

ROBERTO CARLOS ORLANDO

**SISTEMA DE VISÃO ARTIFICIAL PARA DISCRIMINAÇÃO ENTRE  
PLANTAS DANINHAS E MILHO**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de "*Doctor Scientiae*".

VIÇOSA  
MINAS GERAIS – BRASIL  
2003

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

T

O71s  
2003

Orlando, Roberto Carlos, 1972-

Sistema de visão artificial para discriminação entre plantas daninhas e milho / Roberto Carlos Orlando.  
– Viçosa : UFV, 2003  
85p. : il.

Orientador: Francisco de Assis de Carvalho Pinto  
Tese (doutorado) – Universidade Federal de Viçosa

1. Erva daninha - Identificação. 2. Processamento de imagens. 3. Inteligência artificial. 4. Máquinas agrícolas - Automação. 5. Agricultura de precisão. I. Universidade Federal de Viçosa. II. Título.

CDD 19.ed. 632.5

CDD 20.ed. 632.5

ROBERTO CARLOS ORLANDO

**SISTEMA DE VISÃO ARTIFICIAL PARA DISCRIMINAÇÃO ENTRE  
PLANTAS DANINHAS E MILHO**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de "*Doctor Scientiae*".

APROVADA: 22 de março de 2003.

---

Prof. Ricardo Capúcio Resende

---

Dr. Décio Karam

---

Prof. Nerilson Terra Santos  
(Conselheiro)

---

Prof. Daniel Marçal de Queiroz  
(Conselheiro)

---

Prof. Francisco de Assis de Carvalho Pinto  
(Orientador)

À minha esposa Gislaine, e  
À minha filha Roberta  
Com amor.

## AGRADECIMENTO

A Deus, por tudo.

A meus pais pela vida e aos meus irmãos pelo apoio.

Ao professor Francisco de Assis de Carvalho Pinto, pela orientação e amizade ao longo do curso.

À Universidade Federal de Viçosa, por intermédio do Departamento de Engenharia Agrícola, pela oportunidade.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos nos primeiros 2,5 anos.

Ao Banco Mundial e Embrapa, através do Projeto de Apoio ao Desenvolvimento de Tecnologia Agropecuária para o Brasil (PRODETAB), pelos recursos financeiros para o desenvolvimento da pesquisa.

Aos pesquisadores da Embrapa milho e Sorgo, Dr. Evandro Mantovani e Dr. Décio Karam.

A Universidade Regional Integrada do Alto Uruguai e das Missões-Campus de Erechim, pela liberação sempre que necessitei.

Ao Professor Daniel Marçal de Queiroz pela colaboração e orientação nos primeiros anos do curso.

Aos conselheiros, pelas valiosas sugestões.

Aos demais colegas da pós-graduação, especialmente ao Darly pelo apoio nos trabalhos de campo.

Aos colegas de trabalho da URI-Campus de Erechim.

A todos que, de uma forma ou de outra, contribuíram para a realização deste trabalho.

## BIOGRAFIA

ROBERTO CARLOS ORLANDO, filho de Olivo Orlando e Santina Fracasso Orlando, nasceu em Sananduva, Rio Grande do Sul, no dia 24 de setembro de 1972.

Em março de 1992 iniciou o curso de Engenharia Agrícola na Universidade Estadual do Oeste do Paraná – UNIOESTE – Campus de Cascavel, Paraná, o qual concluiu em dezembro de 1996.

Em março de 1997, iniciou o curso de Mestrado em Engenharia Agrícola, área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa, Minas Gerais, defendendo a dissertação em março de 1999.

Em abril de 1999 iniciou o curso de Doutorado na mesma instituição, defendendo tese em março de 2003.

No mês de agosto de 2001 foi contratado como professor, no curso de Engenharia Agrícola, pela Universidade Regional Integrada do Alto Uruguai e das Missões-Campus de Erechim-RS.

## ÍNDICE

RESUMO .....	vii
ABSTRACT .....	ix
1. INTRODUÇÃO .....	1
2. REVISÃO BIBLIOGRÁFICA .....	6
2.1 Mapeamento de plantas daninhas .....	6
2.2 Análise textural.....	9
2.2.1 Matriz de co-ocorrência .....	11
2.3 Dimensão da matriz de co-ocorrência .....	13
2.4 Estádio de maturação da planta.....	14
2.5 Tamanho de sub-blocos da imagem .....	15
2.6. Classificadores estatísticos .....	16
2.7 Classificadores Neuroniais.....	16
3. MATERIAL E MÉTODOS.....	21
3.1 Escolha das espécies de plantas .....	21
3.2 Aquisição das imagens .....	22
3.2.1 Variação da iluminação .....	24
3.2.2 Dias após a emergência.....	25
3.2.3 Altura da câmera.....	25
3.3 Pré-processamento das imagens.....	26
3.3.1 Dimensões dos sub-blocos da imagem.....	26
3.3.2 Realce e Normalização .....	27
3.3.3 Discretização do valor do pixel.....	27
3.4 Processamento das imagens .....	28

3.5 Classificação .....	31
3.5.2 Classificador estatístico.....	31
3.5.1 Classificador Neuronal.....	33
3.6 Seleção dos níveis dos fatores em estudo .....	35
3.6.1 Definição da dimensão dos sub-blocos para cada tipo de imagem...	36
3.6.2 Definição do nível da discretização dos valores dos pixels para cada tipo de imagem.....	37
3.6.3 Definição da altura da câmera.....	37
3.6.4 Definição do tipo de imagem da câmera .....	37
3.6.5 Definição do tipo de classificador .....	38
4. RESULTADOS E DISCUSSÕES .....	39
4.1) Tipos de imagens coletadas.....	39
4.2 Dimensão dos sub-blocos das imagens .....	44
4.3 Definição do nível da discretização dos valores dos pixels .....	46
4.4 Definição da altura da câmera.....	48
4.5 Definição do tipo de imagem .....	50
4.6 Definição do tipo de classificador .....	54
5. RESUMO E CONCLUSÕES .....	57
6. SUGESTÕES PARA TRABALHOS FUTUROS .....	59
7. REFERÊNCIAS BIBLIOGRÁFICAS .....	60
APÊNDICES .....	68



## RESUMO

ORLANDO, Roberto Carlos, D.S., Universidade Federal de Viçosa, março de 2003. **Sistema de Visão Artificial para discriminação entre plantas daninhas e milho.** Orientador: Francisco de Assis de Carvalho Pinto. Conselheiros: Daniel Marçal de Queiroz, Nerilson Terra Santos e Evandro Chartuni Mantovani.

A agricultura de precisão busca adequar as práticas agrícolas às exigências e potencial produtivo de parcelas dos talhões, objetivando maximizar o lucro, racionalizar o uso dos fatores de produção e reduzir a contaminação ambiental. Esses objetivos estão condicionados ao desenvolvimento de técnicas capazes de operacionalizá-los. As técnicas de Visão Artificial podem trazer benefícios, principalmente, na racionalização do uso de herbicidas que é uma das maiores fontes de custos e de contaminação ambiental. O objetivo do presente trabalho foi desenvolver e avaliar um sistema para identificação de plantas daninhas e milho, utilizando imagens digitais coloridas e monocromáticas. Foram obtidas imagens de plantas de Picão Preto (*Bidens pilosa* L.), Leiteira, (*Euphorbia heterophylla* L.), Capim-milhã (*Digitaria horizontalis* Willd), Timbête (*Cenchrus echinatus* L.) e milho (*Zea mays*). Para a classificação das plantas utilizou-se análise textural com base na técnica da matriz de co-ocorrência de sub-blocos das imagens. Das matrizes de co-ocorrência retirou-se oito parâmetros texturais, os quais foram utilizados com dados de entrada em um classificador. Foram testados quatro classificadores (um estatístico e três neuronais). Foram testados fatores que podem interferir na classificação automática de plantas daninhas por um sistema de visão artificial: três dimensões de sub-bloco da imagem (17 x 17, 34 x 34, 68 x 68

pixels), quatro níveis de valores numéricos de pixels (32, 64, 128 e 256 níveis), três alturas da câmera (1,32 m, 1,58 m, 2,04 m para a câmera CIR/RGB e 1,35, 1,61, 2,04 m para a monocromática) quatro tipos de imagens (verde, excesso de verde, falsa cor infravermelha e monocromática), três diferentes números de dias após a emergência (22 DAE, 25 DAE, 29 DAE) e quatro níveis de iluminação (600, 700, 800 e 900 W). Inicialmente foram fixadas as variáveis dias após a emergência (29 dias), nível de iluminação (900 W) e classificador estatístico para testar os parâmetros dimensões do sub-bloco, número de níveis de valores de pixel e altura da câmera somente para. As combinações de variáveis que apresentaram melhores exatidões na classificação foram escolhidas para definir o melhor tipo de imagem por meio da influência de diferentes níveis de iluminação. Por fim, comparou-se a performance dos quatro classificadores para os diferentes dias após a emergência. Os resultados obtidos indicaram que: a) Dadas as condições metodológicas do estudo, os melhores valores da exatidão global, em todas as combinações dos fatores estudados tenderam a ocorrer para o tamanho de sub-bloco 68 x 68 pixels; b) a variação dos níveis de cinza aparentemente não alterou a classificação, definindo-se pelo menor número de níveis (32 níveis); c) a altura da câmera de 2,04 m tendeu a resultar em melhores valores de exatidão global; d) para a câmera CIR/RGB a imagem que tendeu a apresentar os melhores resultados de exatidão global foi a imagem de excesso de verde; e) imagem monocromática tendeu a apresentar valores superiores a imagem excesso de verde da câmera CIR/RGB; f) O classificador neuronal com maior número de neurônios (arq10\_10) aparentemente apresentou os melhores resultados de exatidão global tanto para a imagem monocromática (86,5%) como para a imagem excesso de verde (86,2%); g) As exatidões globais alcançadas pelo classificador estatístico tenderam a ser inferiores aos resultados obtidos pelo classificador neuronal para os dois tipos de imagens testadas, 77,5% e 80,1% para a imagem monocromática e excesso de verde, respectivamente.

## ABSTRACT

ORLANDO, Roberto Carlos, D.S., Universidade Federal de Viçosa, march of 2003. **Machine vision system for automatic discrimination of weed and corn.** Adviser: Francisco de Assis de Carvalho Pinto. Committee members: Daniel Marçal de Queiroz, Nerilson Terra Santos and Evandro Chartuni Mantovani.

Precision farming looks up to adjust the agricultural practices to the parcels demands and productive potential to maximize the profit, rationalize the use of the product factors and reduce the environmental damage. Those objectives are conditioned to the development of techniques capable of make them viable. Machine Vision techniques can bring benefits mainly in the rationing herbicides use. The herbicides are one of the largest sources of costs and environmental damage. The goal of the present work was to develop and evaluate a weeds and corn identification system, using color and monochromatic digital images. Images of plants of picão preto (*Bidens pilosa* L.), leiteira (*Euphorbia heterophylla* L.), capim-milhã (*Digitaria horizontalis* Willd) and timbête (*Cenchrus echinatus* L.) and corn (*Zea mays*) were obtained. Two of the weed species were crabgrass, Timbete and Capim-milhã, and the other two were broadleaf Picão Preto and leiteira. A co-occurrence matrix technique was used to classify sub-blocks of plant images. Eight textural features were obtained from the co-occurrence matrixes and used with input in four types of classifiers (one statistic and three neural). Some factors that can interfere in the automatic classification of weed plants for machine vision system were tested. The tested factors were: three block sizes (17 x 17 pixels, 34 x 34 pixels, 68 x

68 pixels), three bands of a RGB camera (green, green excess and near-infrared), two cameras (monochromatic and RGB), four grayscale levels (32, 64, 128 and 256 levels), three different days after the emergency (22 DAE, 25 DAE, 29 DAE), three distances of the camera (1,32 m, 1,58 m, 2,04 m) and four illumination levels (600, 700, 800 and 900 W). Initially the parameters sub-block size, the grayscale level and the camera height were defined to 29 days after the emergence, the illumination level of 900 W and statistical classifier. The parameter combinations that presented the best classification accuracy were choose to define the best kind of image by studing the influence of the different illumination levels. At the end, the four classifiers performance were compared to the different days after the emergence. The results indicated that: a) the better global accuracy, in all the studied factor combinations, occurred for 68 x 68 pixels block; b) the gray level variations apparently didn't alter the classification, and the smalles level number (32 levels) was defined; c) the camera height of 2,04 m resulted in better values of global accuracy; d) for the CIR/RGB camera, the image that presented the best results of global accuracy was the green excess image; e) the monochromatic image presented superior values than the green excess image of the CIR/RGB camera; f) the neural classifier with the liggest number of neurons (arq 10-10) presented the best results of global accuracy for monochromatic image (86,5%) as well as for green excess image (86,2%); g) the global accuracy of the statistic classifier tend to be smaller than those of the neural classifier for the two kinds of image tested; 77,5% and 80,1% for monochromatic image and green excess, respectively.

## 1. INTRODUÇÃO

No Brasil e no mundo, a partir da década de 70, com a chamada revolução verde, houve grande avanço tecnológico na área agrônômica, com a disponibilização de novas cultivares para diferentes ambientes, desbravamento e a incorporação de novas fronteiras de produção, domínio da recomendação de fertilizantes para diferentes tipos de solo e eficiente controle químico de plantas daninhas, insetos e doenças. Entretanto, problemas decorrentes da utilização dessas tecnologias não deixaram de existir, como contaminação do meio ambiente, desperdício na utilização de insumos e falta de racionalização dos processos de perdas (MANTOVANI, 2000).

A competitividade e as exigências do mercado consumidor têm pressionado o setor agrícola a buscar maior eficiência na produção. Além disso, a busca pela conservação dos recursos naturais, diminuindo tanto quanto possível a poluição do meio ambiente, é outro fator que tem motivado a procura de melhor gerenciamento do processo produtivo da agricultura, visando competitividade e controle dos problemas ambientais causados pela agricultura, que envolvem a qualidade da água, do ar e dos alimentos. As aplicações convencionais de fertilizantes e defensivos baseadas nas necessidades médias vêm sendo objeto de pesquisa, visando melhorar sua execução. Essas aplicações significam, muitas vezes, aplicações excessivas em algumas áreas do campo e insuficientes em outras, pois uma área dificilmente é uniforme. Dessa maneira, as aplicações excessivas dos insumos podem tornar-se fontes de contaminação das águas subterrâneas e superficiais (ZHANG e CHAISATTAPAGON, 1995).

Para FELTON et al. (1991), o aumento substancial no uso de herbicidas tem sido uma tendência crescente para compensar as deficiências do controle mecânico tradicional. No ano de 2000 no Brasil, os gastos com herbicidas totalizaram U\$\$ 1,30 bilhões. Em termos médios, cerca de 20-30% do custo de produção deve-se ao controle de plantas daninhas (SINDAG, 2002; NEVES et al., 2002).

Pesquisadores têm buscado meios para reduzir a quantidade de defensivos aplicados e o impacto sobre o meio ambiente (WILLIS e STOLLER, 1990; CHANCELLOR e GORONEA, 1993; TIAN et al., 1999). Estes pesquisadores estudaram a variabilidade espacial das plantas daninhas com o objetivo de diminuir o volume aplicado através do mapeamento das áreas infestadas ao longo dos anos.

HUMMEL e STOLLER (2002) comparando os gastos com herbicida para a aplicação convencional e a taxa variada, em diferentes densidades de infestação por plantas daninhas, observaram que a redução de custo tende a diminuir com o aumento da densidade de plantas sendo que a redução devido à aplicação diferenciada foi, em média, de US\$ 7,0 por hectare.

Em muitos segmentos ligados a produção agrícola, seja os fabricantes de agroquímicos, o desenvolvimento produtos seletivos de baixa toxicidade e mobilidade reduzida; ou busca de cultivares mais competitivos; ou inovações presentes na tecnologia de aplicação, nota-se a preocupação com a necessidade de desenvolvimento de técnicas conservacionistas que sejam economicamente viáveis. Entretanto, a maioria dessas inovações desconsidera a variabilidade espacial da infestação tratando a área de maneira uniforme.

A Agricultura de Precisão é uma ferramenta que permite o uso de tecnologias atuais para o manejo do solo, insumos e culturas de modo adequado as variações espaciais e temporais em fatores que afetam a produtividade das culturas e o meio ambiente. A agricultura de precisão pode ser conceituada como a habilidade em monitorar e acessar a atividade agrícola em sítios específicos, com o objetivo de aumentar a eficiência do processo produtivo (QUEIROZ et al., 2000).

THOMPSON et al. (1990) afirmam que é possível reduzir o volume aplicando baixas doses, por meio por um sistema de aplicação mais eficiente e, pela utilização de defensivos somente nas áreas infestadas.

ROBERT (2002) revisou 108 estudos dedicados a análise da viabilidade econômica da adoção da Agricultura de Precisão, verificando que em 63% dos casos a adoção resultou em benefícios, em 26% dos casos não houve melhora e em 11% os resultados foram negativos. Entretanto, as análises não consideraram os benefícios do ganho tecnológico e ambiental devido a dificuldade de quantificá-los.

O conceito de agricultura de precisão é muito difícil de ser aplicado em muitas operações de campo, destacando, que o controle diferenciado de plantas daninhas é uma das operações mais difíceis e que a prática tradicional de controle químico é uma das principais causas da contaminação do solo, das águas superficiais e do lençol freático (TIAN, 2002).

O mapeamento da ocorrência de plantas daninhas pode ser feito utilizando técnicas que incluem a utilização do GPS através de um veículo dedicado a amostragem, durante a colheita, amostragem intensiva do campo (grade ou pontos) ou por imagens aéreas. Porém, estas técnicas, apesar de se mostrarem capazes, o tempo para processamento e interpretação dos mapas, e seu custo tem limitado seu uso comercial.

Dentre as ferramentas utilizadas na agricultura de precisão destaca-se o potencial do sensoriamento remoto, muito utilizado para o mapeamento de áreas de cultura e estimação do rendimento das mesmas. Entretanto, nos últimos anos a pesquisa tem sido direcionada para o monitoramento das condições da cultura como, por exemplo, a identificação de deficiências nutricionais em plantas, a ocorrência de pragas e doenças, a classificação e quantificação de plantas daninhas, dentre outros, que podem ser facilmente incorporadas às práticas de agricultura de precisão (GOEL et al., 2000). A detecção de plantas daninhas através do sensoriamento remoto orbital ainda possui limitações quanto a resolução espacial e temporal. Acredita-se que existe potencial para utilização de sistemas de visão artificial (SVA) como sensores para coleta de dados em agricultura de precisão (PINTO et al., 2001). Esse tipo de sistema é constituído, basicamente, por uma câmera conectada a um computador por meio de uma placa de aquisição de vídeo, e por programas computacionais específicos de processamento de imagens para extração das informações desejadas.

Para MARQUES FILHO e VIEIRA NETO (1999), os SVAs, dentre outras funções, têm a capacidade de obter e fazer o reconhecimento automático de informações extraídas de uma cena, ou seja, os SVAs tentam dotar máquinas com uma capacidade visual semelhante a dos seres humanos. Segundo estes mesmos autores, esses sistemas realizam basicamente as seguintes etapas: aquisição da imagem, pré-processamento, segmentação, extração de características, reconhecimento e interpretação.

O desenvolvimento de SVAs capazes de reconhecer e distinguir regiões infestadas pode resultar na redução substancial do volume de defensivos aplicados, já que, este está diretamente ligado à magnitude da infestação.

O processo de desenvolvimento de um SVA passa necessariamente por três distintas fases. Primeiramente, coleta-se imagens digitais. Posteriormente, extrai-se das imagens as características descritoras das diferentes espécies de plantas. Na fase seguinte as características descritoras serão os dados de entrada no algoritmo de classificação, o qual é utilizado na terceira etapa.

Embora seja possível diferenciar três diferentes etapas no processo de desenvolvimento do sistema de classificação, estas estão interligadas. A adoção de uma técnica ou outra em cada fase do desenvolvimento do sistema de visão artificial depende de inúmeros fatores inerentes ao problema estudado.

Com a finalidade de explorar o potencial dessa tecnologia na agricultura, o Departamento de Engenharia Agrícola da Universidade Federal de Viçosa (DEA-UFV), juntamente com outras seis instituições, participa de um Projeto de Apoio ao Desenvolvimento de Tecnologia Agropecuária para o Brasil (PRODETAB), sob o tema desenvolvimento, ajuste e aplicação de técnicas de agricultura de precisão para o aumento de eficiência e redução de impactos ambientais de sistemas de produção agrícola sob condições de plantio direto (PRODETAB 030). Dessa maneira, este trabalho está inserido dentro dos objetivos do Subprojeto 02 do PRODETAB 030 que visa a utilização de “Técnicas de sensoriamento remoto para monitoramento espaço-temporal de variáveis do sistema de produção”.

Em face da inexistência de estudos que considerem características de plantas daninhas brasileiras, bem como, os vários fatores que influenciam na performance de um sistema de visão artificial, este trabalho teve como objetivos:



- Identificar qual dimensão de sub-bloco da imagem, níveis de valores numéricos dos pixels e altura da câmera que resultam em uma melhor classificação das espécies de plantas daninhas;
- Identificar, para as câmeras CIR/RGB e monocromática, qual tipo de imagem (verde, infravermelho, excesso de verde e monocromática) resultou em uma melhor classificação em diferentes condições de iluminação;
- Desenvolver, testar e comparar quatro classificadores de plantas daninhas e milho, sendo um estatístico e três neuronais.

## **2. REVISÃO BIBLIOGRÁFICA**

### **2.1 Mapeamento de plantas daninhas**

O mapeamento da ocorrência de plantas daninhas pode ser feito utilizando técnicas que incluem a utilização do GPS através de um veículo dedicado a amostragem, caminhamento, durante a colheita ou amostragem intensiva do campo. Porém, estas técnicas, apesar de se mostrarem capazes, o tempo de mapeamento, custo e por ser uma atividade laboriosa tem limitado uso comercial (LAMB e BROWN, 2001; SALVADOR, 2002).

Os avanços em processamento de imagens, o sensoriamento remoto, particularmente quando se faz uso das imagens digitais não orbitais, passou a ser uma importante ferramenta de estudo da variabilidade espacial das culturas e das plantas daninhas, podendo resultar em equipamentos para o manejo localizado de culturas em tempo real.

As técnicas de visão artificial têm sido usadas na área agrícola principalmente como mecanismo de inspeção da qualidade dos produtos (PARK et al., 1998; BASSET et al., 2000; PARK e CHEN, 2001), mas sempre se mostram como ferramentas potenciais para a identificação de plantas daninhas, como pode ser observado nos trabalhos de THOMPSON et al. (1990), WILLIS e STOLLER (1990), FELTON et al. (1991), WANG et al. (2000), ALVES et al. (2002), TIAN et al. (1999) e BURKS et al. (1998). Esses estudos têm como objetivo fundamental a redução de custos em função da redução do volume de herbicida aplicado nas áreas de produção agrícola, devido a

pressões sociais e leis que exigem a diminuição da aplicação desses defensivos.

Segundo TIAN et al. (1999), pesquisas realizadas nos Estados Unidos têm mostrado que a percentagem de infestação por planta daninha pode variar entre 21 e 73% em relação ao total da área cultivada. Nessas situações, o gerenciamento espacial e os sistemas de aplicações localizadas possuem grande potencial de diminuição do uso de defensivos agrícolas. O desenvolvimento dessa tecnologia pode trazer consideráveis acréscimos à viabilidade da produção agrícola e à redução de riscos ao meio ambiente.

Sabe-se que a ocorrência de algumas espécies de plantas daninhas se dá em reboleiras, devido à forma de propagação das mesmas. Entretanto, por questões técnicas, a aplicação de defensivos é feita em toda a área, não levando em consideração essa ocorrência desigual. Recentemente estudos guiados pela idéia de agricultura de precisão têm permitido o mapeamento da ocorrência de plantas daninhas (LAMB e BROWN, 2001; NORDMEYER et al., 1997).

BROWN e STECKLER (1995) trabalharam com imagens aéreas com altitude aproximada de 900m e segmentação baseada na cor para identificar e mapear três diferentes espécies de plantas invasoras, com a finalidade de gerar mapas de aplicação diferenciada, objetivando a redução do uso de defensivos em uma lavoura de milho sob plantio direto. Os estudos mostraram que a identificação de plantas daninhas via fotos aéreas é viável e que a redução na quantidade total de herbicidas foi de 40%.

Para NUSPL et al. (1996), é possível uma economia de herbicida na ordem de 30 a 80% quando se utiliza o controle localizado de plantas daninhas em áreas mapeadas, comparada a aplicação em área total. A aplicação localizada de defensivos pode ser realizada por equipamentos capazes de identificar e controlar a planta daninha em tempo real ou por equipamentos que realizam a aplicação de acordo com um mapa de prescrição.

BALASTREIRE e BAIO (2002) mapearam as manchas de ocorrência das plantas daninhas com o auxílio de um DGPS, anotando as espécies de plantas daninhas presentes e o seu estágio de desenvolvimento. Por meio desse mapeamento foi gerado um mapa de aplicação para uma área de 9,8 ha. A aplicação diferenciada representou uma economia de 31,6% de herbicida,

quando comparado à aplicação em área total, ilustrando, assim, o potencial desta tecnologia.

A técnica de segmentação baseada na frequência espacial, utilizando transformada de Fourier, foi usada nos trabalhos desenvolvidos por SU et al. (1997) e TANG et al. (1999) para o reconhecimento de plantas daninhas. Estes pesquisadores relataram que o baixo tempo computacional e a possibilidade de utilização de equipamentos mais baratos são as principais justificativas desse método que se baseia na discriminação textural entre as plantas.

A viabilidade da aplicação de imagens para a identificação de plantas daninhas e mapeamento das áreas infestadas é fortemente influenciada por fatores como: radiação incidente, espécie, densidade e estágio de crescimento das plantas (SU et al., 1997).

STEWART e TIAN (1998) utilizaram câmeras de vídeo fixadas a uma estrutura metálica montada sobre um trator para desenvolver um sistema de identificação, em tempo real, de plantas daninhas na cultura da soja. Os resultados obtidos mostram que o algoritmo utilizado apresentou alto índice de acerto e baixo tempo computacional.

WANG et al. (2000) realizaram o mapeamento de plantas daninhas na cultura do trigo, em laboratório e a campo, utilizando sensores óticos, para as classes de solo nu, trigo e planta daninha. Para as condições de laboratório verificaram que durante o treinamento do classificador, 100% das amostras de solo e de trigo em todas as suas densidades foram classificadas corretamente. Já para a classe plantas daninhas, apenas 58.7% foram classificadas corretamente. Nas condições de campo considerando apenas duas classes, plantas daninhas e trigo, os resultados obtidos variaram entre 87% a 98%, sendo que o menor valor ocorreu para a classe plantas daninhas.

## 2.2 Análise textural

De acordo com TANG et al. (1999), as pesquisas em identificação e classificação de plantas daninhas baseiam-se em duas categorias: características de forma e textura da planta. As que utilizam forma tem sua utilização limitada à análise individual da planta ou da folha da planta, o que somente é possível em plantas jovens e com baixa densidade de infestação. Segundo os autores, a utilização de características texturais derivadas da matriz de co-ocorrência tem conseguido classificações com acurácia de 93% e 85% para folhas largas e estreitas, respectivamente. Porém, para classificação individual de espécies a acurácia tem variado entre 30% e 77%.

Segundo FAN et al. (1998), a utilização de imagens para a detecção de plantas invasoras tem sido feita com base na forma, textura e cor para determinar características de cada espécie. No entanto, a identificação de plantas pela forma, principalmente da folha, apresenta problemas devido à sobreposição, diferentes orientações e movimentos provocados pelo vento. Por esse motivo, apenas a textura e as informações de cor vêm merecendo maiores atenções no desenvolvimento de algoritmos para segmentação das plantas daninhas dos outros objetos na imagem.

LEE e SLAUGHTER (1998) utilizaram parâmetros de forma na identificação de quatro diferentes classes, três de tomate e uma de plantas daninhas. Utilizando um classificador estatístico e outro neuronal, verificaram que ambos apresentaram resultados pouco promissores em pelo menos duas das quatro classes. A baixa acurácia dos classificadores foi devido à sobreposição das folhas das plantas.

HEMMING e RATH (2001) desenvolveram um algoritmo de classificação com base em oito diferentes características morfológicas e três características de cor de imagens de plantas daninhas, obtidas em condições de campo com iluminação controlada. O algoritmo de classificação baseado em lógica "Fuzzy" mostrou-se capaz de segmentar completamente plantas daninhas do solo. Porém, a classificação das diferentes espécies de plantas daninhas foi significativamente influenciada pelo estágio de crescimento e densidade de plantas, variando de 51 a 95 % a classificação correta.

FAN et al. (1998) citam que a classificação baseada em análise textural pode ser influenciada pelo mau ajuste do foco da câmera e pela movimentação da folha da planta. No caso do movimento foliar este pode ser eliminado se a taxa de captura da câmera for elevada.

A análise textural de imagens vem sendo usada nas áreas agrícolas e de alimentos principalmente na seleção e controle de qualidade. A principal proposta da análise textural é mapear diferenças na estrutura espacial em diferentes níveis de cor ou de cinza para serem posteriormente separadas em áreas homogêneas (TODD e HANS DU BUF, 1993),

Para PARK e CHEN (2001), a análise textural é o método mais robusto para a medida da intensidade da cor ou dos níveis de cinza porque contém informações estatísticas no domínio espacial independentemente do tom da imagem. Além disso, muitos dos descritores das características texturais, como, momento angular, entropia, soma e diferenças da entropia são invariáveis com a translação, rotação ou escala da imagem.

PARK e CHEN (2001) utilizaram a análise textural na identificação de defeitos em carcaças de frango, com base em imagens multiespectrais, utilizando diferentes distâncias entre vizinhos e treze diferentes descritores texturais. Esses pesquisadores observaram que os melhores descritores foram: variância, soma das médias, soma da variância e soma da entropia.

Em BURKS et al. (1998) foi testada a análise estatística discriminante tradicional na classificação de seis diferentes classes, utilizando parâmetros texturais de imagens coloridas. Os resultados mostraram que a técnica utilizada foi capaz de separar as classes com acurácia de até 93% usando apenas a matiz e a saturação. Segundo os autores, a principal contribuição do trabalho foi a retirada dos parâmetros texturais derivados da intensividade, sem que essa eliminação prejudicasse significativamente a classificação dos modelos, permitindo ainda, a redução em um terço do tempo computacional.

EL-FAKI et al. (2000a) afirmam que métodos baseados na cor são mais eficientes do que os que utilizam análises texturais ou forma, por serem pouco influenciados pela sobreposição e orientação das folhas, foco da câmera e efeito do vento. Entretanto, salienta que a utilização direta dos níveis de cor é inadequada porque são fortemente influenciados pela iluminação, sendo necessário a criação de índices relativos adequados para cada uma das

classes de interesse. Os índices de maior significância foram utilizados na função discriminante e também em um classificador com base em rede neuronal artificial, o qual apresentou menor acurácia que o anterior. Os pesquisadores concluíram que o estágio de desenvolvimento da cultura, deficiências nutricionais, coloração, textura, umidade e teor de matéria orgânica do solo, além da presença de outras plantas, podem degradar a eficiência dos classificadores em nível de campo, sendo necessária um novo treinamento dos algoritmos. Estes fatores que afetam a classificação são estudados em outro trabalho (EL-FAKI et al., 2000b), merecendo destaque a influência da iluminação que foi minimizada com o uso de índices relativos entre as cores.

Dentre as técnicas de análise textural, a matriz de co-ocorrência tem sido utilizada por muitos pesquisadores (SHEARER, 1987; SHEARER e HOLMES, 1990; GONZALEZ e WOODS, 1992; PHAM e ALCOCK, 1998; BURKS et al., 2000; ALVES et al., 2002), pois esta técnica contém várias informações texturais que não dependem da orientação da imagem (SHEARER, 1987).

### **2.2.1 Matriz de co-ocorrência**

A matriz de co-ocorrência,  $P_{\mathbf{q}}^d(i, j)$  representa a freqüência dos níveis de valores numéricos dos pixels  $i$  que estão a uma distância  $d$  do pixel com valor numérico  $j$ , seguindo uma orientação  $\mathbf{q}$  pré-determinada. Os parâmetros texturais são considerados como parâmetros estatísticos de segunda ordem por não serem derivados diretamente de dados das imagens (SHEARER, 1987; PHAM e ALCOCK, 1998).

SHEARER (1987) e GONZALEZ e WOODS (1992) exemplificam a criação de uma matriz de co-ocorrência para uma imagem  $I_m(x,y)$  com quatro níveis de valores numéricos do pixel, considerando o vizinho seguinte ( $d=1$ ), na direção horizontal ( $\theta=0$ ).

Nesse exemplo, a imagem  $Im(x, y) = \begin{bmatrix} 0 & 0 & 3 & 1 \\ 2 & 1 & 0 & 2 \\ 3 & 2 & 0 & 3 \\ 1 & 2 & 1 & 3 \end{bmatrix}$  resultou a matriz de

$$\text{co-ocorrência } P_0^1(i, j) = \begin{bmatrix} 2 & 1 & 2 & 2 \\ 1 & 0 & 3 & 2 \\ 2 & 3 & 0 & 1 \\ 2 & 2 & 1 & 0 \end{bmatrix}.$$

Dessa maneira, por exemplo, o valor  $P_0^1(2, 3) = 3$  está representando os três pixels da imagem  $Im(x, y)$  que tem o nível dois (valor numérico 1) seguido, na mesma linha ( $\theta=0$ ), do nível três (valor numérico 2) ou nível três seguido de dois. Estas ocorrências estão destacadas na  $Im(x, y)$ .

Tendo como base esse exemplo, percebe-se que: a) imagens com alta frequência espacial (variações de valores numéricos dos pixels) geram valores altos na matriz de co-ocorrência; b) imagens com baixos valores numéricos dos pixels apresentam valores mais altos no quarto superior esquerdo da matriz de co-ocorrência, ocorrendo o inverso para imagens com valores numéricos mais altos; c) a dimensão da matriz de co-ocorrência é proporcional ao número de níveis de valores numéricos.

Segundo Haralick e Shanmugan (1974), citado por SHEARER (1987), da matriz de co-ocorrência podem ser gerados 16 descritores de textura da imagem: 1) segundo momento angular; 2) contraste; 3) correlação; 4) soma de quadrados; 5) momento do produto; 6) momento inverso da diferença; 7) momento da diferença; 8) soma das médias; 9) soma das variâncias; 10) soma das entropias; 11) entropia; 12) diferença da variância; 13) diferença da entropia; 14 e 15) medidas de correlação; 16) máximo coeficiente de correlação.

SHEARER e HOLMES (1990) utilizaram a técnica de segmentação de imagens baseada em matriz de co-ocorrência para identificar sete diferentes cultivares. Nesse trabalho foram geradas matrizes de co-ocorrência para a intensidade, saturação e matiz das imagens. Estudando vários modelos de classificação, estes pesquisadores chegaram a conclusão de que os melhores



resultados foram obtidos no modelo que continha informações texturais das matrizes de co-ocorrência baseadas na intensidade e no matiz com acurácia de 91%.

ALVES et al. (2002), por meio da análise de componentes principais dos parâmetros da matriz de co-ocorrência, concluíram que os melhores descritores, para a classificação entre plantas daninhas de folha larga e estreita, foram a média e a entropia.

Embora alguns descritores sejam relacionados como melhores por alguns pesquisadores, não se pode tomá-los como os únicos eficientes para todo tipo de problema. Assim, determinado parâmetro que se mostra eficiente em uma banda da imagem, ou numa situação específica, pode ser ineficiente em outra.

Também BURKS et al. (2000) utilizaram descritores da matriz de co-ocorrência de imagens coloridas como parâmetros de entrada de um classificador neuronal para a identificação de seis diferentes espécies de plantas daninhas e solo nu. O estudo avaliou se a acurácia dos diferentes modelos estudados era função dos parâmetros texturais ou da arquitetura e forma de treinamento da rede. Os resultados mostraram que para todos os modelos testados a acurácia da classificação individual foi sempre superior a 90%.

### **2.3 Dimensão da matriz de co-ocorrência**

A matriz de co-ocorrência é quadrada e a sua dimensão e, conseqüentemente, o esforço computacional para gerá-la depende do número de níveis de valores dos pixels na imagem. Por exemplo, para 32 níveis, tem-se uma matriz de dimensões 32 linhas x 32 colunas. Se por um lado a redução dos níveis permite um processamento mais rápido, por outro sua redução pode mascarar as diferenças entre as classes de interesse devido ao agrupamento dos pixels com tonalidades mais próximas.

BURKS et al. (2000) discretizaram as imagens para 64 valores de pixels, pois a utilização de 256 valores demanda muita memória para o

armazenamento das matrizes de co-ocorrência com dimensões 256 x 256 pixels, além de aumentar o tempo de processamento.

## **2.4 Estádio de maturação da planta**

O estágio de desenvolvimento de uma planta pode influenciar significativamente o seu reconhecimento num sistema de visão artificial. Para avaliar o efeito do estágio de desenvolvimento, faz-se necessário tomar a imagem das plantas em diferentes períodos de tempo (SANTOS et al., 2002; SENA JÚNIOR et al., 2002).

NGOUAJIO et al. (1999) também afirmaram que o estágio de desenvolvimento das plantas é primordial no desenvolvimento de técnicas para estimação da densidade de ocorrência das mesmas e a estimação de sua área foliar. Neste trabalho concluíram que o melhor estágio para se obter a estimativa da área foliar coincide com a época de aplicação para a maioria dos herbicidas pós-emergentes, ou seja, 3 a 4 pares de folha.

TANG et al. (1999), ao trabalharem no desenvolvimento de um classificador de plantas daninhas, optaram por coletar as imagens 4 semanas após o plantio por ser um estágio de desenvolvimento normalmente utilizado para a aplicação de herbicidas pós-emergentes.

WANG et al. (2000), testando a viabilidade do uso de sensores óticos na detecção de plantas daninhas na cultura do trigo sob diferentes densidades de plantas, conduziram os testes 21 dias após a data de plantio em condições de laboratório. Em condições de campo, as plantas daninhas apresentavam de 2 a 6 folhas e o trigo possuía de 3 folhas no início dos testes e 5 folhas, com princípio de perfilhamento, ao final do experimento.

GOEL et al. (2000), ao avaliar as potencialidades do sensoriamento remoto multiespectral na detecção de infestações por plantas daninhas, realizaram o imageamento das parcelas aproximadamente 26 dias após a semeadura.

Pelos trabalhos apresentados nota-se que há uma tendência de que os trabalhos sejam conduzidos entre 20 e 30 dias após a emergência das plantas,

ou seja, em um estágio em que normalmente são aplicados os herbicidas pós-emergentes.

## **2.5 Tamanho de sub-blocos da imagem**

Na análise textural para discriminação entre objetos, é comum retirar os descritores de sub-blocos da imagem para classificação desses objetos em cada porção da imagem. A utilização de diferentes tamanhos de sub-blocos parece ser aleatória, pois, vários pesquisadores limitam-se a citar o tamanho utilizado. Entretanto, blocos pequenos tendem a representar a textura da folha e tamanhos de bloco maior, dependendo a resolução da câmera, normalmente, representam a textura do dossel.

SHEARER e HOLMES (1990) utilizaram um sub-bloco de 64 x 64 pixels ao utilizarem parâmetros texturais da matriz de co-ocorrência para a identificação de plantas daninhas. PARK e CHEN (2001) e BURKS et al. (2000) também utilizaram este tamanho de sub-bloco.

YANG et al. (1998), ao testarem a aplicação de redes neurais no reconhecimento de imagens em Agricultura de Precisão, utilizaram um sub-bloco de 100 x 100 pixels. Já em outro trabalho de YANG et al. (1999), o tamanho escolhido foi de 80 x 80 pixels.

TANG et al. (1999) utilizaram três diferentes tamanhos de sub-blocos (9 x 9, 13 x 13 e 17 x 17 pixels) e verificaram que os mesmos influenciam no tempo de processamento e na acurácia da classificação, sendo que o bloco maior foi o que apresentou os melhores resultados.

LEE e SLAUGHTER (1998), trabalhando com identificação de classes de tomateiros e plantas daninhas, utilizaram um sub-bloco de 8 x 8 pixels.

ALVES et al. (2002) determinaram uma função discriminante para quatro estádios de desenvolvimento de plantas daninhas e obtiveram os melhores valores de exatidão para o segundo estágio para definir ambos os tamanhos de sub-blocos testados. Para o sub-bloco 5 x 5 pixels, observaram-se 94%, 100%,

92% e 82% de exatidão de classificação para os quatro estádios estudados. Para o sub-bloco 20 x 20 pixels os resultados foram: 90%, 100%, 76% e 86%.

## **2.6. Classificadores estatísticos**

Segundo GONZALEZ e WOODS (1992), os classificadores estatísticos normalmente se baseiam em uma abordagem probabilística dada a aleatoriedade na qual as classes de padrões estão envolvidas. Basicamente partem da teoria geral da probabilidade e dos erros onde o objetivo é a minimização do mesmo.

BURKS et al. (1998) e BURKS et al. (2000) provaram que as técnicas de análise estatística discriminante na diferenciação de seis diferentes classes (5 plantas daninhas e solo) são ferramentas robustas para classificação. Em ambos os trabalhos foram considerados apenas um estágio de desenvolvimento quando as plantas apresentavam entre 3,8 e 8,9 cm de altura.

SHEARER e HOLMES (1990) utilizaram parâmetros texturais da matriz de co-ocorrência da intensidade, saturação e do matiz. Variando os padrões texturais presentes em seis diferentes modelos estatísticos, obtiveram exatidões globais entre 64% e 91%.

ELFAKI et al. (2000a) utilizaram análise discriminante na classificação de plantas daninhas na cultura do trigo com base nos valores numéricos dos pixels. As funções desenvolvidas apresentaram exatidões globais entre 43,7% e 80,6% dependendo da espécie de planta daninha considerada.

## **2.7 Classificadores Neuroniais**

A utilização de rede neuronal artificial, tem ganhado popularidade como uma alternativa aos modelos de regressão para descrever processos biológicos. Essa capacidade de decisão pode ser melhor utilizada na análise de imagens onde o processo não é governado por nenhuma equação matemática, sendo considerada uma técnica robusta quando os dados são ambíguos ou o problema requer a manipulação de uma grande quantidade de dados

relacionados a vários resultados como, por exemplo, várias classes (JAYAS et al., 2000).

Uma rede neuronal artificial é composta por várias unidades de processamento (neurônios). Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma rede neuronal artificial vem das interações entre as unidades de processamento da rede.

Na Figura 1 observa-se o modelo de um neurônio onde  $x_1, x_2 \dots x_p$  são os dados de entrada que podem ser valores de saída de outra unidade ou os vetores de característica das classes;  $W_1, W_2 \dots W_p$  são os pesos atribuídos a cada valor de entrada;  $f(a)$  é a função de transferência da unidade e  $y$  é o valor de saída do neurônio.




Figura 1- Modelo de unidade de processamento (neurônio). FONTE: <http://www.din.uem.br/ia/neurais> (14/03/2003)

A forma como são associadas e organizadas essas unidades de processamento que compõem a rede neuronal é chamada de arquitetura ou topologia da rede. A Figura 2 representa um modelo hipotético de uma rede neuronal multicamada com duas camadas intermediárias.




Figura 2 – Representação hipotética de uma rede neuronal multicamadas.

FONTE: <http://www.din.uem.br/ia/neurais> (14/03/2003)

Usualmente as camadas são classificadas em três grupos:

**Camada de Entrada:** onde os padrões são apresentados à rede.

**Camadas Intermediárias ou Escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas (pesos  $W$ ). Podem ser consideradas como interpretadoras das características.

**Camada de Saída:** onde o resultado final é concluído e apresentado.

Uma rede neuronal é especificada, principalmente, pela sua arquitetura (número de camadas e neurônios), pelas características dos nós (tipo de função de ativação) e pelas regras de treinamento. A arquitetura da rede não se pode definir a priori ao treinamento da mesma, e, geralmente, é determinada por tentativa e erro.

A propriedade mais importante das redes neuronais é a habilidade de aprender, relacionando o valor de entrada (vetor de características) com o valor desejado (a classe). Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

A regra de treinamento é o algoritmo utilizado para determinação dos parâmetros livres da rede (pesos  $W$ ). Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neuronais, estes

algoritmos diferem entre si principalmente pelo modo como os pesos são ajustados.

TANG et al. (1999) implementaram classificadores neuronais para a classificação de plantas daninhas em folhas largas e folhas estreitas com base em descritores texturais, alcançando uma acurácia de 100% em um tempo de processamento que possibilita a aplicação em tempo real. A técnica utilizada consistiu em obter padrões texturais, utilizando transformada Fourier, uma ferramenta clássica na análise de sinais que permite reunir informações espaciais e de frequência.

SÉRÉLÉ et al. (2000) desenvolveram um modelo de rede neuronal artificial para identificação de deficiências de Nitrogênio, através de imagens espectrais, índices texturais e parâmetros topográficos. Os estudos mostraram que a utilização de redes neuronais possui grande potencial, e que, embora aqueles parâmetros sejam primordiais como fontes descritoras, a utilização em conjunto de ambos leva a resultados melhores, principalmente à medida que o número de interações aumentava até o valor de 400 a partir do qual o erro permanecia constante. Neste trabalho as imagens foram tomadas 70 dias após o plantio, tardiamente para uma intervenção que tenha como objetivo corrigir a deficiência detectada.

YANG et al. (1998) utilizaram diferentes arquiteturas de rede para separar plantas de milho de diversas plantas daninhas com base no valor de cor dos pixel de um sub-bloco de 100 x 100 pixels. A acurácia da classificação para o milho ficou entre 80% e 100% e entre 60 e 80% para as plantas daninhas.

Em outro trabalho de YANG et al. (1999) foram consideradas novas espécies de plantas daninhas juntamente com planta de milho. Neste trabalho os autores utilizaram os níveis de cinza dos pixels, em sub-blocos de 80 x 80 pixels, com o objetivo de classificar todas as plantas separadamente. A acurácia da classificação, no caso do milho, variou entre 74% e 100%. Já para as plantas daninhas ficou entre 38% e 92%.

ARAÚJO et al. (2000) utilizaram redes neuronais na classificação de grãos torrados de café misturados à madeira e cevada. As informações texturais foram modeladas no domínio da frequência espacial de regiões da imagem. Estas características eram organizadas em um vetor de entrada para

a rede neuronal. Os resultados apresentados, segundo os autores, são bastante promissores.

LEE e SLAUGHTER (1998) utilizaram redes neurais para a identificação de 3 diferentes classes de plantas de tomate e uma quarta classe com plantas daninhas. A partir de dados de forma da planta, obtiveram valores altos de classificação, máximo de 95,5%, para a classe 4 e de 80,7 % para a classe 1 com plantas cotiledonares. Por outro lado, para a classe 2 (plantas com folhas válidas) e classe 3 (plantas cotiledonares, válidas e danificadas por insetos) a classificação foi de 21,2% e 12,9%, respectivamente. Estes dados reforçam as afirmações de TANG et al. (1999) de que a classificação baseada em parâmetros morfológicos tem mais chance de sucesso para plantas mais jovens.

SUI et al. (1998) utilizaram características de reflectância detectadas por fotodiodos em diferentes bandas e digitalizadas por um “data logger” para obter parâmetro de entrada para uma rede neuronal com o objetivo de detectar plantas de algodão com deficiência de nitrogênio. A classificação alcançou 91% de acertos tanto para plantas com deficiência como para plantas sem deficiência.

GOPALAPILLAI et al. (2000) utilizaram modelos neurais para estimar a densidade de plantas daninhas em situações distintas de tipo de solo e aplicação de herbicida para duas diferentes resoluções de imagens aéreas (5,3 m/pixel e 1,52 m/pixel). Através de análise estatística dos dados verificaram que o tipo de solo não interferiu no modelo e foi descartado do treinamento da rede. As análises mostraram que o aumento da resolução prejudica o ajuste do modelo, para a resolução de 5,3 m/pixel o  $R^2$  foi de 0,89, já para a resolução 1,52 m/pixel o ajuste do modelo foi muito baixo  $R^2= 0,49$ . O número de amostras utilizadas no ajuste do modelo foi muito maior para a maior resolução e poucas para a resolução menor, o que pode não ter representado a variabilidade da densidade de plantas daninhas.



### 3. MATERIAL E MÉTODOS

A coleta das imagens foi realizada nos meses de junho e julho de 2001 na Embrapa Milho e Sorgo, em Sete Lagoas-MG. O cultivo das plantas daninhas foi feito em bandejas retangulares em casa de vegetação com controle automático de temperatura.

O solo utilizado para o plantio foi peneirado em peneira 20 mm e adubado com formulação NPK 4 14 8 na dosagem de 3 g por kg de solo.

Quatro níveis de iluminação foram combinados com três alturas de câmeras para realizar a coleta de imagens em três repetições plantadas de quatro espécies de plantas daninhas e milho. As imagens foram coletadas aos 22, 25 e 29 dias após a emergência usando uma câmera monocromática e outra CIR-RGB. Das imagens coletadas da câmera CIR-RGB foram obtidas três tipos de imagens. O total de imagens coletadas foi igual a 1620.

#### 3.1 Escolha das espécies de plantas

A escolha das espécies de plantas daninhas foi feita com base no critério de maior incidência para as condições de manejo, clima e solo, presentes na Embrapa Milho e Sorgo e também do tipo de folha da planta daninha. As espécies de folha larga escolhidas foram o picão preto (*Bidens pilosa* L.), leiteira, (*Euphorbia heterophylla* L.), e as de folha estreita foram

capim-milhã (*Digitaria horizontalis* Willd) e timbête (*Cenchrus echinatus* L.). O híbrido Monsanto AG 8088 foi escolhido para ser utilizado no trabalho.

### 3.2 Aquisição das imagens

Utilizou-se uma câmera monocromática e CIR/RGB para a aquisição das imagens. A câmera CIR/RGB utilizada foi a DUNCANTECH, modelo MS3100, a qual foi conectada a um computador Pentium 75 por meio de uma placa de aquisição de vídeo digital fabricada pela National Instruments, modelo PCI 1424. As imagens foram armazenadas com 1392 (H) e 1039 (V) pixels no formato TIF (“tagged image file format”) e em duas composições de bandas: colorida (bandas vermelha, verde e azul) e falsa-cor (bandas infravermelho próximo, vermelho e verde). A câmera possui três CCD (“charge-coupled device”), com controle individual do ganho e do tempo de exposição. Um CCD era destinado à coleta da banda do vermelho (Vm), outro à coleta do infravermelho próximo (IV próx.) e o terceiro à coleta das bandas verde e azul (Vd-Az). A lente, com distância focal de 17 mm permitia o controle manual da abertura da íris, em que o “f-stop” foi ajustado em 3,5. A Tabela 1 apresenta os ganhos e os tempos de exposição utilizados para cada CCD na aquisição das imagens das plantas.

Tabela 1: Ganho e o tempo de exposição para cada um dos três CCD (“charge-coupled device”) nas bandas do vermelho (Vm), do infravermelho próximo (IV próx) e do verde e azul (Vd-Az).

CCD	Vm.	IV próx.	Vd-Az
Ganho (dB)	15,0	12,9	10,2
Exposição (ms)	123,000	122,625	122,625

Na Figura 3 observa-se a resposta dos três CCDs nas bandas CIR/RGB, onde as curvas representam as respostas dos CCDs destinados à coleta das bandas verde (Vd), vermelho (Vm) e do infravermelho próximo (IV próx.), respectivamente.




Figura 3 – Representação das respostas dos CCDs da câmera CIR/RGB.

FONTE: <http://www.duncantech.com> (12/03/2003)

As mesmas plantas foram utilizadas para coletar imagens com uma câmera monocromática do modelo DMK 3002-IR, com lente de 12 mm de distância focal, conectada a uma placa de aquisição de vídeo analógico fabricada pela Imagenation Vision System Specialist, modelo PXC200F-02, que digitalizou as imagens com resolução de 768 (H) x 494 (V) e salvou as mesmas no formato BMP (“Bit Map da Microsoft”). Na Figura 4 observa-se a resposta do CCD da câmera monocromática, nas faixas do espectro visível e do infravermelho próximo. Este sensor apresenta uma sensibilidade no infravermelho próximo superior aos CCDs convencionais.

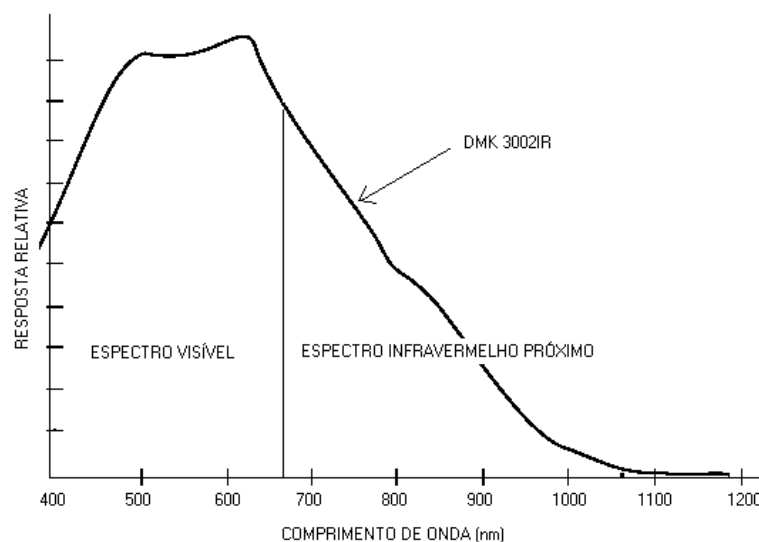


Figura 4 – Representação da resposta do CCD da câmera monocromática.

FONTE: Manual da câmera

### 3.2.1 Variação da iluminação

Muitos pesquisadores têm mostrado que o efeito da variação da iluminação sobre as imagens pode afetar de maneira significativa a eficácia do sistema de visão artificial. Dessa maneira, a coleta foi feita para todas as parcelas, sob quatro diferentes níveis de intensidade de iluminação 600, 700, 800 e 900 W.

Para obtenção das imagens em condições de iluminação controlada, construiu-se uma estrutura metálica com dimensões 1,50m por 1,50m e 2,00m, revestida com lona plástica, tendo uma face branca voltada para o interior da estrutura. O sistema de iluminação foi composto por seis lâmpadas incandescentes dicróicas de 50 watts e quatro refletores com lâmpadas incandescentes halógenas de 150 watts. O sistema de iluminação foi disposto de modo a fornecer uma iluminação mais difusa possível. Para garantir que os níveis de iluminação fossem os mesmos, todos os dias, as imagens foram obtidas à noite, pois, a lona plástica utilizada não era totalmente opaca. As quatro intensidades de iluminação foram obtidas, mantendo-se os quatro refletores acesos e acendendo-se as demais lâmpadas sucessivamente, duas a duas (Figura 5).



Figura 5 – Sistema de iluminação montado para a coleta das imagens.

### 3.2.2 Dias após a emergência

Com o crescimento da planta, algumas de suas características podem mudar, como por exemplo, a cor e a textura. Portanto, a idade da planta é outro fator que pode influenciar a análise das imagens. Dessa maneira, é necessário testar os algoritmos de processamento e análise de imagens com relação também a esta fonte de variação, já que as plantas têm germinação gradual e existe uma época ótima para a aplicação de herbicidas.

Foram utilizadas as imagens tomadas nos dias 10, 13 e 17 de julho, que equivalem a 22, 25 e 29 dias após a emergência. Nesse período normalmente é feita a aplicação de herbicida. No início do período de coleta considerado, as plantas daninhas de folhas estreitas apresentavam-se no início do perfilhamento e as de folhas largas apresentavam de 2 a 3 pares de folhas.

### 3.2.3 Altura da câmera

O aumento da distância entre a câmera e o objeto reduz a resolução da imagem. Foram tomadas imagens nas distâncias 2,04 m (h1), 1,58 m (h2) e 1,32 m (h3) para a câmera CIR/RGB e 2,04 m, 1,61 m e 1,35 m para a câmara monocromática.

A Tabela 2 apresenta as resoluções espaciais, em mm/pixel, para as duas câmeras nas diferentes alturas. As resoluções foram determinadas pela relação do número de pixel na imagem e a dimensão real das bandejas.

Tabela 2: Resolução espacial das câmeras para as três distâncias consideradas em mm/pixel.

Câmeras	Altura (m)	Resolução (mm/pixel)
CIR/RGB	2,04	0,55
	1,58	0,43
	1,32	0,36
Monocromática	2,04	1,10
	1,61	0,85
	1,35	0,75

### **3.3 Pré-processamento das imagens**

Para que o sistema seja capaz de discriminar diferentes plantas é necessário transformar as diferenças entre as classes em números que representem padrões de cada espécie, de tal forma que seja possível classificá-las. Os algoritmos para identificação de plantas e obtenção dos descritores foram implementados no programa computacional MATLAB® R12 e foi idealizado em três etapas: pré-processamento, processamento e classificação das imagens.

De maneira geral, o pré-processamento das imagens tem por finalidade diminuir ou anular características das imagens que possam vir a dificultar; e realçar as que forem de interesse para o reconhecimento de padrões. Neste trabalho, o pré-processamento tem por finalidade diminuir a influência da iluminação e realçar o contraste entre as diferentes espécies. O pré-processamento consistiu de três etapas: divisão da imagem em sub-blocos, normalização, realce e discretização do valor do pixel.

#### **3.3.1 Dimensões dos sub-blocos da imagem**

A obtenção das características texturais foi feita em sub-blocos da imagem com dimensões de 17 x 17, 34 x 34 e 68 x 68 pixels, recortados em regiões de interesse das imagens coletadas através de um programa computacional implementado no MATLAB® R12 (Apêndice A). Este programa gerou um arquivo texto com as coordenadas do canto esquerdo superior de cada sub-bloco, retiradas em regiões de interesse que continham plantas de cada uma das cinco classes. O corte dos sub-blocos foi feito por outro programa que lê o arquivo de coordenadas e a imagem correspondente recortando os blocos (Apêndice B). De cada um desses sub-blocos foi gerada uma matriz de co-ocorrência da qual foram obtidos os descritores texturais durante a fase de processamento por outro programa computacional desenvolvido com essa finalidade (Apêndice C). Para cada combinação dos fatores estudados, foram recortados 100 sub-blocos de cada repetição, totalizando 300 amostras de cada espécie.

### 3.3.2 Realce e Normalização

Foram utilizadas para fins de classificação as imagens das bandas verde e infravermelha, a imagem de excesso de verde e a imagem monocromática.

A imagem de excesso de verde foi obtida através do modelo:

$$ExV = \frac{2 * G - R - B}{G + R + B} \quad (1)$$

em que

ExV = imagem de excesso de verde;

G = banda verde;

R = banda vermelha;

B = banda azul.

A divisão do numerador da equação pela soma dos índices representa a normalização da imagem de excesso de verde, com isso espera-se a redução do efeito da iluminação sobre a eficiência dos classificadores. Dessa maneira, ao final do pré-processamento, obteve-se uma imagem monocromática representando o excesso de verde de cada sub-bloco.

As imagens das bandas verde e infravermelha da câmera CIR/RGB e a imagem monocromática utilizadas na classificação não foram realçadas nem normalizadas durante o pré-processamento.

### 3.3.3 Discretização do valor do pixel

Na técnica de análise textural, na qual se considera a variação do valor do pixel e de seus vizinhos, os níveis destes valores são diretamente proporcionais à dimensão da matriz de co-ocorrência e, portanto, ao tempo de processamento. Estipulou-se trabalhar com quatro diferentes níveis de valores dos pixels, 32, 64, 128 e 256, com o objetivo de estudar a influência desses na eficiência dos classificadores. A obtenção dos diferentes níveis foi feita pela divisão dos valores de pixel dos sub-blocos das imagem com 256 níveis por oito, quatro, dois e um para 32, 64, 128 e 256 níveis, respectivamente, e arredondamento para o inteiro mais próximo, em cada sub-bloco de todas as classes envolvidas. A obtenção dos níveis de valor dos pixels foi feita após a etapa de realce e normalização para a imagem excesso de verde.

### 3.4 Processamento das imagens

No processamento das imagens foram retirados os descritores texturais da matriz de co-ocorrência normalizada (equação 2) na direção horizontal ( $\theta = 0$ ) do pixel seguinte ( $d = 1$ ).

$$P(i, j) = \frac{p(i, j)}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j)} \quad (2)$$

em que

$P(i, j)$  = matriz de co-ocorrência normalizada;

$p(i, j)$  = elementos da matriz de co-ocorrência;

$N_g$  = número total de níveis do atributo.

Os descritores utilizados foram:

**A) Momento angular:** Essa característica é uma medida da homogeneidade da imagem. Poucas mudanças de intensidade acarretam poucos valores de alta magnitude na matriz de co-ocorrência, resultando num alto momento angular. O momento angular foi determinado pela seguinte expressão

$$C_1 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} [p(i, j)]^2 \quad (3)$$

em que

$C_1$  = momento angular;

**B) Média:** é uma medida da intensidade da imagem representado em uma matriz de co-ocorrência, e foi determinada pela seguinte expressão:

$$C_2 = \sum_{i=0}^{N_g-1} i \times p_x(i) \quad (4)$$

em que

$C_2$  = média;

$i$  = valor observado;

$p_x(i)$  = probabilidade marginal da matriz de co-ocorrência (soma da linha).



**C) Variância:** identifica as variações da intensidade de uma imagem. Assim, pixels da imagem com valores similares fazem com que a variância tenda a zero. A variância foi determinada pela seguinte expressão:

$$C_3 = \sum_{i=0}^{N_g-1} (i - C_2)^2 p_x(i) \quad (5)$$

em que

$C_3$  = variância;

**D) Entropia:** é uma medida da aleatoriedade, atingindo o seu valor máximo quando todos os valores da matriz de co-ocorrência forem iguais, e foi determinada pela seguinte expressão:

$$C_4 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \ln [p(i, j)] \quad (6)$$

em que

$C_4$  = entropia;

ln = logaritmo neperiano.

**E) Correlação:** é uma medida da dependência linear da intensidade da matriz de co-ocorrência. A correlação da intensidade da matriz de co-ocorrência de uma imagem com grandes áreas homogêneas tende a ser um valor mais alto do que com uma maior variação do valor do pixel. A correlação foi determinada pela expressão:

$$C_5 = \frac{\left[ \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} ij p(i, j) \right] - C_2^2}{C_3} \quad (7)$$

em que

$C_5$  = correlação;

i e j = coordenadas do pixel observado;

**F) Momento do produto:** retorna um valor baixo quando os valores altos da matriz de co-ocorrência estiverem próximos da diagonal, o que acontece quando os valores dos pixels das imagens não apresentam mudança brusca. O momento do produto ( $C_6$ ) foi determinado pela expressão:

$$C_6 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - C_2)(j - C_2) p(i, j) \quad (8)$$

**G) Momento inverso da diferença:** este descritor possui valor alto quando os valores altos da matriz de co-ocorrência estiverem próximos da diagonal, o que acontece quando os valores dos pixels das imagens não apresentam mudança brusca. O momento inverso da diferença ( $C_7$ ) foi calculado pela expressão:

$$C_7 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (9)$$

**H) Medidas de correlação:** Segundo SHEARER (1987), aparentemente não existe uma interpretação física dessa medida, ela é uma representação da taxa de entropia da matriz de co-ocorrência e foi determinada pela expressão:

$$C_8 = \frac{C_2 - HXY1}{HX} \quad (10)$$

em que

$$HX = - \sum_{i=0}^{N_g-1} p_x(i) \ln[p_x(i)] \quad (11)$$

$$HXY1 = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \ln[p_x(i)p_x(j)] \quad (12)$$

em que

$C_8$  = medidas de correlação;

$p_x(j)$  = probabilidade marginal da matriz de co-ocorrência (soma da coluna).

Essas características da matriz de co-ocorrência foram escolhidas de um dos modelos testados por SHEARER (1987) que apresentou a melhor acurácia. Algumas delas são citadas também por PARK e CHEN (2001) e ALVES et al. (2002) como características promissoras.

O Apêndice C apresenta o programa de computador implementado para a extração das características da matriz de co-ocorrência, com base nas equações (2) a (12).

### 3.5 Classificação

O processo de classificação de imagens, ou de regiões desta que apresentem os mesmos padrões, é considerada uma etapa complexa com base em decisões teóricas a partir de vetores de características das diversas classes. As principais abordagens para a classificação por decisões teóricas são os classificadores por distância mínima, correlacionadores, classificadores bayesianos e redes neuronais (GONZALES e WOODS, 1992).

Para o desenvolvimento e teste dos classificadores foram utilizados os 300 sub-blocos de cada espécie. Foram utilizados um classificador estatístico e três neuronais.

#### 3.5.2 Classificador estatístico

O classificador Bayesiano descrito por GONZALEZ e WOODS (1992) foi utilizado para a separação das diferentes espécies de plantas daninhas. A função de decisão desse classificador é expressa pela equação a seguir.

$$d_j(x) = \ln P(W_j) - \frac{n}{2} \ln 2\mathbf{p} - \frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad (13)$$

em que

$C_j$  = matriz de covariância da classe  $j$ ;

$x$  = vetor de características das classes;

$m_j$  = vetor de médias das características da classe  $j$ ;

$T$  = transposta;

$P(W_j)$  = probabilidade de ocorrência da classe  $j$ ;

$n$  = dimensão dos vetores de descritores.

Como a dimensão dos vetores de padrões ( $n$ ) e a probabilidade de ocorrência de cada classe  $P(W_j)$  são os mesmos para todas as classes, os termos  $\frac{n}{2} \ln 2p$  e  $\ln P(W_j)$ , podem ser eliminados da equação que se torna:

$$d_j(x) = -\frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad (14)$$

Dessa maneira tem-se uma função de decisão para cada uma das cinco classes (quatro espécies de plantas daninhas e milho). Quando um novo vetor de características é introduzido no modelo, ele é atribuído à classe em que o valor da função decisão  $[d_j(x)]$  for maior. A matriz de covariância e derivada da matriz de cada classe onde cada linha da matriz representa um sub-bloco e cada coluna uma característica textural.

Dos 300 vetores de padrões das amostras de cada classe, 200 foram escolhidas aleatoriamente para a geração da matriz de covariância e do vetor de médias das classes. Os 100 vetores restantes foram utilizados para testar o classificador.

Na elaboração do classificador estatístico seguiram-se os passos descritos a seguir:

a) o usuário define para que condição: dia após a emergência, tamanho de bloco, banda ou imagem, altura da câmera, nível de iluminação e nível de valor de pixel que deseja realizar a classificação;

b) o algoritmo lê os arquivos que contém os parâmetros texturais da matriz de co-ocorrência para a condição escolhida;

c) 200 vetores de características das classes são escolhidos aleatoriamente para compor as médias das classes;

d) a matriz de teste é criada com 100 amostras aleatoriamente selecionadas;

e) são calculadas a matriz de covariância e sua inversa e o logaritmo do determinante da matriz de covariância;

f) são criadas as funções de decisão;

g) Calcula-se o valor das funções de decisão  $[d_j(x)]$  para cada vetor de característica da amostra de teste;

h) Atribui-se o vetor característica à classe que apresentar o maior valor;

i) a classificação é salva em arquivo texto e a matriz de classificação é apresentada.

O código fonte do classificador estatístico é apresentado no Apêndice D.

### 3.5.1 Classificador Neuronal

A arquitetura básica da rede neuronal utilizada está demonstrada na Figura 6. A rede foi constituída por quatro camadas: uma de entrada, duas intermediárias (ocultas) e uma de saída. O vetor de entrada tem dimensão igual a oito que são os parâmetros texturais da matriz de co-ocorrência. A camada de saída possui cinco neurônios, ou seja, o vetor de saída tem dimensão igual ao número de classes de interesse (quatro espécies diferentes de plantas daninhas e a planta de milho). O elemento do vetor de saída que representa uma determinada classe tem o valor um e os outros zero. Dessa maneira, por exemplo, um vetor de entrada da espécie dois, tem um vetor esperado de saída igual a (0,1,0,0,0).

Foram testadas três combinações de número de neurônios das duas camadas intermediárias: 10\_10, 10\_5 e 5\_5. As redes foram treinadas com o algoritmo de retropropagação do erro, atualizando os parâmetros livres pela aproximação Resilient Backpropagation (função “trainrp” do MatLab).

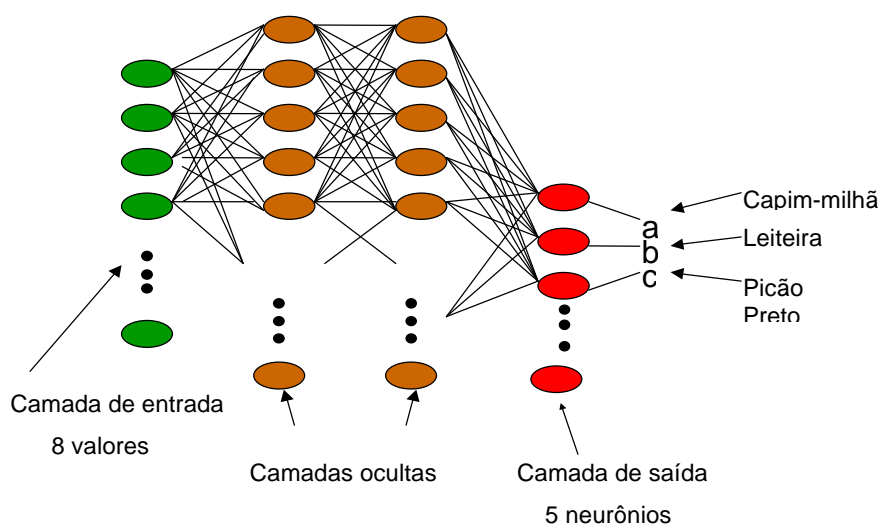


Figura 6 – Representação simplificada da arquitetura da rede neuronal.

A função de transferência tangente hiperbólica sigmóide (função “tansig” do MatLab) foi utilizada para as duas camadas intermediárias (Figura 7).




Figura 7 – Representação gráfica da função de transferência tangente hiperbólica sigmóide.

Na camada de saída foi utilizada a função de transferência logarítmica sigmóide (função “logsig” do MatLab) (Figura 8).




Figura 8 – Representação gráfica da função de transferência logarítmica sigmóide.

Dessa maneira, ao apresentar um vetor desconhecido na rede, este foi considerado da espécie de planta cujo neurônio de saída mais se aproximou do valor um.

Para elaboração do classificador neuronal seguiu os passos descritos a seguir:

a) o usuário define para que condição deseja realizar a classificação: dia após a emergência, tamanho de bloco, banda ou imagem, altura da câmera, nível de iluminação e nível de valor de pixel;

b) o algoritmo lê os arquivos que contém os parâmetros texturais da matriz de co-ocorrência para a condição escolhida;

c) os vetores de características das classes são escolhidos aleatoriamente para compor as matrizes de treinamento (aproximadamente 2/3 da amostra dos sub-blocos) e teste (aproximadamente 1/3 da amostra) da rede;

- d) as matrizes respostas de teste e treinamento são criadas;
  - e) o usuário define a arquitetura da rede;
  - f) a rede é criada e treinada cinco vezes com 1000 ciclos de iterações;
  - g) a rede que apresentar o menor erro médio quadrático durante os cinco treinamentos é salva;
  - h) a rede é testada com a matriz de amostras de teste;
  - i) as classes são separadas e é apresentada a matriz de classificação.
- O código fonte do classificador neuronal baseado em parâmetros texturais é apresentado no Apêndice E.

### 3.6 Seleção dos níveis dos fatores em estudo

Os níveis dos fatores dimensão do sub-bloco, discretização dos valores numéricos dos pixels, altura da câmera, tipo de imagem e classificador foram selecionados utilizando-se da comparação descritiva da média e do desvio padrão da exatidão global de classificação.

A exatidão global é a relação entre o número total de vetores de características de cada espécie de planta, classificados corretamente, e o número total de vetores. Esses valores foram obtidos da matriz de classificação, onde a diagonal representa os vetores corretamente classificados. A Tabela 3 exemplifica uma matriz de classificação, onde foram utilizados 58 sub-blocos de cada espécie de plantas para testar a performance do classificador, sendo a exatidão global determinada pela seguinte equação:

$$EG = \frac{CC}{T} \times 100 \quad (15)$$

em que

EG = exatidão global;

CC = total de vetores de característica classificados corretamente (233);

T = total de vetores de característica (290).

Tabela 3: Exemplo de matriz de classificação onde foram utilizados 58 sub-blocos de cada espécie de plantas para testar a performance do classificador

CLASSES	C	L	P	T	M	Total
Capim colchão	54	0	0	4	0	58
Leiteiro	0	50	6	0	2	58
Picão Preto	8	4	32	14	0	58
Timbete	7	0	11	40	0	58
Milho	1	0	0	0	57	58
Totais						<b>233 290</b>

Primeiramente, foram definidos os fatores que seriam controlados em um sistema de visão artificial no campo: dimensão do sub-bloco, discretização dos valores numéricos dos pixels e altura da câmera. Na definição dos fatores controláveis fixou-se a data de coleta das imagens em 29 dias após a emergência, o nível de iluminação em 900 W e o classificador estatístico.

O tipo de imagem, apesar de ser um fator controlado no sistema, foi definido fixando-se o fator iluminação em 900 W que não é um fator controlável em campo. No entanto, o efeito da iluminação pode ser minimizado nas etapas de realce e normalização da imagem. Na definição da imagem, além da fixação do fator iluminação, fixou-se também a data de coleta das imagens em 29 dias após a emergência e o classificador estatístico.

Finalmente, acessou-se a performance do sistema para as diferentes datas de coleta de imagem o qual é um fator sem controle no campo e diferentes classificadores (um estatístico e três neuronais).

### 3.6.1 Definição da dimensão dos sub-blocos para cada tipo de imagem

Para definição da dimensão de sub-bloco para cada tipo de imagem, as estimativas das médias e desvios-padrão da exatidão global foram obtidas a partir de 12 valores que representam a combinação de quatro níveis de valores numéricos de pixel com três alturas da câmera. No total o estudo da dimensão do sub-bloco da imagem compreendeu 144 valores de exatidão global (quatro tipos de imagens x três sub-blocos x quatro níveis de valores de pixels x três alturas).



### **3.6.2 Definição do nível da discretização dos valores dos pixels para cada tipo de imagem**

A escolha do nível de valores dos pixels que apresentou os melhores resultados, para cada tipo de imagem foi feita na condição de melhor tamanho de sub-bloco previamente selecionado. As estimativas das médias e desvios-padrão da exatidão global foram obtidas a partir de três valores que representam as três alturas da câmera. No total o estudo do nível de valores dos pixels da imagem compreendeu 48 valores de exatidão global (quatro tipos de imagens x quatro níveis de valores de pixels x três alturas).

### **3.6.3 Definição da altura da câmera**

A escolha da altura da câmera que apresentou os melhores resultados, para cada tipo de imagem, foi feita na condição de melhor tamanho de sub-bloco e nível de valores de pixels previamente selecionado. Neste caso um único valor de exatidão global foi utilizado para diferenciar as alturas para cada tipo de imagem.

### **3.6.4 Definição do tipo de imagem da câmera**

A escolha do tipo de imagem CIR/RGB (verde, excesso de verde e infravermelha) foi feita considerando-se somente a melhor dimensão de sub-bloco, nível de valores de pixels e altura da câmera. Neste estudo foram incluídos os quatro níveis de iluminação, desse modo, as estimativas das médias e desvios-padrão da exatidão global foram geradas de quatro valores. A imagem da câmera CIR/RGB que apresentou os melhores resultados de exatidão global foi comparada com a imagem tons de cinza da câmera monocromática.

### **3.6.5 Definição do tipo de classificador**

Uma vez determinada a dimensão de sub-bloco, tipo de imagem da câmera CIR/RGB, altura da câmera e níveis de valores de pixels, foram testados, também para a imagem monocromática, os dois classificadores considerando-se três datas de coleta das imagens (dias após a emergência). Primeiramente foram testadas as três arquiteturas do classificador neuronal, escolhendo-se a que apresentou o melhor resultado de exatidão global. O resultado da melhor arquitetura foi comparado com o resultado obtido pelo classificador estatístico nas mesmas condições.

## **4. RESULTADOS E DISCUSSÕES**

### **4.1) Tipos de imagens coletadas**

Na Figura 9 são apresentados exemplos dos três tipos de imagens coletadas pelas duas câmeras utilizadas no experimento. As imagens da figura foram obtidas na altura de 1,32 m para as imagens RGB e falsa cor infravermelha (CIR); e de 1,35 m para a imagem monocromática. O nível de iluminação foi de 900 W e a data de coleta aos 29 dias após a emergência. As imagens apresentadas representam um mesmo local de uma imagem coletada, da mesma espécie de planta daninha e mesma bandeja, com o intuito de facilitar a visualização das diferenças entre elas.




Figura 9 – Exemplo de imagens coletadas aos 29 dias após a emergência, ao nível de iluminação de 900 W e altura da câmera de 1,32 m para a câmera CIR/RGB e 1,35 m para a câmera monocromática: (a) RGB, (b) falsa cor infravermelha e (c) monocromática.

Exemplos de imagens RGB, CIR e monocromática das quatro espécies de plantas daninhas e a planta do milho, coletadas aos 29 dias após a emergência com nível de iluminação de 900 W, podem ser vistas nas Figuras 10, 11 e 12, respectivamente. Observa-se, visualmente, que os dosséis de cada espécie apresentam texturas diferentes, reforçando a hipótese que a discriminação entre classes pode ser realizada por análise textural. Porém, na análise visual, nota-se que a resolução estudada não foi suficiente para registrar a textura da folha.




Figura 10 – Exemplos de imagens RGB das plantas utilizadas no estudo aos 29 DAE, nível de iluminação de 900 W e 1,32 m de altura da câmera: (a) capim-milhã, (b) leiteira, (c) picão Preto, (d) timbête e (e) milho.




Figura 11 – Exemplos de imagens falsa cor infravermelha das plantas utilizadas no estudo aos 29 DAE, nível de iluminação de 900 W e 1,32 m de altura da câmera: (a) capim-milhã, (b) leiteira, (c) picão Preto, (d) timbêta e (e) milho.




Figura 12 – Exemplos de imagens monocromáticas das plantas utilizadas no estudo aos 29 DAE, nível de iluminação de 900 W e 1,35 m de altura da câmera: (a) capim-milhã, (b) leiteira, (c) picão Preto, (d) timbête e (e) milho.



## 4.2 Dimensão dos sub-blocos das imagens

Os gráficos da Figura 13 apresentam para cada tipo de imagem e dimensão de sub-bloco, as médias e a dispersão da exatidão global do classificador estatístico, obtidas a partir das combinações das três alturas de câmera com os quatro níveis de valores de pixel. Percebe-se que houve uma tendência de melhora na exatidão global a medida que a dimensão do sub-bloco aumentava em todos os tipos de imagem. Isso sugere que quando o sub-bloco continha somente parte de uma folha, o que geralmente ocorreu para o sub-bloco 17 x 17 pixels, o classificador estatístico não apresentou bons resultados. A exatidão global da classificação para a dimensão de sub-bloco 68 x 68 pixels tendeu a ser superior aos demais em todos os tipos de imagens.




Figura 13 – Representação da média e desvio padrão de 12 valores de exatidão global para as diferentes dimensões dos sub-blocos e tipos de imagens aos 29 DAE, 1,32 m de altura de câmera CIR/RGB e 1,35 m para a câmera monocromática com nível de iluminação de 900 W.



Os três tamanhos de sub-blocos utilizados no estudo, retirados na mesma posição em uma imagem RGB de cada planta utilizada no estudo, são apresentados na Figura 14. Nota-se pela figura que o sub-bloco 17 x 17 pixels contém exclusivamente parte da folha e que os blocos 34 x 34 pixels e 68 x 68 pixels representam a textura do dossel.




Figura 14 - Tamanhos de sub-blocos utilizados para as diversas espécies envolvidas no estudo: (a) capim-milhã, (b) leiteira, (c) picão preto, (d) timbête, (e) milho.

Os sub-blocos 68x68 pixels representaram áreas de 591,34 e 2614 mm<sup>2</sup> para as câmeras CIR/RGB e monocromática, respectivamente. No campo, o sistema pode apresentar problemas na identificação das plantas caso apareça mais do que uma espécie em cada sub-bloco da imagem, porém, pela pequena área representada pelo sub-bloco 68 x 68 pixels, acredita-se que essa situação não será a norma.

Um sub-bloco maior significa um processamento mais rápido da imagem, porém, a classificação pode ser influenciada pela densidade de plantas, pois ao passo que a dimensão do sub-bloco aumenta deixa-se ter informações de textura exclusivamente da folha e passa-se a obter informações da textura do dossel.

TANG et al. (1999) utilizaram três diferentes tamanhos de sub-blocos (9 x 9, 13 x 13 e 17 x 17 pixels) e verificaram que os mesmos influenciaram no tempo de processamento e na acurácia da classificação, sendo que o bloco maior foi o que apresentou os melhores resultados. Entretanto, ALVES et al. (2002) trabalhando a dez centímetros de distância da planta, com tamanhos de bloco de 5 x 5 pixels e 20 x 20 pixels, encontraram melhores resultados para o bloco menor. Também ZANDONADI et al. (2002) optaram pelo tamanho de bloco 9 x 9 pixel aos tamanhos 3 x 3 pixels e 13 x 13 pixels. Esses resultados encontrados sugerem que o tamanho de bloco é influenciado pela resolução da imagem, já que estes últimos pesquisadores trabalharam com uma resolução mais alta, o que provavelmente permitiu captar a textura das folhas, o que não ocorreu neste trabalho.

Com base nos resultados apresentados, escolheu-se o sub-bloco de dimensão 68 x 68 pixels para realizar os estudos dos demais fatores.

#### **4.3 Definição do nível da discretização dos valores dos pixels**

Os gráficos da Figura 15 apresentam para cada nível de valor numérico do pixel e tipo de imagem, as médias e a dispersão da exatidão global do classificador estatístico, obtidas a partir das três alturas das câmeras. Pode-se inferir que o nível de valor do pixel influenciou pouco na classificação para todos os tipos de imagens. Nesse caso, a adoção de 32 níveis é justificada pelo menor tempo de processamento requerido para determinação da matriz de co-ocorrência e dos descritores das classes dela retirados.

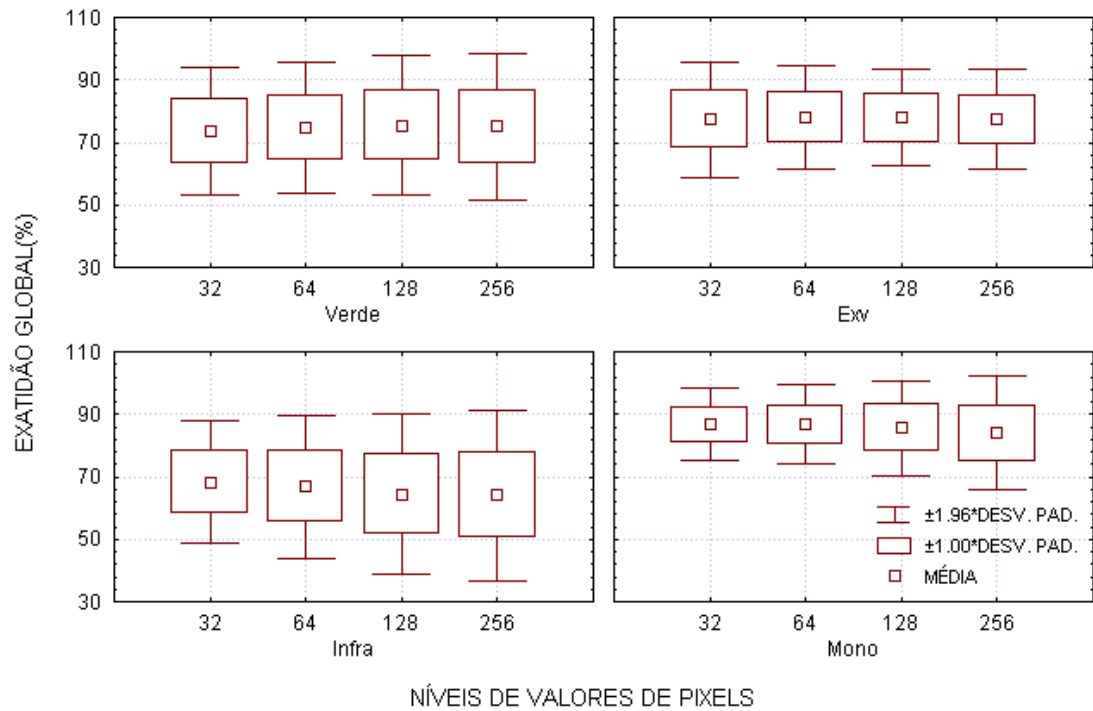


Figura 15 – Exatidão global dos níveis de valores de pixel para todos os tipos de imagens utilizadas no estudo, considerando o sub-bloco 68 x 68 pixels.

Quando os níveis de valores dos pixels de uma imagem são reduzidos, valores próximos são agrupados em um único nível. A pouca influência dos níveis de pixels na classificação deve ter ocorrido pelo fato da textura da folha não ter sido detectada nas imagens, ou seja, os valores dos pixels da folha eram próximos. Por outro lado, conforme pode ser constatado na Figura 16, a textura do dossel pode ser distinguida nas imagens.




Figura 16– Efeito da discretização dos valores dos pixels em uma mesma imagem excesso de verde: (a) 32 níveis, (b) 64 níveis, (c) 128 níveis, (d) 256 níveis.

Com base na discussão apresentada escolheu-se 32 níveis de valores de pixels para e a dimensão de sub-bloco 68 x 68 pixels, realizar os demais estudos.

#### 4.4 Definição da altura da câmera

Na Figura 17 são apresentados os valores da exatidão global do classificador estatístico para as diferentes alturas da câmera em todos os tipos de imagens. Observa-se uma tendência de melhora na classificação com o aumento da altura da câmera em todos os tipos de imagens. Com o aumento da altura da câmera uma área maior da imagem é representada no sub-bloco, apresentando melhor a textura do dossel (Figura 18).

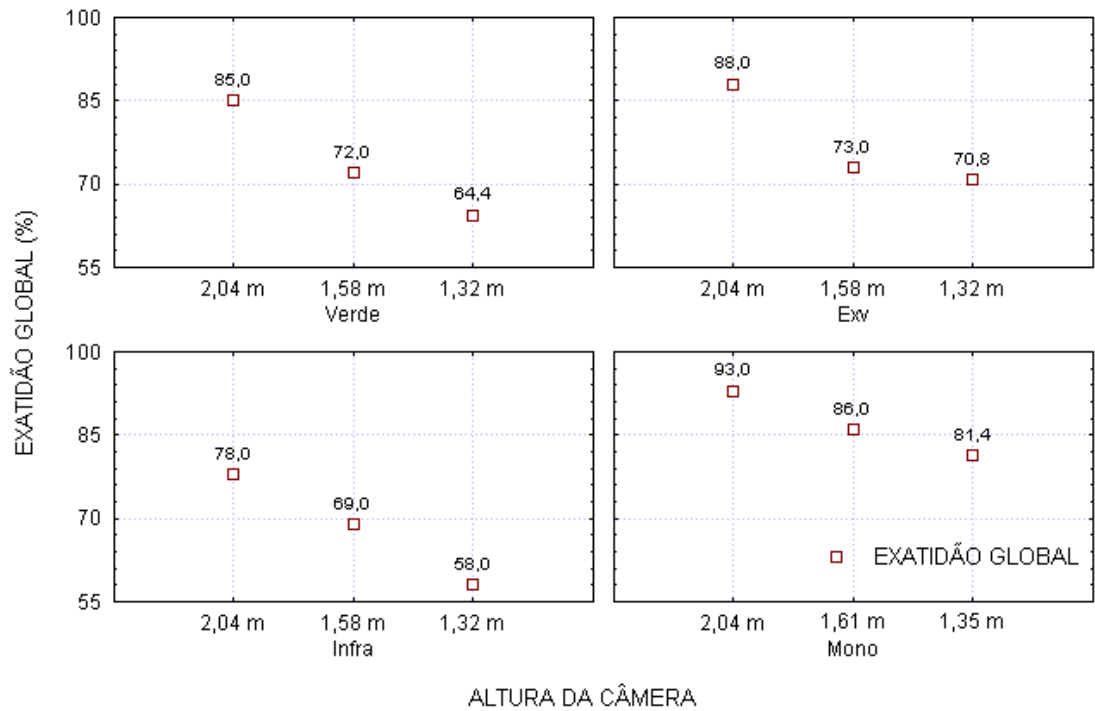


Figura 17 – Exatidão global para três alturas da câmera e quatro tipos de imagens utilizando o sub-bloco de 68 x 68 pixels e 32 níveis de valores de pixel.




Figura 18 – Área de exposição para diferentes alturas das câmeras: (a) câmeras RGB e (b) monocromática.

Dessa maneira, pelos resultados apresentados, a altura escolhida para ambas as câmeras CIR/RGB e monocromáticas foi 2,04 m.

#### 4.5 Definição do tipo de imagem

A Figura 19 representa o comportamento da exatidão global do classificador estatístico para os tipos de imagens da câmera CIR/RGB e níveis de iluminação, para o sub-bloco de 68 x 68 pixels, altura da câmera de 2,04 m e 32 níveis de valores de pixels. Percebe-se que existe uma tendência da imagem excesso de verde (Exv) apresentar melhor classificação em todos os níveis de iluminação. Isso pode ser explicado pelo realce do componente verde da imagem na fase de pré-processamento, ter aumentado o contraste entre plantas e solo, caracterizando melhor a textura do dossel.

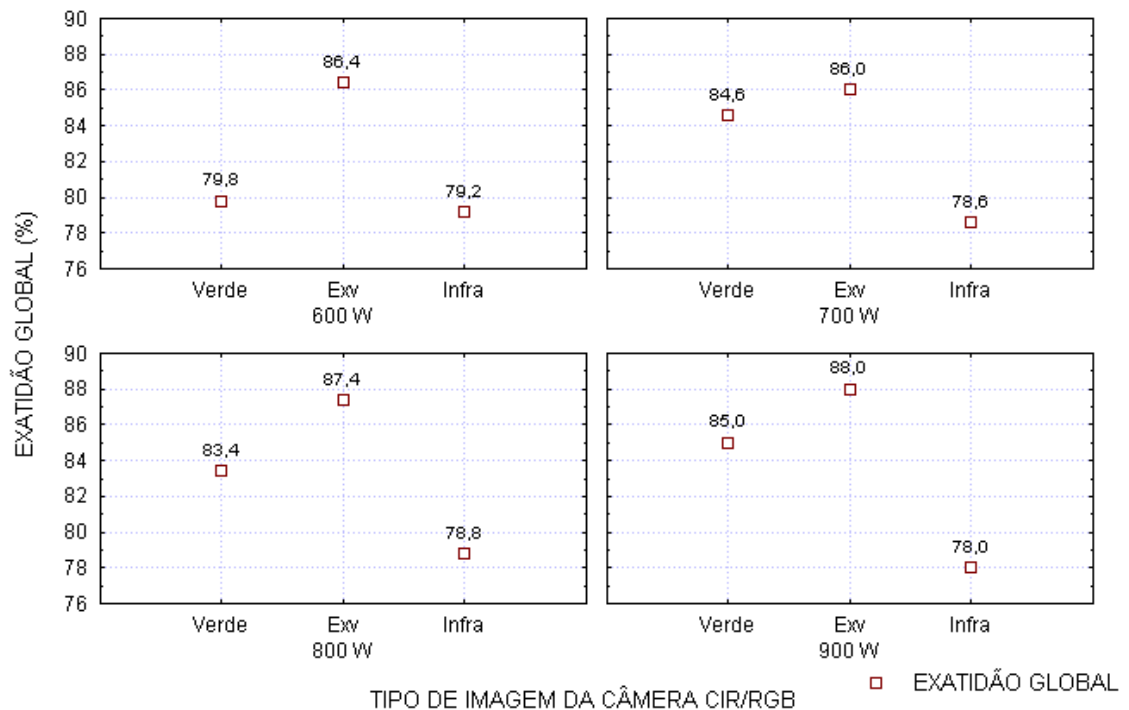


Figura 19 – Representação da exatidão global para os diferentes tipos de imagem CIR/RGB e níveis de iluminação, considerando a dimensão de bloco de 68 x 68 pixels, altura da câmera de 2,04 m, 32 níveis de valores de pixels.

Na Figura 20 são apresentadas as médias e dispersões dos valores da exatidão global dos quatro níveis de iluminação para cada tipo de imagem da câmera CIR/RGB. Observa-se que a imagem de excesso de verde (Exv) apresentou uma menor dispersão do que a imagem verde, mostrando uma

eficiência da normalização na fase de pré-processamento na redução do efeito da iluminação e sombra conforme pode ser visto na Figura 21.

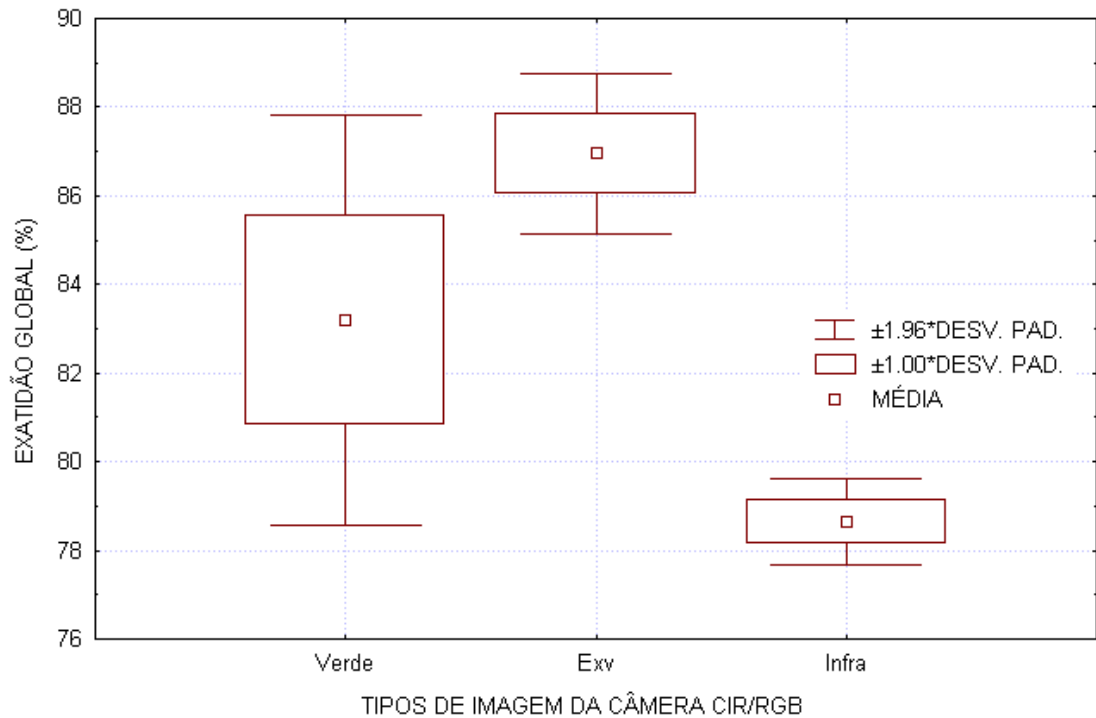


Figura 20 – Representação das médias e desvios dos valores de exatidão global da classificação as imagens da câmera CIR/RGB, considerando o sub-bloco 68 x 68 pixels, 32 níveis de valores de pixel e altura da câmera de 2,04 m.




Figura 21 – Diferença das imagens verde e excesso de verde para todos os níveis de iluminação, altura da câmera em 2,04 m e sub-bloco de 68 x 68 pixels: (a) verde, (b) Exv.

Dentre as imagens da câmera CIR/RGB, a que tendeu apresentar os melhores resultados de exatidão global foi a imagem de excesso de verde (Figura 20). Porém, houve uma tendência da imagem monocromática apresentar resultados superiores a imagem excesso de verde (Figura 22).

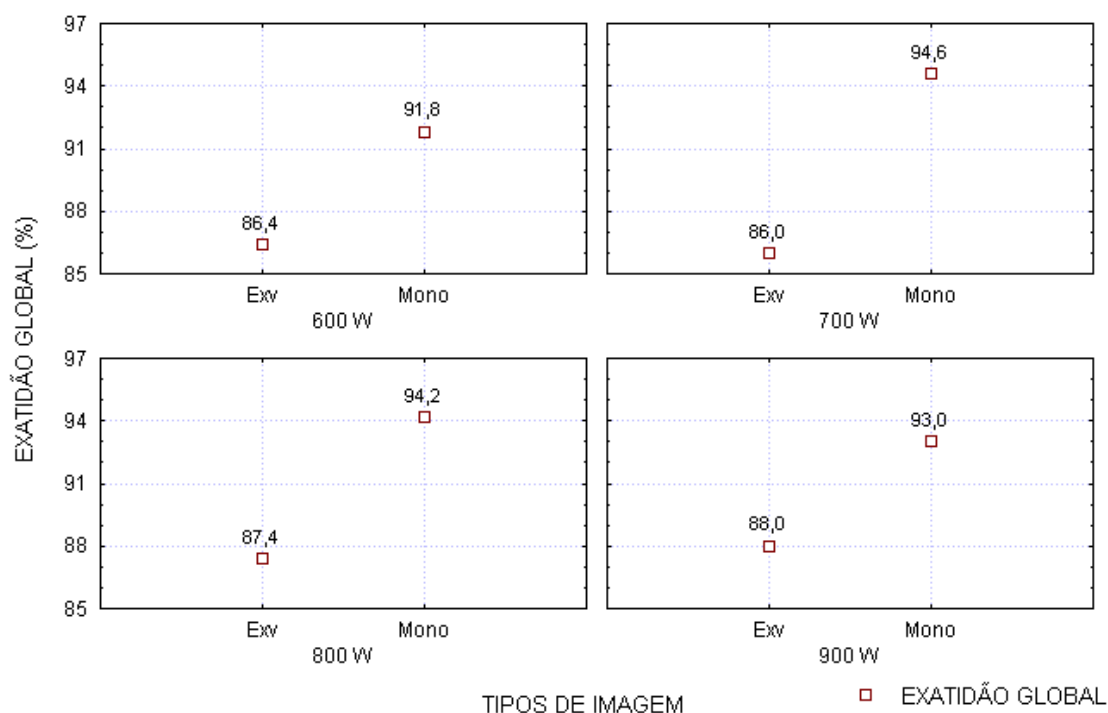


Figura 22 – Representação da exatidão global para a imagem excesso de verde da câmera CIR/RGB e a imagem monocromática (câmera monocromática), considerando a dimensão de bloco de 68 x 68 pixels, altura da câmera de 2,04 m, 32 níveis de valores de pixels para diferentes intensidades de iluminação.

A textura do dossel das imagens é uma textura grosseira o que faz desaparecer a vantagem da câmera CIR/RGB, de melhor resolução espacial (1,76 pixel/mm), em relação à câmera monocromática de resolução igual a 0,91 pixel/mm. Além disso, a câmera monocromática contempla parte do espectro infravermelho, o que pode ter auxiliado no aumento do contraste entre as folhas das plantas e o espaço entre elas (Figura 23).






Figura 23 – Imagens excesso de verde e monocromática para o nível de iluminação de 900 W, altura da câmera em 2,04 m e sub-bloco de 68 x 68 pixels: (a) Exv, (b) monocromática.

Outro fator que pode ter influenciado no desempenho da câmera monocromática é a lente auto-íris instalada na câmera que tenta manter constante a energia incidente no CCD. Isso pode explicar a dispersão reduzida nos valores de exatidão global dos quatro níveis de iluminação, como pode ser visualizado na Figura 24.

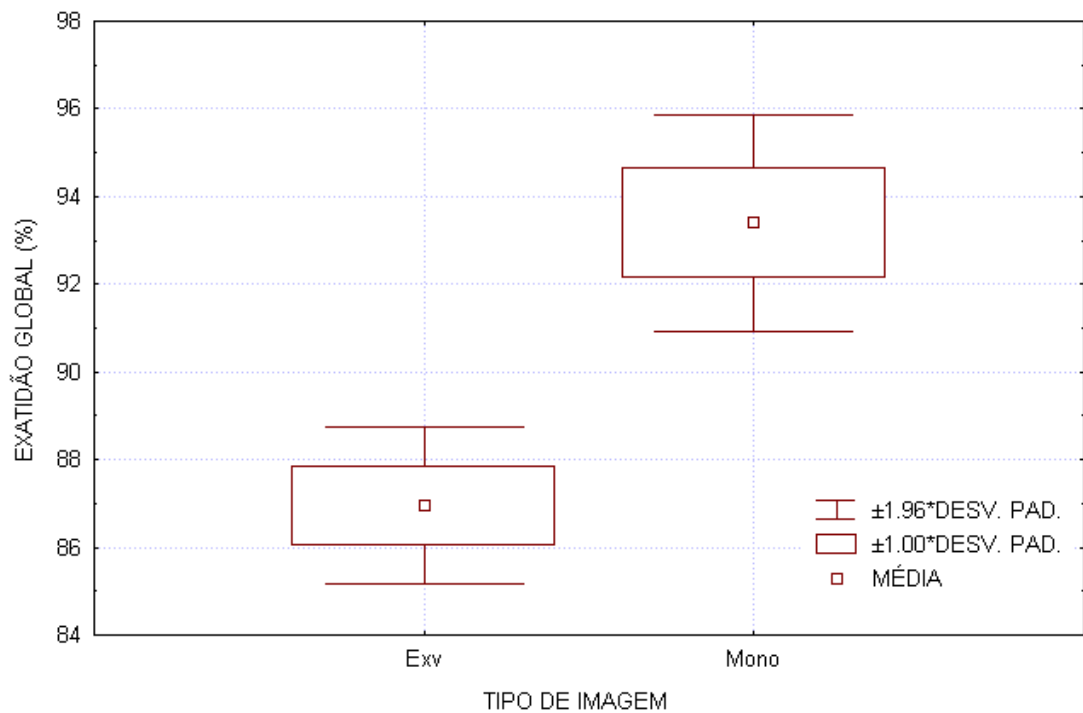


Figura 24 – Representação das médias e dispersões das imagens Exv e monocromática.

#### 4.6 Definição do tipo de classificador

Nos gráficos da Figura 25 é apresentado o comportamento da exatidão global na imagem excesso de verde da câmera CIR/RGB para cada tipo de classificador nos quatro níveis de iluminação e datas de coleta. Observa-se que existe uma tendência de que os três classificadores neuroniais resultem em melhores valores de exatidão global do que o classificador estatístico. Dentre os classificadores neuroniais, a exatidão global da classificação tende a melhorar com o aumento do tamanho do número de neurônios da rede. O classificador com maior número de neurônios (arq10\_10), tendeu a apresentar resultados superiores aos demais em todos os níveis de iluminação com exceção do nível 900 W. Os valores de exatidão globais alcançados pelo classificador estatístico foram de 75,3%, 76,8%, 77,5% e 77,3%, para os níveis de iluminação de 600, 700, 800 e 900 W, respectivamente. Estes valores de exatidão global são inferiores aos valores 78,8%, 83,8%, 86,2% e 85,2% alcançados pelo classificador neuronal que apresentou os melhores resultados.

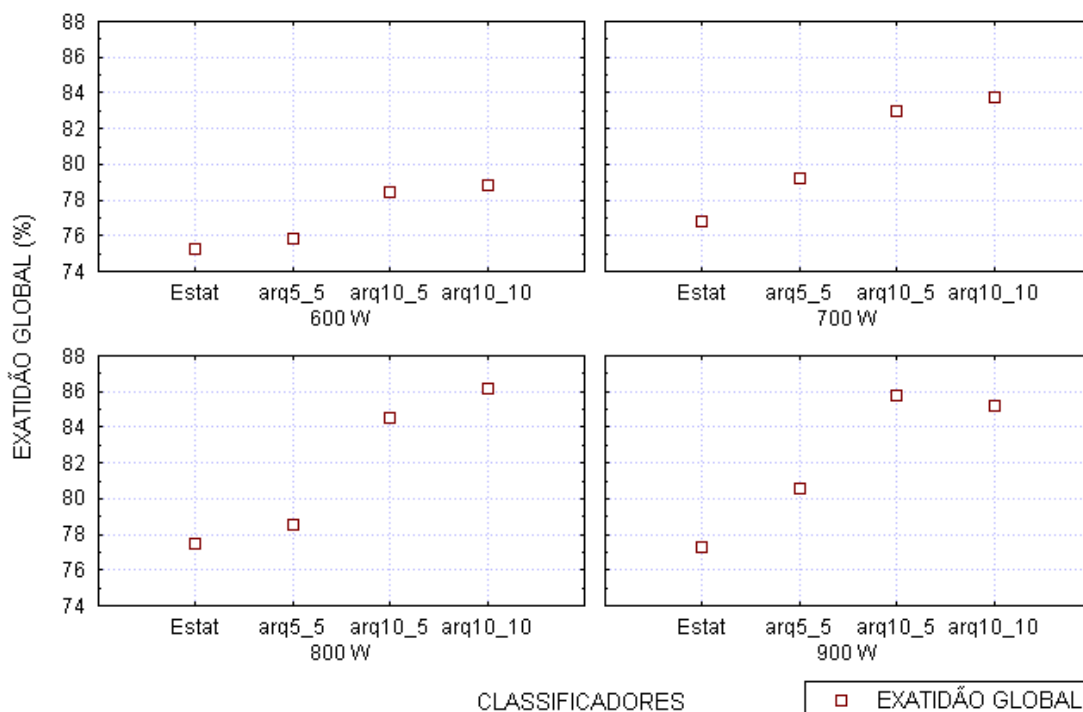


Figura 25 – Representação do desempenho dos quatro classificadores (um estatístico e três neuroniais) para as imagens de Exv da câmera CIR/RGB.

Nos gráficos da Figura 26 é apresentado o comportamento da exatidão global na imagem monocromática para cada tipo de classificador, nos quatro níveis de iluminação e todas as datas de coleta. Observa-se que existe uma tendência de que, com exceção do classificador com menor número de neurônios (arq5\_5), os classificadores neuroniais resultem em melhores valores de exatidão global do que o classificador estatístico. Dentre os classificadores neuroniais, a exatidão global da classificação tende a melhorar com o aumento do tamanho do número de neurônios da rede. O classificador com maior número de neurônios (arq10\_10), aparentemente, foi superior aos demais em todos os níveis de iluminação. Os valores de exatidão global alcançados pelo classificador estatístico foram de 80,1%, 79,8%, 80,0% e 77,9%, para os níveis de iluminação de 600, 700, 800 e 900 W, respectivamente. Estes valores de exatidão global são ligeiramente inferiores aos valores 86,5%, 83,4%, 84,4% e 81,0% alcançados pelo classificador neuronal que apresentou os melhores resultados.

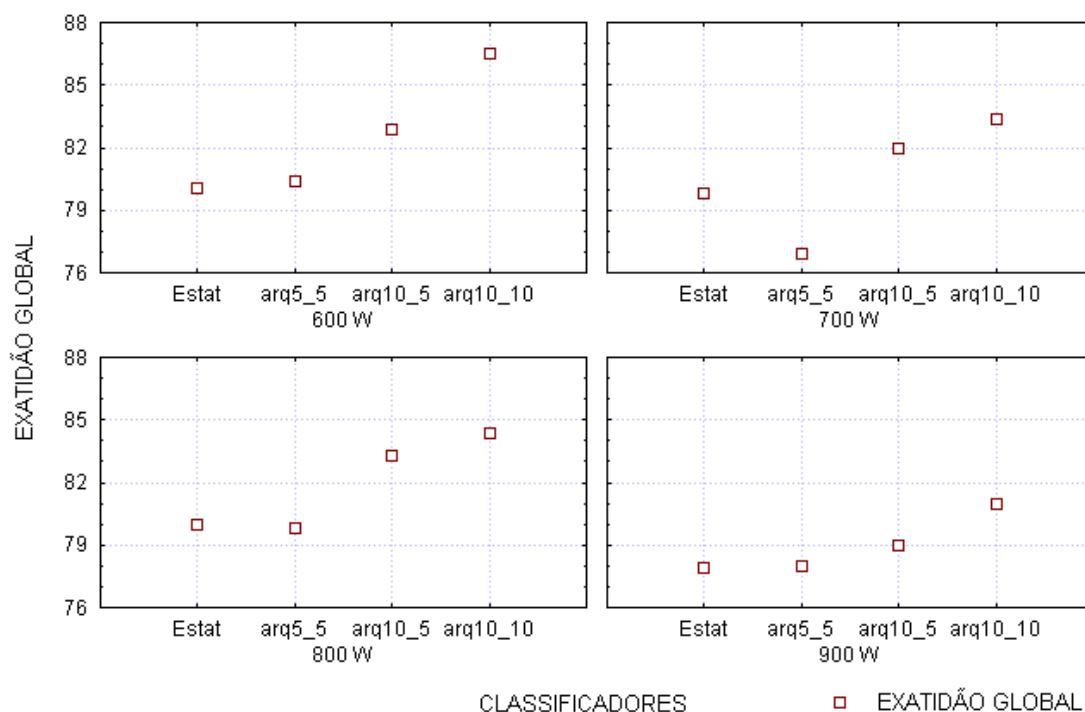


Figura 26 – Representação do desempenho dos quatro classificadores (um estatístico e três neuroniais) para as imagens monocromáticas.

O fato de que para ambas as imagens e níveis de iluminação a exatidão global da classificação ter melhorado com o aumento do número de neurônios da rede, sugere que aparentemente a arquitetura ideal da rede não foi utilizada neste estudo. Um número maior de neurônios nas camadas intermediárias pode melhorar a classificação entre as espécies de planta.

Analisando separadamente o desempenho do classificador neuronal com oito nós na camada de entrada, dez neurônios nas duas camadas intermediárias e cinco neurônios na camada de saída (arq10\_10), para cada espécie de planta utilizada no estudo por meio da Figura 27 percebe-se, que a exatidão da classificação tendeu a ser pior para o picão-preto independente do nível de iluminação estudado. Isso pode ter ocorrido porque a folha cotiledonar do mesmo possui textura semelhante às plantas daninhas de folha estreita utilizadas no experimento.

		1	2	3	4	5	Total	
capim colchão	1	193	0	17	26	0	236	
leiteiro	2	2	196	11	1	26	236	
picão preto	3	20	9	177	14	16	236	
timbete	4	38	1	8	188	1	236	
milho	5	0	27	30	3	176	236	
Exatidão global	78,8%						930	1180

600 W

		1	2	3	4	5	Total	
capim colchão	1	187	1	15	25	0	228	
leiteiro	2	0	202	12	1	13	228	
picão preto	3	20	13	177	11	7	228	
timbete	4	26	1	6	195	0	228	
milho	5	1	23	10	0	194	228	
Exatidão global	83,8%						955	1140

700 w

		1	2	3	4	5	Total	
capim colchão	1	200	0	15	26	2	243	
leiteiro	2	0	218	11	0	14	243	
picão preto	3	19	13	188	12	11	243	
timbete	4	26	2	3	212	0	243	
milho	5	0	10	4	0	229	243	
Exatidão global	86,2%						1047	1215

800 W

		1	2	3	4	5	Total	
capim colchão	1	189	0	22	22	1	234	
leiteiro	2	1	205	10	1	17	234	
picão preto	3	22	10	180	13	9	234	
timbete	4	22	1	2	209	0	234	
milho	5	0	12	7	1	214	234	
Exatidão global	85,2						997	1170

900 W

Figura 27 – Representação das matrizes de classificação para o classificador neuronal (arq10\_10) em todos os níveis de iluminação para as imagens de excesso de verde.

## 5. RESUMO E CONCLUSÕES

A agricultura de precisão busca adequar as práticas agrícolas às exigências e potencial produtivo de parcelas dos talhões, objetivando maximizar o lucro, racionalizar o uso dos fatores de produção e reduzir a contaminação ambiental. Esses objetivos estão condicionados ao desenvolvimento de técnicas capazes de operacionalizá-los. As técnicas de Visão Artificial podem trazer benefícios, principalmente, na racionalização do uso de herbicidas que é uma das maiores fontes de custos e de contaminação ambiental. O objetivo do presente trabalho foi desenvolver e avaliar um sistema para identificação de plantas daninhas e da planta de milho, utilizando imagens digitais coloridas e monocromáticas. Foram obtidas imagens de plantas de picão preto (*Bidens pilosa* L.), leiteira, (*Euphorbia heterophylla* L.), capim-milhã (*Digitaria horizontalis* Willd) e timbête (*Cenchrus echinatus* L.). Para a classificação das plantas utilizou-se análise textural com base na técnica da matriz de co-ocorrência de sub-blocos das imagens. Das matrizes de co-ocorrência retirou-se oito parâmetros texturais, os quais foram utilizados com dados de entrada em um classificador. Foram testados quatro classificadores (um estatístico e três neuronais). Testou-se também, fatores que podem interferir na classificação automática de plantas daninhas por um sistema de visão artificial: três dimensões de sub-bloco da imagem (17 x 17, 34 x 34, 68 x 68 pixels), quatro níveis de valores numéricos de pixels (32, 64, 128 e 256 níveis), três alturas da câmera (1,32 m, 1,58 m, 2,04 m para a câmera CIR/RGB e 1,35, 1,61, 2,04 m para a monocromática) quatro tipos de imagens (verde, excesso de verde, falsa cor infravermelha e monocromática), três

diferentes números de dias após a emergência (22 DAE, 25 DAE, 29 DAE), e quatro níveis de iluminação (600, 700, 800 e 900 W). Inicialmente foram definidos os parâmetros dimensões do sub-bloco, número de níveis de valores de pixel e altura da câmara para 29 dias após a emergência, nível de iluminação de 900 W e classificador estatístico. As combinações de variáveis que apresentaram melhores exatidões na classificação foram escolhidas para se definir o melhor tipo de imagem por meio da influência de diferentes níveis de iluminação. Por fim, comparou-se a performance dos quatro classificadores para os diferentes dias após a emergência.

Os resultados obtidos indicaram as seguintes conclusões:

- Dadas as condições metodológicas do trabalho, observa-se que os melhores valores da exatidão global, em todas as combinações dos fatores estudados tenderam a ocorrer para o tamanho de bloco 68 x 68 pixels.

- A variação dos níveis de valores aparentemente não alterou a classificação, justificando a adoção de 32 níveis de valores de pixels devido ao menor tempo de processamento.

- A altura da câmara de 2,04 m tendeu a apresentar resultados melhores da exatidão global.

- Para a câmara CIR/RGB a imagem que tendeu a apresentar os melhores resultados de exatidão global foi a imagem de excesso de verde.

- A imagem monocromática tendeu a apresentar valores superiores a imagem excesso de verde da câmara CIR/RGB, aos 29 DAE, altura da câmara em 1,35 m e nível de iluminação em 900 W.

- As exatidões globais alcançadas pelo classificador estatístico entre 75,3 e 77,5% para a imagem excesso de verde e, 77,9 e 80,1% para a imagem monocromática, tenderam a ser inferiores aos resultados obtidos pelo classificador neuronal para os dois tipos de imagens testadas.

- O classificador neuronal com oito nós de entrada, 10 neurônios nas duas camadas intermediárias e cinco na camada de saída, tendeu a apresentar os melhores resultados de exatidão global variando entre 81 e 86,5% para a imagem monocromática, e, entre 78,8 e 86,2% para a imagem excesso de verde dependendo da condição de iluminação.

## 6. SUGESTÕES PARA TRABALHOS FUTUROS

Com o objetivo de suprir a necessidade de estudos que detectem a influência dos vários fatores que podem afetar a classificação automática de plantas daninhas por um sistema de visão artificial, dado o grande impacto que a utilização desta ferramenta pode ter sobre a redução de custos e dos riscos ambientais e, aliada a necessidade da formação de técnicos que dominem estas tecnologias sugere-se para trabalhos futuros os seguintes estudos.

- Verificar o efeito de uma redução ainda maior dos níveis de valores de pixel, pois a redução dos mesmos interfere fortemente no tempo computacional;
- Testar blocos de tamanhos maiores em diferentes densidades de planta;
- Estudar os efeitos dos fatores considerados sobre cada espécie de planta daninha incluída no estudo;
- Analisar quais características texturais possuem maior influência na classificação.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, E. A.; KHOURY JUNIOR, J. K.; PINTO, F. A. C.; QUEIROZ, D. M. Classificação de plantas daninhas utilizando características texturais em imagens digitais. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG, 2002. CD Rom.
- ARAÚJO, A. A.; OLIVEIRA, R.A.R.; CLAUDINO, L.M.B.; GUIMARÃES, S.J.F.; BASTOS, E. Unsupervised image segmentation based on wavelet textural analysis and neural networks. **Proceedings of the IBERAMIA-SBIA 2000 Workshops, I Workshop on Artificial Intelligence and Computer Vision - WAICV**, Atibaia-SP, Brazil, 2000, pp 77-81.
- BALASTREIRE, L. A.; BAIO, F. H. R. Avaliação de um sistema para aplicação localizada de defensivos baseado na variabilidade espacial das plantas daninhas. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG. 2002. CD Rom.
- BASSET, O.; BUQUET, B.; ABOUELKARAM, S.; DELACHARTRE, P.; CULIOLI, J. Application of texture image analysis for the classification of bovine meat. **Food Chemistry**. Nº 69, p. 437- 445, 2000.
- BROWN, R. B.; STECKLER, J-P. G. A. Prescription maps for spatially variable herbicide application in no-till corn. **Transactions of the ASAE**, v. 38, nº. 6, p. 1659-1666, 1995.



- BURKS, T.F.; SHEARER, S.A.; GATES, R. S.; DONOHUE, K. D. Backpropagation neural network design and evaluation for classifying weed species using color image texture. **Transactions of the ASAE**, v. 43, n° 4, p. 1029-1037, 2000.
- BURKS, T.F.; SHEARER, S.A.; PAYNE, F. A. Classification of weed using color texture features and discriminant analysis. **Transactions of the ASAE**, v. 43, n° 2, p. 441-448, 2000.
- BURKS, T.F.; SHEARER, S.A.; PAYNE, F. A. Evaluation of statistical discriminant analysis techniques for classification of weed species using machine vision. **ASAE Annual International Meeting**. Orlando, Florida. Paper n° 983037, 18p, 1998.
- CHANCELLOR, W. J.; GORONEA, M. A. Effects of spatial variability of nitrogen, moisture, and weeds on the advantages of site-specific application for wheat. **Transactions of the ASAE**, v. 37, n° 3, p. 717-724, 1993.
- EL-FAKI, M. S.; ZHANG, N.; PETERSON, D. E. Weed detection using color machine vision. **Transactions of the ASAE**, v. 43, n° 6, p. 1969-1978, 2000a.
- EL-FAKI, M. S.; ZHANG, N.; PETERSON, D. E. Factors affecting color-based weed detection. **Transactions of the ASAE**, v. 43, n° 4, p. 1001-1009, 2000b.
- FAN, G.; ZHANG, N.; PETERSON, D. E.; LOUGHIN, T. M. Real-time weed detection using machine vision. **The 1998 ASAE annual International Meeting**. Orlando, Florida. Paper n° 983032, 17 p, 1998.
- FELTON, W. L.; DOSS, A. F.; NASH, P. G.; McCLOY, K. R. A microprocessor controlled technology to selectively spot spray weeds. **Proceedings of the Automated Agricultural for the 21st Century Symposium**, Chicago, IL. p. 427-432, 1991.

- FELTON, W. L.; McCLOY, K. R. Spot spraying. **Agricultural Engineering**, v.73, n<sup>o</sup>. 6, p. 9-12.1992.
- GOEL, P. K.; PRASHER, S. O.; PATEL, R. M.; DITOMMASO, A.; SMITH, D. L. Airborne optical remote sensing for detection of weed investation in site specific management of field crops. **The 2000 ASAE Annual International Meeting**. Milwaukee, WI. Paper n<sup>o</sup> 003056, 13 p, 2000.
- GONZALEZ, R.C.; WOODS, R.E. **Digital image processing**. Addison Wesley, 1992. New York. 716 p.
- GOPALAPILLAI, S., L. TIAN, C. GOERING, AND L. TANG. Identification and mapping of weed density in a soybean field using DMS images. **The 2000 ASAE Annual International Meeting**. Milwaukee, WI. Paper n<sup>o</sup> 003058, p, 2000.
- HEMMING, J.; RATH, T. Computer-vision-based weed identification under field conditions using controlled lighting. **Journal Agricultural Engineering Research**, v.78, n<sup>o</sup> 3, p. 233-243, 2001.
- HUMMEL, J. W.; STOLLER, E. W. On-the-go weed sensing and herbicide application for the Northern Cornbelt. **The 2002 ASAE Annual International Meeting**. Chicago, IL. Paper n<sup>o</sup> 021021, 13p, 2002.
- JAYAS, D. S.; PALIWAL, J.; VISEN, N. S. Multi-layer Neural Networks for image analysis of agricultural products. **Journal Agricultural Engineering Research**, v. 77. n<sup>o</sup> 2, p. 119-128, 2000.
- LAMB, D.W.; BROWN, R. B. Remote Sensing and mapping of weeds in crops. **Journal Agricultural Engineering Research**, v. 78. n<sup>o</sup> 2, p. 117-125, 2001.
- LEE, W. S.; SLAUGHTER, D. C. Plant recognition using Hardware-based neural network. **The 1998 ASAE annual International Meeting**. Orlando, Florida. Paper n<sup>o</sup> 983040, 14 p, 1998.

- MANTOVANI, E.C. Prefácio. In: **Borém, A.; Giudice, M.P.; Queiroz, D.M.; Mantovani, E.C.; Ferreira, L.R.; Valle, F.X.R.; Gomide, R.L.** Editores. Agricultura de Precisão. Viçosa: UFV, 2000.
- MARKS, R. S.; WARD, J. R. Nutrients and pesticide threats to water quality. In: **Proc. Soil Specific management workshop.** Editors: P.C. Roberts, R. H. Rust, e W. E. Larson. Madison, Wis.: ASA-CSSA-SSSA. 1993.
- MARQUES FILHO, O.; VIEIRA NETO, H. Processamento digital de imagens. Rio de Janeiro: **Editores Brasport**, 1999, 406 p.
- NEVES, E. M.; RODRIGUES, L.; DAYOUB, M.; DRAGONE, D. S. Conheça a estrutura de consumo de defensivos no Brasil. **Revista Coopercitrus**, Bebedouro, SP. Ano XVI, 2002.
- NGOUAJIO, M.; LEROUX, G. D.; LEMIEUX, C. Influence of images recording height and crop growth stage on leaf cover estimates and their performance in yield prediction models. **Crop Protection.** V. 18, p. 501-508, 1999.
- NORDMEYER, H.; HÄUSLER, A.; NIEMANN, P. Patchy weed control as na approach in precision farming. In: **Precision Agriculture**, Warwick, *Proceedings...* Oxford: SCI, v.1, 1997. p.307-314. 1997.
- NUSPL, S. J.; RUDOLPH, W. W.; GUTHLAND, R. Use of injection for site-specific chemical application. In: **Precision Agriculture**, 3, Bloomington, *Proceedings...* Madison: ASA-CSSA-SSSA, p.739-744. 1996.
- PARK, B.; CHEN Y.R. Co-occurrence matrix texture feature of multi-spectral images on poultry carcasses. **Journal Agricultural Engineering Research**, v. 2, nº.78, p. 127-139, 2001.

- PARK, B.; CHEN, Y. R.; NGUYEN, M. Multi-spectral image analysis using neural network algorithm for inspection of poultry carcasses. **Journal Agricultural Engineering Research**, v.1, nº 69, p. 351-363, 1998.
- PHAM, D. T.; ALCOCK, R. J. Automated grading and defect detection: A review. **Forest Products Journal**, v. 48, nº. 4, p. 34-42, 1998.
- PINTO, F.A.C.; SENA Jr, D.G.; QUEIROZ, D.M.; GOMIDE, R.L.. Visão artificial na agricultura de precisão. In: III Simpósio sobre agricultura de precisão, 2001, Piracicaba, Anais... Piracicaba.
- QUEIROZ, D.M., DIAS, G.P., MANTOVANI, E.C. Agricultura de precisão na produção de grãos. In: **Borém, A.; Giudice, M.P.; Queiroz, D.M.; Mantovani, E.C.; Ferreira, L.R.; Valle, F.X.R.; Gomide, R.L.** Editores. Agricultura de Precisão. Viçosa: UFV, p. 1-41. 2000.
- ROBERT, P. C. The economical feasibility of precision agriculture. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG, 2002. CD Rom.
- SALVADOR, A.; ANTUNIASSI, U. R. Métodos de mapeamento da distribuição espacial da infestação de plantas daninhas em sistemas de agricultura de precisão. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG, 2002. CD Rom.
- SANTOS, N. T.; SENA JÚNIOR, D. G.; PINTO, F. A. C.; QUEIROZ D. M. Análise estatística de limiares de imagens tomadas em três estádios de desenvolvimento de plantas de milho. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG, 2002. CD Rom.
- SENA JÚNIOR, D.G. **Sistema de visão artificial para identificação de plantas de milho atacadas pela lagarta do cartucho (*Spodoptera frugiperda*)**. Viçosa, MG: UFV, 2002. 71p. (dissertação mestrado).

- SÉRÉLÉ, C.Z.; GWYN, Q.H.J.; BOISVERT, J.B.; PATTEY, E.; McLAUGHLIN, N.; DAOUST, G. Detection of corn nitrogen status from airborne vis-nir imagery using artificial neural networks. IN: **Proceedings of the Fifth International Conference on Precision Agriculture**. ASA-CSSA-SSSA, p.12. 2000.
- SHEARER, S. A. **Plant identification using color co-ocurrence matrices derived from digitalized images**. Ohio State University, 1987. (PhD these).
- SHEARER, S. A.; HOLMES, R. G. Plant identification using color co-occurrence matrices. **Transactions of the ASAE**, v. 33, nº 6, p. 2037-2044, 1990.
- SINDAG 2002 – **Sindicato Nacional da Indústria para Defesas Agrícolas** - <http://www.sindag.com.br/index.php3> – 05/02/2003, 19:48 h.
- STEWARD, B. L., TIAN, L. F. Real-time machine vision weed-sensing. **The 1998 ASAE Annual International Meeting**. Orlando, Florida. Paper nº 983033. 17p. 1998.
- SU, M. H. B.; TIAN, L. F.; REID, J. F. Spatial-frequency analysis for detection of weed-infestation areas with the wavelet decomposition. **The 1997 ASAE Annual International Meeting**. Minneapolis, Munnesota. Paper nº 9733133. 1997.
- SUI, R.; JOHN B.; WILKERSON, J. B.; HART, W. E.; HOWARD, D. D. Integration of neural networks with a spectral reflectance sensor to detect nitrogen deficiency in cotton. **The 1998 ASAE Annual International Meeting**. Orlando, Florida. Paper nº 983104, 12 p, 1998.
- TANG, L.; TIAN, L. F.; STEWARD, B. L.; REID, J. F. Texture-based weed classification using Gabor Wavelets and Neural Network for real-time selective herbicide applications. **ASAE/CSAE-SCGR Annual International Meeting**. Toronto, Ontario. Paper nº 993036, 10 p, 1999.

- THOMPSON, J. F.; STAFFORD, J. V.; MILLER, P. C. H. Selective application of herbicides to UK cereal crops. **ASAE Annual International Meeting**. Paper nº. 901629. St. Joseph, Mich.: ASAE, 1990.
- TIAN, L. Machine vision-based precision farming systems. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG. 2002 (palestra). CD Rom.
- TIAN, L.; REID, J.F.; HUMMEL, J.W. Development of a precision sprayer for site-specific weed management. **Transactions of the ASAE**. St. Joseph, MI. v. 42, nº.4, p. 893 – 900. 1999.
- WANG, N.; ZHANG, N.; PETERSON, D. E.; DOWELL, F. E. Testing of a Spectral-based Weed Sensor. **ASAE Annual International Meeting**. Milwaukee, WI. Paper nº 003127, 13 p, 2000.
- WILLIS, B. D.; STOLLER, E. W. Weed suppression for vegetation management in corn and soybeans. **Proc. N. Central Weed. Sci. Soc.** v. 45, n.9. 1990.
- YANG, C. C.; PRASHER, S. O.; LANDRY, J. A. Application of artificial neural networks to image recognition in precision farming. **ASAE Annual International Meeting**. Orlando Florida. Paper nº 983039, 10 p, 1998.
- YANG, C. C.; PRASHER, S. O.; LANDRY, J. A. Weed recognition in precision farming. **ASAE Annual International Meeting**. Toronto, Ontario. Paper nº 993115, 10 p, 1999.
- ZANDONADI, R. S.; PINTO, F. A. C.; SENA JÚNIOR, D. G.; QUEIROZ, D. M. Efeito do tamanho de blocos de imagens digitais na classificação automática de plantas de milho atacadas por *Elasmopalpus lignosellus*. **II Simpósio Internacional de Agricultura de Precisão**. Viçosa, MG. 2002. CD Rom.

ZHANG, N.; CHAISATTAPAGON, C. Effective criteria for weed identification in wheat fields using machine vision. **Transactions of the ASAE**. St. Joseph, MI v. 38, n<sup>o</sup>.3, p. 965-974. 1995.

## **APÊNDICES**



## Apêndice A

### **Código-fonte do programa computacional implementado no MATLAB para a obtenção das coordenadas dos sub-blocos das imagens**

```
%Algoritmo para criar arquivo texto para corte de blocos em imagens
%LABORATÓRIO DE VISÃO ARTIFICIAL E PROJETO DE MÁQUINAS
(PROVISAGRO)marco de 2003
clear
% le a imagem
[nome, caminho]=uigetfile({'*.bmp'}, 'imagem a processar' );
conta=0;
% verifica se algum dado foi fornecido
if ~ischar(nome)
    warndlg('imagem nao fornecida!!');
else
    arquivo=fullfile(caminho,nome);
    ima=imread(arquivo);
end
imshow(ima);
[col lin r]=impixel(ima);
local=strcat(nome, '.txt');
fid=fopen(local, 'w');
arq=[col lin];
fprintf(fid, '%4.0f %4.0f\n', arq);
conta=size(col,1)
fclose(fid);
```

## Apêndice B

### Código-fonte do programa de computador implementado no MATLAB para recorte dos sub-blocos das imagens

```
% Algoritmo para corte dos sub-blocos
% Autor DARLY GERALDO SENA JUNIOR & ROBERTO CARLOS ORLANDO
% marco de 2003
clear
[nome, caminho]=uigetfile({'*.bmp'}, 'imagem a processar' );
% Checa se o nome da imagem foi fornecida
if ~ischar(nome)
    warndlg('imagem nao fornecida!!');
else
    arquivo=fullfile(caminho,nome);
    ima=imread(arquivo);
end
% Arquivo de coordenadas de corte dos blocos com nome igual a da
imagem que será recortada.
x=xlsread('0710z1h3i4.xls');
%recortando e gravando as amostras
for i=1:100
    i
    lin=x(i,2);
    col=x(i,1);
    amostra=ima(lin:lin+67,col:col+67,:);
    nome=strcat('bloco',num2str(i),'.tif');
    imwrite(amostra,nome);
end
clear
[nome, caminho]=uigetfile({'*.bmp'}, 'imagem a processar' );
% Checa se o nome da imagem foi fornecida
if ~ischar(nome)
    warndlg('imagem nao fornecida!!');
else
    arquivo=fullfile(caminho,nome);
    ima=imread(arquivo);
end
% Arquivo de coordenadas de corte dos blocos com nome igual a da
imagem que será recortada.
x=xlsread('0710z2h3i4.xls');
%recortando e gravando as amostras
for i=1:100
    i
    lin=x(i,2);
    col=x(i,1);
    amostra=ima(lin:lin+67,col:col+67,:);
    nome=strcat('bloco',num2str(i+100),'.tif');
    imwrite(amostra,nome);
end
clear
[nome, caminho]=uigetfile({'*.bmp'}, 'imagem a processar' );
% Checa se o nome da imagem foi fornecida
if ~ischar(nome)
    warndlg('imagem nao fornecida!!');
else
    arquivo=fullfile(caminho,nome);
```

```
        ima=imread(arquivo);
end
% Arquivo de coordenadas de corte dos blocos com nome igual a da
imagem que será recortada.
x=xlsread('0710z3h3i4.xls');
%recortando e gravando as amostras
for i=1:100
    i
    lin=x(i,2);
    col=x(i,1);
    amostra=ima(lin:lin+67,col:col+67,:);
    nome=strcat('bloco',num2str(i+200),'.tif');
    imwrite(amostra,nome);
end
```

## Apêndice C

### Código-fonte do programa de computador implementado no MATLAB para obtenção dos parâmetros texturais da matriz de co-ocorrência

```
% Programa para calcular a matriz de co-ocorrencia da matriz I
% OBS. So serve para distancia entre pixels igual a 1. Dessa maneira a
% matriz de co-ocorencia e simétrica. O algoritmo gera os parâmetros
% texturais nas direções 0° 45° 90° e 135°. No desenvolvimento da
% pesquisa utilizou-se somente 0°
% ROBERTO CARLOS ORLANDO & HENRIQUE ANASTÁCIO ALVES
% marco de 2003

clear
for n=1:300
    n
    % lendo as amostras

A=imread(strcat('C:\roberto\0717b68\verde\c\bloco',num2str(n),'.tif'))
;

% fazendo o excesso de verde
Im=(double(A(:,:,2)).*2-double(A(:,:,1))-
double(A(:,:,3)))./(double(A(:,:,1))+double(A(:,:,2))+double(A(:,:,3))
);
Ii=(Im+1).*255./3;
I=fix(Ii);
clear Ii A;

ngl=256; % numero de niveis de verde
n_linhas = size(I,1); % numero de linhas
n_colunas = size(I,2); %numero de colunas
P=zeros(ngl); % zera a matriz de co-ocorrencia
P_45=zeros(ngl);
P_90=zeros(ngl);
P_135=zeros(ngl);

% Matriz P para teta igual a zero
for i=1:n_linhas
    for j=1:n_colunas
        if (j==1)
            P(I(i,1)+1,I(i,2)+1)=P(I(i,1)+1,I(i,2)+1)+1;
        Else if (j==n_colunas)
            P(I(i,n_colunas)+1,I(i,n_colunas-
1)+1)=P(I(i,n_colunas)+1,I(i,n_colunas-1)+1)+1;
        else
            P(I(i,j)+1,I(i,j+1)+1)=P(I(i,j)+1,I(i,j+1)+1)+1;
            P(I(i,j)+1,I(i,j-1)+1)=P(I(i,j)+1,I(i,j-1)+1)+1;
        end
    end
end

%Matriz P para teta igual a 45
for i=1:n_linhas
    for j=1:n_colunas
        if (i==1)
            if (j~=1)
```

```

        P_45(I(i,j)+1,I(i+1,j-1)+1)=P_45(I(i,j)+1,I(i+1,j-1)+1)+1;
    end
    else if (i==n_linhas)
        if (j~=n_colunas)
            P_45(I(i,j)+1,I(i-1,j+1)+1)=P_45(I(i,j)+1,I(i-
1,j+1)+1)+1;
        end
        else if (j==1)
            P_45(I(i,j)+1,I(i-1,j+1)+1)=P_45(I(i,j)+1,I(i-
1,j+1)+1)+1;
        else if (j==n_colunas)
            P_45(I(i,j)+1,I(i+1,j-1)+1)=P_45(I(i,j)+1,I(i+1,j-
1)+1)+1;
        else
            P_45(I(i,j)+1,I(i+1,j-1)+1)=P_45(I(i,j)+1,I(i+1,j-
1)+1)+1;
            P_45(I(i,j)+1,I(i-1,j+1)+1)=P_45(I(i,j)+1,I(i-
1,j+1)+1)+1;
        end
    end
end
end
end
end
end

% matriz P para teta igual a 90
for i=1:n_linhas
    for j=1:n_colunas
        if (i==1)
            P_90(I(1,j)+1,I(2,j)+1)=P_90(I(1,j)+1,I(2,j)+1)+1;
        else if (i==n_linhas)
            P_90(I(n_linhas,j)+1,I(n_linhas-
1,j)+1)=P_90(I(n_linhas,j)+1,I(n_linhas-1,j)+1)+1;
        else
            P_90(I(i,j)+1,I(i+1,j)+1)=P_90(I(i,j)+1,I(i+1,j)+1)+1;
            P_90(I(i,j)+1,I(i-1,j)+1)=P_90(I(i,j)+1,I(i-1,j)+1)+1;
        end
    end
end
end

% matriz P para teta igual a 135
for i=1:n_linhas
    for j=1:n_colunas
        if (i==1)
            if (j~=n_colunas);
                P_135(I(i,j)+1,I(i+1,j+1)+1)=P_135(I(i,j)+1,I(i+1,j+1)+1)+1;
            end
        else if (i==n_linhas);
            if (j~=1);
                P_135(I(i,j)+1,I(i-1,j-1)+1)=P_135(I(i,j)+1,I(i-1,j-
1)+1)+1;
            end
        else if (j==1);
            P_135(I(i,j)+1,I(i+1,j+1)+1)=P_135(I(i,j)+1,I(i+1,j+1)+1)+1;
        else if (j==n_colunas);
            P_135(I(i,j)+1,I(i-1,j-1)+1)=P_135(I(i,j)+1,I(i-1,j-
1)+1)+1;
        else

```

```

P_135(I(i,j)+1,I(i+1,j+1)+1)=P_135(I(i,j)+1,I(i+1,j+1)+1)+1;
P_135(I(i,j)+1,I(i-1,j-1)+1)=P_135(I(i,j)+1,I(i-1,j-
1)+1)+1;
end
end
end
end
end
end
end

```

```

% Normalização da matriz

```

```

p = P./sum(sum(P));
p_45 = P_45./sum(sum(P_45));
p_90 = P_90./sum(sum(P_90));
p_135 = P_135./sum(sum(P_135));

```

```

% probabilidade marginal da matriz

```

```

px=sum(p);
px_45=sum(p_45);
px_90=sum(p_90);
px_135=sum(p_135);

```

```

% momento angular

```

```

f1=sum(sum(p.^2));
f1_45=sum(sum(p_45.^2));
f1_90=sum(sum(p_90.^2));
f1_135=sum(sum(p_135.^2));

```

```

% valor medio

```

```

f2=0;
f2_45=0;
f2_90=0;
f2_135=0;
for i=0:ngl-1
    f2=(i*px(i+1))+f2;
    f2_45=(i*px_45(i+1))+f2_45;
    f2_90=(i*px_90(i+1))+f2_90;
    f2_135=(i*px_135(i+1))+f2_135;
end

```

```

% variância

```

```

f3=0;
f3_45=0;
f3_90=0;
f3_135=0;
for i=0:ngl-1
    f3=((i-f2)^2)*px(i+1)+f3;
    f3_45=((i-f2_45)^2)*px_45(i+1)+f3_45;
    f3_90=((i-f2_90)^2)*px_90(i+1)+f3_90;
    f3_135=((i-f2_135)^2)*px_135(i+1)+f3_135;
end

```

```

% correlação

```

```

f4=0;
f4_45=0;
f4_90=0;
f4_135=0;

```

```

for i=0:ngl-1
    for j=0:ngl-1
        f41=i*j*p(i+1,j+1)+f4;
        f41_45=i*j*p_45(i+1,j+1)+f4_45;
        f41_90=i*j*p_90(i+1,j+1)+f4_90;
        f41_135=i*j*p_135(i+1,j+1)+f4_135;
    end
end
if f3==0
    f3=0.00001;
end
if f3_45==0
    f3_45=0.00001;
end
if f3_90==0
    f3_90=0.00001;
end
if f3_135==0
    f3_135=0.00001;
end
f4=(f41-f2^2)/f3;
f4_45=(f41_45-f2_45^2)/f3_45;
f4_90=(f41_90-f2_90^2)/f3_90;
f4_135=(f41_135-f2_135^2)/f3_135;

% momento do produto
f5=0;
f5_45=0;
f5_90=0;
f5_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        f5=((i-f2)*(j-f2))*p(i+1,j+1)+f5;
        f5_45=((i-f2_45)*(j-f2_45))*p_45(i+1,j+1)+f5_45;
        f5_90=((i-f2_90)*(j-f2_90))*p_90(i+1,j+1)+f5_90;
        f5_135=((i-f2_135)*(j-f2_135))*p_135(i+1,j+1)+f5_135;
    end
end

% Diferença inversa do momento
f6=0;
f6_45=0;
f6_90=0;
f6_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        f6=(p(i+1,j+1)/(1+(i-j)^2))+f6;
        f6_45=(p_45(i+1,j+1)/(1+(i-j)^2))+f6_45;
        f6_90=(p_90(i+1,j+1)/(1+(i-j)^2))+f6_90;
        f6_135=(p_135(i+1,j+1)/(1+(i-j)^2))+f6_135;
    end
end

% entropia
f7=0;
f7_45=0;
f7_90=0;
f7_135=0;
for i=0:ngl-1
    for j=0:ngl-1

```

```

    if p(i+1,j+1)==0
        p(i+1,j+1)=0.000001;
    end
    f7=p(i+1,j+1)*log(p(i+1,j+1))+f7;

    if p_45(i+1,j+1)==0
        p_45(i+1,j+1)=0.000001;
    end
    f7_45=p_45(i+1,j+1)*log(p_45(i+1,j+1))+f7_45;

    if p_90(i+1,j+1)==0
        p_90(i+1,j+1)=0.000001;
    end
    f7_90=p_90(i+1,j+1)*log(p_90(i+1,j+1))+f7_90;

    if p_135(i+1,j+1)==0
        p_135(i+1,j+1)=0.000001;
    end
    f7_135=p_135(i+1,j+1)*log(p_135(i+1,j+1))+f7_135;
end
end

% medidas de correlação
hx=0;
hx_45=0;
hx_90=0;
hx_135=0;
for i=1:ngl
    if px(i)==0
        px(i)=0.00001;
    end
    hx= -px(i)*log(px(i))+hx;

    if px_45(i)==0
        px_45(i)=0.00001;
    end
    hx_45= -px_45(i)*log(px_45(i))+hx_45;

    if px_90(i)==0
        px_90(i)=0.00001;
    end
    hx_90= -px_90(i)*log(px_90(i))+hx_90;

    if px_135(i)==0
        px_135(i)=0.00001;
    end
    hx_135= -px_135(i)*log(px_135(i))+hx_135;
end

hxy1=0;
hxy1_45=0;
hxy1_90=0;
hxy1_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        pcx1=px(i+1)*px(j+1);
        pcx1_45=(px_45(i+1)*px_45(j+1));
        pcx1_90=(px_90(i+1)*px_90(j+1));
        pcx1_135=(px_135(i+1)*px_135(j+1));
        if pcx1==0

```



```

        pcx1=0.0001;
    end
    hxy1=-(p(i+1,j+1)*log(pcx1))+hxy1;

    if pcx1_45==0
        pcx1_45=0.00001;
    end
    hxy1_45=-(p_45(i+1,j+1)*log(pcx1_45))+hxy1_45;

    if pcx1_90==0
        pcx1_90=0.00001;
    end
    hxy1_90=-(p_90(i+1,j+1)*log(pcx1_90))+hxy1_90;

    if pcx1_135==0
        pcx1_135=0.00001;
    end
    hxy1_135=-(p_135(i+1,j+1)*log(pcx1_135))+hxy1_135;
end
end

hxy2=0;
hxy2_45=0;
hxy2_90=0;
hxy2_135=0;
for i=0:ngl-1
    for j=0:ngl-1
        pcx2=px(i+1)*px(j+1);
        pcx2_45=(px_45(i+1)*px_45(j+1));
        pcx2_90=(px_90(i+1)*px_90(j+1));
        pcx2_135=(px_135(i+1)*px_135(j+1));

        if pcx2==0
            pcx2=0.00001;
        end
        hxy2= -(px(i+1)*px(j+1))*log(pcx2)+hxy2;
        if pcx2_45==0
            pcx2_45=0.00001;
        end
        hxy2_45= -(px_45(i+1)*px_45(j+1))*log(pcx2_45)+hxy2_45;

        if pcx2_90==0
            pcx2_90=0.00001;
        end
        hxy2_90= -(px_90(i+1)*px_90(j+1))*log(pcx2_90)+hxy2_90;

        if pcx2_135==0
            pcx2_135=0.00001;
        end
        hxy2_135= -(px_135(i+1)*px_135(j+1))*log(pcx2_135)+hxy2_135;
    end
end

f10=0;
f10_45=0;
f10_90=0;
f10_135=0;
f10=(f7-hxy1)/hx;
f10_45=(f7_45-hxy1_45)/hx_45;
f10_90=(f7_90-hxy1_90)/hx_90;
f10_135=(f7_135-hxy1_135)/hx_135;

```

```

% salva o resultado da imagem
salva=[f1 f1_45 f1_90 f1_135 f2 f2_45 f2_90 f2_135 f3 f3_45 f3_90
f3_135 f4 f4_45 f4_90 f4_135 f5 f5_45 f5_90 f5_135 f6 f6_45 f6_90
f6_135 f7 f7_45 f7_90 f7_135 f10 f10_45 f10_90 f10_135];
fed=fopen('0717h3i4b68c256.txt','a');
fprintf(fed,'%10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t
%10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t
%10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t
%10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\t
%10.4f\t %10.4f\t %10.4f\t %10.4f\t %10.4f\n',salva);
fclose(fed);
end

```

## Apêndice D

### **Código-fonte do algoritmo implementado no MATLAB, para o classificador estatístico baseado nos parâmetros texturais das imagens.**

```
%Classificador estatístico
%formacao das classes das amostra 1 a 300 na direcao 0,com 200
repeticoes
%randonicamente selecionadas
% lendo o arquivo que contem os numeros randonicos para cada classe
clear
na=900;
nt=na/3;
% lendo arquivo de parametros texturais de cada classe
z1=xlsread(strcat('c:\novatese\classif\exv\ilc.xls'));
z2=xlsread(strcat('c:\novatese\classif\exv\ill.xls'));
z3=xlsread(strcat('c:\novatese\classif\exv\ilp.xls'));
z4=xlsread(strcat('c:\novatese\classif\exv\ilt.xls'));
z5=xlsread(strcat('c:\novatese\classif\exv\ilz.xls'));

z1=z1'; z2=z2';z3=z3';z4=z4';z5=z5';
x1=z1(1:4:32,:);x2=z2(1:4:32,:);x3=z3(1:4:32,:);x4=z4(1:4:32,:);x5=z5(
1:4:32,:);

clear z1 z2 z3 z4 z5;

PT1=[];P1=[];
PT2=[];P2=[];
PT3=[];P3=[];
PT4=[];P4=[];
PT5=[];P5=[];

in=[];ind=[];
rand('state',sum(100*clock));
ind = rand([1,nt]);
ind = round(ind*(na-1));
ind = sort(ind)+1;
% retirada dos indices repetitivos
j=1;
in(1)=ind(1);
PT1=[x1(:,in(1))];          PT2=[x2(:,in(1))];          PT3=[x3(:,in(1))];
PT4=[x4(:,in(1))]; PT5=[x5(:,in(1))];
```

```

P1=[x1(:,1:in(1)-1)];P2=[x2(:,1:in(1)-1)];P3=[x3(:,1:in(1)-
1)];P4=[x4(:,1:in(1)-1)];
P5=[x5(:,1:in(1)-1)];

for i=1:nt-1
    if ind(i+1) ~= ind (i)
        j=j+1;
        in(j)=ind(i+1);
        PT1=[PT1 x1(:,in(j))]; PT2=[PT2 x2(:,in(j))]; PT3=[PT3
x3(:,in(j))]; PT4=[PT4 x4(:,in(j))];
        PT5=[PT5 x5(:,in(j))];
        P1=[P1 x1(:,in(j-1)+1:in(j)-1)];P2=[P2 x2(:,in(j-1)+1:in(j)-
1)];P3=[P3 x3(:,in(j-1)+1:in(j)-1)];
        P4=[P4 x4(:,in(j-1)+1:in(j)-1)];P5=[P5 x5(:,in(j-1)+1:in(j)-1)];
    end
end
P1=[P1 x1(:,in(j)+1:na)];P2=[P2 x2(:,in(j)+1:na)];P3=[P3
x3(:,in(j)+1:na)];P4=[P4 x4(:,in(j)+1:na)];
P5=[P5 x5(:,in(j)+1:na)];
% criando a matriz de vetores de teste t a partir de 100 repeticoes
c=[];
t=[];
% atribuindo as classes 1 a 5 na matriz de classes c
c(:, :, 1)=P1';
c(:, :, 2)=P2';
c(:, :, 3)=P3';
c(:, :, 4)=P4';
c(:, :, 5)=P5';
% Atribuindo os vetores de teste na matriz de testes t
t(:, :, 1)=PT1';
t(:, :, 2)=PT2';
t(:, :, 3)=PT3';
t(:, :, 4)=PT4';
t(:, :, 5)=PT5';
% excluindo as variaveis x
clear x1 x2 x3 x4 x5 P1 P2 P3 P4 P5 PT1 PT2 PT3 PT4 PT5;
% Fazendo a media das classes
mc1=mean(c(:, :, 1))';
mc2=mean(c(:, :, 2))';
mc3=mean(c(:, :, 3))';
mc4=mean(c(:, :, 4))';

```

```

mc5=mean(c(:, :, 5))';
% Covariancia das classes
C1=cov(c(:, :, 1));
C2=cov(c(:, :, 2));
C3=cov(c(:, :, 3));
C4=cov(c(:, :, 4));
C5=cov(c(:, :, 5));
% Log do determinante das matrizes de covariancia
detC1=log(det(C1));
detC2=log(det(C2));
detC3=log(det(C3));
detC4=log(det(C4));
detC5=log(det(C5));
% matriz inversa da covariancia
C1in=inv(C1);
C2in=inv(C2);
C3in=inv(C3);
C4in=inv(C4);
C5in=inv(C5);
% iniciando a função de decisao
class=[]; % matriz resultado das classificações dos blocos
for j=1:5
    for i=1:size(t,1)
        d1=-0.5*detC1-0.5*(t(i, :, j) '-mc1)' *C1in*(t(i, :, j) '-mc1);
        d2=-0.5*detC2-0.5*(t(i, :, j) '-mc2)' *C2in*(t(i, :, j) '-mc2);
        d3=-0.5*detC3-0.5*(t(i, :, j) '-mc3)' *C3in*(t(i, :, j) '-mc3);
        d4=-0.5*detC4-0.5*(t(i, :, j) '-mc4)' *C4in*(t(i, :, j) '-mc4);
        d5=-0.5*detC5-0.5*(t(i, :, j) '-mc5)' *C5in*(t(i, :, j) '-mc5);
        d=[d1 d2 d3 d4 d5];
        [Y,I]=max(d);
        class_il_exv(i,j)=I;
        salva=class_il_exv(i,j);
        fed=fopen('il_exv.txt', 'a');
        fprintf(fed, '%2.0f\n', salva);
        fclose(fed);
    end
end
%separando as classes
c=class_il_exv(:,1);
l=class_il_exv(:,2);
pic=class_il_exv(:,3);

```

```
tim=class_il_exv(:,4);
m=class_il_exv(:,5);
%gerando a matriz de classificacao
classm_il_exv=[sum(c==1) sum(c==2) sum(c==3) sum(c==4) sum(c==5)
               sum(l==1) sum(l==2) sum(l==3) sum(l==4) sum(l==5)
               sum(pic==1) sum(pic==2) sum(pic==3) sum(pic==4) sum(pic==5)
               sum(tim==1) sum(tim==2) sum(tim==3) sum(tim==4) sum(tim==5)
               sum(m==1) sum(m==2) sum(m==3) sum(m==4) sum(m==5)];
save classm_il_exv;
classm_il_exv
```

## Apêndice E

### **Código-fonte do algoritmo implementado no MATLAB, para o classificador neuronal**

```
clear
na=900;
nt=270;

% lendo arquivo de parametros texturais de cada classe
z1=xlsread(strcat('c:\novatese\classif\mono\ilc.xls'));
z2=xlsread(strcat('c:\novatese\classif\mono\ill.xls'));
z3=xlsread(strcat('c:\novatese\classif\mono\ilp.xls'));
z4=xlsread(strcat('c:\novatese\classif\mono\ilt.xls'));
z5=xlsread(strcat('c:\novatese\classif\mono\ilz.xls'));
z1=z1'; z2=z2'; z3=z3'; z4=z4'; z5=z5';
x1=z1(1:4:32,:); x2=z2(1:4:32,:); x3=z3(1:4:32,:); x4=z4(1:4:32,:); x5=z5(
1:4:32,:);

clear z1 z2 z3 z4 z5;

PT1=[]; P1=[];
PT2=[]; P2=[];
PT3=[]; P3=[];
PT4=[]; P4=[];
PT5=[]; P5=[];

in=[]; ind=[];
rand('state',sum(100*clock));
ind = rand([1,nt]);
ind = round(ind*(na-1));
ind = sort(ind)+1;
% retirada dos indices repetitivos
j=1;
in(1)=ind(1);
PT1=[x1(:,in(1))]; PT2=[x2(:,in(1))]; PT3=[x3(:,in(1))];
PT4=[x4(:,in(1))]; PT5=[x5(:,in(1))];
P1=[x1(:,1:in(1)-1)]; P2=[x2(:,1:in(1)-1)]; P3=[x3(:,1:in(1)-
1)]; P4=[x4(:,1:in(1)-1)];
```

```

P5=[x5(:,1:in(1)-1)];
for i=1:nt-1
    if ind(i+1) ~= ind (i)
        j=j+1;
        in(j)=ind(i+1);
        PT1=[PT1 x1(:,in(j))]; PT2=[PT2 x2(:,in(j))]; PT3=[PT3
x3(:,in(j))]; PT4=[PT4 x4(:,in(j))];
        PT5=[PT5 x5(:,in(j))];
        P1=[P1 x1(:,in(j-1)+1:in(j)-1)];P2=[P2 x2(:,in(j-1)+1:in(j)-
1)];P3=[P3 x3(:,in(j-1)+1:in(j)-1)];
        P4=[P4 x4(:,in(j-1)+1:in(j)-1)];P5=[P5 x5(:,in(j-1)+1:in(j)-1)];

    end
end
P1=[P1 x1(:,in(j)+1:na)];P2=[P2 x2(:,in(j)+1:na)];P3=[P3
x3(:,in(j)+1:na)];P4=[P4 x4(:,in(j)+1:na)];
P5=[P5 x5(:,in(j)+1:na)];

p=[P1 P2 P3 P4 P5];
%criando a resposta do treinamento
control=size(p,2)/5;
p_r=zeros(5,size(p,1));
for i=1:5
    p_r(i,(i-1)*control+1:(i-1)*control+control)=1;
end

t=[PT1 PT2 PT3 PT4 PT5];
% criando a resposta de teste
control=size(t,2)/5;
t_r=zeros(5,size(t,1));
for i=1:5
    t_r(i,(i-1)*control+1:(i-1)*control+control)=1;
end

clear P1 P2 P3 P4 P5 PT1 PT2 PT3 PT4 PT5 x1 x2 x3 x4 x5
%arquitetura da rede
mseant=10000;
n1=10;
n2=5;
% criar, treinar e encontrar a melhor arquitetura da rede
mm=minmax(p);

```



```

for i=1:5
    i
net=newff([mm],[n1,n2,5],{'tansig','tansig','logsig'},'trainrp');
net.trainParam.epochs=1000;
net.trainParam.show=100;
[net,tr]=train(net,p,p_r);
r_s=sim(net,t);
e_tr=sqrt((r_s-t_r).^2);
mseatual=mean(e_tr(:));
if mseatual<mseant
    mseant=mseatual;
    save nn10_5_i1;
end
end
clear net tr;
% testando a rede
load nn10_5_i1;
r_s=sim(net,t);
[y,in]=max(r_s,[],1);
%separando as classes
c=in(1:(size(in,2)/5));
l=in((size(c,2))+1:(size(c,2)*2));
pic=in((size(c,2)*2)+1:(size(c,2)*3));
tim=in((size(c,2)*3)+1:(size(c,2)*4));
m=in((size(c,2)*4)+1:(size(c,2)*5));
%gerando a matriz de classificaçao
class10_5_i1=[sum(c==1) sum(c==2) sum(c==3) sum(c==4) sum(c==5)
    sum(l==1) sum(l==2) sum(l==3) sum(l==4) sum(l==5)
    sum(pic==1) sum(pic==2) sum(pic==3) sum(pic==4) sum(pic==5)
    sum(tim==1) sum(tim==2) sum(tim==3) sum(tim==4) sum(tim==5)
    sum(m==1) sum(m==2) sum(m==3) sum(m==4) sum(m==5)];
save class10_5_i1;
class10_5_i1
mseant

```