b4}_1$	$NDVI_1 - b4_1$	$b3_1 - b4_1$	0	$b5_1 - b4_1$		$NDVI_{10} - b4_1$	$b3_{10} - b4_1$	$b4_{10} - b4_1$	$b5_{10} - b4_1$
$\overline{b5}_1$	$NDVI_1 - b5_1$	$b3_1 - b5_1$	$b4_1 - b5_1$	0		$NDVI_{10} - b5_1$	$b3_{10} - b5_1$	$b4_{10} - b5_1$	$b5_{10} - b5_1$
...			→	$dist_{MAX}$			
\overline{NDVI}_{10}	$NDVI_1 - NDVI_{10}$	$b3_1 - NDVI_{10}$	$b4_1 - NDVI_{10}$	$b5_1 - NDVI_{10}$		0	$b3_{10} - NDVI_{10}$	$b4_{10} - NDVI_{10}$	$b5_{10} - NDVI_{10}$
$\overline{b3}_{10}$	$NDVI_1 - b3_{10}$	$b3_1 - b3_{10}$	$b4_1 - b3_{10}$	$b5_1 - b3_{10}$		$NDVI_{10} - b3_{10}$	0	$b4_{10} - b3_{10}$	$b5_{10} - b3_{10}$
$\overline{b4}_{10}$	$NDVI_1 - b4_{10}$	$b3_1 - b4_{10}$	$b4_1 - b4_{10}$	$b5_1 - b4_{10}$		$NDVI_{10} - b4_{10}$	$b3_{10} - b4_{10}$	0	$b5_{10} - b4_{10}$
$\overline{b5}_{10}$	$NDVI_1 - b5_{10}$	$b3_1 - b5_{10}$	$b4_1 - b5_{10}$	$b5_1 - b5_{10}$		$NDVI_{10} - b5_{10}$	$b4_{10} - b5_{10}$	$b4_{10} - b5_{10}$	0

3.16 – Organização dos Dados para Produzir Mapas Temáticos

Após a classificação, utilizou-se um outro programa em linguagem C (Apêndice F) para transformar os arquivos de saída SNNS em matrizes numéricas. A saída do aplicativo SNNS é uma única e contínua lista, com um rótulo por linha, como na lista abaixo:

```
#1.1
0.02739 0.00101 0.05694 0.01797 0.50381 0.17875 0.17635 0.16303
#1.2
0.03122 0.00147 0.07339 0.03083 0.50151 0.15608 0.17269 0.14603
#1.3
0.04448 0.00253 0.1033 0.07328 0.60033 0.12753 0.1746 0.1228
.
.
.
#1.1392445
0.00001 0.00835 0.85109 0.00095 0.27269 0.08664 0.0148 0.15739
#1.1392446
0.00001 0.00835 0.95109 0.00095 0.27269 0.08664 0.0148 0.15739
```

```
#1.1392447  
0.00001 0.00835 0.85109 0.00095 0.27269 0.08664 0.0148 0.15739
```

O programa lê os oito números dos neurônios de saída e guarda em cada posição x,y da grade numérica gerada a posição ordinal do neurônio que tinha a ativação maior que 0,5 (a função utilizada foi a logística). Caso nenhum ou mais de um neurônio fosse ativado (>0,5), o programa atribuía a mesma ativação do primeiro neurônio – 1 - que é a classe não agrícola (1 0 0 0 0 0 0). Outra entrada do programa em C é o número de colunas, ou seja, para as dimensões da área de estudo, a cada 1281 execuções (colunas) o programa começava a escrever uma nova linha, gerando uma matriz com as dimensões de 1087x1281, a partir da lista de 1.392.447 linhas de saída do SNNS.

Essas matrizes foram importadas para o SPRING como PI numérico. A seguir foi executado um fatiamento em programa LEGAL, para a geração de um PI temático.

Além das classificações com o conjunto de dez imagens que continha uma imagem simulada por presença real de nuvens, fez-se uma simulação maior de presença de nuvens omitindo-se datas intercaladas (Figuras 3.12a e 3.12b). A metodologia proposta prevê que nem sempre será possível obter todas as imagens com baixa cobertura de nuvens, principalmente para o cultivo de verão. A substituição das imagens extraídas foi feita pelas médias aritméticas simples entre a anterior e a posterior. Esta execução permite avaliar outra vantagem das redes neurais: a tolerância a falha de dados.

A simulação foi executada com o próprio conjunto de imagens de 2002, do qual se extraíram as amostras de treinamento. No entanto, a classificação com um conjunto de imagens, completo ou não, de futuros anos agrícolas, é o objetivo maior a ser pesquisado.

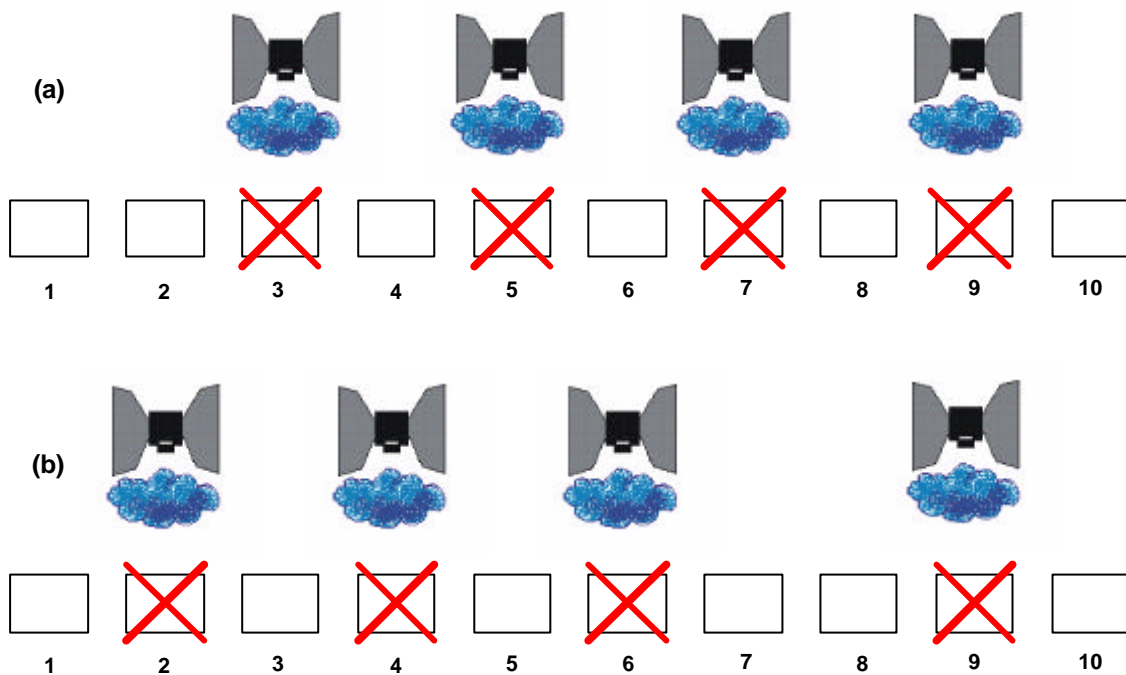


FIGURA 3.12 – Duas simulações de perda de dados por nebulosidade em datas alternadas. Situação (a) perda das imagens 3, 5, 7 e 9. Situação (b) perda das imagens 2, 4, 6, 9 (A imagem 8 já é simulada no conjunto original de onde se extraíram amostras de treinamento).

3.17 - Classificação com o Classificador Gaussiano de Máxima Verossimilhança (MaxVer)

Era necessário comparar o desempenho dos classificadores de redes neurais com os algoritmos tradicionais de classificação de imagens. Entre os classificadores tradicionais, escolheu-se o algoritmo de máxima verossimilhança, que, ao contrário das redes neurais, é paramétrico e de ampla citação na literatura (Swain, 1978; Murthy et al., 2003).

O aplicativo utilizado na classificação foi o ENVI 3.5. Primeiramente, criou-se, em ambiente SPRING, um PI temático e todos os polígonos de 3x3 pixels dos PIs cadastrais foram importados para este PI. Depois, esses polígonos foram rotulados de acordo com as classes correspondentes ao PI de origem (cara de ano e meio, feijão 1, feijão 2, etc.) e foram transformados em dados matriciais (“vetor→raster”). Isto permitiu importá-los para o ENVI (em formato raw) e executar a operação (“band

threshold to ROI¹⁴”). Assim, exatamente os mesmos polígonos, de onde se extraíram as amostras para o SNNS foram utilizados para a amostragem do classificador MaxVer no ENVI.

Para a classificação MaxVer utilizou-se o limiar de probabilidade de 95%. No treinamento não se utilizou a classe não-agrícola (não-cultivado), porque continha amostras de terrenos em pousio, cidades e matas, e produzia uma variância muito grande, o que poderia comprometer a classificação das outras classes. Assim, todo pixel fora do limite de probabilidade de 95% e todo pixel não classificado foi computado na classe não-agrícola. As classificações foram realizadas com “única data” e “temporal” com 40 componentes espectrais: NDVI, b3, b4 e b5 em dez datas.

As classificações resultantes foram exportadas em formato ASCII (matriz com dígitos de 1 a 8) e importadas para o SPRING como PI numérico. O PI numérico foi fatiado e transformado em PI temático com as 8 classes pré-definidas.

3.18 – Análises, Arquiteturas, Algoritmos e Parâmetros Estatísticos

A Tabela 3.4 traz a seqüência de análises, algoritmos, arquiteturas e parâmetros estatísticos utilizados. Primeiramente procuraram-se os melhores parâmetros estatísticos para treinamento da rede com algoritmos de retropropagação do erro. Utilizou-se a média e desvio padrão dos quatro parâmetros NDVI, b3, b4 e b5. Uma segunda classificação foi feita com a média e o desvio padrão das três bandas e apenas a média do NDVI. Na última classificação temporal utilizou-se apenas o parâmetro estatístico média. O número de neurônios na camada oculta foi mantido na análise temporal independentemente do tamanho da entrada e do algoritmo utilizado (RPE ou FBR). Nas classificações de uma única data, independentemente do algoritmo, foi mantida a arquitetura 4-9-8.

¹⁴ ROI – Region of Interest

TABELA 3.4 – Análises, algoritmos, arquiteturas e parâmetros estatísticos utilizados.

Análise	Algoritmo	Arquitetura	Parâmetros Estatísticos
Temporal	RPE	80-70-8	média e desvio padrão do NDVI e das bandas 3, 4 e 5
Temporal	RPE	70-70-8	média do NDVI e média e desvio padrão das bandas 3, 4 e 5
Temporal	RPE	40-70-8	média do NDVI e das bandas 3, 4 e 5
Uma data 11/04	RPE	4-9-8	Média
Uma data 27/04	RPE	4-9-8	Média
Uma data 13/05	RPE	4-9-8	Média
Uma data 29/05	RPE	4-9-8	Média
Uma data 14/06	RPE	4-9-8	Média
Uma data 30/06	RPE	4-9-8	Média
Uma data 16/07	RPE	4-9-8	Média
Uma data 01/08 (simulada)	RPE	4-9-8	Média
Uma data 17/08	RPE	4-9-8	Média
Uma data 02/09	RPE	4-9-8	Média
Uma data 11/04	FBR	4-9-8	Média
Uma data 27/04	FBR	4-9-8	Média
Uma data 13/05	FBR	4-9-8	Média
Uma data 29/05	FBR	4-9-8	Média
Uma data 14/06	FBR	4-9-8	Média

(continua)

(continuação)

Uma data 30/06	FBR	4-9-8	Média
Uma data 16/07	FBR	4-9-8	Média
Uma data 01/08 (simulada)	FBR	4-9-8	Média
Uma data 17/08	FBR	4-9-8	Média
Uma data 02/09	FBR	4-9-8	Média
Primeira-falha	RPE	40-70-8	Média
Segunda_falha	RPE	40-70-8	Média
Primeira_falha	FBR	40-70-8	Média
Segunda_falha	FBR	40-70-8	Média

3.19 - Geração de Grade com Pontos de Referência e Análise Estatística

Todas as classificações foram avaliadas por procedimentos de estatística kappa. Para realizar essa avaliação foram gerados 2415 pontos através de planilha eletrônica. As coordenadas de cada ponto x, y foram dadas por:

$x = \text{função aleatória} * \text{número de colunas} + \text{coordenada X do canto inferior esquerdo}$

$y = \text{função aleatória} * \text{número de linhas} + \text{coordenada Y do canto inferior esquerdo}$

Esses pontos foram importados para um PI temático e foram associados, com auxílio das planilhas de campo, com as respectivas classes nas quais eles estavam contidos. Posteriormente, esse PI foi transformado em PI matricial com resolução de 30 m. Esse PI de referência foi comparado com cada resultado de classificação da Tabela 3.4 através da função de tabulação cruzada implementada no SPRING. A saída é um arquivo ASCII.

A matriz de confusão foi estruturada em planilha Excel. A formulação do kappa (\hat{k}) e da variância do kappa ($\hat{v}\text{ar}(\hat{k})$) foram derivadas dessa matriz, após preenchimento das células da mesma com os arquivos ASCII resultantes da tabulação cruzada.

A matriz de confusão foi montada de acordo com Congalton e Green (1999) (Tabela 3.5).

TABELA 3.5 – Matriz de confusão genérica.

	j = colunas (referência)				total linha n_{i+}
		1	2	K	
i = linhas classificação	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	K	n_{k1}	n_{k2}	n_{kk}	n_{k+}
	total coluna n_{+j}	n_{+1}	n_{+2}	n_{+k}	N

Com os dados da matriz (Tabela 3.5) calcula-se o índice kappa, que é dado por (3.11):

$$\hat{k} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{i+} \cdot n_{+i})}{n^2 - \sum_{i=1}^k (n_{i+} \cdot n_{+i})} \quad (3.11)$$

onde:

k = Número de linhas da matriz de confusão.

n = número total de observações da matriz.

n_{ii} = número de observações na linha i e coluna i (na diagonal principal)

$$n_{i+} = \sum_{j=1}^k n_{ij}$$

$$n_{+j} = \sum_{i=1}^k n_{ij}$$

A variância do índice kappa é dada por (3.10):

$$\text{vâr}(\hat{K}) = \frac{1}{n} \left\{ \frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right\} \quad (3.12)$$

onde:

$$\theta_1 = \frac{1}{n} \sum_{i=1}^k n_{ii} ,$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^k n_{i+} n_{+i} ,$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^k n_{ii} (n_{i+} + n_{+i}) ,$$

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

Os resultados das classificações, expressos no índice kappa, foram comparados dois a dois para verificar se as diferenças eram significativas. A distribuição da razão $\hat{k} / \sqrt{\text{vâr}(\hat{k})}$ é aproximadamente Gaussiana (Tso e Mather, 2001). Uma classificação com o índice kappa (\hat{k}_1) e com a variância ($\text{vâr}(\hat{k}_1)$), e uma segunda classificação com o índice kappa (\hat{k}_2) com a variância ($\text{vâr}(\hat{k}_2)$) foram avaliadas através do teste Z. O teste Z padronizado e normalmente distribuído é dado por (3.13).

$$Z = \frac{|\hat{k}_1 - \hat{k}_2|}{\sqrt{\text{vâr}(\hat{k}_1) + \text{vâr}(\hat{k}_2)}} \quad .13)$$

Em seguida foram realizados os testes de hipóteses onde, para duas classificações diferentes tanto pelo uso de temporalidade, algoritmos ou uso de dados falhos a hipótese H_0 , onde $H_0 : (\hat{k}_1 - \hat{k}_2) = 0$, ou seja não existe diferença significativa entre as classificações. Também verificou-se a hipótese alternativa, existe diferença significativa, $H_1 : (\hat{k}_1 - \hat{k}_2) \neq 0$.

A avaliação dos parâmetros estatísticos utilizados foi feita tomando-se o melhor resultado do kappa em comparação com os outros dois resultados de classificação.

Com relação à temporalidade, comparou-se cada classificação de data simples com a classificação temporal. Este procedimento foi feito para os algoritmos de RPE, FBR e MaxVer.

Com relação à tolerância a dados falhos, os resultados do kappa para as duas simulações foram comparados com o conjunto completo de imagens. Esse procedimento foi feito tanto para o algoritmo FBR como para o RPE.

O índice kappa pode gerar um resultado que pode levar a interpretações enganosas. Por exemplo, caso uma certa classe seja dominante numa cena e, além de tudo, de fácil discriminação, o índice kappa obtido pode não refletir a realidade da exatidão de classificação das outras classes (Tso e Mather, 2001). Por isso, decidiu-se, além de gerar o kappa (convencional), gerar também o kappa condicional. Esse procedimento permitiu avaliar se a temporalidade traz melhorias significativas à classificação de uma determinada classe, e saber se a utilização de um conjunto de imagens é compensadora para um mapeamento específico.

Segundo Congalton e Green (1999), o kappa condicional para a classe i é dado pela fórmula (3.14):

$$\hat{k}_{i+} = \frac{n * n_{ii} - n_{i+} * n_{+i}}{n * n_{i+} - n_{i+} * n_{+i}} \quad (3.14)$$

e a variância do kappa condicional é dada por (3.15):

$$\text{vâr}(\hat{k}_{i+}) = \frac{n(n_{i+} - n_{ii})}{[n_{i+}(n - n_{+i})]^3} [(n_{i+} - n_{ii})(n_{i+} * n_{+i} - n * n_{ii}) + n * n_{ii}(n - n_{i+} - n_{+i} + n_{ii})] \quad (3.15)$$

Porém, Congalton e Green (1999) não mencionam que esta fórmula avalia apenas a exatidão do usuário (“user accuracy”) de determinada classe, avaliando o quanto existiu de erro de comissão numa classificação, independentemente da exclusão que tenha ocorrido (ver na Seção 4.1 discussão mais detalhada). Ou seja, numa classificação onde

$n_{ii} \cong n_{i+}$, o valor resultante do kappa condicional é alto; no entanto, esta classificação pode ter um $n_{+j} \gg n_{ii}$, como resultado de uma grande omissão.

Rossiter (2003) lembra que o kappa condicional pode ser calculado por linha (exatidão do usuário) avaliando os erros de comissão, ou por coluna (exatidão do produtor) avaliando os erros de omissão. Dessa maneira, o kappa condicional analisado pelas colunas (exatidão do produtor) e sua variância são dados por:

$$\hat{k}_{+j} = \frac{n * n_{jj} - n_{j+} * n_{+j}}{n * n_{+j} - n_{j+} * n_{+j}} \quad (3.16)$$

$$\hat{v}ar(\hat{k}_{+j}) = \frac{n(n_{+j} - n_{jj})}{[n_{+j}(n - n_{j+})]^3} [(n_{+j} - n_{jj})(n_{+j} * n_{j+} - n * n_{jj}) + n * n_{jj}(n - n_{+j} - n_{j+} + n_{jj})] \quad (3.17)$$

Nesse trabalho calculou-se o kappa condicional pela linha e coluna para analisar se existiu significativa melhora em relação à comissão (“user accuracy”) ou à omissão (“producer reliability”).

CAPÍTULO 4

RESULTADOS E DISCUSSÕES

4.1- Complexidade da Área de Estudo

Como descrito no item 3.2, a área de estudo possui um grande dinamismo de cultivo ocasionado por dois fatores: a irrigação, que flexibiliza a data de plantio das culturas, e os períodos de plantio/colheita da cana-de-açúcar, que são realizados de maneira programada para manter um constante abastecimento das usinas. Para ilustrar a variação fenológica, observa-se na Figura 4.1 a cultura do milho em três diferentes pivôs co-existindo desde o estágio fenológico 1 até o estágio 10.




FIGURA 4.1 – Imagem composição 3B4R5G de 27 de abril de 2002 e fotos do dia 22 de abril. O milho do polígono 10/122 está com 0,3 m de altura e o milho do polígono 10/107 com aproximadamente 1,0 m, enquanto que o milho do polígono 6/27 está pronto para colheita. A numeração dos polígonos é a mesma utilizada no trabalho de campo: m^2 quadrícula/ m^2 talhão.

A conseqüência da variação temporal ilustrada é que, durante a seleção de amostras, ou o usuário define várias subclasses como Medeiros et al. (1996), ou considera todas as amostras em uma única classe – milho - com um desvio padrão muito grande e grande região de confusão entre classes. Outro problema é que a distribuição de freqüência dessa classe abrangente pode não ser unimodal (um pico de freqüência), afastando-se muito do pressuposto de aplicação do algoritmo de máxima verossimilhança (Mather, 1999).

O mapa temático de referência obtido através dos trabalhos de campo nos meses de agosto e abril é ilustrado na Figura 4.2. Utilizou-se esse mapa para rotular 2415 pontos da matriz de confusão.

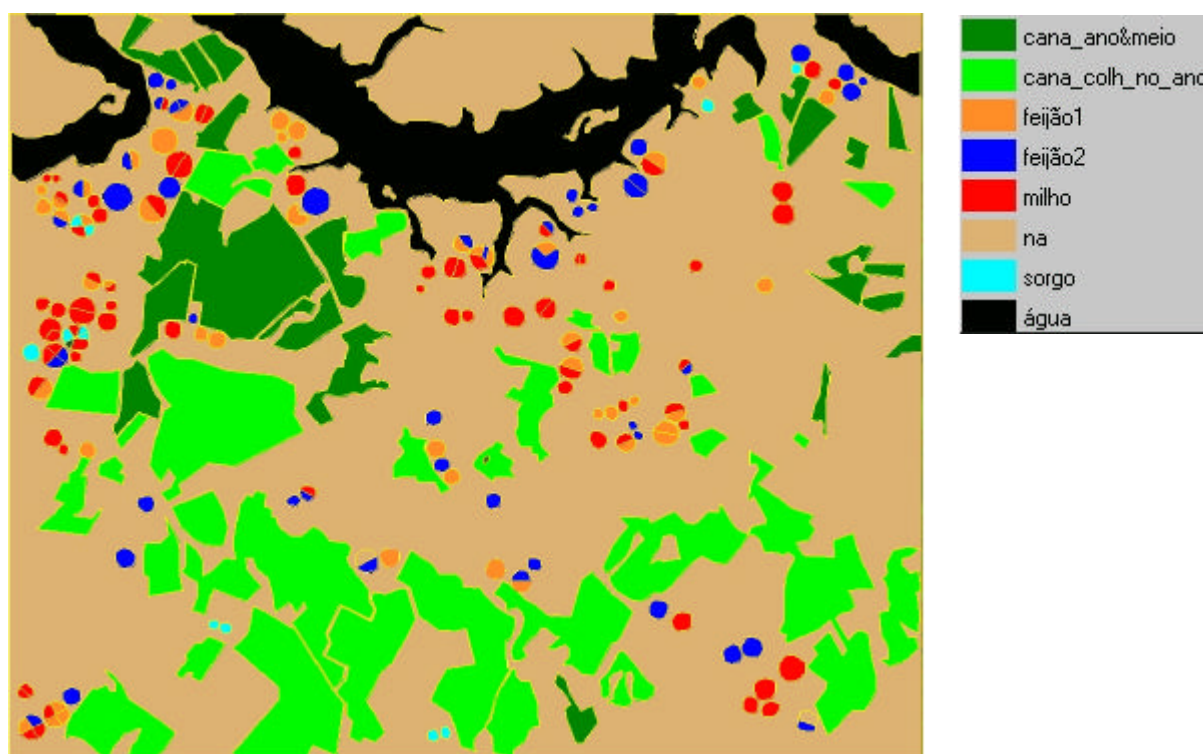


FIGURA 4.2 – Mapa de referência obtido através dos levantamentos de campo de abril e agosto de 2002.

4.2 – Resultados da Correção Atmosférica

A correção atmosférica executada foi realizada na imagem do dia 10 de março, pela excelente qualidade visual e ser um dia de poucos aerossóis. O modelo DOS3 utilizado supõe a transmitância para uma atmosfera sem aerossóis. Como descrito no capítulo anterior, é impossível saber, numericamente, o quanto esta correção foi boa. Fez-se a plotagem dos valores de alguns alvos antes e após a correção e verificou-se a coerência dos valores encontrados (Figura 4.3) antes de iniciar a retificação das imagens. Assumiu-se que essa correção foi suficiente para o trabalho.




FIGURA 4.3 – Comparação dos valores de DN em dosséis de algodão e água antes e após a correção atmosférica.

4.3 – Retificação

A condição de verificação de uma retificação proposta por Hall et al. (1991) é que a diferença dos valores, em número digitais, entre as áreas claras e as áreas escuras da imagem-objeto e da imagem-referência não seja maior do que uma unidade. Atendendo a esta condição, as bases dos gráficos de cada retificação “greenness” versus “brightness” estariam sobrepostas, ou seja, os pontos pseudo-invariantes (de controle radiométrico) teriam o mesmo valor (Figura 4.4).

Desse modo, os valores digitais de água e o solo exposto têm seus valores trasladados para os valores de água e solo exposto da imagem tomada como referência (imagem de

10 de março). Essa transformação é linear e uniforme, ou seja, admite-se que a atmosfera alterou os valores de todos os alvos na mesma magnitude; os alvos que tiveram os seus valores alterados (por exemplo: alvos vegetados) têm a sua magnitude de mudança final (ΔDN) corrigida na mesma magnitude de correção dos alvos de controle radiométrico.

A imagem simulada do dia 01 de agosto foi gerada a partir da média de duas imagens retificadas: 7 (16/07/2002) e 9 (17/08/2002). Como os alvos de controle radiométrico dessas duas imagens têm valores digitais muito próximos ($\Delta DN < 1$), os alvos dinâmicos da imagem resultante assumem valores médios na alteração temporal das imagens.




FIGURA 4.4 – Nuvens de pixels do gráfico “greenness” versus “brighthness” da imagem referência e da imagem objeto.

A Tabela 4.1 ilustra os resultados das diferenças para as áreas claras (Br-Bs) como para as áreas escuras (Dr-Ds) entre a imagem referência (r) e objeto (s) para as nove datas. Todos os valores resultantes da diferença entre Br e Bs, e Dr e Ds foram menor que uma unidade, ou seja, o solo exposto e a água de todas as cenas diferem em menos de um DN em relação à imagem de 10 de março.

TABELA 4.1 - Média e diferença dos alvos claros e escuros entre a imagem referência e as imagens objeto (retificadas).

Imagem Referência				Imagem Objeto 1							
						Br-Bs			Dr-Ds		
Br1	22,4	Dr1	20,6	Bs1	22,1	0,3	Ds1	20,2	0,4		
Br2	30,1	Dr2	19,2	Bs2	29,7	0,4	Ds2	18,7	0,5		
Br3	55	Dr3	10,6	Bs3	54,4	0,6	Ds3	10,2	0,4		
Br4	36,9	Dr4	7,11	Bs4	36,2	0,7	Ds4	6,55	0,56		
Br5	53,8	Dr5	8,75	Bs5	53,2	0,6	Ds5	7,99	0,76		
Br7	47,7	Dr7	9,25	Bs7	47,3	0,4	Ds7	9,01	0,24		
Imagem Objeto 2					Imagem Objeto 3						
		Br-Bs			Dr-Ds			Br-Bs			Dr-Ds
Bs1	22,1	0,3	Ds1	20,2	0,4	Bs1	22,2	0,2	Ds1	20,1	0,5
Bs2	29,5	0,6	Ds2	18,5	0,7	Bs2	29,8	0,3	Ds2	18,6	0,6
Bs3	54,6	0,4	Ds3	10,2	0,4	Bs3	54,6	0,4	Ds3	9,99	0,61
Bs4	36,8	0,1	Ds4	6,91	0,21	Bs4	36,5	0,4	Ds4	7,00	0,11
Bs5	53,3	0,5	Ds5	8,26	0,50	Bs5	53,3	0,5	Ds5	7,84	0,09
Bs7	47,2	0,5	Ds7	8,86	0,39	Bs7	47,2	0,5	Ds7	8,60	0,66
Imagem Objeto 4					Imagem Objeto 5						
		Br-Bs			Dr-Ds			Br-Bs			Dr-Ds
Bs1	21,9	0,5	Ds1	20,2	0,4	Bs1	22,0	0,4	Ds1	21,4	0,2
Bs2	29,5	0,6	Ds2	18,6	0,6	Bs2	29,7	0,4	Ds2	18,7	0,5
Bs3	54,6	0,4	Ds3	9,92	0,69	Bs3	54,3	0,7	Ds3	10,3	0,3
Bs4	36,4	0,5	Ds4	6,53	0,58	Bs4	36,5	0,4	Ds4	6,45	0,66
Bs5	53,2	0,6	Ds5	7,92	0,84	Bs5	53,3	0,5	Ds5	8,30	0,45
Bs7	47,2	0,5	Ds7	8,53	0,72	Bs7	47,2	0,5	Ds7	8,62	0,63

(continua)

TABELA 4.1 - (conclusão).

Imagem Objeto 6						Imagem Objeto 7					
		Br-Bs			Dr-Ds			Br-Bs			Dr-Ds
Bs1	22,0	0,4	Ds1	20,0	0,6	Bs1	22,0	0,4	Ds1	20,0	0,6
Bs2	29,2	0,9	Ds2	18,4	0,8	Bs2	29,7	30,1	Ds2	18,5	0,7
Bs3	54,4	0,6	Ds3	10,2	0,4	Bs3	54,6	0,4	Ds3	10,1	0,5
Bs4	36,2	0,7	Ds4	6,47	0,64	Bs4	36,4	0,5	Ds4	6,94	0,18
Bs5	53,1	0,7	Ds5	8,39	0,36	Bs5	53,3	0,5	Ds5	8,41	0,34
Bs7	47,3	0,4	Ds7	8,60	0,65	Bs7	47,2	0,5	Ds7	8,79	0,46
Imagem Objeto 9						Imagem Objeto 10					
		Br-Bs			Dr-Ds			Br-Bs			Dr-Ds
Bs1	22,0	0,4	Ds1	20,0	0,6	Bs1	21,9	0,5	Ds1	20,1	0,5
Bs2	29,5	0,6	Ds2	18,7	0,5	Bs2	29,5	0,6	Ds2	18,7	0,5
Bs3	54,6	0,4	Ds3	10,3	0,3	Bs3	54,5	0,5	Ds3	10,2	0,4
Bs4	36,4	0,5	Ds4	6,93	0,18	Bs4	36,2	0,7	Ds4	6,91	0,20
Bs5	53,2	0,6	Ds5	8,14	0,62	Bs5	53,2	0,6	Ds5	8,35	0,41
Bs7	47,2	0,5	Ds7	8,74	0,52	Bs7	47,2	0,5	Ds7	8,95	0,31

4.4 – Normalização dos Dados

Como exposto por Bishop (1995), é necessário que os dados de entrada de uma rede sejam normalizados, pois se diferirem em ordens de magnitude a saída da rede pode não expressar igualmente a importância dos mesmos no resultado final. Nos itens seguintes são apresentados os resultados das normalizações dos arquivos de média e desvio padrão.

4.4.1 – Normalização dos Arquivos de Média

Conforme descrito no item 3.11 tomou-se cuidado para que os parâmetros estatísticos média e desvio padrão tivessem a mesma ordem de grandeza. Após gerar as imagens médias através de uma janela 3x3, analisou-se o histograma para as componentes NDVI, b3, b4 e b5, cujos valores máximos foram 249, 205, 220 e 247, respectivamente

e o valor mínimo sempre zero. Dessa maneira, todas as datas, para cada banda espectral, foram normalizadas pela Equação 3.7.

$$x_i = \frac{DN_i - DN_{iMIN}}{DN_{iMAX} - DN_{iMIN}} \quad (3.7)$$

4.4.2 – Normalização dos Arquivos de Desvio Padrão

A normalização pelo procedimento de Rosin (2001) foi necessária porque o histograma de desvio padrão apresentava valores muito discrepantes, com picos de frequência e intensidade (valores de desvio padrão). Conforme descrito, os valores de desvio padrão eram tão baixos que foram multiplicados por 100, uma vez que os polígonos agrícolas eram bastante homogêneos. Os valores de desvio padrão oriundos do interior dos polígonos agrícolas ficavam no pico de frequência do histograma (Figura 4.5 lado A), enquanto que no pico de intensidade (Figura 4.5 lado B) ficavam os valores resultantes de bordas de talhões, rios, estradas. No pico de frequência os valores estavam com uma ordem de grandeza inferior aos arquivos de média. No item 4.6.1 será discutida a influência do desvio padrão na classificação, mas aqui já se descreve que o desvio padrão de uma janela 3x3 não contribuiu com nenhuma informação, sendo, praticamente, um detector de bordas (Figura 4.6). O aumento da janela para 5x5, 7x7 ou 9x9, por exemplo, poderia trazer melhores resultados, porém as áreas irrigadas eram pequenas e muitas vezes subdivididas com até quatro diferentes talhões dentro do mesmo pivô, e uma janela maior seria incompatível com a característica espacial encontrada na região, e levaria a misturas de informações (classes) durante o deslocamento de uma janela NxN.




Figura 4.5 – Histograma resultante do cálculo do desvio padrão de uma janela 3x3. Na porção A do histograma encontram-se as altas frequências de baixo valores provindos de talhões agrícolas. Na porção B, altos valores resultantes de bordas de rios, estradas e talhões.




FIGURA 4.6 – Visualização da imagem ASCII desvio padrão. No interior dos talhões agrícolas o desvio padrão é baixo; apenas os carregadores aumentam o desvio padrão. Em contraste, nas bordas de estradas, talhões e rios o desvio padrão é alto.

Os valores limiares máximos de desvio padrão encontrados para as bandas 3, 4 e 5 e NDVI nas dez datas analisadas foram 2,2099; 2,4300; 3,3209; 3,671; respectivamente. O valor mínimo sempre foi zero. Esses valores foram utilizados na Equação de normalização 3.8. Por esse procedimento, subtraíram-se da matriz os valores de desvio

padrão de baixa frequência e grande valor, tornando os arquivos de desvio padrão com valores menos discrepantes. Observa-se que mesmo multiplicando o arquivo de desvio padrão por 100 e aplicando o processo de limiarização de Rosin (2001), os valores máximos ficaram entre 2-3, reforçando a constatação de homogeneidade interna de um polígono agrícola.

4.5 – Definição das Classes

A análise das amostras temporais obtidas dos polígonos 3x3, oriundas das imagens reflectâncias, permitiu a definição de oito classes, das quais seis são agrícolas e duas não. As classes agrícolas foram: cana colhida no ano, cana de ano e meio, feijão 1, feijão 2, sorgo e milho. As classes não-agrícolas incluem a água e não-agrícola (não-cultivado): fragmentos florestais e cidades. Na análise para definição das classes somente o perfil temporal do NDVI foi utilizado. No entanto, apresenta-se a seguir, além do NDVI, a temporalidade das bandas 3, 4 e 5, uma vez que todas foram utilizadas na classificação. Ilustram-se nas Figuras 4.7 à 4.12, e nas Figuras 4.14, 4.15 e 4.17 perfis temporais. Esses perfis foram construídos utilizando-se função gráfica de suavização ilustrando de modo contínuo os dados discretos. Em cada gráfico exibem-se cinco linhas (vetores) que foram amostradas do conjunto de 100 vetores utilizados no treinamento da rede neural.

4.5.1 – Perfil Espectro-Temporal da Cultura de Feijão

Na região plantam-se até duas safras de feijão irrigado por ano. A classe - Feijão1 – foi definida como o feijão da primeira safra e a classe –Feijão 2 – da segunda. Esta separação parece um contra-senso com a metodologia proposta, uma vez que é proposta a discriminação temporal de uma cultura ocorrendo esta em qualquer intervalo de tempo dentro de um período analisado e não separá-la previamente em diferentes classes de acordo com o período próximo de ocorrência. A decisão foi tomada porque um vetor que represente o padrão temporal de uma cultura de ciclo mais curto está sujeito a desvantagens (variações) em relação a uma cultura de ciclo mais longo (Figura 4.7). Para elucidar este ponto analisa-se o gráfico de temporalidade de NDVI na Figura 4.7, que exibe 5 amostras (linhas) coloridas obtidas do conjunto de 100 vetores utilizados para treinar a rede neural:




FIGURA 4.7 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe feijão 1. Cada linha colorida representa uma amostra obtida do conjunto de 100 vetores utilizados no treinamento da RNA.

No gráfico temporal de NDVI, observa-se que o ciclo do feijão durou aproximadamente 80 dias (do dia 110 ao dia 190). Então, cinco imagens (80/16¹⁵) seriam necessárias para descrever o vetor temporal da cultura de feijão. Entretanto, após o fim do ciclo (intervalo azul), uma outra cultura (intervalo vermelho) poderia ser plantada. Então o vetor temporal – “feijão”- de 10 datas poderá conter parte do ciclo de outra cultura, como feijão, milho ou pousio, por exemplo. O próprio vetor temporal de feijão terá a variância inerente dentro do intervalo do ciclo, ocasionada pelas práticas agrícolas de diferentes adubações, plantio convencional ou não, além das variações pelos tipos (hábitos) de crescimentos que podem ser tipo I, II ou III. Dessa maneira, o padrão

¹⁵ Resolução temporal do sensor ETM+

temporal feijão 1 foi definido como o ciclo do feijão e um ruído a posteriori, e o padrão temporal feijão 2, como um ruído anterior e o padrão feijão a posteriori.

O padrão de resposta temporal da classe feijão 2 é ilustrado na Figura 4.8 Assim como na classe feijão 1, o padrão temporal do NDVI caracteriza-se por uma ascensão rápida do NDVI, a partir do dia do ano 160, um período de pico com duração curta e depois a entrada do período de senescência.




FIGURA 4.8 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe feijão 2. Cada linha colorida representa uma amostra obtida do conjunto de 100 vetores utilizados no treinamento da RNA.

A ascensão rápida do NDVI, aproximadamente entre os dias 160 a 190, tem forte relação com a variação de IAF. Entre os hábitos de crescimento descritos no item 2.9.3, apenas o TIPO IV (hábito trepador/tutorado) não é cultivado, pois se trata de cultivos de hortas domésticas, não utilizados em plantações comerciais. O rápido incremento de IAF pode ser analisado pela planta do tipo III, que é o ciclo mais longo exetando-se o

tipo IV. O feijoeiro inicia a fase reprodutiva (R5) próximo aos 30 dias, e nessa fase o feijoeiro já possui uma quantidade grande de folhas pois terminou a fase vegetativa (Figura 2.26). Este rápido incremento aliado ao espaçamento médio de cultivo de 0,5 m, com média de 12 plantas por metro, causa uma alta densidade de folhas por metro quadrado, o que explica o rápido incremento de IAF e, conseqüentemente, do NDVI. De acordo com a Figura 2.26, para as plantas com hábito de crescimento I, II e III, existe pouco mais de 20 dias da fase R5 à R8, quando se inicia a senescência e o desfolhamento das plantas.

Como era esperado, observa-se próximo ao dia do ano 160 a queda do sinal do vermelho (ETM+3), e o aumento do sinal de infravermelho próximo (ETM+4). Observa-se ainda no gráfico de temporalidade de NDVI, as variações existentes antes do dia 160, o que ilustra a complexidade de atividades pré-cultivo da cultura feijão que podem existir em diferentes talhões agrícolas. Exemplos mais detalhados das variações pré cultivo de feijão 2 podem ser observados nas Figuras 4.9a e 4.9b que ilustram as variações do perfil temporal do NDVI. Esses perfis foram obtidos de dois polígonos amostrais diferentes: o perfil (a) foi extraído de um polígono cuja cultura anterior era feijão, e no polígono (b) a cultura anterior era milho. Esses ruídos indesejados trazem uma variância que não pertence ao padrão temporal feijão 2 que se inicia aproximadamente após o dia 150.




FIGURA 4.9 – Perfis temporais do NDVI oriundos de dois polígonos de feijão 2 cuja cultura anterior era feijão (a) e milho (b). Cada linha colorida representa uma amostra obtida do conjunto de 100 vetores utilizados no reinamento da RNA.

4.5.2 – Perfil Espectro-Temporal da Cultura de Milho

O perfil temporal da cultura do milho descrito pelo NDVI (Figura 4.10) caracteriza-se por uma ascensão lenta, um patamar de estabilidade (saturação) mais longo do que a cultura do feijão e depois uma queda do seu valor retratando o período de senescência. O patamar de saturação dura do estágio 5 (primeiras bonecas) até o início do estágio 8 (fim do acúmulo de matéria seca), com aproximadamente 60 dias de máximo vigor. Para o milho, a ascensão do valor do NDVI até a saturação ocorre do dia 100 até aproximadamente ao dia 150 (estádio 4), e é mais gradual do que a ascensão do NDVI na cultura do sorgo (Figura 4.11). Um outro fator a ser analisado é a densidade de plantas por área: na região, o milho é plantado num espaçamento de 0,9 m entre as linhas e com uma densidade de plantio na linha que oscila de 5 a 7 plantas por metro. A Figura 4.10 ilustra a temporalidade do NDVI e das bandas 3, 4 e 5 para o milho.




FIGURA 4.10 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe milho. Cada linha colorida representa uma amostra obtida do conjunto de 100 vetores utilizados no reinamento da RNA.

4.5.3 – Perfil Espectro-Temporal da Cultura do Sorgo

O perfil temporal de variáveis espectrais para a cultura do sorgo é caracterizado por uma ascendência abrupta do NDVI e um longo patamar de estabilização. Isso pode ser explicado porque o sorgo é plantado num espaçamento entre fileiras de apenas 0,45 m, numa densidade de 14 plantas por metro, e, no estágio 3, que ocorre ao redor de 30 dias após o plantio, o sorgo já tem de 7 a 10 folhas. Como mencionado no item 2.8, o IAF pode estar tendo incrementos mas o NDVI pouco responde a valores de IAF maiores que 3. A Figura 4.11 ilustra a temporalidade do NDVI e das bandas 3, 4 e 5 do sensor ETM+ para a cultura do sorgo.




FIGURA 4.11 – Perfis temporais de NDVI e bandas 3,4 e 5 ETM+ para a classe sorgo. Cada linha colorida representa uma amostra obtida do conjunto de 100 vetores utilizados no reinamento da RNA.

4.5.4 – Perfil Espectro-Temporal da Cultura da Cana-de-Açúcar

4.5.4.1 – Cana Colhida no Ano

A cana de ano é a cana plantada de setembro a outubro do ano anterior. O comportamento do NDVI que será descrito foi observado em talhões de cana de ano e cana de ano e meio plantados no ano anterior, assim como em talhões de cana soca (rebrotas). Desse modo, a classe “cana colhida no ano”, agrupa os talhões com cana de ano e a cana de ano e meio plantados no ano anterior, assim como a cana soca.

Após as chuvas de verão que ocorrem de novembro a janeiro, estes talhões estão com boa capacidade de vigor, mas ao longo do ano este vigor tende a cair durante o período de seca que ocorre no outono/inverno. A Figura 4.12 ilustra a temporalidade do NDVI e das bandas 3, 4 e 5. A característica geral do NDVI é uma curva com um lento gradiente descendente ao longo do ano. Após o término do período chuvoso, com a consequente entrada da estação mais seca, a cana entra em maturação e ocorre a concentração de sacarose.




FIGURA 4.12 – Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para a classe cana colhida no ano. Cada linha colorida representa uma amostra obtida do conjunto de 100 vetores utilizados no reinamento da RNA.

Deve-se ter cautela na análise do gráfico de NDVI em relação ao gráfico de cana ano (12 meses) da Figura 2.27. Aquele gráfico representa, na linha azul, o crescimento e, na linha verde, o período de amadurecimento de um dossel já desenvolvido em tamanho. No amadurecimento, que ocorre durante um período mais seco, ocorre perda de clorofila e água, mais evidenciadas nas bandas 3 e 5, por volta do dia do ano 180 (Figura 4.12). Como boa parte da radiação detectada pelo sensor é influenciada pelo topo do dossel, a interpretação dos índices de vegetação deve ser cautelosa, uma vez que, no caso do dossel de cana, um valor baixo do índice pode não implicar num dossel de baixo porte, mas num dossel adulto, em processo de concentração de sacarose numa fase seca do ano (Figura 4.13).



FIGURA 4.13 – Foto de campo ilustrando as folhas senescentes do dossel de cana adulta.

Conforme comentado, a cana pode ser colhida de maio a novembro, dependendo da variedade e data de corte do ano anterior.

Após a análise visual dos perfis temporais decidiu-se treinar a rede com talhões que foram colhidos em novembro (Figura 4.12), ou seja, sem interferência antrópica. A última data da seqüência utilizada nesse estudo é do dia 02 de outubro. Devido à possibilidade de corte ao longo de praticamente sete meses, o padrão temporal da cana é um dos mais complexos e de difícil definição. Analisando apenas o NDVI observa-se na Figura 4.14 algumas variações temporais do índice em talhões colhidos nos meses de junho e julho. Essa queda brusca do NDVI pode ocorrer ao longo de sete meses; e a ascensão do perfil, indicando a rebrota pode ocorrer com diferentes intensidades tornando a variância do padrão temporal muito grande.




FIGURA 4.14 – Variações do NDVI para talhões de cana-de-açúcar colhidos antes de novembro. Cada linha colorida representa um vetor espectro-temporal.

Além do corte da cana ser escalonado, existem outros fatores que adicionam variabilidade temporal, como a maneira de colher e as práticas culturais após a colheita. A cana pode ser colhida manualmente, após uso do fogo, ou mecanicamente. As Figuras 4.15 e 4.16 ilustram, respectivamente, os perfis temporais e as imagens para um talhão colhido mecanicamente. As Figuras 4.17 e 4.18 ilustram os perfis de NDVI e as imagens do talhão que, após a colheita manual, teve os restos de palha incorporados ao solo. A Figura 4.16 ilustra, em destaque com a seta amarela, o talhão de cana de onde se extraíram os perfis temporais. Nota-se na Figura 4.15 um aumento das curvas espectrais para as bandas 3 e 5 resultantes da palha sobre o solo vistas de cor azulada na Figura 4.16. Este aumento não é observado na Figura 4.17 para as bandas 3 e 5 uma vez que houve operação de incorporação da palhada visualizado na Figura 4.17 (em destaque com seta amarela) e confirmado em trabalho de campo.

Devido à enorme variabilidade espectro-temporal de talhões colhidos antes da última data analisada (02 de setembro), o vigor da rebrota e diferentes tipos de colheita que alteram em muito a resposta espectral (Figuras 4.15 e 4.17), escolheram-se, para representar a classe temporal cana colhida no ano, os talhões que seriam colhidos em outubro e novembro (Figura 4.12), pois são talhões sem intervenção antrópica no período analisado.





FIGURA 4.15 - Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para cana colhida mecanicamente. Cada linha colorida representa um vetor espectral-temporal.



11 de abril (101) 27 de abril (117) 13 de maio (133) 29 de maio (149) 14 de junho (165)
 30 de junho (181) 17 de julho (197) 01 agosto (simulada) 17 de agosto (229) 02 de setembro
 FIGURA 4.16 – Composição 3B4R5G destacando-se um talhão de cana colhido mecanicamente. Entre parênteses o dia do ano.




FIGURA 4.17 - Perfis temporais de NDVI e bandas 3, 4 e 5 ETM+ para cana colhida mecanicamente com remoção da palhada. Cada linha colorida representa um vetor espectro-temporal.




FIGURA 4.18 – Composição 3B4R5G destacando com seta amarela o talhão de cana colhido manualmente com incorporação da palhada.

4.5.4.2 – Cana de Ano e Meio

Esta cana é plantada de janeiro a março para ser colhida no inverno do ano seguinte. Atualmente, recomenda-se o plantio nesse período pela menor incidência de pragas e concorrência com ervas daninhas. Ao contrário da cana de ano, em que o valor de NDVI é alto no início do período analisado, observa-se na Figura 4.19 um valor baixo de NDVI, que é levemente ascendente ao longo do ano, tendo durante o inverno seco uma queda de vigor da mesma maneira que observado na cana de ano. A possível explicação para um início de queda de vigor mais tardio que a cana de ano é que se trata de cana crescendo com máximo¹⁶ vigor, e desenvolvendo-se a partir de colmos com reserva nutritiva.




FIGURA 4.19 – Perfis temporais de NDVI e bandas 3,4 e 5 ETM+ para a classe cana de ano e meio.

¹⁶ Com os cortes sucessivos, ocorre uma queda progressiva de vigor e produtividade.

4.6 – Discriminação e Identificação

Os perfis temporais descritos anteriormente permitem descrever de maneira mais característica uma dada cultura onde, através de um perfil, pode-se identificar a cultura cultivada. Hall e Badhwar (1987) definem os termos discriminação e identificação e o que cada uma das ações exigem. No trabalho, ao utilizarem o termo “separabilidade” e não “discriminação”, eles afirmam que a separabilidade requer que a variância dos valores característicos de uma classe seja significativamente menor que a variância entre classes. Para que ocorra a identificação, essa ação exige que a relação dos valores característicos entre as classes seja previsível, ou seja, que a feição (perfil temporal) típica a dada cultura seja associada ao IAF e ao estágio fenológico. Segundo os autores, a análise temporal permite satisfazer as duas condições: separabilidade e identificabilidade.

Na literatura existem usos do termo identificação, quando, na verdade, analisados pela definição de Hall e Badhwar (1987), existiu apenas discriminação de classes: por exemplo, Lobell e Asner (2003) utilizam o termo identificação quando conseguiram uma boa discriminação de milho e trigo através de uma única imagem ETM+. Essa discriminação foi favorecida pelo estágio fenológico homogêneo intraclasse e heterogêneo entre classe. O milho estava senescendo e o trigo cobria 80% do solo.

Os perfis temporais ilustrados até aqui ilustram feições típicas de culturas agrícolas para uma determinada área de estudo, o que levou à identificabilidade para um determinado grupo de culturas. Porém, deve-se ressaltar que mesmo os perfis temporais não são “assinaturas espectro-temporais” ou “assinaturas fenológicas”. O termo assinatura lembra um traço gráfico, imutável e exclusivo, mas a análise temporal está sujeita a maiores variações pois, além dos efeitos direcionais da geometria de radiação (Jackson et al., 1990), o efeito do solo de fundo é um fator causador de variância na resposta temporal (Huete, 1988).

Quanto ao perfil temporal deve-se analisar se ele é mais característico para as culturas em termos de espectro-temporalidade descrito nas bandas ou fenologia descrito no índice de vegetação. Antes dessa discussão, deve-se analisar grandezas e conceitos já consagrados na literatura, como a reflectância espectral. A reflectância espectral de

muitas culturas é descrita para as folhas com medidas obtidas em condições de laboratório (Gausman, 1985; Bowker et al., 1985), e às vezes para dosséis, com medições em campo (Bowker et al., 1985).

As curvas temporais ilustradas para as bandas 3, 4 e 5, apresentadas nesse estudo, foram obtidas de sensores orbitais com todas as interferências inerentes a este nível de aquisição de dados, o que dificulta a obtenção da reflectância da superfície. A espectro-temporalidade de determinada cultura deve ser descrita com radiômetros de campo em condições controláveis e mensuráveis dos fatores de cena envolvidos. Ao contrário da curva espectral de uma folha ou de um dossel pleno (Bowker et al., 1985), a curva espectro-temporal tem grande influência espectral do solo (substrato) onde o dossel se desenvolve (Fig. 4.15 e 4.17); assim, uma descrição do substrato onde a cultura se desenvolve deve acompanhar a curva espectro-temporal.

Como a influência espectral do solo na fase inicial do ciclo é grande (Huete, 1988), a generalização temporal, descrita por Pax-Lenney et al. (2001), na qual se objetiva fazer uma RNA treinada em um determinado ano classificar em anos futuros, teria que ser feita para a mesma área ou área de solos espectralmente semelhantes.

Quanto à “assinatura fenológica” descrita pelos índices de vegetação, estas são respostas mais típicas no decorrer do ciclo, apesar da influência de fatores indesejáveis. Os índices de vegetação minimizam mas não eliminam a influência dos diferentes substratos (Huete, 1988; Qi et al., 1994); no entanto, esta minimização tornou as curvas temporais mais características para as culturas.

Na região, um agravante à metodologia são as plantas daninhas (ou plantas indesejáveis), comuns em alguns pivôs. Elas causam um “ruído” de IAF que altera a resposta espectro-temporal pura das culturas levando a erros de classificação digital. No entanto, erros ocorreram até mesmo em nível de campo: durante o segundo trabalho de campo, inicialmente foi anotado na planilha a cultura de feijão para um certo pivô, descobriu-se *a posteriori* que a cultura plantada era milho, e que estava com 10 cm de altura. Os pés de feijão existentes, com aproximadamente 25 cm, não estavam alinhados e eram resultado de perda de colheita. Portanto, o sucesso da metodologia proposta está estritamente relacionado a boas e adequadas práticas agronômicas.

4.7 – Avaliação das Classificações

As avaliações das classificações foram feitas através de avaliações quantitativas expressas na diferença significativa, ou não, do índice kappa e do kappa condicional. Também fizeram-se análises visuais qualitativas, uma vez que ruídos ou outras características do mapa temático gerado não são bem retratados no valor do índice kappa.

Quanto ao kappa condicional procurou-se analisar a exatidão do usuário e do produtor, pois alguns bons e significativos valores isolados de kappa (usuário ou produtor) não são indicadores absolutos de sucesso da metodologia empregada.

4.7.1 – Avaliação dos Parâmetros Estatísticos

A primeira classificação foi feita utilizando-se a RPE com um vetor de 80 números para cada posição espacial, que era composta de quatro componentes (NDVI, b3, b4 e b5) em 10 datas e dois parâmetros estatísticos-média e desvio padrão - para descrever o padrão temporal das culturas. Na Figura 4.20 observa-se a existência de muitos erros de classificação, principalmente para a classe sorgo, que não existe fora dos sistemas de pivôs. As classes cana de ano e cana de ano e meio praticamente não existiram ou estavam muito ruidosas. A qualidade numérica dessa classificação, como de todas as outras, será mais bem expressa em termos do índice kappa, sua variância e significância.




Figura 4.20 – Resultado da classificação com a rede RPE com arquivos de média e desvio padrão do NDVI e das bandas 3, 4 e 5 nas 10 datas. Rede 80-70-8¹⁷.

Após essa classificação decidiu-se excluir o desvio padrão temporal do NDVI, deixando as bandas 3, 4 e 5 contribuírem com a média e o desvio padrão, e o NDVI somente com a média (indicador de fenologia). O resultado da nova classificação é exibido na Figura 4.21. Nota-se uma melhora na classificação, com diminuição da confusão da classe sorgo, e as classes parecem ficar mais definidas.

¹⁷ Rede 80-70-8. Para cada posição (x, y) da imagem existiam quatro variáveis (NDVI, b3, b4 e b5), em 10 datas e dois parâmetros estatísticos (\bar{x} e s) perfazendo um vetor de 80 números; setenta neurônios na camada oculta foi um número arbitrado e oito na camada de saída são referentes às oito classes.




FIGURA 4.21 – Resultado da classificação com a rede RPE com arquivo de média e desvio padrão das bandas 3, 4 e 5, com o arquivo de média do NDVI nas 10 datas. Rede 70-70-8¹⁸.

No item 4.4.2 discutiu-se a homogeneidade do polígono agrícola, e esta homogeneidade acaba sendo maior dentro de um pequeno espaço, como uma janela 3x3. A normalização de Rosin (2001) trouxe o desvio padrão do interior dos talhões agrícolas para a mesma ordem de grandeza da média. Porém, aparentemente, esse procedimento realçou variações que não contribuíram na caracterização da classe e sim “ruídos”, como possíveis falhas de plantio, ruído de detector, encharcamento de solo ou qualquer outro fator que alterasse a homogeneidade da janela 3x3 pixels. Como o tamanho dos talhões é pequeno, o aumento da janela não é a solução ideal. O desvio padrão poderia ser utilizado na classificação com janelas maiores numa região com grandes talhões, ou após uma segmentação de talhões onde a estatística de uma cultura fosse mais

¹⁸ A entrada dessa rede tem 70 neurônios com uma redução de 10 números no vetor temporal, ou seja, sem o desvio padrão do NDVI nas 10 datas.

representativa. Na última classificação de teste de parâmetros utilizaram-se somente os arquivos de média, cujo resultado é visualizado na Figura 4.22.

Observa-se que o aspecto ruidoso da imagem temática diminuiu e resultou em uma melhor definição das classes.




FIGURA 4.22 – Resultado da classificação com a rede RPE com arquivo de média e das bandas 3, 4 e 5 e do NDVI nas dez datas. Rede 40-70-8.

Na Tabela 4.2 observa-se a análise do kappa das classificações temporais derivados das redes RPE. Nota-se também o valor da estatística Z e o nível de significância (p) encontrado, comparando-se a a terceira classificação com a primeira e a terceira classificação com a segunda. Observa-se que a rede 40-70-8 produziu resultado muito melhor que a rede 80-70-8, sendo que essa exatidão é significativa ao nível de 5%. Por outro lado, a análise comparativa da rede 40-70-8 com a rede 70-70-8 mostra que a a diferença entre as duas não foi significativa. Uma análise visual mostra que a rede 40-70-8 proporcionou uma classificação menos ruidosa; esse ruído não é detectado no índice kappa. Outra vantagem é que os arquivos de média têm praticamente a metade do

tamanho dos arquivos com média e desvio. O arquivo com médias e desvios tem as dimensões de 1087x102480 resultando num arquivo ASCII de aproximadamente 1 Gb.

TABELA 4.2 - Avaliação estatística do índice kappa resultante da classificação com a rede RPE temporal utilizando dados de média e desvio padrão do NDVI e das bandas 3, 4 e 5 (classificação 1), média e desvio padrão excetuando-se o desvio do padrão do NDVI (classificação 2), e a rede treinada só com arquivos de média (classificação 3).

Classificação	Arquitetura	\hat{k}	$v\hat{a}r(\hat{k})$	Análise	Z	p
1	80-70-8	0,30518	0,01683	3 vs 1	1,7852*	0,037
2	70-70-8	0,61573	0,01587	3 vs 2	0,0583NS	0,476
3	40-70-8	0,62607	0,01548			

NS – Não significativo, * $p < 0,05$; ** $p < 0,01$

4.7.2 – Avaliação da Temporalidade

4.7.2.1 – Rede Neural com Algoritmo de Retropropagação do Erro

O valor de kappa de 0,62607 obtido com a rede 40-70-8 (Tabela 4.2) treinada com os arquivos de média não é um valor baixo. No entanto, Fidalgo (1995) lembra que não existe fundamentação teórica para indicar os níveis mínimos de aceitação desse índice cujo uso inicial era análise de diagnósticos clínicos. A classificação digital da área é um desafio, e não existe preocupação quanto aos valores absolutos e sim quanto ao ganho de melhoria na classificação que os parâmetros estatísticos, a temporalidade ou algoritmos de RNA podem proporcionar. A Tabela 4.3 resume o desempenho da rede RPE na classificação temporal em relação à classificação de única data. Embora somente em cinco casos a classificação temporal tenha superado as classificações espectrais ao nível de significância de pelo menos 5%, em todas as análises ela foi bastante superior, mostrando que analisar um pixel agrícola num contínuo temporal é muito melhor do que a análise em qualquer fase fenológica única. Um outro resultado que reforça a superioridade da análise espectro-temporal em relação à análise espectral uni-temporal é que, nas classificações espectrais (única data) a RNA precisa de aproximadamente 5 ou 6 mil épocas para serem treinadas mas, com a utilização da temporalidade, a RNA tem um rápido decréscimo do EMQ, sendo treinada com apenas

150 épocas. Este rápido treinamento mostra que o vetor espectro-temporal caracteriza melhor as culturas agrícolas do que somente o vetor espectral (Gleriani et al., 2004).

Como ilustração da classificação simples, observa-se na Figura 4.23 o resultado da quinta data, que resultou no maior valor de kappa (0,44609), que contém muito erro com relação à classe feijão 2.

TABELA 4.3 - Avaliação estatística do índice kappa resultante da classificação com a rede de RPE temporal em relação às classificações de retropropagação com única data.

Data	Arquitetura	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1	4-9-8	0,36612	0,01704	11 vs 1	1,44NS	0,074
2	4-9-8	0,36099	0,0176	11 vs 2	1,45NS	0,072
3	4-9-8	0,39648	0,01758	11 vs 3	1,26NS	0,103
4	4-9-8	0,30348	0,01729	11 vs 4	1,78*	0,037
5	4-9-8	0,44609	0,01695	11 vs 5	0,99NS	0,158
6	4-9-8	0,28504	0,01717	11 vs 6	1,88*	0,029
7	4-9-8	0,36811	0,01674	11 vs 7	1,43NS	0,075
8	4-9-8	0,25877	0,01542	11 vs 8	2,08*	0,0185
9	4-9-8	0,32811	0,01708	11 vs 9	1,65*	0,049
10	4-9-8	0,29421	0,0181	11 vs 10	1,81*	0,035
11/temporal	40-70-8	0,62607	0,01548			

NS – Não significativo, * p<0,05, **p<0,01




Figura 4.23 - Resultado da classificação da rede de RPE para a quinta data.

4.7.2.2 – Função de Base Radial (FBR)

Na Tabela 4.4 apresenta-se o desempenho da rede FBR para a classificação temporal em comparação com as demais classificações com única data. Novamente, a análise temporal definiu e discriminou melhor as classes. Somente em quatro situações a análise comparativa entre os dois modos de classificação não são significativamente diferentes pelo menos ao nível de 5%; porém, também nesses casos o kappa da análise temporal é maior.

As Figuras 4.24 e 4.25 ilustram a classificação temporal com a FBR e a segunda classificação que foi a que apresentou maior valor de kappa com uma única data.

TABELA 4.4 - Avaliação estatística do índice kappa resultante da classificação com a rede FBR temporal em relação às classificações FBR com única data.

Data	Arquitetura	\hat{k}	$\text{var}(\hat{k})$	Análise	Z	p
1	4-9-8	0,25412	0,01831	11 vs 1	1,702*	0,0443
2	4-9-8	0,3593	0,01853	11 vs 2	1,136NS	0,1279
3	4-9-8	0,33536	0,01855	11 vs 3	1,263NS	0,1032
4	4-9-8	0,28037	0,01832	11 vs 4	1,561NS	0,0592
5	4-9-8	0,27408	0,01779	11 vs 5	1,607NS	0,0540
6	4-9-8	0,21605	0,01769	11 vs 6	1,928*	0,0269
7	4-9-8	0,25371	0,01637	11 vs 7	1,753*	0,0397
8	4-9-8	0,20422	0,01517	11 vs 8	2,063*	0,0195
9	4-9-8	0,23045	0,01616	11 vs 9	1,887*	0,0295
10	4-9-8	0,19893	0,01732	11 vs 10	2,026*	0,0214
11/temporal	40-70-8	0,57252	0,01669			

NS – Não significativo, * p<0,05, **p<0,01




Figura 4.24 - Resultado da classificação temporal com a rede FBR .




FIGURA 4.25 - Resultado da classificação da rede FBR para a segunda data.

4.7.2.3 – Classificador por Máxima Verossimilhança (MaxVer)

Com relação à classificação temporal, o classificador Máxima Verossimilhança não produziu resultados tão bons quanto os classificadores de redes neurais. Somente em duas datas (oitava e décima) a classificação temporal foi significativamente melhor a nível 5% que a classificação de uma única data (Tabela 4.5).

As Figuras 4.26 e 4.27 ilustram a classificação temporal MaxVer e a melhor classificação de uma única data (segunda) que resultou num kappa de 0,3294. Na Figura 4.26 observa-se a grande confusão ocorrida com a classe milho, que aparece muito nas áreas onde os dados de referência indicam presença de cana colhida no ano e cana de ano e meio. Na Figura 4.26 a classe feijão2 que aparece pode ser palha, solo ou a combinação que produz repostas semelhantes que levam o classificador a tomar as decisões observadas. Sabe-se que a classe feijão2 começa aparecer aproximadamente da quinta data em diante.

TABELA 4.5 – Avaliação estatística do índice kappa resultante da classificação MaxVer temporal em relação às classificações MaxVer com única data.

Data	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1	0,26916	0,01854	11 vs 1	0,7479NS	0,227
2	0,32945	0,017	11 vs 2	0,4284NS	0,334
3	0,3173	0,01877	11 vs 3	0,4832NS	0,314
4	0,2299	0,01743	11 vs 4	0,9783NS	0,163
5	0,2372	0,01732	11 vs 5	0,9398NS	0,173
6	0,23449	0,01412	11 vs 6	1,006NS	0,157
7	0,17214	0,01671	11 vs 7	1,314NS	0,094
8	0,09326	0,01662	11 vs 8	1,760*	0,039
9	0,19543	0,01815	11 vs 9	1,157NS	0,123
10	0,19215	0,000116	11 vs 10	1,742*	0,040
11/temporal	0,4060	0,01495			

NS – Não significativo, * p<0,05, **p<0,01




FIGURA 4.26 – Classificação temporal realizada com o classificador MaxVer.




FIGURA 4.27 – Resultado da classificação MaxVer para a segunda data.

4.7.3 – Desempenho dos Classificadores

Outro objetivo desse trabalho, foi fazer uma análise comparativa dos classificadores (algoritmos), que é ilustrada na Tabela 4.6. Nessa tabela tem-se a análise estatística do kappa resultante das classificações temporais de redes de retropropagação em relação à rede FBR e ao classificador MaxVer.

O resultado da rede com algoritmo de retropropagação (RPE) teve valor de kappa maior do que do classificador MaxVer, mas a diferença na classificação não alcançou os 5% de significância. A rede FBR tem um desempenho bastante similar à rede de retropropagação, e a diferença não foi estatisticamente diferentes. Uma única classe mal classificada, como o milho no MaxVer, por exemplo, não provocou uma queda tão acentuada no índice kappa, o que mostra a necessidade de o analista observar a distribuição e a conformação espacial da classificação, ou seja, apenas os números podem não traduzir quão boa foi uma classificação, como bem demonstram as Figuras 4.22, 4.24 e 4.26.

TABELA 4.6 - Avaliação estatística do índice kappa resultante das classificações temporais com o MaxVer e as redes FBR e RPE.

Classificador	Arquitetura	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1 – MaxVer	-	0,4063	0,01495	3 vs 1	1,2613NS	0,1035
2 – FBR	40-70-8	0,57252	0,01669	3 vs 2	0,2985NS	0,3826
3 – RPE	40-70-8	0,62607	0,01548			

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

4.7.4 – Tolerância a Dados Falhos

Uma das grandes vantagens das redes neurais é a tolerância a dados falhos. Bishop (1995) relata que se a quantidade de padrões completos for suficientemente grande e a proporção dos padrões afetados por dados perdidos for pequena, esses padrões falhos devem ser descartados. No entanto, quando existem poucos padrões para serem descartados ou quando a proporção dos vetores falhos é grande, faz-se necessário fazer o uso da informação potencialmente disponível nos vetores (padrões) incompletos.

Entre os vários métodos heurísticos propostos, o autor cita a substituição da valores perdidos pela média dos valores correspondentes nos padrões onde eles forem disponíveis. Esse exemplo em sensoriamento remoto aconteceria no caso de um ruído localizado na imagem, onde as substituições dos dados perdidos seriam feitas pela média dos valores de onde eles fossem disponíveis.

No caso de perda de imagem por presença de nuvens, pode ocorrer perda parcial da imagem com possibilidade de preenchimento dos vetores com dados de áreas limpas. Porém, optou-se pela simulação mais drástica de perda total. Os dados de preenchimento foram estimados das cenas precedentes e subseqüentes. Um dos objetivos futuros é analisar a pontencialidade da rede em generalizar classificações futuras sem a execução de novos treinamentos, assim sendo, a rede com entrada de 40-70-8 necessitará de 10 valores médios temporais do NDVI e das três bandas no arquivo de entrada. Caso não existam terão que ser simulados.

Por isso, na presente pesquisa, falhas foram simuladas, os quais foram simulados com as médias entre a imagem anterior e a posterior à imagem faltante, para manter o tamanho da entrada do vetor (40 números). O resultados da comparação da primeira e segunda

falhas com a rede de retropropagação (Tabela 4.7), assim como a primeira e segundas falhas com a rede FBR (Tabela 4.8) mostram que, apesar de as classificações tornarem-se ruidosas (Figuras 4.28 e 4.29), o índice kappa não teve queda significativa em nenhuma das simulações em relação ao conjunto completo de imagens.

Na Tabela 4.8, o resultado da simulação de dados falhos, principalmente na segunda simulação mostra uma diminuição do índice kappa, embora esta diferença não seja significativa ao nível de 5%.

TABELA 4.7 – Avaliação estatística do índice kappa resultante da classificação da rede RPE em duas situações: com dados completos e duas falhas simuladas.

Classificador	Arquitetura	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1 – 1ª falha	40-70-8	0,49644	0,01666	3 vs 1	0,723NS	0,2348
2 – 2ª falha	40-70-8	0,52323	0,01673	3 vs 2	0,444NS	0,2833
3 – RPE	40-70-8	0,62607	0,01548			

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Odenweller e Johnson (1984), ao analisarem os perfis temporais do índice “greenness”, relatam que duas imagens, em períodos chaves do ciclo, seriam suficientes para a identificação da soja e do milho. No entanto, os autores relatam que, caso ocorra perda de momentos chaves do ciclo, características importantes para discriminação podem não ser detectadas. Nas Figuras 4.28 e 4.29 nota-se o desaparecimento da classe sorgo por provável desaparecimento da ascensão brusca da sua resposta espectro-temporal existente na Figura 4.11, ocasionado pela operação de média.

TABELA 4.8 - Avaliação estatística do índice kappa resultante da classificação da rede FBR em duas situações: com dados completos e duas falhas simuladas.

Classificador	Arquitetura	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1 – 1ª falha	40-70-8	0,46605	0,01557	3 vs 1	0,5927NS	0,2766
2 – 2ª falha	40-70-8	0,54123	0,0173	3 vs 2	0,6170NS	0,4326
3 – FBR	40-70-8	0,57252	0,01669			

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Uma aplicação prática da análise de tolerância a falhas de dados é na safra de verão. Essa safra tem uma importância econômica muito maior que a safra de inverno

analisada. Porém, por ser um período quente e chuvoso, a perda de imagens é comum. Nesse caso, os dados para o treinamento da RNA com um ciclo completo das culturas, teriam que ser providos via radiometria de campo os quais teriam que ser calibrados para os mesmos valores das imagens através de alvos comuns.

Confrontando as Figuras 4.22 e 4.28 com as Figuras 4.24 e 4.29 observa-se que alguns pivôs ou talhões praticamente mantiveram a qualidade da classificação, porém outros não. A simulação de dados falhos na safra de inverno tem a agravante da flexibilidade da data de plantio, onde os perfis ilustrados dos itens 4.5.1 ao 4.5.4.2 podem estar deslocados temporalmente. Esse deslocamento temporal entre os talhões praticamente não ocorre na safra de verão onde o início de cultivo dos diferentes talhões é determinado pelo início da estação chuvosa. Assim, as conseqüências do uso de dados falhos seriam mais homogêneas no mapa temático final.




FIGURA 4.28 – Classificação com a rede RPE com arquivo da primeira falha simulada.

Ao fazer a análise das conseqüências dos dados falhos na classificação deve-se lembrar que se trata de um sensor com resolução temporal de 16 dias (ETM+/Landsat), e que o

resultado da tolerância ao uso de dados falhos na classificação pode ser diferente com o uso de dados de um sensor com frequência de imageamento maior, ou com o uso combinado de sensores com características semelhantes aos sensores do programa Landsat, como o CCD do CBERS. Com o aumento da repetitividade, as falhas de obtenção de dados não seriam tão críticas.

Não existiu a possibilidade de testar dados falhos com o MaxVer. Após gerar os vetores de média e as matrizes de covariância, os algoritmos iniciam automaticamente a classificação, sem a possibilidade de interrupção e salvamento da estatística obtida das amostras. Pelo contrário, o SNNS permite interromper um treinamento e salvar o arquivo, onde as funções de ativação, pesos e arquiteturas de rede podem ser utilizadas *a posteriori*.




FIGURA 4.29 – Classificação com a rede FBR com arquivo da primeira falha simulada.

4.8 – Kappa Condicional

Nesse trabalho, o kappa condicional foi gerado porque permite uma avaliação classe a classe do desempenho do classificador. Duas classes de boa separabilidade e grande domínio numa cena podem gerar um bom valor de kappa (convencional), o que oculta

classificações ruins de outras classes (Tso e Mather, 2001). Ao executar o índice kappa condicional no resultado das classificações de única data e também na temporal, verifica-se se a temporalidade é necessária para a classificação de todas as culturas e, em um contexto de custo/benefício, permite concluir se a classificação com uma única data (espectral) não seria satisfatória.

Quanto ao kappa condicional, a análise de algumas classificações expressas na tabela de confusão, e não apenas no valor do kappa condicional (exatidão do usuário) dela derivado, levaram à cautela no uso do índice descrita em Congalton e Green (1999). Esses autores, ao comentarem sobre esse índice, expressam somente a fórmula, sem explicitar que o que se está calculando é a exatidão do usuário, ou seja, respondendo à questão: “os n pontos classificados como feijão2 são realmente de feijão2 ?”; e não respondem à questão: “classificou todos os n pontos de feijão2 como feijão2 ?”. A Tabela 4.9 ilustra o resultado da matriz de confusão obtido com o classificador de máxima verossimilhança para a quarta data.

TABELA 4.9 – Matriz de confusão resultante do classificador MaxVer para a quarta data (13/05/2002).

		Referência								Total
		M	S	CCA	CAEM	A	F1	F2	NA	
Classificado	M	9	2	<u>7</u>	1	0	0	2	56	77
	S	11	5	<u>10</u>	2	0	1	0	0	29
	CCA	<u>0</u>	<u>0</u>	<u>34</u>	<u>0</u>	<u>0</u>	<u>0</u>	<u>0</u>	<u>0</u>	34
	CAEM	0	0	<u>0</u>	5	0	0	0	0	5
	A	0	0	<u>0</u>	0	235	0	0	0	235
	F1	3	0	<u>0</u>	0	0	110	0	0	113
	F2	23	2	<u>115</u>	10	6	1	65	223	445
	NA	188	55	<u>416</u>	195	4	53	43	523	1477
	Total	234	64	582	213	245	165	110	802	2415

M-Milho, S-Sorgo, CA – Cana Colhida no Ano, CAEM – Cana Ano e Meio, A – Água, F1 – Feijão1, F2 - Feijão2, NA – Não Agrícola.

Observa-se que para a classe cana colhida no ano (CCA), e de acordo com a Equação 3.12, que o valor da diagonal principal n_{ii} é igual ao valor n_{i+} , o que resultou num valor

de kappa igual a 1 com variância 0 (zero). Apesar desse valor, apenas 5,8% dos pontos (34/582) foram classificados como cana colhida no ano (CCA), o que foi uma grande omissão. Congalton e Green (1999) ao apresentarem o kappa condicional não mencionam o fato de essa análise fornecer somente a exatidão do usuário. Diante dessa questão, optou-se pelo cálculo do kappa condicional não só por linha, ou também conhecido como exatidão do usuário, mas também por coluna, também conhecido como exatidão do produtor¹⁹ (Rossiter, 2003). No caso acima citado, o kappa condicional na avaliação dos dados de referência (exatidão do produtor) foi apenas 0,045 com uma variância de 0,00006, sendo considerado um valor muito baixo.

4.9 – Avaliação do Kappa condicional para a Classe Milho

Ao analisar primeiramente a classificação para a classe milho, observa-se na Tabela 4.10 o valor do índice kappa, sua variância e a estatística Z. Através dessa estatística, confrontou-se uma a uma as classificações de única data com a classificação temporal. Essa análise permitiu verificar se a classificação temporal é realmente superior ou, caso não sendo, determinar o melhor mês para execução da classificação de uma única data. A análise sempre foi realizada verificando se houve ganho em ambas as exatidões - usuário e produtor - por razões já descritas.

A Tabela 4.10 exhibe a classificação executada com a rede RPE. Nota-se que a diferença de classificação foi significativa, mostrando a superioridade da classificação temporal sobre as classificações de uma única data, tanto na exatidão de usuário como na do produtor, com exceção de duas datas (3 e 5).

¹⁹ Rossiter (2003) não utiliza o termo “producer’s accuracy” e sim “producer’s reliability”

TABELA 4.10– Análise estatística do kappa condicional da classe milho, comparando-se as classificações com a rede treinada com o algoritmo RPE com única data, com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,234	0,0008	12,8**	0,000	0,27	0,0011	2,27*	0,011
2	0,1429	0,0006	15,5**	0,000	0,1833	0,001	4,27**	0,000
3	0,2849	0,0006	12,4**	0,000	0,524	0,0014	3,05**	0,001
4	0,0403	0,0003	19,3**	0,000	0,0626	0,0008	0,61**	0,000
5	0,661	0,0013	3,4**	0,000	0,5442	0,0011	3,7**	0,000
6	0,2826	0,0016	10,1**	0,000	0,1857	0,0008	4,44**	0,000
7	0,5633	0,022	1,79**	0,000	0,328	0,001	1,03NS	0,15
8	0,547	0,006	3,38**	0,000	0,0946	0,0004	7,47**	0,000
9	0,317	0,0015	9,66**	0,000	0,226	0,0009	3,38**	0,000
10	0,244	0,0014	11,2**	0,000	0,1725	0,0008	4,75**	0,000
temporal	0,8377	0,0014			0,3743	0,001		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Nessas duas datas específicas, a classificação de uma única data superou a classificação temporal por incluir um maior número de pontos de referência de milho na classe milho. Mas, ao analisar apenas os pontos classificados como milho, a classificação temporal é superior, porque foi mais seletiva em relação aos pontos de outras culturas serem incluídos nessa classe.

A Tabela 4.11 apresenta o desempenho das classificações com a rede FBR nas 10 avaliações de única data e na classificação temporal para a cultura do milho.

TABELA 4.11 – Análise estatística do kappa condicional da classe milho, comparando-se as classificações com a rede FBR com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,1965	0,001	11,2**	0,000	0,179	0,0008	6,86**	0,000
2	0,1258	0,0035	8,85**	0,000	0,028	0,0002	12,8**	0,000
3	0,0083	0,0006	16,5**	0,000	0,0063	0,0003	12,9**	0,000
4	-0,0142	0,0008	16,2**	0,000	-0,006	0,0002	13,8**	0,000
5	-0,107	0,00005	22,4**	0,000	-0,0012	0,00005	14,6**	0,000
6	0,446	0,1531	0,76NS	0,220	0,003	0,00002	14,7**	0,000
7	- ^a	- ^a	- ^a **	- ^a	0 ^b	0 ^b	14,9**	0,000
8	- ^a	- ^a	- ^a **	- ^a	0 ^b	0 ^b	14,9**	0,000
9	0,42	0,0026	5,34**	0,000	0,21	0,0008	5,98**	0,000
10	0,239	0,0072	9,16**	0,000	0,144	0,0006	8,07**	0,000
temporal	0,7453	0,0014			0,473	0,001		

NS – Não significativo, * p<0,05, **p<0,01

a – Indefinido. Nenhum pixel classificado como milho.

b- Zero. Todos pontos de milho (234) foram inclusos em outras classes .

Novamente observa-se que a classificação temporal teve um desempenho superior às classificações de única data e, com exceção da exatidão do usuário na sexta data, a classificação temporal sempre foi superior.

Quanto ao desempenho do classificador MaxVer para a cultura do milho, o resultado mostrou baixos valores de kappa. Apesar de a temporalidade propiciar um aumento do kappa condicional em relação à análise dos dados de referência, fazendo com que mais pontos de milho sejam classificadas como milho, existe uma grande inclusão de pontos de outras classes na classe milho, o que resultou num valor baixo de kappa temporal (usuário) de 0,1321. A consequência desse baixo valor é que somente na terceira e sétima data o kappa temporal foi superior às classificações de única data; nas outras, ou a temporalidade proporcionou ganhos estatisticamente insignificantes ou foi inferior. De maneira geral, observa-se que para a classe milho, o classificador MaxVer teve uma queda de desempenho com o uso temporal de imagens (Tabela 4.12).

TABELA 4.12 – Análise estatística do kappa condicional para a classe milho, comparando-se as classificações do MaxVer com única data e com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,4463	0,0382	1,60NS	0,054	0,0138	0,00006	14,9**	0,000
2	0,0443	0,0019	1,96NS	0,249	0,0128	0,0002	14,4**	0,000
3	-0,039	0,0014	4,43**	0,000	-0,0007	0,0005	15,4**	0,000
4	0,0222	0,0016	2,66**	0,004	0,0068	0,0001	14,9**	0,000
5	0,3971	0,0032	4,61**	0,000	0,1433	0,0006	10,4**	0,000
6	0,4463	0,0382	1,60NS	0,054	0,0138	6,0e-07	15,2**	0,000
7	-0,018	0,0014	3,83**	0,000	-0,004	8,6e-05	15,3**	0,000
8	0,1027	0,0031	0,52NS	0,302	0,0235	0,0002	14,2**	0,000
9	0,406	0,0026	5,27**	0,000	0,1806	0,0007	9,4**	0,000
10	0,2715	0,0072	1,63NS	0,051	0,0404	0,0002	13,8**	0,000
temporal	0,1321	0,0001			0,6423	0,0017		

NS – Não significativo, * p<0,05, **p<0,01

4.10 – Avaliação do Kappa Condicional Para a Classe Sorgo

Na Tabela 4.13, observa-se a avaliação estatística do kappa condicional para a exatidão do usuário e para a exatidão do produtor resultante da classificação com uma rede RPE. Nota-se que com exceção da exatidão do produtor na sexta data, a classificação temporal sempre foi superior, ao nível de 1%.

TABELA 4.13 – Análise estatística do kappa condicional para a classe sorgo, comparando-se as classificações com a rede RPE com única data e na classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,154	0,004	10,2**	0,000	0,0808	0,0009	3,81**	0,000
2	0,026	0,0006	19,0**	0,000	0,0316	0,0007	4,59**	0,000
3	0,116	0,0014	14,8**	0,000	0,157	0,0026	2,36**	0,000
4	0,213	0,0062	8,32**	0,000	0,098	0,001	3,5**	0,000
5	0,109	0,008	8,56**	0,000	0,025	0,0002	4,94**	0,000
6	0,477	0,004	6,09**	0,000	0,439	0,0059	0,86NS	0,190
7	0,413	0,0122	4,59**	0,000	0,133	0,0007	3,14**	0,000
8	0,443	0,0108	4,58**	0,000	0,163	0,0026	2,29*	0,011
9	0,278	0,0058	7,78**	0,000	0,159	0,0022	2,42**	0,007
10	0,1643	0,0026	11,9**	0,000	0,151	0,0024	2,48**	0,006
temporal	0,957	0,0018			0,3529	0,0042		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Na Tabela 4.14, nota-se um desempenho inferior da rede FBR. Observa-se que, para este algoritmo, existe uma grande omissão de classificação verificada na exatidão do produtor, para todas as datas, inclusive na análise temporal. Os valores de kappa condicional, que expressam a exatidão do produtor, podem ser considerados para todos os casos muito baixos. Pela análise da exatidão do usuário observa-se um grande ganho com a análise temporal, com kappa de 0,921, o que mostra que a temporalidade permite uma menor inclusão de pontos de outras classes na classe sorgo. Porém, em relação à exatidão produtor, o valor de kappa na análise temporal é baixo (0,183), resultado de uma grande omissão de classificação. Isso torna o kappa de 0,921, da exatidão do usuário, um número alto, mas sem uma expressão prática.

TABELA 4.14 – Análise estatística do kappa condicional para a classe sorgo, comparando-se as classificações com a rede FBR com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	-0,027	0,00001	12,4**	0,000	-0,01	0,000003	4,98**	0,000
2	-0,007	0,0001	12,1**	0,000	-0,017	0,0008	4,17**	0,000
3	- ^a	- ^a	- ^a **	- ^a	0 ^b	0 ^b	4,72**	0,000
4	- ^a	- ^a	- ^a **	- ^a	0 ^b	0 ^b	4,72**	0,000
5	0,358	0,0061	5,16**	0,000	0,221	0,0036	0,54NS	0,290
6	0,196	0,0077	6,24**	0,000	0,0693	0,0012	2,19*	0,014
7	0,238	0,0064	6,18**	0,000	0,113	0,0019	1,19NS	0,01
8	0,343	0,0096	4,66**	0,000	0,1316	0,0021	0,85NS	0,19
9	0,261	0,0023	7,3**	0,000	0,367	0,0064	2,07*	0,019
10	0,109	0,0013	9,64**	0,000	0,156	0,0028	0,41NS	0,340
temporal	0,921				0,183	0,0015		

NS – Não significativo, * p<0,05, **p<0,01

a – Indefinido. Nenhum pixel classificado como sorgo.

b- Zero. Todos pontos de sorgo (64) foram inclusos em outras classes.

A Tabela 4.15 exibe a análise do resultado da classificação do algoritmo MaxVer para a classe sorgo. Nota-se, em relação à exatidão do produtor, que o desempenho do classificador foi bastante semelhante à rede FBR, uma vez que existiram muitos erros de omissão e baixos valores de kappa condicional até mesmo na análise temporal. Analisando-se a exatidão de classificação do usuário, existe um bom desempenho para a análise temporal com valor do kappa de 0,8132. No entanto, repete-se o desempenho da rede FBR, em que o kappa de 0,136 observado na análise do produtor mostra uma grande exclusão da rede e, novamente, torna a boa exatidão do usuário sem utilidade prática.

TABELA 4.15 – Análise estatística do kappa condicional para a classe sorgo, comparando-se as classificações com o MaxVer com única data e na classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,4864	0,0109	2,06*	0,019	0,179	0,0029	0,74NS	0,230
2	1	0	1,56NS	0,058	0,0152	0,0002	4,96**	0,000
3	0,3051	0,0067	3,51**	0,000	0,16	0,006	0,43NS	0,360
4	0,1499	0,0051	4,77**	0,000	0,0669	0,0012	1,74**	0,041
5	0,334	0,0064	3,34**	0,000	0,1907	0,0028	0,95NS	0,17
6	0,401	0,021	2,19*	0,014	0,0735	0,0011	1,63NS	0,051
7	0,351	0,0063	3,22**	0,000	0,206	0,0034	1,13*	0,120
8	0,327	0,0081	3,25**	0,000	0,146	0,0024	0,17*	0,430
9	0,429	0,007	2,63**	0,004	0,238	0,0039	1,55*	0,005
10	0,236	0,005	4,1**	0,000	0,1424	0,0024	0,11*	0,450
Temporal	0,8132	0,0142			0,136	0,0004		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

4.11 – Avaliação do kappa Condicional Para a Classe Cana Colhida no ano

A Tabela 4.16 ilustra a análise estatística da classificação para a classe de cana colhida no ano com o algoritmo de RPE. Nota-se, em relação à exatidão do usuário, que apesar da temporalidade proporcionar uma melhora significativa em relação aos valores de kappa de todas as data (com exceção da segunda), os valores de kappa resultantes das duas primeiras classificações são altos (0,8026 e 0,8948).

Outro fator a ser analisado nos altos valores de kappa (0,8026 e 0,8948) de abril é que, nesse mês, as culturas da safra de verão, principalmente o milho e o sorgo, já haviam sido colhidas, e as culturas de pivô não tinham resposta espectral para serem incluídas nessa classe. Nas datas sucessivas, a queda gradual do valor de kappa mostra que existiu uma inclusão cada vez maior de outras classes na classe cana colhida no ano.

Com alguma variação, a análise em relação à exatidão do produtor mostra uma queda gradual do valor do kappa da primeira até a décima data. Como discutido anteriormente,

para evitar uma grande variância do padrão temporal para esta classe, as amostras foram colhidas em talhões colhidos após 02 de setembro. Isto ocorre porque, no decorrer dos meses, as mudanças espectrais para esta cultura, que começa a ser colhida no fim de abril, são cada vez maiores. Os polígonos de onde se extraíram as amostras tinham a cana em pé e eram cada vez menos representativos de talhões recém colhidos ou em brotação, que começaram a aparecer nas datas sucessivas.

Apesar de a análise temporal ser significativamente superior em seis datas, observa-se que nas duas primeiras datas o kappa resultante da classificação simples (0,4241 e 0,3081) é superior à temporal (0,2986), tendo uma diferença significativa ao nível de 1% favorável à primeira data.

Um exame das duas primeiras datas, tanto para a exatidão do usuário como do produtor, mostra que a classificação de uma única data apresenta um resultado que ilustra que a temporalidade não traz melhorias à classificação dessa classe e que a classificação de uma única data é bastante satisfatória.

A pergunta subsequente a esta análise é: qual o melhor mês para se efetuar a classificação da cana colhida no ano?

No presente trabalho não foram realizadas classificações comparativas nos meses janeiro a março, porém, o mês de abril é o mês limiar do início da colheita. Os talhões colhidos no ano anterior, ou a cana colhida no ano, plantada de setembro a outubro do ano precedente, apresentam canas com diferenças de porte. No entanto, após as chuvas que ocorrem de novembro a março, os talhões estariam espectralmente mais semelhantes. A interação dos comprimentos de onda no espectro óptico com um dossel é superficial, principalmente na região do vermelho. Desse modo, a cana com o ciclo de ano teria grande chance de sucesso de ser classificada no mês de abril, pois apresenta um vigor razoavelmente homogêneo dentro da classe e, pelo calendário agrícola, nenhuma cultura da safrinha estaria com vigor semelhante.

Existem ainda outros pontos que podem ser explorados para melhorar a classificação dessa cultura. Entre eles, a mudança na arquitetura da rede, utilizando entradas NxN que adicionam informação textural (Bischof et al., 1992; He e Collet, 1999). Os talhões de cana, ao contrário das áreas irrigadas, são grandes, compatíveis com entradas NxN. Como a resolução espacial do sensor fornece maior riqueza textural (Mather, 1999), a

banda pancromática do ETM+ é um produto a ser apreciado devido à sua resolução espacial de 15 m. Uma rede com entrada NxN com o uso das bandas 3, 4 e 5 e o canal PAN é uma abordagem a ser investigada.

TABELA 4.16 – Análise estatística do kappa condicional para a classe cana colhida no ano, comparando-se as classificações com a rede RPE com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,8026	0,0006	3,66**	0,000	0,4241	0,0008	3,62**	0,000
2	0,8948	0,0005	0,79NS	0,210	0,3081	0,0005	0,32NS	0,37
3	0,7282	0,0012	4,75**	0,000	0,2333	0,0003	2,46**	0,006
4	0,550	0,0021	7,35**	0,000	0,1338	0,0002	6,7**	0,000
5	0,6948	0,0011	5,77**	0,000	0,2778	0,0005	0,69NS	0,24
6	0,688	0,0015	5,27**	0,000	0,1948	0,0003	3,92**	0,000
7	0,701	0,0011	5,6**	0,000	0,2768	0,0005	0,73NS	0,23
8	0,5816	0,0015	7,72**	0,000	0,1956	0,0004	3,64**	0,000
9	0,589	0,0021	6,58**	0,000	0,1405	0,0002	6,45**	0,000
10	0,347	0,0011	14,7**	0,000	0,1858	0,0004	3,98**	0,000
temporal	0,9184	0,0004			0,2986	0,0004		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Com o algoritmo FBR (Tabela 4.17), a classificação da cana colhida no ano teve um desempenho semelhante ao obtido com o algoritmo de RPE. A análise do kappa para a exatidão do produtor nas duas primeiras datas são significativamente melhores que a classificação temporal. Na análise de exatidão do usuário houve a superioridade da análise temporal (0,889) em relação à segunda classificação (0,743), mas os valores de kappa nas duas primeiras classificações são considerados também altos (0,882 e 0,743).

TABELA 4.17 – Análise estatística do kappa condicional para a classe cana colhida no ano, comparando-se as classificações com a rede FBR com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}	vâr (\hat{k})	Z	p	\hat{k}	vâr (\hat{k})	Z	p
1	0,882	0,0018	0,14*	0,445	0,3927	0,0008	5,69**	0,000
2	0,743	0,0007	3,77**	0,000	0,422	0,0009	6,21**	0,000
3	0,716	0,0019	3,33**	0,000	0,1525	0,0002	2,41**	0,007
4	0,736	0,0027	2,57**	0,005	0,1002	0,0001	5,32**	0,000
5	0,695	0,0017	3,87**	0,000	0,169	0,0003	1,53NS	0,062
6	0,705	0,0012	4,11**	0,000	0,236	0,0004	1,11NS	0,13
7	0,778	0,0012	2,47**	0,006	0,2165	0,0003	0,40NS	0,34
8	0,611	0,0021	5,15**	0,000	0,1421	0,0002	2,88**	0,001
9	0,69	0,0026	3,41**	0,000	0,1126	0,0002	4,20**	0,000
10	0,288	0,0056	7,51**	0,000	0,0287	0,00007	9,24**	0,000
temporal	0,889	0,0008			0,206	0,0003		

NS – Não significativo, * p<0,05, **p<0,01

Para o classificador MaxVer (Tabela 4.18) nota-se a mesma tendência observada no desempenho dos outros classificadores, porém com um desempenho diferente a partir da quarta data, tanto na exatidão do usuário como na do produtor. Em relação à exatidão do produtor, o kappa temporal não foi estatisticamente superior ao kappa das duas primeiras datas e, a partir da quarta data, existe uma queda grande dos valores de kappa, ou seja, poucos pontos da classe cana colhida no ano são classificados como cana colhida no ano. Em relação à exatidão do usuário, o analista não deve se iludir com os altos valores de kappa após a quarta data. Essa análise já foi apresentada na Tabela 4.9 e discutida no item 4.8. Nas datas subseqüentes à quarta data, todas as classificações seguem a mesma tendência: o alto kappa da exatidão do usuário não corresponde a um alto kappa na exatidão do produtor; a oitava data por exemplo, com um kappa de 0,0787, é o melhor valor da quarta à décima data, mas classificou apenas 60 pontos de um total de 582.

TABELA 4.18 – Análise estatística do kappa condicional, para a classe cana colhida no ano, comparando-se as classificações com o MaxVer com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,7389	0,0008	3,0**	0,001	0,359	0,0008	1,49NS	0,067
2	0,7269	0,0011	3,0**	0,001	0,259	0,0005	1,45NS	0,073
3	0,7124	0,0014	3,12**	0,000	0,1993	0,0003	3,7**	0,000
4	1	0	5,46**	0,000	0,045	0,00006	11,0**	0,000
5	0,8226	0,0039	0,48NS	0,310	0,057	0,00008	10,3**	0,000
6	0,8378	0,0029	0,29NS	0,38	0,073	0,0001	9,49**	0,000
7	0,9006	0,0023	0,82NS	0,205	0,063	0,00009	9,95**	0,000
8	0,917	0,0016	1,29NS	0,097	0,0787	0,0001	9,25**	0,000
9	0,9006	0,0023	0,82NS	0,205	0,063	0,00009	9,95**	0,000
10	0,5718	0,0094	2,82**	0,002	0,030	0,00005	11,7**	0,000
temporal	0,8554	0,0007			0,3055	0,0005		

4.12 – Avaliação do Kappa Condicional Para a Classe Cana de Ano e Meio

Na Tabela 4.19 tem-se a análise do kappa condicional para a classe cana de ano e meio. Analisando-se o kappa para a exatidão do produtor, observa-se que a classificação temporal com a rede RPE teve um desempenho com kappa considerado bastante alto (0,8628), sendo significativamente superior, ao nível de 1%, a todas as datas.

Em relação à exatidão do usuário, observam-se baixos valores de kappa, principalmente para a classificação temporal (0,3842). Em todas as tabelas de confusão geradas observou-se, com exceção da nona data, que a classe cana colhida no ano é a classe que mais aparece inclusa na classe cana de ano e meio. Como ilustração dessa inclusão, a Tabela (4.20) apresenta a matriz de confusão que é resultado da classificação temporal. Nota-se que a classe cana colhida no ano, é a classe de maior inclusão (153 pontos) na classe cana de ano e meio, que tem 189 pontos classificados corretamente entre 213

existentes. Esse comportamento mostra que o uso da temporalidade foi benéfico para a exatidão do produtor, mas não para a exatidão do usuário.

TABELA 4.19 – Análise estatística do kappa condicional para a classe cana de ano e meio, comparando-se as classificações com a rede RPE com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$v\hat{a}r(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$v\hat{a}r(\hat{k}_{+j})$	Z	p
1	0,5464	0,0012	3,82**	0,000	0,5661	0,0012	6,7**	0,000
2	0,4075	0,0007	0,64NS	0,26	0,7083	0,0011	3,62**	0,000
3	0,332	0,0008	1,38NS	0,083	0,519	0,0014	7,54**	0,000
4	0,423	0,0011	0,95NS	0,17	0,512	0,0013	0,92**	0,000
5	0,4174	0,001	0,83NS	0,2	0,511	0,0013	7,83**	0,000
6	0,378	0,0012	0,14NS	0,44	0,399	0,00128	10,4**	0,000
7	0,414	0,0011	0,73NS	0,23	0,492	0,0013	8,3**	0,000
8	0,5588	0,0016	3,72**	0,000	0,448	0,00123	9,47**	0,000
9	0,3089	0,0008	2,01*	0,022	0,439	0,0014	9,33**	0,000
10	0,429	0,0009	1,16NS	0,12	0,610	0,0012	5,83**	0,000
temporal	0,3842	0,0006			0,8628	0,00068		

NS – Não significativo, * p<0,05, **p<0,01

TABELA 4.20 – Matriz de confusão resultante da classificação temporal com o classificador de RPE.

		Referência								Total
		M	S	CCA	CAEM	A	F1	F2	NA	
Classificado	M	93	15	1	0	0	0	0	0	109
	S	1	23	0	0	0	0	0	0	24
	CCA	4	0	212	1	0	0	0	9	226
	CAEM	4	0	153	189	1	0	0	84	431
	A	0	0	0	0	244	0	0	0	244
	F1	4	0	7	0	0	138	0	5	154
	F2	16	2	17	0	0	7	98	14	154
	NA	109	24	192	23	0	23	12	690	1073
	Total	231	64	582	213	245	168	110	802	2415

M-Milho, S-Sorgo, CCA – Cana Colhida no Ano, CAEM – Cana Ano e Meio, A – Água, F1 – Feijão1, F2 - Feijão2, NA – Não Agrícola

A Tabela 4.21 ilustra o resultado da classificação da classe cana de ano e meio com a rede FBR. Com relação à exatidão do produtor a análise temporal só não foi estatisticamente superior à terceira data. Em relação à exatidão do usuário, a análise temporal só não foi superior à primeira e sexta datas. A rede FBR apresentou, em relação à rede RPE, uma menor inclusão da classe cana colhida no ano.

TABELA 4.21 - Análise estatística do kappa condicional para a classe cana ano e meio, comparando-se as classificações com o FBR com única data com classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,619	0,0028	0,43NS	0,34	0,2621	0,0009	5,9**	0,000
2	0,414	0,0018	4,12**	0,000	0,301	0,0011	4,9**	0,000
3	0,276	0,0006	8,3**	0,000	0,508	0,0015	0,59NS	0,28
4	0,41	0,0017	4,2**	0,000	0,2967	0,001	5,12**	0,000
5	- ^a	- ^a	- ^a	- ^a	0 ^b	0 ^b	15,4**	0,000
6	0,6344	0,0222	0,07NS	0,47	0,0328	0,00014	13,6**	0,000
7	0,332	0,001	6,4**	0,000	0,384	0,0022	2,64**	0,004
8	0,329	0,0009	6,6**	0,000	0,434	0,00135	2,06*	0,019
9	0,410	0,0014	4,5**	0,000	0,381	0,00123	3,18**	0,000
10	0,355	0,0015	5,4**	0,000	0,299	0,0011	4,95**	0,000
temporal	0,6466	0,0014			0,538	0,00123		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

a – Indefinido. Nenhum pixel classificado como cana de ano e meio.

b- Zero. Todos os pontos de cana de ano e meio (213) foram incluídos em outras classes.

Na análise para a classe cana colhida no ano feita com o algoritmo MaxVer (Tabela 4.22), nota-se que a classificação temporal foi superior em relação às classificações de única data com um kappa de 0,7881, no entanto, em relação à exatidão do usuário somente a classificação temporal só é superior às classificações de única data na primeira e na quinta data. Em relação às outras datas, ou o uso da temporalidade não proporcionou ganhos significativos ou esta abordagem foi significativamente inferior às classificações de única data.

TABELA 4.22 – Análise estatística do kappa condicional para a classe cana de ano e meio, comparando-se as classificações com o MaxVer com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	– ^a	– ^a	– ^a **	– ^a	0 ^b	0 ^b	24,9**	0,000
2	0,9086	0,0025	11,3**	0,000	0,1421	0,00054	16,4**	0,000
3	0,3015	0,0015	0,02NS	0,48	0,233	0,00097	12,5**	0,000
4	1	0	34,9**	0,000	0,0214	0,00009	23,2**	0,000
5	0,4715	0,0035	2,74**	0,003	0,1735	0,0007	14,9**	0,000
6	0,884	0,006	7,3**	0,001	0,0725	0,00029	19,8**	0,000
7	0,535	0,0034	3,81**	0,000	0,202	0,0007	14,1**	0,000
8	0,2847	0,0117	0,14NS	0,44	0,0283	0,00014	22,4**	0,000
9	0,6907	0,0062	4,81**	0,000	0,1172	0,00047	17,5**	0,000
10	-0,096	0,000048	18,7**	0,000	-0,0004	0,0000002	24,9**	0,000
temporal	0,300	0,0004			0,7881	0,001		

NS – Não significativo, * p<0,05, **p<0,01

a – Indefinido. Nenhum pixel classificado como cana de ano e meio.

b- Zero. Todos os pontos de cana de ano e meio (213) foram inclusos em outras classes.

4.13 – Avaliação do Kappa Condicional Para a Classe Feijão 1

A análise estatística do kappa condicional na avaliação da exatidão da classe feijão 1 será discutida até a quinta data. Após essa data, uma nova cultura poderia ser cultivada ou poderia existir um período de pousio no talhão. Essas cinco datas adicionais não acrescentam informação espectro-temporal à classe, e foram mantidas devido à necessidade de 10 datas para representar as culturas de ciclo mais longo.

Na Tabela 4.23 observa-se a avaliação da classificação para a rede RPE. Em relação à exatidão do produtor, a classificação temporal com um kappa de 0,8093 é significativamente melhor, ao nível de 1%, em relação às classificações de única data, com exceção da quinta data.

Em relação à exatidão do usuário, a quarta data é superior à classificação temporal, e a quinta não é significativa. Isso mostra que, apesar de a análise temporal fazer com que

mais pontos de feijão 1 sejam classificados como feijão 1, o vetor (padrão) temporal faz com que outras classes sejam incluídas na classe feijão 1.

Quanto ao desempenho do algoritmo FBR para a classe feijão 1, existe um comportamento bastante semelhante ao da rede RPE. Na Tabela 4.24 observa-se, em relação à exatidão do produtor, que existe uma melhora significativa do kappa com a análise temporal, com exceção da quarta data. Com relação à exatidão do usuário, a análise temporal não traz melhorias significativas, e as classificações da quarta e quinta data são superiores à classificação temporal.

TABELA 4.23 – Análise estatística do kappa condicional para a classe feijão1, comparando-se as classificações com a rede RPE com única data e na classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,2215	0,00113	15,6**	0,000	0,2462	0,00136	11,6**	0,000
2	0,093	0,0004	24,0**	0,000	0,1865	0,0015	12,5**	0,000
3	0,797	0,0015	1,93**	0,027	0,5236	0,00155	5,7**	0,000
4	0,9537	0,0004	1,97*	0,024	0,6562	0,0014	3,14**	0,000
5	0,8588	0,00085	0,75NS	0,23	0,7866	0,0011	0,50NS	0,31
6	0,050	0,00013	29,3**	0,000	0,2258	0,002	10,0**	0,000
7	0,0485	0,00008	30,1**	0,000	0,3128	0,00305	7,82**	0,000
8	0,035	0,000055	31,3**	0,000	0,3102	0,0037	7,3**	0,000
9	0,133	0,00017	25,7**	0,000	0,661	0,00202	2,71**	0,003**
10	0,207	0,00064	18,7**	0,000	0,3867	0,0018	8,02**	0,000**
temporal	0,888	0,0007			0,8093	0,00097		

NS – Não significativo, * p<0,05, **p<0,01

Na Tabela 4.25 analisa-se o desempenho do classificador MaxVer. Foi constatada a mesma tendência observada para os classificadores RPE e FBR. Em relação à exatidão do produtor, a temporalidade permite uma melhor classificação, Porém, em relação à exatidão do usuário, as datas 3, 4 e 5 têm uma menor inclusão de outras classes na classe feijão 1.

TABELA 4.24 – Análise estatística do kappa condicional para a classe feijão1, comparando-se as classificações a rede FBR com única data com classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,342	0,00427	5,99**	0,000	0,123	0,0007	16,1**	0,000
2	0,184	0,00156	11,62**	0,000	0,137	0,0009	14,9**	0,000
3	0,834	0,00153	1,05NS	0,14	0,476	0,0015	6,34**	0,000
4	0,9493	0,0004	4,41**	0,000	0,718	0,00127	1,59NS	0,055
5	0,891	0,0008	2,56**	0,005	0,68	0,00136	2,35**	0,009
6	-0,027	0,00008	23,8**	0,000	-0,109	0,00122	19,0**	0,000
7	0,0412	0,00007	21,8**	0,000	0,2912	0,00325	7,7**	0,000
8	0,032	0,00006	22,23**	0,000	0,2529	0,00352	8,03**	0,000
9	0,032	0,000064	22,21**	0,000	0,244	0,0034	8,27**	0,000
10	0,1272	0,00086	14,9**	0,000	0,141	0,0010	14,4**	0,000
temporal	0,78	0,00107			0,795	0,0010		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Diante desse resultado, o problema a ser abordado é a classificação de culturas com diferentes durações de ciclo. Para todos os classificadores a temporalidade permite uma melhor definição da classe, porém, existe na classificação temporal uma maior inclusão de outras classes na classe feijão 1.

Pela análise das matrizes de confusão para as classificações temporais RPE, FBR e MaxVer, observa-se que as classes cana colhida no ano e milho foram as classes mais incluídas na classe feijão 1. Essa confusão pode estar associada principalmente às cinco datas desnecessárias do padrão que definia essa classe.

TABELA 4.25 – Análise estatística do kappa condicional para a classe feijão1, comparando-se as classificações com o MaxVer com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,034	0,0007	15,7**	0,000	0,0285	0,00048	24,9**	0,000
2	- ^a	- ^a	- ^a	- ^a	0 ^b	0 ^b	33,5**	0,000
3	0,925	0,001	4,98**	0,000	0,3878	0,00142	10,7**	0,000
4	0,971	0,00026	7,5**	0,000	0,650	0,0014	5,03**	0,000
5	0,9119	0,00064	5,2**	0,000	0,73	0,001	3,65**	0,000
6	-0,022	0,0008	16,5**	0,000	-0,008	0,00011	31,4**	0,000
7	0,026	0,00008	19,6**	0,000	0,157	0,0028	12,3**	0,000
8	-0,004	0,000057	20,7**	0,000	-0,03	0,0028	15,4**	0,000
9	0,0238	0,0001	19,5**	0,000	0,117	0,0025	13,8**	0,000
10	-0,0484	0,00062	18,0**	0,000	-0,0119	0,00004	33,0**	0,000
temporal	0,696	0,001			0,881	0,0007		

NS – Não significativo, * p<0,05, **p<0,01

a – Indefinido. Nenhum pixel classificado como cana de ano e meio.

b- Zero. Todos os pontos de cana de ano e meio (213) foram inclusos em outras classes

4.14 – Avaliação do Kappa Condicional Para a Classe Feijão 2

A análise da classificação feijão 2 é oposta à da classe feijão 1, sendo restrita da sexta à décima data.

Os resultados obtidos são bastante semelhantes à classe feijão 1: a avaliação da exatidão do produtor mostra que a temporalidade permite a classificação de um número maior de pontos da classe feijão 2 como feijão 2. No entanto, em relação à exatidão do usuário, nas classificações de algumas datas isoladas, ocorre uma menor inclusão de outras classes. Pela consulta às matrizes de confusão da classificação temporal observa-se que as classes que são mais incluídas na classe feijão 2, fazendo com que o kappa que expressa a exatidão do usuário não seja maior, são as classes milho e cana colhida no ano.

As Tabelas 4.26, 4.27 e 4.28, ilustram o kappa condicional resultante das classificações em datas individuais em comparação com o kappa derivado da classificação temporal. Observa-se um comportamento muito semelhante ao da classe feijão 1. Em relação ao kappa do produtor existe uma melhora significativa, no nível 1%, com a classificação temporal em comparação a todas as classificações de datas individuais para os três algoritmos.

TABELA 4.26 – Análise estatística do kappa condicional para a classe feijão2, comparando-se as classificações com a rede RPE com única data com classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,090	0,00017	12,6**	0,000	0,5047	0,0033	5,75**	0,000
2	0,3044	0,0018	5,36	0,000	0,339	0,0022	9,59**	0,000
3	0,155	0,00046	10,3**	0,000	0,469	0,0028	6,72**	0,000
4	0,087	0,00017	12,8**	0,000	0,464	0,0033	6,35**	0,000
5	0,0809	0,00014	13,0**	0,000	0,514	0,00348	5,51**	0,000
6	0,2433	0,0009	7,4**	0,000	0,455	0,00257	7,17**	0,000
7	0,688	0,00238	1,09NS	0,14	0,584	0,00227	5,24**	0,000
8	0,3092	0,00122	5,86**	0,000	0,528	0,0025	6,01**	0,000
9	0,761	0,0027	2,16*	0,015	0,476	0,0023	7,11**	0,000
10	0,179	0,0005	9,56**	0,000	0,496	0,00276	6,3**	0,000
temporal	0,619	0,00157			0,884	0,00099		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

Um dos questionamentos que surgem diz respeito às cinco datas extras necessárias para manter o tamanho do vetor, porém desnecessárias para informar a espectralidade do feijão 1 ou feijão 2. Talvez esta seja a causa da confusão e do erro de inclusão de outras classes verificados na exatidão do usuário.

Uma das maneiras de melhorar essa classificação seria o uso de redes específicas para os ciclos das culturas. Um dos pontos a serem investigados é o uso de redes com

arquitecturas um pouco mais específicas para classificar culturas com duração de ciclo específico: longo ou curto. Dessa maneira poderia ser evitado que um padrão temporal contivesse “ruído”. Por exemplo, a Figura 4.30 ilustra essa alternativa possível: a rede A classificaria as culturas de ciclo mais curto, a rede B classificaria as culturas de ciclo mais longo, e o mapa temático final seria derivado de mapas temáticos parciais através de uma simples aplicação de álgebra booleana.

TABELA 4.27 – Análise estatística do kappa condicional, para a classe feijão2, comparando as classificações com a rede FBR com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{Var}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,097	0,00098	7,5**	0,000	0,109	0,0012	14,5**	0,000
2	0,0588	0,00164	7,3**	0,000	0,031	0,00046	19,2**	0,000
3	0,1844	0,001	5,6**	0,000	0,287	0,002	9,3**	0,000
4	0,0926	0,00018	9,4**	0,000	0,478	0,0033	5,3**	0,000
5	0,048	0,00011	10,8**	0,000	0,304	0,0036	7,6**	0,000
6	0,295	0,0014	3,0**	0,001	0,436	0,0024	6,6**	0,000
7	0,644	0,00239	3,17**	0,000	0,583	0,00228	4,3**	0,000
8	0,498	0,0027	0,72NS	0,24	0,441	0,0023	6,6**	0,000
9	0,655	0,0026	3,25**	0,000	0,537	0,0023	5,0**	0,000
10	0,133	0,0005	7,6**	0,000	0,346	0,0026	7,9**	0,000
temporal	0,4522	0,00127			0,8416	0,00132		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

TABELA 4.28 – Análise estatística do kappa condicional para a classe feijão2, comparando as classificações com o MaxVer com única data com a classificação temporal.

Data	Classificado (usuário)				Referência (produtor)			
	\hat{k}_{i+}	$\text{vâr}(\hat{k}_{i+})$	Z	p	\hat{k}_{+j}	$\text{vâr}(\hat{k}_{+j})$	Z	p
1	0,09	0,00028	11,2**	0,000	0,3196	0,0028	7,2**	0,000
2	0,209	0,0037	5,2**	0,000	0,0984	0,00091	14,0**	0,000
3	0,136	0,00038	9,9**	0,000	0,4525	0,0029	5,2**	0,000
4	0,105	0,00022	11,0**	0,000	0,4985	0,00317	4,3**	0,000
5	0,0584	0,000078	12,6**	0,000	0,520	0,004	3,7**	0,000
6	0,1	0,00162	8,5**	0,000	0,07	0,00082	14,9**	0,000
7	0,622	0,00344	0,42NS	0,33	0,400	0,0022	6,4**	0,000
8	0,916	0,0016	5,56**	0,000	0,406	0,0022	6,3**	0,000
9	0,7874	0,0025	3,02**	0,001	0,485	0,0023	5,0**	0,000
10	0,3587	0,0035	3,21**	0,000	0,2316	0,0017	11,7**	0,000
temporal	0,591	0,0017			0,7968	0,00156		

NS – Não significativo, * $p < 0,05$, ** $p < 0,01$

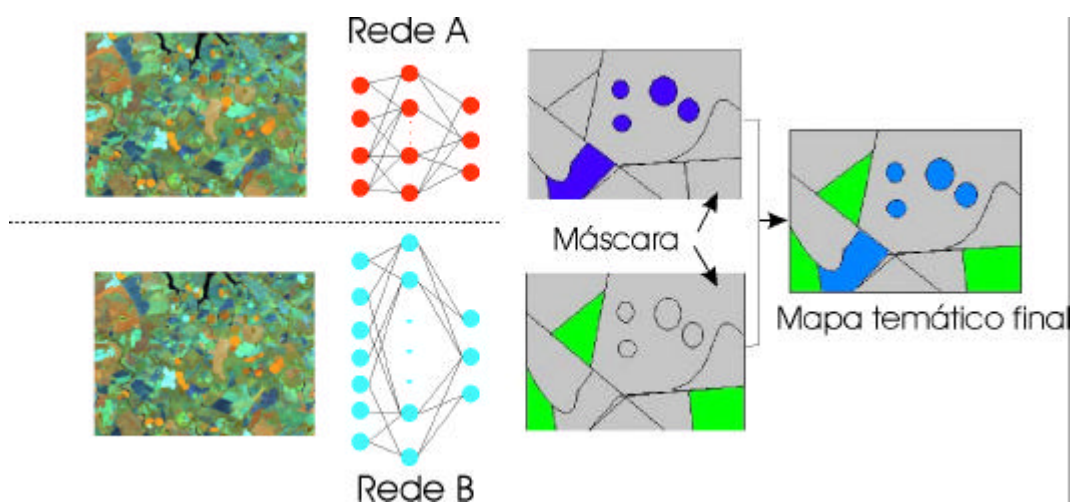


Figura 4.30 – Classificação de culturas com duração do ciclo fenológico muito distinto, utilizando redes com arquiteturas mais específicas. O mapa final é gerado pela união dos mapas temáticos parciais.

CAPÍTULO 5

CONCLUSÕES E RECOMENDAÇÕES

Este trabalho objetivou fornecer alternativas à classificação digital de cenas agrícolas, as quais possuem complexidades intrínsecas geradas pelo dinamismo das culturas, diferentes estádios fenológicos entre talhões com mesma cultura e respostas semelhantes, de diferentes culturas, quando imageadas com os sensores orbitais com as usuais bandas espectrais. Analisando um pixel de maneira contínua no tempo, procurou-se conseguir uma melhor caracterização das classes e uma maior variabilidade interclasse. As principais conclusões desse trabalho são:

- Entre os parâmetros estatísticos utilizados, a média de uma janela 3x3 pixels apresentou o melhor resultado na classificação final. Os valores de desvio padrão não contribuíram para um melhor desempenho dos classificadores e apenas adicionaram ruídos à classificação final;
- O valor do kappa (convencional) obtido com a rede RPE foi o maior valor encontrado com as análises temporais. Os algoritmos de RPE e da rede FBR tiveram um desempenho superior com a classificação temporal em relação às classificações de única data, embora com diferenças nem sempre significativas;
- O algoritmo de máxima verossimilhança teve o pior desempenho com o uso da temporalidade e, raramente a classificação espectro-temporal foi superior à classificação espectral (única data);
- A classificação temporal com a rede RPE apresentou maiores valores de kappa (convencional) em relação à rede FBR e o MaxVer, embora sem diferenças significativas;
- As duas redes utilizadas (RPE e FBR) mostraram-se com tolerância a dados falhos, sem queda significativa no valor do kappa. Porém, a cultura do sorgo deixou de existir após a substituição dos dados originais por médias das imagens precedentes e subseqüentes;

- O kappa condicional permitiu uma melhor análise classe a classe do uso da temporalidade e de determinado classificador. Porém, em muitas análises nem sempre uma melhoria na exatidão do usuário foi acompanhada pela mesma performance em relação à exatidão do produtor;
- O kappa condicional mostrou que existe benefício do uso da temporalidade na classificação de culturas como milho, sorgo e cana de ano e meio, com vantagens diferentes em relação a erros de comissão e exclusão, dependendo da rede utilizada;
- Com relação à classe cana colhida no ano, a definição do padrão espectro-temporal dessa classe em talhões com interferência antrópica é difícil e com grande variabilidade. Porém, o padrão temporal definido em talhões sem ação antrópica, os quais foram colhidos no fim da safra, torna-os pouco representativos dos talhões que são colhidos ao longo do ano. Apesar da dificuldade em representar temporalmente o ciclo da cana de ano e meio, os resultados obtidos apontam o mês de abril como o melhor mês para a classificação, pois os talhões estariam espectralmente mais semelhantes. Além disso, segundo o calendário agrícola, nenhuma cultura de verão ou “safrinha” teriam vigor e respostas semelhantes. Para uma melhoria da classificação dessa cultura sugere-se ainda a utilização de redes com entradas NxN. Essa cultura é cultivada em grandes talhões compatíveis com essa arquitetura de rede. Uma banda pancromática, com melhor resolução espacial, poderia fornecer informação textural e ser utilizada juntamente com as bandas apropriadas para classificação espectral;
- A exatidão da classificação da cana com ciclo de ano e meio apresenta grande melhora com a classificação temporal, quando analisada pela exatidão do produtor. Quando analisada pela exatidão do usuário, existe uma inclusão muito grande da classe cana colhida no ano. Essa inclusão diminui com o uso da rede FBR;
- A classificação da cultura do feijão, separada nas classes feijão 1 e feijão 2, apresenta uma sensível melhora em relação à exatidão do produtor; porém, em

relação à exatidão do usuário, classificações de única data têm menor erro de inclusão que a classificação temporal. Uma das alternativas seria o uso de redes com arquiteturas de entrada mais compatíveis com o ciclo fenológico de determinado grupo de culturas, evitando a entrada e o uso de cinco cenas adicionais que apenas atrapalham a classificação.

Recomenda-se testar essa metodologia para culturas de verão, que é a safra com maior expressão econômica. Esta safra tem data de plantio determinada pelo início da estação chuvosa, existindo maiores semelhanças fenológicas entre os talhões para uma mesma cultura. Diante da dificuldade de obtenção de todas as imagens para treinamento das redes, recomenda-se adquirir esses dados com radiômetros de campo. Os dados das medições radiométricas sobre os alvos pseudoinvariantes claros e escuros seriam utilizados como arquivos de referência na retificação das imagens utilizadas nas classificações.

Outra investigação seria com relação à substituição dos dados falhos. Neste trabalho utilizou-se a média entre as imagens anterior e posterior, porém o preenchimento dos dados falhos simplesmente com o valor zero deve ser analisado.

A metodologia proposta neste trabalho mostra que a análise temporal permite uma melhor caracterização das culturas agrícolas proporcionando ganhos à classificação, principalmente com as redes MLP treinadas com o algoritmo de RPE. Esses novos classificadores não-paramétricos apresentam vantagens em relação ao tradicional classificador Gaussiano de máxima verossimilhança. Pelas características não-paramétricas e pela tolerância a dados falhos, esses classificadores são de uso promissor para classificação de cenas agrícolas.

REFERÊNCIAS BIBLIOGRÁFICAS

- Ajai, A.K.; Golapan, K.S.; Kamat, D.S. Discrimination of winter crops using temporal spectral profiles. **International Journal of Remote Sensing**, v.6, n.9, p. 1575-1580, Jun. 1985.
- Alfonsi, R.R.; Pedro, M.J.; Brunini, O.; Barbieri, V. Condições climáticas para a cana-de-açúcar. In: Paranhos, S. **Cana-de-açúcar: cultivo e utilização**. São Paulo: Fundação Cargill. CARGILL, 1987. cap1, p.42-87.
- Anderson, J.E.; Fisher, R.L.; Deloach, S.R. Remote sensing and precision agriculture: ready for harvest or still maturing? **Photogrammetric Engineering and Remote Sensing**, v.65, n.10, p.1118-1123, Oct. 1999.
- Antunes, M.A.H. **Modelos de correção atmosféricas não lineares**. [mensagem pessoal]. Mensagem recebida por <gleriani@ufv.br> em 13 set. 2004.
- Asrar, G.; Fuchs, M.; Kanematsu, E.T.; Hatfield, J.L. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. **Agronomy Journal**, v.76, n.2, p.300-306, Feb. 1984.
- Atkinson, P.M.; Tatnall, A.R. Neural networks in remote sensing. **International Journal of Remote Sensing**, v.18, n.4, p.699-709, Mar. 1997.
- Badhwar, G.D. Automatic corn-soybean classification using Landsat MSS data I. Near-harvest crop proportion estimation. **Remote Sensing of Environment**, v.14, n. 1, p.15-29, Jan. 1984.
- Badhwar, G.D; Carnes, J.G.; Austin, W.W. Use of Landsat-derived temporal profiles for corn-soybean feature extraction and classification. **Remote Sensing of Environment**, v.12, n. 1, p.57-79, Jan. 1982.
- Baret, F.; Guyot, G. Potentials and limits of vegetation indices for LAI and APAR assessment. **Remote Sensing of Environment**, v.35, n.2, p.161-173, Feb-Mar. 1991.
- Bauer, M. E. Spectral inputs to crop identification and condition assessment. **Proceedings of the IEEE**, v.73, n.6, p. 1071-1085, 1985.

- Benedetti, R.; Rossini, P. On the use of NDVI profiles as a tool for agricultural statistics: the case study of Emilia Romagna. **Remote Sensing of Environment**, v.45, n.3, p. 311-326, Set. 1993.
- Benediktsson, J.A.; Swain, P.H.; Ersoy, O.K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. **IEEE Transactions on Geoscience and Remote Sensing**, v.28, n.4, p.540-552, Jul. 1990.
- Berberoglu, S.; Lloyd, C.D.; Atkinson, P.M.; Curran, P.J. The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean. **Computers and Geosciences**, v.26, n.4, p.385-396, May 2000.
- Bernard, A.C.; Wilkinson, G.G.; Kanellopoulos, I. Training strategies for neural network soft classification of remotely-sensed data. **International Journal of Remote Sensing**, v.18, n.8, p.1851-1856, May 1997.
- Bernardo, S. **Manual de irrigação**. Viçosa, M G: Universidade Federal de Viçosa, 1989. 596 p.
- Bischof, H.; Schneider, W.; Pinz, A. J. Multispectral classification of Landsat images using neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, n.3, p.482-490, May 1992.
- Bishop. C.M. **Neural networks for pattern recognition**. 1 ed., Oxford, New York, Oxford University Press, 1995, 482p.
- Blamire, P.A. The influence of relative sample size in training artificial neural networks. **International Journal of Remote Sensing**, v.17, n.1, p.233-230, Jan. 1996.
- Bowker, D.E.; Davis, R.E.; Myric, D.L.; Stacy, K.; Jones, W.T. **Spectral reflectance of natural targets for use in remote sensing studies**. Hampton, (NASA Reference Publication, n.1139), 1985, 195p.
- Câmara, G. M.S.; Oliveira; E.A.M. **Produção da cana-de-açúcar**. Piracicaba: ESALQ/USP, 1993, 241p.

- Câmara, G.; Souza, R.; Freitas, U.; Garrido, J.; Li, F. SPRING: Integrating remote sensing and GIS with object-oriented data modeling. **Computers and Graphics**, v.20, n.3, p.395 - 403, Jul. 1996.
- Chavez Jr, P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v.24, n.3, p. 459-479, Dec. 1988.
- Chavez Jr, P.S. Image-based atmospheric corrections - revisited and improved. **Photogrammetric Engineering and Remote Sensing**, v.62, n.9, p.1025-1036, Sep. 1996.
- Chen, C.S.; Batista, G.T.; Tardin, A.T. Landsat TM band combinations for crop discrimination. In: **International Symposium on Remote Sensing for Resources Development and Environmental Management**, 7., 1986, Enschede, Holanda. **Proceedings...** Rotterdam: A.A. Balkema, 1986, p.211-214.
- Civco, D. L. Landsat TM land use and land cover mapping using a artificial neural network. In: **Annual Meeting of the American Society for Photogrammetry and Remote Sensing**, Bethesda, Maryland, 1991, **Proceedings...** Bethesda, MD. American Society for Photogrammetry and Remote Sensing, p.67-77.
- Civco, D.L. Artificial neural networks for land-cover classification and mapping. **International Journal of Geographical Information Systems**, v.7, n.2, p.173-186, Mar-Apr. 1993.
- Congalton, R. G.; Green, K. **Assessing the accuracy of remotely sensed data: principles e practices**. New York, Lewis Publishers. 1999. 137p.
- Dadhwal, V.K.; Parihar, J.S.; Medhavy, T.T.; Ruhel, D.S.; Jarwal, S.D.; Khera, A.P. Comparative performance of thematic mapper middle-infrared bands in crop discrimination. **International Journal of Remote Sensing**, v.17, n.9, p.1727-1734, Jun. 1996.
- Dourado Neto, D.; Fancelli, A.L. **Produção de feijão.**, Guaíba, RS: Agropecuária, v.1, 2000, 385p.

Du, Y.; Teillet, P.M.; Cihlar, J. Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection. **Remote Sensing of Environment**, v.82, n.1, p.123-134, Sep. 2002.

Fageria, N. K. **Solos tropicais e aspectos fisiológicos das culturas**. Brasília, D.F. EMBRAPA, 1989, 425p.

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**. 1995. 167p. (INPE-5944-TDL/570). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995.

Fletcher, D.; Goss, E. Forecasting with neural networks: an application using bankruptcy data. **Information and Management**, v.24, n.3, p.159–167, Mar. 1993.

Foody, G.M. The significance of border training patterns in classification by a feedforward neural networks using back propagation learning. **International Journal of Remote Sensing**, v.20, n.18, p. 3549-3562, Dec. 1999.

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

Francis, D. **Política Agrícola**. (Curso de Extensão Rural – Universidade Federal de Uberlândia, 1 semestre 1989). 12p. (manuscrito).

Gausman, H.W. **Plant leaf optical properties in visible and near-infrared light**, Tech University, Lubbock, Texas Tech Press, 1985, 77p.

German, G.W.H.; Gahegan, M.N. Neural network architectures for the classification of temporal image sequences. **Computers and Geoscience**, v.22, n.9, p. 969-979, Nov. 1996.

Gilbert, M.A.; Conese, C.; Maselli, F. An atmospheric correction method for the automatic retrieval of surface reflectances from TM images. **International Journal of Remote Sensing**, v.15, n.10, p.2065-2086, Jul. 1994.

Gleriani, J. M. **Influência do solo de fundo e geometria de radiação na resposta espectral da cultura do feijão**. São José dos Campos. 66p. (INPE-5632-TDI/556). Dissertação. (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1994.

Gleriani, J. M.; Silva, J. D. S.; Epiphanyo, J. C. N. Performance comparison of neural networks and maximum likelihood for supervised classification of agricultural crops: single date and temporal analysis. In: International Joint Conference on Neural Networks (IJCNN 2004). IEEE International Conference of Fuzzy Systems (FUZZ-IEEE 2004). Budapest, 2004. Budapest, Hungary, **Anais...** Budapest: IEEE, 2004, p.2959-2964, 1 CD-ROM.

Green, R.O.; Eastwood, M.L.; Sarture, C.M.; Chrien, T.G.; Aronsson, M.; Chippendale, B.J.; Faust, J.A.; Pavri, B.E.; Chovit, C.J.; Solis, M.S.; Olah, M.R.; Williams, O. Imaging spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer. **Remote Sensing of Environment**, v.65, n.3, p.227-248, Sep. 1998.

Hagan, M.T.; Demuth, H.B.; Beale, M. **Neural network design**. Boston, USA, PWS Publishing Company. 1996. 637p.

Hall, F.G.; Badhwar, G.D. Signature-extendable technology: global space-based crop recognition. **IEEE Transactions on Geoscience and Remote Sensing**. v.25, n.1, p.93-103, Jan. 1987.

Hall, F.G.; Strebel, D.E.; Nickeson, J.E.; Goetz, S.J. Radiometric rectification: toward a common radiometric response among multirate, multisensor images. **Remote Sensing of Environment**, v.35, n.1, p.11-27, Jan. 1991.

Han, M.; Cheng, L.; Meng, H. Application of four-layer neural network on information extraction. **Neural Networks**. v.16, n.5-6, p.547-553. Jun-Jul. 2003.

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

He, H.; Collet, C. Combining spectral and textural features for multispectral image classifications with artificial neural network. In: International archives of

photogrammetry and remote sensing, 1999, Valladolid. **Proceedings...** Valladolid: IPRS, June. 1999. v.32, p.175-181.

Hepner, G.F. Artificial neural network classification using a minimal training set: comparison to conventional supervised classification. **Photogrammetric Engineering and Remote Sensing**, v.56, n.4, p.469-473, Apr. 1990.

Hill, J.; Sturm, B. Radiometric correction of multitemporal thematic mapper. **International Journal of Remote Sensing**, v.12, n.7, p.1471-1491, Jun. 1991.

Holben, B.N. Characteristics of maximum-value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, v.7, n.11, p.1417-1434, Nov. 1986.

Holben, B.N.; Tucker, C.J.; Fan, C-J. Spectral assessment of soybean leaf area and leaf biomass. **Photogrammetric Engineering and Remote Sensing**, v.46, n.5, p.651-656, Nov. 1980.

Huete, A.R. A soil-adjusted vegetation index. **Remote Sensing of Environment**, v.25, n.3, p.295-309, Aug. 1988.

Ippoliti-Ramilo, G.A., Epiphanyo J.C.N., Shimabukuro, Y.E. Landsat-5 Thematic Mapper data for pre-planting evaluation area in tropical countries. **International Journal of Remote Sensing**, v.24, n.7, p. 1521-1534, Apr. 2003.

Jackson, R.D. Remote sensing of vegetation characteristics for farm management. **Proceedings of SPIE**. The International Society for Optical Engineering, Arlington, Virginia, v.475, p.81-96. 1984.

Jackson, R.D.; Huete, A.R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v.11, n.3-4, p.185-200, Dec. 1991.

Jackson, R.D.; Pinter Jr., P.J. Spectral response of architecturally different wheat canopies. **Remote Sensing of Environment**, v.20, n.1, p.43-56, Aug. 1986.

Jackson, R.D.; Teillet, P.M.; Slater, P.N.; Fedosejevs, G.; Jasinski, M.F.; Aase, J.K.; Moran, M.S. Bidirectional measurements of surface reflectance for view angle

corrections of oblique imagery. **Remote Sensing of Environment**, v.32, n.2-3, p.189-202, May-Jun. 1990.

Jacquemoud, S.; Baret, F.; Andrieu, B.; Danson, F.M.; Jaggard, K. Extraction of vegetation biophysical parameters by inversion of the PROSPECT+SAIL models on sugar beet canopy reflectances data. Application to TM and AVIRIS sensors. **Remote Sensing of Environment**, v.52, n.1, p.163-172, Jun. 1995.

Jarvis, C.H.; Stuart, N. The sensitivity of a neural network for classifying remotely sensed imagery. **Computers and Geoscience**, v.22, n.9, p.959-967, Nov. 1996.

Jewell, N. An evaluation of multi-date SPOT data for agriculture and land use mapping in the United Kingdom. **International Journal of Remote Sensing**, v.10, n.6, p.939-951, Jun. 1989.

Johannsen, C.J.; Carter, P.J. Spectral properties for site specific management. In: Simpósio Internacional de Agricultura de Precisão, 2., 2002. Viçosa **Anais....** Viçosa, MG: Universidade Federal de Viçosa, 2002. 1 CD-ROM.

Justice, C.O.; Townshend, J.R.G.; Holben, B.N.; Tucker, C.J. Analysis of the phenology of global vegetation using meteorological satellite data. **International Journal of Remote Sensing**, v.6, n.8, p.1271-1318, Aug. 1985.

Kanellopoulos, I.; Varfis, A.; Wilkinson, G.G.; Mégier, J. Land-cover discrimination in SPOT HRV imagery using an artificial neural network – a 20 class experiment. **International Journal of Remote Sensing**, v.13, n.5, p.917-924, Mar. 1992.

Kanellopoulos, I; Wilkinson, G.G. Strategies and best practice for neural network classification. **International Journal of Remote Sensing**, v.18, n.4, p.711-725, Mar. 1997.

Kaufman, Y.J. The atmospheric effect on remote sensing and its correction. In: Asrar, G (ed). **Theory and application of optical remote sensing**. New York: John Wiley and Sons, 1989. v. 1, cap. 9, p.1375-1381.

Kauth, R.J.; Thomas, G.S. The tasseled cap transformation - A graphic description of the spectral temporal development of agricultural crops as seen by Landsat. In:

- Symposium on the Machine Processing of Remotely Sensed Data. **Proceedings...**
Purdue: Purdue University, Jan. 1976, v.4B, p.4B41-4B51.
- Kavzoglu, T.; Mather, P.M. Pruning artificial neural networks: an example using land cover classification of multi-sensor images. **International Journal of Remote Sensing**, v.20, n.14, p. 2787-2903, Sep. 1999.
- Kavzoglu, T.; Mather, P.M. The use of backpropagation artificial neural networks in land cover classification. **International Journal of Remote Sensing**, v.24, n.13, p. 4907-4938, Dec. 2003.
- Landgrebe, D. Evolution of Landsat data analysis. **Photogrammetric Engineering and Remote Sensing**, v.63, n.7, p.859-867, Jul. 1997.
- Lillesand, T.M.; Kiefer, R.W. **Remote sensing and image interpretation**. New York: John Wiley and Sons, 1994. 750 p.
- Lipmann, R.P. An introduction to computing with neural nets. **IEEE ASSP Magazine**. v.4, n.2, p.4-22, 1987.
- Lo, T.H.C.; Scarpace, F. L.; Lillesand, T. M. Use of multitemporal spectral profiles in agricultural land-cover classification. **Photogrammetric Engineering and Remote Sensing**, v.52, n.4, p. 535-544, Apr. 1986.
- Lobell, D.B.; Asner, G.P. Comparison of Earth Observing-1 ALI and Landsat ETM+ for crop identification and yield prediction in Mexico. **IEEE Transactions on Geoscience and Remote Sensing**, v.41, n.6, p.1277-1281, Jun. 2003.
- Lu, D.; Mausel, P.; Brondizio, E.; Moran, E. Assessment of atmospheric correction methods for Landsat TM data applicable to Amazon basin LBA research. **International Journal of Remote Sensing**, v.23, n.13, p.2651-2671, Jul. 2002.
- Luiz, A. J. B.; Gurtler, S.; Gleriani, J.M.; Epiphanyo, J.C.N.; Campos, R. C. Reflectância a partir do número digital de imagens ETM+. In: Simpósio Brasileiro de Sensoriamento Remoto, 11., Belo Horizonte, 2003. **Anais...** São José dos Campos: INPE, 2003, 8p. 1 CD-ROM.

- MacDonald, R.B.; Bauer, M.E., Allen, R.D.; Clifton, J.W.; Erickson, J.D.; Landgrebe, D.A. **Results of the 1971 corn blight watch experiment**. Purdue: Purdue University, 1972. 157-189 p. (LARS Technical Note 100272).
- Mather, P. M. **Computer procesing of remotely-sensed images: an introduction**. West Succex, John Wiley and Sons, 1999. 292p.
- Medeiros, A.M.; Rudorff, B.F.T.; Shimabukuro, Y.E. Imagens Landsat na estimativa de áreas de cana-de-açúcar, milho e soja. In: Simpósio Brasileiro de Sensoriamento Remoto, 8., Salvador, 1996. **Anais...** São José dos Campos: INPE, 1996. 8p. 1 CD-ROM.
- Miller, D. M.; Kaminsky, E. J.; Rana, S. Neural network classification of remote sensing data. **Computers and Geoscience**, v.21, n.3, p.377-386, Mar. 1995.
- Milton, E.J. **Teaching atmospheric correction** [online]. <www.soton.ac.uk/~ejm/Chavez.html> Jun. 2002.
- Milton, E.J. Teaching atmospheric correction using a spreadsheet. **Photogrammetric Engineering and Remote Sensing**, v.60, n.6, p.751-754, Jun. 1994.
- Moran, M.S.; Jackson, R.D.; Raymond, L.H.; Gay, L.W.; Slater, P.N. Mapping surface energy balance components by combining Landsat thematic mapper and ground-based meteorological data. **Remote Sensing of Environment**, v.30, n.1, p.77-87, Oct. 1989.
- Moran, M.S.; Jackson, R.D.; Slater, P.N.; Teillet, P.M. Evaluation of simplified procedures for retrieval of land surfaces reflectances factors from satellite sensor output. **Remote Sensing of Environment**, v.41, n.2-3, p.169-184, Jun. 1992.
- Moran, M.S; Inoue, Y; Barnes, E.M. Opportunities and limitations for image-based remote sensing in precision crop management. **Remote Sensing of Environment**, v.61, n.3, p.319-346, Sep. 1997.
- Murakami, T.; Ogawa, S.; Ishitsuka, N.; Kumagai, K.; Saito, G. Crop discrimination with multitemporal SPOT/HRV data in the Saga Plains, Japan. **International Journal of Remote Sensing**, v.22, n.7, p.1335-1348, Jun. 2001.

Murthy, C.S.; Raju, P.V.; Badrinath, K.V.S. Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks.

International Journal of Remote Sensing, v.24, n.3, p.4871-4890, Dec. 2003.

Myers, V.I. Remote sensing applications in agriculture. In: Colwell, R.W. (ed). **Manual of Remote Sensing**. Falls Church, VA: American Society of Photogrammetry, 1983. v. 2, cap. 33, p. 2111-2228.

Myneni, R.B.; Keeling, C.D.; Tucker, C.J.; Asrar, G.; Nemani, R.R. Increased plant growth in the northern high latitudes from 1981 to 1991. **Nature**, v.386, n.6626, p.698-702. Apr. 1997.

Myneni, R.B.; Maggion, S.; Jaquinta, J.; Privette, J.L.; Gobron, N.; Pinty, B.; Kimes, D. S.; Verstraete, M.M.; Williams, D.L. Optical remote sensing of vegetation: modeling, caveats, and algorithms. **Remote Sensing of Environment**, v.51, n.1, p.169-188, Jan. 1995.

NASA . **Landsat-7 science data users handbook - chapter 11** – data products.

Disponível em: <http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_htmls/chapter11/chapter11.html> Acesso em 12 out. 2002a.

NASA . **Landsat-7 science data users handbook - chapter 6** – data properties.

Disponível em <http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_htmls/chapter6/chapter6.html> Acesso em 12 out. 2002b.

NASA. **Terra: flagship of the Earth Observing System**. Versão 1, 26p, 1999.

Disponível em < http://terra.nasa.gov/Publications/terra_press_kit.pdf.> Acesso em 14 Oct. 2001.

Netto, A.D. A grande safra e seus problemas. **Jornal Folha de São Paulo**, São Paulo, 26 mar. 2003, Caderno 2, p.2.

Odenweller, J. B.; Johnson, K. I. Crop identification using Landsat temporal-spectral profiles. **Remote Sensing of Environment**, v.14, n.1, p. 39-54, Jan-Feb. 1984.

Oliveira, J.B.; Camargo, M.N.; Rossi, M.; Calderano Filho, B. **Mapa pedológico do Estado de São Paulo**: legenda expandida. IAC (Instituto Agrônomo de Campinas)/EMBRAPA-Solos. Campinas, 1999, 64p.

Ortiz, M.J. **Integração de sensoriamento remoto, sistemas de informações geográficas e banco de dados na identificação de culturas agrícolas de inverno**. 1993. 141p. (INPE-5633-TDI/557). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1993.

Paola, J.D.; Schowengerdt, R.A. A review and analysis of backpropagation neural networks for classification of remotely-sensed multispectral imagery. **International Journal of Remote Sensing**, v.16, n.16, p.3033-3058, Nov. 1995.

Paola, J.D.; Schowengerdt, R.A. The effect of neural-network structure on a multispectral land-use/land-cover classification. **Photogrammetric Engineering and Remote Sensing**, v.63, n.5, p.535-544, May 1997.

Pax-Lenney, M.; Woodcock, C.E.; Macomber, S.A.; Gopal, S.; Song, C. Forest mapping with a generalized classifier and Landsat TM data. **Remote Sensing of Environment**, v.77, n.3, p.241-250, Sep. 2001.

Qi, J.; Chehbouni, A.; Huete, A.R.; and Kerr, Y.H. Modified soil adjusted vegetation index (MSAVI), **Remote Sensing of Environment**, v.48, n.2, p.119-126, May 1994.

Rao, B.R.M.; Sankar, T.R.; Dwivedi, R.S.; Thammappa, S.S.; Venkataratnam, L.; Sharma, R.C.; Das, S.N. Spectral behavior of salt-affected soils. **International Journal of Remote Sensing**, v.16, n.12, p.2125-2136, Aug. 1995.

Ray, W.T. **FAQ on vegetation indices on remote sensing**. Disponível em: <<http://www.shef.ac.uk/~bryant/6370/veg/vegcover.htm>> Acesso em: 17 jun. 2003.

Rosin, P.L. Unimodal thresholding. **Pattern Recognition**, v.34, n.1, p.2083-2096, Nov. 2001.

Rossiter, D.G. **Assessing the thematic accuracy of area-class soil maps**. Versão 1, 31 aug. 2001, 46p. Disponível em: <http://www.itc.nl/~rossiter/docs/AccuracySoilMaps_

Preprint31Aug2001.pdf> Acesso em: 10 sep. 2002.

Schott, J.R.; Salvaggio, C.; Volchok, W.J. Radiometric scene normalization using pseudoinvariant features. **Remote Sensing of Environment**, v.26, n.1, p.1-16, Oct. 1988.

Sharma, S.A.; Bhatt, H.P.; Ajai, A.K.S. Oilseed crop discrimination: selection of optimum bands and role of middle infrared. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.50, n.5, p.25-30, Oct. 1995.

Skirvin, S. **Atmospheric and radiometric correction of Landsat Thematic Mapper data using the COST model Chavez, 1996**. Disponível em: <www2.erdas.com/supportsite/downloads/models/user_models/user_model_2.html> Acesso em: 07 sep. 2002.

Song, C.; Woodcock, C.E.; Seto, K.C.; Lenney, M.P.; Macomber, S.C. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? **Remote Sensing of Environment**, v.75, n.2, p. 230-244, Feb. 2001.

Spinelli, E. Governo solta R\$ 500 mi para estoque de álcool. **Jornal Folha de São Paulo**. São Paulo, 03 maio 2003. Caderno 3, p.B3.

Steven, M.D.; Jaggard, K.W. Advances in crop monitoring by remote sensing. In: Danson, F.M.; Plummer, S. E. ed. **Advances in Environmental Remote Sensing**. 1ed. Baffins Lane, England. Wiley, 1995, cap. 9, p.143-156.

Swain, P.H. Fundamentals of pattern recognition in remote sensing. In: Swain, P. H.; Davis, S.H. **Remote sensing: a quantitative approach**. 1ed. EUA, McGraw-Hill, 1978, cap.3, p.136-187.

Tanré, D.; Deroo, C.; Duhaut, P.; Herman, M.; Morcette, J.J; Perbos, J.; Deschamps, P.Y. Description of a computer code to simulate the satellite signal in the solar spectrum: the 5S code. **International Journal of Remote Sensing**, v.11, n.4, p. 659-668, Apr. 1990.

- Tennakoon, S.B.; Murty, V.V.N.; Eiumnoh, A. Estimation of cropped area and grain yield of rice using remote sensing data. **International Journal of Remote Sensing**, v.13, n.3, p.427-439, Feb. 1992.
- Thomas, I.L.; Benning, V.M.; Ching, N.P. **Classification of remotely sensed images**. Bristol, J W Arrowsmith Ltd, 1987. 268p.
- Townshend, J.R.G. Agricultural land-cover discrimination using thematic mapper spectral bands. **International Journal of Remote Sensing**, v.5, n.4, p.681-698, Apr. 1984.
- Tso, B.; Mather P.M. **Classification methods for remotely sensed data**. New York, NY: Taylor and Francis, 2001. 332 p.
- Tso, B.; Mather, P.M. Crop discrimination using multi-temporal SAR imagery. **International Journal of Remote Sensing**, v.20, n.2, p.2443-2460, Aug. 1999.
- Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v.8, n.2, p.127-150, Feb. 1979.
- United States Geological Survey (USGS). **Landsat-4 data users handbook**, Alexandria, V.A., 1984.
- United States Geological Survey USGS. **Earth Observing1** – hyperion. Disponível em: <eo1.usgs.gov/instru/hyperion.asp>. Acesso em: 10 nov. 2002.
- van der Sanden, J.J.; Budkewitsch, P.; Flett, D.; Landry, R.; Lukowski, T.I.; McNairn H. , Pultz T. J.; Sokol, J.; Touzi, R.; Vachon, P. W. Application potential of planned C-band SAR satellites: leading to RADARSAT-2. In: IGARSS'01 (International Geoscience and Remote Sensing Symposium), 2001. **Proceedings...** Sydney, Austrália: IGARSS, 2001. 5p.
- Vanderlip, R. L.; Reeves, H. E. Growth stages of sorghum. **Agronomy Journal**, v.64, n.1, p.13-16, Jan. 1972.
- Vermote, E.F.; Tanré, D; Deuzi, J.L.; Herman, M.; Morcrette, J.J. Second simulation of the satellite signal in the solar spectrum: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, v.35, n.3, p.675-686, May 1997.

Verstraete, M.M.; Pinty, B.; Myneni, R.B. Potential and limitations of information extraction on the terrestrial biosphere from satellite remote sensing. **Remote Sensing of Environment**, v.58, n.03, p.201-214, Sep. 1996.

Wiegand, C.L.; Richardson, A.J.; Escobar, D.E., Gerbermann, A. H. Vegetation indexes in crop assessments. **Remote Sensing of Environment**, v.35, n.2-3, 105-119, Feb-Mar. 1991.

Wilkinson, G.G.; Folving, S.; Kanellopoulos, I; McCormick, N.; Fullerton, K.; Mégier, J. Forest mapping from multi-source satellite data using neural network classifier – an experiment in Portugal. **Remote Sensing Reviews**, v.12, n.2, p.83-106, Mar. 1995.

Xin, J.; Yu, Z.; van Leeuwen, L.; Driessen, P.M. Mapping crop key phenological stages in the North China Plain using NOAA time series images. **International Journal of Applied Earth Observation and Geoinformation**, v.4, n.2, p.109-117, Nov. 2002.

Zell, A.; Mamier, G.; Mache, M.V.N.; Hübner, R.; Dörin, S.; Hermann, K-U; Soye, T.; Schmalzl, M.; Sommer, T.; Hatzigeorgiou, A.; Posselt, D.; Schreiner, T.; Kett, B.; Clemente, G.; Wieland, J.; Gatter, J. **SNNS – Stuttgart Neural Network Simulator v.4.2**, User Manual, University of Stuttgart/ University of Tübingen, 338p. 1998.

Zhuang, X.; Engel, B.A.; Lozano-Garcia, D.F.; Fernández, R.N.; Johannsen, C.J. Optimization of training data required for neuro-classification. **International Journal of Remote Sensing**, v.15, n.16, p.3271-3277, Nov. 1994.

Zullo Jr, J. **Utilização do 6S**. (INPE, set. 2002). Comunicação Pessoal.

APÊNDICE A

MODELO DE CORREÇÃO ATMOSFÉRICA DOS3 EM LEGAL

```
{  
  
Imagem Im1, Im2, Im3, Im4, Im5, Im7, Imare1, Imare2, Imare3, Imare4, Imare5, Imare7  
("Imagem_100302");  
Numerico Lsen1, Lsen2, Lsen3, Lsen4, Lsen5, Lsen7 ("Image_MNT_1003");  
Numerico Imnt1, Imnt2, Imnt3, Imnt4, Imnt5, Imnt7 ("Image_MNT_1003");  
  
Im1=Recupere (Nome="imagem_1_DN_1003");  
Im2=Recupere (Nome="imagem_2_DN_1003");  
Im3=Recupere (Nome="imagem_3_DN_1003");  
Im4=Recupere (Nome="imagem_4_DN_1003");  
//Im5=Recupere (Nome="imagem_5_DN_1003");  
//Im7=Recupere (Nome="imagem_7_DN_1003");  
  
//Imagem reflectância (numérico)  
  
Imnt1=Novo (Nome="DOS3_1003_sup1", ResX=30, ResY=30, Escala=50000, Min=0, Max=10);  
Imnt2=Novo (Nome="DOS3_1003_sup2", ResX=30, ResY=30, Escala=50000, Min=0, Max=10);  
Imnt3=Novo (Nome="DOS3_1003_sup3", ResX=30, ResY=30, Escala=50000, Min=0, Max=10);  
Imnt4=Novo (Nome="DOS3_1003_sup4", ResX=30, ResY=30, Escala=50000, Min=0, Max=10);  
//Imnt5=Novo (Nome="DOS3_1003_sup5", ResX=30, ResY=30, Escala=50000, Min=0, Max=10);  
//Imnt7=Novo (Nome="DOS3_1003_sup7", ResX=30, ResY=30, Escala=50000, Min=0, Max=10);  
  
//Radiância medida pelo sensor - (numérico)  
  
Lsen1=Novo (Nome="DOS3_1003_rad1", ResX=30, ResY=30, Escala=50000, Min=0, Max=5000);  
Lsen2=Novo (Nome="DOS3_1003_rad2", ResX=30, ResY=30, Escala=50000, Min=0, Max=5000);  
Lsen3=Novo (Nome="DOS3_1003_rad3", ResX=30, ResY=30, Escala=50000, Min=0, Max=5000);  
Lsen4=Novo (Nome="DOS3_1003_rad4", ResX=30, ResY=30, Escala=50000, Min=0, Max=5000);  
//Lsen5=Novo (Nome="DOS3_1003_rad5", ResX=30, ResY=30, Escala=50000, Min=0, Max=5000);  
//Lsen7=Novo (Nome="DOS3_1003_rad7", ResX=30, ResY=30, Escala=50000, Min=0, Max=5000);  
  
// imagem "exibição" da reflectância  
  
Imare1=Novo (Nome="DOS3_1003_sup1", ResX=30, ResY=30, Nbits=8);  
Imare2=Novo (Nome="DOS3_1003_sup2", ResX=30, ResY=30, Nbits=8);  
Imare3=Novo (Nome="DOS3_1003_sup3", ResX=30, ResY=30, Nbits=8);  
Imare4=Novo (Nome="DOS3_1003_sup4", ResX=30, ResY=30, Nbits=8);  
//Imare5=Novo (Nome="DOS3_1003_sup5", ResX=30, ResY=30, Nbits=8);  
//Imare7=Novo (Nome="DOS3_1003_sup7", ResX=30, ResY=30, Nbits=8);  
  
elev=53.02/57.2957795130;  
zen=90/57.2957795130 - elev;  
pi=3.141592654;  
dmax=255;  
d=0.9927;  
pid2 = pi*d^2;
```

```

e = 2.71828182;

// Novos parametros - lambida central

lamb1= 0.485;
lamb2= 0.565;
lamb3= 0.660;
lamb4= 0.840;
//lamb5= 1.650;
//lamb7= 2.22;

tr1 = 0.008569* lamb1^(-4)*(1+0.0113*lamb1^(-2)+0.00013*lamb1^(-4));
tr2 = 0.008569* lamb2^(-4)*(1+0.0113*lamb2^(-2)+0.00013*lamb2^(-4));
tr3 = 0.008569* lamb3^(-4)*(1+0.0113*lamb3^(-2)+0.00013*lamb3^(-4));
tr4 = 0.008569* lamb4^(-4)*(1+0.0113*lamb4^(-2)+0.00013*lamb4^(-4));
//tr5 = 0.008569* lamb5^(-4)*(1+0.0113*lamb5^(-2)+0.00013*lamb5^(-4));
//tr7 = 0.008569* lamb7^(-4)*(1+0.0113*lamb7^(-2)+0.00013*lamb7^(-4));

// como (teta)v ( v de visada) eh igual a zero (VISADA VERTICAL) cos [(teta)v] = 1

tv1 = e ^(-tr1);
tv2 = e ^(-tr2);
tv3 = e ^(-tr3);
tv4 = e ^(-tr4);
//tv5 = e ^(-tr5);
//tv7 = e ^(-tr7);

tz1 = e ^((-tr1)/cos(zen));
tz2 = e ^((-tr2)/cos(zen));
tz3 = e ^((-tr3)/cos(zen));
tz4 = e ^((-tr4)/cos(zen));
//tz5 = e ^((-tr5)/cos(zen));
//tz7 = e ^((-tr7)/cos(zen));

// DN do pixel escuro

DNmin1 = 56;
DNmin2= 33;
DNmin3 = 24;
DNmin4 = 7;
//DNmin5 = 6;
//DNmin7 = 5;

//Parâmetros de calibração são obtidos na página:
//http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_htmls/chapter11/chapter11.html
// verificar na página -
//http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_htmls/chapter6/chapter6.html
//o link "nominal gain file (ASCII)" a recomendação de baixo ou alto ganho (órbita/ponto & dia ano)

Lmin1=-6.2;
Lmin2=-6.4;
Lmin3=-5.0;
Lmin4=-5.1;
//Lmin5=- 1.0;
//Lmin7=-0.35;

```

```

Lmax1=191.6;
Lmax2=196.5;
Lmax3=152.9;
Lmax4=241.1;
//Lmax5=31.06;
//Lmax7=10.80;

Esun1=1969;
Esun2=1840;
Esun3=1551;
Esun4=1044;
//Esun5=225.7;
//Esun7=82.07;

// Lmin = Radiância Mínima Alvo (Song et al. RSE, v75, p 230-244, julho 2001)

//Lp = B    DN *    G

Lmia1 = Lmin1 + DNmin1 * (Lmax1 - Lmin1)/ dmax;
Lmia2 = Lmin2 + DNmin2 * (Lmax2 - Lmin2)/ dmax;
Lmia3 = Lmin3 + DNmin3 * (Lmax3 - Lmin3)/ dmax;
Lmia4 = Lmin4 + DNmin4 * (Lmax4 - Lmin4)/ dmax;
//Lmia5 = Lmin5 + DNmin5 * (Lmax5 - Lmin5)/ dmax;
//Lmia7 = Lmin7 + DNmin7 * (Lmax7 - Lmin7)/ dmax;

// Radiância de fundo - 1%
//OBS - A Irradiancia difusa foi considerada = ZERO
// 0.01*[(Eo * cos (zen) * tz)]* (tv/pi)

L11pc = 0.01*((Esun1*cos(zen))*tz1)*(tv1/pi);
L21pc = 0.01*((Esun2*cos(zen))*tz2)*(tv2/pi);
L31pc = 0.01*((Esun3*cos(zen))*tz3)*(tv3/pi);
L41pc = 0.01*((Esun4*cos(zen))*tz4)*(tv4/pi);
//L51pc = 0.01*((Esun5*cos(zen))*tz5)*(tv5/pi);
//L71pc = 0.01*((Esun7*cos(zen))*tz7)*(tv7/pi);

L1haze = Lmia1 - L11pc;
L2haze = Lmia2 - L21pc;
L3haze = Lmia3 - L31pc;
L4haze = Lmia4 - L41pc;
//L5haze = Lmia5 - L51pc;
//L7haze = Lmia7 - L71pc;

// Radiância "bruta" recebida no sensor;

Lsen1 = Lmin1 + Digital (Im1) * (Lmax1 - Lmin1) / dmax ;
Lsen2 = Lmin2 + Digital (Im2) * (Lmax2 - Lmin2) / dmax ;
Lsen3 = Lmin3 + Digital (Im3) * (Lmax3 - Lmin3) / dmax ;
Lsen4 = Lmin4 + Digital (Im4) * (Lmax4 - Lmin4) / dmax ;
//Lsen5 = Lmin5 + Digital (Im5) * (Lmax5 - Lmin5) / dmax ;
//Lsen7 = Lmin7 + Digital (Im7) * (Lmax7 - Lmin7) / dmax ;

// geração da reflectância (MNT) subtraindo-se a Lsen (bruta) - Lhaze

```

```

Imnt1= (pid2 * (Lsen1 - L1haze))/(tv1*(Esun1)*(cos(zen)*tz1));
Imare1= Imagem (Imnt1*676);
Imnt2= (pid2 * (Lsen2 - L2haze))/(tv2*(Esun2)*(cos(zen)*tz2));
Imare2= Imagem (Imnt2*616);
Imnt3= (pid2 * (Lsen3 - L3haze))/(tv3*(Esun3)*(cos(zen)*tz3));
Imare3= Imagem (Imnt3*667);
Imnt4= (pid2 * (Lsen4 - L4haze))/(tv4*(Esun4)*(cos(zen)*tz4));
Imare4= Imagem (Imnt4*285);
//Imnt5= (pid2 * (Lsen5 - L5haze))/(tv5*(Esun5)*(cos(zen)*tz5));
//Imare5= Imagem (Imnt5*478);
//Imnt7= (pid2 * (Lsen7 - L7haze))/(tv7*(Esun7)*(cos(zen)*tz7));
//Imare7= Imagem (Imnt7*500);

}

```


APÊNDICE B

GERAÇÃO DAS COMPONENTES GREENNESS (GR) E BRIGHTNESS (BR)

```
{  
Image Im1, Im2, Im3, Im4, Im5 ("imagem");  
Im1=Recupere (Nome="ref3_00");  
Im2=Recupere (Nome="ref4_00");  
Im3=Recupere (Nome="ref5_00");  
Im4=Novo (Nome="GREENNESS_00", ResX=30, ResY=30);  
Im5=Novo (Nome="BRIGHTNESS_00", ResX=30, ResY=30);  
Im4=((Im1*-0.5436) + (Im2*0.7243) + (Im3*0.0840) + 100.5);  
Im5=((Im1*0.4743) + (Im2*0.5585) + (Im3*0.5082) + 0.5);  
}
```

FATIAMENTO DAS COMPONENTES GR E BR

```
{  
Image Im1 ("imagem");  
Tematico Tem1, Tem2 ("GRBR");  
Tabela fatia1 (Fatiamento);  
Tabela fatia2 (Fatiamento);  
fatia1=Novo(CategoriaFim="GRBR", [100,118]:"claros_brightness");  
fatia2=Novo(CategoriaFim="GRBR", [8,35]:"escuros_brightness");  
Im1=Recupere(Nome="BRIGHTNESS_98");  
Tem1=Novo(Nome="clarosBR", ResX=30, ResY=30, Escala=50000);  
Tem2=Novo(Nome="escurosBR", ResX=30, ResY=30, Escala=50000);  
Tem1=Fatie(Numerico(Im1), fatia1);  
Tem2=Fatie(Numerico(Im1), fatia2);  
}
```

```
{  
Image Im1 ("imagem");  
Tematico Tem1, Tem2 ("GRBR");  
Tabela fatia1 (Fatiamento);  
Tabela fatia2 (Fatiamento);  
fatia1=Novo(CategoriaFim="GRBR", [185,220]:"claros_greenness");  
fatia2=Novo(CategoriaFim="GRBR", [92,104]:"escuros_greenness");  
Im1=Recupere(Nome="GREENNESS_98");  
Tem1=Novo(Nome="clarosGR_98", ResX=30, ResY=30, Escala=50000);  
Tem2=Novo(Nome="escurosGR_98", ResX=30, ResY=30, Escala=50000);  
Tem1=Fatie(Numerico(Im1), fatia1);  
Tem2=Fatie(Numerico(Im1), fatia2);  
}
```

**CRUZAMENTO DOS TEMAS GR claro e BR claro
PARA OBTER ÁREAS DE CONTROLE RADIOMÉTRICO CLARAS**

```
{  
Tematico Tem1, Tem2, cross ("GRBR");  
  
Tem1=Recupere (Nome="clarosBR_98");  
Tem2=Recupere (Nome="clarosGR_98");  
cross=Novo (Nome="CLAROS_98", ResX=30, ResY=30, Escala=50000);  
  
cross=Atribua (CategoriaFim="GRBR")  
    {  
        "claros":(Tem1.Classe == "claros_brightness" && Tem2.Classe == "claros_greenness")  
    };  
}
```

**CRUZAMENTO DOS TEMAS GR escuros e BR escuros
PARA OBTER ÁREAS DE CONTROLE RADIOMÉTRICO ESCURAS**

```
{  
Tematico Tem1, Tem2, cross ("GRBR");  
Tem1=Recupere (Nome="escurosBR_98");  
Tem2=Recupere (Nome="escurosGR_98");  
cross=Novo (Nome="ESCUROS_98", ResX=30, ResY=30, Escala=50000);  
cross=Atribua (CategoriaFim="GRBR")  
    {  
        "escuros":(Tem1.Classe == "escuros_brightness" && Tem2.Classe == "escuros_greenness")  
    };  
}
```

**OBTENÇÃO DOS VALORES MÉDIOS DE DN NAS ÁREAS DE CONTROLE
RADIOMÉTRICO CLARAS**

```
{  
Image Im1, Im2, Im3 ("imagem");  
Tematico TemCL ("GRBR");  
Numerico NumCL1, NumCL2, NumCL3 ("MEDIAS");  
Im1=Recupere (Nome="ref3_98");  
Im2=Recupere (Nome="ref4_98");  
Im3=Recupere (Nome="ref5_98");  
TemCL=Recupere (Nome="CLAROS_98");  
NumCL1=Novo (Nome="Media-claros-3", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);  
NumCL2=Novo (Nome="Media-claros-4", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);  
NumCL3=Novo (Nome="Media-claros-5", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);  
NumCL1=MedZ (Im1, TemCL.Classe == "claros");  
NumCL2=MedZ (Im2, TemCL.Classe == "claros");  
NumCL3=MedZ (Im3, TemCL.Classe == "claros");  
}
```

```
{  
Image Im1, Im2, Im3 ("imagem");  
Tematico TemESC ("GRBR");  
Numerico NumESC1, NumESC2, NumESC3 ("MEDIAS");
```

```

Im1=Recupere (Nome="ref3_98");
Im2=Recupere (Nome="ref4_98");
Im3=Recupere (Nome="ref5_98");
TemESC=Recupere (Nome="ESCUROS_98");
NumESC1=Novo (Nome="Media-escuros-3", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumESC2=Novo (Nome="Media-escuros-4", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumESC3=Novo (Nome="Media-escuros-5", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumESC1=MedZ (Im1, TemESC.Classe == "escuros");
NumESC2=MedZ (Im2, TemESC.Classe == "escuros");
NumESC3=MedZ (Im3, TemESC.Classe == "escuros");
}

```

CÁLCULO DE m_i e b_i E A GERAÇÃO DE BANDAS RETIFICADAS

```

{
Image Im1, Im2, Im3, Im4, Im5, Im6 ("ImagemTM");
Im1=Recupere (Nome="ref3");
Im2=Recupere (Nome="ref4");
Im3=Recupere (Nome="nref5");
Im4=Novo (Nome="retif3", ResX=30, ResY=30);
Im5=Novo (Nome="retif4", ResX=30, ResY=30);
Im6=Novo (Nome="retif5", ResX=30, ResY=30);
br3=
br4=
br5=
dr3=
dr4=
dr5=
bs3=
bs4=
bs5=
ds3=
ds4=
ds5=
m3=(br3-dr3)/(bs3-ds3);
b3=(dr3*bs3-ds3*br3)/(bs3-ds3);
Im4=Im1*m3+b3;
m4=(br4-dr4)/(bs4-ds4);
b4=(dr4*bs4-ds4*br4)/(bs4-ds4);
Im5=Im2*m4+b4;
m5=(br5-dr5)/(bs5-ds5);
b5=(dr5*bs5-ds5*br5)/(bs5-ds5);
Im6=Im3*m5+b5;
}

```


APÊNDICE C

MACRO PARA GERAÇÃO DE POLÍGONOS

```
Sub calc()  
  Sheets("Quad").Select  
  Range("a1").Select  
  Sheets("ponto").Select  
  Range("a1").Select  
  delta = Range("e1")  
  While (ActiveCell) <> ""  
    x = ActiveCell  
    y = ActiveCell.Offset(0, 1)  
    Sheets("Quad").Select  
    ActiveCell = x - delta  
    ActiveCell.Offset(0, 1) = y + delta  
    ActiveCell.Offset(1, 0) = x + delta  
    ActiveCell.Offset(1, 1) = y + delta  
    ActiveCell.Offset(2, 0) = x + delta  
    ActiveCell.Offset(2, 1) = y - delta  
    ActiveCell.Offset(3, 0) = x - delta  
    ActiveCell.Offset(3, 1) = y - delta  
    ActiveCell.Offset(4, 0) = x - delta  
    ActiveCell.Offset(4, 1) = y + delta  
    ActiveCell.Offset(5, 0) = "END"  
    ActiveCell.Offset(6, 0).Activate  
    Sheets("ponto").Select  
    ActiveCell.Offset(1, 0).Activate  
  Wend  
End Sub
```


APÊNDICE D

LEGAL DE FILTRO DE MÉDIA (3X3)

```
{
Numerico Imnt3, Imnt4, Imnt5, mntNDVI, Imnt3m, Imnt4m, Imnt5m, mntNDVIm ("NDVI_temporal");

Imnt3=Recupere (Nome="14b3_0909_Zeroum");
Imnt4=Recupere (Nome="14b4_0909_Zeroum");
Imnt5=Recupere (Nome="14b5_0909_Zeroum");
mntNDVI = Recupere (Nome = "14NDVI_0909_sample");

Imnt3m = Novo (Nome = "14b3_media", ResX=30, ResY=30, Escala=50000, Min=0.0, Max=1.0);
Imnt4m = Novo (Nome = "14b4_media", ResX=30, ResY=30, Escala=50000, Min=0.0, Max=1.0);
Imnt5m = Novo (Nome = "14b5_media", ResX=30, ResY=30, Escala=50000, Min=0.0, Max=1.0);
mntNDVIm = Novo (Nome = "14NDVI_media", ResX=30, ResY=30, Escala=50000, Min=-1.0,
Max=1.0);

mntNDVIm= ( ( mntNDVI[-1,1] + mntNDVI[0,1] + mntNDVI[1,1] + mntNDVI[-1,0] +
mntNDVI[0,0] + mntNDVI[1,0] + mntNDVI[-1,-1] + mntNDVI[0,-1] + mntNDVI[1,-1] ) / 9);

Imnt3m = ( ( Imnt3 [-1, 1] + Imnt3 [0,1] + Imnt3 [1,1] + Imnt3 [-1,0]
+ Imnt3[0,0] + Imnt3 [1,0] + Imnt3 [-1,-1] + Imnt3 [0,-1] + Imnt3 [1,-1] )/9);

Imnt4m = ( ( Imnt4[-1, 1] + Imnt4 [0,1] + Imnt4 [1,1] + Imnt4 [-1,0]
+ Imnt4 [0,0] + Imnt4 [1,0] + Imnt4 [-1,-1] + Imnt4 [0,-1] + Imnt4 [1,-1] )/9);

Imnt5m = ( ( Imnt5 [-1, 1] + Imnt5 [0,1] + Imnt5 [1,1] + Imnt5 [-1,0]
+ Imnt5 [0,0] + Imnt5 [1,0] + Imnt5 [-1,-1] + Imnt5 [0,-1] + Imnt5 [1,-1] )/9);
```

FILTRO DE DESVIO PADRÃO (3X3) x 100

```
{
Numerico Imnt3, Imnt4, Imnt5, NDVI, Imnt3m, Imnt4m, Imnt5m, NDVIm ("NDVI_temporal");
Numerico Im3des, Im4des, Im5des, NDVIDes ("NDVI_temporal");

Imnt3=Recupere (Nome="13b3_0209_Zeroum");
Imnt4=Recupere (Nome="13b4_0209_Zeroum");
Imnt5=Recupere (Nome="13b5_0209_Zeroum");
NDVI = Recupere (Nome = "13NDVI_0209_sample");

Imnt3m=Recupere(Nome="13b3_media");
Imnt4m=Recupere(Nome="13b4_media");
Imnt5m=Recupere(Nome="13b5_media");
NDVIm=Recupere(Nome="13NDVI_media");

Im3des= Novo (Nome = "13b3des", ResX=30, ResY=30, Escala=50000, Min=-50.0, Max=50.0);
Im4des = Novo(Nome = "13b4des", ResX=30, ResY=30, Escala=50000, Min=-50.0, Max=50.0);
Im5des= Novo (Nome = "13b5des", ResX=30, ResY=30, Escala=50000, Min=-50.0, Max=50.0);
NDVIDes = Novo (Nome = "13NDVIDes", ResX=30, ResY=30, Escala=50000, Min=-50.0, Max=50.0);

NDVIDes= (sqrt(( ( NDVI[-1,1] - NDVIm[0,0] )^2 + ( NDVI[0,1] - NDVIm[0,0] )^2 + ( NDVI[1,1] -
NDVIm[0,0] )^2 + ( NDVI[-1,0] - NDVIm[0,0] )^2+)
```

$(NDVI[0,0] - NDVIm[0,0])^2 + (NDVI[1,0] - NDVIm[0,0])^2 + (NDVI[-1,-1] - NDVIm[0,0])^2 + (NDVI[0,-1] - NDVIm[0,0])^2 + (NDVI[1,-1] - NDVIm[0,0])^2 / 8) * 100;$

$Im3des = (\sqrt{((Imnt3[-1,1] - Imnt3m[0,0])^2 + (Imnt3[0,1] - Imnt3m[0,0])^2 + (Imnt3[1,1] - Imnt3m[0,0])^2 + (Imnt3[-1,0] - Imnt3m[0,0])^2 + (Imnt3[0,0] - Imnt3m[0,0])^2 + (Imnt3[1,0] - Imnt3m[0,0])^2 + (Imnt3[-1,-1] - Imnt3m[0,0])^2 + (Imnt3[0,-1] - Imnt3m[0,0])^2 + (Imnt3[1,-1] - Imnt3m[0,0])^2) / 8}) * 100;$

$Im4des = (\sqrt{((Imnt4[-1,1] - Imnt4m[0,0])^2 + (Imnt4[0,1] - Imnt4m[0,0])^2 + (Imnt4[1,1] - Imnt4m[0,0])^2 + (Imnt4[-1,0] - Imnt4m[0,0])^2 + (Imnt4[0,0] - Imnt4m[0,0])^2 + (Imnt4[1,0] - Imnt4m[0,0])^2 + (Imnt4[-1,-1] - Imnt4m[0,0])^2 + (Imnt4[0,-1] - Imnt4m[0,0])^2 + (Imnt4[1,-1] - Imnt4m[0,0])^2) / 8}) * 100;$

$Im5des = (\sqrt{((Imnt5[-1,1] - Imnt5m[0,0])^2 + (Imnt5[0,1] - Imnt5m[0,0])^2 + (Imnt5[1,1] - Imnt5m[0,0])^2 + (Imnt5[-1,0] - Imnt5m[0,0])^2 + (Imnt5[0,0] - Imnt5m[0,0])^2 + (Imnt5[1,0] - Imnt5m[0,0])^2 + (Imnt5[-1,-1] - Imnt5m[0,0])^2 + (Imnt5[0,-1] - Imnt5m[0,0])^2 + (Imnt5[1,-1] - Imnt5m[0,0])^2) / 8}) * 100;$

}

APÊNDICE E

ORGANIZADOR DE ARQUIVOS PARA O SNNS

```
#include <stdio.h>
#include <stdlib.h>

#define TAM_COL 200000 // tamanho maximo de colunas de cada arquivo
#define NFILE 80 // numero maximo de arquivos

int main(int argc, char *argv[])
{
    char aux[NFILE][20],
        arqSai[20],
        tst[20],
        buffer[TAM_COL];

    int i,j,k,
        nc,nl,nf;

    FILE *vetp[TAM_COL],
        *fp;

    printf("\nAtencao: o arquivo [arquivos.txt] deve existir!\n");
    printf(" Esse arquivo contem a lista dos nomes de arquivos para processamento!\n");
    printf(" O 1o nome da lista serah o arquivo como o resultado final!\n");
    printf(" Tecele ENTER e boa sorte!\n");
    getchar();

    if( (fp=fopen("arquivos.txt","rt")) ==NULL) {
        printf("Arquivo arquivos.txt NAO encontrado!");
        system("PAUSE");
        return 0;
    }

    nf=0; // numero de arquivos
    while( fgets(buffer,TAM_COL,fp) != NULL){
        buffer[strlen(buffer)-1]=0;

        if( nf == 0) { //1o arquivo é de saída => para escrita
            strcpy(arqSai,buffer);
            if( (vetp[nf]=fopen(buffer,"wt")) ==NULL) {
                printf("Erro ao abrir arquivo: %s para escrita!",buffer);
                system("PAUSE");
                return 0;
            }
            nf=1;
            continue;
        }
        if( (vetp[nf]=fopen(buffer,"rt")) ==NULL) {
            printf("Erro ao abrir arquivo: %s para leitura!",buffer);
            system("PAUSE");
            return 0;
        }
    }
}
```

```

    }
    if( strlen(buffer) > 4) // eliminar CR no final do arquivo
        // incrementa o número de arquivo de leitura
        nf++;
    }

// verificar a dimensão do arquivo: ncolunas e nlinhas
nc=1; // cada coluna é separada por um " "
fgets(buffer,TAM_COL,vetp[1]);
for(i=0; i<strlen(buffer); i++) {
    if( buffer[i]== '\n') break;
    else if(buffer[i] == ' ') nc++;
}
rewind(vetp[1]);
nl=0;
while( fgets(buffer,TAM_COL,vetp[1]) != NULL) {
    if( strlen(buffer) < 10 )
        continue;
    nl++;
}
rewind(vetp[1]);

printf("Cada arquivo possui: %d linhas com %d colunas!",nl,nc);

for(i=0; i<nl; i++) { // # linhas
    for(j=0; j<nc; j++) { // # colunas
        for( k=1; k<nf; k++) { // # de arquivos
            fscanf(vetp[k],"%s",tst);
            strcpy(aux[k-1],tst);
        }
        for( k=1; k<nf; k++)
            fprintf(vetp[0],"%s ",aux[k-1]); // escreve os dados
        }
    fprintf(vetp[0],"\\n");
}

printf("\\nFim de Processamento!\\n");
printf("\\nArquivo de saída: %s \\n",arqSai);
system("PAUSE");

for(i=0; i<nf; i++)
    fclose(vetp[i]);
fclose(fp);
return 0;
}

```

APÊNDICE F ORGANIZADOR DE ARQUIVOS SNNS –SPRING

```
// Fonte: Patter.c      Compilador: C BloodShed (GNU)      2003
// Autor: Anibal Fernandes
// Entrada: contendo os seguintes dados:
//      #1.120496
//      0.00552 0.96238 0.00633 0 0.00039 0.00065 0.00003 0.00002
//      #1.120497
//      0.00476 0.96546 0.00383 0 0.00046 0.00081 0.00003 0.00003
//
// Saida: A saída segue o seguinte algoritmo:
//      O programa le oito numeros verificando qual deles é maior que 0.5
//      e armazena sua posição na lista.
//      O resultado é armazenado uma matriz de saida cujo número de
//      colunas é definida pelo usuário, via teclado.
//      Caso nenhum neuronio ou mais do que um sejam ativados ( > 0.5)
//      o pixel é rotulado como não agrícola.

#include <stdio.h>
#include <stdlib.h>
#include <string.h>
#include <math.h>

int main(int argc, char *argv[])
{
    char  arqIn[50],
          arqOu[50],
          lixo[20];

    int  i,ncol,ai,mmeio;
    float p,nval,nsai;

    FILE  *fi,
          *fo;

    printf("\nPrograma para saida da Rede!\n");
    printf("Nome do arquivo de ENTRADA: ");
    scanf("%s",arqIn);

    printf("Nome do arquivo de SAIDA: ");
    scanf("%s",arqOu);

    printf("Atencao: Entre com o #Colunas: ");
    scanf("%d",&ncol);

    if( (fi=fopen(arqIn,"rt")) == NULL ){
        printf("Arquivo de entrada %s NAO localizado",arqIn);
        getchar();
        return 0;
    }

    if( (fo=fopen(arqOu,"wt")) == NULL ){
```

```

    printf("Arquivo de saida %s NAO aberto",arqOu);
    getchar();
    return 0;
}
printf("ncol: %d\n",ncol);
ai=0;

printf("\nProcessando...");

while( (fscanf(fi,"%s",lixo))!=EOF){ // primeiro valor é lixo
    ai++;
    mmeio=0;
    // tudo isso abaixo para formar um elemento da Matriz de saida
    nsai=-1.000; // valor absurdo

    for(i=1; i<=ncol; i++) {
        fscanf(fi,"%f",&nval);
        if( nval > nsai) {
            p=(float)i; // indice do elemento na linha
            nsai=nval;
            if( nval > 0.50) // limiar
                mmeio++;
        }

    }

    if( (mmeio > 1) || (mmeio == 0) ) // ha mais que 1 numero maior que meio OU nenhum
        p=1.0;

    fprintf(fo,"% .5f ",p);

    if( (ai%ncol) == 0) { // significa que foram escritas ncolunas
        fprintf(fo,"\n");
        ai=0;
    }
}
fclose(fi);
fclose(fo);
printf("\nFim de Processando > arquivo: %s\n,arqOu");

return 0;
}

```