

RAFAELLE DA SILVA SCHIMITH

**GENERALIZAÇÃO ESPAÇO-TEMPORAL DE REDES NEURAIIS
ARTIFICIAIS PARA CLASSIFICAÇÃO DO USO E COBERTURA DO
SOLO DA REGIÃO DE MIGUELÓPOLIS-SP.**

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

**VIÇOSA
MINAS GERAIS - BRASIL
2008**

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

T

S335g
2008

Schimith, Rafaelle da Silva, 1982-

Generalização espaço-temporal de redes neurais artificiais
para classificação do uso e cobertura do solo da região de
Miguelópolis – SP / Rafaelle da Silva Schimith
– Viçosa, MG, 2008.

xvi, 87f. : il. (algumas col.) ; 29cm.

Inclui apêndice.

Orientador: José Marinaldo Gleriani

Dissertação (mestrado) - Universidade Federal de Viçosa

Referências bibliográficas: f. 73-80

1. Mapeamento florestal. 2. LANDSAT (Satélites).
 3. Processamento de imagens. 4. Sensoriamento remoto.
 5. Redes neurais (Computação). 6. Imagens multiespectrais
- I. Universidade Federal de Viçosa. II. Título.

CDD 22.ed. 634.918258

RAFAELLE DA SILVA SCHIMITH

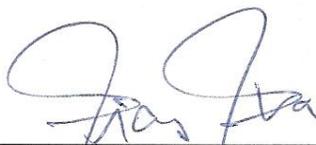
**GENERALIZAÇÃO ESPAÇO-TEMPORAL DE REDES NEURAIIS
ARTIFICIAIS PARA CLASSIFICAÇÃO DO USO E COBERTURA DO
SOLO DA REGIÃO DE MIGUELÓPOLIS-SP.**

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

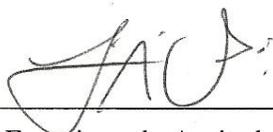
APROVADA: 24 de julho de 2008



Prof. Vicente Paulo Soares
(Co-Orientador)



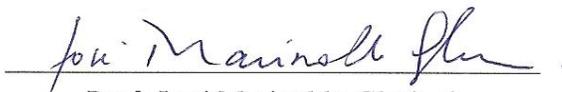
Prof. Elias Silva
(Co-Orientador)



Prof. Francisco de Assis de
Carvalho Pinto



Prof. Sebastião Venâncio Martins



Prof. José Marinaldo Gleriani
(Orientador)

“Um hipotético viajante espacial que examinasse nosso planeta, a partir de uma órbita não muito distante, logo descobriria que existe uma civilização tecnológica na Terra. As luzes das cidades, as emissões inequívocas de ondas de rádio e televisão, o padrão regular das plantações são sinais claros de vida racional. Ao aprofundar suas observações, ele notaria também que alguma coisa fundamentalmente errada está ocorrendo na superfície do planeta. Os organismos inteligentes dominantes na Terra estão destruindo suas principais fontes de vida. A camada de ozônio, as florestas tropicais o solo fértil e o uso dos recursos naturais estão sob constante ataque. Provavelmente, a essa altura, o visitante espacial faria uma revisão da sua análise.”

(Carl Sagan)

*Aos meus pais, meus exemplos
de força, coragem e disposição de viver!*
Dedico

AGRADECIMENTOS

Primeiramente a Deus meu eterno e verdadeiro amigo, por ter me dado saúde, força de vontade nos momentos difíceis. À minha mãe Herneli da Silva Gomes, amiga, forte, perseverante, pela fé em tudo que faço e acredito e por tudo que faz para me ajudar. Ao meu pai Antonio Schimith Gomes, por tudo que me ensinou e fez para eu estar onde estou, e pelas últimas palavras de apoio, incentivo, amor incondicional e compreensão nos momentos da minha ausência.

Às minhas irmãs Michelle Cristiane Schimith e Danielle da Silva Barros Schimith, pelos momentos que me proporcionaram de carinho e amizade, mesmo na distância.

Ao meu orientador Dr. José Marinaldo Glerani, que com muita paciência e dedicação me mostrou os caminhos para o desenvolvimento desta pesquisa e novos caminhos para as futuras, pela sua compreensão, amizade e momentos de descontração.

Ao prof. Elpídio Inácio Fernandes Filho, pela amizade, carinho, conselhos e atenção em toda minha trajetória nesta instituição.

Aos Co-orientadores Vicente Soares e Elias Silva, aos professores Francisco Pinto, Hélio Garcia Leite e Sebastião Venâncio, pelo aprendizado em suas disciplinas, pela contribuição para minha formação e disponibilidade.

Aos amigos de curso Jairo, Adelson, Cecília, Adriane, pelo carinho amizade, compreensão, atenção e por compartilhar conhecimentos.

Aos verdadeiros amigos, que torceram por mim, que de alguma maneira se faziam presentes em todos os momentos, mostrando que eu podia contar com eles.

À Universidade Federal de Viçosa, pelo aprendizado no Departamento de Artes e Humanidades e no Departamento de Engenharia Florestal, em especial à Secretaria de Pós Graduação, pela oportunidade de estar cursando o mestrado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, pelo incentivo financeiro.

SUMÁRIO

	Pág.
LISTA DE FIGURAS	vii
LISTA DE QUADROS	ix
RESUMO	xi
ABSTRACT	xiii
1 INTRODUÇÃO	1
2 REVISÃO DE LITERATURA	3
2.1 Fenologia	3
2.1.1 Fenologia da cultura do sorgo	3
2.1.2 Fenologia da cultura do milho	4
2.2.3 Fenologia da cultura de feijoeiro	5
2.3.5 Fenologia da cana-de-açúcar	6
2.2 Sensoriamento Remoto e Extração de Informações	7
2.2.1 Retificação Radiométrica	12
2.2.2 Correção Atmosférica	13
2.2.3 Índices de Vegetação	15
2.3 Resposta Espectral e Classificação de Alvos Agrícolas	18
2.4 Classificação de Imagens e Generalização	20
2.4.1 Redes Neurais Artificiais como Classificadores de Imagens	21
2.4.1.1 Conceito e Origem	22
2.4.1.2 Aplicações	22
2.5 Avaliação da Classificação de Imagens	27
2.6 Contexto Ambiental	30
3 MATERIAIS E MÉTODOS	34
3.1 Localização da Área de Estudo e Caracterização Geral	34
3.2 Base de Dados	35
3.3 Softwares para Processamento dos Dados	37
3.4 Processamento	37
3.4.1 Retificação Radiométrica	37
3.4.2 Geração do NDVI	39
3.4.3 Imagens Refletância	39
3.4.4 Amostras e Arquiteturas das Redes	40
4 RESULTADOS E DISCUSSÃO	43
4.1 Retificação Radiométrica e Imagens Reflectância.....	43
4.2 Complexidade da Área de Estudo	48
4.3 Perfil Temporal do NDVI das Culturas	50

4.3.1 Cultura de Feijão	51
4.3.2 Cultura de Milho	52
4.3.3 Cultura de Sorgo	53
4.3.4 Cultura de Cana-de-Açúcar	54
4.4 Resultados da Classificação e Avaliação	55
4.5 Contexto Ambiental em Miguelópolis – SP	69
5 CONCLUSÕES E RECOMENDAÇÕES	71
6 REFERÊNCIAS BIBLIOGRÁFICAS	73
APÊNDICE	81

LISTA DE FIGURAS

		Pág.
Figura 1	Estádios fenológico da cultura do sorgo	3
Figura 2	Estádios fenológico da cultura do milho	4
Figura 3	Ciclo fenológico do feijoeiro	5
Figura 4	Ciclo de cultura de cana-de-açúcar com três cortes	7
Figura 5	Curva de Kc generalizada para culturas	17
Figura 6	a) Neurônio biológico, b) neurônio artificial	22
Figura 7	Ilustração de uma rede MLP	25
Figura 8	Fluxo de processamento do algoritmo de retropropagação do erro	26
Figura 9	Representação esquemática de uma matriz de erros	29
Figura 10	Localização do município de Miguelópolis-SP e área de estudo representada pelo retângulo pontilhado	34
Figura 11	Entrada multitemporal do NDVI e das bandas 3, 4 e 5 na rede com arquivos de médias e a correspondente codificação de saída	41
Figura 12	Fluxograma das atividades	42
Figura 13	Médias antes e após a retificação dos alvos claros das bandas 3, 4 e 5	46
Figura 14	Médias antes e após a retificação dos alvos escuros das bandas 3, 4 e 5	46
Figura 15	Análise temporal no ano de 2001 para uma área representativa de Miguelópolis – SP	49
Figura 16	Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da primeira safra de cultura de feijão	51
Figura 17	Variação do NDVI ao longo do tempo ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da segunda safra de cultura de feijão	52
Figura 18	Variação do NDVI ao longo do tempo ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de milho	52
Figura 19	Variação do NDVI ao longo do tempo ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de sorgo	53
Figura 20	Variação do NDVI ao longo do tempo ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de cana ano ..	54
Figura 21	Variação do NDVI ao longo do tempo ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de cana ano e meio	54
Figura 22	Mapa temático resultante da classificação espectro-temporal de cenas retificadas radiometricamente, do ano de 2001, classificado com a rede MLP 40-12-8, treinadas com dados do ano de 2001	56
Figura 23	Mapa temático resultante da classificação espectro-temporal de cenas do ano de 2001, classificado com a rede MLP 40-70-8, treinadas com	

	dados do ano de 2002	60
Figura 24	Mapa temático resultante da classificação espectro-temporal de cenas do ano de 2002, classificado com a rede MLP 40-12-8, treinadas com dados do ano de 2001	64
Figura 25	Imagem da área estudada	69

LISTA DE QUADROS

		Pág.
Quadro 1	Principais características e aplicações da radiação eletromagnética correspondente às bandas do sensor TM do Landsat -5 e ETM+ do Landsat 7	9
Quadro 2	Informação sobre a irrigação e recursos hídricos a partir de dados de sensoriamento remoto para manejo da irrigação	11
Quadro 3	Qualidade da classificação associada aos valores do Kappa.	30
Quadro 4	Relação das Imagens utilizadas	36
Quadro 5	Valores BR e GR e Médias antes e após a retificação	44
Quadro 6	Média das Imagens após a Retificação e valores do Δ	45
Quadro 7	Parâmetros utilizados para gerar a imagem reflectância	47
Quadro 8	Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2001, retificadas radiometricamente, classificadas com a rede neural treinada com dados de 2001	58
Quadro 9	Exatidão do usuário e exatidão do produtor derivadas da matriz de confusão com dados de treinamento e classificação, retificados radiometricamente, do ano de 2001	58
Quadro 10	Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2001 classificadas com a rede neural treinada com dados de 2002	61
Quadro 11	Exatidão do usuário e exatidão do produtor derivadas da matriz de confusão com dados de treinamento de 2002 e classificação do ano de 2001	62
Quadro 12	Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2001 com rede neural treinada com dados do ano de 2001, com cenas do ano de 2001 classificadas com rede treinada com dados do ano de 2002	62
Quadro 13	Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2002 classificadas com a rede neural treinada com dados de 2001	65
Quadro 14	Exatidão do usuário e exatidão do produtor derivadas da matriz de confusão com dados de treinamento e classificação do ano de 2001 ..	65

Quadro 15	Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2002 com rede neural treinada com dados do ano de 2002, com cenas do ano de 2002 classificadas com rede treinada com dados do ano de 2001	66
Quadro 16	Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2001 classificadas com a rede neural treinada com dados de 2001. Imagens refletância	67
Quadro 17	Exatidão do usuário e exatidão do produtor derivadas da matriz de confusão com dados de treinamento e classificação do ano de 2001 Imagens refletância	67
Quadro 18	Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2001 com rede neural treinada com dados do ano de 2001, retificadas, com cenas do ano de 2001 classificadas com rede treinada com dados do ano de 2001, refletância	68

RESUMO

SCHIMITH, Rafaelle da Silva, M. Sc. Universidade Federal de Viçosa, Julho de 2008. **Generalização espaço-temporal de redes neurais artificiais para classificação do uso e cobertura do solo da região de Miguelópolis-SP.** Orientador: José Marinaldo Gleriani. Co-Orientadores: Vicente Paulo Soares e Elias Silva.

A classificação de imagens de satélites subsidia na identificação e extração de informações possibilitando a produção de novos mapas contendo informações específicas, que auxiliam em pesquisas ambientais relacionadas às distintas linhas de pesquisas. Toda classificação executa uma generalização espacial, no entanto, a generalização temporal, aonde um classificador é treinado com amostras distantes no tempo é pouco conhecido e pode ser bastante útil na irrigação, análise de ciclos da cultura, análise do uso e ocupação do solo, dentre outros. Neste contexto, este trabalho teve o objetivo de testar o desempenho da generalização espaço-temporal de redes supervisionadas MLP (*Multilayer Perceptron*) para classificar o uso e ocupação do solo, especificamente as culturas agrícolas no município de Miguelópolis – SP. Foram utilizadas 20 cenas ETM+/Landsat 7 e TM/Landsat-5 do ano de 2001 e do ano de 2002, onde as imagens de 2001 foram retificadas com a cena base do ano de 2002. Foram separados dois grupos, um destas imagens retificadas e o outro destas imagens apenas com reflectância para ambos os testes serem feitos. Os processamentos de registro, retificação, geração do NDVI e imagens reflectância foram realizados no software de *Sistemas de Informações Geográficas - SPRING* e para estabelecer a arquitetura da rede e treinamento foi utilizado o software *Stuttgart Neural Network Simulator – SNNS empregando o* algoritmo de retropropagação do erro, esperando erro de saída de 0,01. Primeiramente foi feita a classificação das cenas de 2001, com amostras coletadas na mesma cena; logo em seguida a classificação foi feita pela abordagem espectro-temporal, classificando as cenas de 2001 com uma rede treinada a partir de amostras de 2002 e depois a classificação foi feita através das cenas do ano de 2002 com uma rede treinada a partir de amostras do ano de 2001. Foram utilizados como parâmetros de entrada as bandas 3, 4 e 5 e o *Índice de Vegetação da Diferença Normalizada – NDVI*, procurando distinguir nas imagens oito classes: feijão de

primeira safra, feijão de segunda safra, milho, sorgo, cana de ano e meio, cana colhida no ano, água e outros usos, que englobam edificações, áreas de florestas que são poucas no retângulo que envolve a área de estudo. As avaliações das classificações foram feitas por meio da estatística Kappa (K) e da estatística Z (Z) para analisar através destes valores a necessidade da retificação radiométrica na classificação espectro-temporal nas imagens retificadas e nas imagens reflectância, verificando se a calibração é o suficiente na uniformização radiométrica das cenas nas classificações. A retificação foi capaz de normalizar a resposta espectral dos alvos nas imagens, entretanto, os valores do (K) foram baixos em todas as classificações, principalmente na classificação espectro-temporal fato que pode estar relacionado à complexidade da área de estudo em identificar as culturas agrícolas que apresentam diferentes estádios fenológicos e grande variação nas épocas de cultivos. Através do NDVI, foi possível traçar em relação aos dias do ano de 2001, o ciclo produtivo das culturas, evidenciando a complexidade destes que influem na classificação no espaço e no tempo. Os testes (Z) mostraram uma queda significativa na exatidão da rede treinada com dados de 2001 para classificar as cenas do ano de 2002 e na treinada com dados de 2002 para classificar as cenas de 2001, mas a classificação com dados treinados e classificados em uma mesma data apresentou resultados aquém das classificações no tempo. A utilização de imagens reflectância do ano de 2001 resultou em uma classificação que não diferiu estatisticamente das imagens retificadas, logo o procedimento de retificação neste trabalho não seria necessário, visto que ele requer tempo e é complexo. Na área de estudo, é possível verificar diante das classificações, a grande quantidade de pivôs para irrigação. A agricultura irrigada, geralmente substitui a mata ciliar, relacionada diretamente com a qualidade da água, gerando inúmeros problemas, portanto, análises neste tocante são necessárias, já que as classificações das imagens auxiliam na aquisição de informações para possíveis tomadas de decisões.

ABSTRACT

SCHIMITH, Rafaelle da Silva, M. Sc. Universidade Federal de Viçosa, July 2008. **Spectral-temporal generalized artificial neural networks for classification landscover of Miguelópolis- SP.** Adviser: José Marinaldo Gleriani. Co-Advisers: Vicente Paulo Soares and Elias Silva.

The images classification of satellites subsidizes in the information identification and extraction making possible the production of new maps with specific information that assists in environmental researches related to distinct research lines. All classification executes a spatial generalization, however, the temporal generalization, where a classifier is trained with distant samples in time, is little known and it can be sufficiently useful in the irrigation, analysis of culture cycles, use analysis and land occupation, among others. In this context, this study aimed to test the performance of the spectral-temporal generalization of supervised networks MLP (*Multilayer Perceptron*) to classify the use and land occupation, especially the agricultural crops in Miguelópolis-SP. 10 scenes ETM +/-Landsat 7 and TM/Landsat-5 of 2001 and 2002 were used, where the images of 2001 were rectified to the base scene of 2002 corrected atmospherically. Two groups had been separated, one of these images rectified and another one only with reflectance with the objective that both tests were done. The register processes, rectification, NDVI generation and reflectance images were performed in *SPRING - Geographical Information Systems* software, and to establish the network architecture and training was used *SNNS-Stuttgart Neural Network Simulator* software, using a multilayer perceptron, that was trained with the algorithm of backpropagation error, expecting exit error of 0.01. First the classification of the 2001 scenes was done, with s collected samples in the same scene; immediately afterwards the classification was done by the spectral-temporal approach, classifying the 2001 scenes with a trained network from the 2002 samples and then the classification was done through the 2002 scenes with a trained network from the 2001 samples. The bands 3, 4 and 5 and NDVI - Normalized Difference Vegetation Index had been used as entrance parameters, trying to distinguish in the

images eight classes: beans of first crop, beans of second crop, corn, sorghum, sugarcane of year and a half, sugarcane harvested in the year, water and other uses, which include constructions, forests areas that are few in the rectangle that involves the study area. The evaluations of the classifications had been made by Kappa (K) statistic and Z statistic (Z) to analyze through these values the necessity of the radiometric rectification in the spectral-temporal classification in the rectified images and in the reflectance images, being verified if the calibration is sufficient in the scenes radiometric standardization in the classifications. The rectification was capable to normalize the spectral response of the targets in the images, however, (K) values had been low in all classifications, mainly in the spectral-temporal classification, fact that can be related to the complexity of the study area in identifying the agricultural crops that present different phenological stadiums and a great variation in cultivate periods. By NDVI, it was possible to trace according to the days of 2001, the productive cycle of the crops, evidencing the complexity of these that influences in the classification of the space and time. (Z) tests had shown a significant decrease in the accuracy of the trained network with data of 2001 to classify the scenes of 2002 and in the trained one with the data of 2002 to classify the scenes of 2001, but the classification with trained and classified data in a same date presented results over the time classifications. The use of reflectance images of 2001 resulted in a classification that did not differ statistically from the rectified images, so the rectification procedure in this work would not be necessary because it requires time and it is complex. In the study area, it is possible to verify ahead of the classifications, the great amount of pivots for irrigation, the irrigated agriculture generally substitutes the ciliar forest, directly related to the water quality, causing innumerable problems, therefore works for these analyses are necessary and the classification of the images helps in the information acquisition for possible taking of decisions.

1. INTRODUÇÃO

O mapeamento do uso e cobertura do solo é um desafio, principalmente em se tratando de identificar culturas agrícolas no espaço e no tempo, devido às características dinâmicas da atividade e dimensão continental do território brasileiro. Dados de sensores orbitais, com características multiespectrais, sinópticas e multitemporais, têm atendido a essa necessidade, no entanto, o mapeamento de culturas irrigadas, com uma única cena (espectral) tem sido um desafio pela grande variação fenológica observada para uma mesma cultura, nos diversos talhões. A abordagem multitemporal (espectro-temporal) aonde um pixel é analisado em um *continuum* no tempo, tem dado resultados superiores à classificação com uma única data (espectral). Tal abordagem permite utilizar a variação fonológica de cada talhão, retratada em várias cenas, como um padrão descritor. A quase totalidade dos trabalhos tem testado a generalização espacial dos classificadores, ou seja, a capacidade de um classificador em rotular pixels desconhecidos, mas pertencentes à mesma cena onde foram coletadas as amostras, mas poucos estudos têm testado a generalização temporal (e também espacial) dos classificadores, onde amostras coletadas em uma dada cena seriam utilizadas para classificar cenas da mesma órbita ponto, porém, distantes no tempo. Nos últimos anos novas ferramentas computacionais como as Redes Neurais Artificiais – RNAs estão em destaque para classificação de imagens digitais, por apresentarem vantagens na tolerância a dados falhos, necessitar de pequena amostragem, pela sua não parametricidade e capacidade de generalização de informações. Procedimentos neste tocante, auxiliam no mapeamento e reconhecimento de informações, e eventos como irrigação, alteração do uso do solo ao longo do tempo, dentre outros.

Neste contexto, o respectivo trabalho teve como objetivo realizar a classificação de culturas agrícolas em imagens ETM+/Landsat-7 e TM/Landsat-5, testando a capacidade de generalização temporal de uma rede *Multilayer Perceptron- MLP*, treinada com o algoritmo de retropropagação do erro, utilizando-se como parâmetros de entrada, as bandas 3, 4 e 5 e o Índice de Vegetação da Diferença Normalizada – NDVI. Especificamente pretende-se

realizar a classificação das culturas agrícolas da safra de 2001, com amostras coletadas na mesma cena; utilizar a abordagem espectro-temporal e classificar as cenas de 2001 com uma rede treinada a partir de amostras de 2002, assim como classificar as cenas do ano de 2002 com uma rede treinada a partir de amostras do ano de 2001 em imagens retificadas e em imagens apenas com a reflectância. Obtendo as classes, objetiva-se avaliar as classificações através da estatística Kappa (K), verificando a precisão das mesmas nas imagens e através da estatística Z (Z), verificar a necessidade da retificação radiométrica na classificação espectro-temporal, analisando se a calibração nas imagens reflectância é suficiente para uniformização radiométrica das cenas na classificação espectro-temporal.

2. REVISÃO DE LITERATURA

2.1 Fenologia

A fenologia é o estudo dos eventos periódicos da vida vegetal em relação às condições de ambiente e correlação com aspectos morfológicos da planta, envolvendo, portanto, as fases de crescimento e desenvolvimento vegetal (FANCELLI & DOURADO NETO, 2000). Descreve-se nos próximos parágrafos o ciclo fenológico das principais culturas que serão abordadas nesse estudo.

2.1.1 Fenologia da cultura do sorgo

A altura da planta de sorgo (*Sorghum bicolor*) varia de 1 a 5 metros, tendo o estudo do desenvolvimento variando com a época do plantio, cultivar, condições climáticas e tipo do solo (FAGERIA, 1989). As fases de desenvolvimento para cultivares de ciclo de aproximadamente 100 dias pode ser caracterizada, conforme Vanderlip & Reeves (1972), pelos seguintes estádios: Estádio Zero (Emergência), Estádio 2 (Visível o colar da 5ª folha), Estádio 3 (Diferenciação do ponto de crescimento) Estádio 4 (Visível a última folha), Estádio 5 (Emborrachamento), Estádio 6 (50% de floração), Estádio 7 (Leitoso), Estádio 8 (Pastoso), Estádio 9 (Maturação Fisiológica) (Figura 1):

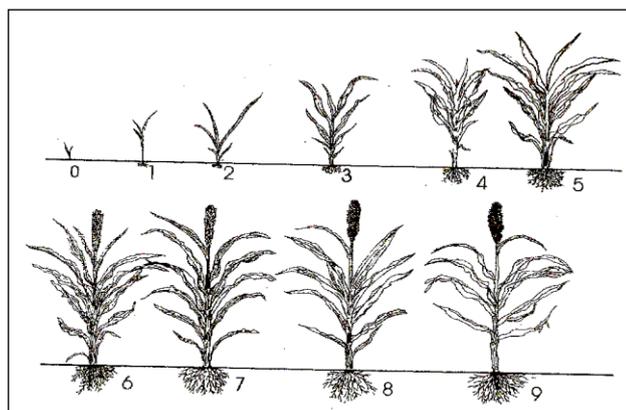


Figura 1 - Estádios fenológico da cultura do sorgo. **Fonte:** Fageria (1989)

2.1.2 Fenologia da cultura do milho

O milho (*Zea mays L*) é cultivado em regiões temperadas e tropicais, considerada uma planta neutra ou de dias curtos, com seu desenvolvimento afetado pela radiação solar que deve ser alta para maior produção. É uma cultura exigente em água, porém é uma das mais eficientes no seu uso, produzindo grande acúmulo de matéria seca por unidade de água absorvida. Seus coeficientes de cultura Kc médios variam de 0,3 a 0,4 entre 0 a 20 dias; 0,65 a 0,75 de 20 a 40 dias; 0,95 a 1,05 de 40 a 70 dias; 0,9 a 0,95 de 70 a 90 dias e 0,85 a 0,9 nos restantes até a colheita (REICHARDT, 1990).

A morfologia da planta de milho como altura, número e tamanho das folhas, número de espigas, cor e tamanho dos grãos varia amplamente, tendo o período de plantio e a colheita variando de três a 12 meses, dependendo do local (DUNCAN, 1975) e (FAGERIA, 1989). Os autores descrevem na os estádios de desenvolvimento da planta de milho para cultivares de 120 a 125 dias: Estádio Zero (emergência), Estádio 1 (visível o colar da 4° folha), Estádio 2 (visível o colar da 8° folha) , Estádio 3 (visível o colar da 12° folha), Estádio 4 (visível o colar da 16° folha), Estádio 5 (75% das plantas estão com o embonecamento visível), Estádio 6 (12 dias após 75% das plantas estarem embonecadas) ,Estádio 7 (24 dias após 75% das plantas estarem embonecadas, Estádio 8 (36 dias após 75% das plantas estarem embonecadas, Estádio 9 (48 dias após 75% das plantas estarem embonecadas), Estádio 10 (plantas amadurecidas). (Figura 2)

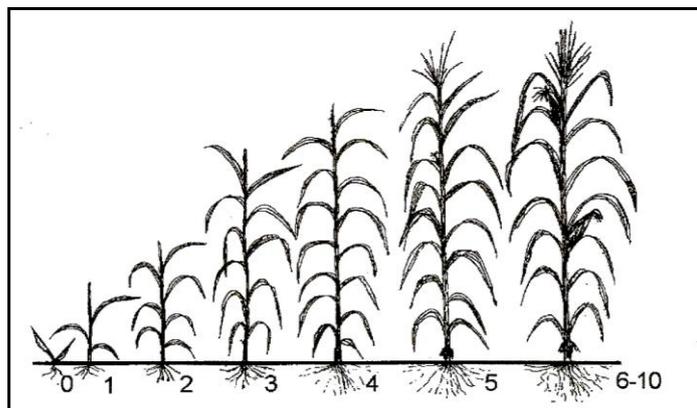


Figura 2 - Estádios fenológico da cultura do milho. **Fonte:** Fageria (1989)

2.1.3 Fenologia da cultura de feijoeiro

O feijoeiro (*Phaseolus vulgaris* L.) é uma leguminosa anual cultivada para obtenção de vagens e de sementes secas na forma de grão que não se adapta às condições muito úmidas. (REICHARDT, 1990). A morfologia da cultura é hereditária e constante, podendo estas ser influenciadas pelo ambiente. Segundo o Centro Internacional de Agricultura Tropical (CIAT), as principais características morfológicas do feijão são: Raízes, haste principal, ramos, folhas, inflorescências, fruto e semente (FAGERIA, 1989). Baseando-se no comportamento e número de nós da haste principal, número e comprimento dos ramos laterais, o autor classifica os feijoeiros como: Tipo I – Arbustivo determinado; Tipo II – Arbustivo indeterminado; Tipo III – Prostrado indeterminado; Tipo IV – Trepador indeterminado. O ciclo completo da cultura, segundo Reichardt (1990), é de 60 a 90 dias no caso da colheita de vagens verdes e 90 a 120 dias para a produção de grãos. A fenologia da cultura do feijão segundo Centro Internacional de Agricultura Tropical (CIAT), citado por Fageria (1989), pode ser observada na Figura 3 e consiste: Germinação (V0), Emergência (V1), Folhas primárias (V2), Primeira folha trifoliolada (V3), Terceira folha trifoliolada (V4); Fase reprodutiva (R): Pré-Floração (R5), Floração (R6), Formação das vagens (R7), Enchimento das vagens (R8), Maturação (R9)

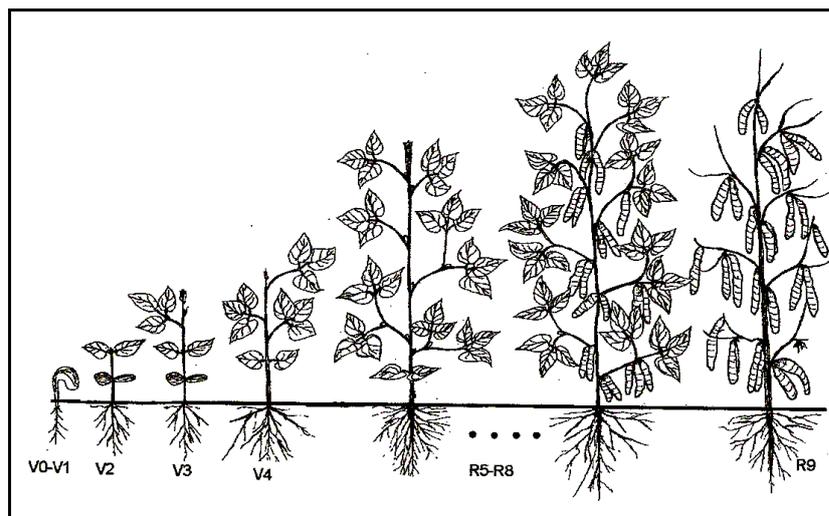


Figura 3 - Ciclo fenológico do feijoeiro; adaptada de Fageria (1989).

2.1.4 Fenologia da cana-de-açúcar

A cana-de-açúcar (*Sccharum spp.*) é uma gramínea perene que perfilha abundantemente na sua fase inicial de desenvolvimento (MAGALHÃES, 1987). Todos os estádios de desenvolvimento e, por conseguinte, os rendimentos agrícolas e industriais da cana-de-açúcar são governados pela estreita interação entre as suas potencialidades genéticas e o meio-ambiente (BARBIERI *et al.*, 1982; MACHADO *et al.*, 1982). O déficit de água durante o período de estabelecimento da cultura no início e durante o período vegetativo tem um efeito negativo sobre a produtividade, reduzindo a germinação, perfilhamento e o alongamento de colmos, podendo forçar o período de maturação da cultura (REICHARDT, 1990).

A cana-de-ano (12 meses), plantada em setembro-outubro, tem seu desenvolvimento máximo de novembro a abril, diminuindo devido às condições climáticas adversas do período de inverno no Centro-Sul, podendo essa colheita ocorrer a partir de julho, isto em função do cultivar.

A cana-de-ano e meio (18 meses) é plantada de janeiro ao início de abril, apresenta taxa de crescimento mínimo, de maio a setembro no Centro-Sul, em função das condições pouco favoráveis do inverno, como pequena disponibilidade hídrica no solo ou mesmo déficit hídrico, baixas temperaturas e menores intensidades de radiação. Já com o início das precipitações, aumento da intensidade luminosa e também da temperatura, a fase de maior desenvolvimento da cultura acontece de outubro a abril, com o pico do crescimento por volta de dezembro a abril. Após o primeiro corte, ocorrem brotações sucessivas, com ciclos de 12 meses, podendo ocorrer até cinco cortes antes de se realizar a renovação do canavial - é a cana denominada de cana “soca”.

Segundo MACHADO *et al.* (1982) a fase inicial de crescimento lento ocorre entre o plantio e 200 dias após ele (março-outubro); a fase de crescimento rápido, entre 200 a 400 dias após o plantio, na qual 75% da Matéria Seca é acumulada (outubro-maio) e a fase final, entre 400 - 500 dias após o plantio, onde o crescimento é novamente lento e responsável por 11% de toda a fitomassa (maio-agosto) (Figura 4).

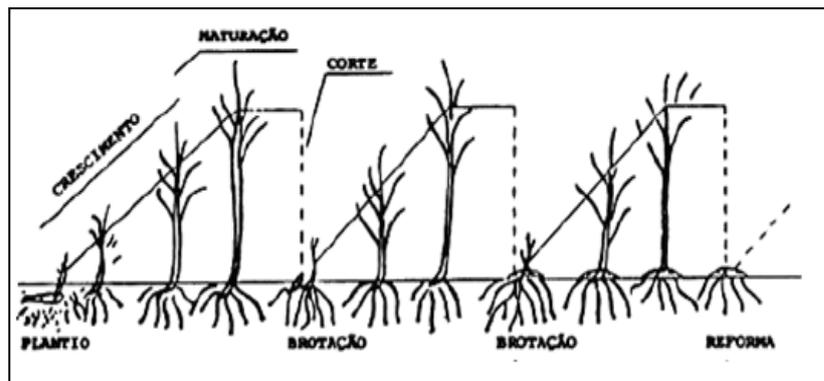


Figura 4 - Ciclo de cultura de cana-de-açúcar com três cortes. **Fonte:** Rodrigues (1995).

2.2 Sensoriamento Remoto e Extração de Informações

O sensoriamento remoto pode ser definido como a tecnologia que permite a aquisição de informações sobre um objeto sem contato físico com ele, onde o objetivo principal é ampliar a percepção sensorial do ser humano, seja através da visão panorâmica das informações aéreas ou espaciais, ou pela possibilidade de se obter informações que seja difícil da visão captar (NOVO, 1992).

O sensoriamento remoto fornece ainda um amplo conjunto de conhecimentos e técnicas úteis para caracterizar fenômenos dinâmicos como em áreas urbanas, agrícolas, dentre outras, consistindo também em uma alternativa para identificação e quantificação de áreas irrigadas de pivô central, devido à forma dos alvos intrinsecamente definidos na imagem (PORTILLO *et al.*, 2003) Por isso, o progresso e a validação de técnicas de análise multitemporal são importantes para conduzir conhecimentos necessários à melhor utilização do sensoriamento remoto neste campo (BRAGA, 2005). Por meio da interpretação de imagens de satélite, obtém-se, de forma rápida, um mapa temático atualizado e preciso das diferentes estruturas espaciais resultantes do processo de ocupação e uso do solo.

Dados do satélite Landsat são recebidos desde 1973 e contam com toda infra-estrutura para sua recepção, processamento e distribuição, através do *Instituto Nacional de Pesquisas Espaciais – INPE* (NOVO, 1992).

As imagens TM/ Landsat -5 possuem uma resolução temporal de 16 dias e cada cena cobre área de 185 km x 185 km no terreno. Quanto à resolução espectral, o sensor *Thematic Mapper - TM* abrange sete bandas, seis delas nos

comprimentos de onda correspondentes ao visível e ao infravermelho próximo e médio, com resolução espacial de 30 m; a outra banda situa-se no infravermelho termal e possui resolução espacial de 120 m. A escolha das bandas espectrais é fator importante para o sucesso de interpretação de imagens de satélite, dependendo dos objetivos, existem bandas mais adequadas por refletirem informações necessárias (MOREIRA, 2003). Por exemplo, estudos relacionados à qualidade e quantidade de água em um rio teriam sucesso em utilizar a banda 2, na região do espectro verde, sensível quanto à presença de sedimentos em suspensão. No Quadro 1 observam-se as principais características e aplicações do TM/ Landsat -5 e do ETM+/ Landsat -7.

Quadro 1 - Principais características e aplicações da radiação eletromagnética correspondente às bandas do sensor TM/ Landsat-5 e do ETM+/ Landsat -7.

Banda	Faixa espectral (µm)	Região do Espectro	Principais aplicações das bandas do Landsat
1	0,45 – 0,52	Azul	Penetra corpos d'água, sofre absorção pela clorofila e outros pigmentos da planta, sensível às plumas de fumaça oriundas de queimadas ou de atividade industrial. Pode apresentar atenuação atmosférica.
2	0,52 – 0,60	Verde	Sensibilidade à presença de sedimentos em suspensão, possibilitando análise quanto à quantidade e qualidade da água. Boa penetração em corpos d'água.
3	0,63 – 0,69	Vermelho	Forte absorção pela vegetação verde. Contrasta áreas com e sem vegetação e diferentes tipos de vegetação. Permite análise litológica em locais com pouca vegetação. Permite o mapeamento de rede de drenagem em regiões com pouca cobertura vegetal. É a banda mais utilizada para delimitar a mancha urbana.
4	0,76 – 0,90	IV próximo	Forte absorção da energia nesta região pela água. Vegetação verde, densa e uniforme reflete muita energia. Sensível à morfologia do terreno. Distingue áreas ocupadas com vegetação que foram queimadas.
5	1,55 – 1,75	IV médio	Sensível ao teor de umidade das plantas. Esta banda sofre perturbações em caso de ocorrência de chuvas antes da obtenção da imagem pelo satélite.
6	10,4 – 12,5	IV termal	Sensível aos fenômenos relativos aos contrastes térmicos detectando propriedades termais de rochas, solos, vegetação e água.
7	2,08 -2,35	IV médio	Sensível à morfologia do terreno, na identificação de minerais com íons hidroxilas e favorável à discriminação de produtos de alteração hidrotermal.

Adaptada de Moreira (2003).

O sensor *Enhanced Thematic Mapper Plus – ETM+* possui as mesmas características espectrais, exceção da inclusão de uma oitava banda pancromática com resolução espacial de 15 m que corresponde à faixa espectral em de 0,52 - 0,90 μm , na região do espectro no visível e no infravermelho próximo, apresentando melhoria na resolução da banda do infravermelho termal para 60 m. Lançado em abril de 1999 esse sensor deixou de operar em maio de 2003, devido a problemas no espelho corretor do deslocamento (MOREIRA, 2003).

A partir do lançamento do primeiro satélite da série Landsat, modelos baseados em cadastros de propriedades rurais de previsão de safra foram aprimorados, através do uso de imagens de satélites como fonte de dados para pesquisa e para previsões (CHEN, 1980). A introdução de imagens de satélites na abordagem metodológica colaborou também para estudos sobre as relações entre os dados coletados por satélites e os parâmetros agronômicos da cultura. Projetos como *Crop Identification Technology Assessment by Remote Sensing - CITARS*, *Large Area Crop Inventory Experiment - LACIE* e *Agriculture and Resources Inventory Surveys Through Aerospace Remote Sensing - AGRISTARS* forneceram uma base sólida para métodos de estimativa de áreas cultivadas (CHEN, 1990). A importância dos dados de plataformas orbitais no planejamento eficiente da irrigação tem sido enfatizada cada vez mais por muitos autores, como Bastiaanssen et al.(2000), onde dados atualizados sobre qual a cultura, área cultivada, quantidade de água utilizada em cada cultura são difíceis de serem obtidos em áreas de centenas de quilômetros quadrados e o grande número de fazendas (EL-MAGAD & TANTON, 2005).

Bastiaanssen et al. (2000) fizeram um resumo das potenciais aplicações, diretas e indiretas, dos dados de sensores ópticos e ativos no manejo da irrigação. Dentre as aplicações: a salinidade do solo, produtividade agrícola, precipitação e evapotranspiração potencial (Quadro 2). El-Magad e Tanton (2005) realizaram um estudo comparativo entre os modelos SEBAL e Penman-Monteith para estimativa da demanda de água em áreas irrigadas ao Norte do Mar de Aral, conseguindo exatidão de classificação de 94% com uma cena do sensor ETM+ \Landsat-7. A E_{Tc} foi calculada pelo produto da E_{To} , derivada do modelo Penman-Monteith, pelo coeficiente das culturas (K_c). Os autores sugerem mais estudos para

validação do SEBAL, pois este apresentou diferença de 20% na estimativa da evapotranspiração via Penman-Monteith.

Quadro 2 - Informação sobre a irrigação e recursos hídricos a partir de dados de sensoriamento remoto para manejo da irrigação.

Tópico	Exatidão	Informação de campo	Melhor método na atualidade
Produtividade agrícola	Boa	Reduzida	Biomassa e índice de colheita
Precipitação	Baixa	Alta	Dados TRMM ¹
Evapotranspiração atual	Boa	Limitada	Algoritmo SEBAL
Evapotranspiração potencial	Boa	Limitada	Evapotranspiração de referência e coeficiente da cultura

Adaptada de Bastiaanssen et al. (2000).

¹ *Tropical Rainfall Mission Satellite*

2.2.1 Retificação Radiométrica

A retificação radiométrica é o ajuste dos valores digitais (ND) das imagens, obtidas em diferentes datas de passagem do satélite, para similares condições tendo como referência uma dessas passagens. Neste procedimento é assegurado que as mudanças observadas no comportamento espectral, no tempo e no espaço, estão estritamente ligadas à interação da radiação eletromagnética com o alvo, amenizando ou uniformizando contribuições do ambiente (aerossóis, geometria de aquisição, degradação de detectores) na reflectância do alvo que foi registrada pelo sensor (EPIPHÂNIO & FORMAGGIO, 1988; HALL *et al.*, 1991; MOREIRA, 2003). Esse procedimento permite tornar as imagens comparáveis em termos de condições atmosféricas e de aquisição (calibração do sensor e iluminação), assegurando assim, que mudanças temporais ou espaciais correspondam a diferenças reais de um mesmo alvo em diferentes datas de aquisição (HILL & STURN, 1991).

A normalização de imagens através da técnica retificação radiométrica pode ser realizada em duas etapas. A primeira consiste na conversão dos números digitais das imagens em valores de reflectância aparente; a segunda etapa refere-se ao processo de retificação radiométrica propriamente dita (HALL *et al.*, 1991). Para tanto, uma imagem retificada em relação a uma de referência, deve parecer como se estivesse sido obtida pelo mesmo sensor e nas mesmas condições atmosféricas e de iluminação da imagem de referência (HALL *et al.*, 1991), sendo necessária para a uniformização de efeitos atmosféricos, ângulos de iluminação e degradação de detectores.

Hall *et al.* (1991) propuseram um algoritmo para retificar radiometricamente imagens do sensor TM/Landsat. O algoritmo está baseado em valores de reflectância de pontos de controle radiométricos ou pseudo-invariantes. Ao contrário dos pontos de ajuste geométrico utilizados em procedimentos de gerreferenciamento, as áreas de controle radiométrico não possuem localização fixa entre as cenas, como o solo exposto, por exemplo. Para a localização destes pontos de controle radiométrico, Hall *et al.* (1991) sugere a utilização da transformação espectral “Tasseled Cap”, também conhecida como transformação

“KT”, proposta por Kauth e Thomas (1976). Esta transformação descreve a trajetória espectro-temporal dos pixels de uma cena agrícola resultando num desenho semelhante a um capuz, daí o nome. A plotagem da primeira componente da transformação KT - “brightness” - na abscissa com a segunda componente - “greenness” - na ordenada permite verificar os intervalos de valores dos alvos pseudo-invariantes e dependendo do aplicativo, localizá-los. A obtenção de cada banda retificada $T(i)$, é dada pela seguinte equação:

$$T(i) = m_i x_i + b_i \quad (2.1)$$

Onde: x_i = banda espectral a ser retificada; m_i e b_i são os coeficientes de inclinação e intercepto calculados através das equações (2.2) e (2.3) abaixo:

$$m_i = (B_{Ri} - D_{Ri}) / (B_{Si} - D_{Si}) \quad (2.2)$$

$$b_i = (D_{Ri} - B_{Si}) - (D_{Si} B_{Ri}) / (B_{Si} - D_{Si}) \quad (2.3)$$

Onde: D_{Si} , D_{Ri} , B_{Si} , B_{Ri} são as médias para as áreas pseudo-invariantes escuras (D) e claras (B) para as imagens a serem retificadas (S) e para as imagens de referência (R).

A técnica de normalização radiométrica é recomendável para ajustar radiometricamente uma série temporal de imagens, sendo necessário corrigir atmosféricamente apenas uma imagem da série. Testes mostraram que a diferença para as áreas pseudo-invariantes não diferiam mais de um DN, caso a correção fosse aplicada a priori em todas as cenas.

2.2.2 - Correção Atmosférica

Imagens obtidas em datas distintas apresentam-se sob diferentes condições atmosféricas e de iluminação. A fim de amenizar a diferença entre as respostas comuns de diferentes alvos presentes nas cenas, procedimentos de correção atmosférica e de normalização relativa têm sido recomendados por alguns autores como Chavez (1988), Schott *et al.* (1988), Hall *et al.*, (1991) e Vermote *et al.*, (1997).

Os sinais da radiação eletromagnética (REM) coletados por sensores remotos são modificados por processos decorrentes do espalhamento e da absorção de gases e de aerossóis quando atravessam a atmosfera. A intensidade da interferência atmosférica é dependente do ângulo de visada, da altitude de varredura do sensor, da frequência e da distribuição das partículas de bruma (névoa) presentes no momento de aquisição dos dados. Estas interferências ocasionam a perda de nitidez das informações contidas nas imagens multiespectrais (CRANE, 1971). A correção da interferência atmosférica em imagens multiespectrais pode ser realizada a partir da utilização de modelos que simulam as propriedades ópticas da atmosfera através de alvos com reflectância conhecida ou através de métodos que utilizam feições presentes na própria imagem (CHEN *et al.*, 1995; CHAVEZ JR, 1988).

O método de subtração do pixel escuro, ou *Dark Object Subtraction - DOS* (CHAVEZ JR., 1988) - é bastante utilizado para corrigir os efeitos do espalhamento atmosférico seletivo (Rayleigh). Esta metodologia assume a existência de objetos escuros na imagem e que possuem valores de reflectância muito próximos de zero. No entanto, estes alvos aparecem na imagem com valores superiores ao real devido ao efeito de espalhamento atmosférico. Portanto, um determinado valor calculado a partir do mínimo valor de ND é atribuído ao espalhamento e deve ser removido de todos os pixels da imagem. Segundo Luiz *et al.* (2003), existem algumas variações para calcular o valor do espalhamento em cada banda, cuja maneira mais simples consiste em calcular este valor apenas transformando o valor mais baixo de ND em cada banda no valor da radiância equivalente e subtraí-lo de todos os pixels da imagem. Outras metodologias levam em consideração a transmitância e utilizam valores normalizados de ganho. Maiores detalhes sobre a metodologia DOS podem ser encontrados em Chavez (1988, 1989 e 1996), Pax-Lenney (2001) e Song *et al.* (2001). Embora o primeiro método (DOS) admita a transmitância atmosférica como sendo a unidade, o segundo método (DOS2) leva em conta o cosseno do ângulo zenital Solar e o método DOS3 a transmissividade específica para cada banda (SONG *et al.*, 2001).

2.2.3 Índices de Vegetação

Os índices de vegetação são utilizados com o propósito de realçar o sinal da vegetação e permitir comparações espaço-temporais confiáveis como, por exemplo, da atividade fotossintética e das variações nos parâmetros estruturais do dossel.

O emprego de índices de vegetação possui vantagens como: compactação dos dados; valores relativos que compensam a variação de intensidade da radiação; correção parcial dos efeitos das variações locais das condições atmosféricas e das variações de ângulo de visada de sensores e ângulos solares, ponderando se esses efeitos na variação da reflectância recebida pelos sensores nas bandas que compõem os índices são da mesma magnitude. O índice de vegetação ideal deve ser sensível à vegetação, insensível ao fundo do solo e não interferências atmosféricas. A superfície da vegetação geralmente absorve a radiação na faixa de visível (0,4 a 0,7 μm - Visível) e reflete na faixa de infravermelho próximo (0,725 a 1,10 μm - Infravermelho Próximo), logo, o índice de vegetação pode ser uma razão, diferença ou várias combinações entre valores de reflectância da faixa de visível e da faixa de infravermelho próximo. Na década de 70 foram desenvolvidos vários índices, posteriormente outros índices derivados baseados nos dados obtidos por outros satélites, sem restrições às outras faixas espectrais (LIU, 2006).

Os dois índices de vegetação mais utilizados, segundo Moreira (2001), são o de Razão simples (*Ratio Vegetation Index - RVI*) e o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index - NDVI*).

O RVI e o NDVI apresentam equivalência funcional contendo o mesmo tipo de informação sobre os parâmetros biofísicos das culturas, porém o NDVI é mais sensível à vegetação esparsa, indicando as mudanças de índice de área foliar -IAF - o qual é um indicador de variação fenológica (JACKSON & HUETE, 1991). O NDVI é o resultado da combinação de duas bandas, corrigindo parcialmente os efeitos de presença dos constituintes atmosféricos, das perturbações radiométricas, expresso na equação (2.4):

$$NDVI = \frac{IVP - V}{IVP + V} \quad (2.4)$$

Onde: *IVP* = energia refletida na região do infravermelho próximo (0,725 a 1,10 μm)

V = Energia refletida nos comprimentos de ondas (0,4 a 0,7 μm)

O seu valor varia de -1 a +1 para superfícies com alguma vegetação, sendo os valores negativos a representação das nuvens e água, ao redor de zero, solo exposto e maior que zero vegetação. O valor +1 indica o mais alto grau de verde na superfície, representando uma vegetação mais densa ou uma vegetação em pleno vigor do crescimento, alcançando valor máximo (HOLBEN,1986).

O estudo do comportamento espectral de alvos agrícolas, através da razão entre bandas espectrais, é mais indicado diante do emprego separado de dados espectrais em cada banda do sensor porque minimiza os erros introduzidos nas estimativas da radiância pela resposta não-lambertiana dos alvos agrícolas (PINTER JR. *et al.*, 1985). Por apresentar estreita correlação com parâmetros biofísicos das plantas, como biomassa (JUSTICE & HIERNAUX, 1986; HOLBEN *et al.*, 1980) e índice de área foliar - IAF(PRICE, 1993), o NDVI tem sido utilizado no monitoramento de vegetações naturais, de áreas agrícolas e para classificar, monitorar e determinar os ciclos fenológicos das culturas.

De modo geral, este índice tem tido importante função no monitoramento de cultivos por indicar uma associação direta entre sua grandeza e as condições hídricas e de biomassa no desenvolvimento das culturas (FONTANA *et al.*, 1998). No trabalho de Neale *et al.* (1989) a evolução temporal de NDVI correlacionou bem com os estágios do crescimento da cultura que é intimamente ligado aos coeficientes da cultura (*Kc*) e índice de área foliar. Os autores apresentaram a seguinte equação (equação 2.5) para estimar o *Kc* em função linear do NDVI durante o ciclo fenológico da cultura:

$$Kc = aNDVI + b \quad (2.5)$$

Onde: *a* e *b* variam com as variações da reflectância causadas pelos diferentes tipos de solo.

A curva do $K_{c_{ini}}$ é constante para a maioria das condições culturais de crescimento, este mais o $K_{c_{fin}}$ podem variar diariamente e dependem da frequência de umidade do solo (FAO, 2006) como pode ser visto na Figura 5. O perfil temporal do NDVI, pode ser analisado como em Neale *et al.* (1989), para estimativas dos valores do K_c , tabelados pela FAO.

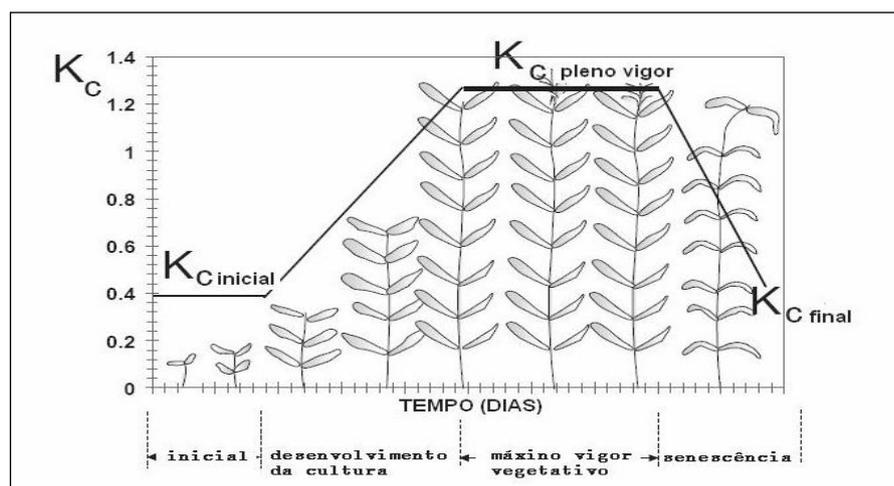


Figura 5 – Curva de K_c generalizada para culturas, adaptada da FAO (2006).

A existência de sensores com alta resolução temporal permite a geração desses índices com maior regularidade, favorecendo a análise e o monitoramento de culturas anuais de ciclo curto, com elevada dinâmica espectral. Este tipo de análise pode ser feita através da construção de gráficos descrevendo o perfil temporal do NDVI, ou seja, o comportamento do índice de vegetação ao longo de todo o ciclo produtivo, mostrando a emergência da cultura, desenvolvimento, maturação e senescência (LABUS *et al.*, 2002), assim, parâmetros quantitativos podem ser extraídos dos perfis temporais, ou de parte deles e correlacionados com valores de produtividade agrícola (HILL & DONALD, 2003).

Para o cálculo de NDVI são necessários valores de reflectância dos pixels da imagem corrigidos em relação aos efeitos atmosféricos, já que estes atuam de maneira desigual ao longo do espectro, sendo maior nos comprimentos de onda menores (SONG *et al.*, 2001).

2.3. Resposta espectral e classificação de alvos agrícolas

Quando a radiação solar incide sobre uma folha da planta, sua energia sofre três alterações: reflexão, absorção e transmissão e dependendo da estrutura da folha e da espécie de planta, estas são diferentes. Liu (2006) relata que a reflectância de uma folha madura é 5% menor que a de uma folha nova na faixa de visível, entretanto a folha madura reflete 15% mais que a nova na faixa do infravermelho próximo. As transmitâncias e reflectâncias múltiplas nas várias camadas de folhas de uma copa da vegetação resultam numa reflectância máxima de 75% na faixa do infravermelho próximo, região do espectro onde a reflectância aumenta com o aumento da idade de uma folha. Durante o ciclo de qualquer cultura anual, há três fases bem nítidas quanto ao padrão geral de comportamento espectral. No início há grande influência do solo, depois há uma fase de resposta espectral da vegetação verde, e no final do ciclo, há resposta de vegetação senescente e do solo. Em situação em que os alvos apresentam num dado momento comportamentos espectrais muito semelhantes é difícil realizar a separação dos mesmos por métodos computacionais quando observados de satélite, uma vez que os algoritmos de classificação levam em conta a diferença existente neste comportamento (BAUER *et al.*, 1981).

O emprego de informações multiespectrais de alvos agrícolas, coletados por sensores a bordo de satélites orbitais, tem sido, nos últimos tempos, muito utilizadas para quantificar e acompanhar as condições de culturas agrícolas devido, principalmente, as características de repetitividade do satélite e da visão sinóptica dos sensores. Entretanto, conforme comentam Shimabukuro e Smith (1991), o sucesso na caracterização e mapeamento de um determinado alvo, através de dados orbitais, depende das características do sensor e das características espectral e espacial do alvo que se deseja analisar.

Uma das causas da baixa exatidão na classificação de culturas agrícolas deve-se a heterogeneidade fenológica (e espectral) que uma mesma cultura apresenta em uma determinada cena, devido às datas de plantio não coincidirem entre os diferentes talhões. Um bom exemplo dessa heterogeneidade pode ser analisada em Medeiros *et al.*(1996). Os autores chegaram a criar cinco sub-classes

para a classe “soja” que foram reagrupadas após a classificação. Uma abordagem alternativa a criação de sub-classes e a utilização de uma única cena é a classificação espectro-temporal onde cada pixel é analisado de maneira contínua no tempo. Nesse método a variação temporal de cada pixel, captada pela repetitividade de um sensor, permite a descrição de um espectro-temporal que melhor descreve as culturas (GLERIANI et al., 2005).

A classificação espectro temporal tem sido utilizada com ganhos significativos em relação à imagem de uma única data, procedimento que vem sendo utilizado em locais onde os alvos agrícolas são dinâmicos. Existem problemas quanto a similaridade espectral entre as culturas em pleno vigor e a abordagem espectro-temporal tende a descrever a fenologia de uma dada cultura, resposta que está associada à variação de Índice de Área Foliar - IAF, função não só da fenologia, mas também das práticas culturais, como a densidade de plantio (GLERIANI, 2004).

Com o interesse de identificar uma cultura no espaço, é necessário atenção, pois, há situações em que irão existir alvos com o comportamento espectral similar ao da cultura de interesse, além disso, também é possível que uma mesma cultura apresente diferente resposta espectral em um mesmo espaço, por estarem distintos estádios de crescimento (RUDORFF *et al.* 2007), situação que faz os alvos apresentarem padrões espectrais diversos, dificultando e comprometendo melhores resultados no procedimento de classificação digital. Estes problemas podem ser corrigidos por meio de uma criteriosa interpretação visual na tela do computador, utilizando o conhecimento do intérprete sobre a cultura e a região de interesse, bem como imagens adquiridas em diferentes datas, dentro de “períodos-chave” ao longo do seu ciclo (RUDORFF *et al.*, 2007; RIZZI & RUDORFF, 2005; RUDORFF *et al.*, 2004). Porém este método além de demorado causa subjetividade ao mapeamento da cultura, assim, de acordo com Rudorff *et al.* (2007), o mesmo deve ser utilizado de forma restrita, onde, primeiramente, exploraram-se as melhores alternativas da classificação digital. Rudorff *et al.* (2007) sugerem como uma das alternativas, o método de *Spectral-Temporal Response Surface -STRS* (VIEIRA, 2000), limitado pela dificuldade de se obter imagens livres de cobertura de nuvens, principalmente durante o ciclo das

culturas de verão, o que acaba influenciando na frequência de aquisição de imagens do sensor utilizado (RUDORFF *et al.*, 2007). A análise espectro-temporal junto à utilização de índices como o NDVI, por apresentar bons resultados ao descrever a fenologia agrícola (BENEDETTI & ROSSINI, 1993) pode ser de grande sucesso na classificação. O pesquisador poderá realizar a composição das melhores imagens com dados de reflectância de superfície, em termos de menor cobertura de nuvens, sendo que as imagens deverão ser geométrica e radiometricamente corrigidas para tornar os alvos semelhantes comparáveis (RUDORFF *et al.*, 2007).

2.4 Classificação de Imagens e Generalização

Toda classificação supervisionada é baseada em generalização, onde um classificador é treinado com amostras que representam as características de interesse e aplicado a rotular dados desconhecidos (PAX-LENNEY *et al.*, 2001). A capacidade de aprender através de exemplos e de generalizar a informação aprendida é o atrativo principal da solução de problemas através de classificadores como as RNAs, que processam e interpretam grandes quantidades de dados. A generalização através das RNAs oferece a oportunidade de classificar uma paisagem sem que seja necessário treinar novamente o classificador para cada respectivo período de tempo. O conceito de generalização espaço-temporal, não é novo, estando associado ao conceito de assinaturas espectrais para discriminação de dados da superfície terrestre que são treinados e testados no tempo e no espaço, ambos diferentes. (PAX- LENNEY *et al.*, 2001). O trabalho de Myers (1983) destaca-se como uma das primeiras tentativas de generalização, através do projeto *Crop Identification Technology Assessment for Remote Sensing - CITARS*, onde foi testada a possibilidade de classificar áreas de soja em uma cena, com o classificador sendo treinado em outra cena. No trabalho de Myers (1983) não foi levado em consideração a interferência atmosférica, indispensável para realizar uma classificação generalizada (PAX-LENNEY *et al.*, 2001), o que acabou por comprometer a acurácia da classificação. Com o mesmo objetivo Pax-Lenney *et al.* (2001) testaram um classificador generalizado para monitorar mudanças em área florestada, especificamente avaliando a habilidade da classificação supervisionada por meio de redes neurais artificiais ARTMAP para distinguir

florestas coníferas de não-coníferas em 17 imagens Landsat (TM) de 1984 e 1996, com órbitas/pontos diferentes do noroeste de Oregon. Primeiramente, os autores generalizaram as informações dentro da cena temporalmente, treinando o classificador em uma data e tentando o mesmo para outra data, em seguida com um intervalo de tempo menor e com cenas de órbitas-pontos diferentes a generalização também foi feita temporalmente. Considerando a interferência atmosférica, foi testada a possibilidade de uniformização das condições atmosféricas através dos métodos: *Digital Numbers - DN*, no correlation; *Simple DOS – DOS 1* (Chavez, 1989); *A histogram math approach applied to DOS 1 - DOSIM– Corrected Bands*; *Improved DOS – DOS 2* (Chavez, 1996); *DOS 1 with a Rayleigh atmosphere – DOS3* (Song *et al.*, 2001) e *Radiative Transfer Code 6S - RTC* (Vermote *et al.*, 1997), já abordados anteriormente. Apesar da queda na exatidão de classificação em torno de 13%, métodos simples de correção como o DOS produziram resultados de uniformização similares aos modelos de transferência radiativa mais complexa.

2.4 .1 Redes Neurais Artificiais como Classificadores de Imagens

A busca por técnicas inspiradas no funcionamento do cérebro gerou uma linha de pesquisa em inteligência computacional conhecida como redes neurais artificiais ou sistemas conexionistas (BRAGA *et al.*, 1998).

2.4.1.1 Conceito e Origem

As RNAs são baseadas na estrutura fisiológica básica dos neurônios humanos, tentando reproduzir as funções das redes biológicas, possui em comum a base na unidade de computação paralela e distribuída que se comunicam através de conexões sinápticas, detectores de características, redundância e modularização das conexões (BRAGA *et al.*, 1998).

As várias unidades de processamento simples, ou os chamados “neurônios artificiais”, realizam uma operação também simples e bem definida, comunicam-se através de ligações, “as sinapses artificiais”, formando uma rede de elementos de processamento maciçamente conectados. Possuem a habilidade de “aprender” e “generalizar” a partir de informações limitadas, alterando a “intensidade” das conexões de um elemento com seus vizinhos (CAUDILL, 1991).

Cerqueira *et al.* (2001) descrevem um neurônio biológico como um corpo celular que possui dois conjuntos de ramificações chamados dendritos e axônio (Figura 6 a). A transmissão de sinais entre neurônios, segundo os autores, ocorre quando o sinal entra no neurônio através dos dendritos, passa pelo corpo celular e em seguida é transmitido para outros neurônios, da rede neural, através do axônio. O sinal de um neurônio para os dendritos de outro neurônio é chamada de sinapse, estas, representam barreiras que modulam o sinal que é trocado através delas e a quantidade de sinal trocado em uma sinapse depende de um parâmetro chamado de intensidade da sinapse. Em um neurônio artificial a intensidade da sinapse é simulada por um fator de ponderação chamado peso da sinapse ou simplesmente peso. Analogamente aos neurônios biológicos, os neurônios artificiais possuem um corpo de processamento de informação com duas ramificações: entradas (dendritos) e saída (axônio), conforme a Figura 6 b.

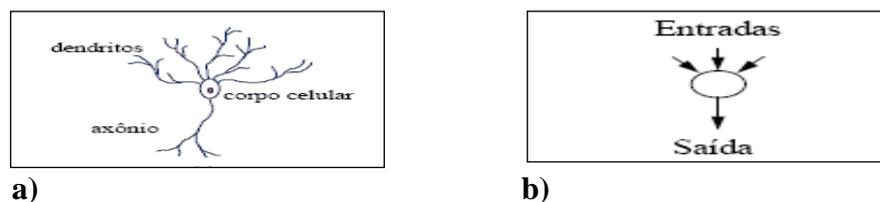


Figura 6 – a) Neurônio biológico, b) neurônio artificial.

Fonte: Cerqueira *et al.* (2001).

As RNAs possuem conhecimentos construídos, não programados, gerando seu próprio conhecimento, ou seja, aprendem, oferecendo soluções aproximadas que podem ser exatas e desta maneira oferecem soluções que podem ou não estar corretas (CERQUEIRA *et al.* , 2001).

2.4.1.2 Aplicações

As RNAs são capazes de generalizar o conhecimento adquirido, podendo ser utilizadas nas mais diversas áreas, principalmente em aplicações que envolvam a resolução de problemas de aproximação e mapeamento de funções e reconhecimento de padrões. Entretanto, para que as soluções através das RNA tenham desempenho satisfatório, os problemas devem ser tolerantes a uma “certa” imprecisão, dispor de uma grande quantidade de dados de treinamento e não

necessitar de regras de decisão discretas (por exemplo, 0 ou 1, sim ou não) (CAUDILL, 1991).

Recentemente, as RNAs têm sido empregadas com sucesso na classificação de imagens, por apresentarem vantagens sobre os classificadores estatísticos e com grande capacidade de generalização - capacidade de reconhecer com precisão padrões que não participaram do processo de treinamento (KAVZOGLU & MATHER, 2003; KIM *et al.*, 1995). Segundo Kavzoglu e Mather (2003), a classificação por RNAs vem apresentando maior exatidão no mapeamento em detrimento aos métodos estatísticos clássicos como o de Máxima Verossimilhança e por não ser um método paramétrico. Em um teste paramétrico a análise de interesse deveria possuir comportamento normal, pois o resultado extraído de um teste depende da validade em assumir a normalidade, necessitando, portanto de amostras maiores; as RNAs como método não-paramétrico independe do comportamento do fenômeno estudado e possui uma gama de testes que possibilitam tratar qualquer tipo de dado, suas vantagens estão no fato de não depender do formato da distribuição da população da qual a amostra é retirada, os cálculos de significância são exatos, se o tamanho da amostra utilizado no teste de hipóteses for muito pequena a utilização de procedimentos não paramétricos será a única alternativa, a menos que se tenha o exato conhecimento da natureza da população, além disso os testes não-paramétricos são mais simples de serem efetuados e mais fáceis de serem compreendidos que os testes paramétricos.

O sistema de inteligência artificial possui grande potencial na discriminação das classes de cobertura da terra, em comparação com os sistemas de classificação convencionais. A generalização, que está associada à capacidade da rede aprender através de um conjunto reduzido de exemplos e, posteriormente, dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações de entrada e saída (HAYKIN, 2001). As RNAs são capazes de extrair informações não apresentadas de forma explícitas através de exemplos. A utilização de uma RNA na solução de uma tarefa passa, antes de tudo, por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de informação apresentados para ela, criando assim uma representação própria para o

problema. Ainda segundo o mesmo autor, a etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. As redes são organizadas de acordo com o número de camadas que compõem a sua estrutura tipológica, existindo também as redes neurais de camadas simples, constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes multicamadas, formadas pela combinação de várias redes de camada simples (BUCENE & RODRIGUES, 2004).

Dentre os tipos de RNAs está a *Multilayer Perceptron* - MLP, uma rede de múltiplas camadas conectada com conexões por propagação - *feedforward*, o que significa que as camadas estão organizadas em uma ordem e os neurônios de uma camada estimulam todos os neurônios da camada seguinte. A arquitetura da rede de multicamadas é construída seguindo uma estrutura conceitual onde a camada de entrada é conectada à camada de saída por uma ou duas camadas ocultas como na Figura 7. A quantidade de neurônios da camada de entrada corresponde às variáveis discriminantes, enquanto que na camada de saída, ele é igual ao número de classes a serem identificadas; por sua vez o número de camadas ocultas e o de neurônios em cada uma são determinados de acordo com o problema (KAVZOGLU & MATHER, 2003). Para determinar o número de neurônios na camada oculta da rede são propostos dois métodos descritos por Vieira (2000), método construtivo (*growing*), onde a camada interna é iniciada com um pequeno número de neurônios que vai sendo adicionado um a um até convergirem a um erro pequeno e aceitável e método de poda (*pruning*), onde a camada interna tem início com um número de neurônio maior do que aquele esperado ser suficiente e à medida que se obtemos resultados, ocorre a remoção de neurônios considerados redundantes. Alguns autores fizeram proposta do número de neurônios que podem ser utilizado nas camadas ocultas, de forma heurística, porém, nenhuma é aceita para estimar a arquitetura ótima em determinados problemas (KAVZOGLU & MATHER, 2003)

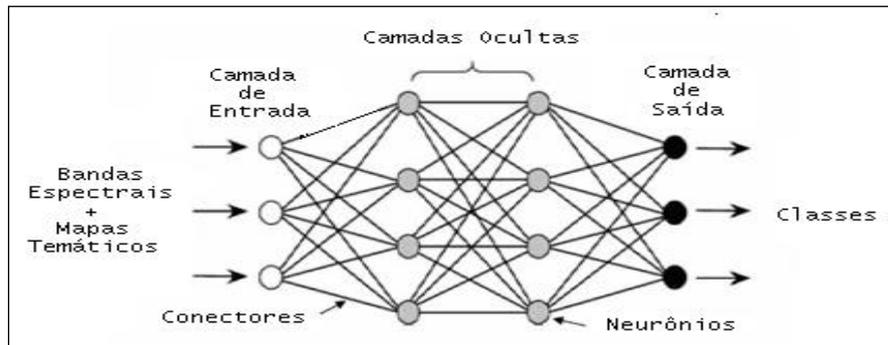


Figura 7 - Ilustração de uma rede MLP. **Fonte:** Modificado de Kavzoglu & Mather, 2003.

No processo de aprendizagem do classificador os números de ciclos de treinamento e a taxa de aprendizagem interferem significativamente na exatidão da classificação (VIEIRA, 2000) e a seleção de variáveis é o procedimento “chave” no processo de classificação, buscando selecionar dados de entrada representativos (BENEDIKTSSON & SVEINSSON, 1997).

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

O algoritmo de treinamento mais utilizado de uma MLP é proposto por Rumelhart e McClelland (1986), conhecido como algoritmo de retro-propagação do erro – *error back-propagation*. É um algoritmo supervisionado estático (não auto-organizável), ou seja, a arquitetura da rede deve ser previamente conhecida, e esta não é alterada durante o treinamento e os únicos parâmetros a serem alterados são os pesos da rede, utilizam-se pares (entrada, saída desejada) para através do mecanismo de correção de erro, ajustar os pesos da rede. A aprendizagem por

retro-propagação de erro é realizada pela fase de propagação – um passo para frente, definindo a saída da rede para um dado padrão de entrada e pela fase retro-propagação – um passo para trás, utilizando a saída desejada e saída fornecida pela rede para atualizar os pesos de suas conexões (BRAGA *et al.*, 1998; BUCENE & RODRIGUES, 2004) (Figura 8).

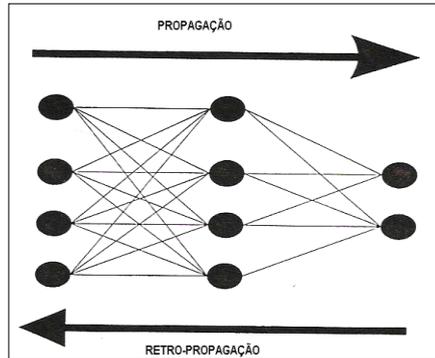


Figura 8 - Fluxo de processamento do algoritmo de retropropagação do erro.
Fonte: Braga *et al.* (1998).

A derivação da regra delta generalizada é simples, a função de custo a ser minimizada de acordo com Braga *et al.* (1998) é uma função de erro ou energia, definida pela soma dos erros quadráticos e representada pela respectiva equação (2.6) que define o erro total cometido pela rede, ou a quantidade, para todos os padrões “*p*” de um dado conjunto:

$$E = \frac{1}{2} \sum_p \sum_{i=1}^K (d_i^p - y_i^p)^2 \quad (2.6)$$

onde: *E* = medida de erro total,

p = número de padrões

K = número de unidades de saída

d_i = *i*-ésima saída desejada

y_i = *i*-ésima saída gerada pela rede

O funcionamento do algoritmo é descrito de forma que no passo para frente, um padrão de atividade (vetor de entrada) é diligente aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Finalmente, é

gerado um conjunto de saídas com a resposta da rede. Durante o passo de propagação, os pesos sinópticos da rede são todos fixos e na fase de retropropagação, os pesos sinópticos são todos ajustados de acordo com uma regra de correção do erro. Especificamente, a resposta da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Este sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinópticas. Os pesos sinópticos são ajustados para fazer com que a resposta real da rede se mova para mais perto da resposta desejada. Geralmente a aprendizagem por retropropagação inicia-se com uma amostra de treinamento e usa o algoritmo para calcular os pesos sinópticos de um MLP carregando (codificando) tantos exemplos de treinamento quanto possível para dentro da rede (HAYKIN, 2001). Espera-se que a rede neural assim projetada seja capaz de generalizar as informações em estudo.

Uma rede pode ser considerada generalizadora quando o mapeamento de entrada-saída computado pela rede for correto (ou aproximadamente correto) para dados de teste não utilizados durante a criação ou treinamento da rede (BUCENE & RODRIGUES, 2004).

2. 5 Avaliação da Classificação de Imagens

A análise da classificação é o último procedimento na classificação (CHEN, 1990). Para tanto existem métodos estatísticos que são utilizados para determinar o grau de concordância de uma imagem classificada em relação a um dado de referência terrestre, através da construção de matrizes de erro e de análise multivariada (CONGALTON & GREEN, 1999).

No tocante à classificação, o coeficiente Kappa (K) (CONGALTON & GREEN, 1999) representado na equação 2.7, é utilizado para avaliar a significância do seu desempenho e é representado pela matriz de contingência, também chamada matriz de erros ou de confusão (Figura 9). Esta matriz possibilita identificar o erro global da classificação, avalia o desempenho das classes individuais observadas, através dos erros de inclusão ou comissão (número de pixels classificados em uma classe a qual não pertencem) e omissão (número

de pixels que foram excluídos da classe a qual de fato pertencem) (CONGALTON & GREEN, 1999; CAMPBELL, 1987). A estatística Kappa expressa na equação (2.7) é baseada na análise multivariada e foi sugerida por Congalton *et al.* (1983) por utilizar todos os elementos da matriz de erro de classificação na sua formulação.

$$\hat{K} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} x_{+i}} \quad (2.7)$$

onde, \hat{K} = coeficiente ou estimador Kappa

r = número de linhas e colunas da matriz de erro;

x_{ii} = número de observações na linha i e coluna i ;

x_{i+} = total de observações na linha i ;

x_{+i} = total de observações na coluna i ;

N = número total de observações.

	Urbana	Floresta	Pasto	Solo	Água	Várzea	Totais	Erro de Comissão
Urbana								
floresta								
pasto								
solo								
água								
várzea								
Totais								
Erro de Omissão								

Fonte: Adaptado de Campbell (1987).

Onde:

	Imagem a ser avaliada
	Imagem de referência
	Linhas Marginais
	Colunas Marginais
	Pixels classificados corretamente
	Número total de pixels classificados corretamente (somatório da diagonal)

Figura 9 - Representação esquemática de uma matriz de erros.

Segundo Moreira (2003), o valor da estatística Kappa é comparado aos valores contidos no Quadro 3, desenvolvida por Landis e Koch (1977). Esta tabela foi elaborada para analisar os resultados de análise de diagnósticos clínicos. Entretanto, ela tem sido referência para classificar mapas resultantes da utilização de imagens de sensoriamento remoto, já que dentro de certas restrições, tem dado bons resultados.

Quadro 3 – Qualidade da classificação associada aos valores do Kappa.

Valor Kappa	Qualidade do mapa temático
<0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

Fonte: Adaptada de Landis e Koch (1977).

Quando o valor do Kappa é multiplicado por 100, informa o percentual da exatidão geral da classificação. Como os resultados são resumidos na forma de uma matriz de significância, na qual os elementos da diagonal principal indicam a significância da classificação, é possível a partir de cada matriz de contingência, calcular o valor Z usando a equação (2.8):

$$Z = \frac{|\hat{K}_1 - \hat{K}_2|}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (2.8)$$

Em que Z é padronizado com distribuição normal e *var* é a variância do coeficiente Kappa. Levando em consideração com as seguintes hipóteses $H_0 : \hat{K}_1 - \hat{K}_2 = 0$, $H_0 : \hat{K}_1 - \hat{K}_2 \neq 0$ e rejeita se $Z \geq Z_{\alpha/2}$, o que implica que a classificação é significativamente diferente em relação a uma classificação aleatória. É possível então, comparar o desempenho entre os diferentes métodos de classificação, que segundo Skidmore (1999), é um teste estatístico possível de ser aplicado em combinações pares de matrizes de erro, determinando se as matrizes são significativamente diferentes.

2.6 Contexto Ambiental

A classificação de imagens de satélite fornece informações quanto ao uso e ocupação do solo das áreas, sendo possível dessa maneira, analisar o aproveitamento do espaço de acordo com a legislação ambiental vigente, além de atribuir melhores usos dos recursos locais.

A degradação do meio ambiente, a disponibilidade de água, o crescimento populacional junto à expansão das fronteiras agrícolas, são assuntos bastante discutidos na atualidade. O setor de produção de alimentos amplia na proporção que a população cresce, demandando através da atividade agrícola 69% da água no Brasil, destacando-se também, no seu desperdício, pois da água derivada ou captada para irrigação apenas 50% são efetivamente utilizadas pelas culturas, refletindo previsões preocupantes em relação ao seu uso (CHISTOFIDIS, 2002; DOMINGUES, 2004), E segundo Bernardo *et al.* (2006) é possível prever que a irrigação irá crescer, pois a área agrícola plantada no Brasil evoluiu de 46,75 (1996) para 51,82 milhões de hectares (2000). A evolução da superfície dominada com sistemas de irrigação e drenagem, destinados à agricultura, indicam que no período de 25 anos houve a incorporação de 1,85 milhões de hectares entre 1975 e 1999 (CHISTOFIDIS, 2002). A área irrigada no país alcançou no ano de 2003, 3,44 milhões de hectares (CHISTOFIDIS, 2006).

A definição de área irrigada no país depende de aspectos como a disponibilidade de água e a viabilidade da sua utilização, sendo necessário considerar a área realmente disponível e a necessidade de preservação de ecossistemas como as várzeas. Neste tocante, segundo Bernardo *et al.* (2006) a expansão da área irrigada deveria ocorrer na substituição de áreas de agricultura de sequeiro (atividade que conta com a água da chuva para que a cultura complete o seu ciclo) e pastos. No Brasil estima-se que o potencial para desenvolvimento sustentável da irrigação é de 14,6 milhões de hectares em terras altas e de 14,9 milhões de hectares em várzeas, onde dessas apenas 3,4 milhões de hectares encontram-se sob irrigação e é levada em consideração a possibilidade de desenvolvimento sustentável da irrigação e o potencial dos solos, tendo seu valor definido a partir de fatores como a disponibilidade de recursos hídricos sem risco de conflitos com usos prioritários da água e atendendo também, a legislação ambiental do Código Florestal (BERNARDO *et al.*, 2006).

Junto à expansão agrícola o solo vem sendo explorado de forma errônea, comprometendo rios e contribuindo para o uso irracional da água, o que comprova a necessidade de substituição dos métodos de irrigação de baixa eficiência, demandando quantidade de água superior do que a requerida pelos

cultivos. Não adotando um método de controle na irrigação, o produtor rural usualmente irriga em excesso, comprometendo a produção e gerando desperdício de energia e de água (CHISTOFIDIS, 2002). A agricultura irrigada, na maior parte das vezes substitui a mata ciliar, relacionada diretamente com a qualidade da água, sua devastação provoca o assoreamento, destruição dos ecossistemas do leito dos rios, erosão, aumento da temperatura da água, diminuição do oxigênio, agravamento de secas e cheias, fim dos alimentos para a fauna aquática e escoamento de resíduos agrotóxicos das áreas agrícolas mais elevadas (FARIA & SOAREA, 1999; ARCOVA & CICCIO, 1999). Um exemplo está no estado de São Paulo, maior produtor nacional de cana-de-açúcar que expande cada vez mais sua produção (CORBI *et al.*; 2006) e junto os recursos hídricos próximos às plantações são comprometidos devido a devastação das matas ciliares, aplicação e uso de herbicidas, pesticidas e fertilizantes durante os diferentes estádios de cultivo da cana. Com o objetivo de avaliar o grau de impacto deste cultivo em córregos adjacentes à cana-de-açúcar Corbi *et al.* (2006), analisou 16 organoclorados e os metais (Cu, Fe, Cd, Zn, Mn, Cr e Ni) presentes nos sedimentos, que desempenham papel importante na poluição dos rios e córregos por metais compostos organoclorados, refletindo na qualidade da água. Esta análise foi realizada em 11 córregos situados em áreas distintas: córregos com mata ciliar, córregos com pastagem e sem mata ciliar; córregos com cana-de-açúcar e sem mata ciliar. Estes últimos evidenciaram o grande problema da devastação das matas ciliares, acarretando diferentes impactos nos recursos hídricos da região central de São Paulo. Para reverter tal situação, Corbi *et al.* (2006), Faria e Soares (1999) destacam a importância de manter a floresta nas áreas de Preservação Permanentes – APP's (mata ciliar, topo de morros e declives elevados), protegidas pelo Código Florestal, sendo necessária a recuperação das matas ciliares, a conscientização sobre o problema, apoio técnico aos projetos e iniciativas setoriais políticas de incentivo e fomento. Com tudo, segundo Marques (2002), é necessário urgentemente a modificação da legislação de proteção ambiental, recentemente promulgada no Brasil, fere profundamente as sábias leis da natureza e os próprios princípios científicos, dificultando e até mesmo impedindo o uso racional e a utilização mais econômica para o desenvolvimento

sustentado da agricultura. A legislação impede que a terra seja realmente explorada de acordo com sua verdadeira capacidade de uso, prejudicando os agricultores tirando-lhes o direito, por exemplo, de usar parcelas importantes de suas terras planas em cultivos anuais e até mesmo em pastagens (MARQUES, 2002).

3. MATERIAL E MÉTODOS

3.1 Localização da Área de Estudo e Caracterização Geral

A cidade de Miguelópolis-SP está localizada entre as coordenadas de 47° 54' 8" , 48° 16' 31,7" W e latitude 20° 5' 14,2" , 20° 23' 16,8" S, representada no retângulo pontilhado (Figura 10). Está situada no Norte do estado de São Paulo, possuindo maior porção no município de Miguelópolis – SP, cuja área é de 827Km², com altitude 510m e no ano de 2002 possuía 138 sistemas de pivô central.

Na área ocorrem solos férteis, predominando, Latossolos Vermelhos (LV) e Latossolos Amarelos (LA), com relevo suave ondulado a plano (OLIVEIRA *et al.*; 1999). O local faz parte de uma bacia com grande disponibilidade de água e excelente acesso à malha viária (BRAGA, 2005).

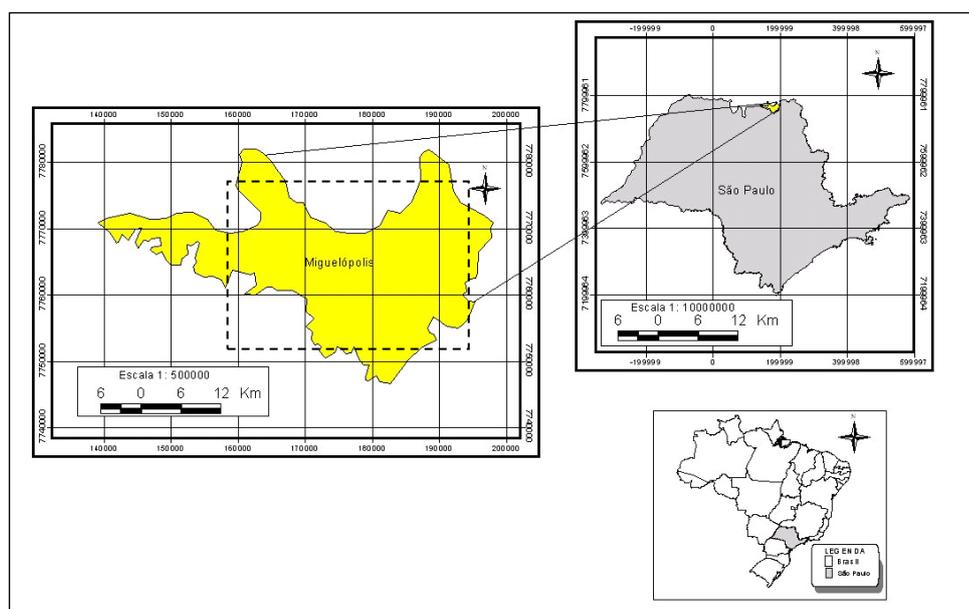


Figura 10 – Localização do município de Miguelópolis-SP e área de estudo representada pelo retângulo pontilhado.

Na área predominam os cultivos de soja e milho no verão, feijão, milho e sorgo no inverno e cana de açúcar o ano todo. Em algumas propriedades existe o cultivo de milho “safrinha” plantado imediatamente após a colheita do milho ou soja de verão. A grande variabilidade da data de plantio faz com que exista uma

grande variação fenológica intra-classe, cuja caracterização espectral é praticamente impossível.

3.2 Base de Dados

Foram utilizadas 20 imagens do satélite Landsat, órbita/ponto 220/74, com a resolução de 30m, sendo 13 delas ETM+/Landsat-7, uma simulada por Gleriani (2004) e o restante do TM/Landsat-5 (Quadro 4). Assim como o citado autor utilizou a imagem do dia 10 de março de 2002 como a imagem referência para a retificação do conjunto de cenas de 2002, por apresentar qualidade visual superior às demais, a mesma foi referência para o conjunto de cenas de 2001.

Quadro 4 – Relação das Imagens utilizadas.

Data da imagem	Sensor/ Satélite	Uso
10/03/2002	ETM+/Landsat 7	Referência para retificação radiométrica
16/04/2001	TM/Landsat 5	Classificação
02/05/2001	TM/ Landsat 5	Classificação
18/05/2001	TM/ Landsat 5	Classificação
03/06/2001	TM/ Landsat 5	Classificação
27/06/2001	ETM+/Landsat 7	Classificação
05/07/2001	TM/ Landsat 5	Classificação
29/07/2001	ETM+/Landsat 7	Classificação
14/08/2001	ETM+/Landsat 7	Classificação
07/09/2001	TM/ Landsat 5	Classificação
25/10/2001	TM/ Landsat 5	Classificação
11/04/2002	ETM+/Landsat 7	Classificação
27/04/2002	ETM+/Landsat 7	Classificação
13/05/2002	ETM+/Landsat 7	Classificação
29/05/2002	ETM+/Landsat 7	Classificação
14/06/2002	ETM+/Landsat 7	Classificação
16/07/2002	ETM+/Landsat 7	Classificação
01/08/2002	simulada por Gleriani (2004)	Classificação
17/08/2002	ETM+/Landsat 7	Classificação
02/09/2002	ETM+/Landsat 7	Classificação

3.3 Software para Processamento dos Dados

Foi utilizado para registro, correção radiométrica e demais procedimentos o software de *Sistemas de Informações Geográficas - SPRING*, versão 4.3.3, que pode ser encontrado no site do Instituto Nacional de Pesquisas Espaciais – INPE (disponível em: <http://www.dpi.inpe.br/spring/>) (CÂMARA, *et al.*, 1996).

Para processar as atividades de montagem da arquitetura da rede e treinamento, foi utilizado o *software* livre *Stuttgart Neural Network Simulator - SNNS*, simulador de Redes Neurais desenvolvido pelo *Institute for Parallel and Distributed High Performance Systems na Universidade de Stuttgart*. O mesmo possui capacidade de criar um ambiente de simulação eficiente e flexível para pesquisa na área de redes neurais e pode ser encontrado na página do *software* (disponível em: <http://www-ra.informatik.unituebingen.de/SNNS/>), onde o usuário encontra um fórum para dúvidas e manuais em formato digital para consultas *on-line*.

3.4 Processamento

Todas as cenas foram georreferenciadas com base no banco de imagens do ano de 2002 criado por Gleriani (2004). A reamostragem foi realizada pelo método do pixel do vizinho mais próximo, preservando de acordo com Thomas *et al.* (1987) o valor digital original do pixel e a projeção/datum utilizados foi a UTM/SAD-69. Procurou-se sempre um erro médio quadrático (RMSE) menor que 0,5 pixel.

3.4.1 Retificação Radiométrica

Após o registro das imagens de 2001, estas passaram pela retificação radiométrica, tendo acena do dia 10 de março de 2003 como referência a qual passou por processamento de correção atmosférica com o algoritmo DOS3 (Song *et al.*, 2001) implementado por Gleriani (2004) em linguagem LEGAL. Esta etapa foi executada através da linguagem de programas do Spring, chamada *Linguagem Espacial para Geoprocessamento Algébrico - LEGAL* (CÂMARA *et al.*, 1996).

A retificação foi executada através da linguagem LEGAL na seguinte seqüência:

1- Geração das componentes “greenness” (GR) e “brightness” (BR), para gerar os chamados planos de informação GREENNESS e BRIGHTNESS no Spring, para cada dada imagem (Apêndice 1a).

2. Fatiamento das componentes GR (Apêndice 1b) e BR (Apêndice 1c) em dois níveis, para obter os valores dos alvos pseudo-invariantes (de controle radiométrico) nos temas claros e escuros, para serem entrada no LEGAL de cruzamento de GR e BR. Foram considerados alvos pseudo-invariantes o solo exposto (tema claro) e a água (tema escuro), obtidos no Spring no modo Info para serem adicionados ao LEGAL para gerar BR claros e escuros e GR claros e escuros de cada cena.

3. Cruzamento dos temas claros GR e BR (Apêndice 1d), temas escuros GR e BR (Apêndice 1e), para obter áreas comuns e de controle radiométrico.

4. Obtenção dos valores das médias, nas regiões temáticas claras (Apêndice 1f) e escuras (Apêndice 1g).

5. Retificação das imagens pelo método proposto por Hall *et al.* (1991). Para cada banda espectral T(i), a transformação linear é dada pela equação (3.1):

$$T(i) = m_i x_i + b_i \quad (3.1)$$

Onde: x_i = banda espectral a ser retificada; m_i e b_i são calculados através da equação (3.2) e da equação (3.3):

$$m_i = (B_{Ri} - D_{Ri}) / (B_{Si} - D_{Si}) \quad (3.2)$$

$$b_i = (D_{Ri} - B_{Si}) - (D_{Si} B_{Ri}) / (B_{Si} - D_{Si}) \quad (3.3)$$

As equações acima foram implementadas na linguagem LEGAL de acordo com o Apêndice 1h.

6. Obtenção das médias dos valores para os alvos claros (Apêndice 1i) e escuros (Apêndice 1j) da imagem retificada, para verificar se estes não diferiam em mais

de uma unidade em relação à média para os respectivos alvos da imagem de referência. Condição proposta em Hall *et al.* (1991) de que $\Delta DN < 1$.

Após a retificação os valores obtidos para cada banda foram normalizados entre 0 e 1 para que existisse uma correta ponderação dos dados de entrada para a rede (Bishop, 1995).

3.4.2 Geração do NDVI

A geração do NDVI (equação 3.4), também realizada em linguagem LEGAL pode ser verificada no Apêndice 1m.

$$NDVI = (B4 - B3) / (B4 + B3) \quad (3.4)$$

Sendo B4 e B3 os valores linearizados da banda 4 e da banda 3.

3.4.3 Imagens reflectância

Com base em parâmetros de calibração da radiância (L) e da irradiância (E) publicados por Chander e Markhan (2003), para o sensor TM/Landsat-5, e dos mesmos parâmetros publicados nas páginas da NASA (NASA, 2007 a e b) para o sensor ETM+/Landsat-7, fez-se, a calibração das cenas. O computo foi realizado através de linguagem LEGAL/SPRING (Apêndice 1n), implementando as equações a seguir. Apenas para o sensor ETM+ \ Landsat-7 existe, atualização dos parâmetros para alto e baixo ganho, dependendo dia do ano, também publicados na página eletrônica:

(http://landsathandbook.gsfc.nasa.gov/handbook/handbook_htmls/chapter6/chapter6.html).

$$\rho_{ap} = \frac{\pi \cdot d^2 \cdot L}{E_0 \cdot \cos \theta_z} \quad (3.5)$$

Onde ρ_{ap} é a reflectância aparente, π (sr) é o parâmetro de conversão da radiância em irradiância, E_0 consiste na irradiância solar ($W \cdot m^{-2}$), θ_z é o ângulo zenital solar, e L é a radiância ($W \cdot m^{-2} \cdot sr$) é obtido através da equação (3.6), :

$$L = \frac{L_{max} - L_{min}}{255} * DN + L_{min} \quad (3.6)$$

e d , é a distância relativa Terra-Sol, em unidades astronômicas (UA) expressa na equação (3.7).

$$d = 1 - 0,01673 * \cos(0,9856 * DA - 4) \quad (3.7)$$

Onde DA é o dia do ano, variando de 1 a 365.

3.4.4 Amostras e Arquitetura das Redes

Todos os arquivos das imagens retificadas e das imagens apenas com a reflectância, foram convertidos para um formato possível de conversão para os softwares utilizados, foi feita a opção de utilizar o formato ASCII (conjunto de caracteres de texto usado por muitos programas MS-DOS) com dimensões 1451 colunas x 1014 linhas, em seguida exportadas do SPRING e organizadas em arquivos de extensão pat (SNNS), com a utilização do algoritmo de retropropagação do erro - *backpropagation*. Os dados de entrada para a rede foram normalizados entre 0 e 1, pois segundo Bishop (1995) em ordens de magnitude a saída da rede pode não expressar igualmente a importância dos mesmos no resultado final, caso não estejam.

Utilizou-se a rede com arquitetura 40-12-8 treinada com 150 ciclos e 40-70-8 proposta por Fletcher e Goss (1993). A arquitetura 40-12-8 foi obtida via módulo IPS (*Intelligent Problem Solver*), fornecendo o número de 12 neurônios na camada oculta. O uso de 40 neurônios deve-se a utilização dos seguintes parâmetros espectrais: b3, b4, b5 e o NDVI em 10 datas (Figura 11), datas ainda não testadas por Gleriane (2004). Oito neurônios na camada de saída devido às oito classes previamente descritas em Gleriani (2004), e a utilização do modo expandido de saída, sugeridos por Tso e Mather (2001). O erro de saída desejado foi de 0,01.

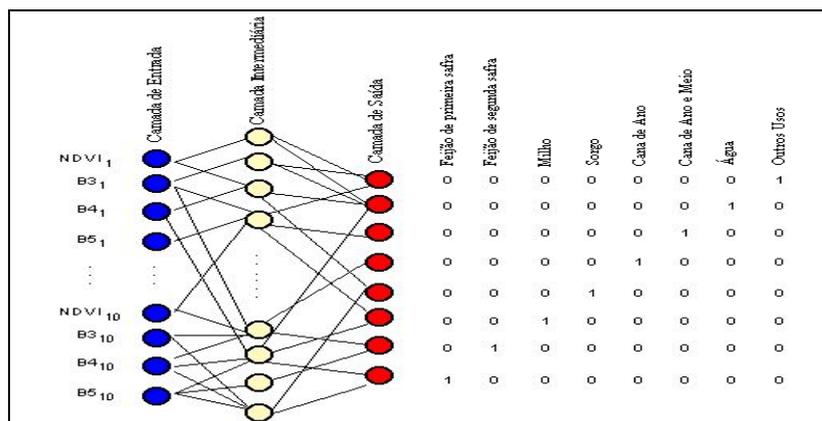


Figura 11 – Entrada multitemporal do NDVI e das bandas 3, 4 e 5 na rede com arquivos de médias e a correspondente codificação de saída.

As classes foram selecionadas via auxílio de campo pelo técnico agrícola da Casa da Agricultura (GLERIANI, 2004) e confirmação pelo perfil do NDVI definindo-se 8 classes: feijão da primeira safra, feijão da segunda safra, sorgo, milho, cana de ano e meio, cana colhida no ano, água e não agrícola.

Após a execução das classificações, organizaram-se os arquivos em matrizes ASCII e procedeu-se a importação para o Spring, onde foi gerado os mapas temáticos através da implementação do LEGAL (Apêndice 1o).

Foi realizada uma amostragem aleatória de 930 pontos de referência para executar a tabulação cruzada e a exportação da respectiva matriz para a planilha Excell, e em seguida fazer o cálculo do Kappa e da estatística Z.

A seqüência de atividades está ilustrada na (Figura 12):

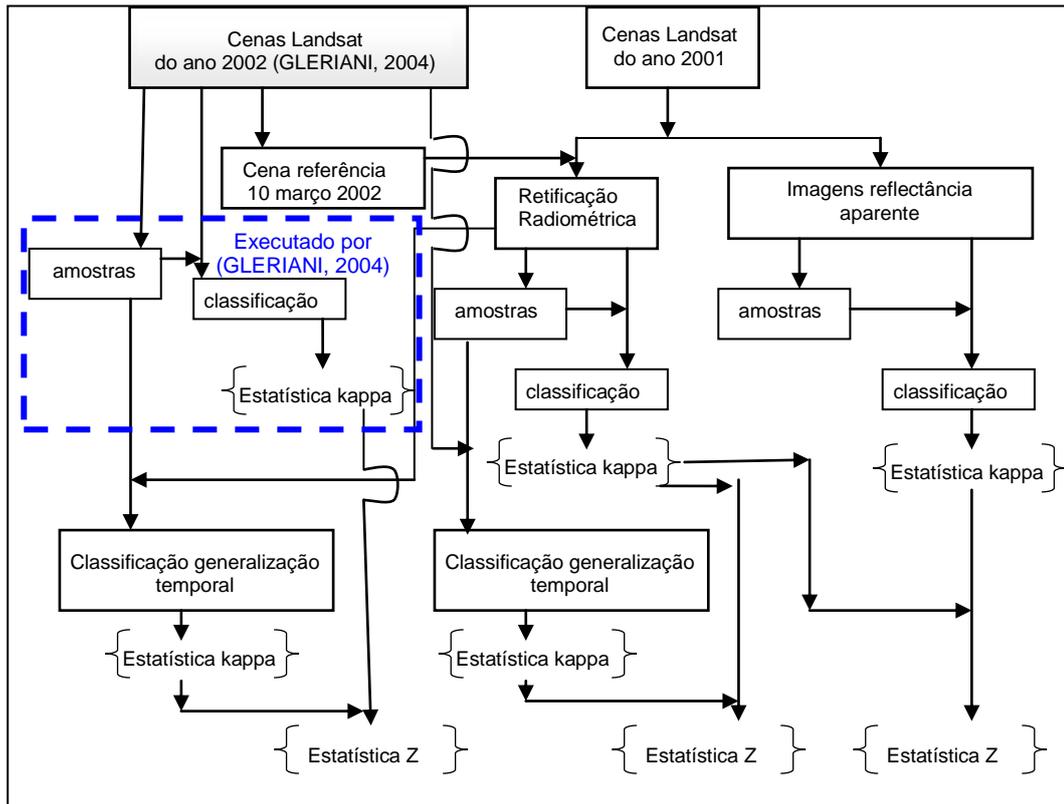


Figura 12- Fluxograma das atividades.

Após a transformação das cenas do ano de 2001 em imagens retificadas e imagens reflectância foram executadas as seguintes classificações:

- Cenas de 2001 com a rede neural treinada com amostras coletadas na mesma cena para imagens retificadas e reflectâncias.
- Cenas de 2001 com a rede treinada com amostras das cenas do ano de 2002 (generalização temporal) para imagens retificadas e reflectâncias.
- Cenas de 2002 com a rede treinada com amostras das cenas do ano de 2001 (generalização temporal) para imagens retificadas e reflectâncias.
- Cálculo da estatística Z para verificar se as generalizações temporais com o uso das cenas/amostras 2001/2001, 2001/2002 e 2002/2001 acarretam perdas significativas na exatidão de classificação.
- Cálculo da estatística Z para verificar se o procedimento de retificação radiométrica é necessário ou se basta calibrar as imagens em imagens reflectância para executar a classificação espectro-temporal.

4. RESULTADOS E DISCUSSÃO

4.1 Retificação Radiométrica e Imagens Reflectância

Uma vez obtidos os valores BR claros e escuros e GR claros e escuros foi feito o cruzamento das componentes, tornando-se possível obter a média dos alvos para as bandas 3, 4 e 5, antes e após a retificação, para todas as imagens (Quadro 5).

Mesmo obtendo os valores das médias com um comportamento linear após a retificação em cada banda espectral, foi checado o resultado da diferença entre as médias dos valores de reflectância referente aos alvos claros e escuros da imagem referência e da imagem retificada de 2001, os quais apresentaram valores abaixo de 1 (Quadro 6), o que indica que os mesmos foram satisfatórios de acordo com o modelo de retificação radiométrica proposto por Hall *et al.* (1991) o que demonstra a eficiência do mesmo na normalização das imagens multitemporais em relação as condições atmosféricas e ângulo solar específico para cada data de aquisição. Observa-se que as imagens estão dentro da condição que Hall *et al.* (1991) coloca - a diferença entre os valores de DN, entre as áreas pseudo-invariantes claras e escuras da imagem utilizada como base (10 de março) e das imagens do ano de 2001 são menores que um, ou seja, os pontos utilizados como alvos pseudo-invariantes, o solo exposto e a água, possuem o mesmo valor.

Quadro 5 - Valores de Brightness e Greenness e Média antes e após a retificação.

IMAGENS	Valores de Brighness (BR) e Greenness (GR)				Médias para Bandas 3, 4 e 5						Médias após Retificação para Bandas 3,4 e 5					
	BR		GR		Claros			Escuros			Claros			Escuros		
	Claros	Escuros	Claros	Escuros	3	4	5	3	4	5	3	4	5	3	4	5
100302²	83-90	41-42	46-57	35-42	53,4	35,5	52,4	13,5	7,228	8,977	-	-	-	-	-	-
160401	69-71	39-40	42-44	36-37	33,9	27,8	36,7	14,5	6,509	3,850	52,8	35,1	51,9	13,0	6,685	8,529
020501	61-65	38-39	42-44	36-38	29,5	23,8	29,9	13,1	6,123	3,318	52,9	35,1	51,8	13	7,094	9,101
180501	56-68	38-39	42-4	36-37	24,0	20,4	22,8	13,5	6,075	3,402	53,1	34,9	51,5	13,0	7,151	8,645
030601	54-55	38-39	42-43	37-38	21,8	17,5	22,0	12,0	5,899	3,830	53,0	35,1	52,0	13,1	6,798	8,342
270601	77-79	56-57	43-45	38-40	49,1	40,4	39,8	23,8	16,7	13,6	53,1	35,0	52,0	12,6	6,854	8,836
050701	57-59	39-40	41-43	37-38	26,0	21,0	29,1	13,0	6,178	4,712	53,1	35,1	51,9	12,9	6,357	8,422
290701	87-89	58-59	42-45	38-39	57,6	44,9	44,9	32,9	21,5	17,1	53,0	34,9	51,9	13,1	6,529	8,344
140801	92-94	57-58	43-45	38-39	61,3	47,4	46,5	31,8	20,6	17,0	52,7	35,3	52,0	13,1	6,643	8,225
070901	68-69	47-48	42-45	37-38	33,9	26,5	35,0	22,0	12,4	9,480	53,0	34,9	51,8	13	6,829	8,473
251001	75-77	43-45	45-47	38-40	38,5	33,9	40,7	17,8	10,8	8,154	53,0	35,0	51,9	12,7	6,826	8,569

²Imagem de Referência

Quadro 6 – Média das Imagens após a Retificação e valores do Δ .

IMAGEM	(Média da Imagem Objeto Retificada – Média dos Alvos Claros e Escuros da Imagem de Referência)					
	Condição $\rightarrow \Delta DN < 1$					
	Média Claros			Média Escuros		
	B3	B4	B5	B3	B4	B5
160401	53,4 - 52,8= 0,6	35,5 - 35,1= 0,4	52,4 - 51,9= 0,5	13,5 - 13,0= 0,5	7,228 - 6,685= 0,5	8,977 - 8,529= 0,4
020501	53,4 - 52,9= 0,5	35,5 - 35,1= 0,4	52,4 - 51,8= 0,6	13,5 - 13,0= 0,5	7,228 - 7,094= 0,1	8,977 - 9,101=-0,1
180501	53,4 - 53,1= 0,3	35,5 - 34,9= 0,6	52,4 - 51,5= 0,9	13,5 - 13,0= 0,5	7,228 - 7,151= 0,1	8,977 - 8,645= 0,3
030601	53,4 - 53,0= 0,4	35,5 - 35,1= 0,4	52,4 - 52,0= 0,4	13,5 - 13,1= 0,4	7,228 - 6,798= 0,4	8,977 - 8,342= 0,6
270601	53,4 - 53,1= 0,3	35,5 - 35,0= 0,5	52,4 - 52,0= 0,4	13,5 - 12,6= 0,9	7,228 - 6,854= 0,4	8,977 - 8,836= 0,1
050701	53,4 - 53,1= 0,3	35,5 - 35,1= 0,4	52,4 - 51,9= 0,5	13,5 - 12,9= 0,6	7,228 - 6,357= 0,9	8,977 - 8,422= 0,6
290701	53,4 - 53,0= 0,4	35,5 - 34,9= 0,6	52,4 - 51,9= 0,5	13,5 - 13,1= 0,4	7,228 - 6,529= 0,7	8,977 - 8,344= 0,6
140801	53,4 - 52,7= 0,7	35,5 - 35,3 = 0,2	52,4 - 52,0 = 0,4	13,5 - 13,1= 0,4	7,228 - 6,643= 0,4	8,977 - 8,225= 0,7
070901	53,4 - 53,0= 0,4	35,5 - 34,9= 0,6	52,4 - 51,8= 0,6	13,5 - 13,0= 0,5	7,228 - 6,829= 0,4	8,977 - 8,473= 0,5
251001	53,4 - 53,0= 0,4	35,5 - 35,0= 0,5	52,4 - 51,9= 0,5	13,5 - 12,7= 0,8	7,228 - 6,826= 0,4	8,977 - 8,569= 0,4

Observa-se na Figura 13 que antes do processo de retificação radiométrica, os alvos claros (solo) possuíam um comportamento espectral diferente nas datas ao longo do ano de 2001, devido às diferentes condições atmosféricas e de iluminação da aquisição das imagens. Após o procedimento de retificação, podem ser verificadas as informações das médias linearizadas ao longo do tempo e espaço, normalizando a resposta espectral dos alvos nas imagens. A mesma situação pode ser verificada na Figura 14 para os alvos escuros (água). Nas figuras os valores estão em relação ao número de cenas, pela ordem das datas de aquisição dos dois quadros anteriores.

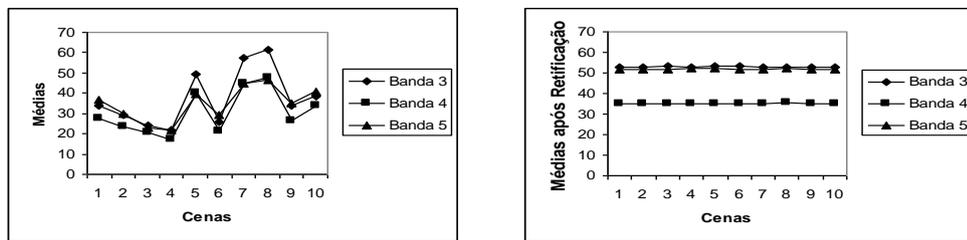


Figura 13- Médias antes e após a retificação dos alvos claros das bandas 3, 4 e 5

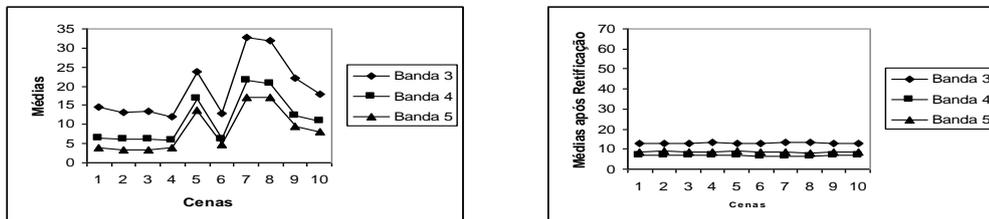


Figura 14 - Médias antes e após a retificação dos alvos escuros das bandas 3, 4 e 5.

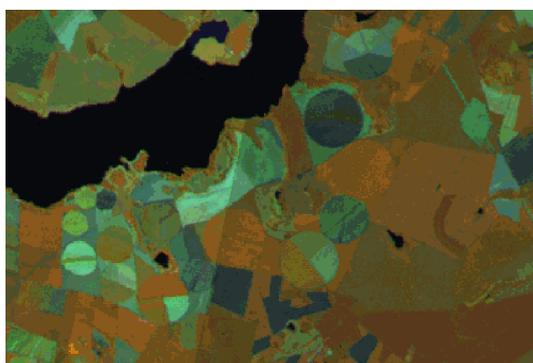
No Quadro 7 podem ser observados os parâmetros levados em consideração nas cenas para gerar a imagem reflectância.

Quadro 7 – Parâmetros utilizados para gerar a imagem reflectância.

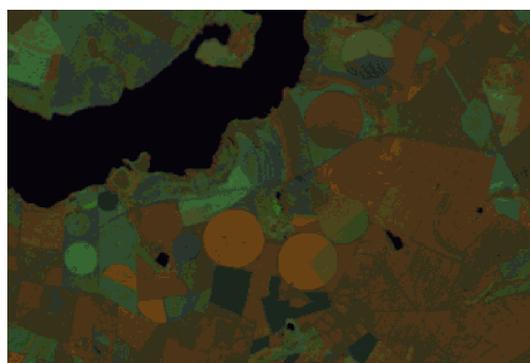
IMAGEM e SENSOR	Dia do Ano	Elevação	Distância Terra Sol (d)	Alto (H) e Baixo ganho (L) por Canal			Radiância Espectral					
				3	4	5	Lmin. por canal			Lmáx. por canal		
							3	4	5	3	4	5
160401/ TM	106	44,6	1,0032	-	-	-	-1,17	-1,51	-1,37	204,30	206,20	27,19
020501/TM	122	41,6	1,0328	-	-	-	-1,17	-1,51	-1,37	204,30	206,20	27,19
180501/TM	138	38,6	1,0175	-	-	-	-1,17	-1,51	-1,37	204,30	206,20	27,19
030601/TM	154	36,3	0,9733	-	-	-	-1,17	-1,51	-0,37	264	221,0	30,2
270601/ETM+	178	35,9	0,9819	H	H	H	-4,5	-4,5	-1,0	158,6	157,5	31,76
050701/TM	186	34,96	1,0016	-	-	-	-1,17	-1,51	-0,37	264	221,0	30,2
290701/ETM+	210	38,8	1,0316	H	H	H	-5,0	-5,1	-1,0	152,9	157,4	31,06
140801/ETM+	226	46,0	0,9991	H	H	H	-5,0	-5,1	-1,0	152,9	157,4	31,06
070901/TM	250	47,6	0,9685	-	-	-	-1,17	-1,51	-0,37	264	221,0	30,2
251001/TM	268	59,9	1,0202	-	-	-	-1,17	-1,51	-0,37	264	221,0	30,2

4.2 Complexidade da Área de Estudo

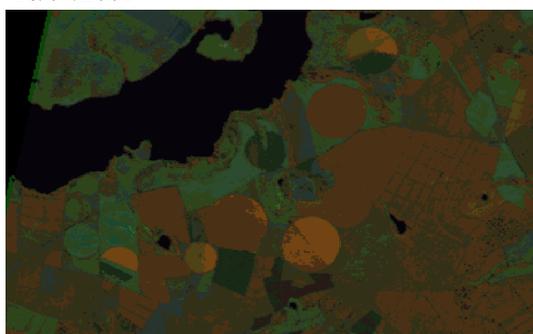
A área de Miguelópolis-SP possui significativa expressão na atividade agrícola, encontrando-se cultivos de sorgo, milho, cana-de-açúcar que ocupam um espaço expressivo no local. (Gleriani, 2004) faz referência sobre o dinamismo das datas de plantio que são facilitadas pela irrigação (pivô central). É comum encontrar pivôs com uma mesma cultura e em diferentes estádios fenológicos, tornando a classificação com uma única data muito difícil, pois os parâmetros estatísticos das amostras normalmente coletados em polígonos com o dossel em pleno vigor vegetativo não são representativos da mesma cultura (classe) encontrada em outros talhões, na figura 15 pode ser analisada a temporalidade de alvos agrícolas que estão na maior parte da área. Outro questionamento está na dificuldade de generalização das redes supervisionadas caso houvesse alteração das culturas de um ano para outro. Em trabalhos na região desde 1991, Ortiz *et al.* (1997), verificaram que existe variação das áreas cultivadas das culturas pelos mais diversos fatores, mas também, as mesmas culturas são encontradas principalmente pela tradição de cultivo dos agricultores.



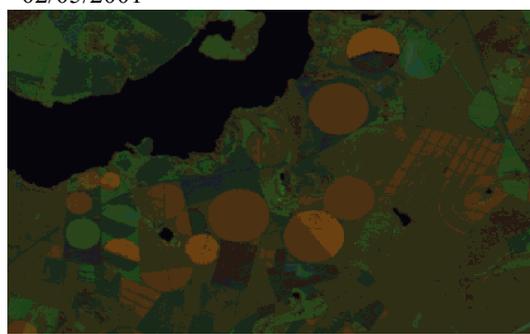
16/04/2001



02/05/2001



18/05/2001



03/06/2001

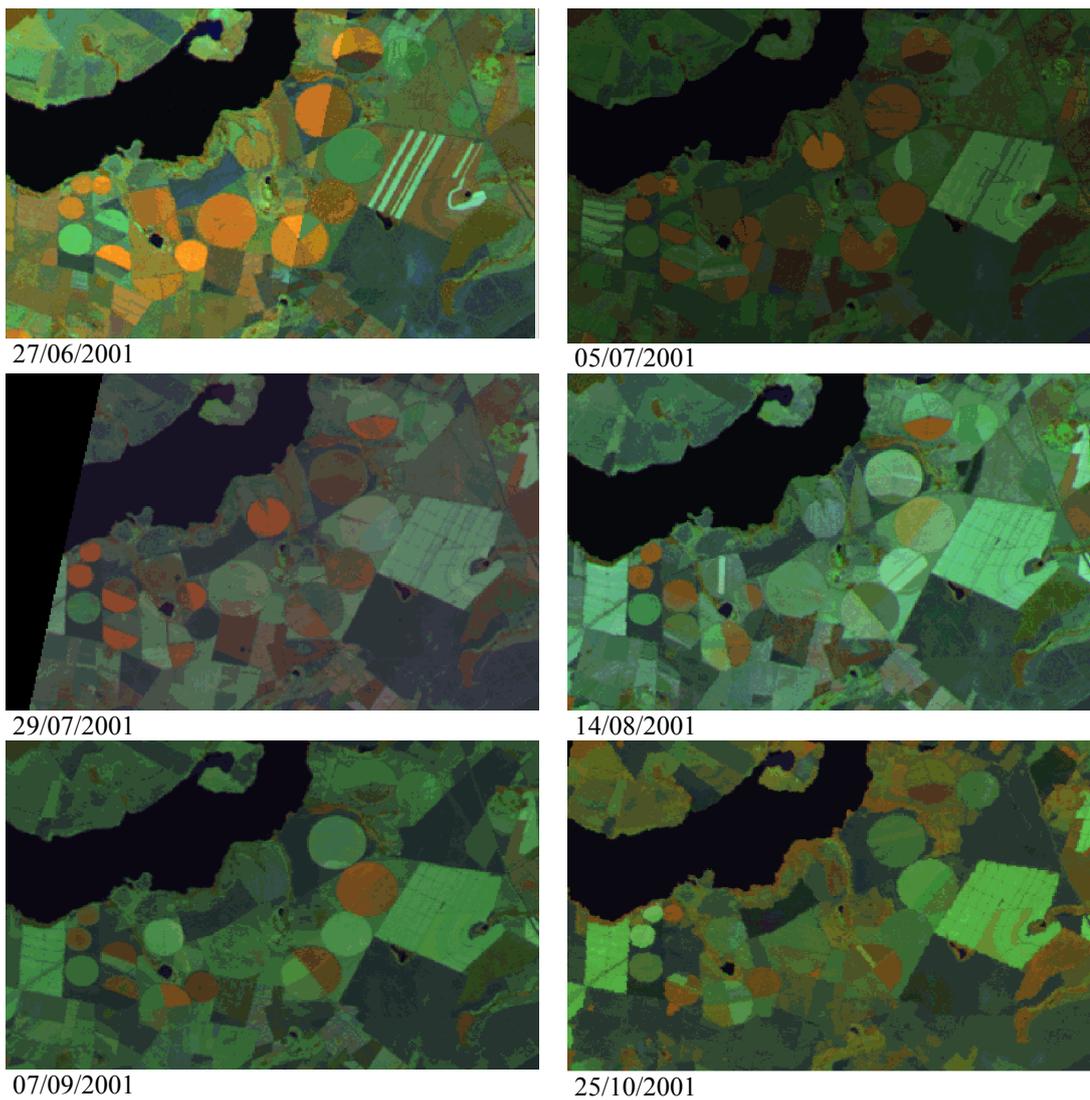


Figura 15 – Análise temporal no ano de 2001 para uma área representativa de Miguelópolis – SP.

4.3 Perfil Espectro Temporal do NDVI das Culturas

Com as imagens foi possível gerar o NDVI temporal, verificando a tendência da caracterização de culturas anuais de ciclo curto, que possuíam elevada dinâmica espectral. Assim como Labus *et al.* (2002), a análise foi feita pela construção de gráficos descrevendo o perfil temporal do NDVI em relação aos dias do ano relacionados às dez imagens de 2001, procurando compreender o ciclo produtivo, mostrando a emergência da cultura, desenvolvimento, maturação e senescência. Os resultados podem ser vistos nas figuras a seguir, onde o perfil temporal para cada cultura é exposto em relação a quatro das 100 amostras coletadas em relação ao dia do ano (Quadro 7) relativo à data de aquisição das imagens.

Os gráficos exibidos mostram a variação fenológica das culturas, para os sensores remotos, são descritos principalmente da interação da radiação eletromagnéticas com as folhas, expressas no parâmetro- índice de área foliar (IAF), função da densidade de plantio o qual é dado pela equação (4.1):

$$IAF = \frac{NPM * AFMP}{EF} \dots\dots\dots(4.1)$$

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

Na região as culturas apresentadas são cultivadas com os seguintes espaçamentos densidades médias: o milho 0,9m entre linha, 5 a 87 plantas/m; o sorgo 0,45 m entre linhas 14 plantas/m e o feijão 0,5m entre linhas com 12 plantas/m.

Deve-se levar em consideração que valores baixos de NDVI podem estar não só relacionados com a fenologia, mas com o adensamento de plantas, o qual altera o IAF.

4.3.1 Cultura de Feijão

A classe de feijão foi diferenciada em entre de feijão de primeira safra e feijão de segunda safra. Esta distinção foi necessária porque após o primeiro cultivo encontra-se o pivô novamente com feijão, milho, pousio (com ervas daninhas), o que causa grande variabilidade no padrão espectral. O perfil do NDVI para feijão de primeira e segunda safra pode ser observado em relação ao dia do ano (Figuras 16 e 17).

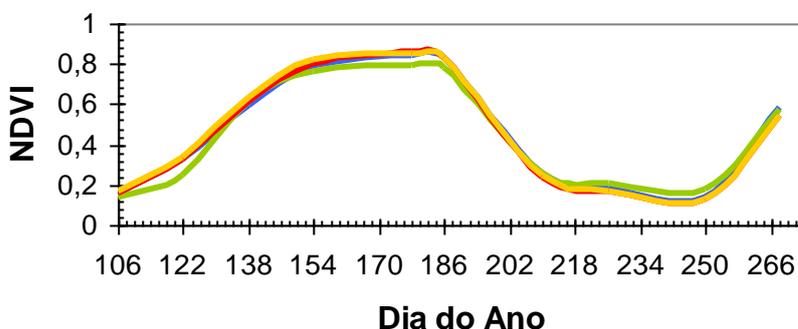


Figura 16 - Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da primeira safra da cultura de feijão.

Levando em consideração que o ciclo completo para a cultura seja como Reichardt (1990) descreveu, de 60 a 90 dias - colheita de vagens verdes e de 90 e 120 dias produção de grãos. Do período de germinação às folhas primárias o NDVI possui valores possivelmente baixos, a etapa chamada como V3 onde 50% das plantas estão abertas possivelmente já possuem maior influência na resposta do perfil. A fenologia da cultura durou cerca de 80 dias. O mesmo ocorre para a classe “feijão 2”. Antes do início do cultivo, pode-se encontrar milho, feijão, palhada o que é fator de alteração desse padrão.

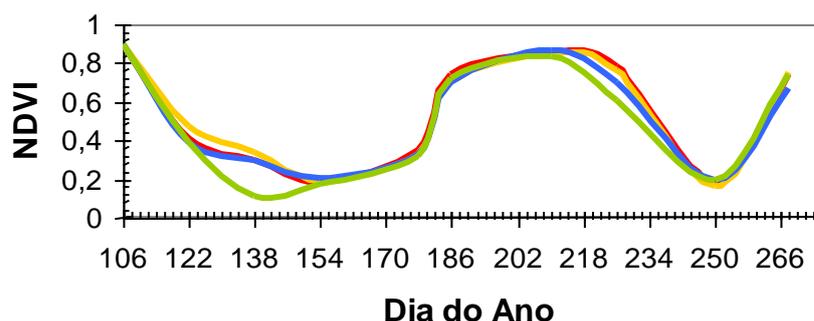


Figura 17 - Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da segunda safra de cultura de feijão.

Ocorre na primeira safra uma ascensão rápida dos valores do NDVI. Existe uma estabilização na curva do perfil temporal possivelmente relacionado ao pousio, outros padrões não exibidos aqui, encontrados por Gleriani (2004), com enorme variabilidade antes do início do plantio de feijão de segunda safra. Devemos levar em consideração que o perfil temporal do feijão pode refletir o perfil de culturas como milho, sorgo, devido ao sistema de rotação

4.3.2 Cultura de Milho

O patamar de estabilização de altos valores de NDVI da cultura do milho, como pode ser observado na Figura 18, é maior que da cultura de feijão, sendo que os valores que refletem a senescência ocorrem após praticamente 60 dias. As quatro amostras representadas exemplificam bem o comportamento fenológico da cultura, pois, não variam de uma para a outra, exceto para o início do período de colheita quando o índice começa a cair.

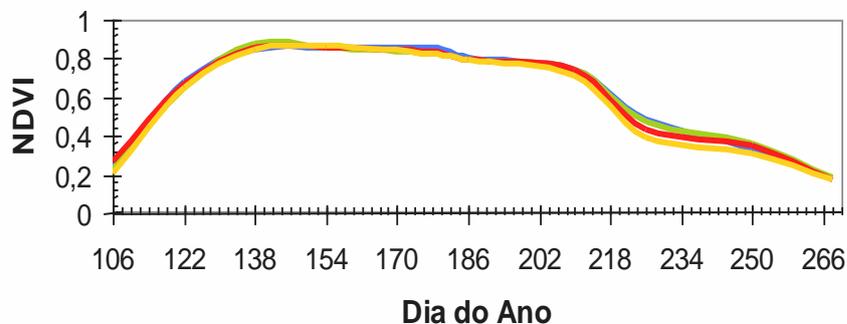


Gráfico 18 - Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de milho.

A cultura apresenta um ciclo muito semelhante ao do sorgo, porém a ascensão inicial do valor do NDVI é menos íngreme.

Outro fator de variabilidade espectral são as plantas invasoras o que alteram o perfil temporal das culturas pelo “ruído” no IAF. Não apenas plantas invasoras, mas, nos pivôs, observou-se com frequência, a existência de feijoeiros em plantios de milho, devido à perda em processos de colheita.

4.3.3 Cultura de Sorgo

Na Figura 19 pode ser observado um patamar de estabilização da cultura em torno de 60 dias assim como na cultura do milho, logo após começa a cair. O ciclo do sorgo é de aproximadamente 100 dias.

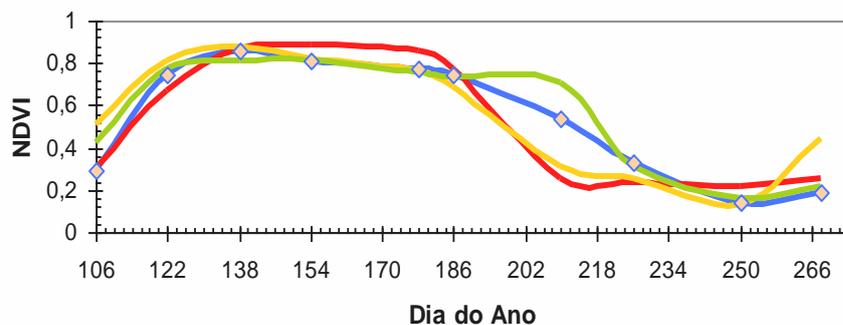


Figura 19 - Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de sorgo.

4.3.4 Cultura de Cana-de-Açúcar

Na Figura 20 é representado o perfil temporal da cultura de cana colhida no ano. Nessa classe inclui-se: a cana de ano e meio plantada de janeiro a março do ano anterior; a cana de ano, plantada de setembro a outubro do ano anterior, e todas as canas “soca”. Ressalta-se que foram escolhidas amostras com os talhões colhidos após a data de 25 de outubro, uma vez que, qualquer data a partir de abril, poderia apresentar uma queda brusca do NDVI (colheita) com uso do fogo ou não, o que causa uma enorme variabilidade, dificultando a definição de um

padrão espectral para essa classe. A longa queda do NDVI é função do aumento de folhas seca e palhas no período de amadurecimento do dossel e concentração de sacarose.

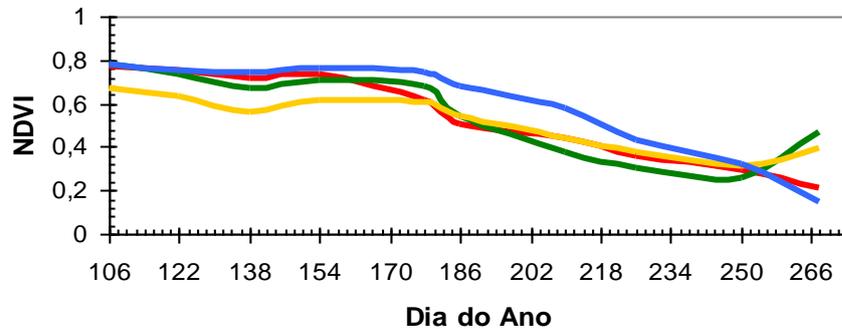


Figura 20 - Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de cana colhida ao ano.

Outro “padrão” confuso é da cana de ano e meio (Figura 21), que é plantada de janeiro a março podendo passar por processos fertirrigação (com vinhaça).

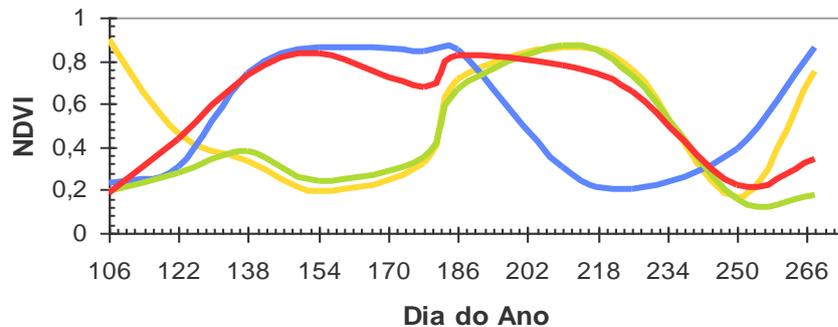


Figura 21 - Variação do NDVI ao longo do tempo do ano de 2001 para quatro das 100 amostras retiradas da cultura de cana ano e meio.

A curva de crescimento da cana de primeiro corte pode ser mais simétrica se o ciclo for anual (cana-de-ano) ou bimodal, caso seja ciclo de mais de um ano (cana-de-ano e meio), em geral tem-se o índice de área foliar maior quando a cana atinge de cinco à seis meses de idade. É necessário levar em consideração que

boa parte da radiação detectada pelo sensor é influenciada pelo topo do dossel, então valores do dossel podem não estar relacionados corretamente com o porte da cultura.

O padrão temporal como verificado nas duas figuras anteriores é o mais complexo, a ascensão da curva do NDVI implica que a rebrota pode estar ocorrendo com diferentes intensidades, o que implica e uma variância do padrão temporal muito grande em relação às demais culturas. Devemos levar em consideração fatores como o corte escalonado da cana, a maneira de colheita e práticas culturais, pois, ambos interferem na variabilidade temporal.

Através do reconhecimento do perfil temporal da cultura no espaço e no tempo é possível reconhecer o padrão de cada cultura, subsidiando assim no reconhecimento do Kc. Provavelmente cultivos de ciclos longos são os principais beneficiários com este tipo de análise. A evolução do NDVI correlacionou bem com os estágios do crescimento da cultura, levando em consideração que quando o IAF for maior, amplia sombreamento do solo e a evapotranspiração, indicando uma vegetação em pleno vigor, segundo Holben (1986), por apresentar uma vegetação mais densa. Porém, essa relação do NDVI com o IAF pode ser tida como estreita, afirma Price (1993), pois, uma área com cana densa pode apresentar cana e palha, e um baixo índice devido a palha, uma área que estivesse no início do ciclo, com folhas bem mais verdes, apenas, poderia ter um índice bem maior. Portanto a interpretação deve ser cuidadosa, porque parte da radiação detectada pelo sensor é influenciada pelo topo do dossel.

4.4 Resultados da Classificação e Avaliação

A partir dos dados de entradas do NDVI, bandas 3, 4 e 5 foram discriminadas as classes água, cana ano, cana ano e meio, feijão de primeira safra, feijão de segunda safra, milho, sorgo e outros usos.

O mapa temático resultante da classificação espectro-temporal do conjunto de cenas do ano 2001, retificadas radiometricamente, classificadas com a rede MLP 40-12-8, treinadas com dados da safra 2001 é apresentado a seguir na figura 22.

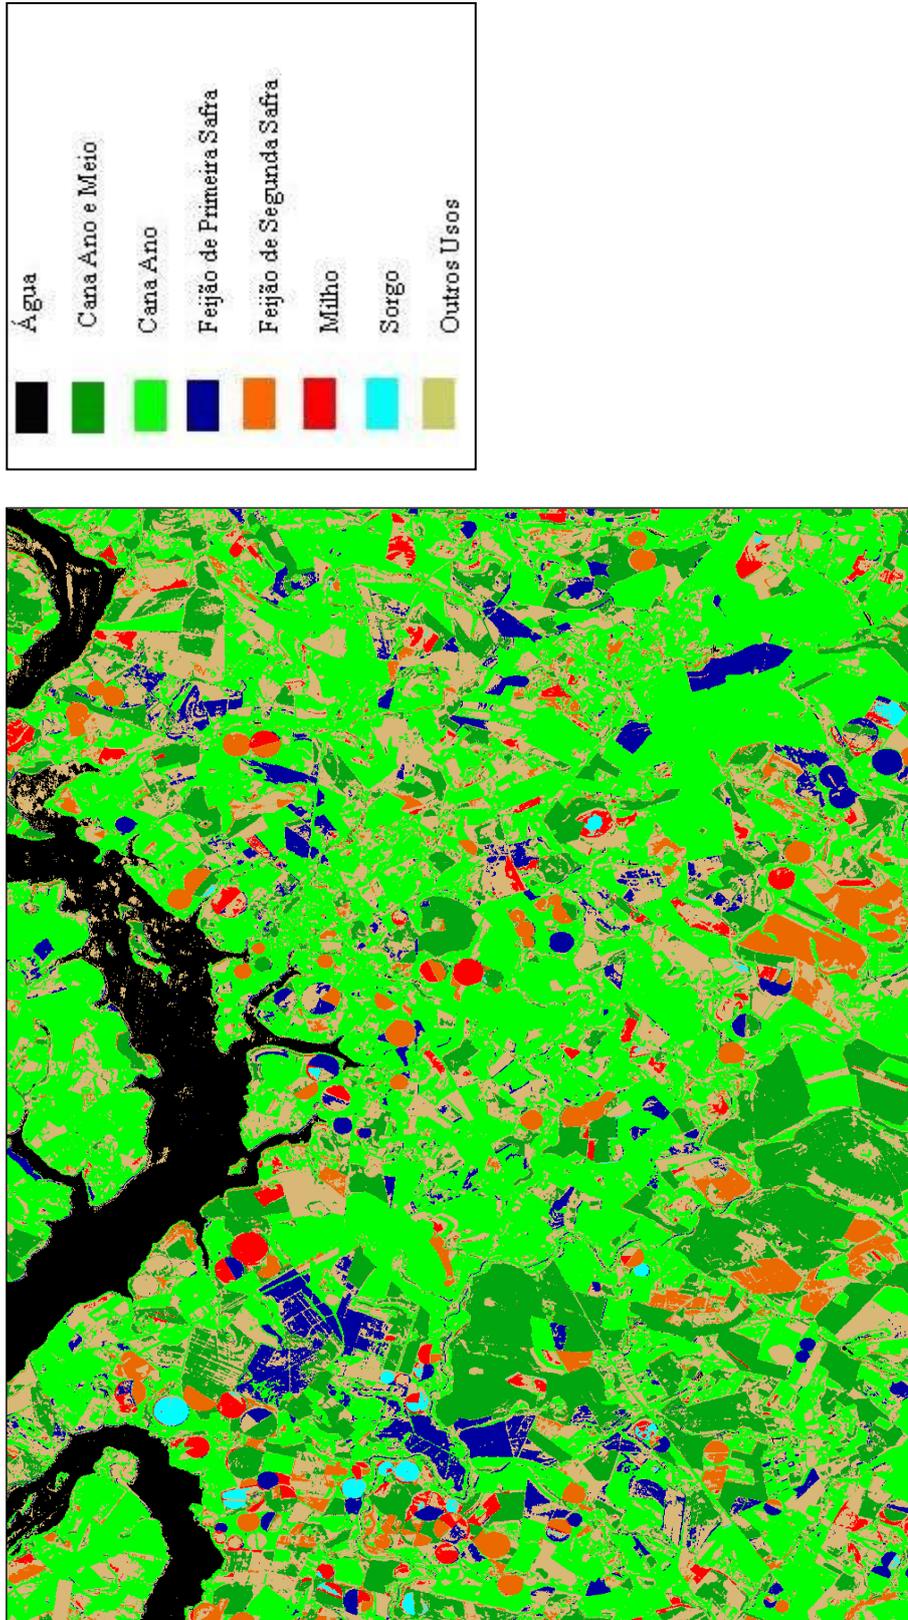


Figura 22 – Classificação espectro-temporal de cenas retificadas radiometricamente, do ano de 2001, classificado com a rede MLP 40-12-8, treinadas com dados do ano de 2001.

Observa-se que a abordagem espectro-temporal traz ganhos, porém erros de classificação ainda existem. Em uma rápida análise visual observa-se a existência das classes de feijão de primeira e segunda safra fora das áreas circulares (pivô central), o que implica em um erro de omissão. Para a classe representando outros usos, esperava-se baixa exatidão, devido à grande variabilidade desse padrão que incluía desde áreas urbanas, matas ciliares, entre outros; diferente da “Água”, que possui eficiente resposta por ser diferenciada dos demais alvos, já para as classes agrícolas como cana colhida no ano, a exatidão é baixa, pois ela se confunde devido a intervenção antrópica (colheita) que pode ocorrer em qualquer época do ano de abril a setembro e no solo podem usar métodos diferentes de tratamento como o fogo. Porém observa-se que a cana colhida no ano (CCA) e/ou a cana de ano e meio (CA&M) tem melhor exatidão de classificação com uma única cena, no mês de abril segundo Gleriani (2004). A exatidão global dessa classificação foi de 46,7%. No Quadro 8 observa-se a matriz de confusão resultante da amostragem de 930 pontos de referência e no Quadro 9 observamos a exatidão do produtor e a exatidão do usuário para cada classe, onde confirma-se a precisão em classificar a água, confusões entre milho e feijão, possivelmente explicadas por terem semelhante resposta espectral e serem plantadas juntas, em CCA e e M é notável a confusão com outros usos, a cultura de cana citada, no espaço é complexa de classificar pela sua resposta que pode estar influenciada por exemplo pela presença de palha, mesmo apresentando o topo verde, então acaba por se assemelhar a diferentes alvos.

Quadro 8 – Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2001, retificadas radiometricamente, classificadas com a rede neural treinada com dados de 2001.

		Referência								
		M	S	CCA	CA&M	A	F1	F2	OU	TOTAL
Classificada	M	44	2	3	1	0	10	1	5	66
	S	5	19	3	0	0	0	0	0	27
	CCA	2	0	36	14	4	0	2	187	245
	CA&M	11	2	6	65	0	4	3	23	118
	A	0	0	0	0	45	0	0	0	45
	F1	7	0	8	0	0	53	1	7	76
	F2	3	0	8	0	0	5	82	9	107
	OU	37	3	73	10	7	13	12	95	250
	TOTAL	109	26	137	90	56	85	101	326	930

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

Quadro 9 – Exatidão do usuário e do produtor derivadas da matriz de confusão com dados de treinamento e classificação, retificados radiometricamente, do ano de 2001.

CLASSES	EXATIDÃO DO USUÁRIO		EXATIDÃO DO PRODUTOR	
M	44/109	40,3%	M	44/66 66,6%
S	19/26	73,0%	S	19/27 70,4%
CCA	36/137	26,2%	CCA	36/245 14,7%
CA&M	65/90	72,2%	CA&M	65/118 55,1%
A	45/56	80,4%	A	45/45 100%
F1	53/85	62,3%	F1	53/76 69,73%
F2	82/101	81,1%	F2	82/107 76,6%
OU	95/326	29,1%	OU	95/250 38,0%

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

O resultado da generalização temporal da rede com a classificação das cenas do ano de 2001 com a rede treinada com amostras coletadas no ano de 2002 é ilustrado na Figura 23. A rede, com arquitetura montada com a fórmula heurística proposta por Fletcher e Goss (1993), tinha arquitetura 40-70-8, porém com apenas 150 ciclos de treinamento atingiu o erro de saída desejado de 0,1. A generalização temporal dessa rede não produziu bons resultados, onde até a classe

“Água” foi inclusa (erro de comissão) em áreas da classe “Cana Colhida no Ano” onde existe colheita mecânica, muita palha sobre o solo e o conseqüente NDVI<0, como ocorre na classe “Água” pode ser uma das explicações.

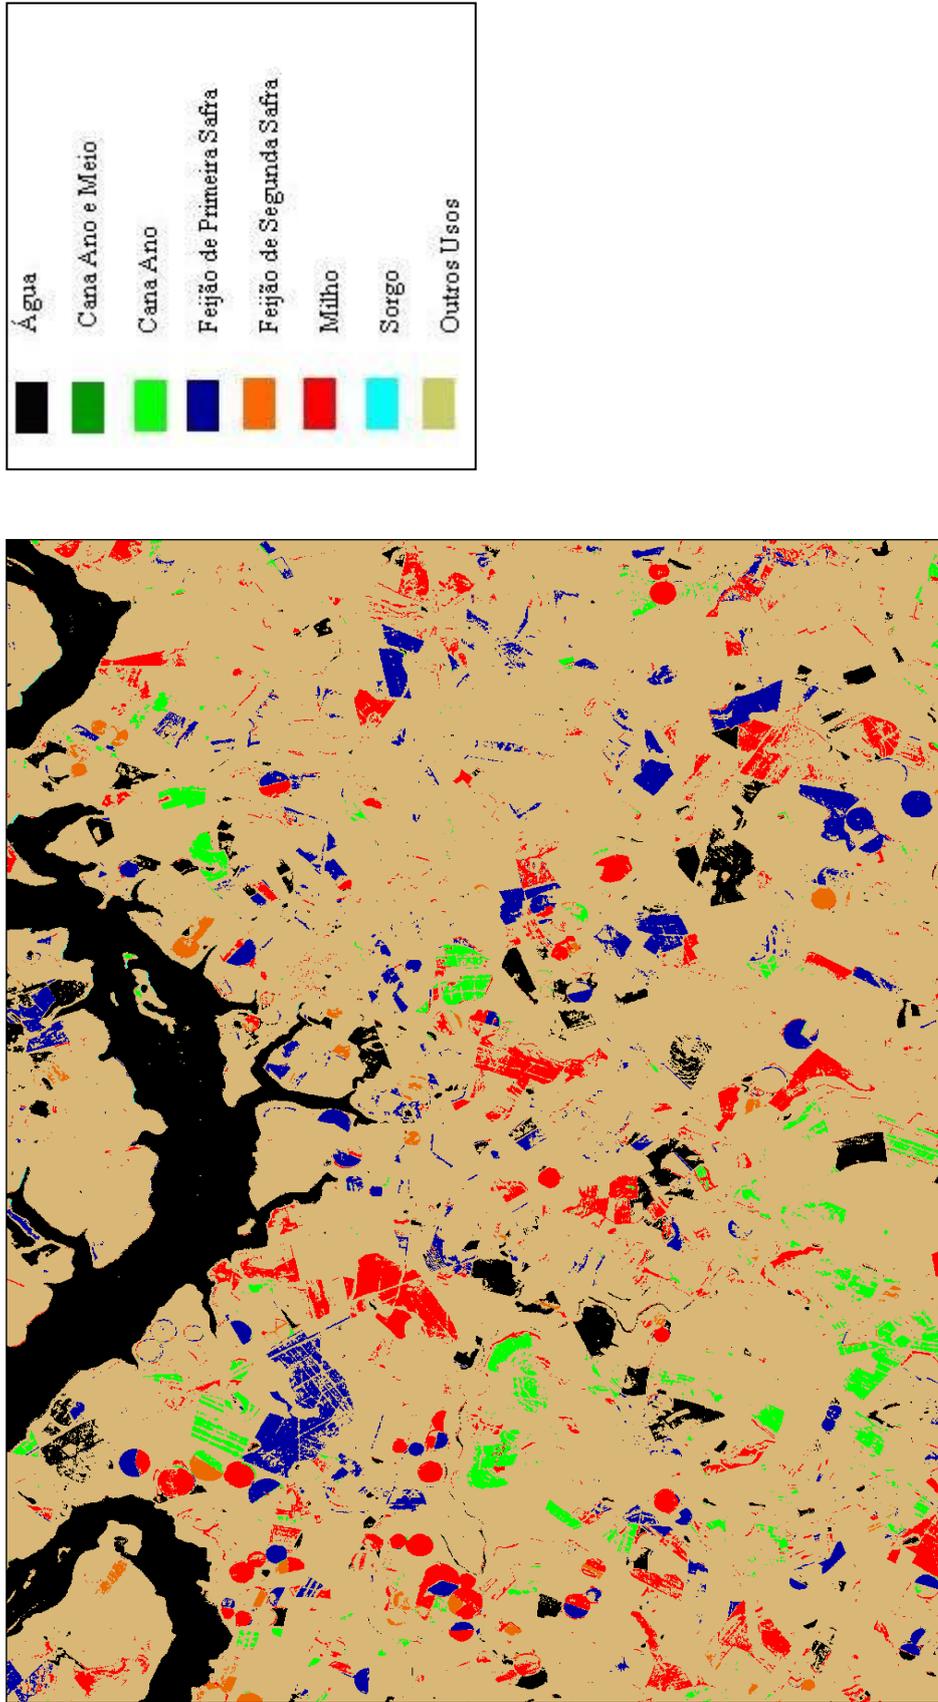


Figura 23 – Classificação espectro-temporal de cenas retificadas radiometricamente, do ano de 2001, classificado com a rede MLP 40-70-8, treinadas com dados do ano de 2002.

No Quadro 10 podemos observar a matriz de confusão para resultante da classificação acima e no Quadro 11 as respectivas exatidões do usuário e produtor para cada classe. A classe “OU” ocupa uma grande área na imagem e, para situação onde nenhum ou mais de um dos oito neurônios de saída é/são ativados, é para essa classe que a rede neural atribui. Tso e Mather (2001) também chamam a atenção para o caso específico onde uma classe específica domina uma imagem e, a exatidão global não reflete o erro que ocorreu nas classes individuais, levando a uma interpretação errônea dos resultados. Entre as classes agrícolas apenas a classe “Feijao1” teve boa exatidões tanto para o produtor quanto para o usuário, a classe de soja deixou de ser classificada, o milho dentre as demais classes mostra-se o mais fácil de distinguir entre as culturas, mas não fica isento da confusão com outros usos, a água ainda está aquém dos demais alvos, possuindo resposta espectral bastante característica, porém na classificação no tempo observa-se confusões com outros usos na imagem, “OU” tem bastante confusão com a classe de CCA.

QUADRO 10 – Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2001 classificadas com a rede neural treinada com dados de 2002.

		Referência								
		M	S	CCA	CA&M	A	F1	F2	OU	TOTAL
Classificada	M	26	18	9	2	0	4	14	14	87
	S	0	0	0	0	0	0	0	0	0
	CCA	1	0	5	0	0	0	0	1	7
	CA&M	0	0	0	0	0	0	3	0	3
	A	0	0	1	0	52	0	0	13	66
	F1	5	0	6	1	0	55	1	0	78
	F2	2	0	1	0	0	2	17	2	24
	OU	75	8	115	87	4	24	70	285	668
	TOTAL	109	26	137	90	56	85	101	326	930

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU**– Outros Usos.

Quadro 11 – Exatidão do usuário e do produtor derivadas da matriz de confusão com dados de treinamento de 2002 e classificação do ano de 2001.

CLASSES	EXATIDÃO DO USUÁRIO		EXATIDÃO DO PRODUTOR		
M	26/109	23,8%	M	26/87	29,9%
S	0/26	0%	S	0/0	0%
CCA	5/137	3,6%	CCA	5/7	71,4%
CA&M	0/90	0%	CA&M	0/0	0%
A	52/56	92,8%	A	52/66	78,8%
F1	55/85	64,7%	F1	55/78	70,5%
F2	17/101	16,8%	F2	17/24	70,8%
OU	285/326	87,4	OU	285/668	42,6%

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

A principal análise a ser executada é a estatística Z (Quadro 12), nela Existiu uma queda de exatidão que foi significativa a nível de 1% mostrando que apesar da retificação radiométrica, e do estabelecimento das mesmas classes espectro-temporais, existe uma perda grande na exatidão, ou seja, o processo de retificação, mesmo sendo bem sucedido, normalizando os alvos em todas as imagens, não aumentou a qualidade da classificação nas imagens classificadas temporalmente. As cenas de 2001 com rede de 2001, possuem o Kappa maior que cenas de 2001 com rede de 2002, estando ambas muito abaixo dos 80% recomendado, mas segundo Landis e Koch (1977) e sendo consideradas de qualidade razoável.

Quadro 12 - Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2001 com rede neural treinada com dados do ano de 2001, com cenas do ano de 2001 classificadas com rede treinada com dados do ano de 2002.

Cenas2001 rede 2001		Cenas2001 rede2002		Estatística Z	
k	Var(k)	k	Var(k)	Z**	p
0,35856	0,000469	0,2696	0,00039	3,34	0,00120

**p<0,01 – NS – Não significativo

A segunda generalização temporal foi a classificação das cenas do ano de 2002 com a rede 40-12-8 treinada com dados de 2001 (Figura 24).

A matriz de confusão e as respectivas exatidões de produtor e usuários são expressas nos Quadros 13 e 14.

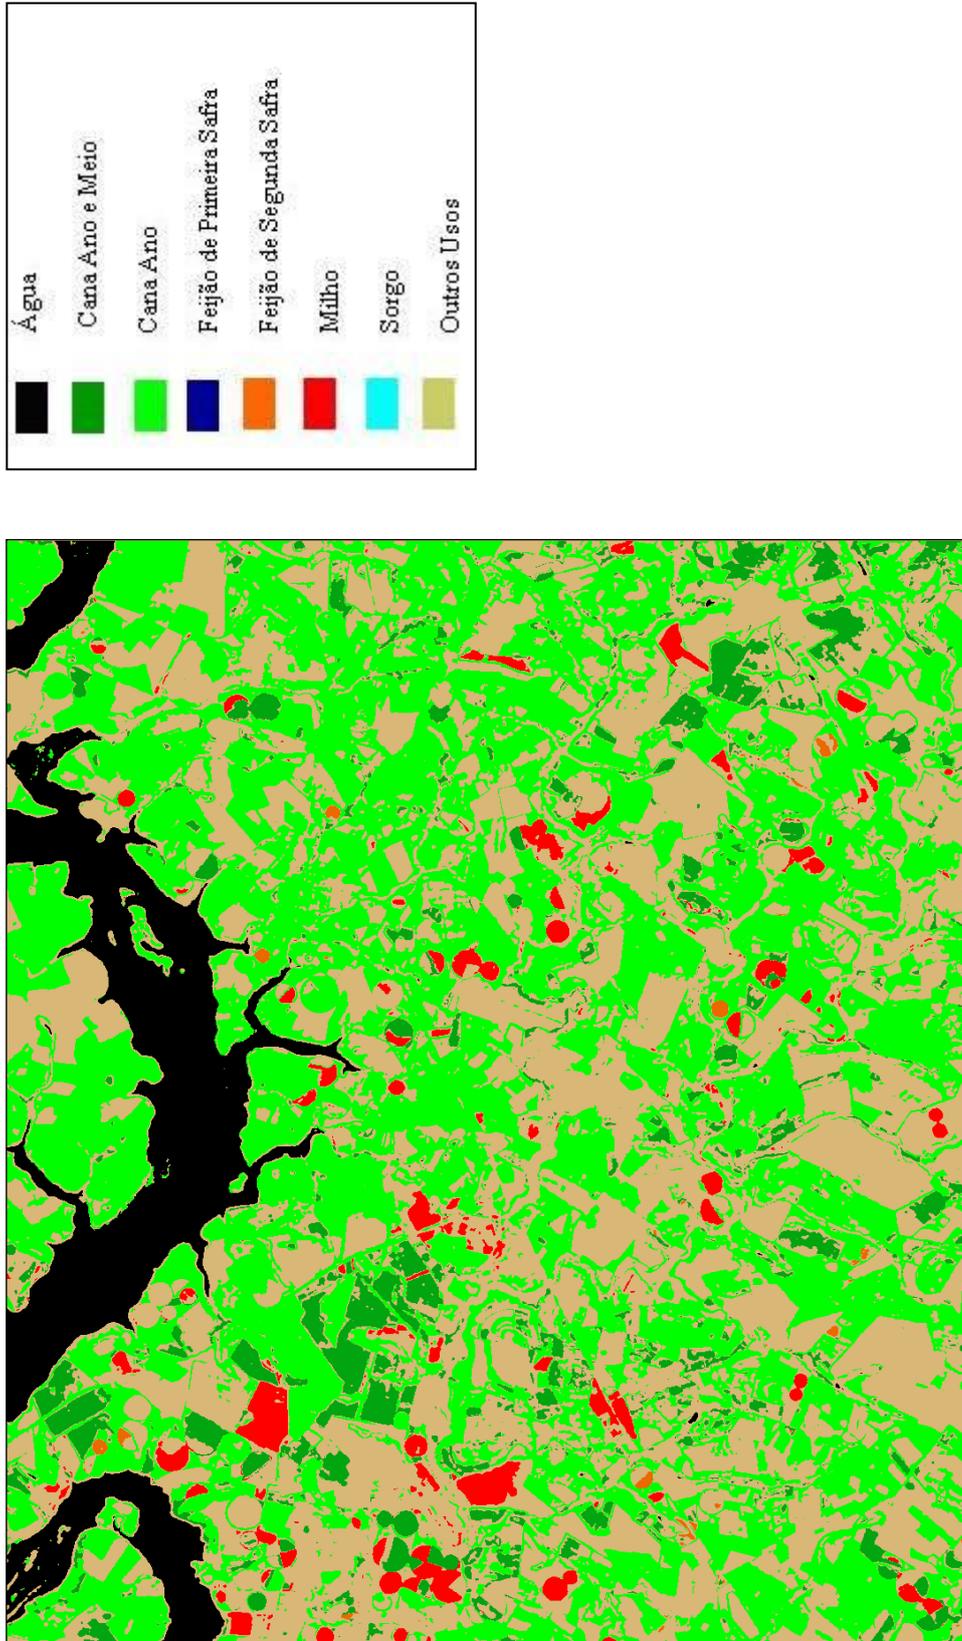


Figura 24 – Classificação espectro-temporal de cenas retificadas radiometricamente, do ano de 2002, classificado com a rede MLP 40-12-8, treinadas com dados do ano de 2001.

Quadro 13 – Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2002 classificadas com a rede neural treinada com dados de 2001.

Classificada	Referência									
	M	S	CCA	CA&M	A	F1	F2	OU	TOTAL	
M	55	45	3	29	0	43	4	4	183	
S	0	0	0	0	0	0	0	0	0	
CCA	27	0	180	28	0	15	68	298	616	
CA&M	52	11	68	57	0	0	0	20	208	
A	0	0	0	0	223	0	0	0	223	
F1	0	0	0	0	0	0	0	0	0	
F2	0	0	0	0	0	0	0	0	0	
OU	65	1	210	90	1	98	17	302	784	
TOTAL	199	57	461	204	224	156	89	624	2014	

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

Quadro 14 – Exatidão do usuário e do produtor derivadas da matriz de confusão com dados de treinamento de 2001 e classificação do ano de 2002.

CLASSES	EXATIDÃO DO USUÁRIO		EXATIDÃO DO PRODUTOR	
M	55/199	27,6%	M	55/183 30,0%
S	0/57	0%	S	0/0 0%
CCA	180/461	39%	CCA	180/616 29,2%
CA&M	57/204	27,9%	CA&M	57/208 27,4%
A	223/224	99,5%	A	223/223 100%
F1	0/156	0%	F1	0/0 0%
F2	0/89	0%	F2	0/0 0%
OU	302/624	48,4%	OU	302/784 38,5%

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

A exatidão global das classes acima foi de 40,5%, e as maiores exatidões ficaram para as classes Outros Usos e “Água”, a água como já abordado, apresenta resposta espectral distinta em relação à outros alvos. É provável que a classe de outros usos influencie nos valores, visto que ocupa maior parte na classificação, obviamente o classificador tem chance de aprender a classificá-la mais rápido e tende a confundir qualquer, sombreamento, influência do solo na classificação das culturas agrícolas com esta classe. A queda de exatidão nessa

segunda generalização temporal foi maior e a diferença também é significativa a nível de 1%.

Gleriani (2004) encontrou um kappa de 0,62607 (Quadro 15); um valor segundo Landis e Koch (1977) muito bom, mas este valor caiu para 0,2500 na classificação executada nesse trabalho, considerada uma razoável classificação. As diferenças de desempenho da rede de Gleriani (2004) e este trabalho, podem estar na substituição à dados falhos que o autor fez utilizando as médias entre a imagem anterior e a posterior. No desempenho das demais classificações no tempo, o autor abordou apenas o ano de 2002, enquanto neste trabalho a temporalidade foi além, o que pode ter agregado numa resposta melhor dos testes realizados por ele, porém dentro de um mesmo padrão de qualidade obtendo valores razoáveis à bons.

Quadro 15 - Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2002 com rede neural treinada com dados do ano de 2002 (Gleriani, 2004), com cenas do ano de 2002 classificadas com rede treinada com dados do ano de 2001.

Cenas2002 rede 2002		Cenas2002 rede2001		Estatística Z	
k	Var(k)	k	Var(k)	Z**	p
0,62067	0,01548	0,2357	0,000207	3,11	0,0009

**p<0,01 – NS – Não significativo

A última análise executada foi a verificação da necessidade ou não da execução da retificação radiométrica das cenas, que é um procedimento trabalhoso, principalmente pela dificuldade de localização dos alvos pseudo invariantes. A classificação derivada desse procedimento foi confrontada com a classificação derivada das imagens reflectância aparente, influenciadas de efeitos atmosféricos, porém calibradas para os valores de radiância de cada sensor (TM e ETM+), ajustado ao logo dos anos (degradação de detectores) e dentro do ano (alto e baixo ganho). O Quadro 16 exhibe a matriz de confusão e o Quadro 17 as exatidões do produtor e do usuário para cada classe.

Quadro 16 – Matriz de confusão para a classificação espectro-temporal com cenas do ano de 2001 classificadas com a rede neural treinada com dados de 2001. Imagens reflectância.

Classificada	Referência									
	M	S	CCA	CA&M	A	F1	F2	OU	TOTAL	
M	28	1	0	0	0	6	1	4	40	
S	9	19	4	0	0	1	1	2	36	
CCA	20	0	89	14	0	7	16	52	218	
CA&M	6	0	14	28	7	0	11	71	117	
A	0	0	0	0	43	0	0	0	43	
F1	4	0	8	0	0	46	0	10	68	
F2	0	0	0	1	0	1	15	0	17	
OU	42	6	22	47	6	24	57	187	391	
TOTAL	109	26	137	90	56	85	101	326	930	

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

Quadro 17 – Exatidão do usuário e exatidão do produtor derivadas da matriz de confusão com dados de treinamento e classificação do ano de 2001. Imagens reflectância.

CLASSES	EXATIDÃO DO USUÁRIO		EXATIDÃO DO PRODUTOR	
M	28/109	25,7%	M	28/40 70,0%
S	19/26	73,0%	S	19/36 52,7%
CCA	89/137	64,9%	CCA	89/218 40,8%
CA&M	28/90	31,1%	CA&M	28/117 23,9%
A	43/56	76,8%	A	43//43 100%
F1	46/85	54,1%	F1	46/68 95,8%
F2	15/101	14,8%	F2	15/17 88,2%
OU	187/326	57,4%	OU	187/391 47,8%

M – milho, **S** – Sorgo, **CCA** – Cana Colhida no ano, **CA&M** – Cana de Ano e Meio, **A** – Água, **F1** – Feijão de primeira safra, **F2** – Feijão de segunda safra, **OU** – Outros Usos.

A exatidão global foi de 49%, porém no Quadro 18 observa-se que não existe diferença significativa entre os valores de kappa expressos pela estatística Z.

Quadro 18 - Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2001 com rede neural treinada com dados do ano de 2001, retificadas, com cenas do ano de 2001 classificadas com rede treinada com dados do ano de 2001, reflectância.

Cenas2001 rede 2001- retificada		Cenas2001 rede2001- reflectancia		Estatística Z	
k	Var(k)	k	Var(k)	Z (NS)	p
0,35856	0,000469	0,3464	0,000442	0,18424	0,4269

**p<0,01 – NS – Não significativo

Como já descrito a região possui um dinamismo de cultivo muito grande a classificação com uma única cena (espectral) acaba produzindo resultados muito aquém de uma abordagem multidas (espectro-temporal). A execução da transformação dos dados de nível digital para reflectância neste respectivo trabalho seria preferencial, uma vez que o processo de retificação é muito trabalhoso.

4.5 Contexto Ambiental em Miguelópolis -SP

Embora o trabalho não tenha abordado profundamente a questão ambiental relacionada, ao uso do solo, Áreas de Preservação Permanente –APP's, uso da água na irrigação, ele representa uma contribuição para aprimorar metodologias para estas análises. Através das classificações realizadas, nota-se que grande parte da área é de cultivos, principalmente de cana-de-açúcar. A questão ambiental nesta localidade deve principalmente ser voltada à água, em relação à aplicação correta e eficiência, nos pivôs, como também o comprometimento da qualidade das águas do rio, processos de sedimentação. Abaixo na Figura 25 é apresentada a imagem da região em estudo, mostrando a grande quantidade de áreas agrícolas, solo exposto, senso provavelmente preparados para mais plantio e pequenos restícios da mata ciliar.

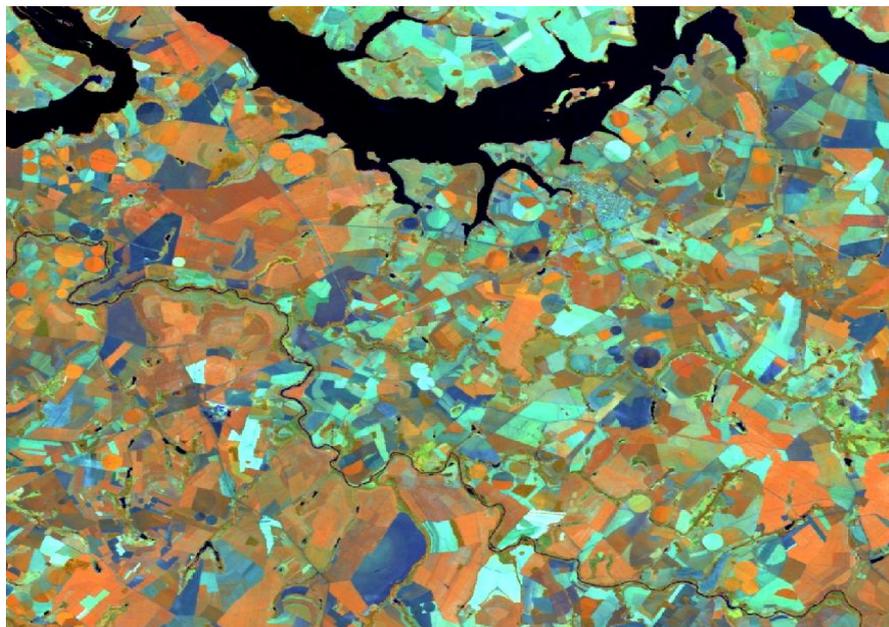


Figura 25 – Imagem da área estudada.

È fato a crescente demanda por alimentos e junto desta virá o aumento da área cultivada e a irrigação, antes vista apenas como aplicação de água, onde o objetivo principal era o combate à seca, e ou, a criação de condições de subsistência para os produtores, hoje consiste em importante instrumento no

aumento da produção principalmente para o comércio, relações do homem com a natureza são indissociáveis das relações econômicas. Neste tocante, é importante a conscientização, uso correto e eficiente de métodos agrícolas, já que serão inevitáveis e antes de tudo, analisar a lei diante das decisões que são tomadas em regiões como esta.

5. CONCLUSÕES E RECOMENDAÇÕES

A generalização espaço-temporal de redes MLP, dentro da abordagem espectro-temporal utilizada nesse estudo permite concluir que:

- A aquisição, de informações sobre culturas agrícolas, não é tarefa simples devido à ampla dispersão de informações e a dinâmica das mesmas, neste tocante a obtenção de imagens temporais foi capaz de fornecer dados sobre a área em pequenos intervalos de tempo.

- A generalização temporal dos classificadores MLP traz perdas significativas à exatidão final, mantendo a estatística Kappa com valores bem baixos.

- Os valores de K deixaram a desejar nas classificações, talvez por considerarmos várias classes dentro de uma única, o caso de Outros Usos, que pode ter influenciado nos valores de K em relação à sua abrangência e alvos semelhantes.

- As maiores exatidões, apesar de ruins ocorrem quando o treinamento se dá na mesma cena onde a classificação é executada, a distinção de algumas culturas agrícolas no espaço é bastante complexa, por apresentarem resposta espectral semelhantes.

- A retificação radiométrica é desnecessária no respectivo trabalho, visto que não foi significativa na estatística Z, portanto a conversão das imagens para dados de reflectância foi suficiente para manter a diferença de exatidão em níveis não significativos.

- A pesquisa pode ser otimizada caso realizada junto aos trabalhos de campo para a análise do comportamento de cada alvo ao longo do tempo.

- Sugere-se que seja feita a classificação de distintos alvos, pode influenciar nos valores do K, ou, seja, a classe de “outros usos” poderia ser desmembrada em classe de edificações, matas ciliares, solo exposto, dentro outras.

- Outros modelos de arquitetura de redes neurais podem ser testados, para que fosse verificada a influência da mesma na rede utilizada e nos valores da estatística Kappa.

- Esta análise temporal junto à outros parâmetros como precipitação, poderiam ajudar na caracterização e na aplicação de modelos de evapotranspiração, para que fossem estimados o K_c de cada cultura, assim subsidiar a irrigação para que a água fosse utilizada de maneira racional.

- São necessários trabalhos de mapeamento e análise da área em relação à questão ambiental, verificando o cumprimento do Código Florestal, a relação entre agricultura, economia local, demanda e desperdício de água, comprometimento da bacia hidrografia local através do assoreamento e qualidade da água.

- A Classificação generalizada pode ser satisfatória na análise multitemporal de alvos que não apresentem expressiva variação temporal, e complexidade no espaço como culturas agrícolas. Logo, análises abordando florestas plantadas, nativas, monitoramento de queimadas, identificação de ataques de pragas em florestas, podem apresentar resposta aquém na exatidão da rede à classificação realizada no respectivo trabalho, facilitando a análise ao longo do tempo, subsidiando pesquisas, planejamento e gestão.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE, C.L. T. de; BRITO, R. A. Métodos de Irrigação e Quimigação. **Circular Técnica 86 - EMBRAPA**. Ministério da Agricultura, Pecuária e Abastecimento. Sete Lagoas , MG. 2006. pág 1-10.
- ARCOVA, F. C. S.; CICCIO, V. de. Water quality in small watersheds with different land uses in Cunha region, State of São Paulo. **Scientia Florestalis**. n. 56, 1999, p. 125-134.
- BARBIERI, V.; MANIERO, M.A.; PEREIRA, A.R. Espaçamento e características agroindustriais da canade- açúcar. In: CONGRESSO NACIONAL DA STAB,4., Olinda, 1987. **Anais**. Olinda: STAB, 1987.p.23-27.
- BASTIAANSEN, W.G.M.. SEBAL – Based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. **Journal of Hydrology**. V. 229.número 1, 27, março 2000. P. 87-100.
- BAUER, M.E.; DAUGHTRY, C.S.T.; VANDERBITT, V.C. Spectral agronomic relationships of maize, soybean and wheat canopies.In: International Colloquium on Spectral Signatures of objects in Remote Sensing , 1., Avignon, 1981. **Anais**. Avgnon: SAM, 1981. p.8-11.
- BENEDETTI, R., and P. ROSSINI. On the use of NDVI profiles as a tool for agricultural statistics: the case study of wheat yield estimate and forecast in Emilia Romagna. **Remote Sensing Environment**. 1993, 45:311- 326.
- BERNARDO, S.; SOARES, A.A.; MANTOVANI, E.C. **Manual de irrigação**. 8. ed. Viçosa, MG: UFV, 2006.
- BENEDIKTSSON, A. J.; SVEINSSON, J.R.. Feature extraction for multisource data classification with artificial neural network. **International Journal of Remote Sensing**. V.18, 1997, p.727-740.
- BISHOP, C.M. **Neural networks for pattern recognition**. 1 ed., Oxford, New York, Oxford University Press, 1995, 482p.
- BRAGA, A. P.; CARVALHO, A.P.L.; LUDERMIR, T.B. **Fundamentos de redes neurais artificiais**. Departamento de Ciência da Computação/IM, COPPE/Sistemas NCE: UFRJ, 1998. 246p.
- BRAGA, A.L.; OLIVEIRA, J. C. de. Identificação e quantificação de áreas irrigadas por pivô central utilizando imagens CCD/CBERS. **Anais... XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 849-856.
- BRITES, R. S. Verificação de exatidão em classificação de imagens digitais orbitais: efeito de diferentes estratégias de amostragem e avaliação de índices de exatidão. Viçosa: UFV. **Tese** (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, 1996, 101 p.
- BUCENE, L.C.; RODRIGUES, L.H.A. Utilização de redes neurais artificiais para avaliação de produtividade do solo, visando classificação de terras para irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, n.2/3, 2004, p.326-329. < <http://www.agriambi.com.br>>

- 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, 1996, p.395-403.
- CAMPBELL, J. B. Introduction to Remote Sensing. **Library of congress Cataloging-in-Publication Date**. 1987, 551p.
- CAUDILL, M.. Expert Networks and emerge tecnologia, marries expert system and neural network to provide the best of worlds. **Byte**, vol.17, outubro, 1991.
- CERQUEIRA, E.O. de; ANDRADE, J.C. de; POPPI, R.J. Redes neurais e suas aplicações em calibração multivariada. **Química Nova**, Vol. 24, N. 6, 2001. pág. 864 – 873.
- CHAVEZ Jr, P.S. Image-based atmospheric corrections-revised and improved. **Photogrammetric Engineering and Remote Sensing**. V.62, n.9, 1996, p. 1025-1036.
- _____, P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**. v. 24, 1988, p. 459-479.
- _____, P.S. Radiometric calibration of Landsat Thematic Mapper multispectral images. **Photogrammetric Engineering and Remote Sensing**, v. 55, 1989, p. 1285-1294.
- CHANDER, G.; MARKHAM, B. Revised Landsat 5 TM radiometric calibration procedures and post-calibration dynamic ranges. 2003. Disponível em: <<http://landsat7.usgs.gov/documents/L5TMCa12003.pdf>>
- CHEN, S. C. Contribuição de dados de satélite no sistema de previsão de safras. In: Seminário Internacional sobre Estimativa da Biomassa Terrestre e da Produção Agrícola Via Satélite, São Paulo, 1990. **Anais...** São José dos Campos: INPE, p. 47-50.
- _____, S. C. **Precisão de classificação do mapa de distribuição de culturas, obtido a partir de imagens Landsat**. São José dos Campos: INPE, 1980. 7 p. (INPE-1889- RPE/232).
- _____, S. C.; GODOY JR., M.; HERZ, R. **Correlação atmosférica através do método de subtração: aplicabilidade para analisar imagens da região amazônica**. São José dos Campos, INPE, 1995. 12p.(INPE-5622).
- CHRISTODIDIS, D. Irrigação, a fronteira hídrica na produção de alimentos. **Revista Item**. N. 54. 2002 pág. 46 – 55.
- _____, D. Oportunidade de irrigação no cerrado - Recursos hídricos dos cerrados e seu potencial de utilização na irrigação. **Revista Item**. N. 69/70. 2006,. Pág 87 -97.
- CONGALTON, R.G.; ODERWAL, R.G. Assessing Landsat classification accuracy using discrete multivariate statistical techniques. **Photogrammetric Engineering and Remote Sensing**, 49(12): 1671-1678, 1983.

- CONGALTON, R.G.; GREN, K. **Assessing the accuracy of remotely sensed data: principles e practices**. New York, Lewis Publishers. 1999. 137p.
- CORBI, J. J.; STRIXINO, S. R.; SANTOS, A. dos; GRANDE M. D. Diagnóstico ambiental de metais e organoclorados em córregos adjacentes a áreas de cultivo de cana-de-açúcar (estado de São Paulo, Brasil). **Quimica Nova**, Vol. 29, No. 1, 2006. pág.61-65.
- CRANE, R. B. Preprocessing techniques to reduce atmospheric and sensor variability in multispectral scanner data. In: International Symposium on Remote Sensing of Environment. **Proceedings**. Michigan: Environment Research, 1971. v. 7, p. 1345 – 1355.
- DOMINGUES, A.F. O estado da arte da agricultura irrigada e as modernas tecnologias no uso racional da água na irrigação. **Seminário da ANA- Agência Nacional das Águas**. Brasília, 2004.
- DOORENBOS, J.; PRUITT, W.O. *Guidelines for predicting crop water requirements*. 2 ed. Rome: **FAO**, 1977 (FAO Irrigation and Drainage Paper 24).
- DUNCAN, W.G. M. In: EVANS, L.T., ed. Crop physiology; some case histories. London, Cambridge University Press, 1975. p. 23-50. In: FAGERIA, Nand Kumar. **Solos tropicais e aspectos fisiológicos das culturas**. Brasília: EMBRAPA –DPU, 1989, pág 297 – 392.
- EL-MAGD, I.A.; TANTON, T. R Remote sensing and GIS for estimation of irrigation crop water demand. **Internatoional Journal of Remote Sensing**. Vol.26, n. 11, 10 de Junho 2005. pág 2.359-2.370.
- EPIPHÂNIO, J. C. N.; FORMAGGIO, A. R. Abordagens de uso de número digital e de reflectância em sensoriamento remoto com dados de satélite. In: Simpósio Brasileiro de Sensoriamento Remoto, 5., 1988. Natal. **Anais...** São José dos Campos: INPE, 1988. v. 2, p. 400-405.
- FAGERIA, N. K. **Solos tropicais e aspectos fisiológicos das culturas**. Brasília: EMBRAPA – DPU, 1989. pág 297 – 392.
- FANCELLI, A.L.; DOURADO NETO, D. **Produção de Feijão** . Livraria e ed. Agropecuária . Guaíba, RS, 2000. pág 23 -48.
- FAO - Food and Agriculture Organization of the United Nations. ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. Smith. Crop Evapotranspiration - Guidelines for Computing Crop Water Requirements—**FAO Irrigation and Drainage Paper 56**. 2006. 333 p.
- FARIA, A.P.; SOARES, J. O desaparecimento de pequenos córregos. **Revista Ciência Hoje**, n 146, 1999.
- FLETCHER, D.; GOSS, E. Forecasting with neural networks: an application using bankruptcy data. **Information and Management**, v.24, n.3, 1993, p.159–167.
- FONTANA, D. C.; BERLATO, M. A; BERGAMASCHI, H.. Relação entre o Índice de Vegetação Global e Condições Hídricas no Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v. 33, n. 8, 1998, 1399 -1405.

- GLERIANI, J.M.; EIPHANIO, J.C.N.; SILVA, J.D. S. da; Classificação espectro-temporal de culturas agrícolas tropicais: tolerância de dois modelos de redes neurais a dados falhos. **Anais. XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 151-158.
- _____, J.M.; Redes Neurais na classificação espectro-temporal de culturas agrícolas. 2004. 198f. **Tese** (Mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais, São José dos Campos, São Paulo.
- HALL, F.G.; STREBEL, D.E.; NICKESON, J.E.; GOETZ, S.J. Radiometric rectification: toward a common radiometric response among multitemporal, multisensor images. **Remote Sensing of Environment**, v.35, n.1, 1991, p. 11-27.
- HAYKIN, S. **Redes Neurais: princípios e práticas**. 2ed. Porto Alegre, Brasil, Bookman, 2001. 900p. In: BUCENE, L.C.; RODRIGUES, L.H.A. Utilização de redes neurais artificiais para avaliação de produtividade do solo, visando classificação de terras para irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, n.2/3, 2004, p.326-329.
- HILL, M.J.; STURN, B. Radiometric correction of multitemporal Thematic Mapper data for use in agricultural land-cover classification and vegetation monitoring. **International Journal of Remote Sensing**, v. 12, n. 7, 1991, p. 1471-1491.
- _____, M.J.; DONALD, G.E. Estimating spatio-temporal patterns of agricultural productivity in fragmented landscapes using AVHRR NDVI time series. **Remote Sensing of Environment**, 84, 2003, p.367-384.
- HOLBEN, B.N. Characteristics of maximum-value composite images from the temporal AVHRR data. **International Journal of Remote Sensing**, Taylor & Francis Ltd, London, UK. vol7; 1986, p.1417-1434.
- _____, 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, 1980, p. 651-656, 1980.
- JACKSON, R.D.; HUETE, A.R. Interpreting vegetation indices. Preventive Veterinary Medicine, v.11, p.185 -200, 1991. In: MOREIRA, M.A. **Fundamentos de sensoriamento remoto e metodologias de aplicação**. Viçosa:UFV, 2003. p.195-204.
- JUSTICE, C.O.; HIERNAUX, P.H.Y. Monitoring the grasslands of the Sahel using NOAA AVHRR data: Niger, 1983. **International Journal of Remote Sensing**, 7, 11, p.1475-1498, 1986.
- 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. The use of backpropagation artificial neural networks in land cover classification. **International Journal of Remote Sensing**, v.24, n.23, 2003, p.4907-4938.
- KIM, K.; YANG, Y.; LEE, J.; Choi, K.; KIM, T. Classification of multispectral image using neural network. In: **Procudings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS) '95**, IEEE , vol. 2. Firenze, Italy, 1995, p.446-448.
- LABUS, M.P.; NIELSEN, G.A.; LAWRENCE, R.L.; ENGEL, R.; LONG, D.S. Wheat yield estimates using multi-temporal NDVI satellite imagery. **International Journal of Remote Sensing**, 23, 20, 2002, p.4169-4180.
- LANDIS, J.R. e KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, n.1, 1977, p. 159-174.
- LIU, W.T.H. **Aplicações de sensoriamento remoto**. Campo Grande: Ed. UNIDERP, 2006. pág. 215 – 242.
- LUIZ, A. J. B.; GÜRTLER, S.; GLERIANi, J. M.; EPIPHANIO, J. C. N.; Campos, R. C. Reflectância a partir do número digital de imagens ETM+. In: Simpósio Brasileiro de Sensoriamento Remoto, 11, 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. CD-ROM.
- MACHADO E.C., PEREIRA, A.R., FAHAL, J.I., ARRUDA, H.V., CIONE, J. Índices biométricos de duas variedades de cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, v.17, n.9, 1982, p.1323- 1329.
- MAGALHÃES, A.C.N. Ecofisiologia da cana-de-açúcar; aspectos do metabolismo do carbono na planta. In: CASTRO, P.R.C., FERREIRA, S.O., YAMADA, T.Y. (ed.) **Ecofisiologia da produção agrícola**. Piracicaba: POTAFOS, 1987. p.113-118.
- MARKHAM, B.; CHANDER, G. Revised Landsat – 5 TM radiometric calibration procedures and postcalibration dynamic ranges. **IEEE Transactionns on Geoscience and Remote Sensing**, vol. 41, Nº 11, November, 2003. 4 p.
- MARQUES, J.Q.de A. Conservação da água: a controvérsia das matas ciliares. **O gronômico**. Campinas, SP, 54(1), 2002. pág 41 a 42.
- MEDEIROS, Ana Maria P., et alii. Imagens Landsat na Estimativa de Áreas de Cana-de-Açúcar, Milho e Soja. In: **Anais**. VIII Simpósio Brasileiro de Sensoriamento Remoto, 1996, Salvador, CD ROM.
- MENDONÇA, J.C.; SOUSA, E. F. de; BERNARDO, S; SUGAWARA, M.T.; PEÇANHA, A.L.; GOTTARDO, R.D. Determinação do coeficiente cultural (Kc) do feijoeiro (*Phaseolus vulgaris* L.), em Campos dos Goytacazes, RJ. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.11, n.5, p.471–475, 2007. Campina Grande, PB, UAEAg/UFCEG . Disponível em: <<http://www.agriambi.com.br>>
- MOREIRA, M.A. **Fundamentos de sensoriamento remoto e metodologias de aplicação**. Viçosa: UFV, 2003. p.195-204.

- _____, M. A. 2001. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**. INPE, São José dos Campos, 250p.
- 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.
- NASA. **Landsat-7 science data users handbook** - Chapter 11 – Data products [online]. http://Ttpwww.gsfc.nasa.gov/IAS/hansbook_htmls/chapter11.html Acesso em novembro 2007a.
- _____. **Landsat-7 science data users handbook** - Chapter 6 - Data properties [online]. http://Ttpwww.gsfc.nasa.gov/IAS/hansbook_htmls/chapter06.html. Acesso em novembro 2007b.
- NEALE, C.M.; BAUSCH, W.C.; HEERMANN, D.F.. Development of reflectance based crop coefficients for corn. **Transaction on American Society of Agricultural Engineering, Academic Press**, New York, USA. 1989.V. 32: 1981-1899.
- NOVO, E M L M. Sensoriamento remoto. Princípios e aplicações. Editora Edgard Blucher: São José dos Campos, 1992, 308p.
- 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. In: GLERIANI, J.M.; **Redes Neurais na classificação espectro-temporal de culturas agrícolas**. São José dos Campos, 2004. 198p. (INPE – no prelo). Dissertação (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.
- ORTIZ, M. J. ; FORMAGGIO, A. R. ; EPIPHANIO, J. C. N. . Classification of croplands through integration of remote sensing, GIS, and historical database.. *International Journal of Remote Sensing*, London, v. 18, n. 1, 1997, p. 95-105.
- PAX-LENNEY, M.; WOODCOCK, S.A. ; MACOMBERR, S.C. Forest mapping with a generalized classifier and Landsat Tm data . **Remote Sensing of Environment. Elsevier Science**. 2001.p.241-250.
- PINTER Jr., JACKSON, R.D.; EZRA, C.E.; GAUSMAN, H.W. Sun-angle and canopy-architecture effects on the spectral reflectance of six wheat cultivars. *International Journal of Remote Sensing*, v.6, n. 12, p. 1813-25, Dec. 1985. In: MOREIRA, M.A. **Fundamentos de sensoriamento remoto e metodologias de aplicação**. Viçosa:UFV, 2003. p.195-204.
- PORTILLO, J.E.; EPIPHANIO, J.C.N.; Görtler, S.; Barreto, Luiz, A.J. Evolução da superfície cultivada principais culturas agrícolas em Guará, Ipuã e São Joaquim da Barra - SP, via imagens de SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, Belo Horizonte - MG, Brasil, **Anais**. São José dos Campos: INPE. Sessão Artigos, 2003. P. 215-222.
- PRICE, J.C. Estimating leaf area index from satellite data. **IEEE Transactions on Geoscience and Remote Sensing**, 31, 3, 1993, p.727-734.

- REICHARDT, K. **A água em sistemas agrícolas**. São Paulo – SP. Ed. Manole Ltda. ESALQ, 1990.pág. 157 – 171.
- RIZZI, R.; RUDORFF, B.F.T. Estimativa da área de soja no rio grande do sul por meio de imagens landsat. **Revista Brasileira de Cartografia**, v.57, n.3, 2005, p.226-234.
- RODRIGUES, J.D. **Fisiologia da cana de açúcar**.Universidade Estadual Paulista, Instituto de Biociências. Botucatu – SP.1995. Site: <http://www.residenciaagronomica.ufpr.br/bibliografia/MATURAD.pdf>. Acesso: 13 de junho de 2007.
- RUDORFF, B.F.T. et al. **Estimativa de área plantada com cana-de-açúcar em municípios do Estado de São Paulo por meio de imagens de satélites e técnicas de geoprocessamento: ano safra 2004/2005**. São José dos Campos: INPE, 2004. 54p. (INPE-11421-RPQ/762).
- RUDORFF, C. de M.; RIZZI, R.; RUDORFF, B. F. T.; SUGAWARA, L. M.; VIEIRA, C. A. O. Superfícies de resposta espectro-temporal de imagens do sensor MODIS para classificação de área de soja no Estado do Rio Grande do Sul. **Revista Ciência Rural**, Santa Maria, v.37, n.1, 2007, p.118-125.
- RUMELHART,D.E. e MCCLELLAND,J.L. Parallel distributed processing, vol 1: Foundations. The MIT Press, 1986. In: BRAGA, A. P.; CARVALHO, A.P.L.; LUDERMIR, T.B. **Fundamentos de redes neurais artificiais**. Departamento de Ciência da Computação/IM, COPPE/Sistemas NCE: UFRJ, 1998.
- SCHOTT, J.R.; SALVAGGIO, C.; VOLCHOK, W.J. Radiometric scene normalization using pseudoinvariant features. **Remote Sensing of Environment**, v. 26, n. 1, 1988, p. 1-16.
- SENTELHAS, P.C.; ANGELOCCI, L.R. Evapotranspiração. Notas de aula da disciplina Meteorologia Agrícola. ESALQ/USP -2007 . <ce.esalq.usp.br/aulas/lce306/aula8.pps>.Acesso: 25 de outubro de 2007.
- SHIMABUKURO, Y.E., SMITH, J.A. The least-squares mixing models to generate fractio images derived from remote sensing multispectral data, IEEE Transactions on Geoscience and Remote Sensing, v. 29, n 1, 1991, p. 16-20.
- SKIDMORE, A.K. Accuracy assessment of spatial information. In: STEIN, A.; MEER, F. van der; GORTE, B. (Ed.). **Spatial statistics for remote sensing**. Dordrecht: Kluwer, 1999. p.197-209.
- SOARES, W.R.; SEDYIAMA,G.C.; RIBEIRO, A.; COSTA, J.M.N. da. Dependência do coeficiente de cultura no estágio inicial de desenvolvimento ($K_{c_{ini}}$) à lâmina de irrigação e textura do solo. **Revista Brasileira de Engenharia Agrícola Ambiental**, Campina Grande, v.5, n.1, 2001, p.23-27.
- SONG, C.; Woodcock, C.E.; SETO, K.C.; Pax-Lenney, M.; MACOMBER, S.A. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? **Remote Sensing of Environment**, v.75, 2001, p. 230-244.

- THOMAS, I.L.; Benning, V.M.; Ching, N.P. **Classification of remotely sensed images**. Bristol, J W Arrowsmith Ltd, 1987. 268p.
- TSO, B.; MATHER P.M. **Classification methods for remotely sensed data**. New York, NY: Taylor and Francis, 2001. 332 p.
- TUBELIS, A. **Conhecimento prático sobre clima e irrigação**. Ed: Fácil, 2001. Pág 99 -112.0.
- VANDERLIP, R.L.; REEVES, H.E. Growth stages of sorghum (*Sorghum bicolor* (L.) Moench). **Agronomy Journal**, v.64, 1972, p.13-16.
- VERMOTE, F.; TANRÉ, D., DEUZÉ, J. L., HERMAN, M., MORCRETE, J. Second simulation of the satellite signal in the solar spectrum, 6S: an overview. **IEEE Transaction on Geoscience and Remote Sensing**, v. 35, n. 3, 1997, p. 675.
- VIEIRA, C.A.O. Accuracy of remotely sensing classification of agricultural s: a comparative study. 2000. 352f. **Thesis** (Degree of Doctor of Philosophy) – University of Nottingham; Nottingham.

APÊNDICE 1

a) GERAÇÃO DAS COMPONENTES GREENNESS (GR) E BRIGHTNESS (BR)

```
{  
Imagem Im3, Im4, Im5, Imgr240401, Imbr240401 ("IMAGEM");  
Im3=Recupere (Nome="SENSOR_b3_DATA");  
Im4=Recupere (Nome="SENSOR_b4_DATA");  
Im5=Recupere (Nome="SENSOR_b4_DATA");  
Imbr030803 = Novo (Nome="BRIGHTNESS_DATA", ResX=30, ResY=30, Nbits=8);  
Imgr030803=Novo (Nome="GREENNESS_DATA", ResX=30, ResY=30, Nbits=8);  
Imgr030803 = Im3 * (-0.5435) + Im4 * (0.7243) + Im5 * (0.084)+40;  
Imbr030803 = (Im3 * (0.3743) + Im4 * (0.4585) + Im5 * (0.4082) + 30) ;  
}
```

b) FATIAMENTO DAS COMPONENTES GR

```
{  
Image Im1 ("IMAGEM");  
Tematico Tem1, Tem2 ("GRBR");  
Tabela fatia1 (Fatiamento);  
Tabela fatia2 (Fatiamento);  
fatia1=Novo(CategoriaFim="GRBR", [45,48]:"claroGR");  
fatia2=Novo(CategoriaFim="GRBR", [38,39,]:"escuroGR");  
Im1=Recupere(Nome="GREENNESS_DATA");  
Tem1=Novo(Nome="clarosGR_DATA", ResX=30, ResY=30, Escala=50000);  
Tem2=Novo(Nome="escurosGR_DATA", ResX=30, ResY=30, Escala=50000);  
Tem1=Fatie(Numerico(Im1), fatia1);  
Tem2=Fatie(Numerico(Im1), fatia2);  
}
```

c) FATIAMENTO DAS COMPONENTES BR

```
{  
Image Im1 ("IMAGEM");  
Tematico Tem1, Tem2 ("GRBR");  
Tabela fatia1 (Fatiamento);  
Tabela fatia2 (Fatiamento);  
fatia1=Novo(CategoriaFim="GRBR", [95,97]:"claroBR");  
fatia2=Novo(CategoriaFim="GRBR", [38,61]:"escuroBR");  
Im1=Recupere(Nome="BRIGHTNESS_DATA");  
Tem1=Novo(Nome="clarosBR_DATA", ResX=30, ResY=30, Escala=50000);  
Tem2=Novo(Nome="escurosBR_DATA", ResX=30, ResY=30, Escala=50000);  
Tem1=Fatie(Numerico(Im1), fatia1);
```

Tem2=Fatie(Numerico(Im1), fatia2);

d) CRUZAMENTO DOS TEMAS GR claros e BR claros PARA OBTER ÁREAS DE CONTROLE RADIOMÉTRICO ESCURAS

```
{
Tematico Tem1, Tem2, Cross ("GRBR");
Tem1=Recupere (Nome="clarosBR_DATA");
Tem2=Recupere (Nome="clarosGR_DATA");
Cross=Novo (Nome="CLAROS_DATA", ResX=30, ResY=30, Escala=50000);
Cross=Atribua (CategoriaFim="GRBR")
{
"claros":(Tem1.Classe == "claroBR" && Tem2.Classe == "claroGR")
};
}
```

e) CRUZAMENTO DOS TEMAS GR escuros e BR escuros PARA OBTER ÁREAS DE CONTROLE RADIOMÉTRICO ESCURAS

```
{
Tematico Tem1, Tem2, Cross ("GRBR");
Tem1=Recupere (Nome="escurosBR_DATA");
Tem2=Recupere (Nome="escurosGR_DATA");
Cross=Novo (Nome="ESCUROS_DATA", ResX=30, ResY=30, Escala=50000);
Cross=Atribua (CategoriaFim="GRBR")
{
"escuros":(Tem1.Classe == "escuroBR" && Tem2.Classe == "escuroGR")
};
}
```

f) OBTENÇÃO DOS VALORES MÉDIOS DE DN NAS ÁREAS DE CONTROLE RADIOMÉTRICO CLARAS

```
{
Image Im3, Im4, Im5 ("SENSOR_IMAGEM");
Tematico TemCL ("GRBR");
Numerico NumCL3, NumCL4, NumCL5 ("MEDIAS");
Im3=Recupere (Nome="SENSOR_b3_DATA");
Im4=Recupere (Nome="SENSOR_b4_DATA");
Im5=Recupere (Nome="SENSOR_b5_DATA");
TemCL=Recupere (Nome="CLAROS_DATA");
NumCL3=Novo (Nome="MediaCl_3_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumCL4=Novo (Nome="MediaCl_4_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
```

NumCL5=Novo (Nome="MediaCl_5_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);

NumCL3=MedZ (Im3, TemCL.Classe == "claros");

NumCL4=MedZ (Im4, TemCL.Classe == "claros");

NumCL5=MedZ (Im5, TemCL.Classe == "claros");

}

g) OBTENÇÃO DOS VALORES MÉDIOS DE DN NAS ÁREAS DE CONTROLE RADIOMÉTRICO ESCURAS

{

Image Im1, Im2, Im3 ("SENSOR_IMAGEM");

Tematico TemESC ("GRBR");

Numerico NumESC1, NumESC2, NumESC3 ("MEDIAS");

Im1=Recupere (Nome="SENSOR_b3_DATA");

Im2=Recupere (Nome="SENSOR_b4_DATA");

Im3=Recupere (Nome="SENSOR_b5_DATA");

TemESC=Recupere (Nome="ESCUROS_DATA");

NumESC1=Novo (Nome="MediaEsc_3_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);

NumESC2=Novo (Nome="MediaEsc_4_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);

NumESC3=Novo (Nome="MediaEsc_5_DATA", 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");

}

h) CÁLCULO DE mi e bi E A GERAÇÃO DE BANDAS RETIFICADAS

{

Imagem Inew3, Inew4, Inew5 ("SENSOR_IMAGEM");

Im3=Recupere (Nome="SENSOR_b3_DATA");

Im4=Recupere (Nome="SENSOR_b4_DATA");

Im5=Recupere (Nome="SENSOR_b5_DATA");

Inew3=Novo (Nome="retif_3_DATA", ResX=30, ResY=30);

Inew4=Novo (Nome="retif_4_DATA", ResX=30, ResY=30);

Inew5=Novo (Nome="retif_5_DATA", ResX=30, ResY=30);

// b - claro r - referencia

br3= entra com o valor da média de DN claros da imagem de referência;

br4= entra com o valor da média de DN claros da imagem de referência;

br5= entra com o valor da média de DN claros da imagem de referência;

// d - escuro r - referencia

dr3= entra com o valor da média de DN escuros da imagem de referência;
dr4= entra com o valor da média de DN claros da imagem de referência;
dr5= entra com o valor da média de DN claros da imagem de referência;
// b - claro s - subject (objeto)
bs3= entra com o valor da média de DN claros da imagem objeto;
bs4= entra com o valor da média de DN claros da imagem de referência;
bs5= entra com o valor da média de DN claros da imagem de referência;
// d - escuro s - subject (objeto)
ds3= entra com o valor da média de DN escuros da imagem de referência;
ds4= entra com o valor da média de DN escuros da imagem de referência;
ds5= entra com o valor da média de DN escuros da imagem de referência;
 $m3=(br3-dr3)/(bs3-ds3);$
 $b3=(dr3*bs3-ds3*br3)/(bs3-ds3);$
 $Inew3=Im3*m3+b3;$
 $m4=(br4-dr4)/(bs4-ds4);$
 $b4=(dr4*bs4-ds4*br4)/(bs4-ds4);$
 $Inew4=Im4*m4+b4;$
 $m5=(br5-dr5)/(bs5-ds5);$
 $b5=(dr5*bs5-ds5*br5)/(bs5-ds5);$
 $Inew5=Im5*m5+b5;$
}

i) OBTENÇÃO DOS VALORES MÉDIOS APÓS RETIFICAÇÃO NAS ÀREAS DE CONTROLE CLARAS

{
Image Im3, Im4, Im5 ("SENSOR_IMAGEM");
Tematico TemCL ("GRBR");
Numerico NumCL3, NumCL4, NumCL5 ("MEDIAS");
Im3=Recupere (Nome="retif_3_DATA");
Im4=Recupere (Nome="retif_4_DATA");
Im5=Recupere (Nome="retif_5_DATA");
TemCL=Recupere (Nome="CLAROS_DATA");
NumCL3=Novo (Nome="MediaCl_retif_3_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumCL4=Novo (Nome="MediaCl_retif_4_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumCL5=Novo (Nome="MediaCl_retif_5_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);
NumCL3=MedZ (Im3, TemCL.Classe == "claros");
NumCL4=MedZ (Im4, TemCL.Classe == "claros");
NumCL5=MedZ (Im5, TemCL.Classe == "claros");
}

}

j) OBTENÇÃO DOS VALORES MÉDIOS APÓS RETIFICAÇÃO NAS ÁREAS DE CONTROLE ESCURAS

{

Image Im1, Im2, Im3 ("SENSOR_IMAGEM");

Tematico TemESC ("GRBR");

Numerico NumESC1, NumESC2, NumESC3 ("MEDIAS");

Im1=Recupere (Nome="retif_3_DATA");

Im2=Recupere (Nome="retif_4_DATA");

Im3=Recupere (Nome="retif_5_DATA");

TemESC=Recupere (Nome="ESCUROS_DATA");

NumESC1=Novo (Nome="MediaES_retif_3_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);

NumESC2=Novo (Nome="MediaES_retif_4_DATA", ResX=30, ResY=30, Escala=50000, Min=0, Max=255);

NumESC3=Novo (Nome="MediaES_retif_5_DATA", 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");

}

k) GERAÇÃO DA IMAGEM PI NUMÉRICO

{

Imagem t3, t4, t5 ("SENSOR_IMAGEM");

Numerico t3N, t4N, t5N ("SENSOR_DATA_numerico");

t3 = Recupere (Nome="B3_SENSOR_DATA");

t4=Recupere (Nome="B4_SENSOR_DATA");

t5=Recupere (Nome="B5_SENSOR_DATA");

t3N= Novo (Nome="B3N_SENSOR_DATA", ResX=30, ResY=30, Escala= 50000, Min=0, Max=255);

t4N=Novo (Nome="B4N_SENSOR_DATA", ResX=30, ResY=30, Escala= 50000, Min=0, Max=255);

t5N=Novo (Nome="B5N_SENSOR_DATA", ResX=30, ResY=30, Escala= 50000, Min=0, Max=255);

t3N= Numerico (t3);

t4N= Numerico (t4);

t5N= Numerico (t5);

}

l) GERAÇÃO DA IMAGEM ZERO-UM

```
{  
Image Im3, Im4, Im5 ("SENSOR_IMAGEM");  
Numerico Imnt3, Imnt4, Imnt5 ("RNA");  
Im3=Recupere (Nome= "B3_ SENSOR_DATA");  
Im4=Recupere (Nome= "B4_ SENSOR_DATA");  
Im5=Recupere (Nome= "B5_ SENSOR_DATA");  
Imnt3=Novo (Nome="B3_DATA_RNA", ResX=30, ResY=30, Escala = 50000, Min=0.0,  
Max=1.0);  
Imnt4=Novo (Nome="B4_DATA_RNA", ResX=30, ResY=30, Escala = 50000, Min=0.0,  
Max=1.0);  
Imnt5=Novo (Nome="B5_DATA_RNA", ResX=30, ResY=30, Escala = 50000, Min=0.0,  
Max=1.0);  
Imnt3= Numerico (( Im3 ) / 120 ) ;  
Imnt4 = Numerico (( Im4 ) / 178) ;  
Imnt5 = Numerico (( Im5 ) / 212 ) ;  
}
```

m) GERAÇÃO DO NDVI

```
{  
Numerico Im3, Im4, ndvi ("SENSOR_DATA_numerico");  
Im3=Recupere(Nome="B3N_ SENSOR_DATA");  
Im4=Recupere(Nome="B4N_ SENSOR_DATA");  
ndvi=Novo(Nome="NDVI_DATA",ResX=30, ResY=30, Min = -1.0, Max= 1.0);  
ndvi = ((Im4-Im3)/(Im4+Im3));  
}
```

n) REFLECTÂNCIA

```
{  
Imagem Im3, Im4, Im5("SENSOR_IMAGEM");  
Numerico Imnt3, Imnt4, Imnt5 ("RNA_ao_retificada");  
Im3=Recupere (Nome="SENSOR_b3_DATA");  
Im4=Recupere (Nome="SENSOR_b4_DATA");  
Im5=Recupere (Nome="SENSOR_b5_DATA");  
Imnt3=Novo (Nome="Reflect_b3_SENSOR", ResX=30, ResY=30, Escala=50000, Min=0,  
Max=1);  
Imnt4=Novo (Nome="Reflect_b4_SENSOR", ResX=30, ResY=30, Escala=50000, Min=0,  
Max=1);  
Imnt5=Novo (Nome="Reflect_b5_SENSOR", ResX=30, ResY=30, Escala=50000, Min=0,  
Max=1);  
elev=37.7/57.2957795130;  
zen=90/57.2957795130 - elev;
```

```

pi=3.141592654;
dmax=255;
d=1.014;
pid2=pi*d^2;
Lmin3=-1.17;
Lmin4=-1.51;
Lmin5=-0.37;
Lmax3=264.0;
Lmax4=221.0;
Lmax5=30.2;
Esun3=1551;
Esun4=1044;
Esun5=225.7;
Imnt3= (( Lmin3 + (Lmax3 - Lmin3) * (Digital (Im3) / dmax)) * pid2 ) / (Esun3*cos(zen)));
Imnt4= ((Lmin4 + (Lmax4 - Lmin4) * (Digital (Im4) / dmax)) * pid2) / (Esun4*cos(zen));
Imnt5= ((Lmin5+(Lmax5-Lmin5)*(Digital (Im5)/dmax)) * pid2)/(Esun5*cos(zen));

```

o) GERAR MAPA TEMÁTICO

```

{
Tematico tem ("Resultados_Tematico");
Numerico nu ("Resultados_ASCII");
Tabela tab (Fatiamento);

nu =Recupere (Nome="40128_900c");

tem = Novo (Nome = "40128_900c", ResX=30, ResY=30, Escala = 50000);

tab = Novo (CategoriaFim = "Resultados_Tematico",
           [ 1.0, 1.0 ] : "na",
           [ 2.0, 2.0 ] : "agua",
           [ 3.0, 3.0 ] : "cana_ano&meio",
           [ 4.0, 4.0 ] : "cana_colh_ano",
           [ 5.0, 5.0 ] : "sorgo",
           [ 6.0, 6.0 ] : "milho",
           [ 7.0, 7.0 ] : "feijao2",
           [ 8.0, 8.0 ] : "feijao1");

tem = Fatie ( nu, tab);

}

```