



**UNIVERSIDADE
ESTADUAL DE LONDRINA**

OSVALDO COELHO PEREIRA NETO

**MAPEAMENTO DE FEIÇÕES AGRÍCOLAS ATRAVÉS DE
REDES NEURAIS ARTIFICIAIS COM FOTOS OBTIDAS POR
VEÍCULO AÉREO NÃO-TRIPULADO (VANT)**

Londrina
2007

OSVALDO COELHO PEREIRA NETO

**MAPEAMENTO DE FEIÇÕES AGRÍCOLAS ATRAVÉS DE
REDES NEURAS ARTIFICIAIS COM FOTOS OBTIDAS POR
VEÍCULO AÉREO NÃO-TRIPULADO (VANT)**

Tese apresentada ao Programa de Pós-Graduação, em Agronomia da Universidade Estadual de Londrina, como requisito parcial à obtenção do título de Doutor em Agronomia.

Orientadora: Profa. Dra. Maria de Fátima Guimarães

Londrina
2007

**Catálogo na publicação elaborada pela Divisão de Processos Técnicos da
Biblioteca Central da Universidade Estadual de Londrina.**

Dados Internacionais de Catalogação-na-Publicação (CIP)

P436m Pereira Neto, Osvaldo Coelho.

Mapeamento de feições agrícolas através de redes neurais com fotos obtidas por veículo aéreo não-tripulado (vant) / Osvaldo Coelho Pereira Neto. – Londrina, 2007.
77f. : il.

Orientador: Maria de Fátima Guimarães.

Tese (Doutorado em Agronomia) – Universidade Estadual de Londrina, Centro de Ciências Agrárias, Programa de Pós-Graduação em Agronomia, 2007.
Bibliografia: f. 61-72.

1. Solos – Manejo – Teses. 2. Agricultura e tecnologia – Teses. 3. Erva daninha – Mapeamento – Teses. 4. Agricultura de precisão – Teses. I. Guimarães, Maria de Fátima. II. Universidade Estadual de Londrina. Centro de Ciências Agrárias. Programa de Pós-Graduação em Agronomia. III. Título.

CDU 631.4

OSVALDO COELHO PEREIRA NETO

**MAPEAMENTO DE FEIÇÕES AGRÍCOLAS ATRAVÉS DE
REDES NEURAS ARTIFICIAIS COM FOTOS OBTIDAS POR
VEÍCULO AÉREO NÃO-TRIPULADO (VANT)**

Tese apresentada ao Programa de Pós-Graduação, em Agronomia da Universidade Estadual de Londrina, como requisito parcial à obtenção do título de Doutor em Agronomia.

BANCA EXAMINADORA

Prof. Dr. Mário Valério Filho
UNIVAP – Universidade do Vale do Paraíba

Dr. Rigoberto Lázaro Prieto Cainzos
CMB Consultoria Ambiental

Prof. Dr. Alan Salvany Felinto
UEL – Universidade Estadual de Londrina

Prof. Dr. Maurício Paulo Ferreira Fontes
UFV – Universidade Federal de Viçosa

Dr. Augusto Guilherme de Araújo (suplente)
IAPAR – Inst. Agrônômico do Paraná

Prof. Dr. João C. Vieira de Almeida (suplente)
UEL – Univ. Estadual de Londrina

Profa. Dra. Maria de Fátima Guimarães
Orientadora
Universidade Estadual de Londrina

Londrina, 09 de fevereiro de 2007.

DEDICATÓRIA

Aos meus amadíssimos super-filhos
GuilhermeBoy e GiovannaGirl

OFERECIMENTO

Aos meus saudosos avós
Maneco e Glorinha, Oswaldo e Teresa,
Como eu queria que vocês estivessem aqui.

AGRADECIMENTOS

Ào Deus Trino, toda honra, glória e louvor, agora e sempre, pelos séculos dos séculos.

À minha orientadora Prof^a Dr^a Maria de Fátima Guimarães pela oportunidade e confiança; uma verdadeira colega de trabalho e reconciliadora de problemas.

Ao Pesquisador Lúcio André de Castro Jorge, da EMBRAPA Instrumentação Agropecuária – São Carlos – SP, por toda a disponibilidade, apoio e aprendizagem proporcionada, pessoa de coração incorruptível.

Ao colega de instituição Prof. Dr. Alan Salvany Felinto, pela elaboração do software; pena não tê-lo conhecido antes, mas artigos futuros nos aguardam.

Ao eterno amigo Sidnei João Siqueira Sant'Anna, pelo apoio logístico na incansável busca bibliográfica.

Às parceiras de departamento e sempre presentes amigas Edna e Regina, por uma quantidade imensa de favores que nem dá para contar.

Aos colegas de trabalho Augusto, Analice, Benedito, Dionísio, Galeano, Isabel, Luis, Maria, Maria José, Sandra, Valdete, Virgínia, Vitor e Zé Maria, pela lista de pequenas coisas do dia-a-dia.

Aos colegas responsáveis pela zeladoria: Anderson, D. Araci, Celsinho, Clenilda, D. Jacira, D. Maria, Pedralina e D. Perci, e toda a equipe de jardinagem da Universidade, pela amizade e profissionalismo na manutenção de um ambiente profissional limpo e “habitável”.

À minha esposa Vânia, por ter aguentado praticamente sozinha, nos 6 meses finais, todo o rojão do dia-a-dia de uma casa com duas crianças; quem tem, sabe que não é fácil!

Aos meus pais, Oswaldo e Esther, a quem eu nunca serei visto como Doutor Oswaldo, mas sempre como o “filhão” e “filhote”, por terem me gerado e amado.

À minha prima Cláudia Vanalli, por todo o “help” na “english language”.

Aos meus irmãos de fé Lincoln e Rosana, Eduardo e Valéria, pela amizade e partilha.

À toda a Comunidade Toca de Assis, pelas orações.

Agradeço imensamente também a minha sogra, Dona Ivone, que por vezes tomou conta de meus filhos com todo amor e zelo.

Gostaria, por último, de listar aquelas pessoas às quais eu não agradeço absolutamente a nada. A quem poderia ter feito algo, mas faltou amor; a quem deveria ter feito algo, mas faltou competência. Porém, a ética e a boa educação me impedem de fazê-lo. A elas, somente meu poético silêncio.

O homem põe a mão no sílex, derruba as montanhas pela base; fura galerias nos rochedos, o olho pode ver nelas todos os tesouros. Explora as nascentes dos rios, e põe a descoberto o que estava escondido. Mas a sabedoria, de onde sai ela? Onde está o jazigo da inteligência? O homem ignora o caminho dela, ninguém a encontra na terra dos vivos. O abismo diz: Ela não está em mim. Não está comigo, diz o mar. Não pode ser adquirida com ouro maciço, não pode ser comprada a peso de prata. Não pode ser posta em balança com o ouro de Ofir, com o ônix precioso ou a safira. Não pode ser comparada nem ao ouro nem ao vidro, ninguém a troca por vaso de ouro fino. Quanto ao coral e ao cristal, nem se fala, a sabedoria vale mais do que as pérolas. Não pode ser igualada ao topázio da Etiópia, não pode ser equiparada ao mais puro ouro. De onde vem, pois, a sabedoria? Onde está o jazigo da inteligência? Um véu a oculta de todos os viventes, até das aves do céu ela se esconde. Dizem o inferno e a morte: Apenas ouvimos falar dela. Deus conhece o caminho para encontrá-la, é ele quem sabe o seu lugar, porque ele vê até os confins da terra, e enxerga tudo o que há debaixo do céu. Quando ele se ocupava em pesar os ventos, e em regular a medida das águas, quando fixava as leis da chuva, e traçava uma rota aos relâmpagos, então a viu e a descreveu, penetrou-a e escrutou-a. Depois disse ao homem: **O temor do Senhor, eis a sabedoria; fugir do mal, eis a inteligência.**

(Livro de Jó, 28: 9-28)

PEREIRA NETO, Osvaldo Coelho. **Mapeamento de feições agrícolas através de redes neurais artificiais com fotos obtidas por veículo aéreo não-tripulado (VANT)**. 2007. 92f. Tese (Doutorado em Agronomia) – Universidade Estadual de Londrina, Londrina, 2007.

RESUMO

A evolução da tecnologia aplicada a agricultura coloca os setores da pesquisa agrícola, atualmente, perante um novo paradigma: o da “Agricultura de Precisão”; muitas pesquisas tem sido conduzidas ao mapeamento da fertilidade do solo, e pouco tem sido feito com relação ao mapeamento de plantas daninhas nas lavouras. O objetivo deste trabalho é produzir um mapeamento preciso das infestações de plantas invasoras em uma cultura de soja, utilizando fotos obtidas através de aeromodelos radiocontrolados. Na primeira etapa do trabalho, com uma foto do aeromodelo sobre a soja, foram feitas várias classificações digitais com os classificadores Maxver, Maxver1CM, Bhattacharya, Distância Euclidiana e Redes Neurais e comparadas com uma classificação feita manualmente (tomada como sendo a verdade terrestre), para se avaliar a porcentagem de acerto total. O melhor classificador foi o de Redes Neurais. Em uma segunda etapa, foram obtidas fotos aéreas por aeromodelo de controle remoto em culturas de cana-de-açúcar, na fase inicial de crescimento, para avaliar falhas de plantio através de processamento de imagens e do classificador por Redes Neurais. A partir do processamento de imagens foi possível a identificação e a quantificação das falhas de plantio na lavoura de cana-de-açúcar. Além das falhas foram identificadas áreas com alteração na lavoura, indicativo de alguma anormalidade, como *Migdolus sp*, nematóide, etc. Estas anormalidades foram classificadas e mapeadas. O desempenho das Redes Neurais foi satisfatório em todas as situações analisadas. Na terceira e última etapa, foi desenvolvido um software de uniformização de temas para se avaliar a melhoria da precisão de mapeamento sobre a foto de cultura de soja contendo infestação de planta daninha, usada na primeira etapa. Testou-se vários graus de intensidade de uniformização; cada nova imagem gerada com a aplicação da uniformização foi interseccionada com a imagem “verdade terrestre” também da primeira etapa. Todas as matrizes de erro foram avaliadas a partir de 3 índices de precisão de mapeamento: Exatidão Global, Tau e Kappa. Observou-se um aumento da precisão de mapeamento com o aumento da intensidade de uniformização de temas até um grau de intensidade máximo de 104 pixels, a partir do qual a precisão começou a decair. O classificador por Redes Neurais mostrou-se uma ferramenta muito eficaz na geração dos mapas temáticos deste trabalho, podendo ser melhorada a precisão de mapeamento desse mapa com aplicação de técnicas de uniformização de temas.

Palavras-chave: Agricultura de precisão. VANT. Redes neurais. Uniformização de temas. Precisão de mapeamento.

PEREIRA NETO, Osvaldo Coelho. **Features crop mapping by artificial neural network from photos obtained unmanned aerial vehicle (UAV)**. 2007. 92p. Tese (Doutorado em Agronomia) – Universidade Estadual de Londrina, Londrina, 2007.

ABSTRACT

The evolution of the technology applied to agriculture places the sectors of the agricultural research, nowadays, before a new paradigm: the “Precision Agriculture”; many researches have been conducted to the mapping of the soil fertility, and little has been done related to the mapping of the weed in crops. The aim of this work is to produce a precise mapping of the infestations of invading plants into a soy plantation, using photos obtained by radio-controlled aeromodels. In the first stage of this work, with a photo taken by the aeromodel over the soy, several digital classifications were made with the classifiers Maxver, Maxver-ICM, Bhattacharya, Euclidian Distance and Neural Networks and compared to a classification made manually (taken as being the terrestrial truth), in order to evaluate the percentage of total findings. The best classifier was the one of Neural Networks. In a second stage, aerial photos of sugarcane plantation were obtained through remote control aeromodel, in the initial growing stage, in order to evaluate the failures of farming through image processing and the Neural Network classifier. From the image processing, it was possible the identification and the quantification of the failures of farming in the sugarcane field. Besides the failures, areas with alteration in the fields were identified and mapped, indicating some abnormality, like *Migdolus sp*, nematodes, etc. The Neural Networks performance was satisfactory in all of the analysed situation. In the third and last stage, a post-classification software was developed in order to evaluate the improvement of the precision of the mapping on the photo of the soy plantation containing weed infestation, used in the first stage. Several smoothing intensity degrees have been tested; each new image generated with the application of the smoothing was intersectioned with the image of the “terrestrial truth” also from the first stage. All of the error matrixes were evaluated from 3 indexes of mapping precision: Global Exactness, Tau and Kappa. It was observed an increase of the mapping precision with the increase of the intensity of smoothing of themes until a maximum degree of intensity of 104 pixels, from where the precision started falling. The classifier through Neural Networks has appeared as a very effective tool in the generation of thematic maps in this work, where the mapping precision of these maps can be improved with the application of post-classification techniques.

Keywords: Precision Farming. UAV. Neural net. Post-classification. Accuracy mapping.

LISTA DE FIGURAS

Figura 2.1 – VANT -Veículo Aéreo Não-Tripulado do projeto ARARA.....	21
Figura 2.2 – Modelo típico de um neurônio.....	28
Figura 2.3 – Modelo de uma Rede Neural tipo MLP.....	29
Figura 3.1 – Composições coloridas utilizadas nas classificações: (a) cor natural, (b) cores R e G atribuídas às componentes G e R da paisagem, respectivamente.	43
Figura 3.2 – Mapas temáticos da área, produzidos pelos classificadores digitais (a) Bhattacharya, (b) Distância Euclidiana, (c) Maxver, (d) Maxver- ICM, (e) Redes Neurais, e pela classificação manual (f) verdade terrestre. “Cultura” em amarelo; “invasora” em vermelho e “entrelinha” em marrom.....	44
Figura 4.1 – Esquema demonstrando o processo watershed: (a) imagem tridimensional análoga a topografia; (b) imagem bidimensional; (c), (d), (e) aumento sucessivo do valor do pixel formando segmentos de contato entre as bacias, chamadas linhas de watershed.....	51
Figura 4.2 – Fluxo de operações de mapeamento.....	52
Figura 4.3 – Detalhe do talhão 2217 (a), de 90,38 ha, e do talhão 2107 (b), de 67,8 ha, com as respectivas localizações e identificação das fotos obtidas.....	53
Figura 4.4 – Imagens típicas obtidas do talhão 2107 em (a) e (b), e os respectivos resultados da segmentação por redes neurais em (c) e (d). Cana-de-açúcar em verde e solo nu em vermelho.	56
Figura 4.5 – Mapas temáticos e estatísticos para os temas cultura e solo nú do talhão 2107. (a) mapa da cultura, (b) mapa estatístico da cultura, (c) mapa do solo nú e (d) mapa estatístico sobre o solo nú	56

Figura 4.6 – Mapas temáticos pela média do Watershed e estatísticos pelo valor das áreas para o talhão 2107. (a) mapa temático para cultura, (b) mapa estatístico de cultura, (c) mapa temático para solo nú, (d) mapa estatístico de solo nú, (e) mapa temático para palha, e (f) mapa estatístico de palha	57
Figura 4.7 – Imagens típicas obtidas do talhão 2217 em (a) e (c), e os respectivos resultados da segmentação por redes neurais em (b) e (d). Cana em verde, solo nu em laranja e palha em vermelho.	58
Figura 4.8 – Mapa temático e estatístico dos temas cultura, solo nú e palha do talhão 2217. (a) mapa da cultura, (b) mapa estatístico da cultura, (c) mapa do solo nú, (d) mapa estatístico do solo nú, (e) mapa de palha, (f) mapa estatístico de palha.	59
Figura 4.9 – Mapas temáticos pela média do Watershed e estatísticos pelo valor das áreas para o talhão 2107. (a) mapa temático para cultura, (b) mapa estatístico de cultura, (c) mapa temático para solo nú, (d) mapa estatístico de solo nú, (e) mapa temático para palha, e (f) mapa estatístico de palha	60
Figura 5.1 – Fotografia aérea obtida por aeromodelo - cultura de soja	68
Figura 5.2 – Imagens classificadas digitalmente (a) Bhattacharya (b) Distância Euclidiana (c) Maxver (d) Maxver-ICM (e) Rede Neural, e (f) classificada manualmente.....	69
Figura 5.3 – Secção de imagens classificadas ilustrando a aplicação da uniformização de temas em graus de intensidade (a) 50, (b) 100 e (c) 150, no classificador digital Maxver-ICM.....	70
Figura 5.4 – Porcentagem de precisão de mapeamento, calculado a partir das matrizes de erro, para cada índice (Exatidão Global, Kappa e Tau), para cada classificador digital e para cada grau de intensidade de uniformização	71
Figura 5.5 – Curvas do classificador por redes neurais para cada um dos índices de precisão de mapeamento e para a média deles, juntamente com suas curvas de regressão (EG = Exatidão Global, T = Tau, K = Kappa).....	72

SUMÁRIO

1 INTRODUÇÃO	14
2 REVISÃO DE LITERATURA	16
2.1 AGRICULTURA DE PRECISÃO	16
2.2 CLASSIFICAÇÃO DIGITAL DE IMAGENS	23
2.2.1 Classificadores Digitais Comumente Utilizados	24
2.2.2 Neurônio biológico e a Rede Neural Artificial	25
2.3 UNIFORMIZAÇÃO DE TEMAS.....	31
2.4 PRECISÃO DE MAPEAMENTO	32
3 ARTIGO A – DESEMPENHO DE REDES NEURAIS NA QUANTIFICAÇÃO DE PLANTAS DANINHAS EM CULTURA DE SOJA: UM ESTUDO PRELIMINAR	35
3.1 RESUMO E ABSTRACT.....	35
3.2 INTRODUÇÃO.....	36
3.3 MATERIAL E MÉTODOS.....	40
3.4 RESULTADOS E DISCUSSÃO	43
3.5 CONCLUSÕES... ..	46
4 ARTIGO B – MAPEAMENTO DE FALHAS DE PLANTIO EM LAVOURAS DE CANA-DE-AÇÚCAR ATRAVÉS DE CLASSIFICAÇÃO POR REDES NEURAIS ARTIFICIAIS	47
4.1 RESUMO E ABSTRACT.....	47
4.2 INTRODUÇÃO.....	48
4.3 MATERIAL E MÉTODOS.....	52
4.4 RESULTADOS E DISCUSSÃO	55
4.5 CONCLUSÕES... ..	61
5 ARTIGO C – AVALIAÇÃO DA INTENSIDADE DE UNIFORMIZAÇÃO DE TEMAS EM RELAÇÃO À PRECISÃO DE MAPEAMENTO DE PLANTAS DANINHAS EM CULTURA DE SOJA	62
5.1 RESUMO E ABSTRACT.....	62

5.2 INTRODUÇÃO.....	63
5.3 MATERIAL E MÉTODOS.....	67
5.3.1 Imagens utilizadas.....	67
5.3.2 Software elaborado	68
5.3.3 Uniformização de temas.....	69
5.4 RESULTADOS E DISCUSSÃO	70
5.5 CONCLUSÕES... ..	73
6 CONCLUSÕES GERAIS	74
REFERÊNCIAS.....	75
APÊNDICES	88
APÊNDICE A – Matrizes de Erro de Classificação	89
APÊNDICE B – Software FillGap	91

1. INTRODUÇÃO

A história registrou as técnicas primitivas de cultivo, e em sua evolução, paralelo à evolução tecnológica mundial, é possível, hoje, visualizar uma terra amplamente mecanizada, com aplicação de conceitos conservacionistas, visando a produção necessária para o alimento da humanidade, sem desfazer da manutenção do meio ambiente e de seus recursos naturais; isso, ao menos, em boa parte do país.

Essa evolução da tecnologia aplicada a agricultura coloca os setores da pesquisa agrícola, atualmente, perante um paradigma: o da “Agricultura de Precisão”. Nos campos agrícolas são tomadas decisões de maneira mais pontual e mais precisa.

Grande parte das pesquisas realizadas atualmente estuda esse tema evolutivo da ciência agrônômica, cuja definição, discutida aqui, abrange duas grandes preocupações da humanidade moderna: a produção de alimentos e a preservação do meio ambiente, através da racionalização na aplicação de insumos agrícolas.

A análise pontual de feições agrícolas já é uma prática realizada em muitas propriedades rurais, mas ainda está, em nível nacional, bastante abaixo do seu potencial de expansão. Dentre as utilidades dessa técnica estão o controle localizado de plantas daninhas e a quantificação de falhas de plantio nas lavouras, feitos através do mapeamento das suas distribuições espaciais.

Uma das maiores ferramentas utilizadas para se fazer trabalhos de mapeamento das mais variadas características físicas das paisagens terrestres é o Sensoriamento Remoto. Iniciando com as fotografias aéreas e evoluindo para as imagens de satélite, despontam hoje os Veículos Aéreos Não Tripulados (VANT, do inglês UAV – Unmanned Aerial Vehicle), que são aeronaves radio-controladas ou autônomas embarcadas com câmeras e/ou filmadoras, por meio dos quais as fotos são obtidas com uma resolução espacial muito melhor que seus antecessores.

Sejam fotos ou imagens, o material obtido pelas técnicas de Sensoriamento Remoto são fonte importante para produzir mapeamentos bastante precisos de qualquer ambiente rural, utilizando, para isso, as mais diversas técnicas de processamento digital de imagens, como a classificação por redes neurais

artificiais.

O processamento digital é, inegavelmente, uma ferramenta extremamente útil para se manipular as imagens para as mais diversas finalidades. Seja para realçar algum componente de interesse na imagem, seja para classificar esses componentes.

A classificação digital de imagens é um método muito utilizado para produzir mapas de uso da terra. Porém, há um problema inerente a esse método. Devido às similaridades nas respostas espectrais dos alvos terrestres e também dos algoritmos utilizados nos programas computacionais utilizados para tais classificações, é comum os mapas possuírem uma fragmentação excessiva de pequenos pontos por todo o mapa. O software classifica elementos muito pequenos da paisagem como sendo diferentes do seu entorno, e que na verdade não o são.

Com isso, é bastante comum se aplicar algoritmos de uniformização de temas nos mapas gerados com classificadores digitais, com o intuito de diminuir a fragmentação de temas e obter um mapa visualmente mais agradável. Porém, delinea-se a hipótese de que uma uniformização muito intensa poderia alterar a classificação que já estaria correta.

Nesse contexto, o objetivo geral deste trabalho é produzir um mapeamento preciso de feições agrícolas em culturas de soja e cana-de-açúcar através do uso de fotos obtidas por VANT. Para se alcançar esse objetivo, foi avaliado o desempenho de vários classificadores digitais, utilizado o melhor desses classificadores para a análise de culturas agrícolas, mapeando anomalias na lavoura e avaliando os resultados, e foi melhorada a precisão do mapeamento obtido através de técnicas de uniformização de temas.

2 REVISÃO DE LITERATURA

2.1 AGRICULTURA DE PRECISÃO

O conceito genérico e simplista de “propriedade agrícola” como uma unidade de produção limitada espacialmente, criou, ao longo da história, a idéia de que essa unidade produtiva deveria ser analisada e avaliada como um todo, onde as intervenções técnicas seriam administradas em toda a propriedade, oriunda de amostragens pontuais. Essas amostragens gerariam um cálculo médio da necessidade de insumos da propriedade.

Atualmente grande parte dos produtores rurais se desfez dessa visão unitária e passou a perceber a grande variabilidade espacial que existe em uma propriedade agrícola enquanto unidade de produção. Tomando-se a fertilidade, umidade e densidade do solo, presença de pragas e doenças e culminando com a própria produtividade, nota-se que a unidade de produção é amplamente segmentada (DAVIS; CASADY; MASSEY, 1998).

Essa evolução do conceito espacial da propriedade agrícola leva o meio rural a um novo paradigma: o da Agricultura de Precisão, onde são tomadas decisões de maneira mais pontual e mais precisa. O termo “Agricultura de Precisão”, segundo Shiratsuchi (2001), é uma nova concepção de agricultura que leva em consideração informações sobre a variabilidade espacial da propriedade agrícola em relação às diversas variáveis ambientais que afetam a produção, como a fertilidade, umidade, pragas e doenças, a fim de otimizar o uso de insumos através de uma aplicação pontual.

O US National Research Council, que juntamente com a National Academy of Sciences, a National Academy of Engineering e o Institute of Medicine, é uma organização de excelência na produção científica nos Estados Unidos, conceitua a agricultura de precisão como “uma estratégia de manejo que usa a tecnologia da informação para a obtenção de dados provenientes de várias fontes, visando dar suporte a decisões associadas à produção agropecuária”. A US Farm Bill define, de forma mais completa, como sendo “um sistema de produção agropecuário baseado na integração da informação com a produção, visando

aumentar, a longo prazo, a eficiência da produção numa área da propriedade ou no todo, aumentar o lucro, com simultânea minimização dos impactos indesejáveis no meio ambiente e na vida selvagem” (MACHADO, 2003).

Porém, em ambas as definições, falta o que Moura, Tybusch e Tavares (2003) destacam: a exigência de dados espaciais precisos, em um sistema georreferenciado (superfície terrestre como referência).

Segundo Fangquan (2002), a implicação básica do conceito de “agricultura de precisão” é a aplicação da técnica 3S: Sistema de Informação Geográfica (GIS), Sistema de Posicionamento Global (GPS) e Sensoriamento Remoto, visando uma completa diagramação das técnicas de manejo agrícola. Feizhou et al. (2005) cita a tecnologia 3S como sendo o principal suporte para se obter, armazenar, atualizar, analisar e aplicar a informação espacial nos diversos biossistemas observados da terra, dos quais os sistemas agrícolas estariam inclusos.

Segundo Burrough e McDonnell (1998), o GIS é um conjunto de ferramentas para coletar, armazenar, transformar e visualizar dados espaciais oriundos do mundo real, com a finalidade de atingir um objetivo particular. Esses dados são representados em termos de um posicionamento (respeitando um sistema de coordenadas conhecido, como UTM), de atributos (características não associadas à posição, como a cor ou pH) e da interrelação espacial (chamado de topologia, descreve como esses dados são interligados uns aos outros).

Dentre os sistemas GIS, o SPRING é um software capaz de gerenciar informações obtidas a partir de metodologias aplicadas em agricultura de precisão, e facilmente manipula essas informações de maneira a se chegar a resultados precisos, que serão retornados ao campo na forma de “tomada de decisão” (DAINESE, 2001).

O posicionamento (ou georreferenciamento) dos dados é possível graças ao desenvolvimento do GPS, o principal responsável pelo sucesso e expansão da Agricultura de Precisão (MOLIN, 1997). Esse sistema determina o posicionamento terrestre através da triangulação de, no mínimo, 3 satélites, de um conjunto de 24 disponíveis, dispostos em 6 planos de órbita ao redor do planeta (MOLIN, 1998).

O georreferenciamento normalmente é feito sobre dados de Sensoriamento Remoto, que podem ser imagens de satélite ou fotografias aéreas. Essa tecnologia consiste da utilização de sensores para aquisição de informações

de um alvo à distância, sem intervenção direta do operador, através do registro da interação da radiação eletromagnética com o alvo (NOVO, 1992).

Essas três tecnologias: GIS, GPS e Sensoriamento Remoto, desenvolveram-se independentemente entre si, mas atualmente são extremamente interligadas; ao se integrar dados de Sensoriamento Remoto a um GIS, o georreferenciamento com GPS sobrepõe corretamente esses dados (BLASCHKE; KUX, 2005).

Essa integração permite manusear de forma eficiente uma grande quantidade de informação espacial, e essa quantidade tende a aumentar à medida que se adquirem dados de campo para análise e se correlacionam estes dados com os fatores de produção agrícola, visando à aplicação dos conceitos da Agricultura de Precisão (MOLIN, 1997).

No contexto da variabilidade espacial do campo agrícola, base da Agricultura de Precisão, várias temáticas são passíveis de estudo: compactação do solo, teor de clorofila da planta, umidade do solo, fertilidade do solo, níveis de infestação e mapas de produtividade.

Dentre essas temáticas, o estudo da infestação das culturas agrícolas por plantas daninhas tem sua importância por acarretar significativa redução nos rendimentos de produção agrícola. Segundo Karam, Melhorança e Oliveira (2006), as perdas na cultura de milho podem ser de 10% da produção, podendo chegar a 85% em áreas onde nenhum controle da infestação foi realizado. Também Gazziero et al. (1998) apontavam perdas da ordem de 13,5% na produção de soja, o que equivale a 15,75 ton/ano da produção mundial do grão.

Por outro lado, vários trabalhos apontam a grande economia de insumos que ocorre com a adoção de práticas da Agricultura de Precisão, e isso também é evidente na aplicação localizada de herbicida oriundo do mapeamento da infestação de plantas daninhas. Johnson, Mortensen e Martin (1995) já apontavam uma economia de herbicidas da ordem de 30 a 71% em dicotiledôneas e de 70 a 94% em monocotiledôneas, comparando a aplicação localizada à aplicação convencional uniforme em toda a área da lavoura. Christensen, Walter e Heisel (1999) apontam que a economia com herbicidas pode ser de 40% em trigo, 72% em soja e de 51 a 94% em milho.

As vantagens econômicas são inúmeras, mas não são unânimes. Lambert e Lowenberg De Boer (2000) apud Shiratsuchi, Christoffoleti e Fontes

(2003) avaliaram 63 trabalhos sobre a lucratividade da aplicação localizada de herbicidas e observaram vantagem econômica em 73% dos casos contra 11% de situações com prejuízo financeiro.

As técnicas de mapeamento de plantas daninhas se dividem, segundo Lutman e Perry (1999), em dois grandes grupos: a detecção manual, onde as áreas infestadas são percorridas e mapeadas "*in locu*" (SALVADOR; ANTUNIASSI, 2006; SHIRATSUCHI, 2001), e a detecção automática, onde são utilizadas imagens aéreas ou orbitais para se localizar e mapear as infestações (TIAN, 2002).

Quanto à detecção automática, Hunt, Hamilton e Everitt (s.d.) recomendam que o tamanho do pixel da imagem a ser utilizada para mapeamento de plantas daninhas seja de, no mínimo, um quarto da área do menor agrupamento de planta daninha que se deseja mapear. Com isso, boa parte das imagens orbitais seria imprópria para um mapeamento detalhado.

Levando em conta, por exemplo, a grade de amostragem de 20X20 metros que Shiratsuchi, Molin e Christoffoleti (2004) e Salvador e Antuniassi (2006) fizeram para levantamento de infestação de plantas daninhas, as imagens orbitais de baixo custo ou gratuitas abrangeriam no máximo um pixel de tamanho; em contrapartida, as imagens de altíssima resolução espacial seriam inviáveis devido ao alto custo.

Dentre os meios possíveis de se obter imagens de sensoriamento remoto para mapear o meio ambiente, já estão consagradas as fotografias aéreas obtidas por aviões específicos para tal finalidade, e as imagens digitais obtidas por um grande número de satélites em órbita da Terra. Considerando a resolução espacial como um fator de fundamental importância no mapeamento detalhado de qualquer feição da paisagem que exija grande definição visual de áreas pequenas, como na infestação de plantas daninhas em uma lavoura, foram criados mais recentemente, os VANT's – Veículos Aéreos Não-Tripulados (do inglês UAV's – Unmanned Aerial Vehicle), na tentativa de se obterem imagens do meio ambiente com altíssima resolução espacial. Os VANT's são aeronaves, radio-controlados ou pré-programados, embarcados basicamente com câmeras fotográficas digitais, filmadoras e GPS.

Segundo Eisenbeiss (2004), o termo VANT's abrange todo veículo aéreo sem nenhuma pessoa a bordo, mas com capacidade de ser controlado.

Sendo fortemente impulsionado pelas aplicações militares no período pós-Segunda Guerra Mundial, as principais aplicações para sensoriamento remoto poderiam ser definidas como observação, levantamento, manutenção e monitoramento do ambiente terrestre. A partir de imagens obtidas desses equipamentos e dos mapas oriundos das análises destas, pesquisadores das mais diversas áreas do conhecimento agrônomo seriam capazes de reconhecer claramente as diferentes taxas de aplicação de insumos em conjunto com os diferentes tipos de manejo dados às lavouras de um modo muito mais detalhado e preciso.

Em relação à alta resolução espacial das imagens produzidas, os VANT's tem potencial para emergir no mercado de sensoriamento remoto como uma alternativa viável econômica e tecnicamente, em comparação às aeronaves tripuladas e às imagens de satélite. E esse potencial está se expandindo no Brasil, pois em junho de 2005 foi realizado, na cidade de São José dos Campos – SP, o 1º Seminário Internacional de VANT, com o objetivo de verificar as tecnologias disponíveis não só no Brasil, mas no mundo.

O ICMC – Instituto de Ciências Matemáticas e de Computação da USP, juntamente com a EMBRAPA Instrumentação Agropecuária, ambas localizadas em São Carlos – SP, desenvolveram o projeto ARARA (Aeronave de Reconhecimento Assistida por Rádio e Autônomas), um VANT de escala reduzida (figura 2.1) para monitoramento de áreas agrícolas ou sujeitas a problemas ambientais. Seu peso total é de 4 kg, transportando até 1,5 kg de carga útil, dentre os quais estão máquinas fotográficas, filmadoras, GPS, altímetros, etc. Mede aproximadamente 1,7 m de comprimento e 2 m de envergadura (TRINDADE JÚNIOR; JORGE; NERIS, 2002).




Figura 2.1 – VANT - Veículo Aéreo Não-Tripulado do projeto ARARA.

Inúmeras são as aplicações possíveis dos VANT's nos mais diversos ramos da sociedade. A U.S. Border Patrol monitora as fronteiras do Estado do Arizona rastreando drogas e contrabando (SWEDLUND, 2005). O Departamento de Tráfego de Israel monitora o trânsito em cidades e rodovias e rastreia motoristas imprudentes (SHARVIT, 2005). Empresas particulares oferecem serviços de mapeamento de linhas de transmissão de energia com sensor infravermelho para acusar pontos de curto-circuito (SCANDICRAFT, 2007) e monitoramento da integridade de oleodutos através de terrenos áridos, desolados e/ou de difícil acesso ao ser humano (TAG, 2007b).

Na área ambiental, os VANT's também são amplamente utilizados. Órgãos governamentais da Suécia na área de meteorologia mapeiam partículas em suspensão na atmosfera em diferentes altitudes (ABRAHAMSSON; NORBERG; NOONE, 2003). Autoridades locais e federais fazem mapeamento de danos causados pela passagem de furacões, como o Katrina (HUNTSVILLE TIMES, 2005). Pesquisadores da NOAA – National Oceanic and Atmospheric Administration observam ciclones bem próximos a sua superfície (NOAA, 2005). A NASA – National Aeronautics and Space Administration realiza missões científicas no Ártico e na Antártida para medir a superfície topográfica da criosfera e suas mudanças ao longo do tempo (NASA, 2005). Gouqing, Chaokui e Penggen (2005) desenvolveram um método de ortorretificação de imagens de vídeo obtidas por VANT para monitorar incêndios florestais.

No tocante às pesquisas agronômicas, cerne deste estudo, a tecnologia dos VANT's está sendo aplicada em várias metodologias de trabalho. Na Universidade de Nottingham estão juntando informações fotográficas de várias safras de trigo para prever com exatidão os estágios de crescimento da cultura (UNIVERSIDADE DE NOTTINGHAM, 2005). O College of Agriculture da Universidade do Kentucky está detectando nível de estresse nutricional em milho e trigo, com fotos tomadas ao longo da safra (STOMBAUGH; MUELLER, s.d.). Eisenbeiss e Vogler (2006) estão gerando modelos de elevação com dados de VANT e estudando a influência da inclinação do terreno sobre a dispersão de pólen na cultura do milho. O vinhedo de San Bernabe, situado ao sul de Monterrey, no Estado da Califórnia, monitora em tempo real, através de sensor infravermelho termal, a temperatura da área, para aplicar medidas de proteção em caso da ameaça de ocorrência de frio (UAVCOLABORATIVE, s.d.). Herwitz et al. (2004) conduziram um levantamento em 1500 hectares de café no Havaí para mapear plantas daninhas e para revelar áreas com anomalias de irrigação e de fertilização.

Jorge et al. (1999) e Jorge (2001) apresentaram os primeiros resultados do processamento de imagens com a aplicação de um VANT para estudo agrícola no Brasil. Em Jorge e Trindade Júnior (2002) e Jorge (2003) são apresentadas as aeronaves utilizadas neste trabalho, bem como alguns resultados nas diferentes culturas.

Mais exemplos de aplicações de VANT's podem ser encontrados em UAVMarketSpace (s.d.) e TAG (2007a).

Qualquer fotografia aérea obtida para fins de levantamento do meio em estudo é analisada visualmente, por intermédio da experiência de um fotointérprete, ou digitalmente, por algoritmos computacionais que processam essas imagens para realçar os elementos da paisagem que, posteriormente, podem ser passíveis de nova análise visual. Dentre esses processamentos digitais, a classificação de imagens é de grande destaque na discriminação e quantificação de elementos temáticos da paisagem. Entre os classificadores digitais mais recentemente elaborados, estão aqueles que fazem parte da tecnologia de Inteligência Artificial, chamados de Redes Neurais Artificiais.

2.2 CLASSIFICAÇÃO DIGITAL DE IMAGENS

Várias observações de campo são conduzidas com intuito de se obter dados para análise do dossel agrícola; como ferramenta auxiliar, o processamento digital de imagens (aéreas ou orbitais) vem acompanhando esse método de trabalho.

Daamen et al. (2003) compararam a estimativa de produção de cana-de-açúcar por observações de campo e por tratamento de imagens de satélite, obtendo boa relação dos dados obtidos em campo com o IVDN - Índice de Vegetação por Diferença Normalizada (do inglês NDVI - Normalized Difference Vegetation Index) obtido da imagem do satélite. Também Berka e Rudorff (2003) estimaram uma área plantada com soja através da análise de imagens do satélite Landsat, e compararam esse dado com as estimativas oficiais de entidades relacionadas às atividades agrícolas; concluíram que há possibilidade de sucesso na comparação se forem obtidas duas imagens em períodos diferentes da safra.

No tocante à classificação digital de imagens, muitas metodologias vêm sendo aplicadas, sempre com relativa contribuição aos pesquisadores da área.

Ippoliti, Gaggero e Costa (2003) aplicaram classificação supervisionada sobre uma área de pastagens, e discriminaram 3 tipos de cobertura: vegetação verde, seca e solo exposto, havendo um pouco de confusão entre área de solo exposto e vegetação seca. Tian (2002) utilizou de imagens de sensoriamento remoto para localizar áreas com infestação de invasoras em uma cultura, e simulou um mapa para navegação em campo com a finalidade de aplicação seletiva de herbicidas.

Em uma escala de abrangência menor, Cruvinel e Minatel (2002) elaboraram um método de classificação digital de fotos de pés de laranja, onde se sabia o vigor da planta através do número e tamanho dos frutos destacados no processamento. De modo semelhante, Bacci et al. (2002) desenvolveram um software que analisa qualidade de sementes por processamento digital, a partir de fotos tiradas de uma pequena quantidade delas.

A classificação de imagens, seja aérea ou orbital, sempre serviu de vigorosa fonte de dados para os Sistemas de Informação Geográfica. Vários classificadores já consagrados pela pesquisa, como Maxver, Bhattacharya ou Distância Euclidiana, produziram mapas temáticos das mais variadas regiões do

planeta Com a constante evolução tecnológica, novos algoritmos surgem na tentativa de serem mais precisos que seus antecessores. Nesse contexto, as chamadas Redes Neurais Artificiais vem se tornando hoje uma excelente opção na elaboração de mapeamentos temáticos, mostrando-se um classificador estatístico poderoso (ANDRADE; BOTELHO; CENTENO, 2003).

2.2.1 Classificadores Digitais Comumente Utilizados

Dependendo do processo utilizado, os classificadores digitais são divididos em dois grupos: classificadores “pixel a pixel”, quando utilizam apenas o valor espectral do pixel como dado para a classificação, e classificadores por regiões, quando, além do valor do pixel, relacionam este aos valores dos pixels espacialmente vizinhos através de um processo chamado segmentação (INPE, 2006). Segundo Moreira (2001), a segmentação tem por objetivo compartimentar a imagem em regiões homogêneas conforme a textura, tom de cinza e contraste da imagem.

Dependendo do tipo de treinamento do classificador, ou seja, do tipo de aquisição de amostras da imagem para cada classe temática, este pode ser: supervisionado (o intérprete conhece a área, identifica as classes na área e pode controlar a aquisição de amostras para treinamento) ou não-supervisionado (o intérprete desconhece a área, o software reconhece classes distintas e o usuário não controla a aquisição de amostras) (INPE, 2006).

Dentre os classificadores utilizados neste trabalho, o Maxver, o Maxver-ICM e a Distância Euclidiana são do tipo “pixel a pixel” com treinamento supervisionado e o Bhattacharya é um classificador por regiões também supervisionado.

Com relação aos classificadores “pixel a pixel”, o classificador Maxver é o mais comumente utilizado dentre os classificadores existentes. Ele pondera as distâncias entre as médias dos valores digitais dos pixels de cada classe temática. As amostras de treinamento configuram o diagrama de dispersão das classes e suas frequências de distribuição, considerando que cada classe se comporta como uma distribuição normal. Quanto ao Maxver-ICM (Interated Conditional Modes), a imagem é classificada como no Maxver e, posteriormente, são consideradas as classes

atribuídas aos pixels vizinhos (chamada de informação contextual). No método por Distância Euclidiana, as amostras de treinamento definem agrupamentos de pixels (classes) e o classificador compara a distância de cada pixel da imagem à média de cada agrupamento, associando-o ao agrupamento que apresentar a menor distância (INPE, 2006).

Quanto aos classificadores por regiões, o método de Bhattacharya utiliza as regiões homogêneas formadas no processo de segmentação como amostras de treinamento, procurando agrupá-las a partir das medidas de similaridade entre elas (INPE, 2006).

2.2.2 Neurônio Biológico e a Rede Neural Artificial

Os animais, incluindo o ser humano, são dotados de vários sistemas sensores (visuais, auditivos, etc.), cuja função é captar informação sobre o meio ambiente ao qual estão inseridos. Essa informação é transformada em uma percepção ou em um movimento pelo cérebro, que contém uma rede de cerca de 100 bilhões de células responsáveis por tal atividade: as células neurais ou neurônios. Esse potencial que o cérebro tem para produzir comportamentos altamente complexos não depende tanto da variedade dessas células, mas, principalmente, da sua quantidade e de suas precisas conexões umas às outras.

Segundo Haykin (2001), o neurônio é como uma unidade de processamento independente, capaz de se comunicar com todo o sistema neural através de contato com outros neurônios.

Um neurônio típico apresenta algumas regiões morfológicamente definidas. O corpo celular, ou soma, é o centro metabólico da célula; abriga as organelas responsáveis pelo funcionamento do neurônio. Deste corpo se prolongam dois tipos de filamentos: os dendritos, que são numerosos e tem a função de receber os sinais gerados por outros neurônios, e o axônio, um único filamento que conduz o sinal (chamado “potencial de ação”) do neurônio de origem (pré-sináptico) para os próximos neurônios conectados (pós-sinápticos).

O ponto de contato entre os neurônios é chamado de sinapse. O axônio pode ter ramificações terminais que podem formar sinapses com até 1.000 outros neurônios. (KANDEL; SCHWARTZ; JESSELL, 2000).

De acordo com a regra chamada “lei de Eccles”, cada neurônio excita ou inibe o sinal para todos os neurônios aos quais está conectado (EBERHART; DOBBINS, 1990).

O potencial de ação provocado no axônio de um neurônio é função da integração espacial e temporal dos estímulos que chegam aos dendritos. Espacial porque combina todos os estímulos excitatórios e inibitórios que chegam, e temporal devido a esses estímulos chegarem a instantes diferentes e permanecerem por alguns milissegundos na “memória” da sinapse (KOVÁCS, 1996).

As informações que chegam ao neurônio são somadas e, ao ultrapassarem certo limiar, chamado de “limiar de disparo”, geram um estímulo que é transmitido pelo axônio aos outros neurônios (KOVÁCS, 1996).

Há basicamente duas razões que justificam o uso do sistema nervoso biológico como modelo para as simulações testadas em computador. A primeira razão deve-se ao fato de o cérebro ser um órgão de reconhecido sucesso quando utilizado em raciocínios diversos e, portanto, seria um ótimo exemplo a ser imitado. A segunda é que as simulações desenvolvidas em computador podem auxiliar o melhor entendimento dos mecanismos de funcionamento do cérebro. As redes computacionais, que tem por característica serem distribuídas e adaptáveis, podem aprender, reconhecer padrões complexos, generalizar e discriminar comportamentos similares; isso leva os pesquisadores dessa área a crerem que o cérebro manipula suas informações através do mesmo mecanismo (MAREN; HARSTON; PAP, 1990).

Uma rede neural artificial (RNA) é uma técnica computacional de Inteligência Artificial que procura viabilizar a mesma funcionalidade do cérebro humano e seus neurônios. Essas redes são especialmente úteis em situações onde não existe uma solução algorítmica, ou seja, os dados não obedecem a uma seqüência lógica para solucionar o problema (WILHELM; LOPES; DOROW, 2003).

Uma rede neural é uma coleção de unidades de processamento, chamadas de neurônios, dispostos em uma estrutura de uma ou várias camadas e conectados uns aos outros de forma paralela. Reagem coletivamente a um dado estímulo e produzem uma única resposta global. Uma rede neural tem a habilidade de

aprender um dado tipo de conhecimento, armazenar este conhecimento e usá-lo mais tarde para executar uma tarefa. O conhecimento de uma rede neural artificial está na estrutura das conexões entre as unidades (neurônios) que a compõe. A cada conexão associa-se um peso (valor numérico) que caracteriza a força da conexão entre dois neurônios. O aprendizado em uma RNA é realizado por um processo de adaptação dos seus pesos (MAREN; HARSTON; PAP, 1990).

Cada unidade da rede é dotada de um estado interno, denominado estado de ativação. As unidades podem propagar seu estado de ativação para as outras unidades através das conexões existentes. A regra que determina a ativação de um neurônio em função das entradas, ponderadas pelos respectivos pesos, se chama regra de ativação ou função de ativação (MAREN; HARSTON; PAP, 1990).

Na Figura 2.2 pode ser visto um neurônio artificial típico. A entrada fixa é utilizada para referência, mas pode ser omitida.

Alterações nas conexões e na estrutura da rede é o que permite realizar o aprendizado de um novo comportamento. Desta maneira, pode-se modificar o estado de ativação na saída da rede em resposta a certa configuração de entradas. Portanto, a rede é capaz de estabelecer associações de entrada-saída (estímulo e resposta) para se adaptar a uma situação proposta. No caso de uma rede com aprendizado supervisionado, a rede deve adaptar os seus pesos de maneira que possa responder de acordo com o exemplo dado, ou seja, gerando na sua saída um estado de ativação compatível para com o esperado. O método utilizado para modificar o comportamento de uma rede é denominado de regra de aprendizado (HAYKIN, 2001).

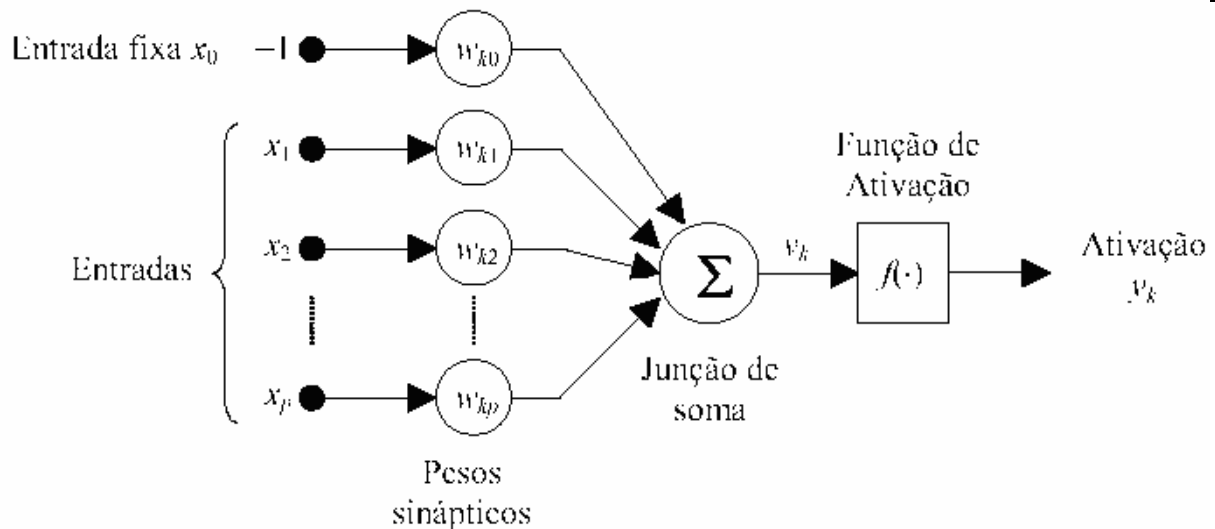


Figura 2.2 – Modelo típico de um neurônio

Fonte: Haykin (2001, p.38)

A forma de aprendizado é em geral um processo gradual e iterativo, onde os pesos são modificados várias vezes, pouco a pouco, seguindo-se uma regra de aprendizado que estabelece a forma como estes pesos são alterados. O aprendizado pode ser supervisionado ou não-supervisionado. No aprendizado supervisionado, o usuário dispõe de um comportamento de referência preciso que ele deseja ensinar para a rede (critério externo). A rede deve ser capaz de medir a diferença entre seu comportamento atual e o comportamento de referência e corrigir os pesos de maneira a reduzir este erro (desvio de comportamento em relação aos exemplos de referência). Nos casos de problemas de classificação, a saída é a classe à qual cada exemplo está associado. No aprendizado não-supervisionado, os pesos da rede são auto-organizados, sem modificação através de critérios externos (FERNANDES, 2003).

A adaptação/otimização dos pesos também pode ser implementada por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado. Dentre vários tipos existentes, os mais utilizados na literatura são os métodos de correção do erro, tendo como principais exemplos de modelos deste tipo o Back-Propagation. Outro elemento importante diz respeito à forma como os neurônios armazenam as informações. As unidades do tipo Perceptron são os modelos de neurônios mais utilizados na atualidade. Ele é a base de diversos tipos de RNA com aprendizado supervisionado utilizando uma adaptação por correção de erros. O

modelo do Perceptron de múltiplas camadas (MLP – Multi-Layer Perceptron) tornou-se muito conhecido e aplicado, sendo na maior parte das vezes associado à regra de aprendizado Back-Propagation (JORGE, 2001).

Para a construção de uma rede neural do tipo MLP – Multi-Layer Perceptron (Figura 2.3), devem ser definidos os elementos que alimentarão a rede (camada de entrada) e os elementos que fornecerão os resultados (camada de saída), sendo que esses elementos devem ter conexões (neurônios) com camadas intermediárias (camadas ocultas) (WILHELM; LOPES; DOROW, 2003).




Figura 2.3 – Modelo de uma Rede Neural tipo MLP.

As redes neurais artificiais têm sido aplicadas em vários estudos agronômicos com sucesso. Shock et al. (2002) analisaram a dinâmica da área agrícola de uma porção da região do rio Nilo, onde a rede neural interrelacionou 10 imagens TM-Landsat; Velloso, Simões e Carneiro (2002) também detectaram mudança na cobertura da superfície da terra com imagens de sensoriamento remoto e redes. Igualmente, Del Frate et al. (2002) monitoraram a evolução de campos de trigo baseado em um modelo de redes neurais. Ulson et al. (2002), com o objetivo de identificar o conteúdo de nitrogênio em plantas, interrelacionaram, por rede neural, diferentes cultivares, tratamentos com fertilizantes, tipos de folha e o conteúdo real de

nitrogênio. Feldberg, Netanyahu e Shoshany (2002) desenvolveram e testaram uma rede neural artificial em uma imagem de satélite Landsat de uma área com gradiente climático de região árida a úmida, visando analisar temporalmente as mudanças na paisagem; o desempenho da rede foi melhor que o dos classificadores por distância mínima e por máxima verossimilhança. Shahin, Tollner e McClendon (2001) desenvolveram uma rede neural artificial para selecionar maçãs conforme o teor hídrico do fruto, baseado em imagens por tomografia. Bucene e Rodrigues (2004) avaliaram alguns atributos de solo, como pH, CTC, P, Mg e K, para classificar a fertilidade do solo, permitindo a diferenciação das terras para fins de irrigação. Uno et al. (2005) avaliaram o potencial de imagem aérea hiper-espectral para desenvolver um sistema de estimativa de produção de milho. Jorge (2001) tem utilizado RNA para determinação da cobertura do solo.

Como parte dos estudos agrônômicos, o estudo de plantas daninhas também é alvo do uso de redes neurais artificiais para sua discriminação no campo. Burks et al. (2005) avaliaram diferentes modelos de redes neurais para discriminar diferentes espécies de plantas daninhas. Aitkenhead et al. (2003) discriminaram plantas daninhas entre mudas de cenoura, assim como Kavdir (2004) com plantas de girassol. Yang et al. (2003) também mapearam plantas daninhas em cultura de milho para gerar um mapa de aplicação pontual de herbicidas.

As redes neurais artificiais são igualmente utilizadas no mapeamento e posterior análise de lavouras de cana-de-açúcar. Madeiro et al. (2006) desenvolveram um algoritmo baseado em redes neurais para calcular mais precisamente o ponto de maturação da cana. Dias (2004) mapearam a infecção de ferrugem na cana com fotos obtidas por aeromodelos. Fanglan et al. (2005) avaliaram as irregularidades na execução do corte da cana visando mais eficiência da colheitadeira. Gleriani (2005) desenvolveu uma nova metodologia de classificação digital por redes neurais através da observação de um pixel ao longo das fenofases da cultura, obtendo sua espectro-temporalidade.

As redes neurais, quando aplicadas em imagens que detenham uma gama de valores de cinza muito variados entre pixels vizinhos, geram mapas temáticos com uma pulverização excessiva de pequenos polígonos distribuídos pelo mapa, como todo classificador do tipo pixel-a-pixel. Para suavizar esse efeito, existem algoritmos de pós-classificação que visam à uniformização dos temas.

2.3 UNIFORMIZAÇÃO DE TEMAS

Nas operações de classificação digital de imagens, onde são associadas classes temáticas aos valores de cada pixel, é comum ocorrer uma pulverização excessiva dos pixels classificados por toda a imagem, principalmente naqueles algoritmos denominados “pixel a pixel”. Isso decorre de valores semelhantes de reflectância de um pixel para outro, mesmo sendo objetos da paisagem diferentes. Esse fato é, de certa forma, indesejável, pois pode dificultar a análise da distribuição espacial dos elementos da paisagem na imagem pelo fotointérprete.

Para minimizar esse efeito, existem processos computacionais chamados de pós-classificação, ou uniformização de temas, o qual é aplicado um filtro digital sobre a imagem classificada na tentativa de eliminar os pontos isolados e melhorar o aspecto visual do produto mapeado. Vários trabalhos citam o uso desse processo (SILVA; MATTOS; PEREIRA NETO, 2000; DAINESE, 2001; LACRUZ, 2003).

Vários são os algoritmos de uniformização de temas existentes. Thomas (1980) descreveu a aplicação de um pós-processamento em dados classificados baseado em uma função de proximidade. Também Townsend (1986) desenvolveu um operador lógico para suavizar a imagem classificada, mas comenta que pode existir perda de informação da imagem, o que não é desejável. Bischof, Schneider e Pinz (1992) aplicaram um algoritmo de redes neurais artificiais para suavizar ruídos de uma imagem Landsat classificada digitalmente também por redes neurais. INPE (2006) utiliza valores de peso e limiar, definidos pelo usuário, para alterar o valor de um ponto central, em uma janela de 3 x 3 pixels, substituindo-o pelo de maior frequência na vizinhança. “Quanto menor os valores de peso e limiar, maior número de substituições serão realizadas”.

Os autores citados anteriormente aplicam a uniformização de temas em toda a imagem, pois os algoritmos são compostos de uma janela de $n \times n$ pixels escaneando toda a imagem. Isso altera não só os pixels desejáveis (ruído), mas também os que já estariam corretos. Como alternativa a esse processo, Chan, Ho e Nikolova (2004) desenvolveram um suavizador de ruídos de imagem que, em uma primeira fase, identifica pixels discrepantes de sua vizinhança (possivelmente ruídos) e, posteriormente, restaura a imagem somente nesses pixels selecionados. Anterior a

isso, Davis e Peet (1977) desenvolveram um método simples para suavizar o mapa temático especificando um tamanho mínimo de área para cada tema, em que todo polígono do mapa seria igual ou maior que o tamanho estipulado.

A técnica de uniformização de temas, embora seja aplicada com o intuito de melhorar o mapa temático no aspecto visual, na verdade altera o resultado apresentado pela classificação digital. Com isso, uma análise de precisão de mapeamento vem a ser necessária para avaliar a intensidade dessa uniformização.

2.4 PRECISÃO DE MAPEAMENTO

A pulverização de classes temáticas tem certa influência na precisão do mapeamento feito, e isso não é assunto recente. Moreira, Chen e Lima (1982) testaram diferentes valores de parâmetros (limiar e peso) para uniformização de temas após uma classificação digital híbrida combinando Média-K com Maxver. Comparando os resultados obtidos com aqueles sem esse processamento, os valores foram estatisticamente significativos ao nível de 5%, concluindo que a uniformização de temas contribui para melhorar a precisão de mapeamento.

Congalton (1991) e Janssen e Van Der Wel (1994) apresentam uma ampla revisão sobre técnicas disponíveis para se fazer a avaliação da precisão de mapeamento. Uma das informações mais utilizadas para se avaliar essa precisão e o resultado de classificação de imagens é a análise da “matriz de erro”, que é considerada adequada para um número pequeno de classes temáticas (CAMPAGNOLO; CAETANO, 2002). É apresentada por uma tabela de dupla entrada onde, de um lado, representam-se as classes observadas na realidade, e de outro, as classes mapeadas pelo classificador. Os valores da diagonal principal da tabela apontam as observações corretamente classificadas (STORY; CONGALTON, 1986).

Dentre os procedimentos usados para medir a precisão da classificação de imagens a partir de uma matriz de erro, existem 3 índices que são amplamente utilizados: a Exatidão Global, o Kappa e o Tau.

O Índice de Exatidão Global (EG) se limita a utilizar a quantidade de pixels corretamente classificados, e foi calculado pela equação:

$$EG = \frac{\sum_{i=1}^M x_{ii}}{N}$$

onde x_{ii} = elementos da diagonal principal da matriz de erro; N = número total de pixels da imagem; M = número de classes temáticas (PONZONI; REZENDE, 2002).

O Índice Kappa (K) é considerado uma medida mais apropriada de exatidão por utilizar todos os elementos da matriz de erro, e não somente a diagonal principal (CONGALTON; MEAD, 1983, apud MACHADO, 2002; GONG; HOWART, 1990). É calculado pela equação:

$$K = \frac{\frac{\sum_{i=1}^M x_{ii}}{N} - \frac{\sum_{i=1}^M (x_{i+} * x_{+i})}{N^2}}{1 - \frac{\sum_{i=1}^M (x_{i+} * x_{+i})}{N^2}}$$

onde x_{ii} = elementos da diagonal principal da matriz de erro; x_{i+} e x_{+i} = somatória na linha e coluna i da matriz de erro, respectivamente; N = número total de pixels da imagem; M = número de classes temáticas.

O Índice Tau (T), sugerido por Ma e Redmond (1995), é calculado pela equação:

$$T = \frac{\frac{\sum_{i=1}^M x_{ii}}{N} - \frac{1}{M}}{1 - \frac{1}{M}}$$

onde x_{ii} = elementos da diagonal principal da matriz de erro; N = número total de pixels da imagem; M = número de classes temáticas.

Brites (1996) utilizou esses 3 índices para avaliar a classificação de imagens digitais orbitais de regiões densamente vegetadas. Concluiu que o índice EG

superestima a avaliação da exatidão e que o índice K subestima-o, tendo o índice T um comportamento sempre intermediário, sendo este o índice ideal para uma correta consideração sobre a exatidão de classificação de imagens. Esse resultado também foi observado por Ponzoni e Rezende (2002).

O coeficiente Tau foi utilizado por Braga e Gherardi (2001) para estimar a exatidão da classificação de imagens de alta resolução no mapeamento de recifes costeiros. Mas apesar da observação anterior de Brites, encontra-se na literatura mais aplicações do índice Kappa do que do índice Tau. Carrilho, Soares e Valério Filho (1996) calcularam os valores de Kappa para avaliar o monitoramento de mudanças na cobertura do solo de cerrado. South, Qi e Lusch (2004) avaliaram a precisão de classificação de 5 classificadores digitais com o índice Kappa, entre os sistemas agrícolas tradicional e de plantio direto. Braga et al. (2006) compararam a eficiência de classificadores supervisionados e não-supervisionados através da geração de matrizes de erro e cálculo do índice Kapa, para mapeamento do uso do solo no município de Serra do Salitre, em Minas Gerais.

Assim, nota-se que a precisão de mapeamento é, de certa forma, influenciada por alguns fatores, como a escolha do índice de avaliação a ser utilizado, a experiência do usuário da metodologia, dentre outros, o que resulta na necessidade de um estudo mais detalhado.

3. ARTIGO A – DESEMPENHO DE REDES NEURAIS NA QUANTIFICAÇÃO DE PLANTAS DANINHAS EM CULTURA DE SOJA: UM ESTUDO PRELIMINAR

3.1. RESUMO E ABSTRACT

RESUMO: A evolução da tecnologia aplicada a agricultura coloca os setores da pesquisa agrícola perante um novo paradigma: o da “Agricultura de Precisão”, levando a tomadas de decisões mais pontuais e mais precisas. Nesse contexto, utilizou-se uma foto aérea de altíssima resolução (1 cm²), obtida por aeromodelo, para o mapeamento da infestação de plantas invasoras em cultura de soja, avaliando-se a eficiência da classificação digital de imagens realizada por redes neurais, em comparação com os classificadores comumente utilizados. A foto foi classificada de forma manual e digital, segundo as classes temáticas “cultura”, “invasora” e “entrelinha”. A classificação digital foi feita com o classificador por Redes Neurais do software AGGeolImagem® (EMBRAPA, 2004) e pelos classificadores Maxver, Maxver-ICM, Distância Euclidiana e Bhattacharya do software SPRING® v.4.1 (INPE, 2004). Cada mapa gerado digitalmente foi sobreposto ao gerado manualmente (verdade terrestre), e dessas intersecções foram calculadas as porcentagens de acerto das classificações. O melhor percentual de acerto foi conseguido com o classificador por Redes Neurais.

ABSTRACT: The evolution of the technology applied to the agriculture places the sectors of the agricultural research facing a new paradigm: the "Precision Farming", taking decisions more punctual and more accurate. In this context, an aerial photography was used, taking on low height, for mapping of the infestation of weeds in soybean crop; it evaluated the efficiency of the image digital classification carried by neural nets, in comparison with the classifiers usually used. The photo was classified of manual and digital manner, according to thematic classes "crop", "weed" and "shadow" (between row). The digital classification was carried with the classifier Neural Nets from software AGGeolImagem (EMBRAPA, 2004) and the classifiers Maxver, Maxver-ICM, Euclidean Distance and Bhattacharya from software SPRING® v.2.1 (INPE, 2004). Each generated digital map was overlapped to manual map

(ground truth data), and of these crossings had been calculated the percentages of accuracy of the classifiers. The best one was obtained with the classifier Neural Nets.

3.2. INTRODUÇÃO

A história registrou as técnicas primitivas de cultivo, e em sua evolução, paralelo à evolução tecnológica mundial, é possível, hoje, visualizar uma terra amplamente mecanizada, com aplicação de conceitos conservacionistas, visando à produção necessária para o alimento da humanidade, sem desfazer da manutenção do meio ambiente e de seus recursos naturais.

Essa evolução da tecnologia aplicada à agricultura coloca os setores da pesquisa agrícola, atualmente, perante um novo paradigma: o da “Agricultura de Precisão”. Decisões são tomadas de maneira mais pontual, mais precisa, nos campos agrícolas. O termo “Agricultura de Precisão”, segundo Shiratsuchi (2001), é uma nova concepção de agricultura que leva em consideração informações sobre a variabilidade espacial da propriedade agrícola em relação às diversas variáveis ambientais que afetam a produção, como a fertilidade, umidade, pragas e doenças, a fim de otimizar o uso de insumos através de uma aplicação pontual.

Dentre essas temáticas, o estudo da infestação das culturas agrícolas por plantas daninhas tem sua importância por acarretar significativa redução nos rendimentos de produção agrícola. Gazziero et al. (1998) apontavam perdas da ordem de 13,5% na produção de soja, o que equivale a 15,75 ton/ano da produção mundial do grão.

Por outro lado, vários trabalhos apontam a grande economia de insumos que ocorre com a adoção de práticas da Agricultura de Precisão, e isso também é evidente na aplicação localizada de herbicida oriundo do mapeamento da infestação de plantas daninhas. Christensen, Walter e Heisel (1999) apontam que a economia com herbicidas pode ser de 40% em trigo, 72% em soja e de 51 a 94% em milho.

As técnicas de mapeamento de plantas daninhas se dividem, segundo Lutman e Perry (1999), em detecção manual, onde as áreas infestadas são percorridas e mapeadas “in locu” (SHIRATSUCHI, 2001; SALVADOR; ANTUNIASSI, 2006), e a detecção automática, onde são utilizadas imagens aéreas ou orbitais para se localizar e mapear as infestações (TIAN, 2002).

Dentre os meios possíveis de se obter imagens para mapear o meio ambiente, já estão consagradas as fotografias aéreas obtidas por aviões específicos para tal finalidade, e as imagens digitais obtidas por um grande número de satélites em órbita da Terra. Considerando a resolução espacial como um fator de fundamental importância no mapeamento detalhado de qualquer feição da paisagem que exija grande definição visual de áreas pequenas, como na infestação de plantas daninhas em uma lavoura, foram criados mais recentemente, os VANT's – Veículos Aéreos Não-Tripulados (do inglês UAV's – Unmanned Aerial Vehicle), equipados basicamente com câmeras fotográficas digitais, filmadoras e GPS, na tentativa de se obterem imagens do meio ambiente com altíssima resolução espacial. Segundo Eisenbeiss (2004), o termo VANT's abrange todo veículo aéreo sem nenhuma pessoa a bordo, mas com capacidade de ser controlado.

No tocante às pesquisas agronômicas, cerne deste estudo, a tecnologia dos VANT's está sendo aplicada em várias metodologias de trabalho. O College of Agriculture da Universidade do Kentucky está detectando nível de estresse nutricional em milho e trigo, com fotos tomadas ao longo da safra (STOMBAUGH; MUELLER, s.d.). Eisenbeiss e Vogler (2006) estão gerando modelos de elevação com dados de VANT e estudando a influência da inclinação do terreno sobre a dispersão de pólen na cultura do milho. Herwitz et al. (2004) conduziram um levantamento em 1500 hectares de café no Havaí para mapear plantas daninhas e para revelar áreas com anomalias de irrigação e de fertilização.

Jorge et al. (1999) e Jorge (2001) apresentaram os primeiros resultados do processamento de imagens com a aplicação de um VANT para estudo agrícola no Brasil. Em Jorge e Trindade Jr. (2002) e Jorge (2003) são apresentadas as aeronaves utilizadas neste trabalho, bem como alguns resultados nas diferentes culturas.

Qualquer fotografia aérea obtida para fins de levantamento do meio em estudo é analisada visualmente, por intermédio da experiência de um fotointérprete, ou digitalmente, por algoritmos computacionais que processam essas imagens para realçar os elementos da paisagem que, posteriormente, podem ser passíveis de nova análise visual. Vários classificadores digitais já consagrados pela pesquisa, como Maxver, Bhattacharya ou Distância Euclidiana, produzem mapas temáticos das mais variadas regiões do planeta. Com a constante evolução tecnológica, novos algoritmos surgem na tentativa de serem mais precisos que seus

antecessores. Nesse contexto, as chamadas Redes Neurais Artificiais vem se tornando hoje uma excelente opção na elaboração de mapeamentos temáticos, mostrando-se um classificador estatístico poderoso (ANDRADE; BOTELHO; CENTENO, 2003).

Dependendo do processo utilizado, os classificadores digitais são divididos em dois grupos: classificadores “pixel a pixel”, quando utilizam apenas o valor espectral do pixel como dado para a classificação, e classificadores por regiões, quando, além do valor do pixel, relacionam este aos valores dos pixels espacialmente vizinhos através de um processo chamado segmentação (INPE, 2006). Segundo Moreira (2001), a segmentação tem por objetivo compartimentar a imagem em regiões homogêneas conforme a textura, tom de cinza e contraste da imagem.

Dependendo do tipo de treinamento do classificador, ou seja, do tipo de aquisição de amostras da imagem para cada classe temática, este pode ser: supervisionado (o intérprete conhece a área, identifica as classes na área e pode controlar a aquisição de amostras para treinamento) ou não-supervisionado (o intérprete desconhece a área, o software reconhece classes distintas e o usuário não controla a aquisição de amostras) (INPE, 2006).

Dentre os classificadores utilizados neste trabalho, o Maxver, o Maxver-ICM e a Distância Euclidiana são do tipo “pixel a pixel” com treinamento supervisionado e o Bhattacharya é um classificador por regiões também supervisionado.

Com relação aos classificadores “pixel a pixel”, o classificador Maxver é o mais comumente utilizado dentre os classificadores existentes. Ele pondera as distâncias entre as médias dos valores digitais dos pixels de cada classe temática. As amostras de treinamento configuram o diagrama de dispersão das classes e suas freqüências de distribuição, considerando que cada classe se comporta como uma distribuição normal. Quanto ao Maxver-ICM (Iterated Conditional Modes), a imagem é classificada como no Maxver e, posteriormente, são consideradas as classes atribuídas aos pixels vizinhos (chamada de informação contextual). No método por Distância Euclidiana, as amostras de treinamento definem agrupamentos de pixels (classes) e o classificador compara a distância de cada pixel da imagem à média de cada agrupamento, associando-o ao agrupamento que apresentar a menor distância (INPE, 2006).

Quanto aos classificadores por regiões, o método de Bhattacharya utiliza as regiões homogêneas formadas no processo de segmentação como amostras de treinamento, procurando agrupá-las a partir das medidas de similaridade entre elas (INPE, 2006).

As redes neurais são uma tecnologia computacional associada à Inteligência Artificial que tenta viabilizar a mesma funcionalidade do cérebro humano e seus neurônios. Essas redes são especialmente úteis em situações onde não existe uma solução algorítmica, ou seja, os dados não obedecem a uma seqüência lógica para solucionar o problema, como é o caso da área de reconhecimento de padrões (WILHELM; LOPES; DOROW, 2003).

A cada neurônio é ponderado um peso e a adaptação/otimização desses pesos pode ser implementada por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado. Dentre vários tipos existentes, os mais utilizados na literatura são os métodos de correção do erro, tendo como principal exemplo de modelo deste tipo o Back-Propagation (JORGE, 2001).

Os neurônios armazenam as informações em unidades baseadas em protótipos ou em unidades do tipo Perceptron. Perceptron é a base de diversos tipos de redes neurais artificiais com aprendizado supervisionado utilizando uma adaptação por correção de erros. O modelo do Perceptron de múltiplas camadas (MLP – Multi-Layer Perceptron) tornou-se muito conhecido e aplicado, sendo na maior parte das vezes associado à regra de aprendizado Back-Propagation (JORGE, 2001).

Para a construção de uma rede neural do tipo MLP – Multi-Layer Perceptron, devem ser definidos os elementos que alimentarão a rede (camada de entrada) e os elementos que fornecerão os resultados (camada de saída), sendo que esses elementos devem ter conexões (neurônios) com camadas intermediárias (camadas ocultas) (WILHELM; LOPES; DOROW, 2003).

As redes neurais artificiais têm sido aplicadas em vários estudos agrônômicos com sucesso. O estudo de plantas daninhas, como parte dos estudos agrônômicos, também é alvo do uso de redes neurais artificiais para sua discriminação no campo. Burks et al. (2005) avaliaram diferentes modelos de redes neurais para discriminar diferentes espécies de plantas daninhas. Aitkenhead et al. (2003) discriminaram plantas daninhas entre mudas de cenoura, assim como Kavdir (2004) com plantas de girassol. Yang et al. (2003) também mapearam plantas daninhas em cultura de milho para gerar um mapa de aplicação pontual de herbicidas.

Sendo assim, acreditando-se ser possível quantificar o nível de infestação de plantas daninhas de uma lavoura de soja através de imagens aéreas de baixa altura, o presente trabalho objetiva avaliar a eficiência da classificação digital de imagens realizada por redes neurais do tipo MLP com algoritmo Backpropagation para essa quantificação, em comparação com os classificadores Maxver, Maxver-ICM, Distância Euclidiana e Bhattacharya, comumente utilizados.

3.3. MATERIAL E MÉTODOS

A área de estudo faz parte da Fazenda Campo Bom, situada entre os municípios vizinhos de Chapadão do Sul – MS e Chapadão do Céu – GO, cujos pontos geográficos extremos são as Latitudes $18^{\circ}29'25,251''S$ e $18^{\circ}47'10,607''S$ e as Longitudes $52^{\circ}49'23,857''W$ e $52^{\circ}32'42,390''W$.

Essa fazenda foi a primeira no Brasil a implantar os conceitos de Agricultura de Precisão. Tem, atualmente, como principal atividade, o plantio do binômio soja-trigo, e, em menor proporção, algumas áreas de milho, feijão e girassol, tudo em sistema de plantio direto.

Fotografias aéreas digitais da propriedade foram obtidas sobre a cultura de soja em fase de pré-florescimento, safra 2002/2003, a partir de um VANT do tipo aeromodelo pertencente a EMBRAPA Instrumentação Agropecuária – Empresa Brasileira de Pesquisa Agropecuária/Centro Nacional de Pesquisa e Desenvolvimento em Instrumentação Agropecuária, localizado em São Carlos-SP, em vôo de baixa altura (cerca de 100m), com resolução de 1 cm^2 .

Os softwares utilizados para a análise das imagens foram:

- AGGeolImagem (plataforma Windows), da EMBRAPA Instrumentação Agropecuária – Empresa Brasileira de Pesquisa Agropecuária/Centro Nacional de Pesquisa e Desenvolvimento em Instrumentação Agropecuária, de São Carlos-SP; trabalha com tecnologia de redes neurais artificiais tipo MLP com algoritmo de “backpropagation”, proporcionando rapidez no processamento digital das imagens (EMBRAPA, 2004).

- SPRING – Sistema de Processamento de Informação Geográfica, v.3.6.03 (plataforma Windows), desenvolvido pelo INPE – Instituto Nacional de Pesquisas Espaciais, em São José dos Campos-SP, para a área de geoprocessamento (INPE, 2004).

No desenvolvimento metodológico foi escolhida uma foto representativa de toda a área estudada, que continha espécies daninhas de grande porte com distribuição pontual e espécies de pequeno porte com distribuição esparsa, sendo importada para o software SPRING.

As cores da foto que um equipamento fotográfico registra são combinações das cores vermelho (R), verde (G) e azul (B) refletidas em diferentes intensidades pelos componentes da paisagem. Na formação da imagem digital, essas intensidades captadas pelo equipamento podem ter suas cores modificadas. Para obter a cor natural da paisagem, são atribuídas às componentes R, G e B captadas, as mesmas cores R, G e B, respectivamente, podendo-se produzir cinco outras combinações diferentes de cor da paisagem se a atribuição das cores forem mudadas (CROSTA, 1992).

Foi, então, analisada visualmente as 6 combinações possíveis de composição colorida RGB para definir a que melhor destacasse a presença de plantas invasoras na cultura.

Essa imagem* foi classificada de forma manual e digital, segundo as classes temáticas “cultura”, “invasora” e “entrelinha” (sombra entre a linha de plantio). Ambas as técnicas de classificação foram feitas através da separabilidade visual, baseada em diferenças de tonalidade, cor, textura e forma (WOLF, 1974).

Na classificação manual, o mapa temático gerado foi considerado como a “verdade terrestre”, e serviu como base comparativa aos métodos digitais, sendo obtido através do traçado do contorno dos temas sobre a própria imagem importada para o sistema.

A classificação digital foi feita com o classificador por Redes Neurais do software AGGeolImage, cujo desempenho foi avaliado pela comparação com os seguintes classificadores do software SPRING: Maxver, Maxver-ICM, Distância Euclidiana e Bhattacharya. Nenhum tipo de processamento digital pré-classificação foi realizado.

Para as classificações digitais dos algoritmos do SPRING foram coletadas 248 amostras de segmentos da imagem, sendo 87 de cultura, 118 de entrelinha e 43 de invasora. A variação da quantidade em cada tema deveu-se ao formato, tamanho e quantidade das feições na imagem. O grande número de

* As fotos, quando inseridas no sistema digital, passaram a ser denominadas “imagens”.

amostras foi para aumentar a precisão na análise estatística dos algoritmos. As amostras foram obtidas em formato retangular e com textura o mais uniforme possível; todas foram usadas em todos os classificadores.

Por se tratar de softwares com linguagens não compatíveis, não foi possível utilizar o arquivo com as amostras coletadas para o SPRING para classificação por redes neurais. Logo, as amostras tiveram que ser adquiridas novamente; porém, não tendo como assumir controle total da aquisição de amostras idênticas às anteriores, procurou-se visualizar o contorno delas e adquirir as novas amostras o mais semelhante às primeiras.

Cada mapa gerado digitalmente foi sobreposto à verdade terrestre, e desses cruzamentos foram obtidas as matrizes de erro de classificação e calculadas as porcentagens de acerto das classificações, conforme as equações de Mendonça (1980), abordadas na metodologia de Donzeli et al. (1983) e adaptadas em Pereira Neto e Valério Filho (1993):

- porcentagem de acerto de classificação da classe i:

$$PA_i = \left(\frac{ACC_i}{AR_i} \right) * 100$$

- porcentagem total de acerto:

$$PAT = \sum_{i=1}^N (w_i * PA_i) * 100 = \sum_{i=1}^N \left(\frac{ACC_i}{AT} \right) * 100$$

- fator de ponderação da classe i:

$$w_i = \frac{AR_i}{AT}$$

em que:

AT – área total, cm²;

AR – área real (verdade terrestre) , cm²;

ACC – área corretamente classificada, cm²;

N – número de classes temáticas.

Assim, dessa análise de precisão de mapeamento, o cruzamento com a maior porcentagem total de acerto foi considerado como sendo o produto do melhor classificador testado, pois obteve a maior relação de igualdade com a verdade terrestre.

3.4. RESULTADOS E DISCUSSÃO

Na análise das composições coloridas, a melhor separabilidade visual entre os temas “entrelinha” e “cultura” ocorreu com a cor natural. Para o tema “planta invasora” a melhor discriminação foi obtida com a atribuição da cor vermelha à componente verde da paisagem; isto concorda com o exposto por Crosta (1992), que afirma que o olho humano tem maior sensibilidade à variações de tonalidades de vermelho do que de verde. Essas duas composições (Figura 3.1) foram, então, utilizadas para todas as classificações. Na figura 3.1a pode ser visto linhas de plantio de soja intercaladas com linhas mais escuras de sombra (entrelinha); a mancha grande a esquerda e as pequenas manchas espalhadas pela imagem são plantas invasoras.




Figura 3.1 – Composições coloridas utilizadas nas classificações: (a) cor natural, (b) cores R e G atribuídas às componentes G e R da paisagem, respectivamente.

Após a geração dos mapas temáticos através da classificação digital, verificou-se a necessidade de que esses mapas fossem tratados com algoritmo de “uniformização de temas” para eliminação de polígonos muito pequenos, exceto o resultante do classificador Bhattacharya, por não conter tais polígonos (Figura 3.2.a,b,c,d,e).

A Figura 3.2.f mostra o mapa gerado por classificação manual

(verdade terrestre), no qual foram reconhecidos e mapeados 100.701 pixels da classe invasora, 1.052.378 de cultura e 312.611 de entrelinha; com este, foi feita a intersecção com cada mapa gerado por classificação digital, obtendo as matrizes de erro de classificação constantes no Apêndice A.




Figura 3.2 – Mapas temáticos da área, produzidos pelos classificadores digitais (a) Bhattacharya, (b) Distância Euclidiana, (c) Maxver, (d) Maxver-ICM, (e) Redes Neurais, e pela classificação manual (f) verdade terrestre. “Cultura” em amarelo; “invasora” em vermelho e “entrelinha” em marrom.

A Tabela 3.1 mostra o resultado da intersecção das áreas da verdade terrestre com as áreas da classificação digital de cada classificador,

resultando nas áreas corretamente classificadas. Estas áreas corretamente classificadas representam os pixels cujas classes coincidiram em cada intersecção, ou seja, um pixel x classificado como cultura na verdade terrestre e também no classificador digital; correspondem aos valores da diagonal principal de cada matriz de erro do Apêndice A. Cada imagem usada tem tamanho de 1.030 linhas por 1.423 colunas, totalizando 1.465.690 pixels. Como cada pixel tem 1cm de resolução, as dimensões reais da imagem são de 10,30m x 14,23m, resultando em uma área de 146,569 m².

Tabela 3.1 – Resultado das sobreposições entre os mapas gerados (unidades em cm², equivalente ao tamanho do pixel da imagem).

CLASSIFICAÇÃO BHATTACHARYA		
temas	área corretamente classificada	classificação digital
invasora	71.314	90.447
cultura	843.772	937.979
entrelinha	244.802	437.264
CLASSIFICAÇÃO DIST. EUCLIDIANA		
temas	área corretamente classificada	classificação digital
invasora	68.372	98.491
cultura	731.579	785.123
entrelinha	288.259	582.076
CLASSIFICAÇÃO MAXVER		
temas	área corretamente classificada	classificação digital
invasora	70.042	95.538
cultura	763.643	819.452
entrelinha	284.877	550.700
CLASSIFICAÇÃO MAXVER-ICM		
temas	área corretamente classificada	classificação digital
invasora	70.148	95.741
cultura	764.479	820.286
entrelinha	284.762	549.663
CLASSIFICAÇÃO REDES NEURAIAS		
temas	área corretamente classificada	classificação digital
invasora	66.112	90.033
cultura	874.870	989.745
entrelinha	229.262	385.912

Os cálculos das Porcentagens de Acertos Totais (PAT) resultaram nos seguintes valores (em ordem decrescente): Redes Neurais = 79,84%,

Bhattacharya = 79,14%, Maxver-ICM = 76,37%, Maxver = 76,31%, Distância Euclidiana = 74,25%. Burks et al. (2005) também obtiveram melhor classificação com o mesmo tipo de rede neural utilizada neste trabalho, ao comparar o desempenho de três tipos diferentes de redes.

Numericamente, a classificação por Redes Neurais resultou ser a melhor; porém, estatisticamente, todos os valores ficaram muito próximos entre si. Assim, procedeu-se a uma análise estatística para avaliar se houve diferença significativa entre os valores de PAT, através do Teste de Hipótese relativo a diferenças entre duas proporções, com nível de significância de 5%.

Esse teste foi aplicado, primeiramente, para comparar Redes Neurais com Bhattacharya, por terem a menor diferença entre os valores de PAT. Assim, se essa diferença for estatisticamente significativa, as demais comparações também o serão. O teste resultou em um valor “z calculado” igual a 14,8416, contra o “z tabelado” de 1,96, sendo rejeitada a hipótese de igualdade entre essas duas proporções; por conseguinte, todas as classificações feitas foram estatisticamente diferentes, mesmo sendo numericamente semelhantes.

A exceção do Bhattacharya, todos os classificadores digitais resultaram em uma pulverização de polígonos; isso pode incorrer em erro na intersecção com a verdade terrestre, pois aumenta a possibilidade de um determinado pixel x de uma classe y da verdade terrestre não coincidir com a mesma classe no classificador digital. Aparentemente, se essa pulverização for diminuída, o resultado dos classificadores poderá ficar ainda melhor.

3.5. CONCLUSÕES

Imagem aérea de baixa altura obtida por Veículo Aéreo Não-Tripulado mostrou ser um material preciso para quantificar o nível de infestação de plantas daninhas de uma lavoura de soja.

O classificador por Redes Neurais foi o mais eficiente dentre os classificadores estudados.

4. ARTIGO B: MAPEAMENTO DE FALHAS DE PLANTIO EM LAVOURAS DE CANA-DE-AÇÚCAR ATRAVÉS DE CLASSIFICAÇÃO POR REDES NEURAIAS ARTIFICIAIS

4.1. RESUMO E ABSTRACT

RESUMO: A tecnologia aplicada à agricultura procura criar equipamentos e métodos de avaliação e análise do meio para a tomada de decisão ser mais rápida e precisa. O mapeamento de feições da paisagem agrícola através de fotos aéreas é um desses métodos, auxiliado pelas técnicas de classificação digital de imagens. Foram obtidas fotos aéreas por aeromodelo de controle remoto em culturas de cana-de-açúcar, na fase inicial de crescimento, para avaliar falhas de plantio através de processamento de imagens e do classificador por Redes Neurais. A partir do processamento de imagens foi possível a identificação e a quantificação das falhas. Também foram identificadas áreas com alteração na lavoura, indicativo de anormalidades, como *Migdolus sp*, nematóide, etc. As anormalidades foram classificadas e mapeadas. O desempenho das Redes Neurais foi satisfatório em todas as situações analisadas.

ABSTRACT: The technology applied to agriculture tries to create equipments and methods of assessment and analyses of the environment for a quicker and more precise decision making. The mapping of agriculture fields through air photos is one of these methods, being helped by digital image classification. Air photos were obtained through remote control aeromodel in cultures like sugarcane, in the initial growing stage, in order to evaluate failures of farming through image processing and the Neural Network classifier. From the image processing, it was possible the identification and the quantification of the failures of farming in the sugarcane field. Besides the failures, areas with alteration in the fields were identified, indicating some abnormality, like *Migdolus sp*, nematodes, etc. These abnormalities were, then, classified and mapped. The Neural Networks performance was satisfactory in all of the analysed situation.

4.2. INTRODUÇÃO

A produção de alimentos para uma população mundial sempre crescente é uma preocupação constante. A tecnologia aplicada à agricultura procura inovar com a criação de equipamentos e métodos de avaliação e análise do meio para a tomada de decisão ser mais rápida e precisa, o que conceitua, em parte, a prática da Agricultura de Precisão.

A Agricultura de Precisão, segundo Shiratsuchi (2001), é uma nova concepção de agricultura que leva em consideração informações sobre a variabilidade espacial da propriedade agrícola em relação às diversas variáveis ambientais que afetam a produção, como fertilidade, umidade, pragas e doenças, a fim de otimizar o uso de insumos através de uma aplicação pontual.

Dentre essas temáticas, o estudo do mapeamento de falhas na cultura da cana-de-açúcar tem sua importância por acarretar redução na produção agrícola. O Brasil é o maior produtor mundial de cana-de-açúcar e exportador de açúcar e álcool, gerando mais de 2 bilhões de dólares/ano para a economia brasileira (INPE, s.d.).

Dentre os meios possíveis de se obter imagens para mapear o meio ambiente, já estão consagradas as fotografias aéreas obtidas por aviões específicos para tal finalidade, e as imagens digitais obtidas por um grande número de satélites em órbita da Terra. A resolução espacial é fundamental no mapeamento detalhado de qualquer feição da paisagem que exija grande definição visual de áreas pequenas, como no mapeamento de falhas em uma lavoura. Na tentativa de melhorar essa resolução foram criados mais recentemente, os VANT's – Veículos Aéreos Não-Tripulados (do inglês UAV's – Unmanned Aerial Vehicle), embarcados basicamente com câmeras fotográficas digitais, filmadoras e GPS, para obtenção de imagens do meio ambiente com altíssima resolução espacial. Segundo Eisenbeiss (2004), o termo VANT's abrange todo veículo aéreo sem nenhuma pessoa a bordo, mas com capacidade de ser controlado.

Jorge et al. (1999) e Jorge (2001) apresentaram os primeiros resultados do processamento de imagens com a aplicação de um VANT para estudo agrícola no Brasil. Em Jorge e Trindade Jr. (2002) e Jorge (2003) são apresentadas as aeronaves utilizadas neste trabalho, bem como alguns resultados nas diferentes culturas.

No tocante às pesquisas agronômicas, cerne deste estudo, a tecnologia dos VANT's está sendo aplicada em várias metodologias de trabalho. Na Universidade de Nottingham estão reunindo informações fotográficas de várias safras de trigo para prever com exatidão os estágios de crescimento da cultura (UNIVERSIDADE DE NOTTINGHAM, 2005). Herwitz et al. (2004) conduziram um levantamento em 1500 hectares de café no Havaí para mapear plantas daninhas e para revelar áreas com anomalias de irrigação e de fertilização. Vinhedos do Estado da Califórnia são monitorados em tempo real, através de sensor infravermelho termal, mapeando a temperatura da área, para aplicar medidas de proteção em caso da ameaça de ocorrência de frio (UAVCOLABORATIVE, s.d.).

Qualquer fotografia aérea obtida para fins de levantamento do meio em estudo é analisada visualmente, por intermédio da experiência de um fotointérprete, ou digitalmente, por algoritmos computacionais que processam essas imagens para realçar os elementos da paisagem que, posteriormente, podem ser passíveis de nova análise visual. Com a constante evolução tecnológica, novos algoritmos surgem na tentativa de serem mais precisos que seus antecessores. Nesse contexto, as chamadas Redes Neurais Artificiais vem se tornando hoje uma excelente opção na elaboração de mapeamentos temáticos, mostrando-se um classificador estatístico eficiente (ANDRADE; BOTELHO; CENTENO, 2003).

A Rede Neural Artificial é uma tecnologia computacional associada à Inteligência Artificial que tenta viabilizar a mesma funcionalidade do cérebro humano e seus neurônios. Essas redes são especialmente úteis em situações onde não existe uma solução algorítmica, ou seja, os dados não obedecem a uma seqüência lógica para solucionar o problema, como é o caso da área de reconhecimento de padrões (WILHELM; LOPES; DOROW, 2003).

A cada neurônio é ponderado um peso e a adaptação/otimização desses pesos pode ser implementada por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado. Dentre vários tipos existentes, os mais utilizados na literatura são os métodos de correção do erro, tendo como principal exemplo o modelo Back-Propagation (JORGE, 2001).

Os neurônios armazenam as informações em unidades baseadas em protótipos ou em unidades do tipo Perceptron. Perceptron é a base de diversos tipos de redes neurais artificiais com aprendizado supervisionado utilizando uma adaptação por correção de erros. O modelo do Perceptron de múltiplas camadas (MLP – Multi-

Layer Perceptron) tornou-se muito conhecido e aplicado, sendo na maior parte das vezes associado à regra de aprendizado Back-Propagation (JORGE, 2001).

Para a construção de uma rede neural do tipo MLP – Multi-Layer Perceptron, devem ser definidos os elementos que alimentarão a rede (camada de entrada) e os elementos que fornecerão os resultados (camada de saída), sendo que esses elementos devem ter conexões (neurônios) com camadas intermediárias (camadas ocultas) (WILHELM; LOPES; DOROW, 2003).

As redes neurais artificiais têm sido aplicadas em vários estudos agronômicos com sucesso. Dentre esses estudos, o mapeamento e estudo dos canaviais também é alvo do uso de redes neurais artificiais para sua discriminação no campo. Madeiro et al. (2006) desenvolveram um algoritmo baseado em redes neurais para calcular mais precisamente o ponto de maturação da cana. Dias (2004) mapeou a infecção de ferrugem na cana com fotos obtidas por aeromodelos. Fanglan et al. (2005) avaliaram as irregularidades na execução do corte da cana visando mais eficiência da colheitadeira. Gleriani (2005) desenvolveu uma nova metodologia de classificação digital por redes neurais através da observação de um pixel ao longo das fenofases da cultura, obtendo sua espectro-temporalidade.

Além das redes neurais, a literatura aponta também bons resultados obtidos na aplicação do algoritmo de segmentação Watershed como método auxiliar na classificação digital de imagens. Esse método baseia-se no conceito topográfico de represamento de bacia hidrográfica onde, através de um processo de inundação do local, determinam-se os pontos de transbordamento da área. Analogamente, a cada valor mínimo de pixel da imagem (nível “zero” de água), os valores de pixel vão sendo sucessivamente aumentados (inundação), e a área da vizinhança do pixel (o nível de água na bacia) vai aumentando. Em determinado instante, os valores dos pixels de uma bacia vão se tocar com os valores dos pixels de outra bacia (pontos de transbordamento), formando um segmento chamado “linha de watershed” (divisor de águas). Um esquema ilustrativo é mostrado na figura 4.1. (KARLSSON, 2003).

Komura, Kubo e Muramoto (2004) desenvolveram um método para delinear copas de árvores em floresta utilizando algoritmo Watershed sobre imagens de satélite de alta resolução e obtiveram excelente resultado na comparação com a inspeção visual em campo. Heirman et al (1997) descreveram um método de delineamento de objetos em imagens através da combinação de algoritmo watershed com redes neurais artificiais; utilizaram películas de raio X para mapear secções de

medula espinhal, obtendo bons resultados e sugerindo que esse método pode ser aplicado em outras situações de análise de imagens.

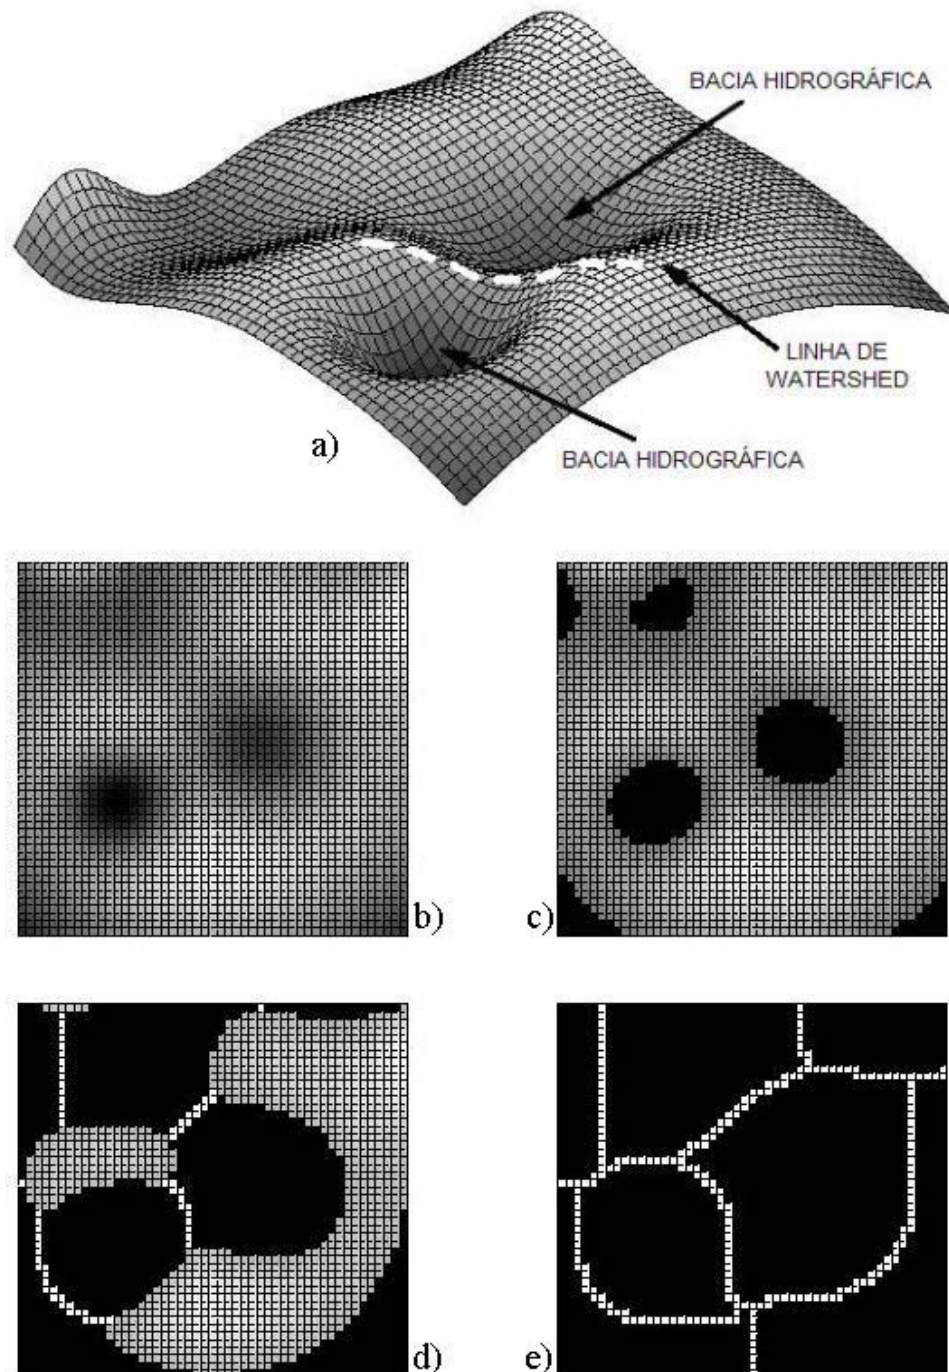


Figura 4.1 – Esquema demonstrando o processo watershed: (a) imagem tridimensional análoga à topografia; (b) imagem bidimensional; (c), (d), (e) aumento sucessivo do valor do pixel formando segmentos de contato entre as bacias, chamadas linhas de watershed.

Fonte: Karlsson (2003, p.17-18)

Nesse contexto, o presente trabalho visa utilizar o classificador por Redes Neurais e o algoritmo Watershed para mapear falhas de plantio em culturas de cana-de-açúcar na fase inicial de crescimento, a partir da análise de fotos aéreas obtidas por aeromodelo de controle remoto.

Esse tipo de pesquisa tem outras aplicações diretas no mapeando de diferentes padrões das lavouras como p.e. ocorrência de nematóides em reboleira, falhas de semeadora em culturas anuais, infestação de plantas daninhas, tamanho de copas de árvores, dentre outros.

4.3. MATERIAL E MÉTODOS

O método utilizado segue o fluxo apresentado na Figura 4.2.

A obtenção das imagens foi feita a partir de um aeromodelo da EMBRAPA Instrumentação Agropecuária – Empresa Brasileira de Pesquisa Agropecuária, Centro Nacional de Pesquisa e Desenvolvimento em Instrumentação Agropecuária, de São Carlos - SP, através do qual foram obtidas fotografias aéreas digitais da cultura de cana-de-açúcar na propriedade da Empresa Açúcar Guarani, no município de Olímpia – SP.

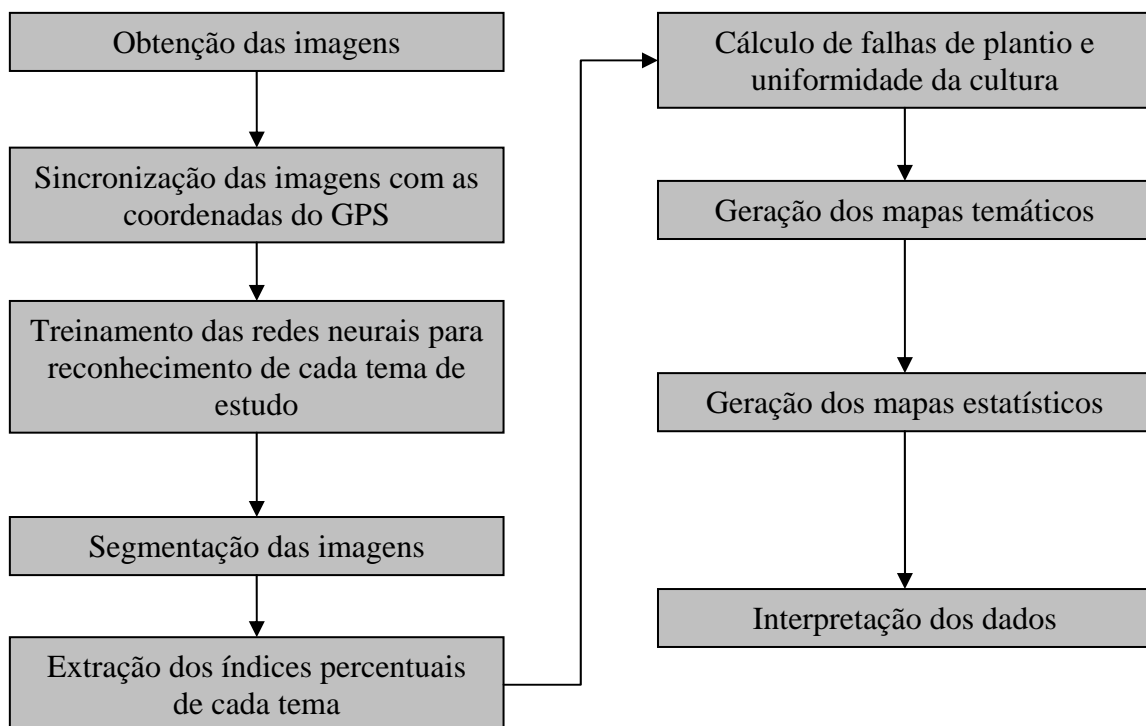


Figura 4.2 – Fluxo de operações de mapeamento

As fotos para estudo de falhas de plantio foram obtidas em vôo de baixa altitude (cerca de 100m), com pixel de resolução linear de 2 centímetros e, sobre estas fotos foi aplicado um software de classificação digital por redes neurais artificiais tipo MLP com algoritmo “back-propagation”. A rede utilizada foi composta de 4 camadas, contendo 3 neurônios na camada de entrada, 5 neurônios em cada camada intermediária e um neurônio para cada classe na camada de saída; o valor do parâmetro “momento” foi de 0,4 e do parâmetro “taxa de aprendizado” foi de 0,6. Neste mesmo software foi feita a integração das coordenadas do GPS com o arquivo da imagem.

Na Figura 4.3 são apresentados dois talhões da área onde foram feitos os mapeamentos, tirando-se uma foto em cada grade amostral de 100x100m.

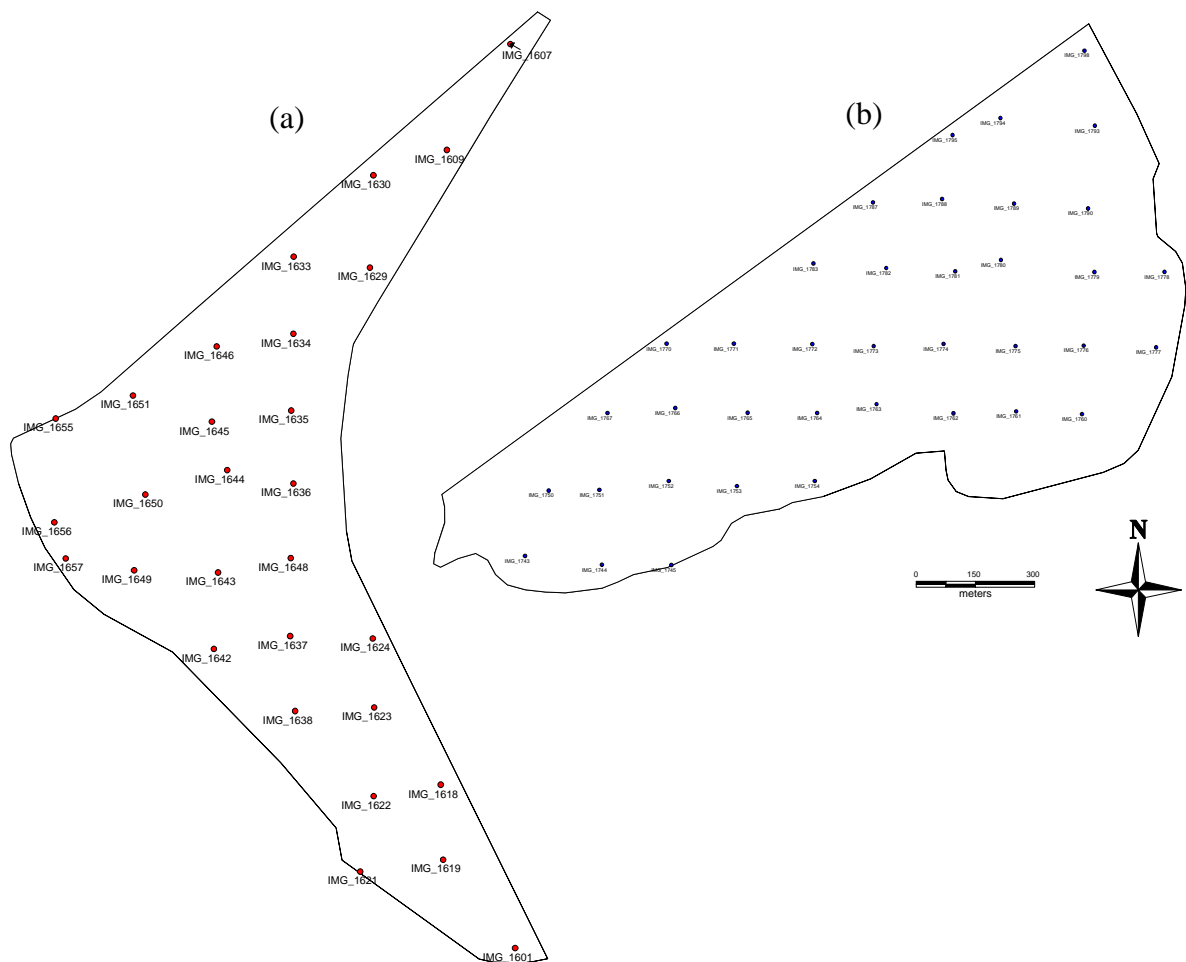


Figura 4.3 – Detalhe do talhão 2217 (a), de 90,38 ha, e do talhão 2107 (b), de 67,8 ha, com as respectivas localizações e identificação das fotos obtidas.

Uma vez obtidas as fotos, efetuou-se o processo de treinamento da rede neural para fazer a segmentação das imagens, tentando identificar automaticamente o que é solo, palha e cana. Depois disso, foram medidas as falhas, seguindo a metodologia de avaliação de falhas em cana-de-açúcar (STOLF, 1986), segundo a qual a ausência de cultura na linha de plantio com distância superior a 50 centímetros caracteriza uma falha.

Como Heirman et al (1997) utilizaram e sugeriram o uso de processamento watershed combinado com redes neurais em qualquer análise de imagens, foi feita a extração das falhas nas imagens através da técnica de Watershed após a segmentação por redes neurais (JORGE, 2001). Essa técnica identifica a falha através de critérios como direção da linha de plantio, comprimento e largura do espaço mapeado e vizinhança do polígono definido. Desta forma, foi extraído o percentual e os metros lineares de falha, gerando mapas dos talhões geomonitorados e do índice de falhas de plantio dos talhões.

Para outras observações na cana-de-açúcar o planejamento de vôo foi feito diretamente sobre áreas em que se sabia haver ocorrência de injúrias sobre a cultura. A altitude de vôo variou de 100 a 600m.

A determinação de áreas com alteração na lavoura indicavam alguma anormalidade na lavoura, como *Migdolus sp*, nematóide, etc. A visualização e quantificação dessas áreas foram feitas através do geomonitoramento das áreas de interesse, a partir das imagens obtidas, o que permitiu quantificar e apresentar os resultados em mapas, imagens georreferenciadas e relatórios comparativos entre os talhões.

Uma vez processadas as imagens, obtidos os índices de falhas, de cobertura do solo por cultura, palha e solo nú, foram elaborados os mapas temáticos fazendo-se a normalização dos dados pelos maiores valores, criando valores percentuais. Além dos mapas temáticos, os dados foram avaliados quanto a sua distribuição estatística normal para identificar, em cada tema, as áreas que realmente apresentavam alterações significativas. Isso gerou mapas estatísticos da distribuição normal do tema, das áreas com problemas e das áreas de oportunidades a serem exploradas. Para tanto, foram utilizados os conceitos de Controle Estatístico de Processos.

O processamento efetuado para os mapeamentos estatísticos tentam identificar áreas com variações especiais, que podem ser “oportunidades” ou

“problemas”, segundo o critério de Controle Estatístico de Processos aplicado à agricultura. Este critério fundamenta-se na correlação espacial entre os valores dos temas em estudo, onde áreas com variações especiais são consideradas como uma região de um talhão que apresenta valores acima (potencial) ou abaixo (problema) da média dos valores apresentados no mesmo talhão, resultando em um mapa de zonas homogêneas denominado “mapa de variações”.

De acordo com a teoria da variabilidade (DEMING, 1990), podem ser inferidos dois erros quando se pretende melhorar um determinado processo: tratar variação normal como se fosse variação especial, ocorrendo em um excesso de ajuste, e tratar variação especial como se fosse normal, ocorrendo em uma falta de ajuste. A partir desta teoria se materializa o conceito do Controle Estatístico de Processos que nada mais é que o conhecimento dos procedimentos visando a menor perda econômica advinda dos dois erros citados. Esta materialização do conceito em agricultura pode ser traduzida por: tratar uma zona de normalidade de produtividade apenas com um tratamento e de forma uniforme, e tratar zonas especiais conforme o diagnóstico específico (AGUIAR et al., 2004).

4.4. RESULTADOS E DISCUSSÃO

No talhão 2107 foram obtidas as fotos e processadas pelo software de redes neurais; exemplos são apresentados na Figura 4.4. Com as imagens devidamente processadas, gerou-se os mapas temáticos dos talhões considerando a cultura e o solo nú (Figura 4.5 a, c). Com base nestes mapas temáticos, foram processados os mapas estatísticos visando identificar as áreas com falhas mais acentuadas. Porém, os mapas estatísticos não apresentaram nenhuma falha significativa (Figura 4.5 b, d), apesar das imagens mostrarem as mesmas. Como os mapas temáticos são gerados a partir de um único valor representando cada imagem, ou seja, um valor de porcentagem de cobertura ou de solo nú por célula da grade, a quantidade de dados não foi suficiente para identificar a não uniformidade nas linhas. Sendo assim, subdividiu-se as fotos em quadrículas de 25 x 25 pixels de tamanho e novamente gerou-se novos mapas temáticos e estatísticos, chegando-se aos mapas da Figura 4.6. Nesta, são apresentados os resultados para os temas: cultura, solo nú e palha. Para cada tema, são apresentados os resultados por grade em função dos valores médios das células e os valores das áreas.

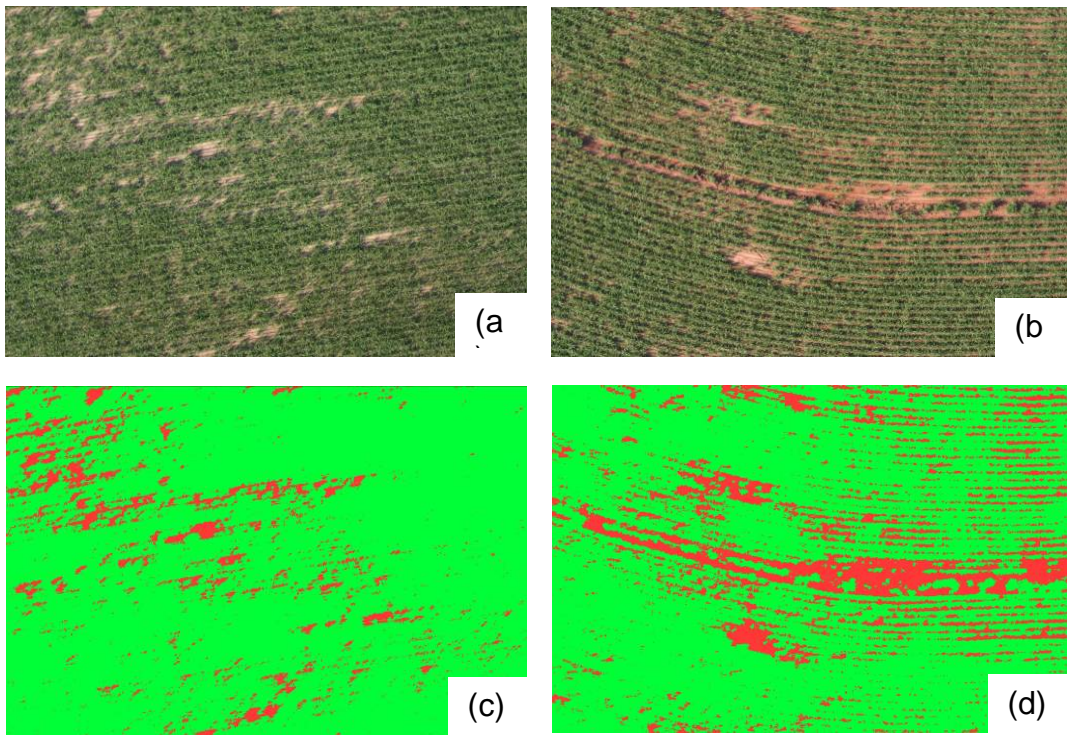


Figura 4.4 – Imagens típicas obtidas do talhão 2107 em (a) e (b), e os respectivos resultados da segmentação por redes neurais em (c) e (d). Cana-de-açúcar em verde e solo nu em vermelho.

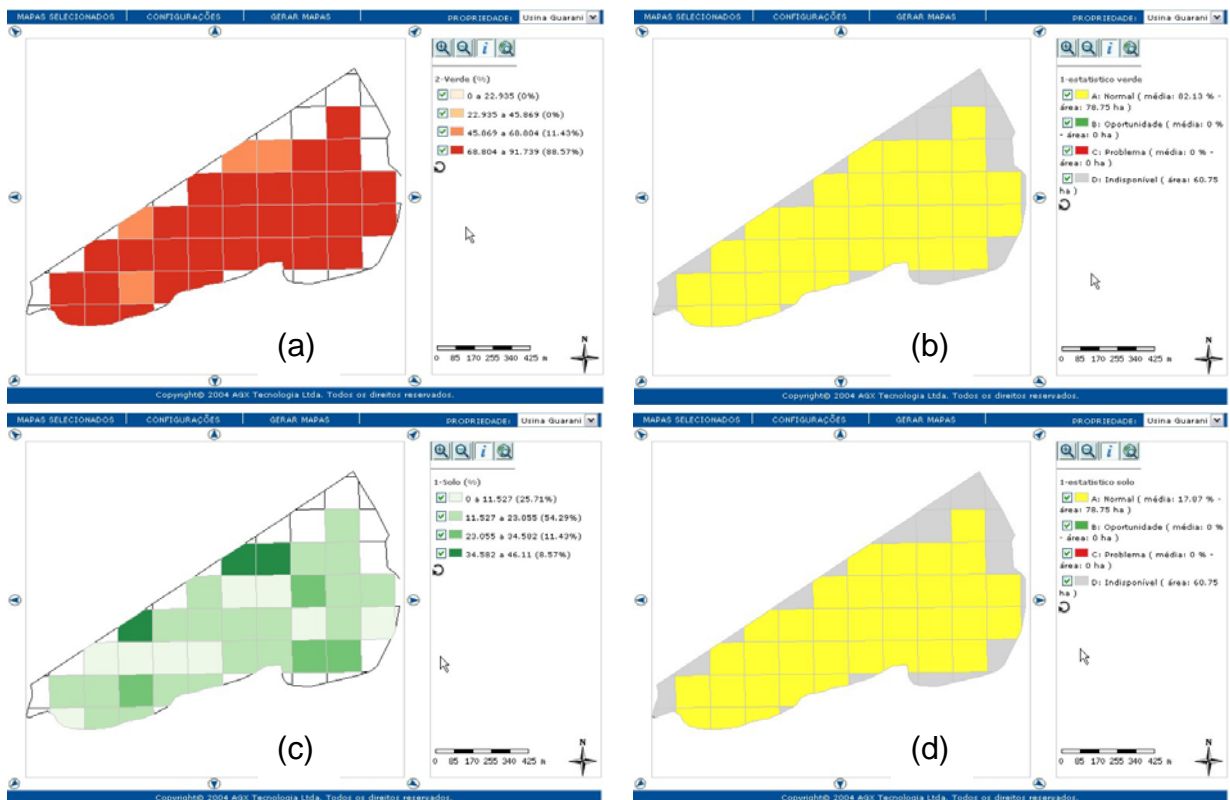


Figura 4.5 – Mapas temáticos e estatísticos para os temas cultura e solo nú do talhão 2107. (a) mapa da cultura, (b) mapa estatístico da cultura, (c) mapa do solo nú e (d) mapa estatístico sobre o solo nú.

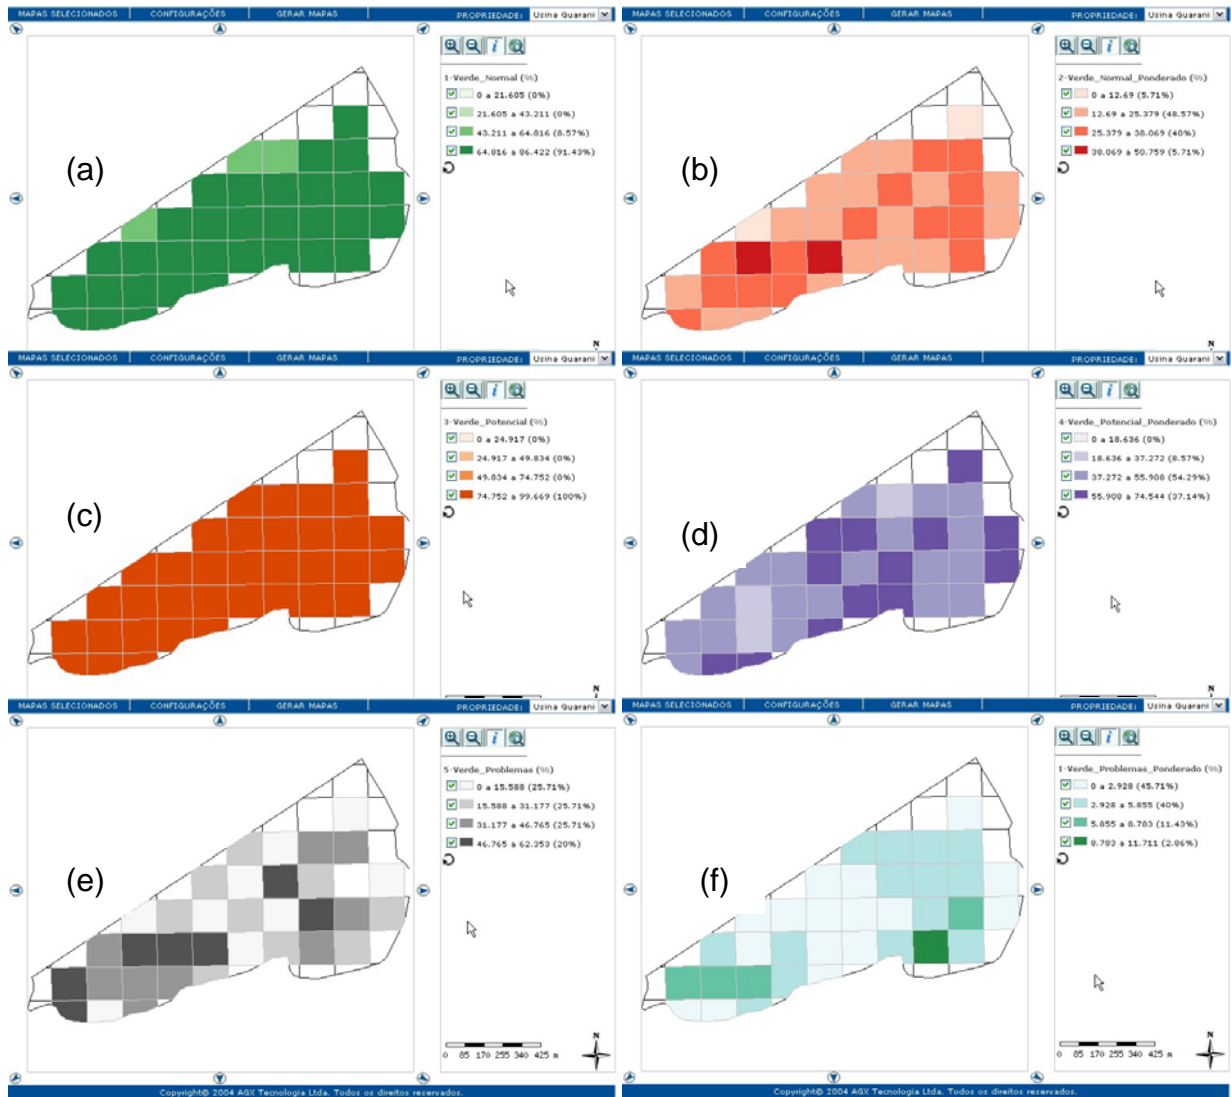


Figura 4.6 – Mapas temáticos pela média do Watershed e estatísticos pelo valor das áreas para o talhão 2107. (a) mapa temático para cultura, (b) mapa estatístico de cultura, (c) mapa temático para solo nú, (d) mapa estatístico de solo nú, (e) mapa temático para palha, e (f) mapa estatístico de palha.

Da mesma forma foram obtidas as imagens para o talhão 2217, conforme apresenta a Figura 4.7. Os mapas gerados para este talhão são apresentados na Figura 4.8. Nos mapas estatísticos já se percebe regiões a serem observadas com cuidado (as áreas em vermelho). Apesar disso, repetiu-se o processo de divisão em sub-grades de 25 x 25 pixels para obter melhor detalhamento, conforme apresentado na Figura 4.9.

Estes resultados permitiram comparar “*in locu*”, junto aos técnicos da propriedade, as reais condições da área e permitiram ver que o método responde prontamente às necessidades do monitoramento de falhas de plantio e outras anomalias.

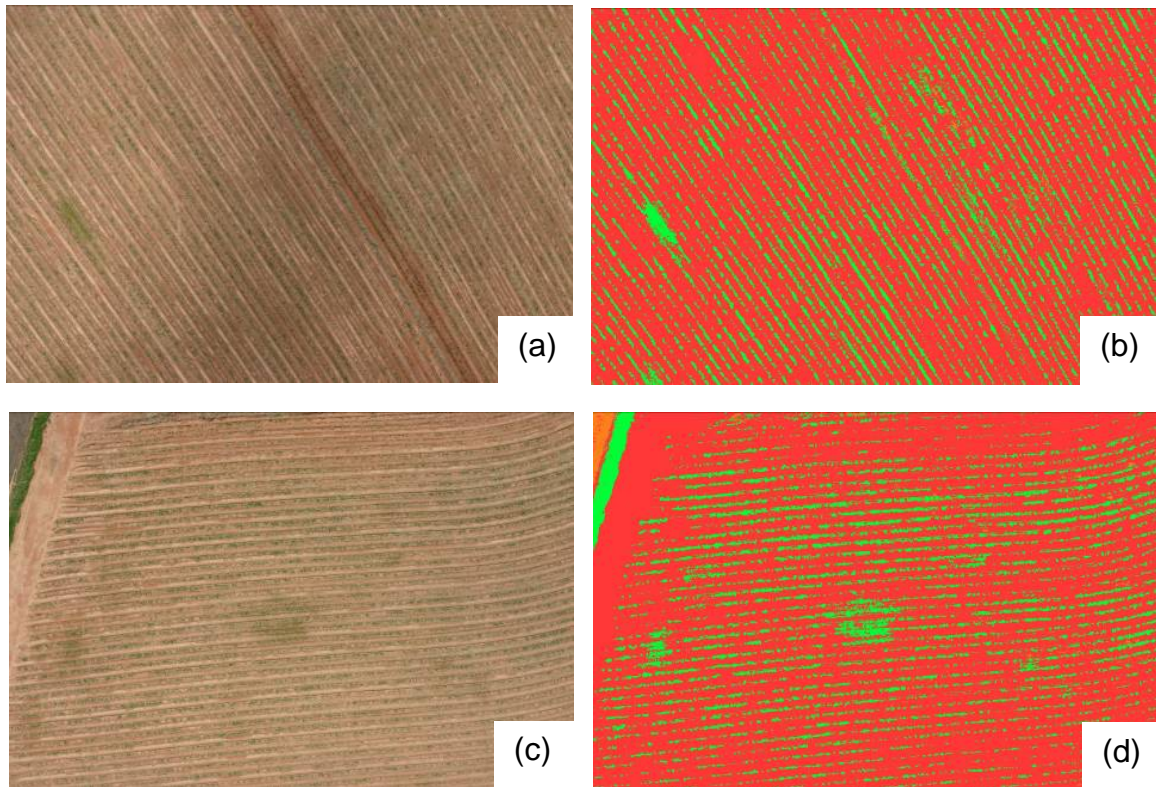


Figura 4.7 – Imagens típicas obtidas do talhão 2217 em (a) e (c), e os respectivos resultados da segmentação por redes neurais em (b) e (d). Cana em verde, solo nu em laranja e palha em vermelho.

Nos mapas estatísticos, o tema “cultura” é classificado como:

- Normal: quando sua ocorrência está dentro de uma distribuição normal pelo dossel;

- Oportunidade: áreas onde a cultura melhor se desenvolve;

- Problema: áreas onde a cultura apresenta problemas de desenvolvimento, podendo ser um determinante de falha.

O tema “solo nu” é classificado como:

- Normal: solo exposto com distribuição normal;

- Oportunidade: maior presença de solo exposto, podendo ser determinante de falha;

- Problema: áreas onde a cultura cobre mais o solo.

O tema “palha” é classificado como:

- Normal: palha com distribuição normal;

- Oportunidade: áreas onde a palha está concentrada;

- Problema: áreas onde a palha está mal distribuída.

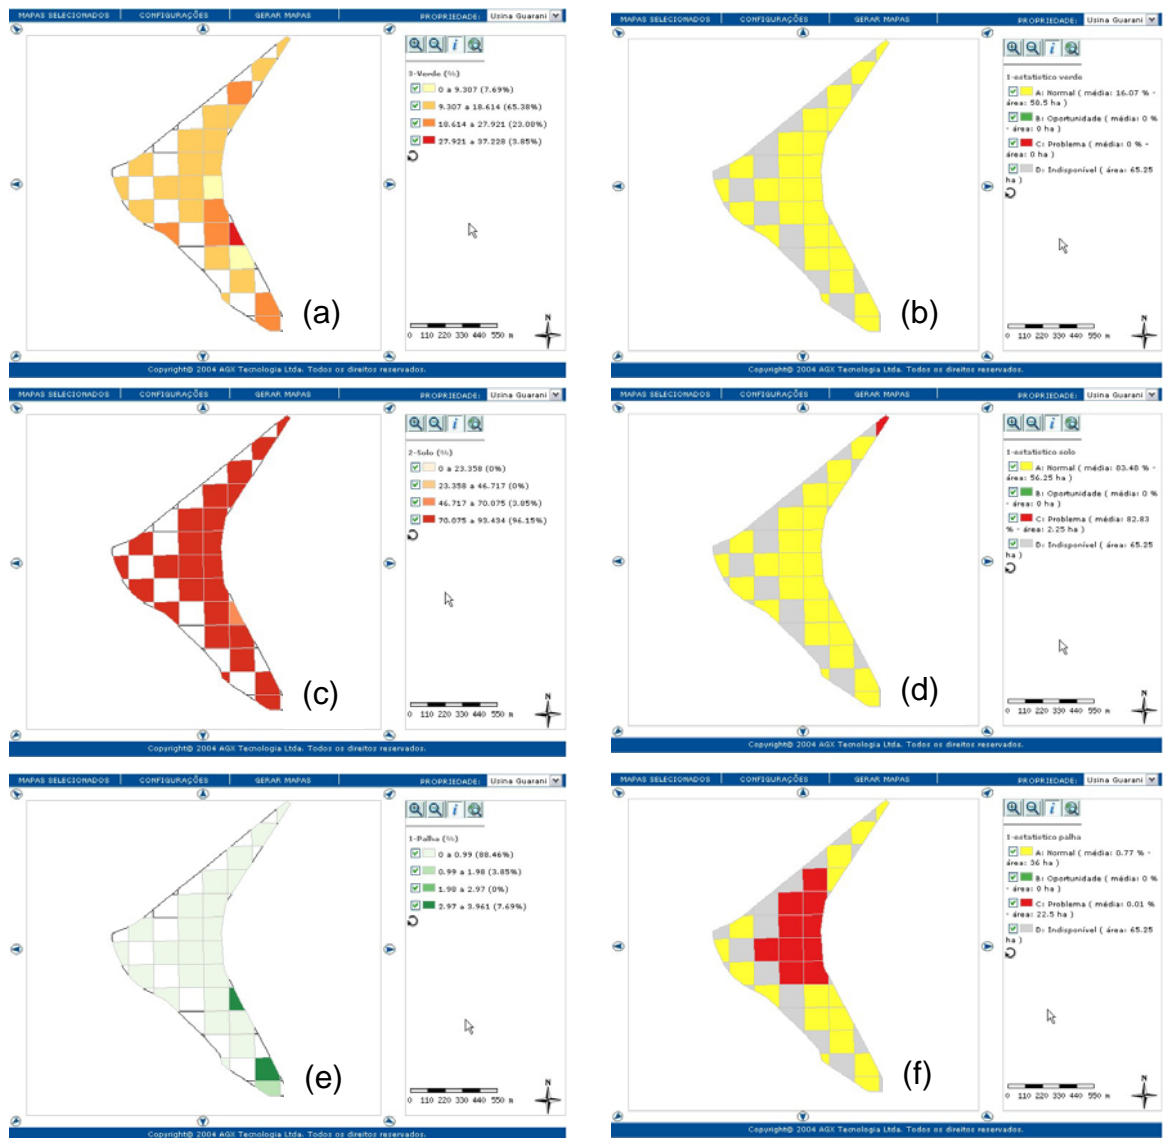


Figura 4.8 – Mapas temáticos e estatísticos dos temas cultura, solo nú e palha do talhão 2217. (a) mapa da cultura, (b) mapa estatístico da cultura, (c) mapa do solo nú, (d) mapa estatístico do solo nú, (e) mapa de palha, (f) mapa estatístico de palha.

Com base nessas informações é possível fazer a determinação dos pontos de coleta para estudo de problemas identificados e tomadas de decisão sobre: manejo diferenciado nas áreas de interesse; análise da necessidade de reforma nos talhões; histórico da lavoura; auxílio na estimativa de safra a partir dos conhecimento da área afetada, dentre outros.

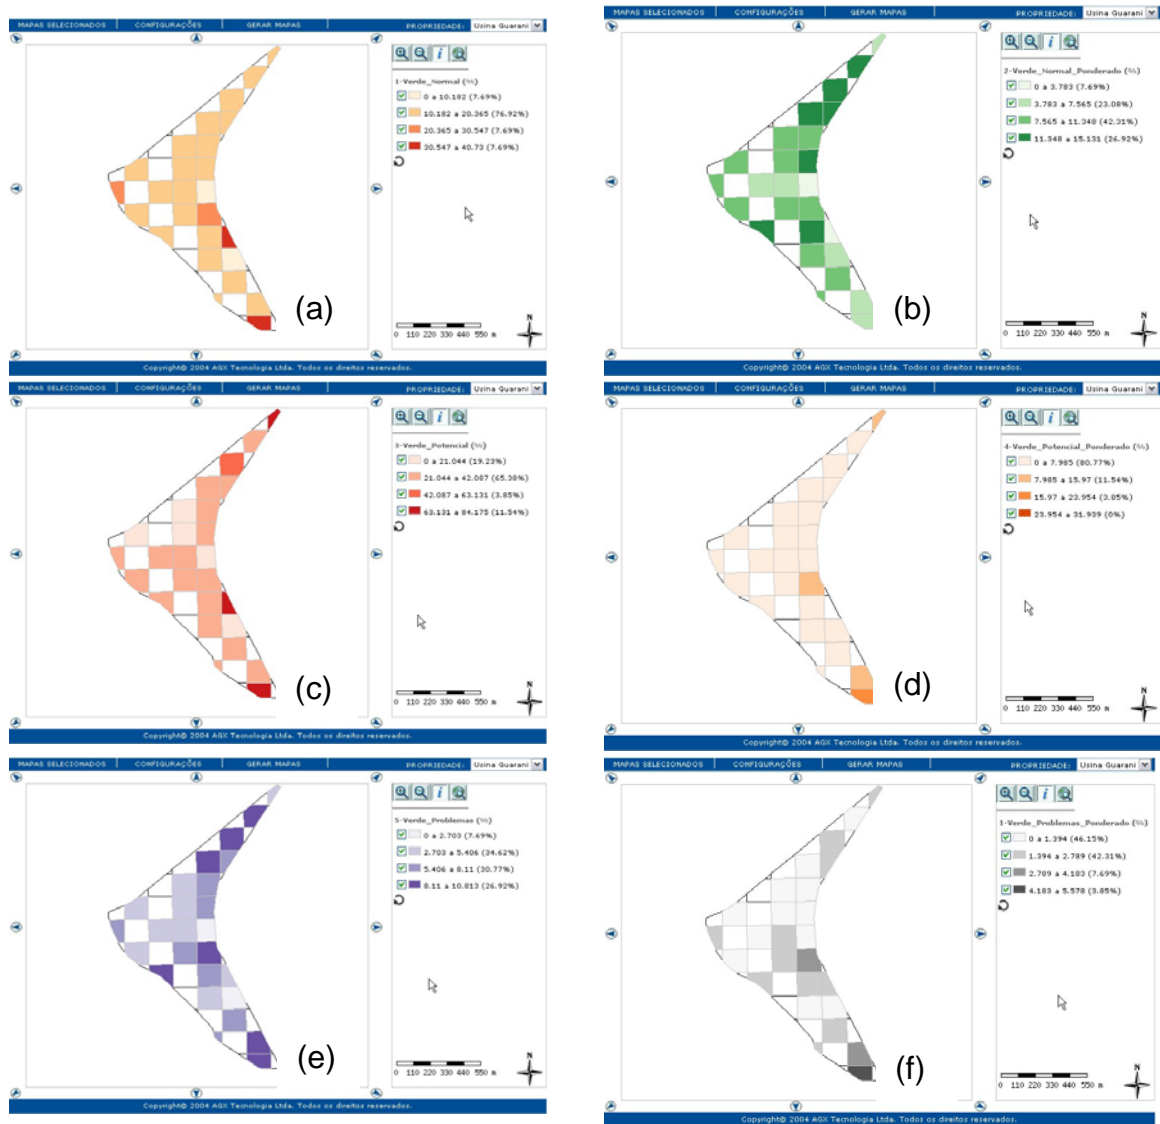


Figura 4.9 – Mapas temáticos pela média do Watershed e estatísticos pelo valor das áreas para o talhão 2107. (a) mapa temático para cultura, (b) mapa estatístico de cultura, (c) mapa temático para solo nú, (d) mapa estatístico de solo nú, (e) mapa temático para palha, e (f) mapa estatístico de palha.

Quanto ao processamento das imagens, a classificação digital por redes neurais acelerou o processo de encontrar e quantificar problemas em campo. Após o processamento da imagem, a identificação do problema pode ser feita pontualmente em campo, por pessoal especialmente treinado. Assim, a solução do problema é feita também pontualmente, significando economia financeira e de tempo.

Em estágios de desenvolvimento da cultura em que estas se apresentem em pleno estado vegetativo é possível observar diferenças de tonalidade no dossel, o que pode indicar problemas no seu desenvolvimento, devendo, portanto, ser investigado com técnicas presenciais em campo. Essas

diferenças de tonalidade podem ser, em hipótese, espacialmente correlacionadas com as características já então mapeadas, resultando em uma tomada de decisão imediata.

4.5. CONCLUSÕES

A metodologia proposta mostrou-se apta para caracterizar o delineamento de falhas de plantio em cultura de cana-de-açúcar na fase inicial de crescimento.

As fotos aéreas obtidas por aeromodelo apresentaram uma alta resolução espacial, o que foi decisivo para o bom desempenho do classificador.

A combinação de processamento Watershed com classificação por Redes Neurais Artificiais obteve ótimos resultados neste tipo de imagem aérea.

5. ARTIGO C: AVALIAÇÃO DA INTENSIDADE DE UNIFORMIZAÇÃO DE TEMAS EM RELAÇÃO À PRECISÃO DE MAPEAMENTO DE PLANTAS DANINHAS EM CULTURA DE SOJA

5.1. RESUMO E ABSTRACT

RESUMO: A classificação digital é uma técnica do processamento de imagens amplamente utilizada para produzir mapas temáticos. Porém, alguns classificadores produzem mapas com uma grande pulverização de pequenos polígonos que interferem na leitura visual desses mapas. Para contornar isso, técnicas de uniformização de temas são aplicadas às imagens classificadas; mas a intensidade dessa uniformização é pouco estudada. O presente trabalho visa analisar a intensidade de uniformização de temas em mapas temáticos gerados pelos classificadores Maxver, Maxver-ICM, Distância Euclidiana, Bhattacharya e Redes Neurais. Foi desenvolvido um software para uniformizar os mapas, suavizando somente os tamanhos de polígonos desejados. As imagens suavizadas foram interseccionadas com uma imagem classificada manualmente, considerada como “verdade terrestre” e as matrizes de erro resultantes foram avaliadas por três índices de precisão de mapeamento: Exatidão Global, Tau e Kappa. Com os valores plotados em um gráfico, a função derivada calculou o ponto de máximo correspondente ao valor ideal de uniformização, que foi de 104 pixels. O classificador por Redes Neurais obteve as melhores porcentagens de precisão de mapeamento nos três índices.

ABSTRACT: The digital classification is a technique widely used in the production of maps. Even some classifiers produce maps with lots of polygons that interfere in the visualization of these maps. To solve this problem, there are techniques to make the classification consistent, but the intensity of this consistency is not well established. The present work has the goal of analyzing the maps generated by Maxver, Maxver-ICM, Euclidian Distance, Bhattacharya and neural networks classifiers. One software was done to make the maps uniform, making smother only the desired polygons. These images were intersected with a manual classification which is considered “ground true”. The matrix of error were analyzed by three ways of precision mapping:

Global Precision, Tau and Kappa. Using a graphic, it was calculated the ideal value for post-classification techniques and this one is 104 pixels. The neural networks got the best percentage of precision mapping among this three indices.

5.2. INTRODUÇÃO

Grande parte da produção científica nacional é, atualmente, concentrada nos estudos relativos ao meio ambiente, em suas mais diferentes concepções. Várias observações do meio ambiente são conduzidas com intuito de se obter dados para análise do ambiente agrícola; como ferramenta auxiliar, o processamento digital de imagens (aéreas ou orbitais) vem acompanhando esse método de trabalho.

Daamen et al. (2003) compararam a estimativa de produção de cana-de-açúcar por observações de campo e por tratamento de imagens de satélite, obtendo boa relação dos dados obtidos em campo com o IVDN - Índice de Vegetação por Diferença Normalizada (do inglês NDVI - Normalized Difference Vegetation Index) obtido da imagem do satélite. Também Berka e Rudorff (2003) estimaram uma área plantada com soja através da análise de imagens do satélite Landsat, e compararam esse dado com as estimativas oficiais de entidades relacionadas às atividades agrícolas; concluíram que há possibilidade de sucesso na comparação se forem obtidas duas imagens em períodos diferentes da safra.

No tocante à classificação digital de imagens, muitas metodologias vêm sendo aplicadas, sempre com relativa contribuição aos pesquisadores da área.

Ippoliti, Gaggero e Costa (2003) aplicaram classificação supervisionada sobre uma área de pastagens, e discriminaram 3 tipos de cobertura: vegetação verde, seca e solo exposto, havendo um pouco de confusão entre área de solo exposto e vegetação seca. Tian (2002) utilizou de imagens de sensoriamento remoto para localizar áreas com infestação de invasoras em uma cultura, e simulou um mapa para navegação em campo com a finalidade de aplicação seletiva de herbicidas.

Em uma escala de abrangência menor, Cruvinel e Minatel (2002) elaboraram um método de classificação digital de fotos de pés de laranja, onde se correlacionava o vigor da planta através do número e tamanho dos frutos destacados no processamento. De modo semelhante, Bacci et al. (2002) desenvolveram um

software que analisa qualidade de sementes por processamento digital, a partir de fotos tiradas de uma pequena quantidade delas.

A classificação digital de imagens é um método muito utilizado para produzir mapas de uso da terra, ou seja, que mostram o uso que está sendo feito da superfície terrestre. Como toda paisagem é composta de pequenos elementos terrestres, e como cada elemento tem sua característica espectral distinta, os softwares de classificação digital tomam cada pequeno elemento da paisagem como sendo diferente do seu entorno, e na verdade não o é. Esse fato é, de certa forma, indesejável, pois pode dificultar a análise da distribuição espacial dos elementos da paisagem na imagem pelo fotointérprete.

Para minimizar esse efeito, existem processos computacionais chamados de pós-classificação, ou uniformização de temas, o qual é aplicado um filtro digital sobre a imagem classificada na tentativa de eliminar os pontos isolados e melhorar o aspecto visual do produto mapeado. Vários trabalhos citam o uso desse processo (SILVA; MATTOS; PEREIRA NETO, 2000; DAINESE, 2001; LACRUZ, 2003).

Vários são os algoritmos de uniformização de temas existentes. Thomas (1980) descreveu a aplicação de um pós-processamento em dados classificados baseado em uma função de proximidade. Também Townsend (1986) desenvolveu um operador lógico para suavizar a imagem classificada, mas comenta que pode existir perda de informação da imagem, o que não é desejável. Bischof, Schneider e Pinz (1992) aplicaram um algoritmo de redes neurais artificiais para suavizar ruídos de uma imagem Landsat classificada digitalmente também por redes neurais. INPE (2006) utiliza valores de peso e limiar, definidos pelo usuário, para alterar o valor de um ponto central, em uma janela de 3 x 3 pixels, substituindo-o pelo de maior frequência na vizinhança. “Quanto menor os valores de peso e limiar, maior número de substituições serão realizadas”.

Os autores citados anteriormente aplicam a uniformização de temas em toda a imagem, pois os algoritmos são compostos de uma janela de $n \times n$ pixels escaneando toda a imagem. Isso altera não só os pixels desejáveis (ruído), mas também os que já estariam corretos. Como alternativa a esse processo, Chan, Ho e Nikolova (2004) desenvolveram um suavizador de ruídos de imagem que, em uma primeira fase, identifica pixels discrepantes de sua vizinhança (possivelmente ruídos) e, posteriormente, restaura a imagem somente nesses pixels selecionados. Anterior a

isso, Davis e Peet (1977) desenvolveram um método simples para suavizar o mapa temático especificando um tamanho mínimo de área para cada tema, em que todo polígono do mapa seria igual ou maior que o tamanho estipulado.

A técnica de uniformização de temas, embora seja aplicada com o intuito de melhorar o mapa temático no aspecto visual, na verdade altera o resultado apresentado pela classificação digital. Com isso, uma análise de precisão de mapeamento vem a ser necessária para avaliar a intensidade dessa uniformização.

Essa pulverização de classes temáticas tem certa influência na precisão do mapeamento feito, e isso não é assunto recente. Moreira, Chen e Lima (1982) testaram diferentes valores de parâmetros (limiar e peso) para uniformização de temas após uma classificação digital híbrida combinando Média-K com Maxver. Comparando os resultados obtidos com aqueles sem esse processamento, os valores foram estatisticamente significativos ao nível de 5%, concluindo que a uniformização de temas contribui para melhorar a precisão de mapeamento.

Congalton (1991) e Janssen e Van Der Wel (1994) apresentam uma ampla revisão sobre técnicas disponíveis para se fazer a avaliação da precisão de mapeamento. Uma das informações mais utilizadas para se avaliar essa precisão e o resultado de classificação de imagens é a análise da “matriz de erro”, que é considerada adequada para um número pequeno de classes temáticas (CAMPAGNOLO; CAETANO, 2002). É apresentada por uma tabela de dupla entrada onde, de um lado, representam-se as classes observadas na realidade, e de outro, as classes mapeadas pelo classificador. Os valores da diagonal principal da tabela apontam as observações corretamente classificadas (STORY; CONGALTON, 1986).

Dentre os procedimentos usados para medir a precisão da classificação de imagens a partir de uma matriz de erro, existem 3 índices que são amplamente utilizados: a Exatidão Global, o Kappa e o Tau.

O Índice de Exatidão Global (EG) se limita a utilizar a quantidade de pixels corretamente classificados, e foi calculado pela equação:

$$EG = \frac{\sum_{i=1}^M x_{ii}}{N}$$

onde x_{ii} = elementos da diagonal principal da matriz de erro; N = número total de pixels da imagem; M = número de classes temáticas (PONZONI; REZENDE, 2002).

O Índice Kappa (K) é considerado uma medida mais apropriada de exatidão por utilizar todos os elementos da matriz de erro, e não somente a diagonal principal (CONGALTON; MEAD, 1983, apud MACHADO, 2002; GONG; HOWART, 1990). É calculado pela equação:

$$K = \frac{\sum_{i=1}^M x_{ii} - \frac{\sum_{i=1}^M (x_{i+} * x_{+i})}{N}}{1 - \frac{\sum_{i=1}^M (x_{i+} * x_{+i})}{N^2}}$$

onde x_{ii} = elementos da diagonal principal da matriz de erro; x_{i+} e x_{+i} = somatória na linha e coluna i da matriz de erro, respectivamente; N = número total de pixels da imagem; M = número de classes temáticas.

O Índice Tau (T), sugerido por Ma e Redmond (1995), é calculado pela equação:

$$T = \frac{\sum_{i=1}^M x_{ii} - \frac{1}{M}}{1 - \frac{1}{M}}$$

onde x_{ii} = elementos da diagonal principal da matriz de erro; N = número total de pixels da imagem; M = número de classes temáticas.

Brites (1996) utilizou esses 3 índices para avaliar a classificação Maxver de imagens digitais Landsat de regiões densamente vegetadas. Concluiu que o índice EG superestima a avaliação da exatidão e que o índice K subestima-o, tendo o índice T um comportamento sempre intermediário, sendo este o índice ideal para uma correta consideração sobre a exatidão de classificação de imagens. Esse resultado também foi observado por Ponzoni e Rezende (2002).

O coeficiente Tau foi utilizado por Braga e Gherardi (2001) para estimar a exatidão da classificação de imagens de alta resolução no mapeamento de recifes costeiros. Mas apesar da observação anterior de Brites, encontra-se na literatura mais aplicações do índice Kappa do que do índice Tau. Carrilho, Soares e Valério Filho (1996) calcularam os valores de Kappa para avaliar o monitoramento de mudanças na cobertura do solo de cerrado. South, Qi e Lusch (2004) avaliaram a precisão de classificação de 5 classificadores digitais com o índice Kappa, entre os sistemas agrícolas tradicional e de plantio direto. Braga et al. (2006) compararam a eficiência de classificadores supervisionados e não-supervisionados através da geração de matrizes de erro e cálculo do índice Kappa, para mapeamento do uso do solo no município de Serra do Salitre, em Minas Gerais.

Nesse contexto, o objetivo do presente trabalho é avaliar o grau de intensidade da uniformização de temas em relação à precisão do mapeamento.

5.3. MATERIAL E MÉTODOS

5.3.1. Imagens utilizadas

Na foto original (Figura 5.1) é possível distinguir as seguintes classes temáticas: "cultura", "entrelinhas" e "planta invasora", sendo essa foto oriunda de fotografia aérea datada da safra 2002/2003 sobre soja em fase de pré-florescimento, obtida pelo aeromodelo da EMBRAPA Instrumentação Agropecuária – Empresa Brasileira de Pesquisa Agropecuária / Centro Nacional de Pesquisa e Desenvolvimento em Instrumentação Agropecuária.



Figura 5.1 – Fotografia aérea obtida por aeromodelo - cultura de soja.

As imagens classificadas digitalmente utilizadas no presente trabalho são as imagens geradas por Pereira Neto, Guimarães e Jorge (2004), através dos classificadores Maxver, Maxver-ICM, Distância Euclidiana e Bhattacharya do software SPRING, e através do classificador por redes neurais do software AGGeolImagem. Foi feita também uma classificação manual (assumida como “verdade terrestre”) no software SPRING (Figura 5.2).

5.3.2. Software elaborado

Foi desenvolvido um software de uniformização de temas neste trabalho, o qual foi denominado FillGap, visando atuar somente nos agrupamentos de pixels dispersos pela imagem, responsáveis pelo visual fragmentado da imagem classificada. Desse modo, não há alteração da imagem nos pixels não selecionados, assim como o software desenvolvido por Chan, Ho e Nikolova (2004). Além disso, neste software pode-se definir o tamanho mínimo dos agrupamentos a serem uniformizados.




Figura 5.2 – Imagens classificadas digitalmente (a) Bhattacharya (b) Distância Euclidiana (c) Maxver (d) Maxver-ICM (e) Rede Neural, e (f) classificada manualmente.

5.3.3. Uniformização de temas

A primeira fase do trabalho foi a uniformização de temas em cada uma das cinco imagens iniciais, através do software FillGap. Iniciou-se a sua aplicação com grau de intensidade 5, ou seja, todo polígono com área de até 5 pixels de tamanho foi abrangido pela classe ao seu redor. Assim, sucessivamente, aplicou-se a uniformização de temas, incrementando sempre 5 graus de intensidade a cada uniformização (5, 10, 15, 20,...) até o grau 150 de intensidade. Cada grau aplicado gerou uma nova imagem, sempre com pulverização de pixels visualmente inferior à imagem anterior, totalizando 150 imagens (30 de cada imagem inicial).

Todas as 150 imagens geradas foram importadas para o software SPRING, onde foi feita a intersecção de cada imagem com a imagem inicial classificada manualmente, considerada como “verdade terrestre”.

Essas intersecções geraram 150 matrizes de erro que foram avaliadas de acordo com três índices de precisão de mapeamento: Exatidão Global, Kappa e Tau. Com esses índices plotados em um gráfico, calculou-se a função derivada da curva para obter seu “ponto de máximo”, sendo esse o correspondente grau de intensidade de uniformização ideal a ser aplicado nas imagens iniciais.

5.4. RESULTADOS E DISCUSSÃO

A uniformização de temas é um processo de melhoria do produto final da classificação. O grau de uniformização aplicado sobre uma imagem classificada faz com que esta seja alterada, sendo necessário haver um limite para essa alteração, de modo a não afetar as partes corretamente classificadas.

Na fase de uniformização da imagem classificada, foram geradas 150 imagens em diferentes graus de intensidade. Como são muitas imagens, a Figura 5.3 mostra somente as uniformizações feitas com graus 50, 100 e 150 para o classificador digital Maxver, para se ter uma idéia do processo de desfragmentação.




Figura 5.3 – Secção de imagens classificadas ilustrando a aplicação da uniformização de temas em graus de intensidade (a) 50, (b) 100 e (c) 150, no classificador digital Maxver-ICM.

Essas imagens, após interseccionadas com a imagem “verdade terrestre”, geraram matrizes de erro ilustradas pelo exemplo da Tabela 5.1.

Os índices de precisão de mapeamento avaliados a partir dessas matrizes são mostrados na Figura 5.4. Como as curvas do classificador Maxver e Maxver-ICM são semelhantes, optou-se por apresentar no gráfico somente as curvas do Maxver representando ambos classificadores; isso foi feito para diminuir a

intensidade de linhas do gráfico, melhorando a diagramação da figura.

Tabela 5.1 – Modelo de matriz de erro oriunda da intersecção da imagem “verdade terrestre” com cada uma das imagens uniformizadas nos diferentes graus de intensidade e diferentes classificadores digitais. Nas linhas: verdade terrestre; nas colunas: imagem uniformizada (unidade em pixels).

	cultura	sombra	invasora	total
cultura	802.648	238.044	11.686	1.052.378
sombra	27.495	284.778	338	312.611
invasora	30.202	2.203	68.296	100.701
total	860.345	525.025	80.320	1.465.690




Figura 5.4 – Porcentagem de precisão de mapeamento, calculado a partir das matrizes de erro, para cada índice (Exatidão Global, Kappa e Tau), para cada classificador digital e para cada grau de intensidade de uniformização.

Este resultado obtido coincide com o resultado encontrado por Brites (1996) e por Ponzoni e Rezende (2002), tendo o índice Tau valores intermediários entre os valores da Exatidão Global e de Kappa.

Observa-se que, para os 3 índices de precisão de mapeamento, os melhores valores foram obtidos com o classificador por redes neurais. A Figura 5.5 mostra essas 3 curvas do classificador por redes neurais isoladas das demais, juntamente com suas correspondentes equações de regressão. Como os 3 índices são amplamente utilizados e comprovados quanto a sua eficiência através de vários trabalhos científicos, optou-se por gerar uma quarta curva de regressão a partir da média dos valores dos 3 índices, também mostrado na Figura 5.5.

Para saber se as 4 curvas tem um ponto de máximo, calculou-se a primeira e a segunda derivada sobre cada uma das 4 funções de regressão. O valor obtido no ponto de máximo corresponde ao grau de uniformização recomendado para que a pulverização de pixels seja visualmente reduzida sem diminuir a precisão do mapeamento. A tabela 5.2 apresenta esses valores juntamente com o valor inicial de acerto de classificação, bem como a taxa de aumento de precisão, que corresponde ao incremento de acerto de classificação entre o inicial e o ponto de máximo.

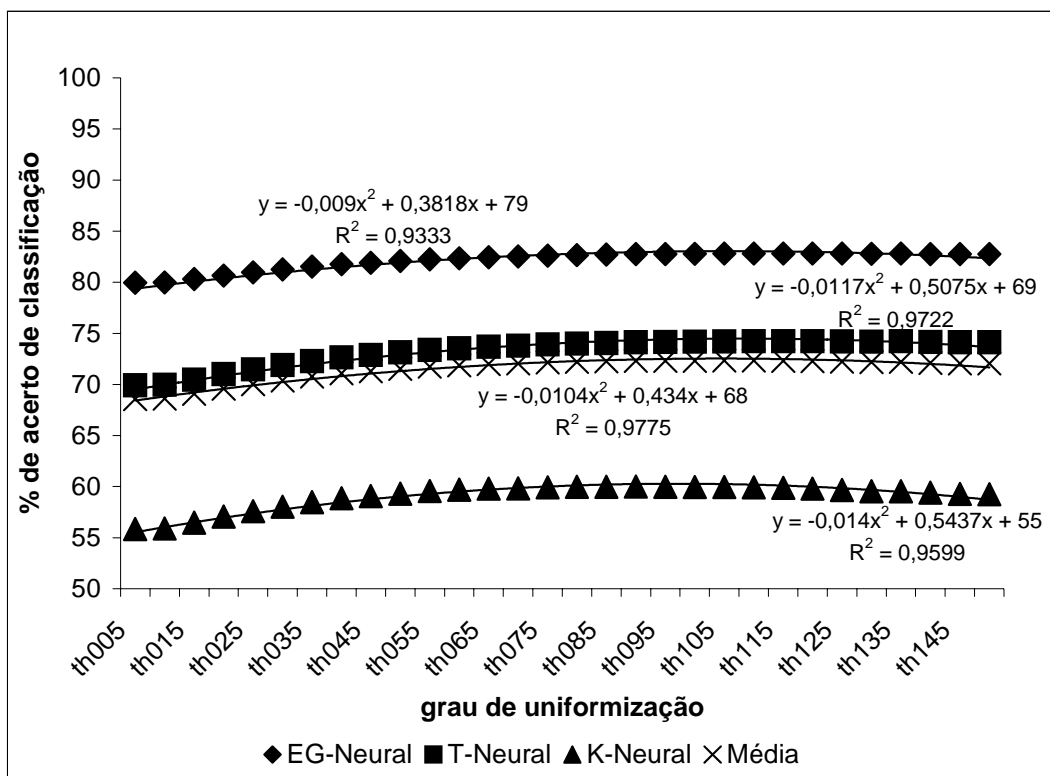


Figura 5.5 – Curvas do classificador por redes neurais para cada um dos índices de precisão de mapeamento e para a média deles, juntamente com suas curvas de regressão (EG = Exatidão Global, T = Tau, K = Kappa).

Tabela 5.2 – Grau máximo de uniformização e a respectiva percentagem de acerto de classificação obtida para cada curva de regressão.

Índices	% de acerto de classificação inicial	Ponto de máximo	Grau de uniformização	% de acerto de classificação	Taxa de aumento de precisão
Exat.Gl.	79,95	21,21	106	83,05	3,88
Tau	69,92	21,69	108	74,50	6,55
Kappa	55,84	19,42	97	60,28	7,95
Média	68,57	20,87	104	72,53	5,78

Pela tabela pode-se observar que a Média e o índice Tau tiveram valores de percentagem de acerto de classificação muito próximos entre si. Isso se deve ao fato de o índice Tau ter a característica de apresentar valores sempre intermediários entre os índices EG e Kappa.

Quanto à taxa de aumento de precisão, nota-se que a EG tem o menor valor; isso mostra que o aumento no grau de uniformização pouco altera o valor desse índice de precisão, tendo, portanto, uma variação mais homogênea em relação aos demais. Esse dado pode ser usado como característica de exclusão desse índice em análises futuras, pois o tempo e recurso que se dispense em testar tal índice não compensa o fraco retorno em precisão.

Pode-se observar pela tabela que os índices Tau e Kappa foram os que apresentaram maiores taxas de aumento de precisão, mostrando que o aumento do grau de uniformização foi importante para o aumento na percentagem de acerto de classificação.

5.5. CONCLUSÕES

O aumento no grau de uniformização foi importante para aumentar a percentagem de acerto de classificação.

O índice Exatidão Global não apresentou bom desempenho para apontar o aumento na taxa de precisão de mapeamento.

O software desenvolvido no presente trabalho mostrou-se de fácil utilização, útil e inovador.

6. CONCLUSÕES GERAIS

-- Imagem aérea de baixa altura obtida por aeromodelo mostrou ser um material preciso para quantificar nível de infestação de plantas daninhas na área testada.

-- O classificador por Redes Neurais foi o mais eficiente dentre os classificadores estudados.

-- O desempenho das Redes Neurais foi adequado na análise de diferentes tipos de anomalias em diferentes lavouras agrícolas.

-- O aumento no grau de uniformização foi importante para aumentar a porcentagem de acerto de classificação.

-- O índice Exatidão Global não apresentou bom desempenho para apontar o aumento na taxa de precisão de mapeamento.

-- O software desenvolvido no presente trabalho para avaliar o grau ideal de uniformização de temas em uma imagem classificada mostrou-se de fácil utilização, útil e inovador.

REFERÊNCIAS

ABRAHAMSSON, M.; NORBERG, O.; NOONE, K. UAVs for atmospheric research in the north of Sweden. UAVMarketSpace, NY, USA, 2003. Disponível em <http://www.uavm.com/images/Eagle_Research_Swedish_Space_Corporation_Eagle_NEAT_paper_ESA_PAC_2003.pdf>. Acesso em jan.2007.

AGUIAR, J.; DAINESE, R.C.; PUGLIESE, P.B.; JORGE, L.A.C. Análise estatística de áreas com anormalidade de produtividade para a definição de zonas homogêneas de manejo. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, mai.2004, Piracicaba-SP. Anais... Piracicaba: ESALQ/USP, 2004.

AITKENHEAD, M.J.; DALGETTY, I.A.; MULLINS, C.E.; MCDONALD, A.J.S.; STRACHAN, N.J.C. Weed and crop discrimination using image analysis and artificial intelligence methods. Computers and Electronics in Agriculture. v.39, p.157-171, 2003.

ANDRADE, A.F.; BOTELHO, M.F.; CENTENO, J.A.S. Classificação de imagens de alta resolução integrando variáveis espectrais e forma, utilizando redes neurais artificiais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte-MG. Anais... São José dos Campos: INPE, 2003.

BACCI, L.; RAPI, B.; COLUCCI, F.; NOVARO, P. Durum wheat quality evaluation software. In: WORLD CONGRESS OF COMPUTER IN AGRICULTURE AND NATURAL RESOURCES, 2002, Foz do Iguaçu, Brasil. Proceedings... Michigan, USA: American Society of Agricultural Engineers, 2002.

BERKA, L.M.S.; RUDORFF, B.F.T.. Estimativa de área plantada com soja através de imagens Landsat em municípios do norte do Paraná. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte-MG. Anais... São José dos Campos: INPE, 2003.

BISCHOF, H.; SCHNEIDER, W.; PINZ, A.J. Multispectral classification of Landsat images using neural networks. IEEE Transactions of Geoscience and Remote Sensing, v.30, n.3, p.482-490, may 1992.

BLASCHKE, T.; KUX, H. Sensoriamento Remoto e SIG: novos sistemas sensores e métodos inovadores. São Paulo: Oficina de Textos, 2005. 286p.

BRAGA, A.L.; FIGUEIREDO, G.C.; SILVA, F.G.; SOARES, V.P. Comparação entre as classificações híbrida e supervisionada no mapeamento do uso do solo usando imagens de alta resolução. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO, 7., out. 2006, Florianópolis-SC. Anais... Florianópolis: UFSC, 2006.

BRAGA, C.Z.; GHERARDI, D.F.M. Mapeamento de recifes costeiros utilizando imagens orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu-PR. Anais... São José dos Campos: INPE, 2001.

BRITES, R.S. Verificação de exatidão em classificação de imagens digitais orbitais: efeitos de diferentes estratégias de amostragens e avaliação de índices de exatidão. 1996. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG. 101p.

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, Campina Grande-PB, v.8, n.2/3, p.326-329, 2004.

BURKS, T.F.; SHEARER, S.A.; HEATH, J.R.; DONOHUE, K.D. Evaluation of neural-network classifiers for weed species discrimination. Biosystems Engineering, v. 91, n.3, p.293-304, 2005.

BURROUGH, P.A.; MCDONNELL, R.A. Principles of Geographical Information System. Oxford: Oxford University Press, 1998. 333p.

CAMPAGNOLO, M.L.; CAETANO, M. Technical Report n.6: Abordagens multiestratégicas para classificação de imagens de satélite – aplicação em uma zona florestal. Lisboa, Portugal: Departamento de Matemática, Instituto Superior de Agronomia, Universidade Técnica de Lisboa, 2002. 71p.

CARRILHO, J.Z.; SOARES, J.V.; VALÉRIO FILHO, M. Detecção automática de mudanças como recurso auxiliar no monitoramento da cobertura do terreno. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador-BA. Anais... São José dos Campos: INPE, 1996.

CHAN, R.H.; HO, C.W.; NIKOLOVA, M. Salt-and-pepper noise removal by median-type noise detectors and detail-preserving regularization. IEEE Transactions on Image Processing, v. 14, p.1479-1485, 2004.

CHRISTENSEN, S.; WALTER, A.M.; HEISEL, T. The patch treatment of weeds in cereals. In: THE BRIGHTON CROP PROTECTION CONFERENCE, 1999, Brighton. Weeds Proceedings, Brighton: (s.ed.), 1999. p.591-600.

CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment, New York, v.37, p.35-46, 1991.

CONGALTON, R.G.; MEAD, R.A. A quantitative method to test for consistency and correctness in photointerpretation. Photogrammetric Engineering and Remote Sensing, Bethesda, v.49, n.1, p.69-74, jan.1983.

CRÓSTA, A.P. Processamento digital de imagens de sensoriamento remoto. Campinas: IG/UNICAMP, 1992. 170p.

CRUVINEL, P.E.; MINATEL, E.R. Image processing in automated pattern classification of oranges. In: WORLD CONGRESS OF COMPUTER IN AGRICULTURE AND NATURAL RESOURCES, 2002, Foz do Iguaçu, Brasil. Proceedings... Michigan, USA: American Society of Agricultural Engineers. 2002.

DAAMEN, M.L.J.; ROCHA, J.V.; LAMPARELLI, R.A.C.; ZULLO JÚNIOR, J. Comparação entre estimativa de produção de cana-de-açúcar auxiliada por processamento digital de imagens de satélite e métodos tradicionais de observação de campo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte-MG. Anais... São José dos Campos: INPE, 2003.

DAINESE, R.C. Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não supervisionada e análise visual. 2001. Dissertação (Mestrado em Agronomia) - Universidade Estadual Paulista, Botucatu, SP. 185p.

DAVIS, G.; CASADY, W.; MASSEY, R. Precision agriculture: An introduction. Water quality. University of Missouri-System, 1998. 8p. Disponível em: <<http://mpac.missouri.edu/pubs/wq0450.pdf>>. Acesso em jan.2007.

DAVIS, W. A.; PEET, F. G. A method of smoothing digital thematic maps. Remote Sensing of Environment, New York, v.6, n.1, p.45-49, 1977.

DEL FRATE, F.; FERRAZZOLI, P.; GUERRIERO, L.; STROZZI, T.; WEGMÜLLER, U.; COOKMARTIN, G.; QUEGAN, S. Wheat cycle monitoring using radar data and a neural network trained by a model. In: INTERNATIONAL GEOSCIENCE AND

REMOTE SENSING SYMPOSIUM, 2002, Toronto, Canada. Anais... Toronto: IEEE, 2002.

DEMING, W.E. Qualidade: A revolução da Administração. Rio de Janeiro: Marques-Saraiva, 1990.

DIAS, D.N. Identificação dos sintomas de ferrugem em áreas cultivadas com cana-de-açúcar. 2004. Dissertação (Mestrado em Ciências) - Universidade de São Paulo, São Carlos, SP. 110p.

DONZELI, P.L.; VALÉRIO FILHO, M.; NOGUEIRA, F.P.; PEREZ FILHO, A.; KOFFLER, N.F. Imagens orbitais e de radar na definição de padrões fisiográficos aplicados ao solo. Revista Brasileira de Ciência do Solo, Viçosa-MG, v. 7, p. 89-94, 1983.

EBERHART, R.C.; DOBBINS, R.W. Neural network PC tools: a practical guide. San Diego, California: Academic, 1990. 414p.

EISENBEISS, H. A mini unmanned aerial vehicle (UAV): system overview and image acquisition. In: INTERNATIONAL WORKSHOP ON PROCESSING AND VISUALIZATION USING HIGH-RESOLUTION IMAGERY, nov.2004, Pitsanulok, Thailand. Proceedings... Pitsanulok, Thailand: ISPRS/GISTDA/ARIDA, 2004.

EISENBEISS, H.; VOGLER, A. Automated processing of UAV-images for the analysis of pollen dispersal in maize. ETH Research Database, Project Summary, Zurich, Deustche, jan.2006. Disponível em <https://www.rdb.ethz.ch/projects/project_pdflatex.php?proj_id=15238>. Acesso em jan.2007.

EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Software AGGeolimagem. EMBRAPA/CNPDIA: São Carlos, SP, 2004.

FANGLAN, M.; SHANGPING, L.; YULIN, H.; SHANSHAN, H.; RONGRONG, S. Comprehensive evaluation of the cutting performance of sugarcane harvester based on fuzzy theory and neural network. In: INTERNATIONAL CONFERENCE ON HIGH-PERFORMANCE COMPUTING IN ASIA-PACIFIC REGION, 8., 2005, Beijing, China. Proceedings... Beijing: HPCASIA, 2005, p.443-450.

FANGQUAN, M. Development and strategy for agricultural information technology. In: WORLD CONGRESS OF COMPUTER IN AGRICULTURE AND NATURAL

RESOURCES, 2002, Foz do Iguaçu, Brasil. Proceedings... Michigan, USA: American Society of Agricultural Engineers, 2002.

FEIZHOU, Z.; YINGCHUN, T.; XIUWAN, C.; DEJIAN, L. The system framework of earth observation information captures based on high altitude UAV. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2005, Seoul, Korea. Proceedings... New York: IEEE, 2005, p.2074-2077.

FELDBERG, I.; NETANYAHU, N.S.; SHOSHANY, M. A neural network-based technique for change detection of linear features and its application to a Mediterranean region. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2002, Toronto, Canada. Proceedings... Toronto: IEEE, v.2, 2002, p.1195-1197.

FERNANDES, A.M.R. Inteligência Artificial: noções gerais. Florianópolis: Visual Books, 2003. 160p.

GAZZIERO, D. L. P.; BRIGHENTI, A. M.; VOLL, E.; MACIEL, C. D. G.. Convivência da planta daninha amendoim bravo (*Euphorbia Heterophylla*) com a cultura da soja no Estado do Paraná. In: REUNIÃO DE PESQUISA EM SOJA NA REGIÃO CENTRAL DO BRASIL, 20., 1998, Londrina-PR. Anais... Londrina-PR: EMBRAPA, 1998, p. 378.

GLERIANI, J.M. Redes neurais artificiais para classificação espectro-temporal de culturas agrícolas. 2005. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos, SP. 212p. INPE-12908-TDI/1011.

GONG, P.; HOWART, P.J. An assessment of some factors influencing multispectral land-cover classification. Photogrammetric Engineering and Remote Sensing, Bethesda, v.56, n.5, p.597-603, may.1990.

GOUQING Z.; CHAOKUI L.; PENGGEN C. Unmanned Aerial Vehicle (UAV) real-time video registration for forest fire monitoring. In: IGARSS – INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 25., jul.2005, Seoul, Korea. Proceedings... Korea: COEX, 2005. p.1803-1806.

HAYKIN, S. Redes Neurais: princípios e prática. Porto Alegre: Bookman, 2001. 900p.

HEIRMAN, P.; SERNEELS, R.; VANDERSTEEN, M.; GELAN, J.; BEULS, E. On a hybrid watershed-neural network approach for the segmentation of high field MR images of the spinal cord. . In: IPA – INTERNATIONAL CONFERENCE ON IMAGE

PROCESSING AND ITS APPLICATIONS, 6., jul.1997, Dublin, Ireland.
Proceedings... Dublin: IEE-Institution of Electrical Engineers, 1997. p.390-393, v.1.

HERWITZ, S.R.; JOHNSON, L.F.; DUNAGAN, S.E.; HIGGINS, R.G.; SULLIVAN, D.V.; ZHENG, J.; LOBITZ, B.M.; LEUNG, J.G.; GALLMEYER, B.A.; AOYAGI, M.; SLYE, R.E.; BRASS, J.A. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. Computers and Electronics in Agriculture, v.44. p.49-61, 2004.

HUNT, R.; HAMILTON, R.; EVERITT, J. Mapping weed infestation using remote sensing. Salt Lake City, USA: USDA Forest Service, Remote Sensing Applications Center – RSAC, s.d.. 8p.

HUNTSVILLE TIMES. Redstone surveillance planes to help assess storm damage. Huntsville Times, Alabama, USA, set.2005. Disponível em <http://www.uavm.com/images/Dragon_Eye_-_Redstone_surveillance_planes_to_help_assess_storm_damage.pdf>. Acesso em jan.2007.

INPE – INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Canasat: mapeamento da cana via imagens de satélite de observação da Terra. INPE: São José dos Campos, SP, s.d.. Disponível em <<http://www.dsr.inpe.br/mapdsr/intro.htm>>. Acesso em jan.2007.

INPE – INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Software Spring versão 4.1. INPE: São José dos Campos, SP, 2004.

INPE – INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Spring: Tutorial. INPE: São José dos Campos, 2006. Disponível em <<http://www.dpi.inpe.br/spring/portugues/tutorial/classific.html>>. Acesso em ago.2006.

IPPOLITI, G.; GAGGERO, M.R.; COSTA, L.M.. Classificação digital de fotografias verticais para estimativa da cobertura do solo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte-MG. Anais... São José dos Campos: INPE, 2003.

JANSSEN, L.L.F.; VAN DER WEL, F.J.M. Accuracy assessment of satellite derived land-cover data: a review. Photogrammetric Engineering and Remote Sensing, Bethesda, v.60, n.4. p.419-426, abr.1994.

JOHNSON, G.A., MORTENSEN, D.A., MARTIN, A.R. A simulation of herbicide use based on weed spatial distribution. Weed Research, v.35, n.3. p.197-205, jun.1995.

JORGE, L. A. C. Determinação da cobertura do solo em fotografias aéreas do Projeto ARARA. 2001. Dissertação (Mestrado em Ciências) – ICMC, Universidade de São Paulo, São Carlos, SP. 97p.

JORGE, L. A. C. Circular técnica n.18: Metodologia para utilização de aeromodelos em monitoramento aéreo: Análise de Imagens. São Carlos, SP: Embrapa Instrumentação Agropecuária, 2003. 11p.

JORGE, L. A. C.; SOUZA, N. P.; TRINDADE JÚNIOR, O.; TOZZI, C. L.; NETO, A. T. Studies of Soil Conservation for Precision Farming by Digital Color Image Analysis. In: ASAE/CSAE-SCGR ANNUAL INTERNATIONAL MEETING, 1999, Toronto. Proceedings... Toronto, Canada: [s. n.], 1999.

JORGE, L. A. C.; TRINDADE JÚNIOR, O. Circular técnica n.15: Metodologia para utilização de aeromodelos em monitoramento aéreo. São Carlos, SP: Embrapa Instrumentação Agropecuária, 2002. 6 p.

KANDEL, E.R.; SCHWARTZ, J.H.; JESSELL, T.M. Principles of neural science. 4.ed. New York: McGraw-Hill, 2000. 1414p.

KARAM, D., MELHORANÇA, A.L., OLIVEIRA, M.F. Circular Técnica n.79: Plantas daninhas na cultura do milho. Sete Lagoas – MG: Embrapa Milho e Sorgo, dez. 2006.

KARLSSON, A. Classification of high resolution satellite images. 2003. Thesis (Master of Science in Engineering Physics) - Chalmers University of Technology, Göteborg, Sweden. 49p.

KAVDIR, I. Discrimination of sunflower, weed and soil by artificial neural networks. Computers and Electronics in Agriculture, v.44, p.153-160, 2004.

KOMURA, R.; KUBO, M.; MURAMOTO, K. Delineation of tree crown in high resolution satellite image using circle expression and watershed algorithm. In: IGARSS – INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 24., sept.2004, Anchorage, Alaska. Proceedings... New Jersey: IEEE, 2004. p.1577-1580.

KOVÁCS, Z.L. Redes neurais artificiais: fundamentos e aplicações. São Paulo: Acadêmica, 1996. 163p.

LACRUZ, M.S.P. Sensoriamento remoto e sistemas de informação geográfica como subsídio para levantamentos fisionômico-estruturais em floresta tropical úmida – estudo de caso: Estação Científica Ferreira Penna, PA. 2003. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos, SP. 111p. INPE-6824-TDI/644.

LAMBERT, D.; LOWENBERG DE BOER, J. Precision agriculture profitability review. Site Specific Management Center, School of Agriculture Purdue University, 2000. Disponível em <<http://mollisol.sgry.purdue.edu/SSMC>>.

LUTMAN, P.J.W.; PERRY, N.H. Methods of weeds patch detection in cereal crops. In: THE BRIGHTON CROP PROTECTION CONFERENCE, 1999, Brighton. Weeds Proceedings. Brighton: s.ed., 1999. p.627-634.

MA, Z.; REDMOND, R.L. Tau coefficients for accuracy assessment of classification of remote sensing data. Photogrammetric Engineering and Remote Sensing, Bethesda, v.61, n.4, p.453-459, apr.1995.

MACHADO, M.L. Caracterização de agroecossistemas cafeeiros da Zona da Mata de Minas Gerais, usando sensoriamento remoto e sistemas de informações geográficas. 2002. Dissertação (Mestrado em Agronomia) – Universidade Federal de Lavras, Lavras, MG.

MACHADO, P.L.O.A. Agricultura de Precisão para a Recomendação de Adubação da Soja sob Plantio Direto. EMBRAPA Solos. Disponível em: <<http://www.cnps.embrapa.br/search/pesqs/proj04/proj4.html>>. Acesso em out. 2003.

MADEIRO, S.S.; OLIVEIRA, F.R.S.; ALEXANDRE, F.B.A.; LIMA NETO, F.B. Intelligent Modeling of Sugar-Cane Maturation. In: WORLD CONGRESS CONFERENCE, 4., jul. 2006. Proceedings. Orlando, USA: ASABE, 2006. Disponível em <<http://asae.frymulti.com/abstract.asp?aid=21950&t=2>>. Acesso em jan.2007.

MAREN, A.J.; HARSTON, C.T.; PAP, R.M. Handbook of neural computing applications. San Diego, Califórnia: Academic, 1990. 448p.

MENDONÇA, F.J. Uso de dados do LANDSAT para avaliação de áreas ocupadas com cana-de-açúcar no Estado de São Paulo. 1980. Dissertação (Mestrado em Sensoriamento Remoto e Aplicações) – INPE, São José dos Campos, SP. INPE-1713-TDL/023.

MOLIN, J.P. Agricultura de Precisão. Parte I: o que é e o estado da arte em sensoriamento. Engenharia Agrícola. Jaboticabal-SP, v.17, n.2, p.109-121, 1997.

MOLIN, J.P. Utilização de GPS em Agricultura de Precisão. Engenharia Agrícola, Jaboticabal-SP, v.17, n.3, p.121-132, 1998.

MOREIRA, M.A. Fundamentos do sensoriamento remoto e metodologias de aplicação. São José dos Campos: INPE, 2001. 250p.

MOREIRA, M.A.; CHEN, S.C.; LIMA, A.M. Estudo do método Uniformização de Temas (UNITOT) e análise da correlação entre áreas estimadas utilizando-se dados do Landsat e fotografias aéreas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2., maio/1982, Brasília. Anais... São José dos Campos: INPE, 1982, v.3, p.935-942.

MOURA, D.; TYBUSCH, T.M.; TAVARES, M.F.F. A agricultura familiar e a agricultura de precisão. Disponível em: <<http://www.grupomontevideo.edu.uy/mesa3/de%20moura%20et%20al.pdf>>. Acesso em out. 2003.

NASA - NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. Mission Concepts for Uninhabited Aerial Vehicles in Cryospheric Science Applications. NASA Goddard Space Flight Center / University of Kansas Remote Sensing Laboratory, feb.2005. Disponível em <<http://geo.arc.nasa.gov/uav-suborbital/docs/Krabill-FinalReport2-02-05.pdf>>. Acesso em jan.2007.

NOAA – NATIONAL OCEANIC & ATMOSPHERIC ADMINISTRATION. NOAA and partners conduct first successful unmanned aircraft hurricane observation by flying through Ophelia. NOAA Magazine, Washington, USA, set.2005. Disponível em <<http://www.noaaneews.noaa.gov/stories2005/s2508.htm>>. Acesso em jan.2007.

NOVO, E.M.L.M. Sensoriamento Remoto: princípios e aplicações. São Paulo: Edgard Blücher, 1992.

PEREIRA NETO, O.C.; VALÉRIO FILHO, M. Análise comparativa de métodos para elaboração de cartas de declividade aplicadas a estudos do meio físico. In:

SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 1993, Curitiba. Anais... São José dos Campos: INPE, 1993.

PEREIRA NETO, O.C.; GUIMARÃES, M.F.; JORGE, L.A.C. Desempenho de redes neurais na quantificação de plantas daninhas em cultura de soja. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, maio/2004, Piracicaba. Anais... Piracicaba: ESALQ, 2004.

PONZONI, F.J.; REZENDE, A.C.P. Influência da resolução espacial de imagens orbitais na identificação de elementos da paisagem em Altamira-PA. Árvore, Viçosa-MG, v.26, n.4, p.403-410, 2002.

SALVADOR, A.; ANTUNIASSI, U.R. Mapeamento da distribuição espacial da infestação de plantas daninhas na cultura do milho em plantio direto. Revista Energia na Agricultura, Botucatu-SP, v.21, n.1, p.1-17, 2006.

SCANDICRAFT. Inspeksjon. Noruega, s.d.. Disponível em <<http://www.scandicraft.com/6>>. Acesso em jan./2007.

SHAHIN, M.A.; TOLLNER, E.W.; MCCLENDON, R.W. Artificial intelligence classifiers for sorting apples based on watercore. Journal of Agriculture Engineering Research, v.79, n.3, p.265-274, 2001.

SHARVIT, N. Traffic police begin using UAVs. Globes Online Israel's Business Arena, Israel, 15 set 2005. Disponível em <<http://www.globes.co.il>>. Acesso em jan.2007.

SHIRATSUCHI, L.S. Mapeamento da variabilidade espacial das plantas daninhas com a utilização de ferramentas da agricultura de precisão. 2001. Dissertação (Mestrado em Agronomia) - ESALQ-USP, Piracicaba-SP. 96p.

SHIRATSUCHI, L.S.; CHRISTOFFOLETI, P.J.; FONTES, J.R.A. Documentos 91: Aplicação localizada de herbicidas. Planaltina-DF: EMBRAPA-Cerrados, 2003. 18p.

SHIRATSUCHI, L.S.; MOLIN, J.P.; CHRISTOFFOLETI, P.J. Mapeamento da distribuição espacial da infestação de *Panicum maximum* durante a colheita da cultura do milho. Revista Planta Daninha, Viçosa-MG, v.22, n.2, p.269-274, 2004.

SHOCK, B.M.; CARPENTER, G.A.; GOPAL, S.; WOODCOCK, C.E. ARTMAP neural network classification of land use change. In: WORLD CONGRESS OF COMPUTER IN AGRICULTURE AND NATURAL RESOURCES, 2002, Foz do Iguaçu, Brasil. Proceedings... Michigan, USA: American Society of Agricultural Engineers, 2002.

SILVA, H.P.; MATTOS, J.T.; PEREIRA NETO, M.L.. Utilização de imagens Tm/Landsat e um sistema de informações geográficas na análise do meio físico visando a avaliação de áreas litorâneas degradadas. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO, out. 2000, Florianópolis-SC. Anais... Florianópolis: UFSC, 2000. Disponível em <http://geodesia.ufsc.br/Geodesia-online/arquivo/cobrac_2000/244 /244.htm>. Acesso em jan.2006.

SOUTH, S., QI, J., LUSCH, D.P. Optimal classification methods for mapping agricultural tillage practices. Remote Sensing of Environment, New York, v.91, p.90-97, 2004.

STOLF, R. Methodology for gap evaluation on sugarcane lines. STAB, Piracicaba, v.4, n.6, p.12-20, jul./ago.1986.

STOMBAUGH, T.; MUELLER, T.G. A low-cost remote sensing platform for agriculture. Biosystems and Agricultural Engineering, College of Agriculture, University of Kentucky, s.d. Disponível em <http://www.bae.uky.edu/precag/PrecisionAg/Development_and_Assessment/phase_5/7-6.pdf>. Acesso em jan.2007.

STORY, M.; CONGALTON, R. Accuracy assessment: a user's perspective. Photogrammetric Engineering and Remote Sensing, Bethesda, v.52, n.3, p.397-399, mar.1986.

SWEDLUND, E. New drone headed for border. UAVMarketSpace, NY, USA, aug.2005. Disponível em <http://www.uavm.com/images/Predator_B_Arizona_Border_Patrol.pdf>. Acesso em jan.2007.

TAG-TACTICAL AEROSPACE GROUP. High performance Unmanned Aircraft Systems UAV VTOL technology for advanced UAS applications and payloads. Beverly Hills, CA, USA, 2007a. Disponível em <<http://www.tacticalaerospacegroup.com/index.html>>. Acesso em jan/2007.

TAG-TACTICAL AEROSPACE GROUP. Pipeline Patrol: autonomous and programmable surveillance. Beverly Hills, CA, USA, 2007b. Disponível em <http://www.tacticalaerospacegroup.com/pipeline_patrol_inspection.html>. Acesso em jan/2007.

THOMAS, I.L. Spatial postprocessing of spectrally classified Landsat data. Photogrammetric Engineering and Remote Sensing, Bethesda, v.46, n.9, p.1201-1206, 1980.

TIAN, L. Sensor-based precision chemical application systems. In: WORLD CONGRESS OF COMPUTER IN AGRICULTURE AND NATURAL RESOURCES, 2002, Foz do Iguaçu, Brasil. Proceedings... Michigan, USA: American Society of Agricultural Engineers, 2002.

TOWNSEND, F.E. The enhancement of computer classifications by logical smoothing. Photogrammetric Engineering and Remote Sensing, Bethesda, v.52, n.2, p.213-221, 1986.

TRINDADE JÚNIOR, O.; JORGE, L.A.C.; NERIS, L.O. Aeromodelos: qualidade por menos. Cultivar Máquinas, set./out.2002, p.16-20.

UAVCOLLABORATIVE. Vineyard Project. Moffett Field, California, USA. s.d. Disponível em <http://www.uav-applications.org/projects/vineyards_1.html>. Acesso em jan.2007.

UAVMARKETSPACE. Commercial and civil applications. Oyster Bay, NY, USA, s.d. Disponível em <<http://www.uavm.com/uavapplications.html>>. Acesso em jan/2007.

ULSON, J.A.C.; BOAS, R.L.V.; GODOY, L.J.G.; SOUZA, A.N. A novel intelligent system to nitrogen content prediction in plants using indirect chlorophyll measurements. In: WORLD CONGRESS OF COMPUTER IN AGRICULTURE AND NATURAL RESOURCES, 2002, Foz do Iguaçu, Brasil. Proceedings... Michigan, USA: American Society of Agricultural Engineers, 2002.

UNIVERSIDADE DE NOTTINGHAM. Flying solo. Innovation Futures, Nottingham, UK, jun. 2005. Disponível em <http://www.research.nottingham.ac.uk/Upload/Content/files/683/Innovation_Futures_11.pdf>. Acesso em jan.2007.

UNO, Y.; PRASHER, S.O.; LACROIX, R.; GOEL, P.K.; KARIMI, Y.; VIAU, A.; PATEL, R.M. Artificial neural networks to predict corn yield from compact airborne spectrographic imager data. Computers and Electronics in Agriculture, v.47, p.149-161, 2005.

VELLOSO, M.L.F.; SIMÕES, M.; CARNEIRO, T.A. Competitive artificial neural network for change-detection of land cover: an unsupervised approach. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2002, Toronto, Canada. Proceedings... New York: IEEE, 2002.

WILHELM, P.P.H.; LOPES, M.C.; DOROW, A. Sistema inteligente de apoio à decisão. Disponível em: <<http://www.inf.furb.br/~mclopes/artigos/ArtSpirit95.doc>>. Acesso em out. 2003.

WOLF, P.R. Elements of Photogrammetry. N.York: Mc Graw Hill, 1974. 563p.

YANG, C.C.; PRASHER, S.O.; LANDRY, J.A.; RAMASWAMY, H.S. Development of an herbicide application map using artificial neural networks and fuzzy logic. Agricultural Systems, v.76, p.561-574, 2003.

APÊNDICES

APÊNDICE A –

Matrizes de Erro de Classificação

Para entendimento do conteúdo dessa tabela toma-se, como exemplo, a classificação Maxver-ICM. O mapa considerado como “verdade terrestre” (classificação manual) delimita 100.701 pixels da imagem como sendo “invasora”, e desses, o classificador acertou 70.148. Houve “erro de omissão” de 28.174 pixels como “cultura” e 2.379 como “sombra”. Paralelamente, também houve “erro de inclusão” de 25.377 pixels da “cultura” e 216 da “sombra”. O raciocínio segue idêntico para toda a tabela.

		CLASSIFICAÇÃO BHATTACHARYA			
		invasora	cultura	sombra	soma linha
VERDADE TERRESTRE	invasora	71.314	26.948	2.439	100.701
	cultura	18.583	843.772	190.023	1.052.378
	sombra	550	67.259	244.802	312.611
	soma coluna	90.447	937.979	437.264	1.465.690

		CLASSIF. DISTÂNCIA EUCLIDIANA			
		invasora	cultura	sombra	soma linha
VERDADE TERRESTRE	invasora	68.372	29.454	2.875	100.701
	cultura	29.857	731.579	290.942	1.052.378
	sombra	262	24.090	288.259	312.611
	soma coluna	98.491	785.123	582.076	1.465.690

		CLASSIFICAÇÃO MAXVER			
		invasora	cultura	sombra	soma linha
VERDADE TERRESTRE	invasora	70.042	28.284	2.375	100.701
	cultura	25.287	763.643	263.448	1.052.378
	sombra	209	27.525	284.877	312.611
	soma coluna	95.538	819.452	550.700	1.465.690


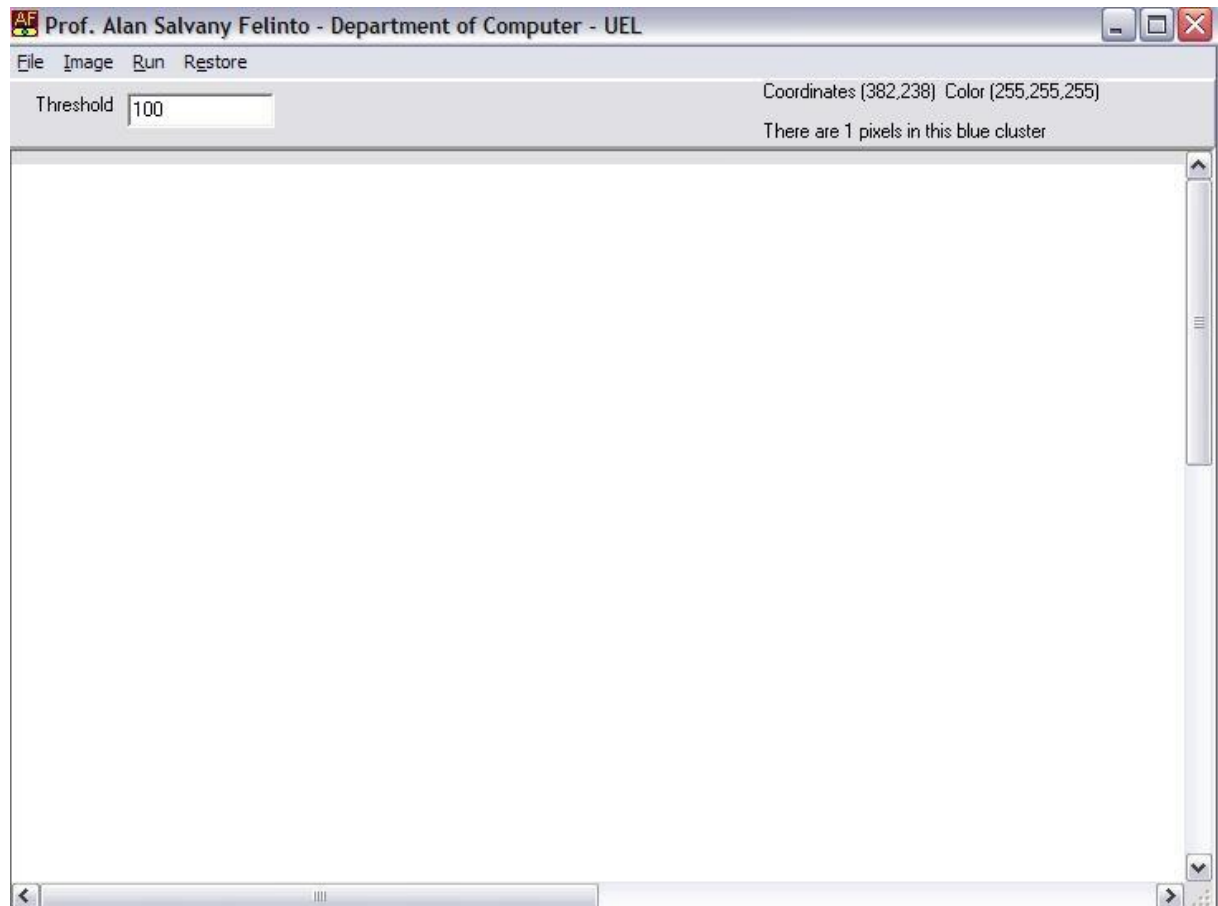
		CLASSIFICAÇÃO MAXVER-ICM			
		invasora	cultura	sombra	soma linha
VERDADE TERRESTRE	invasora	70.148	28.174	2.379	100.701
	cultura	25.377	764.479	262.522	1.052.378
	sombra	216	27.633	284.762	312.611
	soma coluna	95.741	820.286	549.663	1.465.690

		CLASSIFICAÇÃO REDES NEURAIIS			
		invasora	cultura	sombra	soma linha
VERDADE TERRESTRE	invasora	66.112	32.294	2.295	100.701
	cultura	23.153	874.870	154.355	1.052.378
	sombra	768	82.581	229.262	312.611
	soma coluna	90.033	989.745	385.912	1.465.690


APÊNDICE B –

Software FillGap

Aspecto geral do software:



Menu FILE: carrega uma imagem BMP, limpa a tela e salva a imagem em BMP.



Menu IMAGE: Processa a imagem tema por tema, acompanhando as mudanças.

Run Restore

Menu RUN: Processa toda a imagem de uma vez.
Menu RESTORE: Desfaz o processo.

Threshold

Input THRESHOLD: entrar tamanho máximo de polígono a ser uniformizado (em número de pixels).

Coordinates (32,11) Color (255,255,255)

There are 38424 pixels in this blue cluster

Apresenta coordenadas do pixel (em lin/col), sua cor (em RGB) e a quantidade de pixels de qualquer polígono da imagem.

--- XX ---